

UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS

FRANCISCO RODRIGUES LIMA JUNIOR

Avaliação da adequabilidade de redes neurais artificiais e sistemas
neuro-*fuzzy* no apoio à predição de desempenho de cadeias de
suprimento baseada no SCOR[®]

São Carlos

2016

FRANCISCO RODRIGUES LIMA JUNIOR

Avaliação da adequabilidade de redes neurais artificiais e sistemas
neuro-*fuzzy* no apoio à predição de desempenho de cadeias de
suprimento baseada no SCOR[®]

Tese de doutorado apresentada ao Programa de
Pós-Graduação em Engenharia de Produção
como parte dos requisitos para obtenção do
título de Doutor em Engenharia de Produção

Área de Concentração: Gestão de Processos e
Operações

Orientador: Prof. Tit. Luiz Cesar Ribeiro
Carpinetti

São Carlos

2016

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTA TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

L732a LIMA JUNIOR, FRANCISCO RODRIGUES
Avaliação da adequabilidade de redes neurais artificiais e sistemas neuro-fuzzy no apoio à predição de desempenho de cadeias de suprimento baseada no SCOR® / FRANCISCO RODRIGUES LIMA JUNIOR; orientador Luiz Cesar Ribeiro Carpinetti. São Carlos, 2016.

Tese (Doutorado) - Programa de Pós-Graduação em Engenharia de Produção e Área de Concentração em Processos e Gestão de Operações -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2016.

1. Predição de desempenho. 2. modelo SCOR®. 3. redes neurais artificiais. 4. sistemas neuro-fuzzy. 5. gestão de cadeias de suprimento. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **FRANCISCO RODRIGUES LIMA JUNIOR.**

Título da tese: "Avaliação da adequabilidade de redes neurais artificiais e sistemas neuro-fuzzy no apoio à predição de desempenho de cadeias de suprimento baseada no SCOR®".

Data da defesa: 02.12.2016.

Comissão Julgadora:

Resultado:

Prof. Titular **Luiz Cesar Ribeiro Carpinetti**
(Orientador)
(Escola de Engenharia de São Carlos/EESC)

APROVADO

Prof. Dr. **Gilberto Miller Devós Ganga**
(Universidade Federal de São Carlos/UFSCar)

Aprovado

Prof. Dr. **Kleber Francisco Espôsto**
(Escola de Engenharia de São Carlos/EESC)

Aprovado

Profa. Dra. **Solange Oliveira Rezende**
(Instituto de Ciências Matemáticas e de Computação/ICMC)

APROVADO

Prof. Dr. **Lauro Osiro**
(Universidade Federal do Triângulo Mineiro/UFTM)

Aprovado

Coordenador do Programa de Pós-Graduação em Engenharia de
Produção
Prof. Associado **Aldo Roberto Ometto**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Luís Fernando Costa Alberto**

AGRADECIMENTOS

Agradeço ao meu orientador, Dr. Luiz C. R. Carpinetti, pela orientação exemplar que me foi dedicada em atividades de pesquisa e ensino ao longo de 6 anos, pela parceria na elaboração de artigos e pela amizade e compreensão.

Aos ilustres professores Dr. Gilberto Miller Devós Ganga, Dr. Kleber Esposto, Dr. Lauro Osiro e Dra. Solange Oliveira Rezende, por todas as contribuições sugeridas para a melhoria desta tese.

À CAPES, pelo financiamento desta pesquisa.

Ao professor Dr. Ivan Nunes Silva, pelas suas excelentes aulas de redes neurais artificiais e sistemas *fuzzy*, que foram essenciais para a realização desta pesquisa.

Ao Murilo, que muito cordialmente revisou o texto e me ajudou no ajuste das referências.

Às secretárias do departamento de Engenharia de Produção da EESC-USP e a todos os demais servidores da USP que contribuíram diretamente ou indiretamente para a realização do meu trabalho.

Aos meus professores da Universidade Estadual de Maringá-PR (UEM).

À minha família, especialmente aos meus pais, Francisco e Geralda.

A todos os amigos de Maringá-PR, Montes Claros-MG e São Carlos-SP.

Aos meus amigos e colegas de trabalho do Centro Universitário da Fundação Educacional Guaxupé (UNIFEG).

Aos amigos da pós-graduação.

À Nina e à Lola.

RESUMO

LIMA JUNIOR, F. R. **Avaliação da adequabilidade de redes neurais artificiais e sistemas neuro-fuzzy no apoio à predição de desempenho de cadeias de suprimento baseada no SCOR®**. 2016. 298 f. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

Sistemas de predição de desempenho de cadeias de suprimento são constituídos por indicadores que visam estimar o desempenho da empresa-foco em decorrência também do desempenho dos indicadores dos fornecedores. Na literatura são encontrados apenas dois modelos quantitativos (GANGA; CARPINETTI, 2011; AGAMI; SALEH; RASMY, 2014) que permitem prever o desempenho de cadeias de suprimento usando os indicadores do modelo SCOR® (*Supply Chain Operations Reference*). Uma limitação de ambos modelos é a dificuldade de se ajustar ao ambiente de uso, uma vez que sua implementação e atualização requerem a parametrização manual de muitas regras de decisão. Tanto o uso de redes neurais quanto de sistemas neuro-fuzzy têm o potencial de contornar essa dificuldade por utilizarem um mecanismo de aprendizagem que possibilita a adaptação ao ambiente de uso usando dados numéricos. Todavia, na literatura não são encontradas aplicações dessas técnicas no apoio à predição de desempenho de cadeias de suprimento, tampouco estudos que discutam qual dessas técnicas se mostra mais adequada para lidar com este problema. Diante disso, o objetivo desta pesquisa é construir e avaliar a adequabilidade de dois sistemas de predição de desempenho, ambos baseados nos indicadores do modelo SCOR®, mas usando alternativamente as técnicas redes neurais e sistemas neuro-fuzzy, para apoiar a gestão de desempenho da empresa-foco e de sua cadeia imediata. A execução desta pesquisa envolveu o uso de simulação computacional e de testes estatísticos. Os resultados mostram que, embora ambas as técnicas apresentem capacidade de predição satisfatória, as redes neurais são mais adequadas em relação à complexidade da definição da configuração topológica, enquanto os sistemas neuro-fuzzy se sobressaíram em relação à capacidade de predição, complexidade do treinamento, quantidade de variáveis de entrada, suporte à tomada de decisão sob incerteza e interpretabilidade dos dados. Outros resultados desta pesquisa estão relacionados à identificação de particularidades do processo de modelagem das técnicas avaliadas, à elaboração de um panorama sobre o uso de técnicas quantitativas na avaliação de desempenho de cadeias de suprimento e à identificação de algumas oportunidades de pesquisa.

Palavras-chave: Predição de desempenho; modelo SCOR®; redes neurais artificiais; sistemas neuro-fuzzy; gestão de cadeias de suprimento.

ABSTRACT

LIMA JUNIOR, F. R. **Evaluation of the adequability of artificial neural network and neuro-fuzzy systems to deal with supply chain performance prediction based on SCOR[®]**. 2016. 298 f. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

Supply chain performance prediction systems are composed by indicators that aim to estimate the performance of a focal company considering also indicators related to their suppliers. There are two quantitative models in the literature (GANGA; CARPINETTI, 2011; AGAMI; SALEH; RASMY, 2014) that enable to predict the supply chain performance using the indicators proposed by the SCOR[®] model (Supply Chain Operations Reference). Nevertheless, there is a drawback of both models that refers to the difficulty in adapting to the environment of use, since implementation and updating of these models require parameterization of many decision rules that must be done by an expert. The application of artificial neural networks as well as neuro-fuzzy systems can overcome this drawback by using a learning mechanism that enables the adaptation to the environment of use using numerical data on supply chain performance. However, there are neither studies in the literature that propose the use of these techniques in order to support supply chain performance prediction nor studies that discuss which of these techniques seem to be more appropriate to deal with this problem. Thus, the objective of this study is to propose and evaluate the adequability of the two types of performance prediction systems based on the performance indicators of the SCOR[®] model, and both using alternatively artificial neural networks and neuro-fuzzy systems to support performance management of a focal company and their supply chain. The implementation of this research involved the use of computer simulation and statistical tests. The results show that although both techniques present a satisfactory predictive capacity, neural networks are more appropriate in relation to the complexity of defining the topological configuration, whereas the neuro-fuzzy systems are more adequate regarding the predictive capacity, complexity of the training, amount of input variables, support to decision-making under uncertainty and interpretability of data. Other results of this research refer to the identification of characteristics of the modeling process of the evaluated techniques, as well as to the review on the use of quantitative techniques for supply chain performance evaluation and to the identification of some research opportunities.

Keywords: Performance prediction; SCOR[®] model; artificial neural networks; neuro-fuzzy systems; supply chain management.

LISTA DE ILUSTRAÇÕES

Figura 1 - Estrutura de uma cadeia de suprimento	21
Figura 2 – Etapas e principais atividades componentes desta pesquisa	32
Figura 3 - Evolução da medição de desempenho como campo do conhecimento	38
Figura 4 - Relacionamento causal entre determinantes do desempenho e resultados de um negócio	46
Figura 5 - Estrutura de rede de uma cadeia de suprimento	48
Figura 6 - Integração e gestão dos processos de negócio ao longo de uma cadeia de suprimento.....	49
Figura 7 - Modelo de gestão de cadeia de suprimento proposto por Cooper, Lambert e Pagh (1997).....	51
Figura 8 - Framework para análise de sistemas de medição de desempenho de cadeias de suprimento.....	57
Figura 9 - Etapas de uma metodologia para condução de benchmarking entre cadeias de suprimento.....	58
Figura 10 - Principais processos de gestão do modelo SCOR®	61
Figura 11 - Organização hierárquica dos processos de negócio do modelo SCOR®	62
Figura 12 - Métricas de avaliação de desempenho propostas pelo modelo SCOR®	64
Figura 13 - Sistema de medição de desempenho preditivo	68
Figura 14 - Quantidade de estudos por ano de publicação	73
Figura 15 - Quantidade de estudos por país de origem	73
Figura 16 - Quantidade de estudos por periódico de origem.....	75
Figura 17 - Listagem de técnicas identificadas e frequência de uso	83
Figura 18 – Abordagens utilizadas pelos modelos analisados para lidar com incerteza.....	84
Figura 19 – Fonte dos indicadores de desempenho utilizados nos modelos analisados	85
Figura 20 - Fonte dos dados para quantificação do desempenho da(s) cadeia(s) avaliada em cada modelo	85
Figura 21 - Aplicações reais de acordo com o setor da cadeia de suprimento	86
Figura 22 - Abordagens utilizadas para validação dos modelos	87
Figura 23 - Exemplo de rede neural biológica (a) e de uma rede neural artificial (b)	94
Figura 24 - Estrutura de um neurônio biológico.....	97
Figura 25 - Etapas de variação do potencial de ação do neurônio	98

Figura 26- Estrutura de um neurônio artificial	98
Figura 27 - Funções de ativação do tipo degrau bipolar (a), linear (b), logística (c) e tangente hiperbólica (d)	100
Figura 28 - Arquitetura feedforward de camada simples (a) e feedforward de camadas múltiplas (b)	101
Figura 29 - Arquiteturas recorrente (a) e arquitetura reticulada (b)	102
Figura 30 - Estrutura de uma rede PMC com duas camadas intermediárias	106
Figura 31 - Fluxo dos dados em uma rede PMC durante as duas fases do backpropagation.	108
Figura 32 - Minimização do erro quadrático médio ao longo do processo de treinamento ...	109
Figura 33 - Minimização do erro quadrático médio usando o algoritmo backpropagation ...	110
Figura 34 - Minimização do erro quadrático médio usando o método de inserção de termo de momentum	117
Figura 35 - Exemplo de uma rede PMC aplicada em problemas de aproximação funcional	119
Figura 36 - Exemplo de uma função a ser mapeada por uma rede PMC	120
Figura 37 - Exemplo de processo de mapeamento de uma função por uma rede PMC	120
Figura 38 - Método de validação cruzada usando amostragem aleatória	125
Figura 39 - Método de validação cruzada usando amostragem aleatória	126
Figura 40 - Método de validação cruzada por unidade	126
Figura 41 - Exemplo de pontos de mínimos locais na função erro	128
Figura 42 - Aplicação de um PMC no mapeamento de uma função seno	129
Figura 43 - Técnica para normalização das amostras usadas na rede	130
Figura 44 - Domínio de normalização para a função de ativação logística	130
Figura 45 - Comportamento de um PMC operando em situação de overfitting	131
Figura 46 - Número <i>fuzzy</i> triangular	134
Figura 47 - Número <i>fuzzy</i> trapezoidal	135
Figura 48 - Número <i>fuzzy</i> com função do tipo gaussiana	135
Figura 49 - Exemplo de escala linguística composta por números <i>fuzzy</i> triangulares	136
Figura 50 – Estrutura do sistema de inferência proposto Mamdani e Assilian (1975)	137
Figura 51 - Exemplo de regra de inferência das arquiteturas de Mamdani e Assilian (a) e de Takagi e Sugeno (b)	138
Figura 52 - Exemplo de sistema de inferência	139
Figura 53 - Agregação do conjunto <i>fuzzy</i> \tilde{A} e do conjunto B para gerar o conjunto resultante C de acordo com os operadores produto algébrico (c), produto drástico (d), Einstein t-norma (e), produto Hamacher (f), mínimo (g), Lukasiewicz t-norma (h), soma	

drástica (i), Einstein t-conorma (j), Lukasiewicz t-conorma (k), soma probabilística (l) e máximo (m)	143
Figura 54 - Exemplo de estrutura de um ANFIS	150
Figura 55 - Exemplo de particionamento das variáveis de entrada em um sistema ANFIS ..	150
Figura 56 – Regras de inferência em um sistema ANFIS	151
Figura 57 – Representação do funcionamento de um sistema ANFIS	152
Figura 58 - Modelo proposto para apoiar a previsão de desempenho de cadeias de suprimento	163
Figura 59 - Estrutura do sistema de previsão de desempenho	166
Figura 60 – Etapas de aplicação da técnica de validação cruzada na modelagem das redes PMC	170
Figura 61 – Etapas de aplicação da técnica de validação cruzada na modelagem dos sistemas ANFIS	172
Figura 62 – Representação do particionamento do conjunto de amostras utilizado neste estudo	177
Figura 63 - Minimização do erro quadrático médio (MSE) do modelo PMC 1.....	180
Figura 64 - Minimização do erro quadrático médio (MSE) do modelo PMC 2.....	182
Figura 65 - Minimização do erro quadrático médio (MSE) do modelo PMC 3.....	184
Figura 66 - Minimização do erro quadrático médio (MSE) do modelo PMC 4.....	186
Figura 67 – Minimização do erro quadrático médio (MSE) do modelo PMC 5.....	188
Figura 68 – Minimização do erro quadrático médio (MSE) do modelo PMC 6.....	190
Figura 69 – Minimização do erro quadrático médio (MSE) do modelo PMC 7.....	192
Figura 70 – Processo de minimização do erro (RMSE) do modelo ANFIS 1	200
Figura 71 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 1	200
Figura 72 – Processo de minimização do erro (RMSE) do modelo ANFIS 2	202
Figura 73 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 2	203
Figura 74 – Processo de minimização do erro (RMSE) do modelo ANFIS 3	205
Figura 75 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 3	205
Figura 76 – Processo de minimização do erro (RMSE) do modelo ANFIS 4	207
Figura 77 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 4	207

Figura 78 – Processo de minimização do erro (RMSE) do modelo ANFIS 5	209
Figura 79 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 5	209
Figura 80 – Processo de minimização do erro (RMSE) do modelo ANFIS 6	211
Figura 81 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 6	211
Figura 82 – Processo de minimização do erro (RMSE) do modelo ANFIS 7	213
Figura 83 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 7	213
Figura 84 – Diagrama de influências entre elementos referentes aos modelos de predição ANFIS	246
Figura 85 – Diagrama de influências entre elementos relativos aos modelos de predição PMC	247
Figura 86 – Base de regras ajustada do modelo de predição ANFIS 7	252
Figura 87 – Funções de pertinência de duas variáveis do modelo ANFIS 3 após o treinamento	253
Figura 88 – Gráficos de superfície de resposta dos modelos de predição ANFIS 3 (a) e ANFIS 7 (b).....	255

LISTA DE QUADROS

Quadro 1 – Exemplos de <i>frameworks</i> para medição de desempenho organizacional.....	40
Quadro 2 - Atributos de desempenho do modelo SCOR®	63
Quadro 3 – Modelos de avaliação de desempenho baseados nos indicadores do SCOR®	66
Quadro 4 - Resultados da busca e seleção de modelos usando a <i>string</i> “ <i>supply chain performance evaluation</i> ”	71
Quadro 5 – Modelos de avaliação de desempenho de cadeias de suprimento coletados no <i>Science Direct</i>	78
Quadro 6 – Modelos de avaliação de desempenho de cadeias de suprimento coletados no <i>Emerald</i>	79
Quadro 7 – Modelos de avaliação de desempenho de cadeias de suprimento coletados no <i>IEEEExplore</i>	79
Quadro 8 – Modelos de avaliação de desempenho de cadeias de suprimento coletados no <i>Scopus</i>	80
Quadro 9 – Modelos de avaliação de desempenho de cadeias de suprimento coletados no <i>Google Scholar</i>	81
Quadro 10 – Classificação dos modelos quantitativos de avaliação de cadeias de suprimento	82
Quadro 11 - Aplicações de redes PMC em problemas de predição	107
Quadro 12 - Algoritmo usado durante o treinamento de uma rede PMC.....	115
Quadro 13 - Algoritmo usado na fase de operação de uma rede PMC	115
Quadro 14 - Aspectos a serem definidos na modelagem de uma rede PMC.....	122
Quadro 15 - Passos da técnica de validação cruzada.....	124
Quadro 16 - Algoritmo do sistema de inferência proposto por Mamdani e Assilian (1975) .	146
Quadro 17 - Algoritmo do sistema de inferência proposto por Takagi e Sugeno (1985).....	146
Quadro 18 – Listagem de aplicações de sistemas ANFIS	149
Quadro 19 - Passos algorítmicos da fase de treinamento de um ANFIS.....	154
Quadro 20 - Passos algorítmicos da fase de uso de um ANFIS	155
Quadro 21 - Aspectos a serem definidos na modelagem de sistemas ANFIS.....	157
Quadro 22 - Estudos comparativos envolvendo redes PMC e sistemas ANFIS	161
Quadro 23 – Detalhamento das variáveis de entrada e saída do sistema de predição de desempenho	167

Quadro 24 – Topologias candidatas definidas para os modelos baseados em redes PMC	174
Quadro 25 – Alternativas avaliadas para definição da configuração topológica dos sistemas ANFIS	195
Quadro 26 – Descrição do teste t emparelhado	221
Quadro 27 – Definições necessárias à modelagem de sistemas de previsão PMC e ANFIS ..	241
Quadro 28 – Número de parâmetros adaptativos dos modelos de previsão PMC e ANFIS e tempo consumido no ajuste destes parâmetros	242
Quadro 29 – Síntese dos resultados da avaliação da complexidade do processo de modelagem dos sistemas de previsão PMC e ANFIS	244
Quadro 30 – Síntese de algumas informações sobre os modelos PMC e ANFIS	245
Quadro 31 – Síntese dos resultados da avaliação da adequabilidade dos modelos PMC e ANFIS	257
Quadro A1 – Detalhamento do indicador <i>total cost to serve</i> e de seus indicadores componentes	282
Quadro A2 – Detalhamento do indicador <i>return on working capital</i> e de seus indicadores componentes	283
Quadro A3 – Detalhamento do indicador <i>cash-to-cash cycle time</i> e de seus indicadores componentes	284
Quadro A4 – Detalhamento do indicador <i>order fulfillment cycle time</i> e de seus indicadores componentes	285
Quadro A5 – Detalhamento do indicador <i>perfect order fulfillment</i> e de seus indicadores componentes	286
Quadro A6 – Detalhamento do indicador <i>overall value at risk (VAR)</i> e de seus indicadores componentes	286
Quadro A7 – Detalhamento do indicador <i>upside supply chain flexibility</i> e de seus indicadores componentes	288
Quadro A8 – Detalhamento do indicador <i>upside supply chain adaptability</i> e de seus indicadores componentes	290
Quadro A9 – Detalhamento do indicador <i>downside supply chain adaptability</i> e de seus indicadores componentes	291
Quadro A10 – Detalhamento do indicador <i>return on supply chain fixed assets</i> e de seus indicadores componentes	292

LISTA DE TABELAS

Tabela 1 - Quantidade de amostras utilizadas nos modelos de predição PMC	173
Tabela 2 - Resultados obtidos pelas topologias candidatas ao modelo PMC 1.....	179
Tabela 3 - Resultados obtidos pelas topologias candidatas ao modelo PMC 2.....	181
Tabela 4 - Resultados obtidos pelas topologias candidatas ao modelo PMC 3.....	183
Tabela 5 - Resultados obtidos pelas topologias candidatas ao modelo PMC 4.....	185
Tabela 6 - Resultados obtidos pelas topologias candidatas ao modelo PMC 5.....	186
Tabela 7 - Resultados obtidos pelas topologias candidatas ao modelo PMC 6.....	188
Tabela 8 - Resultados obtidos pelas topologias candidatas ao modelo PMC 7.....	190
Tabela 9 - Síntese dos resultados da implementação computacional dos modelos PMC.....	192
Tabela 10 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 1..	199
Tabela 11 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 2..	201
Tabela 12 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 3..	204
Tabela 13 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 4..	206
Tabela 14 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 5..	208
Tabela 15 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 6..	210
Tabela 16 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 7..	212
Tabela 17- Síntese dos resultados da implementação computacional dos modelos ANFIS	214
Tabela 18 - Descrição dos testes de hipótese realizados	221
Tabela 19 - Resultados dos testes de predição do indicador <i>total cost to serve</i>	222
Tabela 20 - Resultado do teste de hipótese 1	223
Tabela 21 - Resultado do teste de hipótese 2.....	224
Tabela 22 - Resultado do teste de hipótese 3.....	224
Tabela 23 - Resultados dos testes de predição usando os modelos PMC 2 e ANFIS 2	225
Tabela 24 - Resultado do teste de hipótese 4.....	226
Tabela 25 - Resultado do teste de hipótese 5.....	226
Tabela 26 - Resultado do teste de hipótese 6.....	226
Tabela 27 - Resultados dos testes de predição do indicador <i>return on working capital</i>	227
Tabela 28 - Resultado do teste de hipótese 7.....	228

Tabela 29 - Resultado do teste de hipótese 8.....	229
Tabela 30 - Resultado do teste de hipótese 9.....	229
Tabela 31 - Resultados dos testes de predição do indicador <i>cash-to-cash cycle time</i> ...	230
Tabela 32 - Resultado do teste de hipótese 10.....	231
Tabela 33 - Resultado do teste de hipótese 11.....	231
Tabela 34 - Resultado do teste de hipótese 12.....	231
Tabela 35 - Resultados dos testes de predição do indicador <i>order fulfillment cycle time</i>	232
Tabela 36 - Resultado do teste de hipótese 13.....	233
Tabela 37 - Resultado do teste de hipótese 14.....	233
Tabela 38 - Resultado do teste de hipótese 15.....	234
Tabela 39 - Resultados dos testes de predição do indicador <i>perfect order fulfillment</i> ..	234
Tabela 40 - Resultado do teste de hipótese 16.....	235
Tabela 41 - Resultado do teste de hipótese 17.....	236
Tabela 42 - Resultado do teste de hipótese 18.....	236
Tabela 43 - Resultados dos testes de predição do indicador <i>overall value at risk</i>	237
Tabela 44 - Resultado do teste de hipótese 19.....	238
Tabela 45 - Resultado do teste de hipótese 20.....	238
Tabela 46 - Resultado do teste de hipótese 21.....	238
Tabela 47 - Resultados obtidos quanto à capacidade de predição de desempenho.....	239

LISTA DE ABREVIATURAS E SIGLAS

ANFIS	Adaptive-Network-based Fuzzy Inference System
BSC	Balanced Scorecard
EQM	Erro Quadrático Médio
IA	Inteligência Artificial
LMS	Least Mean Square (método dos mínimos quadrados)
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MBE	Mean Bias Error
MSE	Mean Square Error (ou erro quadrático médio)
PMC	Perceptron de Múltiplas Camadas
R	Índice de Correlação Linear
RMSE	Root Mean Square Error (ou raiz do erro quadrático médio)
RNA	Redes Neurais Artificiais
SCC	Supply Chain Council
SCOR [®]	Supply Chain Operations Reference

SUMÁRIO

CAPÍTULO 1: INTRODUÇÃO	21
1.1 CONTEXTUALIZAÇÃO	21
1.2 CARACTERIZAÇÃO DO TEMA DE PESQUISA	22
1.3 DELIMITAÇÃO DO PROBLEMA DE PESQUISA	28
1.4 DECLARAÇÃO DO OBJETIVO.....	28
1.5 RELEVÂNCIA DA PESQUISA	29
1.6 PROCEDIMENTOS METODOLÓGICOS.....	31
1.6.1 Caracterização da pesquisa.....	31
1.6.2 Etapas da pesquisa.....	32
1.6.3 Materiais utilizados	33
1.6.4 Procedimentos para obtenção dos dados	33
1.6.5 Procedimentos para análise dos resultados.....	34
1.7 ESTRUTURA DA TESE.....	34
CAPÍTULO 2: GESTÃO DE DESEMPENHO DE CADEIAS DE SUPRIMENTO	37
2.1 BREVE HISTÓRICO DA MEDIÇÃO DE DESEMPENHO	37
2.2 MEDIÇÃO DE DESEMPENHO	39
2.3 GESTÃO DE DESEMPENHO	43
2.4 GESTÃO DE DESEMPENHO NO CONTEXTO DE CADEIAS DE SUPRIMENTO.....	47
2.4.1 Gestão de cadeias de suprimento.....	47
2.4.2 Gestão de desempenho baseada na avaliação de cadeias de suprimento	54
2.4.3 O modelo SCOR®	60
2.5 PREDIÇÃO DE DESEMPENHO.....	67
2.6 MODELOS QUANTITATIVOS PARA AVALIAÇÃO DE DESEMPENHO DE CADEIAS DE SUPRIMENTO	70
2.6.1 Procedimentos de busca e seleção dos estudos	70
2.6.2 Origem dos estudos analisados.....	72
2.6.3 Características dos modelos	76
2.6.4 Aplicação e validação dos modelos.....	86
2.6.5 Análise crítica e oportunidades de pesquisa	87

CAPÍTULO 3: MODELAGEM DE SISTEMAS INTELIGENTES	91
3.1 APRESENTAÇÃO DO CAPÍTULO.....	91
3.2 BREVE HISTÓRICO DA INTELIGÊNCIA ARTIFICIAL.....	91
3.3 REDES NEURAIS ARTIFICIAIS	94
3.3.1 O neurônio artificial	97
3.3.2 Arquiteturas de redes neurais artificiais	101
3.3.3 Treinamento de redes neurais artificiais.....	103
3.4 REDES PERCEPTRON DE MÚLTIPLAS CAMADAS	105
3.4.1 O método de aprendizagem <i>backpropagation</i>	107
3.4.2 O uso de redes PMC como um aproximador funcional	118
3.4.3 Modelagem de redes PMC	121
3.4.4 Limitações de redes neurais artificiais.....	132
3.5 SISTEMAS DE INFERÊNCIA <i>FUZZY</i>	133
3.5.1 Fundamentos da teoria dos conjuntos <i>fuzzy</i>	133
3.5.2 Arquiteturas de sistemas de inferência <i>fuzzy</i>	136
3.5.3 Operações em sistemas de inferência <i>fuzzy</i>	140
3.5.4 Limitações de sistemas de inferência <i>fuzzy</i>	146
3.6 SISTEMAS DE INFERÊNCIA NEURO- <i>FUZZY</i>	148
3.6.1 Sistemas ANFIS	148
3.6.2 Treinamento de sistemas ANFIS	152
3.6.3 Modelagem de sistemas ANFIS	155
3.6.4 Limitações de sistemas ANFIS	159
3.7 ESTUDOS COMPARATIVOS ENTRE REDES PMC E ANFIS	160
CAPÍTULO 4: MODELOS PROPOSTOS PARA PREDIÇÃO DE DESEMPENHO.....	163
4.1 APRESENTAÇÃO DO MODELO TEÓRICO	163
4.2 IMPLEMENTAÇÃO COMPUTACIONAL DOS MODELOS BASEADOS EM REDES PMC	172
4.2.1 Organização das amostras	172
4.2.2 Definição das topologias candidatas aos modelos PMC	174
4.2.3 Planejamento do processo de treinamento dos modelos PMC.....	176
4.2.4 Resultados do treinamento e da validação dos modelos PMC	178

4.2.5 Síntese dos resultados da implementação computacional dos modelos PMC.....	192
4.3 IMPLEMENTAÇÃO COMPUTACIONAL DOS MODELOS BASEADOS EM ANFIS.....	194
4.3.1 Organização das amostras	194
4.3.2 Definição das topologias candidatas aos modelos ANFIS	194
4.3.3 Planejamento do processo de treinamento dos modelos ANFIS	197
4.3.4 Resultados do treinamento e da validação dos modelos ANFIS	198
4.3.5 Síntese dos resultados da implementação computacional dos modelos ANFIS ..	213
CAPÍTULO 5: AVALIAÇÃO DA ADEQUABILIDADE DOS MODELOS DE PREDIÇÃO	217
5.1 DEFINIÇÃO DOS PARÂMETROS DE AVALIAÇÃO.....	217
5.2 CAPACIDADE DE PREDIÇÃO DE DESEMPENHO	220
5.3 COMPLEXIDADE DO PROCESSO DE MODELAGEM	240
5.4 QUANTIDADE DE VARIÁVEIS DE ENTRADA	244
5.5 ADEQUAÇÃO A MUDANÇAS DAS MÉTRICAS E ALTERNATIVAS	248
5.6 MODELAGEM DE INCERTEZA	249
5.7 INTERPRETABILIDADE DOS DADOS.....	250
5.8 SÍNTESE DAS VANTAGENS E LIMITAÇÕES DOS MODELOS DE PREDIÇÃO	255
CAPÍTULO 6: CONCLUSÃO	261
6.1 CONCLUSÃO	261
6.2 DIFICULDADES ENCONTRADAS.....	266
6.3 LIMITAÇÕES DA PESQUISA.....	266
6.4 SUGESTÕES PARA PESQUISAS FUTURAS	267
REFERÊNCIAS	269
APÊNDICE A - DETALHAMENTO DOS INDICADORES DO SCOR®	281
APÊNDICE B – EQUAÇÕES DAS ESTATÍSTICAS USADAS NESTE ESTUDO	293
APÊNDICE C – EQUAÇÕES PARA O CÁLCULO DA QUANTIDADE DE PARÂMETROS ADAPTATIVOS DOS MODELOS PMC E ANFIS	294

APÊNDICE D – RECOMENDAÇÕES PARA O DESENVOLVIMENTO DE SISTEMAS DE PREDIÇÃO DE DESEMPENHO PMC.....	295
APÊNDICE E – RECOMENDAÇÕES PARA O DESENVOLVIMENTO DE SISTEMAS DE PREDIÇÃO DE DESEMPENHO ANFIS.....	297

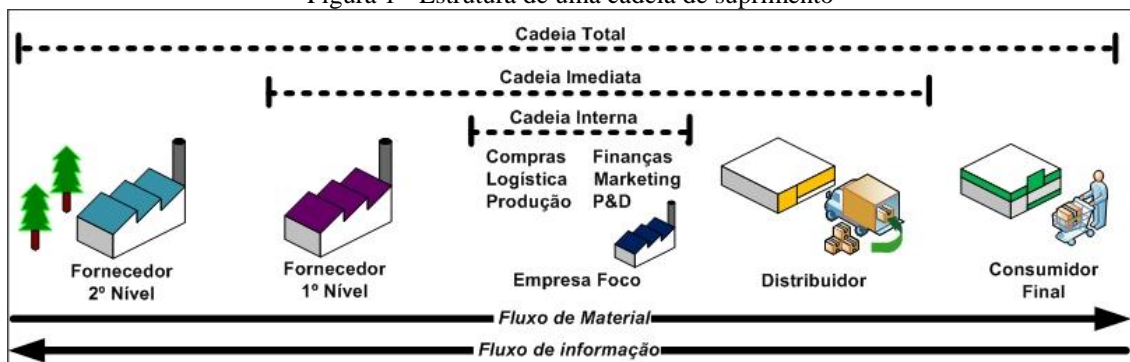
Capítulo 1

INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Uma cadeia de suprimento (ou *supply chain*) pode ser vista como um conjunto de processos de negócio integrados, que compreende todas as atividades associadas ao fluxo e à transformação de bens, desde o estágio de matéria-prima até a entrega do produto final ao consumidor (BEAMON, 1999; HANDFIELD; NICHOLS, 1999). Uma cadeia de suprimento não inclui apenas fabricantes e fornecedores, mas também engloba transportadoras, armazéns, varejistas e clientes. Conforme ilustra a Figura 1, enquanto uma cadeia interna se refere ao fluxo de materiais e informações entre departamentos, células ou setores de operação dentro da própria empresa, uma cadeia imediata compreende os fornecedores e clientes imediatos, chamados de elos de primeiro nível ou primeira camada. Já a cadeia total se refere a todas as cadeias imediatas que compõem um determinado setor industrial ou de serviços, podendo envolver os elos de segunda camada (os fornecedores de fornecedores ou os clientes de clientes), bem como outros elos de camadas superiores (SLACK, 2002).

Figura 1 - Estrutura de uma cadeia de suprimento



Fonte: Proposto pelo autor com base em Slack (2002).

De acordo com Mentzer et al. (2001), a gestão de uma cadeia de suprimento consiste na coordenação estratégica e sistêmica das funções de negócio tradicionais e de ações táticas numa companhia e através de seus negócios ao longo da cadeia, com o propósito de aprimorar o desempenho de longo prazo das companhias individualmente e da cadeia de suprimento como um todo. A gestão de cadeias de suprimento envolve o gerenciamento estratégico dos fluxos de bens, serviços, finanças e informações, bem como das relações entre as empresas. No ambiente de cadeias de suprimento, a gestão colaborativa tende a criar um efeito de sinergia, no qual a cadeia inteira passa a ser mais

efetiva do que a soma de suas partes individuais. Por isso, cabe às empresas criar mecanismos de coordenação visando estabelecer estratégias de gestão que promovam a melhoria sistêmica do desempenho da cadeia (MENTZER et al., 2001; ESTAMPE et al., 2013; SHAFIEE; LOTFI; SALEH, 2014).

Diversos estudos da literatura acadêmica vêm destacando a importância de se quantificar o desempenho de cadeias de suprimento para apoiar o planejamento de práticas de gestão e avaliar os resultados alcançados após a implantação destas (MARCHAND; RAYMOND, 2008; NUDURUPATI et al., 2011). A avaliação de desempenho de cadeias de suprimento envolve muitos atores que cooperam para alcançar determinados objetivos estratégicos e logísticos, por isso requer a adoção de indicadores relacionados a seus processos intra e inter organizacionais (LAPIDE, 2000; CHAN; QI, 2003). Além disso, são requeridas informações de desempenho atualizadas, integradas, dinâmicas e acessíveis, na tentativa de garantir uma tomada de decisão ágil e promover um estilo de gestão proativa (NUDURUPATI; BITITCI, 2005).

1.2 CARACTERIZAÇÃO DO TEMA DE PESQUISA

Na literatura relacionada à gestão de desempenho de cadeias de suprimento podem ser encontrados vários estudos que propõem modelos de apoio à avaliação de desempenho usando abordagens qualitativas (GUNASEKARAN; PATE; TIRTIROGLU, 2001; SARODE; SUNNAPWAR; KHODKE, 2008) e quantitativas (THEERANUPHATTANA; TANG, 2008; GANGA; CARPINETTI, 2011; AGAMI; SALEH; RASMY, 2014). Também há estudos que apresentam revisões sistemáticas das abordagens existentes (AKYUZ; ERKAN, 2010; BALFAQIH et al., 2016), discussões sobre os indicadores usados no processo de avaliação (BEAMON, 1999; GUNASEKARAN; PATE; TIRTIROGLU, 2001; SHEPHERD; GÜNTER, 2006; CUTHBERTSON; PIOTROWICZ, 2011) ou análises de alguns modelos de avaliação de desempenho existentes (KO, TIWARI; MEHNEN, 2010; ESTAMPE et al., 2013). A partir da revisão de dezenas de estudos encontrados na literatura, foram identificadas as seguintes características relativas aos modelos quantitativos de avaliação de desempenho de cadeias de suprimento:

- i. Uso de diferentes tipos de técnicas quantitativas:** As técnicas quantitativas usadas no desenvolvimento de novos modelos incluem métodos de tomada de decisão multicritério, de programação matemática, de simulação, técnicas estatísticas e de inteligência artificial. A aplicação de técnicas quantitativas à

avaliação de desempenho de cadeias de suprimento permite estimar o desempenho de uma ou mais cadeias de suprimento por meio da síntese dos valores obtidos em cada uma das métricas de desempenho adotadas. Algumas destas técnicas, como AHP - *Analytic Hierarchy Process* (CHO et al. 2012) e ANP - *Analytic Network Process* (YANG, 2012), também possibilitam atribuir níveis de importância relativa (pesos) aos indicadores, que determinam o quanto estes contribuem para o desempenho global de uma dada cadeia de suprimento;

ii. Avaliação de desempenho frequentemente restrita à cadeia imediata: Devido à dificuldade de se obter informações que possibilitem avaliar o desempenho de todos os elos que compõem uma determinada cadeia de suprimento, a maioria dos modelos quantitativos atuais são delimitados à cadeia de suprimento imediata, ou seja, avaliam o desempenho da empresa-foco e de seus clientes e fornecedores de primeira camada, sob a perspectiva da empresa-foco (BERRAH; CLIVILLE, 2007; YEH; CHEN; CHI, 2007; THEERANUPHATTANA; TANG, 2008; OLUGU; WONG, 2012; BEHROUZI; WONG, 2013; VINODH et al., 2013; ARIF-UZ-ZAMAN, AHSAN, 2014). Com uma frequência menor, há alguns estudos que consideram quatro ou mais elos (BAS, 2013, FATTAHI; NOOKABADI; KADIVAR, 2013, TAVANA et al., 2013, MIRHEDAYATIAN; AZADI; SAEN, 2014);

iii. Validação do modelo baseada somente na análise ou comparação dos resultados: A maioria dos estudos que propõe modelos quantitativos de avaliação de desempenho de cadeias de suprimento se limita a apresentar os resultados da aplicação em casos reais ou simulados, sem utilizar um método específico para validar o modelo proposto. Menos frequentemente, há modelos que são validados utilizando técnicas estatísticas (KUMAR; BANERJEE, 2014), métodos de análise de sensibilidade (GONG, 2008; HAGHIGHI; TORABI; GHASEMI, 2016) e comparação dos resultados com dados reais (HALMAN; VOORDIJK, 2012; KHAMSEH; ZAHMATKESH, 2015) ou com os resultados fornecidos por outras técnicas (YEH; CHEN; CHI, 2007; XIYAO; HANKUN, 2015). Não foram encontrados estudos que avaliem a adequação de técnicas quantitativas específicas quando aplicadas no apoio à avaliação ou à predição de desempenho de cadeias de suprimento, de modo a analisar o alinhamento entre as características da técnica adotada e os requisitos do domínio de problema em questão;

iv. Indicadores de desempenho definidos a partir da literatura acadêmica, da opinião de especialistas e de outros modelos: Os modelos da literatura predominantemente adotam indicadores de desempenho operacionais e / ou estratégicos baseando-se principalmente em outros estudos relacionados. Há também modelos que selecionam os indicadores a partir da opinião de especialistas (TAVANA et al., 2013; SHAFIEE; LOTFI; SALEH, 2014), geralmente funcionários de empresas ou acadêmicos. Com menor frequência, existem modelos que utilizam indicadores de desempenho do *Balaced Scorecard* (FAN et al., 2013; HAGHIGHI; TORABI; GHASEMI, 2016), que é um modelo criado para apoiar a avaliação de desempenho intraorganizacional, e do SCOR[®] – *Supply Chain Operations Reference* (GANGA; CARPINETTI, 2011; AGAMI; SALEH; RASMY, 2014; BUKHORI et al., 2015; ABOLGHASEMI et al., 2015), um modelo de referência mundialmente usado para apoiar a gestão, a avaliação e a comparação de cadeias de suprimento.

O desdobramento dos indicadores de desempenho do modelo SCOR[®] torna possível analisar o desempenho dos processos de planejamento, abastecimento, produção, entrega e retorno, ao longo dos elos de uma ou mais cadeias de suprimento. Ademais, nesse modelo, o relacionamento entre os indicadores de tendência e de resultado é explicitado quantitativamente, tornando possível a realização da predição de desempenho, ou seja, um diagnóstico prospectivo dos valores dos indicadores de resultado. O uso dos indicadores do SCOR[®] também possibilita a realização de *benchmarking* em nível mundial entre cadeias de suprimento usando a base de *benchmarking SCORmark*, o que auxilia as empresas na implementação de mudanças que levem a melhorias significativas nos seus produtos e processos, e conseqüentemente nos seus resultados de desempenho da cadeia (SHEPHERD; GÜNTER, 2006; UNAHABHOKHA; PLATTS; TAN, 2007; APICS, 2016). Apesar de existirem vários benefícios decorrentes da adoção dos indicadores de desempenho do modelo SCOR[®], a maioria dos modelos quantitativos de avaliação de desempenho de cadeias de suprimento utilizam um conjunto singular de indicadores, fazendo com que estes não sejam compatíveis para comparar os valores de desempenho alcançados com outras cadeias de suprimento em bases de *benchmarking* em nível mundial.

Dentre 93 estudos que propõem abordagens quantitativas para a avaliação de desempenho de cadeias de suprimento, somente 15 usam os indicadores do SCOR[®]. Entretanto, uma limitação que afeta a maioria dos modelos quantitativos baseados no

SCOR[®] é a impossibilidade de modelar as funções não lineares que representam os relacionamentos entre alguns indicadores de tendência e de resultado, já que tais modelos predominante são baseados em métodos de decisão multicritério que realizam uma combinação linear ponderada entre os valores dos indicadores de tendência para calcular os indicadores de resultado (CHAN; QI, 2003; SELLITO; MENDES, 2006; GOLPARVAR; SEIFBARGHY, 2009; JALALVAND et al., 2011; CLIVILLÉ; BERRAH, 2012; KOCAOGLU et al., 2013; BUKHORI et al., 2015; SELLITTO et al., 2015). Os modelos baseados em comparações par a par entre as alternativas limitam a quantidade de cadeias de suprimento que podem ser avaliadas simultaneamente (CHAN; QI, 2003; SELLITO; MENDES, 2006; THEERANUPHATTANA; TANG, 2008; CLIVILLÉ; BERRAH, 2012; YANG; JIANG, 2012; BUKHORI; WIDODO; ISMOYOWATI, 2015; SELLITTO et al., 2015). Além disso, os modelos baseados nas técnicas AHP (SELLITO; MENDES, 2006; BUKHORI; WIDODO; ISMOYOWATI, 2015; SELLITTO et al.; 2015) e TOPSIS (GOLPARVAR; SEIFBARGHY, 2009; KOCAOGLU; GÜLSÜN; TANYA, 2013) apresentam um problema conhecido como *ranking reversal*, que consiste na alteração dos resultados de desempenho das cadeias avaliadas quando novas alternativas são incluídas, causando uma inversão na ordenação relativa do desempenho das alternativas e comprometendo a consistência dos resultados.

Na literatura podem ser identificados dois modelos de avaliação de desempenho de cadeias de suprimento, baseados na combinação entre os indicadores do SCOR[®] e técnicas de inteligência artificial, que possuem uma abordagem preditiva a fim de estimar os valores futuros dos indicadores de resultado com base nos valores medidos ou estimados dos indicadores de tendência (GANGA; CARPINETTI, 2011; AGAMI; SALEH; RASMY, 2014). Ambos os modelos utilizam sistemas de inferência *fuzzy* do tipo Mamdani, o que permite incorporar à estrutura do modelo o conhecimento de especialistas a respeito das relações de causa e efeito entre os indicadores, utilizando regras de decisão parametrizadas por meio de julgamentos linguísticos. Embora esses modelos tenham apresentado contribuições significativas para a literatura deste tema, uma dificuldade de uso provém da necessidade de parametrização manual das variáveis de entrada e de saída usando conjuntos *fuzzy*, bem como do ajuste manual das dezenas ou até milhares de regras de decisão dos sistemas de inferência.

Dentre todos os modelos de avaliação de desempenho baseados no SCOR[®], nenhum é dotado de capacidades adaptativas, de modo a permitir o ajuste do modelo ao ambiente de uso a partir da leitura de dados históricos ou dados estimados de desempenho.

Por meio de buscas realizadas em bases de periódicos, foram localizados somente quatro estudos que propõem modelos dotados de aprendizagem para prever o desempenho de uma cadeia de suprimento. Três deles utilizam um tipo de sistema neuro-*fuzzy* denominado ANFIS (*Adaptive-Network-based Fuzzy Inference System*), que incorpora mecanismos de aprendizagem advindos de redes neurais artificiais à estrutura dos sistemas de inferência *fuzzy* (JANG, 1993). Durante o processo de treinamento desses sistemas, é apresentado ao modelo um conjunto de amostras dos valores dos indicadores com a finalidade de mapear o comportamento dos indicadores do ambiente de uso e armazená-lo na estrutura do sistema (DIDEHKHANI; JASSBI; PILEVARI, 2009). Após o treinamento, na fase de uso do modelo, a partir da apresentação de valores reais ou estimados para os indicadores de tendência, o modelo é capaz de prever o desempenho dos indicadores de resultado de uma ou mais cadeias de suprimento. Apesar de incrementarem novas funcionalidades aos modelos de avaliação de desempenho existentes, os três modelos ANFIS utilizam um conjunto de indicadores restrito a uma única dimensão de desempenho: Côrrea e Da Silveira (2012) avaliam a competitividade de cadeias de suprimento; Jassbi, Seyedhosseini e Pilevari (2010) avaliam a agilidade; e Didekhani, Jassbi e Pilevari (2009) avaliam a flexibilidade. Por apresentarem um escopo de avaliação limitado, esses modelos não são capazes de quantificar o desempenho de uma cadeia de suprimento considerando a diversidade de dimensões de desempenho e de processos de negócio envolvidos em cadeias de suprimento.

Além dos sistemas ANFIS, outro tipo de sistema dotado de mecanismos de aprendizagem supervisionada que vem sendo explorado na resolução de problemas reais de predição é um tipo de rede neural artificial denominado perceptron de múltiplas camadas (PMC, ou *Multilayer Perceptron*). Alguns exemplos de aplicação dessas redes em problemas de predição incluem a predição da demanda de itens em um supermercado (ABURTO; WEBER, 2007), predição do tamanho de porcos criados pelos fornecedores de uma indústria de processamento de carnes para apoiar decisões sobre a atribuição de pedidos de compra (APICHOTTANAKUL; PATHUMNAKUL; PIEWTHONGNGAM, 2012) e predição de resultados de negociações de preço de uma indústria química com seus fornecedores (MOOSMAYER et al., 2013).

A ampla aplicabilidade das redes PMC e sua capacidade de aproximação de funções não lineares contribuem para que este seja o tipo de rede neural mais usado na literatura (SILVA; SPATI, FLAUZINO, 2010; BILGEHAN, 2011; APICHOTTANAKUL; PATHUMNAKUL; PIEWTHONGNGAM, 2012). Apesar disso,

na literatura foi encontrado somente um modelo baseado em redes PMC voltado para avaliação de desempenho de cadeias de suprimento (FAN et al., 2013). Uma limitação desse estudo é o uso de indicadores do *Balanced Scorecard*, uma vez que este modelo foi originalmente desenvolvido para avaliação de desempenho intraorganizacional, sem considerar o ambiente de cadeias de suprimento (ESTAMPE et al., 2013). Outra limitação do modelo proposto por Fan et al. (2013) que também é válida para os modelos existentes baseados em ANFIS (DIDEHKHANI; JASSBI; PILEVARI, 2009; JASSBI; SEYEDHOSSEINI; PILEVARI, 2010; CÔRREA; DA SILVEIRA, 2012) vem do fato de utilizarem um conjunto singular de indicadores de desempenho, não sendo compatíveis para comparar os valores de desempenho estimados com os valores contidos em bases de *benchmarking* de nível global. Isso impossibilita a empresa-foco e sua cadeia imediata de compararem seus valores de desempenho com outras cadeias em nível mundial visando estimular a melhoria de desempenho e competitividade.

O desenvolvimento de novos modelos de predição a partir da combinação dos indicadores do modelo SCOR[®] com redes PMC ou com sistemas ANFIS poderia ajudar a superar todas as limitações relatadas nesta subseção, uma vez que traria contribuições como: a possibilidade de fazer uma avaliação prospectiva do desempenho de uma empresa-foco e sua cadeia imediata; o mapeamento do conhecimento sobre o problema e armazenamento na estrutura interna do sistema; a adaptação ao ambiente de uso usando dados reais ou estimados; a modelagem quantitativa dos relacionamentos de causa e efeito não lineares entre os indicadores de desempenho; a consideração de múltiplas dimensões de desempenho e; a capacidade de realizar *benchmarking* em nível global. Contudo, apesar da ampla utilização dessas técnicas na resolução de problemas de predição, na literatura acadêmica não são encontrados modelos que utilizem os indicadores do SCOR[®] com redes PMC nem com sistemas ANFIS. Tampouco são encontrados estudos que avaliem a adequabilidade destas técnicas quando aplicadas a esse domínio de problema.

Na literatura há estudos que comparam o desempenho de PMC e ANFIS quando aplicados na previsão de demanda em cadeias de suprimento (EFENDIGIL; ÖNUT; KAHARAMAN, 2012), na estimativa de pontuações de aplicações de crédito financeiro (AKKOÇ, 2012), na previsão de carga crítica em projetos estruturais (BILGEHAN, 2011), entre outros domínios de problema. Contudo, enquanto alguns estudos apontam que modelos ANFIS apresentam melhor desempenho na predição de resultados, outros concluem que modelos PMC são mais precisos. Conforme evidenciam os resultados dessas comparações, o desempenho e a adequação de cada técnica variam conforme as

características do problema modelado. Neste sentido, posto o grande potencial que ambas as técnicas possuem para apoiar a predição de desempenho de SC, a aplicação e a avaliação da adequabilidade de ANFIS e PMC considerando as particularidades deste domínio de problema se mostram uma oportunidade de pesquisa relevante.

1.3 DELIMITAÇÃO DO PROBLEMA DE PESQUISA

Diante da lacuna de pesquisa identificada, esta pesquisa busca responder ao seguinte questionamento: “Como os sistemas neuro-*fuzzy* ANFIS e as redes neurais artificiais PMC podem ser usados para apoiar a predição de desempenho de cadeias de suprimento baseada nos indicadores do SCOR[®]?”. A fim de melhor delinear o escopo deste estudo, a questão de pesquisa enunciada é desdobrada em três questionamentos:

- i. Quais são as configurações topológicas adequadas para a aplicação de modelos ANFIS e PMC na predição de desempenho de cadeias de suprimento baseada no SCOR[®]?
- ii. Como as características intrínsecas a cada uma destas técnicas podem ajudar e / ou dificultar a predição de desempenho de cadeias de suprimento?
- iii. Qual das técnicas apresenta melhor capacidade de predição, ou seja, qual delas consegue modelar mais precisamente as relações de causa e efeito entre os indicadores do SCOR[®]?

1.4 DECLARAÇÃO DO OBJETIVO

Tendo em vista as questões de pesquisas enunciadas, este projeto tem como objetivo principal: propor e avaliar a adequabilidade de dois tipos de modelo de apoio à tomada de decisão, construídos com base nos indicadores de desempenho do SCOR[®], sistemas ANFIS e redes PMC, para predizer o desempenho de uma empresa-foco situada em uma cadeia de suprimento. Para isso, são definidos os seguintes objetivos específicos:

- i. Caracterizar o estado da arte sobre o uso de modelos quantitativos para a avaliação de desempenho de cadeias de suprimento e estruturar um referencial teórico sobre os temas avaliação, predição e gestão de desempenho, gestão de cadeias de suprimento, modelo SCOR[®], redes neurais artificiais, sistemas de inferência *fuzzy* e sistemas ANFIS;
- ii. Desenvolver um modelo teórico baseado no SCOR[®] para predição de desempenho de cadeias de suprimento. O modelo teórico embasará a implementação

computacional de um conjunto de modelos baseados em ANFIS e de outro conjunto de modelos baseados em redes PMC;

iii. A partir das definições feitas no modelo teórico, implementar os modelos computacionais e treiná-los usando um método de aprendizagem supervisionado para selecionar a configuração topológica mais adequada para cada modelo;

iv. Comparar a capacidade de predição de desempenho dos modelos computacionais ANFIS e PMC a partir do uso de parâmetros de desempenho quantitativos selecionados da literatura;

v. Avaliar qualitativamente como as características dos sistemas ANFIS e das redes PMC podem contribuir ou dificultar a predição de desempenho de cadeias de suprimento.

Esta pesquisa se baseia na hipótese de que modelos computacionais dotados de aprendizagem supervisionada, baseados na combinação entre os indicadores do SCOR[®] com sistemas ANFIS e rede PMC, sejam capazes de predizer o desempenho de uma cadeia de suprimento visando apoiar a tomada de decisão para melhoria do desempenho da empresa-foco e de sua cadeia imediata. Os modelos de predição de desempenho se restringem à empresa-foco situada em uma cadeia imediata devido à dificuldade atual de se avaliar o desempenho de todos os elos que compõem uma cadeia de suprimento (GANGA, 2010). Essa dificuldade advém da complexidade de se desenvolver estratégias conjuntas, da disparidade de interesses, da falta de confiança entre os membros e da dificuldade de se obter informações de medição de todos os elos da cadeia (HWANG; LIN; LYU JR., 2008). Todavia, isso não impossibilita a avaliação do desempenho de uma cadeia imediata sob a perspectiva da empresa-foco. O uso do SCOR[®] mostra-se essencial para a estruturação dos modelos propostos, uma vez que oferece uma arquitetura de referência que engloba processos à jusante e à montante da empresa-foco, bem como um conjunto de indicadores capazes de avaliar aspectos associados à cadeia interna, aos fornecedores de primeira camada e clientes (GANGA, 2010; GANGA; CARPINETTI, 2011).

1.5 RELEVÂNCIA DA PESQUISA

A construção e avaliação da adequabilidade de modelos de predição de desempenho de cadeias de suprimento baseados em ANFIS e PMC permitirá avaliar o desempenho destas técnicas quando aplicadas a este domínio de problema. Essa discussão é especialmente útil para ajudar pesquisadores e desenvolvedores de soluções

automatizadas de tomada de decisão a escolher uma técnica adequada para aplicação nesse tipo de problema. Também será possível identificar particularidades do processo de modelagem e treinamento de modelos ANFIS e PMC.

A elaboração de modelos de previsão de desempenho que combinem os indicadores do SCOR[®] com ANFIS e redes PMC possibilitará quantificar o desempenho de uma cadeia de suprimento, fornecendo informações que permitirão analisar a lacuna entre o nível de desempenho existente e o nível desejado. Desta forma, esses modelos possibilitarão aos gestores maior oportunidade de conjecturar sobre a efetividade de suas estratégias e de identificar situações para a melhoria de desempenho da empresa-foco e de sua cadeia imediata.

Atualmente, uma barreira do presente tema de pesquisa consiste em explorar como os sistemas de avaliação de desempenho podem responder a mudanças no ambiente interno e externo (MARCHAND; RAYMOND, 2008; NUDURUPATI et al., 2011). Usando um mecanismo de aprendizagem supervisionada e amostras de valores dos indicadores, advindas do ambiente de uso, os modelos ANFIS e PMC permitirão o ajuste automático das relações de causa e efeito entre indicadores de tendência e indicadores de resultado, possibilitando a adaptação ao cenário em questão.

Diante da necessidade de competir em nível global, muitos autores também apontam para a necessidade de fazer *benchmarking* entre cadeias de suprimento em nível mundial (CHAN; QI, 2003; SIMATUPANG; SRIDHARAN, 2004; WONG; WONG, 2007; SAHU; DATTA; MAHAPATRA, 2014). Por utilizar os indicadores do SCOR[®], os modelos de previsão ANFIS e PMC permitirão comparar as estimativas de desempenho obtidas com valores de outras cadeias usando o *SCORmark*. A partir da constatação de deficiências nos valores dos indicadores de resultado, poderão ser elaborados planos de ações corretivas focados na melhoria dos índices de desempenho críticos, contribuindo assim para que a empresa-foco seja mais proativa na busca por melhores resultados.

Outra contribuição desta pesquisa consiste em um levantamento bibliográfico sobre o uso de técnicas quantitativas na avaliação de desempenho de cadeias de suprimento. Na literatura foram encontrados apenas dois artigos de revisão relacionados a esse assunto, sendo que um deles analisou modelos baseados em técnicas de inteligência artificial voltados para gestão de cadeias de suprimento (KO; TIWARI; MEHNEN, 2010), enquanto o outro analisou 83 modelos qualitativos e quantitativos de avaliação de desempenho de cadeias de suprimento, publicados entre 1996 e 2015 (BALFAQIH et al.,

2016). Contudo, esse estudo não analisa como os indicadores de desempenho são escolhidos; não investiga como são obtidos os dados para quantificar o desempenho da cadeia de suprimento; não identifica precisamente a frequência de uso de técnicas e os setores que vêm recebendo mais aplicações; e também não discutem sobre a capacidade de aprendizagem dos modelos nem a abordagem usada para a validação dos resultados. Desta forma, verifica-se a necessidade de ajudar a traçar um panorama do estado da arte deste tema de pesquisa.

Portanto, os resultados esperados deste estudo são:

- i. A construção e a avaliação da adequabilidade de dois conjuntos de modelos de predição de desempenho de cadeias de suprimento baseados no SCOR®;
- ii. Uma aplicação de redes neurais artificiais combinadas com os indicadores do modelo SCOR® na predição de desempenho de cadeias de suprimento, bem como uma aplicação de sistemas neuro-*fuzzy* combinados com os indicadores do SCOR® neste mesmo problema;
- iii. Uma discussão sobre a modelagem, treinamento e uso dos modelos preditivos propostos, destacando benefícios e limitações;
- iv. Uma revisão sistematizada da literatura acadêmica sobre o uso de técnicas quantitativas no apoio à avaliação de desempenho de cadeias de suprimento.

1.6 PROCEDIMENTOS METODOLÓGICOS

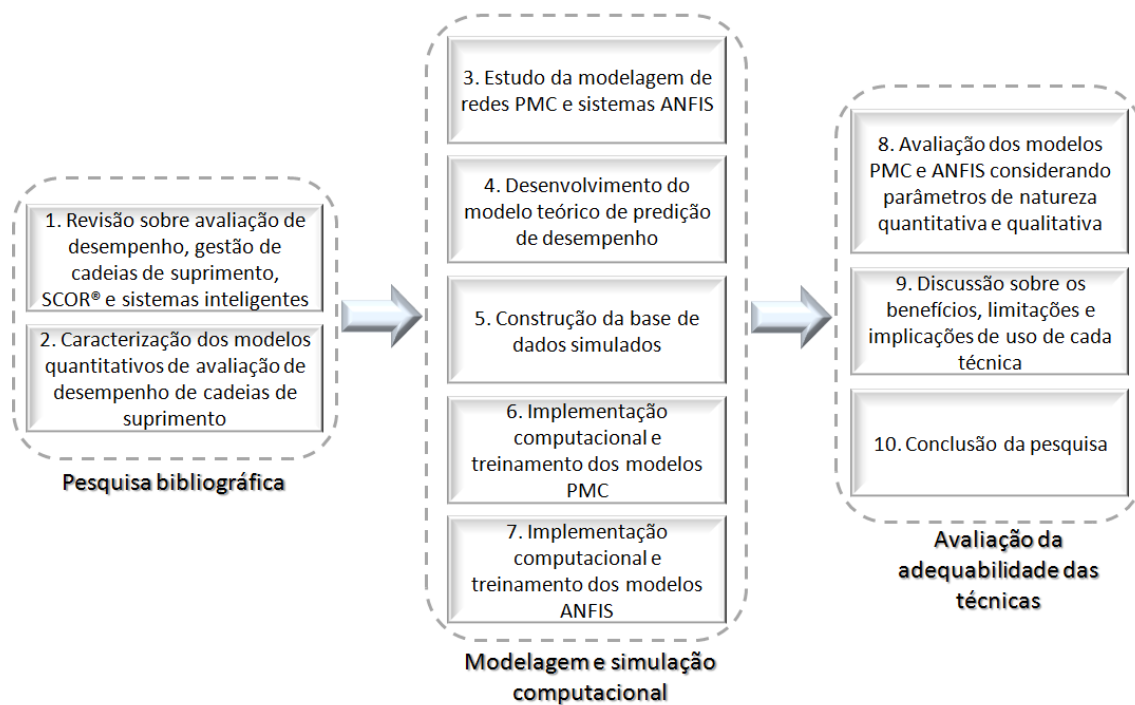
1.6.1 Caracterização da pesquisa

De acordo com a classificação proposta por Bertrand e Fransoo (2002), esta pesquisa pode ser caracterizada como uma pesquisa quantitativa empírica descritiva baseada em modelagem e simulação computacional. Segundo Bertrand e Fransoo (2002), esse tipo de pesquisa está interessado principalmente na criação de modelos que descrevam adequadamente os relacionamentos causais entre as variáveis representativas de domínio de problema específico. Bertrand e Fransoo (2002) complementam que o uso de relacionamentos causais e quantitativos entre variáveis ajuda a prever o estado futuro do processo modelado ao invés de somente explicar as observações feitas. Nesta pesquisa, tais variáveis são definidas pelo conjunto de indicadores de desempenho propostos pelo SCOR®, abrangendo os indicadores dos níveis 1 e 2, representadas na Figura 12 da Subseção 2.4.3 do Capítulo 2.

1.6.2 Etapas da pesquisa

Conforme ilustra a Figura 2, a execução desta pesquisa envolve três etapas: pesquisa bibliográfica; modelagem e simulação computacional; e avaliação da adequabilidade das técnicas redes PMC e ANFIS quando aplicadas à predição de desempenho de cadeias de suprimento.

Figura 2 – Etapas e principais atividades componentes desta pesquisa



Fonte: Proposto pelo autor.

A etapa de revisão bibliográfica visou criar um embasamento teórico que subsidiou a execução das etapas posteriores da pesquisa. Para isso, foram usados alguns livros e principalmente artigos de periódicos científicos internacionais sobre temas relacionados à avaliação, medição ou predição de desempenho organizacional e de cadeias de suprimento, bem como à modelagem, aplicação e comparação de redes neurais, sistemas de inferência *fuzzy* e sistemas de inferência *neuro-fuzzy*. Também foi realizada uma pesquisa bibliográfica sistematizada visando caracterizar os modelos quantitativos propostos na literatura para apoiar a avaliação de desempenho de cadeias de suprimento. Isso permitiu identificar limitações dos modelos existentes e apontar algumas lacunas de pesquisa relacionadas a esse tema.

A segunda etapa da pesquisa, de modelagem e simulação computacional, iniciou-se com o desenvolvimento de um modelo teórico para apoiar a predição de desempenho de cadeias de suprimento, que orientou a implementação computacional dos modelos

PMC e ANFIS. Esta etapa também compreendeu: o estudo da modelagem de redes PMC e sistemas ANFIS usando o *software* MATLAB; a construção de uma base de dados simulados, discutida na Subseção 1.6.4, contendo amostras de valores dos indicadores dos níveis 1 e 2 do modelo SCOR[®]; e a implementação computacional e o treinamento supervisionado dos modelos PMC e ANFIS com base na técnica de validação cruzada. A validação cruzada permitiu avaliar algumas topologias candidatas para cada um dos modelos de predição, com diferentes configurações estruturais e paramétricas, a fim de escolher a forma apropriada para as funções de pertinência das variáveis, os operadores adequados para o processo de inferência, as funções de ativação dos neurônios e o número de neurônios usados nas camadas intermediárias. Nessa etapa é selecionada a melhor configuração topológica dentre as avaliadas para cada um dos modelos de predição.

Na terceira etapa, referente à avaliação da adequabilidade das técnicas quando aplicadas a esse domínio de problema, a capacidade de predição de desempenho (ou de generalização de resultados) dos modelos PMC e ANFIS foi avaliada comparativamente, a partir do treinamento desses modelos e da realização de experimentos de predição de desempenho usando dados simulados. Além disso, nessa etapa os modelos baseados em redes PMC e sistemas ANFIS foram avaliados qualitativamente a fim de identificar vantagens, limitações e implicações de uso na predição de desempenho de cadeias de suprimento baseada no SCOR[®]. Por último, na conclusão deste estudo, foram identificadas as dificuldades e limitações da pesquisa e algumas sugestões para estudos futuros.

1.6.3 Materiais utilizados

Os materiais necessários à execução desta pesquisa são exclusivamente ferramentas computacionais. Para a construção dos modelos computacionais e simulação de uso, foi usado o *software* MATLAB[®]. Na análise de resultados da pesquisa, foi feito um tratamento estatístico dos dados utilizando o *software* Microsoft Excel.

1.6.4 Procedimentos para obtenção dos dados

O treinamento e a simulação de uso dos modelos de predição de desempenho propostos por este estudo requerem um amplo conjunto de amostras, composto por centenas de dados históricos ou de estimativas de desempenho de uma cadeia de suprimento em relação a todos os indicadores considerados. Diante da dificuldade de se obter dados reais, optou-se por simular os valores dos indicadores. Como o modelo

SCOR[®] fornece fórmulas e diretrizes para o cálculo dos indicadores do nível 1, foi possível criar uma base de dados usando uma planilha eletrônica composta por um conjunto de valores aleatórios, definidos no intervalo [0, 1], para as variáveis de entrada e saída dos sistemas de predição. Ressalta-se que o uso de dados normalizados não prejudica os resultados produzidos pelos modelos computacionais, uma vez que a normalização de amostras é uma prática frequentemente adotada para alinhar o universo de discurso das variáveis à região dinâmica das funções de ativação (SILVA; SPATTI; FLAUZINO, 2010).

1.6.5 Procedimentos para análise dos resultados

A análise dos resultados utilizou de técnicas estatísticas. Para quantificar e comparar a capacidade de predição dos modelos avaliados, foram usadas as estatísticas erro quadrático médio (*Mean Square Error*, MSE), raiz do erro quadrático médio (*Root Mean Square Error*, RMSE), erro médio absoluto (*Mean Absolute Error*, MAE) e índice de correlação linear de Pearson (R), cujas fórmulas estão detalhadas no Apêndice B. Também foram feitos testes de hipótese usando o teste *t* com amostras pareadas, a fim de verificar se existe diferença significativa entre os valores de desempenho esperados e os valores estimados por cada técnica (MONTGOMERY; RUNGER, 2009). Os testes de hipótese foram conduzidos usando o *software Microsoft Excel*.

1.7 ESTRUTURA DA TESE

Quanto à organização do texto, este estudo está dividido da seguinte forma:

- O Capítulo 2 apresenta uma revisão bibliográfica sobre assuntos relacionados à gestão de desempenho de cadeias de suprimento e ao modelo SCOR[®], analisando também os modelos quantitativos já existentes para avaliação e predição de desempenho de cadeias de suprimento;
- O Capítulo 3 revisa os principais conceitos relacionados à modelagem e ao funcionamento de três tipos de sistemas inteligentes: redes neurais artificiais, sistemas de inferência *fuzzy* e sistemas ANFIS, destacando também alguns estudos comparativos envolvendo tais técnicas.
- O Capítulo 4 apresenta o modelo teórico de predição de desempenho de cadeias de suprimento proposto por este estudo e os resultados da implementação computacional dos modelos PMC e ANFIS;

- O Capítulo 5 foca na avaliação da adequabilidade dos modelos desenvolvidos, discutindo vantagens, limitações e implicações de uso de cada técnica.
- Por último, o Capítulo 6 apresenta as conclusões, dificuldades encontradas, limitações da pesquisa e sugestões para estudos futuros.

Capítulo 2

GESTÃO DE DESEMPENHO DE CADEIAS DE SUPRIMENTO

2.1 BREVE HISTÓRICO DA MEDIÇÃO DE DESEMPENHO

Os principais estudos que embasam a teoria atual sobre medição de desempenho surgiram entre o final da década de 1980 e meados dos anos 1990. Neste período, muitos pesquisadores e gestores passaram a se interessar pelo tema, o que gerou uma grande quantidade de publicações relacionadas e promoveu o avanço da área. Neely (1999) estima que cerca de 3600 artigos sobre esse tema foram publicados entre 1994 e 1996. Desde então, a quantidade de estudos publicados por ano vem aumentando constantemente (FOLAN; BROWNE, 2005).

Apesar do desenvolvimento relativamente recente deste tema no âmbito acadêmico, a medição do desempenho de funcionários vem sendo praticada em algumas organizações desde o final do século XIX. Nessa época, o principal papel da medição de desempenho era autenticar a determinação dos salários e direcionar o comportamento dos funcionários para o alcance de metas específicas. Em algumas organizações, também já era praticada a medição detalhada de custos e receitas. Contudo, os gestores e os *stakeholders* obtinham pouca informação sobre o desempenho das operações da organização (DE WAAL, 2007).

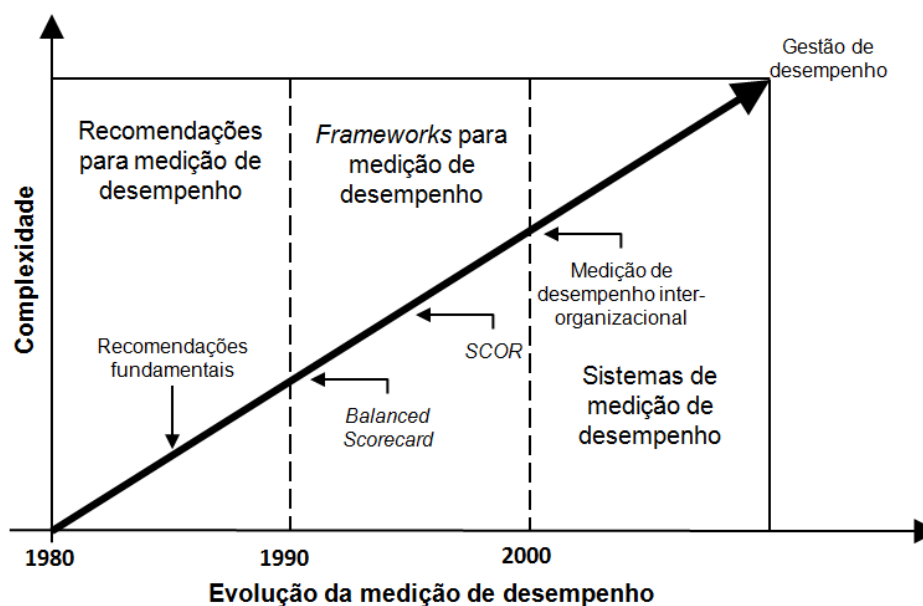
Já na década de 1920, a empresa Dupont, fabricante de produtos químicos, criou o conceito de retorno sobre o investimento (*Return On Investment - ROI*) e passou a medir o seu desempenho usando este indicador visando ao alcance de metas preestabelecidas, na tentativa de melhorar a eficiência de uso dos seus recursos. A partir da década de 1930, surgiram sistemas que integravam o controle de custos e a contabilidade gerencial. Após a segunda guerra mundial, como muitas organizações aumentaram a diversidade de produtos oferecidos e passaram a se organizar em estruturas multidivisionais, os sistemas de controle tradicionais, desenvolvidos inicialmente para organizações de manufatura com produção em massa, passaram a não ser apropriados para lidar com este aumento da complexidade organizacional (DE WAAL, 2007).

Nas décadas de 1960 e 1970, a necessidade de aperfeiçoar as práticas de gestão e de medição foi impulsionada pelos efeitos da globalização, que forçou as empresas a desenvolver uma orientação estratégica e a investir mais em qualidade e inovação com a finalidade de aumentar a competitividade e garantir a sobrevivência no mercado. Em 1979, surge o conceito de fator crítico de sucesso, que prega a existência de um número

limitado de áreas da empresa cujos resultados são determinantes dos níveis de desempenho. Sugeria-se que as atividades destas áreas mereciam maior atenção e deveriam ser continuamente medidas e gerenciadas por indicadores primários (*prime measures*), que ao longo do tempo passaram a ser chamados de KPIs - *Key Performance Indicators* (DE WAAL, 2007).

Conforme ilustra a Figura 3, ao longo da década de 1980 e começo da década de 1990, com base em experiências empresariais já existentes, a literatura passou a recomendar uma série de boas práticas para orientar a medição de desempenho intraorganizacional (FOLAN; BROWNE, 2005). Autores como Kaplan e Norton (1992) propunham que os sistemas de medição de desempenho balanceassem o uso de medidas internas e externas, bem como medidas financeiras e não financeiras. Identificava-se também a necessidade de alinhar os indicadores de desempenho adotados com os objetivos estratégicos da organização. Poucos anos depois, surgiram modelos (*frameworks*) de medição de desempenho em nível organizacional que incorporavam estes conceitos, destacando-se o *Balanced Scorecard* e o *Performance Prism*.

Figura 3 - Evolução da medição de desempenho como campo do conhecimento



Fonte: Folan e Browne (2005)

A partir do final dos anos 1990 e início dos 2000, surgiram os primeiros modelos que expandiram as fronteiras da medição de desempenho para o contexto interorganizacional. Em 1997, foi lançado o modelo de referência denominado SCOR[®], composto por diversos indicadores essencialmente voltados para a avaliação de cadeias de suprimento. Nos anos seguintes, modelos de medição de desempenho intraorganizacional passaram a ser adaptados para lidar com o contexto

interorganizacional. Alguns deles incrementavam dimensões interfuncionais e de parcerias estratégicas na cadeia à estrutura do modelo *Balanced Scorecard*. Outra contribuição importante para a literatura da área foi o surgimento do conceito de “gestão de desempenho”, que representa um processo mais amplo do que a medição de desempenho ao estimular a melhoria contínua organizacional visando ao alcance de determinadas metas (AMARATUNGA; BALDRY; SARSHAR, 2001).

Atualmente, as publicações relacionadas a esse tema continuam em alta e focam em temas bastante variados. Algumas pesquisas qualitativas propõem novos modelos para medição de desempenho, que costumam focar no âmbito organizacional, em arranjos produtivos locais ou em cadeias de suprimento. Outras pesquisas quantitativas propõem o uso de métodos de apoio à tomada de decisão multicritério e de técnicas de inteligência artificial para criar modelos com novas funcionalidades (por exemplo, representação e processamento dos valores dos indicadores em formato linguístico). Há também pesquisas focadas em casos de implantação de sistemas de medição de desempenho intraorganizacional (LOHMAN; FORTUIN; WOUTERS, 2004), nas causas de falhas na implantação e uso (BOURNE et al., 2002), na revisão e atualização dos indicadores (BRAZ; SCAVARDA; MARTINS, 2011), no desenvolvimento de sistemas de predição de desempenho (UNAHABHOKHA; PLATTS; TAN, 2007), na avaliação do desempenho de fornecedores (OSIRO, LIMA JUNIOR; CARPINETTI, 2014) e na predição de desempenho de cadeias de suprimento (GANGA; CARPINETTI, 2011). As subseções a seguir apresentam os principais conceitos e modelos voltados para a medição, predição e gestão de desempenho, com destaque para aqueles voltados para cadeias de suprimento.

2.2 MEDIÇÃO DE DESEMPENHO

O conceito de desempenho é definido por Neely, Gregory e Platts (1995) como a eficiência e a eficácia das ações (práticas de gestão) dentro de um contexto de negócio. Enquanto a eficácia se refere ao compromisso com o atendimento dos requisitos do cliente, a eficiência está relacionada a como os recursos da organização são usados para o alcance de níveis de satisfação dos clientes. Os mesmos autores complementam que a medição de desempenho consiste no processo de quantificar a eficiência e a eficácia das atividades de um negócio por meio de indicadores de desempenho (NEELY; GREGORY; PLATTS, 1995). Esses indicadores também costumam ser referenciados na literatura como métricas ou critérios de desempenho (LEBAS, 1995).

Outra definição de medição de desempenho é apresentada por De Waal (2007), que a conceitua como o processo de quantificação de ações passadas, sendo que as ações passadas determinam o desempenho atual da organização. De Waal (2007) também aponta que o uso do termo “medição” não é completamente apropriado porque o processo de medição em si não conduz automaticamente a melhorias no desempenho da organização, sendo somente o início de uma sequência de ações de gestão que visam à identificação e melhoria de fatores críticos de desempenho. Por isso, esse autor adota o uso do termo gestão de desempenho.

Como na literatura não parece haver um consenso sobre a diferenciação entre os termos “medição de desempenho” e “avaliação de desempenho”, neste estudo ambos os termos são usados para se referir à mesma prática. Já o termo “gestão de desempenho” é usado com um significado mais amplo, englobando a medição e a predição de desempenho.

Diversos estudos da literatura apresentam modelos de referência (*frameworks*) para medição do desempenho intraorganizacional, os quais são compostos por indicadores bastante distintos entre si. Outra diferença é que enquanto alguns modelos são de natureza procedimental e apresentam um conjunto de passos para condução do processo de medição, outros consistem em uma estrutura baseada em dimensões de dimensões de desempenho focadas em diferentes processos de negócio da organização (ESTAMPE et al., 2013). O Quadro 1 apresenta exemplos de alguns desses modelos.

Quadro 1 – Exemplos de *frameworks* para medição de desempenho intraorganizacional

Nome	Autores	Tipologia	Dimensões de desempenho
<i>Balanced Scorecard</i>	Kaplan e Norton (1992)	Estrutural	Perspectiva financeira, de clientes, do negócio e de aprendizado e crescimento
<i>Performance Prism</i>	Neely, Adams e Kennerly (2002)	Estrutural	Satisfação dos <i>stakeholders</i> , estratégias, processos, capacidades e contribuição dos <i>stakeholders</i>
<i>Performance Pyramid</i>	Lynch e Cross (1991a)	Estrutural	Visão, mercado, financeiro, satisfação de clientes, flexibilidade, produtividade, qualidade, entrega, tempo de ciclo e desperdício
Modelo dos dez passos	Lynch e Cross (1991b)	Procedural	Não utiliza
Modelo para pequenas e médias empresas	Hudson, Lean e Smart (2001)	Procedural	Não utiliza

Fonte: Proposto pelo autor.

Os *frameworks* de medição de desempenho são operacionalizados nas organizações por meio da implantação e uso de sistemas de medição de desempenho. Esses sistemas são constituídos por indicadores de desempenho, *software* com base de dados e procedimentos que medem o desempenho das ações de gestão e apoiam processos de tomada de decisão por meio da coleta, compilação, análise e disseminação de dados e informações de valor para a organização (LOHMAN; FORTUIN; WOUTERS, 2004). Entre os benefícios decorrentes da adoção de sistemas de medição de desempenho, estão o melhor monitoramento e controle do desempenho organizacional, a capacidade de identificar áreas que precisam de atenção, o estímulo à motivação dos funcionários, a melhoria da comunicação e o fortalecimento de responsabilidades na organização (NUDURUPATI et al., 2011).

Muitas recomendações são apontadas na literatura para orientar o projeto, a implantação, o uso e a atualização de sistemas de medição de desempenho (NEELY et al., 2000; FOLAN; BROWNE, 2005). Algumas delas são:

- O desenvolvimento do sistema deve envolver os funcionários da organização;
- O sistema de medição de desempenho deve ter o suporte da alta gestão da empresa;
- Ser baseado nas relações entre indicadores de desempenho, onde o resultado de uma medida seja uma consequência de algumas outras;
- Devem ser estabelecidas rotinas para que os indicadores possam ser medidos;
- Os indicadores de desempenho devem estar sob o controle da unidade operacional avaliada;
- Deve possuir uma interface amigável e permitir aos gestores visualizar o desempenho em várias áreas simultaneamente;
- As informações devem ser apresentadas de maneira clara, usando diagramas, gráficos ou outros recursos que facilitem a visualização;
- Deve medir o desempenho de todo o sistema de entrega do produto, desde o fornecedor até o cliente final;
- O desempenho deve ser relatado diariamente ou semanalmente;
- Ser atualizado ao longo do tempo (conforme as mudanças da organização);
- Deve haver foco na evolução do sistema de medição, melhoria contínua e aprendizagem.

A seleção dos indicadores de desempenho é discutida por diversos estudos por ser uma atividade crítica para a efetividade do sistema de medição de desempenho. A ausência de um conjunto de indicadores adequados dificulta o planejamento e o controle

das operações, fazendo com que não seja possível medir se os objetivos organizacionais estão sendo alcançados (BRAZ; SCAVARDA; MARTINS, 2011). Algumas diretrizes para a escolha de um conjunto de indicadores adequados são listadas a seguir (KAPLAN; NORTON, 1992; FOLAN; BROWNE, 2005):

- Os indicadores devem estar alinhados com a estratégia e com os objetivos organizacionais;
- Devem abranger os níveis tático e operacional da organização;
- Devem focar nas atividades que são críticas para o desempenho organizacional;
- Os indicadores devem ser escolhidos por meio de discussões com as pessoas envolvidas (clientes, gestores e funcionários);
- Um número reduzido de medidas deve ser escolhido;
- O foco da medição deve ser os processos de gestão do negócio, não os grupos de trabalho individuais;
- Devem ser selecionados indicadores perceptíveis aos clientes;
- Devem ser selecionadas medidas financeiras e não financeiras;
- Os indicadores devem tornar possível a comparação entre empresas do mesmo negócio.

Além da escolha de indicadores, o desenvolvimento e a implantação de um sistema de medição de desempenho também requer que sejam definidos o significado de cada indicador, a unidade de medida, o valor meta almejado, a frequência de medição, o responsável pela medição, a origem dos dados a serem coletados, o responsável pela coleta de dados, a fórmula de cálculo e a frequência de revisão do indicador (NEELY et al., 2000; LOHMAN; FORTUIN; WOUTERS, 2004; BRAZ; SCAVARDA; MARTINS, 2011).

Uma vez selecionados os indicadores de desempenho, conforme ocorrem mudanças no ambiente em que a empresa está inserida, a necessidade de mudar a estratégia empresarial pode implicar na revisão e atualização dos indicadores de desempenho usados. A atualização periódica é especialmente importante para empresas inseridas em mercados turbulentos. Os indicadores devem ser atualizados de modo a alinhá-los com o ambiente, a cultura, a estrutura e a estratégia organizacional (MELNYK et al., 2014). Melnyk et al. (2014) sugerem o uso do método Delphi para identificar as tendências emergentes no ambiente de negócio e explorar como estas tendências poderão afetar o futuro do sistema de medição de desempenho.

Embora haja diversos estudos que relatem casos de implantação bem sucedidos de sistemas de medição de desempenho, também existem relatos de casos de implantação

mal sucedidos, cujas causas geralmente são semelhantes. Os fatores apontados comumente na literatura como sendo barreiras para a implantação e uso de sistemas de medição de desempenho incluem (NEELY; GREGORY; PLATTS, 1995; BOURNE et al., 2002; NUDURUPATI et al., 2011):

- Adoção de grande número de medidas, difíceis de serem gerenciadas;
- Informações limitadas no escopo do sistema de medição (foco no desempenho financeiro);
- Dificuldade de medir resultados que são qualitativos por natureza;
- Muito tempo e investimento requeridos para análise de dados;
- Informações que não dão suporte à avaliação em todos os níveis gerenciais e funções da organização (foco em dados operacionais);
- Ausência de processos para garantir disponibilidade contínua de dados relevantes;
- Falta de uma plataforma de tecnologia da informação adequada;
- Falta de comprometimento da alta gestão da organização;
- Dados armazenados em diferentes formatos e em diferentes locais da organização, sendo que alguns podem estar ocultos e outros duplicados.

A partir dessa listagem de complicadores para a implantação e uso de sistemas de medição de desempenho, verifica-se que a maioria destes está relacionada a falhas no projeto do sistema de medição, ao baixo esforço investido por funcionários e pela gestão da empresa e à ausência de processos de gestão que garantam a disponibilidade de dados e que estimulem a melhoria organizacional (NUDURUPATI et al., 2011). Na tentativa de fortalecer a importância de combinar a medição de desempenho com a adoção de práticas de gestão que estimulem a melhoria contínua dos processos organizacionais, muitos pesquisadores da área adotam o termo “gestão de desempenho” em suas pesquisas, incorporando ao processo de medição de desempenho uma série de atividades de planejamento de ações, execução, controle e correção que visam aumentar o desempenho organizacional (AMARATUNGA; BALDRY; SARSHAR, 2001).

2.3 GESTÃO DE DESEMPENHO

O principal objetivo da gestão de desempenho é estimular a melhoria contínua dos processos organizacionais a fim de alcançar metas de desempenho predeterminadas para cada indicador. Empresas como Xerox, Dupont, General Electric, Hewlett-Packard, Johnson & Johnson, Motorola, Pepsico e Wal-mart consideram que a prática da gestão de desempenho é um dos fatores-chave de seu sucesso de mercado (DE WAAL, 2007).

Segundo Amaratunga, Baldry e Sarshar (2001), a gestão de desempenho deve usar as informações do sistema de medição de desempenho para gerar mudanças de efeito positivo na cultura organizacional e nos processos de gestão. Alguns dos benefícios que decorrem da gestão de desempenho nas organizações são (DE WAAL, 2007; MELNYK et al., 2014):

- O suporte ao planejamento das atividades;
- O incentivo a uma cultura voltada ao desempenho;
- O desenvolvimento de relacionamentos construtivos e abertos entre gestores e seus funcionários por meio do diálogo contínuo;
- A criação de uma visão compartilhada entre os funcionários;
- O reconhecimento do trabalho de equipes por meio de incentivos e bonificações;
- O estímulo ao desenvolvimento das habilidades individuais e ao aprendizado contínuo;
- Um melhor aproveitamento das competências dos funcionários em prol da organização;
- A obtenção de mais informações para apoiar a tomada de decisão e justificar os investimentos;
- A facilitação da implementação de novas estratégias;
- A melhoria do desempenho organizacional.

Para conduzir a gestão de desempenho nas organizações, é necessário: (1) estabelecer indicadores de desempenho agregados (compostos a partir de outros indicadores) e respectivas metas de desempenho; (2) desenvolver planos de ação visando à resolução de problemas, à melhoria dos níveis de desempenho e ao alcance dos objetivos organizacionais; (3) alocar e priorizar a aplicação de recursos e; (4) quando necessário, mudar políticas que estejam sendo utilizadas na tentativa de alcançar as metas propostas (AMARATUNGA; BALDRY; SARSHAR, 2001).

De Waal (2007) ressalta que os gestores têm o papel de criar os planos de ação e de garantir que estes planos estejam sendo implantados efetivamente. Para isso, os funcionários envolvidos em cada um dos processos do negócio devem ser comunicados claramente sobre a estratégia, as ações planejadas, os indicadores a serem medidos, os procedimentos para medi-los e as metas a serem alcançadas em cada indicador.

Durante e após a execução das atividades dos planos de ação, os resultados de interesse devem ser coletados e registrados no sistema de medição. Para cada indicador usado, devem ser estabelecidos os procedimentos e sistemas para apoiar a criação e a coleta de dados. Também devem ser instituídos procedimentos para a conversão desses

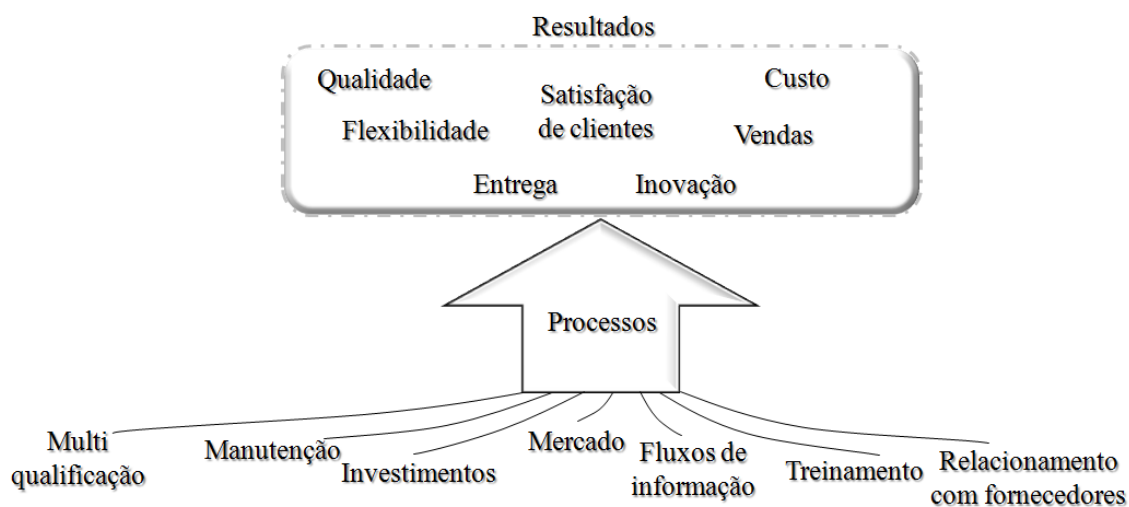
dados em informações úteis usando gráficos de comparação e técnicas estatísticas, bem como para comunicar as informações geradas às pessoas certas no tempo certo por meio de relatórios (NUDURUPATI; BITITCI, 2005). Os relatórios de desempenho proveem um *feedback* aos gestores sobre os planos de ação implantados. Os gestores devem analisar as informações dos relatórios, entender as relações de causa e efeito entre os resultados das diferentes variáveis do sistema de medição, comparar o valor de desempenho alcançado em cada indicador com o valor de desempenho almejado (meta estabelecida) e identificar áreas que estejam precisando de correção ou melhoria. Também é papel dos gestores fornecer um *feedback* aos funcionários sobre os resultados alcançados e, quando necessário, promover discussões e corrigir ações do plano para que as metas de desempenho possam ser atingidas (DE WAAL, 2007). De Waal (2007) recomenda que essa avaliação do plano de ação seja feita mensalmente, enquanto a revisão da estratégia adotada deve ser feita quadrimestralmente.

Uma prática que pode ser combinada à gestão de desempenho e que vem sendo difundida desde a década de 1980 é denominada *benchmarking*. De acordo com a *American Production and Inventory Control Society* (APICS, 1998), *benchmarking* pode ser definido como um processo sistemático e contínuo de avaliação e comparação dos produtos, serviços e processos de negócio de uma empresa com outra(s) considerada(s) melhor na categoria (*best in class*). Esse processo visa à busca por melhores práticas, ideias inovadoras e eficiência produtiva, de modo a estabelecer novos padrões de desempenho e conduzir a organização à melhoria contínua (WONG; WONG, 2007). Diversas técnicas quantitativas são sugeridas na literatura para apoiar a realização de *benchmarking*, tais como DEA (*Data Envelopment Analysis*), AHP (*Analytic Hierarchy Process*) e análise de regressão (SONI; KODALI, 2010).

Fazer *benchmarking* auxilia as empresas na implantação de mudanças que levam a melhorias significativas nos produtos e processos da organização, e conseqüentemente, nos seus resultados (WONG; WONG, 2007). O *benchmarking* estimula o rápido aprendizado organizacional a partir da observação e “imitação” de outros cenários, podendo ser usado para comparar os níveis de desempenho alcançados pelos processos de uma mesma unidade fabril, de diferentes unidades de uma mesma organização, de diferentes empresas ou ainda de cadeias de suprimento distintas (SONI; KODALI, 2010; ESTAMPE et al., 2013). Para que seja possível fazer a comparação, é necessário definir marcos de referência quantitativos ou qualitativos, denominados *benchmarks*, que podem ser determinados a partir de indicadores de desempenho comuns às partes comparadas.

A combinação das atividades do processo de gestão de desempenho com a prática de *benchmarking* pode ser apoiada pelo uso da ferramenta PDCA (*Plan, Do, Check e Action*), uma vez que as etapas envolvidas nesse processo de gestão seguem a lógica do planejamento de ações, execução, verificação (avaliação) e correção de ações (WONG; WONG, 2007). O foco da gestão não deve ser a comparação dos valores de desempenho alcançados, mas sim a busca e o entendimento das causas e práticas de gestão que conduziram a determinados valores de desempenho. Conforme sugere a Figura 4, os resultados de desempenho de um negócio são determinados pelas ações da gestão relacionadas ao treinamento de funcionários, multi qualificação, relacionamento com fornecedores, fluxos de informação, investimentos e manutenção, bem como pelo ambiente de mercado em que a empresa opera (LEBAS, 1995). Neste sentido, ao realizar o *benchmarking*, a análise das relações de causa e efeito entre os fatores determinantes do desempenho (dos processos, organizações ou cadeias de suprimento comparadas) e os resultados alcançados pelos indicadores direciona a criação de planos de ação visando à melhoria de desempenho.

Figura 4 - Relacionamento causal entre determinantes do desempenho e resultados de um negócio



Fonte: Lebas (1995)

A análise das relações de causa e efeito entre os fatores determinantes do desempenho e os resultados de um negócio pode ser apoiada pelo uso de sistemas de predição de desempenho (UNAHABHOKHA; PLATTS; TAN, 2007). O uso desse tipo de sistema no apoio à gestão de desempenho e ao *benchmarking* ainda é pouco discutido na literatura.

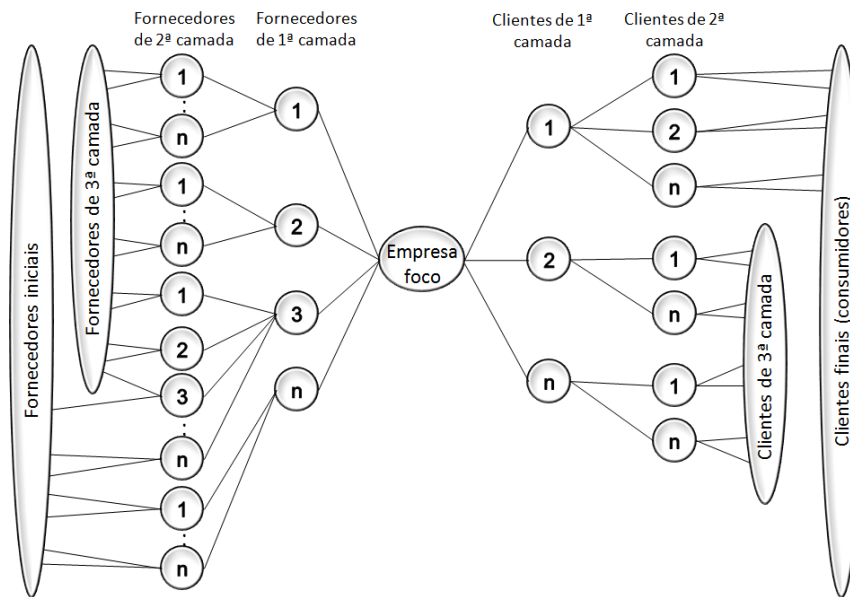
2.4 GESTÃO DE DESEMPENHO NO CONTEXTO DE CADEIAS DE SUPRIMENTO

Para entender como os sistemas de predição de desempenho podem ser usados no apoio à gestão de desempenho de cadeias de suprimento, é necessário conhecer as características e as práticas de gestão de cadeias de suprimento. As subseções a seguir discutem assuntos relacionados à gestão de cadeias de suprimento e à gestão de desempenho de cadeias de suprimento, destacando alguns dos modelos que podem ser usados para orientar o planejamento, implementação e melhoria de tais práticas.

2.4.1 *Gestão de cadeias de suprimento*

O termo gestão de cadeia de suprimento (*Supply Chain Management - SCM*) foi introduzido inicialmente por consultores no começo da década de 1980. No ambiente acadêmico, os primeiros estudos sobre a estruturação e a gestão dessas cadeias surgiram no começo da década de 1990. A Figura 5 representa a estrutura de uma cadeia de suprimento como uma rede de empresas na qual os membros componentes são representados por vértices (nós) e as conexões entre eles representam os relacionamentos de negócio existentes na cadeia. Um dos principais motivadores para a gestão dessas cadeias é o argumento de que as empresas não mais competem individualmente, pois a competição passou a ocorrer entre cadeias de suprimento (LAMBERT; COOPER; PUGH, 1998; WEBSTER, 2002). Outras razões se devem à nova forma como as empresas vem fazendo negócios: (1) maior compartilhamento de informação entre vendedores e clientes; (2) substituição das funções departamentais verticais por processos de negócio horizontais; (3) evolução da produção em massa para a produção customizada; (4) aumento de confiança na terceirização e redução no número de fornecedores; (5) maior ênfase na flexibilidade dos processos; (6) necessidade de coordenar processos que atravessam muitos lugares; e (7) pressões competitivas para introduzir novos produtos mais rapidamente (LUMMUS; VOKURKA; 1999).

Figura 5 - Estrutura de rede de uma cadeia de suprimento



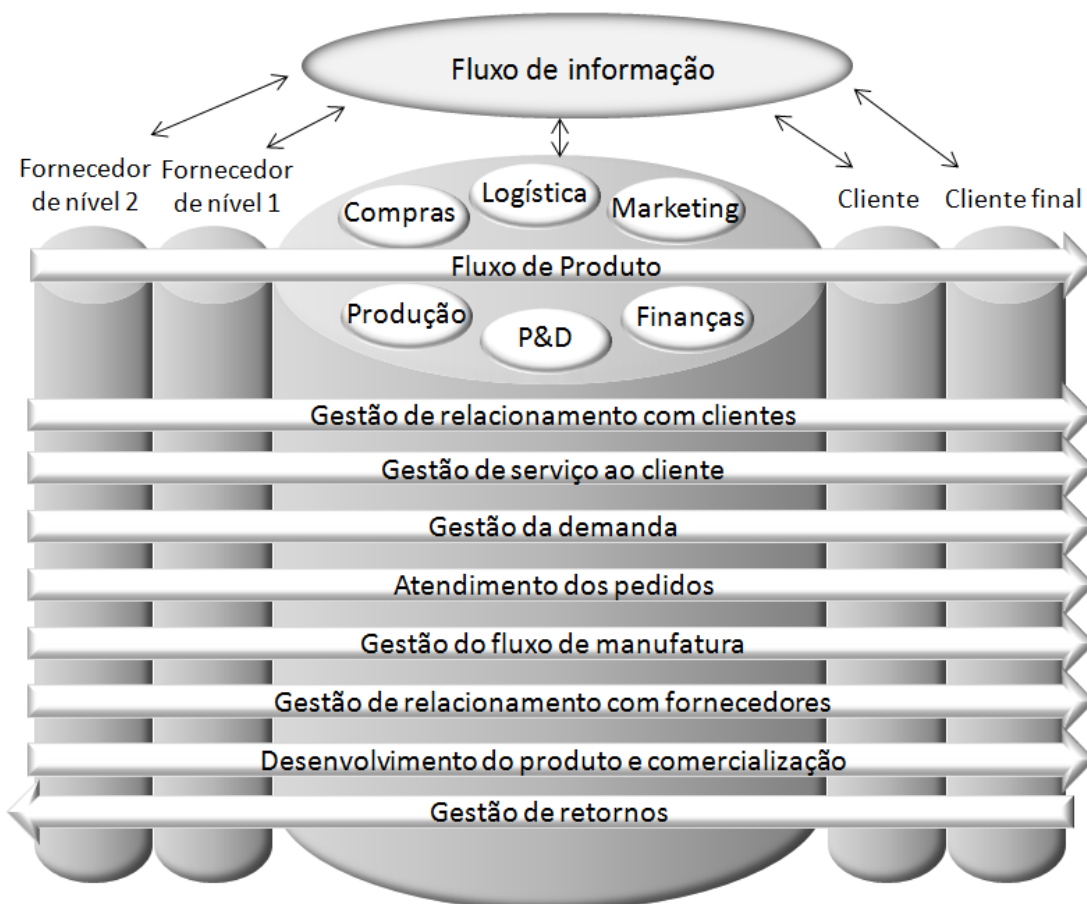
Fonte: Lambert, Cooper e Pagh (1998)

Uma definição de gestão de cadeias de suprimento amplamente aceita foi proposta pelos membros do *Global Supply Chain Forum* em 1998. De acordo com essa definição, a gestão de cadeias de suprimento consiste na integração dos processos de negócio chave, do usuário final até os fornecedores originais, que fornecem produtos, serviços e informação que agregam valor aos clientes e outros *stakeholders* (LAMBERT; COOPER; PAGH, 1998). Outra definição, proposta por Mentzer et al. (2001), declara que a gestão de uma cadeia de suprimento é a coordenação estratégica e sistêmica das funções de negócio tradicionais e de ações táticas numa companhia e através de seus negócios dentro da cadeia de valor, com o propósito de aprimorar o desempenho de longo prazo das companhias individualmente e da cadeia como um todo. Embora existam muitas definições para o conceito de gestão cadeia de suprimento, há um certo consenso de que esta gestão envolve os fluxos de produto e informação à montante e à jusante do negócio e deve focar na satisfação dos requisitos do cliente final e *stakeholders* (SWEENEY, 2011).

A Figura 6 procura ilustrar o conceito de gestão de cadeias de suprimento a partir da visão de Cooper, Lambert e Pagh (1997). Apesar da estrutura simplificada da cadeia, que não contempla os múltiplos relacionamentos com outros membros à montante e à jusante da empresa-foco, essa figura destaca os processos de negócio e os fluxos de informação e de produto que atravessam os silos funcionais (compras, logística, *marketing*, produção, finanças e pesquisa e desenvolvimento) da empresa-foco e dos outros membros da cadeia. Nota-se que os processos de negócio da cadeia de suprimento

operam através das fronteiras internas e externas de cada membro componente (LAMBERT; COOPER; PAGH, 1998).

Figura 6 - Integração e gestão dos processos de negócio ao longo de uma cadeia de suprimento



Fonte: Cooper, Lambert e Pagh (1997)

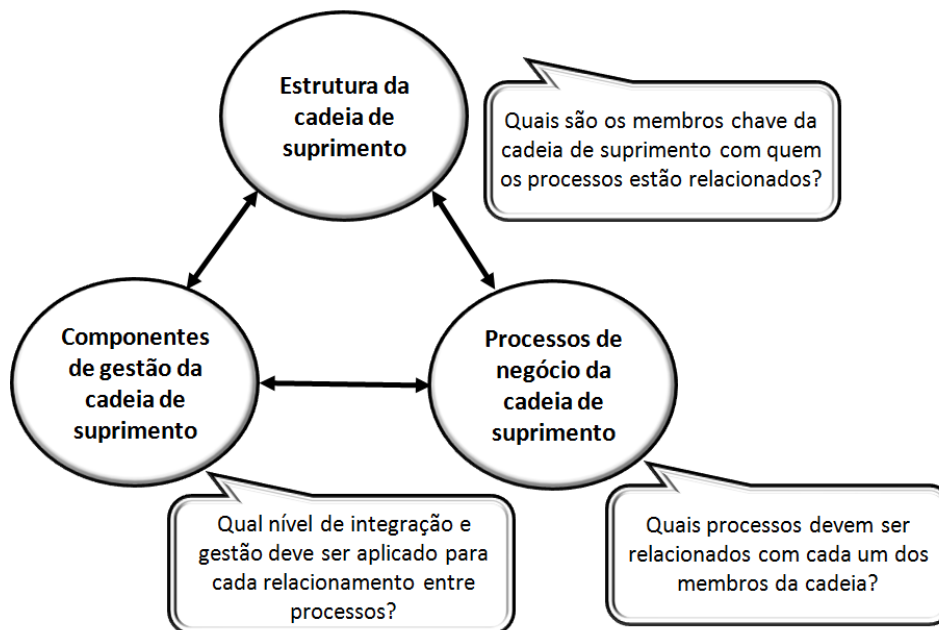
Embora seja frequente a confusão por parte de alguns estudos que consideram os termos “gestão de cadeias de suprimento” e “logística integrada” como sendo sinônimos (SWEENEY, 2011), a logística integrada consiste em um importante componente da gestão da cadeia de suprimento. De acordo com a definição apresentada pelo CLM (*Council of Logistics Management*, atualmente denominado *Supply Chain Council*) em 1998, a logística integrada é a parte da gestão da cadeia de suprimento que planeja, implementa e controla efetivamente o fluxo e a armazenagem de produtos, serviços e informações relacionadas do ponto de origem até o ponto de consumo com o objetivo de atender os requisitos dos clientes. A confusão em relação a esses termos pode estar no fato de que ambos apontam para a necessidade de integração dos processos de negócio chave que são externos à empresa-foco (LAMBERT; COOPER; PAGH, 1998). Christopher e Ryals (1999) complementam que a gestão da cadeia deve garantir a integração de todos os processos operacionais chave nos níveis estratégico, tático e

operacional, entre usuários finais e fornecedores de produtos, serviços e informações que agreguem valor aos clientes e outros *stakeholders*.

Além de ter o objetivo de aumentar o nível de satisfação dos clientes e *stakeholders* da rede, as iniciativas de gestão de cadeia de suprimento podem ter como objetivo reduzir o investimento em estoques ao longo da cadeia, melhorar a utilização de recursos, obter mais informações sobre o comportamento da demanda, compartilhar riscos e benefícios, aumentar a confiabilidade e a competitividade da cadeia como um todo (MENTZER et al., 2001; SWEENEY, 2011). A tecnologia da informação e comunicação tem um papel fundamental no alcance desses objetivos, uma vez que ajuda os gestores a definir estratégias, mensurar o desempenho, atenuar e / ou eliminar barreiras de tempo e distância, implementar atividades de negócio e programas de melhoria, compartilhar recursos, capacitar pessoas e obter informações em tempo real e de qualidade para apoiar a tomada de decisão (BOWERSOX; COOPER; CLOSS, 2006).

Um dos primeiros modelos desenvolvidos para apoiar a gestão de cadeias de suprimento foi proposto por Cooper, Lambert e Pagh (1997). Conforme mostra a Figura 7, esse modelo possui uma tipologia estrutural baseada em três elementos principais: estrutura da cadeia, componentes e processos de negócio. Para cada um deles, a figura destaca quais são as decisões chave envolvidas na gestão. Em relação à identificação dos membros que irão compor a cadeia, Cooper, Lambert e Pagh (1997) ressaltam que incluir todos os membros da rede pode gerar uma cadeia altamente complexa. Uma recomendação é incluir os membros que participam de processos de negócio que são críticos para o desempenho da cadeia. A estrutura da cadeia será então formada por membros primários (companhias autônomas ou unidades de negócio estratégicas que desempenham atividades operacionais) e membros de suporte (empresas que simplesmente fornecem recursos, conhecimento utilidades ou ativos, como por exemplo, os bancos que fazem empréstimos). Outra questão importante é definir as dimensões estruturais da cadeia, como o número de elos ao longo da cadeia e de fornecedores e clientes dentro de cada elo, e a proximidade da empresa-foco com o ponto de origem ou com o cliente final da cadeia (LAMBERT; COOPER; PAGH, 1998).

Figura 7 - Modelo de gestão de cadeia de suprimento proposto por Cooper, Lambert e Pagh (1997)



Fonte: Cooper, Lambert e Pagh (1997)

O nível de integração entre os elos componentes da cadeia deve variar de acordo com o tipo de relacionamento já existente e com os objetivos específicos da cadeia, podendo mudar ao longo do tempo. Lambert, Cooper e Pagh (1998) identificam quatro tipos de relação entre processos de negócio em cadeias de suprimento:

- i.** Processo gerenciado: compreende os processos de negócio críticos para a empresa-foco. A empresa-foco integra um processo com um ou mais elos, devendo gerenciar ativamente as atividades críticas de seus elos de primeira camada e de alguns dos elos de segunda camada;
- ii.** Processo monitorado: são processos considerados não críticos para a empresa-foco. Contudo, a empresa-foco considera importante a integração e o gerenciamento adequados desses processos por parte dos outros membros da cadeia e, sempre que preciso, a empresa-foco monitora ou faz auditoria de alguns destes processos;
- iii.** Processo não gerenciado: são processos em que a empresa-foco não está envolvida ativamente no gerenciamento e que não são suficientemente críticos para que sejam investidos recursos;
- iv.** Processo não membro: refere-se aos casos em que uma empresa que não faz parte da cadeia, mas compartilha processos com outra organização que é membro desta cadeia.

Por último, os componentes gerenciais da cadeia determinam como cada relacionamento entre os processos de negócio é integrado e gerenciado. Esses

componentes podem ser subdivididos entre “componentes técnicos e físicos”, que são mais visíveis, tangíveis, mensuráveis e fáceis de gerenciar, e “componentes comportamentais e gerenciais”, que são menos tangíveis e difíceis de avaliar e alterar. Os componentes gerenciais técnicos e físicos são constituídos pelos métodos de controle e planejamento, estrutura organizacional, estrutura para facilitar o fluxo de informação e comunicação e pela estrutura para facilitar o fluxo de produto. Já os componentes comportamentais e gerenciais incluem os métodos de gestão, a estrutura de liderança, estrutura de recompensa e risco, atitude e cultura organizacional (COOPER; LAMBERT; PAGH, 1997; LAMBERT; COOPER; PAGH, 1998).

Os conceitos apresentados no modelo de gestão de cadeia de suprimento proposto em Cooper, Lambert e Pagh (1997) e Lambert, Cooper e Pagh (1998) serviram de base para o desenvolvimento de muitos estudos sucessores, os quais propuseram outros modelos e metodologias para lidar com questões mais específicas do gerenciamento de cadeias de suprimento. Atualmente podem ser encontrados na literatura modelos focados no gerenciamento de riscos de cadeias de suprimento (HECKMANN; COMES; NICKEL, 2015), na formação da rede de membros da cadeia baseada nos requisitos dos clientes (COSKUN et al., 2015), no gerenciamento colaborativo de demanda (EKSOZ; MANSOURI; BOURLAKIS, 2014), na avaliação de desempenho de cadeias de suprimento (AZFAR; KHAN; GABRIEL, 2014; CHAN et al; 2014), entre outros. Também podem ser encontrados estudos que avaliam e comparam modelos qualitativos voltados para um mesmo propósito (ESTAMPE et al., 2013).

Além de modelos conceituais, a literatura também apresenta algumas orientações para conduzir o planejamento e a implantação de práticas de gestão de cadeias de suprimento. Algumas delas são (LUMMUS; VOKURKA; 1999; SWEENEY, 2011):

- Identificar os objetivos da cadeia e desenvolver planos para garantir que todos os processos sejam individualmente capazes de alcançar estes objetivos;
- Desenvolver sistemas para captar informações sobre a demanda e se planejar de acordo com estas informações;
- Gerenciar as fontes de suprimento por meio de parcerias com fornecedores para reduzir custos e *lead time*, bem como para melhorar a qualidade;
- Desenvolver redes logísticas customizadas para cada segmento de cliente;
- Desenvolver sistemas de informação capazes de suportar a tomada de decisão em todos os níveis da cadeia e de oferecer uma visão clara do fluxo de produtos;
- Adotar medidas de desempenho associadas a cada um dos processos de negócio da cadeia, considerando aspectos de serviço e financeiros;

- Relacionar a estratégia de gestão da cadeia à estratégia organizacional para alinhar as iniciativas da cadeia aos objetivos do negócio.

De acordo com as características do ambiente de mercado em que opera, uma cadeia de suprimento pode adotar diferentes tipos de estratégia competitiva. Com base nas características comuns a essas estratégias competitivas, Gattorna (2010) define quatro tipos de configuração diferentes para cadeias de suprimento: enxuta (*lean*), ágil (*agile*), totalmente flexível (*fully flexible*) e de reabastecimento contínuo (*continuous replenishment*). Uma cadeia enxuta trabalha com alto volume de pedidos, baixa variedade entre os produtos e baixos custos. Sua gestão foca em programas de redução de custo, obtenção de previsibilidade do comportamento da demanda e de *lead times*, aumento da eficiência produtiva e alta confiabilidade. As cadeias ágeis são caracterizadas pela alta capacidade de resposta a mudanças externas, uma vez que operam em mercados turbulentos, em que o sucesso da cadeia depende de sua capacidade de lançamento de novos produtos antes da concorrência. Sua gestão deve desenvolver uma capacidade de resposta rápida em condições imprevisíveis, garantir uma estrutura física com alta capacidade, baixo tempo de entrega e de lançamento de novos produtos e tomada de decisão ágil. As cadeias de reabastecimento contínuo são caracterizadas pelos altos níveis de qualidade, confiabilidade de entrega, desenvolvimento de relacionamentos de longo prazo, parcerias estratégicas e confiança mútua, possuindo uma gestão baseada em colaboração, que requer o suporte de sistemas de informação para o compartilhamento de dados. Finalmente, as cadeias completamente flexíveis são formadas para desenvolver soluções rápidas para demandas não previstas, e sua gestão foca em inovação, flexibilidade, capacidade de resolução de problemas e velocidade.

Além dos quatro tipos apontados por Gattorna (2010), na literatura podem ser encontrados outros tipos de orientação estratégica para a gestão de cadeias de suprimento. Uma delas é a gestão da cadeia de suprimento “verde” (*green*), que consiste em um conjunto de práticas que visam estimular e controlar o desempenho ambiental por meio da alocação de recursos humanos e materiais e da redefinição das responsabilidades e procedimentos organizacionais (SEURING, 2013). Outro tipo de estratégia que estimula o desempenho ambiental é a gestão de cadeias de suprimento sustentável (*sustainable supply chain management* - SSCM), que consiste na gestão de materiais, informação e capital, e também na cooperação entre empresas ao longo da cadeia, de modo a integrar os objetivos econômicos, ambientais e sociais, definidos a partir dos requisitos dos clientes e *stakeholders* (KIM; YOUN; ROH, 2011). Por meio de uma comparação entre dezenas de estudos sobre esses dois tipos de estratégia, Ahi e Searcy (2013) concluíram

que a estratégia de gestão de cadeia sustentável pode ser vista como uma extensão da gestão de cadeia de suprimento verde.

Promover a implantação de estratégias de gestão e alcançar os níveis de integração desejados aos processos de negócio ao longo dos diversos elos que compõem uma cadeia de suprimento é bastante complexo. Fatores como ausência de coordenação, turbulências de mercado, dificuldade de localizar os problemas que afetam o desempenho da cadeia, indicadores inapropriados e falta de confiança entre os membros da cadeia dificultam a implementação de ações de melhoria neste ambiente (MENTZER et al., 2001; HWANG; LIN; LYU JR., 2008). Outros complicadores que dificultam a gestão integrada de cadeias de suprimento são a falta de orientações para criação de alianças com parceiros da cadeia, dificuldade de desenvolver métricas para monitorar alianças, dificuldade de integrar os procedimentos internos da empresa, falta de confiança em relação aos membros internos e externos à empresa e falta de sistemas de informação integrados (LUMMUS; VOKURKA; 1999).

Embora existam muitos complicadores que podem afetar a integração e a gestão dos processos de uma cadeia de suprimento, na literatura são encontrados alguns relatos de casos de sucesso (SELLITO; MENDES, 2006), principalmente entre cadeias do setor automotivo, em que geralmente a montadora é a principal responsável pela coordenação das ações de melhoria e medição. Quanto à medição e gestão de desempenho de cadeias de suprimento, embora já existam diversos estudos sobre o assunto, a literatura propõe vários métodos que parecem não ser utilizados ainda na prática, posto que não foram encontrados estudos que relatem casos reais de implantação e manutenção de sistemas de avaliação de desempenho integrados ao longo de mais de dois elos da cadeia. A subseção a seguir foca na discussão da teoria sobre esse assunto.

2.4.2 *Gestão de desempenho baseada na avaliação de cadeias de suprimento*

O desenvolvimento de teorias relacionadas à gestão de desempenho de cadeias de suprimento vem sendo feito de forma fragmentada (FOLAN; BROWNE, 2005; AKYUZ; ERKAN, 2010). Na literatura não foram encontradas definições objetivas e bem delimitadas do termo “gestão de desempenho de cadeias de suprimento”. Embora esse termo se mostre mais adequado para designar a coordenação das atividades de planejamento, implantação, avaliação e melhoria de práticas visando ao aumento de desempenho no contexto interorganizacional, a maioria dos estudos adotam os termos “medição de desempenho interorganizacional” (*inter-organisational performance measurement*), “avaliação de desempenho de cadeias de suprimento” (*supply chain*

performance evaluation) e “medição de desempenho de cadeias de suprimento” (*supply chain performance measurement*) ao apresentar diretrizes de gestão e métodos de apoio a tais atividades (LOHMAN; FORTUIN; WOUTERS, 2004; FOLAN; BROWNE, 2005; AKYUZ; ERKAN, 2010; AHI; SEARCY, 2015).

Com base em alguns estudos relacionados ao tema, pode-se entender a gestão de desempenho de cadeias de suprimento como o gerenciamento dos processos de negócio de uma ou mais empresas, baseando-se em informações extraídas de um sistema de medição, predição ou avaliação de desempenho, que contemple indicadores internos à empresa-foco e indicadores associados a processos de negócio à montante e à jusante, visando ao planejamento, implantação e monitoramento de ações de melhoria que impactem positivamente sobre o desempenho da empresa-foco e da cadeia avaliada (LAMBERT; COOPER; PAGH, 1998; AMARATUNGA; BALDRY; SARSHAR, 2001; FOLAN; BROWNE, 2005; UNAHABHOKHA; PLATTS; TAN, 2007; AKYUZ; ERKAN, 2010; CUTHBERTSON; PIOTROWICZ, 2011; BALFAQIH et al., 2016).

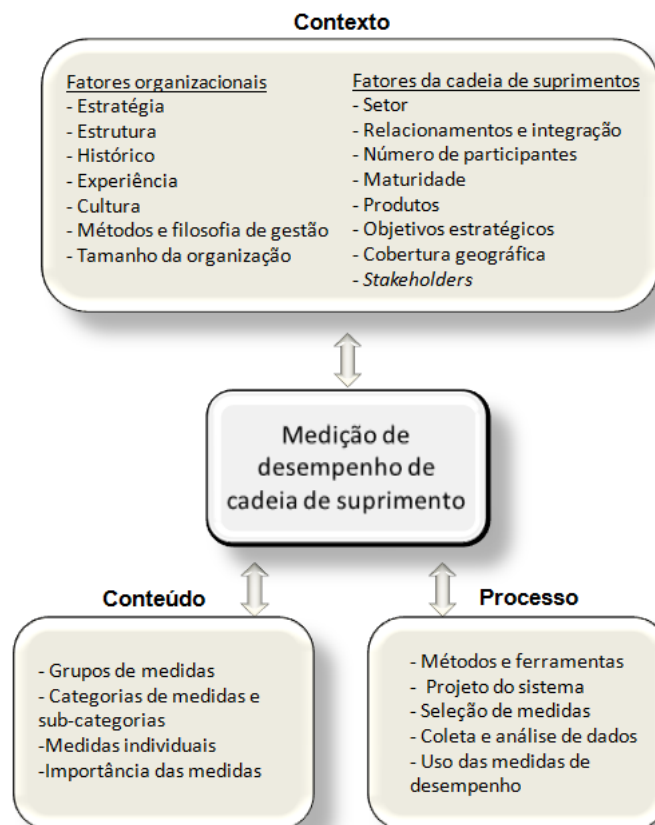
O monitoramento e a melhoria do desempenho de uma cadeia de suprimento é complexo, principalmente porque é um processo transversal, que envolve vários atores cooperando para alcançar objetivos estratégicos e logísticos (ESTAMPE et al., 2013). Há dezenas de indicadores sugeridos na literatura que podem ser usados para conduzir essa avaliação. Tais indicadores incluem medidas quantitativas e qualitativas, bem como financeiras e não financeiras, que são associadas aos processos de negócio da cadeia, podendo abranger os níveis estratégico, tático e operacional (SHEPERD; GÜNTER, 2006). Estampe et al. (2013) sugerem que os indicadores usados foquem no nível de satisfação dos clientes e nos custos incorridos. Sarode, Sunnapwar e Khodke (2008) revisaram dezenas de estudos e concluíram que os indicadores de desempenho de cadeias de suprimento mais usados na literatura são relacionados à confiabilidade de entrega, custos, flexibilidade e responsividade, qualidade, capacidade tecnológica, utilização de recursos, serviço e confiança.

Na literatura são encontrados modelos de avaliação de desempenho de cadeias de suprimento conceituais (teóricos) e quantitativos. Enquanto a maioria dos modelos conceituais sugere um conjunto de indicadores selecionados e às vezes ponderados de acordo com o julgamento de especialistas (GUNASEKARAN; PATEL; MCGAUGHEY, 2004; SARODE; SUNNAPWAR; KHODKE, 2008), os modelos quantitativos propõem o uso de métodos de apoio à tomada de decisão multicritério (CHITHAMBARANATHAN et al., 2015), técnicas de programação matemática (GONG, 2008), técnicas estatísticas (AHI; SEARCY, 2015), métodos de simulação

(BHASKAR; LALLEMENT, 2008) e técnicas de inteligência artificial (GANGA; CARPINETTI, 2011) para quantificar o desempenho da cadeia em relação a um conjunto de métricas de desempenho específicas.

Gunasekaran, Patel e Tirtiroglu (2001) propuseram um modelo conceitual pioneiro que abrange os níveis estratégico, tático e operacional e usa indicadores financeiros e não financeiros associados ao desempenho em planejamento, aquisição, produção, entrega, satisfação e serviço ao cliente. Theeranuphattana e Tang (2008) propuseram um modelo quantitativo com base nos indicadores do modelo SCOR® para avaliar o desempenho global de cadeias de suprimento considerando as dimensões de desempenho confiabilidade, responsividade, custos, flexibilidade e ativos (patrimônio). Ahi e Searcy (2015) desenvolveram um modelo para apoiar a avaliação de desempenho de cadeias sustentáveis que considera indicadores relacionados às dimensões econômica, ambiental, social, resiliência, fluxos, valor, *stakeholders*, eficiência, relacionamento e coordenação.

Cuthbertson e Piotrowicz (2011) propuseram um *framework* para apoiar a análise de sistemas de medição de desempenho de cadeias de suprimento que permite avaliar o conjunto de métricas, ferramentas e métodos usados e captar diferenças e similaridades entre os sistemas avaliados. Uma contribuição desse modelo é a identificação dos principais elementos envolvidos no processo de medição e gestão de desempenho neste ambiente. Conforme ilustra a Figura 8, esse *framework* é baseado nos componentes contexto (*context*), conteúdo (*content*) e processo (*process*). O componente contexto se refere às condições nas quais a medição é realizada (contexto organizacional ou contexto de cadeia de suprimento) e aos fatores que impactam sobre o sistema de medição de desempenho. O componente processo se refere a como a medição de desempenho é conduzida, englobando ferramentas, métodos e modelos para medição de desempenho, e também à forma como os dados são coletados, apresentados e usados. Já o componente conteúdo diz respeito ao que é medido, incluindo os indicadores de desempenho, seus níveis, categorias e dimensões de desempenho adotados.

Figura 8 - *Framework* para análise de sistemas de medição de desempenho de cadeias de suprimento

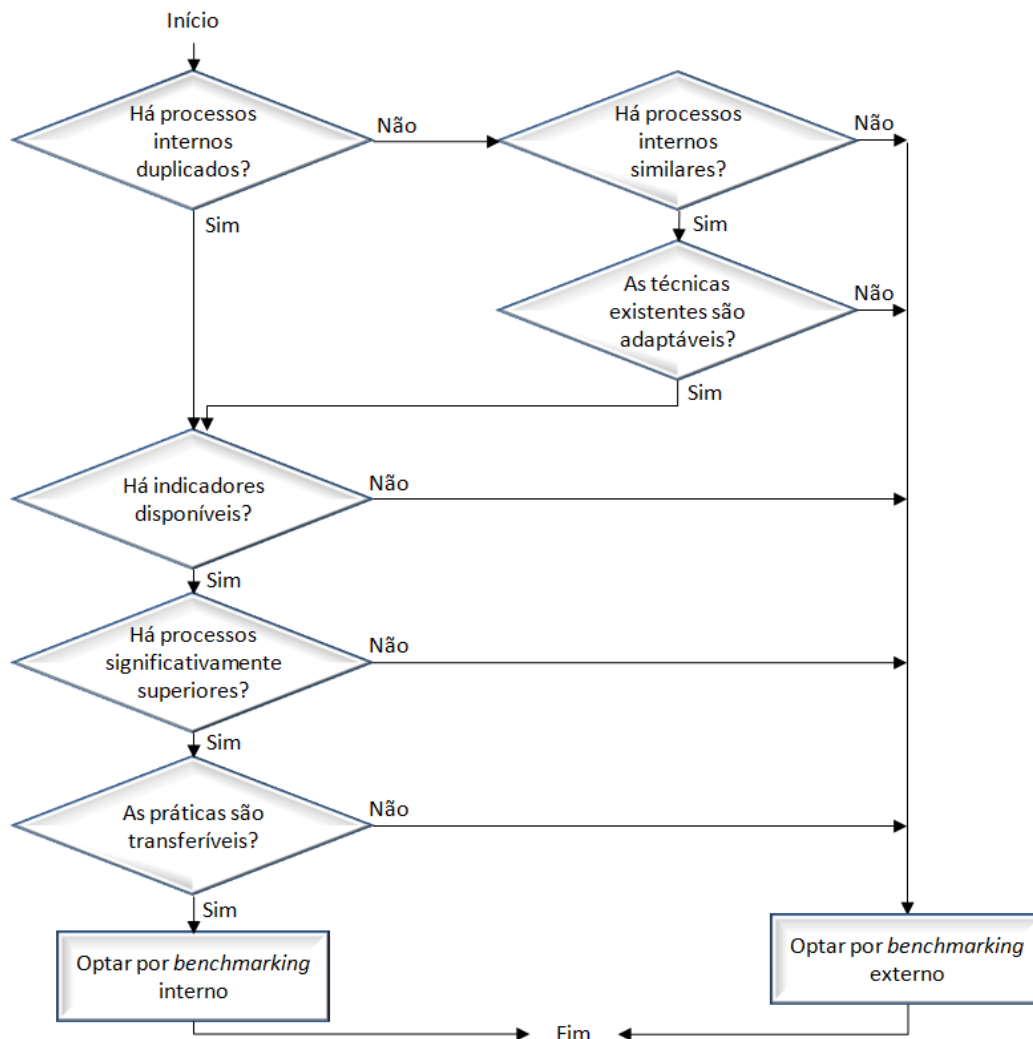
Fonte: Cuthbertson e Piotrowicz (2011)

Para apoiar ações de gestão de desempenho em cadeias de suprimento, Chang e Qi (2003) sugerem a criação de equipes compostas por representantes dos elos membros de várias áreas de gestão, incluindo operadores do chão de fábrica, supervisores de processos, gerentes departamentais e diretores. O papel dessas equipes é avaliar e discutir os dados da medição com base nas diferentes experiências e visões dos membros. A gestão de desempenho de cadeias também pode ser apoiada pela prática de *benchmarking* visando à melhoria das atividades e do desempenho da cadeia. Nesse caso, o *benchmarking* envolve uma comparação de medidas de sucesso de empresas e cadeias, cobrindo aspectos financeiros e não financeiros relacionados a processos, produtos e estratégias. A comparação pode ser feita entre cadeias internas ou externas à empresa-foco (WONG; WONG, 2007).

Baseando-se em Southard (2007), Soni e Kodali (2010) propuseram uma metodologia para condução de *benchmarking* interno entre cadeias, ilustrada na Figura 9, cujo objetivo é minimizar a variabilidade entre o desempenho das cadeias de uma empresa-foco. Por meio de alguns passos, essa metodologia permite verificar se o *benchmarking* interno é realmente a melhor opção para a organização. Primeiramente, verifica-se se há processos duplicados (idênticos) ou se há similaridades entre os processos internos das diferentes cadeias avaliadas. Caso haja processos similares, deve-

se avaliar se as técnicas usadas em um contexto são adaptáveis para o contexto do outro processo. Em seguida, verifica-se se há indicadores de desempenho disponíveis. Caso exista, analisa-se se a lacuna de desempenho existente entre as cadeias comparadas justifica o *benchmarking*. Caso justifique, avalia-se se as práticas usadas na cadeia com desempenho superior são transferíveis para a cadeia com desempenho inferior. Caso os requisitos de cada um desses passos não possam ser atendidos, uma alternativa viável pode ser a realização de um *benchmarking* externo entre diferentes cadeias.

Figura 9 - Etapas de uma metodologia para condução de *benchmarking* entre cadeias de suprimento



Fonte: Southard (2007) e Soni e Kodali (2010)

Embora diversos estudos destaquem a importância do *benchmarking* externo, foram encontrados poucos estudos que propõem modelos quantitativos de suporte ao *benchmarking* entre cadeias de suprimento e todos eles utilizam dados simulados (JOSHI; BANWET; SHANKAR, 2011; SAHU; DATTA; MAHAPATRA, 2014; SAHU; DATTA; MAHAPATRA, 2015) ou dados de pesquisas de levantamento (SIMATUPANG; SRIDHARAN, 2004) para obter os índices de desempenho a serem comparados. A principal dificuldade associada ao *benchmarking* entre cadeias de

suprimento parece ser a falta de um conjunto de *benchmarks* comuns às empresas comparadas, o que se deve à grande diversidade entre os indicadores usados nos sistemas de avaliação de desempenho. Essa falta de padronização aliada à falta de uma base de dados de desempenho de outras empresas faz com que os modelos de avaliação de desempenho de cadeias de suprimento existentes na literatura não sejam compatíveis para comparar os valores de desempenho em nível mundial. A única exceção consiste no modelo SCOR[®], que possui um conjunto padrão de medidas adotadas por organizações de vários países e provê uma base de dados virtual em que as empresas associadas podem se comparar em relação a diferentes *benchmarks* (SHEPHERD; GÜNTER, 2006; WONG; WONG, 2007).

Além da impossibilidade de apoiar o *benchmarking* em nível mundial, outras limitações dos modelos de avaliação de desempenho de cadeias de suprimento são apontadas na literatura. Folan e Browne (2005) apontam que esses sistemas tradicionalmente focam em medidas logísticas tradicionais (por exemplo, índices de atendimento de pedido, taxa de erros, custos de inventário e tempo de entrega), e por isso não oferecem suporte para responder a questões relacionadas ao nível de integração das empresas, à flexibilidade da cadeia e à confiança mútua. Sheperd e Günter (2006) criticam a falta de conexão desses sistemas com a estratégia, o foco insuficiente nos clientes e na concorrência, o uso de sistemas estáticos ao invés de dinâmicos e a falta de uma visão sistêmica, que acaba estimulando a otimização local. Outro complicador é a dificuldade de implantação prática, que se deve principalmente a barreiras como infraestrutura de tecnologia da informação dispersa, relatórios históricos operacionais e descentralizados, pouco conhecimento sobre os relacionamentos entre as métricas de desempenho usadas e baixa comunicação entre quem gera as informações e quem usa (LOHMAN; FORTUIN; WOUTERS, 2004). Finalmente, Sheperd e Günter (2006) apontam que a literatura não discute quais são os fatores-chave que determinam o sucesso de implantação de um sistema de avaliação de cadeias de suprimento nem como deve ser feita a manutenção do sistema de avaliação ao longo do tempo para que este permaneça alinhado com o ambiente em que opera e com as mudanças nas estratégias competitiva.

Uma ferramenta capaz de ajudar na escolha de um modelo de avaliação de desempenho adequado foi proposta por Estampe et al. (2013). Essa ferramenta visa comparar os modelos de avaliação de desempenho de cadeias de suprimento existentes com base em um conjunto de critérios. Esses critérios também servem como direcionadores ao identificar quais são os aspectos relevantes a serem considerados no projeto e análise da adequação destes modelos. Um dos critérios avalia a maturidade dos

modelos de medição com base na configuração dos elos envolvidos e no nível de integração entre eles, podendo ser classificado como intraorganizacional, interorganizacional, interorganizacional estendido, multi cadeia e social. Outros critérios considerados são o nível de decisão afetado pela avaliação (estratégico, tático ou operacional), os tipos de fluxo sob análise (físico, de informação ou financeiro), os tipos de *benchmarking* factíveis (interno ou externo) e os aspectos da qualidade, capital humano e sustentabilidade. Com base nesses critérios, Estampe et al. (2013) compararam 16 modelos e concluíram que o modelo SCOR[®] é o mais adequado entre os avaliados por atender à maioria dos requisitos.

2.4.3 O modelo SCOR[®]

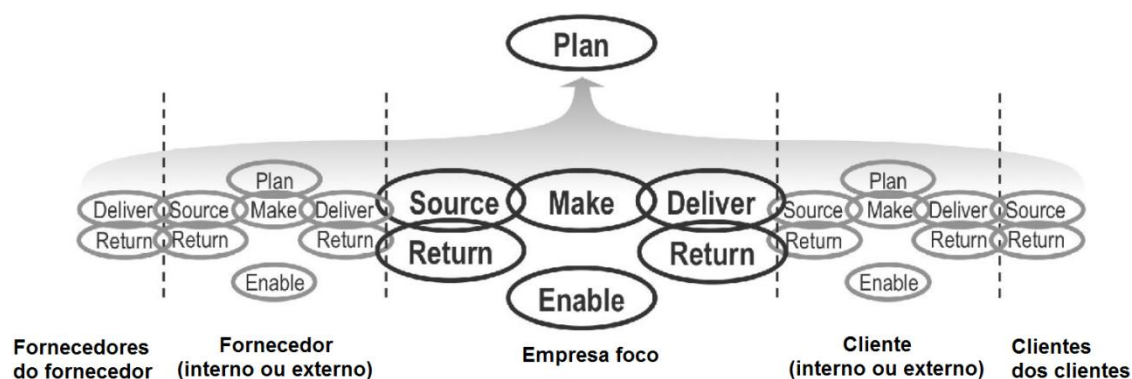
O SCOR[®] (*Supply Chain Operations Reference*) é um modelo de referência que relaciona processos de negócio, métricas de desempenho e melhores práticas de gestão de cadeias de suprimento, a fim de apoiar a descrição, a avaliação e a comparação das atividades e do desempenho destas cadeias (SCC, 2012). Esse modelo foi desenvolvido com o intuito de descrever todas as atividades inerentes a todas as fases do processo de atendimento da demanda dos clientes, suportar a comunicação entre parceiros em cadeias de suprimento e melhorar a efetividade da gestão destas cadeias e das atividades de melhoria relacionadas. O SCOR[®] é flexível e pode ser usado por indústrias de qualquer setor para descrever cadeias de suprimento simples ou bastante complexas. Vale ressaltar que esse modelo não visa prescrever como uma organização deve conduzir seus negócios, uma vez que serve como arquitetura de referência que apoia a modelagem e a melhoria de processos e atividades genéricas inerentes à gestão de cadeias de suprimento (SHEPHERD; GÜNTER, 2006). De acordo com Theeranuphattana e Tang (2008), embora cada vez mais empresas venham adotando esse modelo na prática, o SCOR[®] ainda é pouco explorado na literatura.

O SCOR[®] foi desenvolvido em meados da década de 1990 pelo *Supply Chain Council*, uma organização sem fins lucrativos que engloba acadêmicos, organizações governamentais e empresas de vários setores, incluindo fabricantes, distribuidores e varejistas. Os membros do *Supply Chain Council* são responsáveis pelo desenvolvimento e pela manutenção desse modelo (SCC, 2012). A versão 11 do SCOR[®], resultante da 13^a revisão é dividida em quatro seções: processos (*process*), práticas (*practices*), pessoas (*people*) e desempenho (*performance*).

Conforme ilustra a Figura 10, a versão 11 do SCOR[®] fornece uma arquitetura baseada em seis processos de negócio, que visam apoiar as atividades de planejamento

(*plan*), abastecimento (*source*), produção (*make*), entrega (*deliver*), retorno (*return*) e implantação dos processos e atividades (*enable*) ao longo de uma cadeia de suprimento. Tais processos incluem todas as interações com os clientes (por exemplo, entrada de pedido), transações de materiais físicos com fornecedores e clientes (incluindo suprimento, peças de reposição, equipamentos, *softwares*, entre outros) e interações de mercado (do entendimento da demanda agregada até o atendimento de cada pedido). Não é o objetivo do SCOR[®] descrever todas as atividades do negócio, uma vez que este modelo não contempla as atividades de vendas e *marketing* (geração de demanda), desenvolvimento de produto, pesquisa e desenvolvimento e algumas atividades de suporte ao cliente pós-venda (THEERANUPHATTANA; TANG, 2008; SCC, 2012). Contudo, o SCC possui outros modelos para apoiar tais atividades, tais como o CCOR (*Customer Chain Operations Reference*), que relaciona operações típicas de vendas com processos, práticas e indicadores de suporte ao cliente, e o DCOR (*Design Chain Operations Reference*), que é voltado para práticas e processos de negócio relacionados à pesquisa e desenvolvimento (APICS, 2016).

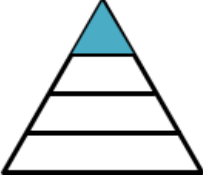
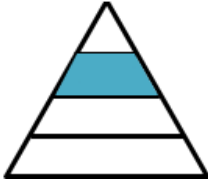

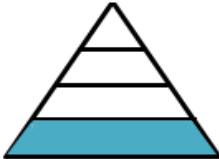
Figura 10 - Principais processos de gestão do modelo SCOR[®]



Fonte: *Supply Chain Council* (2012)

Conforme ilustra a Figura 11, o SCOR[®] oferece suporte à análise dos processos de negócio de cadeias de suprimento em múltiplos níveis, descrevendo a forma como os processos são feitos, como interagem e quais as habilidades são requeridas das equipes que os operam. O escopo desse modelo abrange somente os níveis de processo que não dependem do tipo de setor industrial, ou seja, os três primeiros níveis de processo. Dessa forma, ao utilizar o SCOR[®] para implantação de melhorias na cadeia, a organização deve estender o modelo pelo menos até o quarto nível, considerando para isso as particularidades do setor industrial, da organização e / ou dos processos, práticas e sistemas específicos de uma determinada planta industrial (SCC, 2012).

Figura 11 - Organização hierárquica dos processos de negócio do modelo SCOR®

Nível hierárquico	Descrição	Exemplos
<p>Nível 1</p> 	<p>Tipos de processo: Define o escopo de uma cadeia de suprimento. Neste nível também são definidas as metas de desempenho conforme a estratégia competitiva da cadeia.</p>	<p><i>Plan, source, make, deliver, return e enable</i></p>
<p>Nível 2</p> 	<p>Categorias de processo (configuração): Define a estratégia de operações e as capacidades dos processos da cadeia.</p>	<p><i>Make to stock; make to order; engineering-to-order; defective products, maintenance, repair and operations products; excess products</i></p>
<p>Nível 3</p> 	<p>Elementos dos processos (etapas ou subprocessos): Define uma configuração particular para os processos e a habilidade de executá-los</p>	<p>Receber produto, verificar produto, transferir produto, autorizar pagamento</p>
<p>Nível 4</p> 	<p>Atividades (implementação): Descreve as atividades feitas dentro da cadeia e implementa processos específicos do setor, da empresa e/ou do produto, bem como práticas específicas para alcançar o desempenho requerido.</p>	<p>Particularidades do setor, da organização e / ou de uma determinada planta industrial</p>

Fonte: SCC (2012)

Além de apresentar uma arquitetura de referência para os processos, o SCOR® também contém um conjunto de práticas de gestão reconhecidas por empresas de diversos setores. Uma prática é uma forma única de se configurar um processo ou atividade. O SCOR® considera que, dentre as práticas de gestão de cadeias, há práticas emergentes, melhores práticas, práticas padrão e práticas em declínio, sendo que a classificação de uma determinada prática pode variar de acordo com o setor industrial da empresa ou com a localização geográfica da organização (SCC, 2012).

Outra seção do modelo SCOR® foca nas habilidades requeridas das pessoas para executar e gerenciar processos. Esta seção foi inserida a partir da versão 10 visando fornecer um padrão para descrição das habilidades requeridas por cada processo. Tais habilidades são descritas por meio de uma definição padrão e da associação a outros aspectos pessoais, como atitudes, experiências, treinamentos e nível de competência (SCC, 2012).

Já a seção voltada para o desempenho de cadeias de suprimento fornece um amplo conjunto de métricas para avaliar os resultados da cadeia. Esse conjunto de métricas é

subdividido em atributos de desempenho e indicadores de desempenho, os quais são organizados hierarquicamente ao longo de uma estrutura em níveis. Conforme descreve o Quadro 2, o nível mais alto da hierarquia é composto por cinco atributos de desempenho, relacionados à confiabilidade (*reliability*), à responsividade (*responsiveness*), à agilidade (*agility*), aos custos (*cost*) e à gestão de ativos (*asset management*) na cadeia (SCC, 2012).

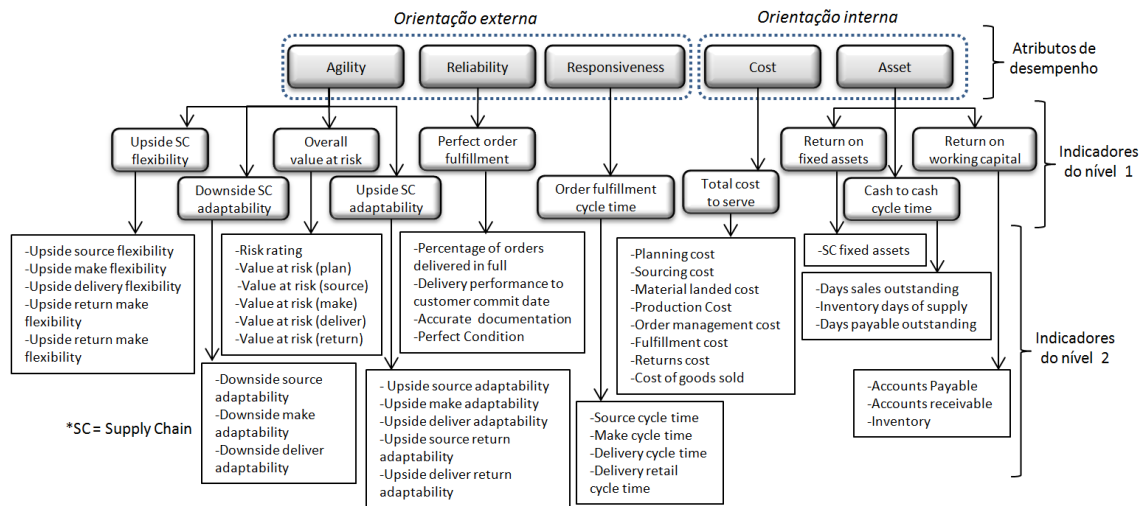
Quadro 2 – Descrição dos atributos de desempenho do modelo SCOR®

Atributo	Descrição
<i>Reliability</i>	Refere-se à habilidade de desempenhar tarefas conforme os requisitos do cliente.
<i>Responsiveness</i>	Diz respeito à velocidade com que as tarefas são executadas.
<i>Agility</i>	Refere-se à velocidade e à habilidade de uma cadeia para responder a mudanças de mercado a fim de ganhar ou manter vantagem competitiva.
<i>Cost</i>	Envolve todos os custos relacionados à operação de uma cadeia de suprimento.
<i>Asset management</i>	Diz respeito à habilidade de utilizar eficientemente recursos fixos e capital de giro para atender à demanda dos clientes.

Fonte: SCC (2012)

Cada um destes atributos de desempenho serve como um agrupamento de indicadores usados para expressar uma determinada orientação estratégica, como, por exemplo, “um determinado produto precisa ser líder de mercado em confiabilidade” ou “os clientes de um dado segmento de mercado requerem que a empresa esteja entre as dez mais ágeis”. A habilidade de alcançar tais orientações estratégicas é medida por meio de um conjunto de indicadores de desempenho associados a cada atributo, conforme ilustra a Figura 12. Os indicadores estão distribuídos ao longo dos níveis 1, 2 e 3 da hierarquia (SCC, 2012). Contudo, na Figura 12 são apresentadas somente as métricas de nível 1 e 2. Optou-se por não traduzir a nomenclatura destas métricas (em inglês) para evitar distorções nos significados das mesmas.

Figura 12 - Métricas de avaliação de desempenho propostas pelo modelo SCOR®



Fonte: Proposto pelo autor com base em SCC (2012).

No gerenciamento do desempenho de uma cadeia de suprimento imediata usando os indicadores do SCOR®, os valores apresentados pelos indicadores do nível 1 explicitam a “saúde” da cadeia, servindo como indicadores de desempenho estratégicos, ou indicadores de desempenho chave (*key performance indicators*, KPI). O desdobramento desses indicadores torna possível analisar o desempenho da cadeia em diferentes perspectivas, já que o relacionamento entre esses indicadores é diagnosticável. Em cada nível da hierarquia, o valor de um indicador de um nível superior é calculado com base nos valores alcançados pelos indicadores no nível imediatamente inferior. O SCOR® apresenta um conjunto de fórmulas para realização de tais cálculos (SCC, 2012). O Apêndice A descreve em detalhes os indicadores do nível 1 e seus respectivos indicadores componentes, pertencentes ao nível 2 da hierarquia.

Enquanto os indicadores do nível 3 possibilitam diagnosticar os valores do nível 2, os indicadores do nível 2 possibilitam diagnosticar os indicadores do nível 1. Desta forma, por meio da análise dos valores de desempenho alcançados pelos indicadores do nível 3, é possível explicar lacunas ou melhorias de desempenho apresentadas pelos indicadores do nível 2. Analogamente, por meio da análise dos valores dos indicadores do nível 3, é possível inferir sobre o comportamento dos indicadores do nível 2. Esse processo de análise das relações entre os indicadores recebe diferentes denominações no SCOR®, tais como diagnóstico de desempenho, análise de causa raiz dos indicadores ou decomposição dos indicadores. Essa análise das relações entre os indicadores constitui a primeira etapa para identificar processos que necessitam de planos de ação visando à melhoria de resultados (SCC, 2012).

Entre os indicadores do modelo do SCOR®, há alguns que possuem relacionamentos lineares entre o indicador de um nível superior e os do nível

imediatamente inferior, bem como indicadores que possuem relacionamentos não lineares. Na literatura não foram encontrados estudos que discorram sobre relacionamentos lineares e não lineares entre os indicadores de desempenho. Com o propósito de esclarecer esses conceitos no contexto de sistemas especialistas, propõe-se o seguinte exemplo: supondo que y seja um indicador do nível superior (variável de resultado), x e z sejam os indicadores do nível imediatamente inferior (variável de entrada) e a e b dois números reais quaisquer. Quando y é estimado por meio de funções lineares como “ $y = ax + b$ ”, “ $y = ax$ ” ou “ $y = x + aw$ ”, pode-se afirmar que existe uma relação linear entre y e os indicadores x e w , já que as variações nos valores de x e w em qualquer faixa de valores refletem proporcionalmente no aumento ou diminuição do valor de y , constituindo uma reta no sistema cartesiano ortogonal (x, y) . Caso o expoente dos indicadores x ou w seja diferente de 1, como nas funções, “ $y = x^2$ ”, “ $y = \sqrt{w}$ ” e “ $y = 100/x = 100 x^{-1}$ ”, o relacionamento é caracterizado como não linear. Nesse caso, a função y poderá assumir formatos como hipérbole ou parábola.

Uma vez que o SCOR[®] é composto por uma grande variedade de indicadores associados a cada atributo, o monitoramento de todos os indicadores simultaneamente pode requerer demasiados recursos para a coleta e análise de dados. Por causa disso, é comum a adoção de uma quantidade balanceada de indicadores conforme as necessidades específicas da empresa e da cadeia, focando principalmente no monitoramento dos processos que são críticos para as operações da cadeia (SCC, 2012).

A padronização de processos e de indicadores de desempenho no SCOR[®] permite a criação de uma linguagem comum que possibilita às organizações associadas se compararem a outras cadeias. O SCOR[®] provê suporte ao *benchmarking* entre cadeias de suprimento por meio da base de dados *online SCORmark*. O *SCORmark* permite estratificar o desempenho de uma cadeia por meio de três posicionamentos: *superior*, que é a mediana de um dado indicador em relação a um percentual de 10% das mais bem classificadas dentro o total de redes avaliadas; *advantage*, que é o desempenho do ponto médio entre as empresas *Top 10*, e a mediana de todas as redes avaliadas; e *parity*, que é o desempenho mediano de todas as redes avaliadas (SCC, 2012; GANGA, CARPINETTI, 2011).

Diversos autores apontam para a necessidade de desenvolver novas ferramentas e métodos para dar suporte às práticas de gestão de cadeias de suprimento (LAMBERT; COOPER; PAGH, 1998; BALFAQIH et al., 2016). A linguagem padronizada do SCOR[®] ajuda a alinhar as funcionalidades de novas ferramentas computacionais às características da cadeia de suprimento (THEERANUPHATTANA; TANG, 2008). Conforme mostra o

Quadro 3, diversos estudos propõem modelos de medição de desempenho baseados na combinação dos indicadores do SCOR[®] com métodos de tomada de decisão multicritério ou com técnicas de inteligência artificial a fim de desenvolver novas ferramentas de apoio à gestão de desempenho de cadeias de suprimento.

Quadro 3 – Modelos de avaliação de desempenho baseados nos indicadores do SCOR[®]

Proposto por	Técnica(s) utilizada(s)
Chan e Qi (2003)	Método híbrido baseado em lógica <i>fuzzy</i> e AHP
Sellito e Mendes (2006)	AHP
Wong e Wong (2007)	DEA
Theeranuphattana e Tang (2008)	Comparações entre números <i>fuzzy</i>
Golparvar e Seifbarghy (2009)	TOPSIS (<i>Technique for Order of Preference by Similarity to Ideal Solution</i>)
Ganga e Carpinetti (2011)	Inferência <i>fuzzy</i>
Jalalvand et al. (2011)	DEA e PROMETHEE II (<i>Preference Ranking Organization Method for Enrichment Evaluations</i>)
Bai et al. (2012)	<i>Rough set theory</i>
Clivillé e Berrah (2012)	MACBETH
Yang e Jiang (2012)	Combinação entre princípios do AHP, método "M(1,2,3)" e números <i>fuzzy</i>
Kocaoglu, Gülsün e Tanya (2013)	AHP e TOPSIS
Agami, Saleh e Rasmy (2014)	Inferência <i>fuzzy</i>
Bukhori, Widodo e Ismoyowati (2015)	AHP
Abolghasemi, Khodakarami e Tehranifard (2015)	Redes baesianas
Sellito et al. (2015)	AHP

Fonte: Proposto pelo autor.

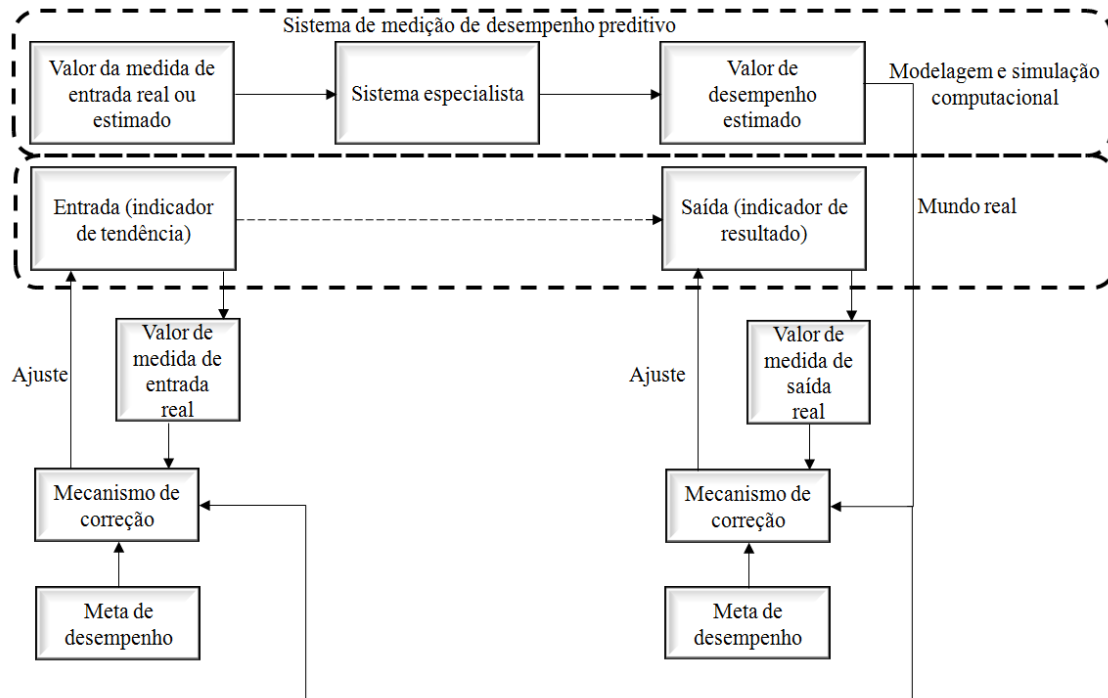
Embora os modelos mostrados no Quadro 3 possibilitem a avaliação de desempenho de cadeias considerando diferentes dimensões de desempenho e permitam a comparação dos valores de desempenho alcançados com os indicadores da base de *benchmarking SCORmark*, somente os modelos propostos por Ganga e Carpinetti (2011) e Agami, Saleh e Rasmy (2014) são capazes de modelar relacionamentos não lineares entre os indicadores e permitem armazenar conhecimento sobre as relações de causa e efeito entre os indicadores em sua estrutura. Além disso, nenhum desses modelos pode ser ajustado ou atualizado automaticamente a partir de dados históricos que descrevam o desempenho de uma cadeia sob a perspectiva da empresa-foco. A subseção a seguir detalha outros modelos quantitativos para avaliação de desempenho de cadeias de suprimento.

2.5 PREDIÇÃO DE DESEMPENHO

Unahabhokha, Platts e Tan (2007) afirmam que a maioria dos sistemas de avaliação de desempenho apresentam mecanismos de controle baseados em medidas de resultado, que permitem às empresas analisar os dados de desempenho alcançados e comparar com os valores que foram almejados baseando-se em dados históricos, que descrevem somente o que já aconteceu. Esses autores criticam que tais sistemas não incorporam uma visão prospectiva, que ajude a investigar quais são as tendências de desempenho futuras. Essa limitação serviu como motivação para que Unahabhokha, Platts e Tan (2007) propusessem o primeiro sistema preditivo de avaliação de desempenho identificado na literatura, também chamado de sistema de predição de desempenho. Este sistema foi desenvolvido usando inferência *fuzzy* com o propósito de prever o *lead time* de uma empresa do setor têxtil com base nos valores de outros cinco indicadores (*lead time* de matéria-prima, *lead time* da estamparia, quantidade de pedido, capacidade interna disponível e capacidade dos fornecedores disponível). A seleção das variáveis de entrada, os ajustes dos parâmetros internos do modelo e a validação dos resultados fornecidos foram feitos com base na opinião de funcionários da empresa.

Conforme ilustra a Figura 13, o mecanismo de predição de desempenho é apoiado por um sistema especialista que quantifica as relações de causa e efeito entre os indicadores de tendência (variáveis de entrada) e os indicadores de resultado (variáveis de saída) por meio de um conjunto de regras de decisão (ou regras de inferência *fuzzy*), que são ajustadas usando julgamentos de especialistas. Enquanto um indicador de tendência mede aspectos que conduzirão a uma medida de desempenho futura, um indicador de resultado mede as saídas ou o sucesso de atividades passadas. Por exemplo, qualidade do produto é um indicador de tendência da satisfação do cliente (UNAHABHOKHA; PLATTS; TAN, 2007). Outros indicadores de tendência estão relacionados à flexibilidade, utilização de recursos e inovação (NEELY et al., 2000). Exemplos de indicadores de resultado são custo de manufatura, desempenho financeiro e competitividade (NEELY et al., 2000; UNAHABHOKHA; PLATTS; TAN, 2007).

Figura 13 - Sistema de medição de desempenho preditivo



Fonte: Unahabhokha, Platts e Tan (2007)

A partir da apresentação de valores reais ou estimados dos indicadores de tendência ao sistema especialista, são fornecidas estimativas de valores para os indicadores de resultado. Se as estimativas fornecidas pelo sistema não alcançarem as metas de desempenho preestabelecidas para cada indicador, os gestores devem estabelecer ações corretivas que reflitam um aumento nos valores dos indicadores de tendência e, conseqüentemente, melhorem os valores dos indicadores de resultado (UNAHABHOKHA; PLATTS; TAN, 2007). Desta forma, o uso de sistemas preditivos permite que os gestores antecipem a elaboração de ações corretivas e não tenham que esperar pela medição dos valores reais dos indicadores de resultado para tomar decisões sobre a melhoria dos processos. Vale ressaltar que uma limitação dos modelos de predição de desempenho atuais é que estes não consideram o fator tempo na análise das relações de causa e efeito entre os indicadores. Desta forma, eles estimam os valores dos indicadores de resultado sem determinar exatamente quando tais valores serão alcançados na prática.

Baseando-se no modelo proposto por Unahabhokha, Platts e Tan (2007), Ganga e Carpinetti (2011) combinaram o mesmo tipo de sistema de inferência *fuzzy* com os indicadores de desempenho do modelo SCOR® 8.0 para prever o desempenho de cadeias de suprimento a partir da perspectiva de uma empresa-foco. Nesse modelo, as regras de decisão do sistema de inferência quantificam os relacionamentos entre os indicadores do nível 1 e do nível 2 da hierarquia de métricas do SCOR®. Uma das

vantagens dessa abordagem é a possibilidade de utilizar as estimativas do sistema de predição para fazer *benchmarking* entre cadeias de suprimento, usando para isso uma base de dados compatível com os indicadores do modelo SCOR[®], o *SCORmark*.

O sistema de predição proposto por Ganga e Carpinetti (2011) foi validado a partir do uso da comparação dos valores estimados com os valores reais fornecidos pelo *SCORmark*. Apesar de apresentar resultados condizentes com os valores do *SCORmark*, os parâmetros do sistema são fornecidos pelo usuário ou por especialistas e o ajuste das regras de decisão só pode ser feito manualmente. Isso faz com que o processo de atualização desse sistema seja árduo, pois requer a parametrização manual de 2.500 regras de inferência. O uso de sistemas de inferência neuro-*fuzzy* ou de redes neurais artificiais permitiria automatizar esse ajuste do sistema.

Por meio da pesquisa bibliográfica realizada neste estudo, foram encontrados na literatura apenas três modelos de predição de desempenho de cadeias de suprimento baseados em sistemas neuro-*fuzzy*, que foram propostos por Didehkhani, Jassbi e Pilevari (2009), Jassbi, Seyedhosseini e Pilevari (2010) e Côrrea e Da Silveira (2012). Os três sistemas são dotados de um método de aprendizagem supervisionado, que atualiza as regras de decisão do sistema de predição usando os valores históricos apresentados pelos indicadores de desempenho de tendência e de resultado.

Apesar de permitir o ajuste automático dos sistemas de predição de desempenho, os três modelos utilizam um conjunto de indicadores restrito à avaliação de uma única dimensão de desempenho, realizando somente a predição de desempenho de único indicador de resultado. Enquanto o modelo proposto por Côrrea e Da Silveira (2012) prediz a competitividade de cadeias de suprimento, o modelo de Jassbi, Seyedhosseini e Pilevari (2010) fornece a agilidade e o de Didehkhani, Jassbi e Pilevari (2009) foca na flexibilidade. Além de não serem capazes de quantificar o desempenho global de uma cadeia de suprimento, esses modelos utilizam um conjunto singular de indicadores de desempenho, fazendo com que não sejam compatíveis para comparar os valores de desempenho em bases de *benchmarking* em nível global. Uma forma de resolver essa limitação consiste em combinar o uso de sistemas neuro-*fuzzy* ou de redes neurais artificiais com os indicadores do modelo SCOR[®], uma vez que estes são compatíveis com a base *SCORmark*. Contudo, na literatura não são encontrados estudos que proponham modelos de predição baseados na combinação dessas técnicas e nos indicadores do SCOR[®].

2.6 MODELOS QUANTITATIVOS PARA AVALIAÇÃO DE DESEMPENHO DE CADEIAS DE SUPRIMENTO

O objetivo desta subseção é traçar um panorama dos estudos que propõem modelos quantitativos, baseados em múltiplos indicadores (ou múltiplos critérios), para apoiar a avaliação de desempenho de cadeias de suprimento. Para isso, foi feito um levantamento bibliográfico sistematizado que analisou 93 artigos extraídos dos principais periódicos da literatura relacionada. Os procedimentos usados para seleção dos artigos, os resultados da caracterização dos modelos e uma análise crítica destes resultados são apresentados nas subseções a seguir.

2.6.1 Procedimentos de busca e seleção dos estudos

O método de busca e seleção dos artigos foi definido a partir de procedimentos recomendados na literatura para elaboração de revisões sistemáticas. Kitchenham e Charters (2007) definem “revisão sistemática da literatura” como um meio de identificar, avaliar e interpretar todas as pesquisas disponíveis relevantes para uma questão de pesquisa específica, ou área temática, ou fenômeno de interesse. Sampaio e Mancini (2007) acrescentam que a elaboração de uma revisão sistemática deve identificar as bases de dados a serem consultadas, definir palavras-chave e estratégias de busca, estabelecer critérios para a seleção de artigos, comparar as buscas dos examinadores, definir a seleção inicial de artigos, aplicar os critérios na seleção destes e justificar possíveis exclusões. Além disso, deve-se analisar criticamente e avaliar todos os estudos incluídos na revisão, bem como preparar um resumo crítico, sintetizando as informações disponibilizadas pelos artigos que foram incluídos na revisão e apresentar uma conclusão.

A pesquisa bibliográfica sobre os modelos quantitativos obedeceu às recomendações de Sampaio e Mancini (2007). Os artigos selecionados foram coletados usando *Science Direct* (www.sciencedirect.com), *Scopus* (www.scopus.com), *Emerald Insight* (www.emeraldinsight.com) e *IEEEExplore* (ieeexplore.ieee.org). Também foi realizada uma busca adicional utilizando a ferramenta *Google Scholar* (scholar.google.com). Os seguintes procedimentos foram utilizados para busca e seleção de artigos: (1) inserção da *string* “*supply chain performance evaluation*” nos campos de busca de cada uma das bases; (2) utilização de um filtro para selecionar somente artigos publicados entre 1995 e 2016; (3) utilização de outro filtro para selecionar somente artigos publicados em periódicos científicos; (4) ordenação dos resultados por relevância a partir de uma funcionalidade contida nas bases (com exceção de *emerald* e *google acadêmico*); (5) seleção dos mil primeiros resultados listados; (6) análise do título, do resumo, das

palavras-chave e às vezes do conteúdo dos artigos para eliminar aqueles que não contemplavam o desenvolvimento de modelos quantitativos para apoiar a avaliação de desempenho de cadeias de suprimento e; (7) eliminação das cópias dos artigos repetidos, ou seja, aqueles que foram listados e selecionados em mais de um portal. O Quadro 4 apresenta a quantidade resultante de artigos após a execução de cada um dos procedimentos de coleta descritos.

Quadro 4 - Resultados da busca e seleção de modelos usando a *string* “*supply chain performance evaluation*”.

Base de periódicos	1	2	3	4	5	6	7
<i>Science direct</i>	63.311	58.118	48.681	48.681	1.000	35	35
<i>Emerald</i>	16.566	14.649	14.566	14.566	1.000	21	21
<i>IEEE Xplore</i>	495	494	25	25	25	4	4
<i>Scopus</i>	1.823	1.638	762	762	762	37	12
<i>Google Scholar</i>	1.800.000	16.400	-	16.400	1.000	39	21
Total							93

Fonte: Proposto pelo autor.

Em relação ao filtro utilizado no passo 2, a seleção dos artigos publicados a partir de 1995 visa eliminar dos resultados da busca os modelos de avaliação de desempenho intraorganizacional, já que as pesquisas sobre gestão de desempenho de cadeias de suprimento emergiram a partir de meados da década de 1990. Quanto ao filtro usado no passo 3, a seleção inicial dos artigos foi limitada a mil estudos principalmente porque o *google acadêmico* permite acessar somente os mil primeiros resultados da busca.

Alguns imprevistos ocorreram durante a realização da busca de artigos. No caso das buscas usando o *google scholar*, como esta não apresenta a funcionalidade de buscar somente artigos de periódicos, os resultados apresentados referentes ao passo 3 também incluem alguns artigos publicados em anais de eventos e resumos de artigos de periódicos. Como o filtro do *emerald* também possui essa limitação, os resultados apresentados no passo 3 neste caso incluem capítulos de livro.


Quanto aos artigos eliminados no passo 3, estes contemplavam revisões sistemáticas sobre diversos assuntos, ontologias para gestão de cadeias de suprimento, modelos para seleção e monitoramento do desempenho de seleção de fornecedores, modelos para avaliação de desempenho intraorganizacional, modelos para o desenvolvimento de redes colaborativas, modelos baseados em teorias de filas para simulação de fluxos em cadeias, modelos quantitativos para ponderação de indicadores de desempenho, estudos sobre a influência de tecnologias, práticas de gestão verdes, práticas colaborativas, integração e responsabilidade social sobre o desempenho da cadeia, modelos para escalonamento de pedidos, para previsão de demanda, modelos conceituais para medição de desempenho de cadeias de suprimento, entre outros.

Conforme mostra o Quadro 4, 93 artigos foram selecionados e analisados. Visando caracterizar o estado da arte do uso de modelos quantitativos para avaliação de desempenho de cadeias de suprimento, foram coletadas diversas informações, as quais foram organizadas em uma planilha eletrônica e dispostas em gráficos. Em relação à origem dos estudos, foram extraídas informações sobre o ano de publicação do artigo, o país de origem dos autores e o nome do periódico em que foi publicado. Sobre as características dos modelos propostos por cada estudo, foram analisados o escopo do modelo proposto, a forma de seleção dos indicadores de desempenho, a técnica(s) quantitativa utilizada, a abordagem utilizada para modelagem de incerteza, o tipo de estratégia competitiva adotada e a fonte dos valores de desempenho da cadeia avaliada. Finalmente, sobre a aplicação e validação dos modelos, foram extraídas informações sobre o tipo de aplicação (real ou simulada), o setor industrial da empresa-foco da cadeia (somente nos casos de aplicação real) e a forma de validação do modelo proposto. A partir de uma análise crítica dos resultados encontrados, foram identificadas algumas oportunidades de pesquisa.

2.6.2 Origem dos estudos analisados

A Figura 14 mostra o percentual de modelos analisados de acordo com o ano de publicação. Os primeiros modelos encontrados foram publicados em 2003, o que sugere que o uso de métodos multicritério de tomada de decisão (*Multicriteria Decision Making*, MCDM), técnicas estatísticas, sistemas inteligentes, programação matemática e simulação é relativamente recente na literatura acadêmica deste tema. Nota-se também que a quantidade de publicações vem crescendo consideravelmente, já que 71% dos estudos analisados foram publicados a partir de 2011.


Figura 14 - Quantidade de estudos por ano de publicação



Fonte: Proposto pelo autor.

A Figura 15 apresenta a frequência de estudos publicados de acordo com o país de origem dos pesquisadores. Como pode ser visto, os pesquisadores dos países China, Índia, Irã e França são responsáveis pela produção da maioria dos estudos encontrados, enquanto 4,3 % é de autoria de pesquisadores brasileiros. Embora o total de estudos analisados nesta pesquisa seja de 93, o somatório da frequência de alguns eventos pode ultrapassar este número. Isso se deve ao fato de que, por exemplo, um estudo pode ser originário de mais de um país, assim como pode abordar a utilização de mais de uma técnica.

Figura 15 - Quantidade de estudos por país de origem




Fonte: Proposto pelo autor.

A Figura 16 identifica os periódicos nos quais os artigos analisados foram publicados ou, em alguns casos, foram aceitos para publicação e estão em edição. Há

grande diversidade de periódicos interessados neste tema de pesquisa, visto que foram identificados 59 periódicos diferentes. Os periódicos *Production Planning & Control* e *International Journal of Production Economics* apresentaram maior quantidade de estudos publicados sobre o tema de pesquisa, somando juntos 10,8% do total. As informações da Figura 16 são úteis para ajudar pesquisadores deste tema a escolher um periódico adequado para submeter seus artigos, de modo a obter o crivo de avaliadores especializados no tema e a agregar valor ao estudo por meio de contribuições mais precisas e consistentes.

Figura 16 - Quantidade de estudos por periódico de origem



Fonte: Proposto pelo autor.

2.6.3 Características dos modelos

Os Quadros 5 a 9 listam todos os modelos analisados, destacando os autores e o escopo de avaliação de cada um. Enquanto a maioria dos modelos considera várias dimensões de desempenho na avaliação (escopo amplo), alguns focam em dimensões de desempenho específicas, relacionadas à colaboração, desempenho ambiental, agilidade, flexibilidade, responsividade, eficiência ou fatores externos. Todos os modelos têm o propósito de avaliar o desempenho de cadeias de suprimento, sendo que sete deles também são capazes de apoiar *benchmarking* (WONG; WONG, 2007; JALALVAND et al., 2011; JOSHI et al., 2011; DEY; CHEFFI, 2013; NIKFARJAM et al., 2015; SAHU et al., 2014; SAHU et al., 2015), enquanto outros três propõem o uso de uma abordagem preditiva para estimar indicadores de resultado com base nos valores de indicadores de tendência, ou para avaliar a estabilidade do desempenho da cadeia ao longo do tempo (GANGA; CARPINETTI, 2011; IP et al., 2011; ABOLGHASEMI et al., 2015).

Quadro 5 – Modelos de avaliação de desempenho de cadeias de suprimento coletados no *Science Direct*

Autor(es)	Breve descrição do estudo	Escopo
Berrah e Cliville (2007)	Sistema de medição de desempenho de cadeias baseado no desdobramento e agregação de indicadores	Amplo
Yeh, Chen e Chi (2007)	Avaliação de desempenho da gestão de cadeias de suprimento usando o ciclo DMAIC	Amplo
Bhaskar e Lallement (2008)	Avaliação do desempenho das atividades de rotina de cadeias baseada nos tempos médios de espera	Amplo
Comelli, Fénìès e Tchernev (2008)	Avaliação de desempenho dos fluxos físicos e financeiros dos processos logísticos e do planejamento da produção de cadeias de suprimento	Amplo
Gong (2008)	Avaliação da flexibilidade de cadeias de suprimento	Flexibilidade
Jain, Benyoucef e Deshmukh (2008)	Avaliação da agilidade de cadeias de suprimento	Agilidade
Tsoufias e Pappis (2008)	Avaliação do desempenho ambiental de cadeias de suprimento	Amplo
Cai et al. (2009)	Modelo baseado em uma abordagem iterativa para analisar quantitativamente os relacionamentos de interdependência entre os indicadores e melhorar o desempenho	Amplo
Xu et al. (2009)	Aplicação da análise por envoltória de dados na avaliação de desempenho de cadeias de suprimento	Amplo
Chen e Yan (2011)	Avaliação do desempenho e do desperdício de recursos internos de cadeias de suprimento	Amplo
Chuu (2011)	Avaliação da flexibilidade de cadeias de suprimento	Flexibilidade
El-Baz (2011)	Avaliação do desempenho global de cadeias de suprimento	Amplo

Autor(es)	Breve descrição do estudo	Escopo
Erol, Sencer e Sari (2011)	Avaliação de cadeias de suprimento com base em aspectos ambientais, sociais e econômicos	Amplio
Ganga e Carpinetti (2011)	Predição de desempenho baseada na relação causal entre os indicadores do SCOR	Amplio
Joshi, Banwet e Shankar (2011)	Modelo de avaliação de desempenho e <i>benchmarking</i> para melhoria de cadeias de suprimento frias	Amplio
Naini et al. (2011)	Sistema de medição de desempenho para avaliação da gestão ambiental de cadeias de suprimento	Desempenho ambiental
Cho et al. (2012)	Medição de desempenho da gestão de cadeias de suprimento de serviços	Amplio
Olugu e Wong (2012)	Medição do desempenho dos ciclos direto e reverse em cadeias de suprimento	Amplio
Uysal (2012)	Modelo integrado para medição de desempenho de cadeias de suprimento sustentáveis	Amplio
Wu et al. (2012)	Avaliação de cadeias de suprimento supondo desmembramentos na estrutura	Amplio
Bas (2013)	Análise holística de cadeias de suprimento de eletricidade visando a avaliação de desempenho e o entendimento das interdependências entre os processos	Amplio
Fan et al. (2013)	Avaliação de desempenho de cadeias baseada em cinco dimensões de desempenho do <i>Balanced Scorecard</i>	Amplio
Tavana et al. (2013)	Avaliação de desempenho de cadeias de suprimento usando DEA	Amplio
Mirhedayatian, Azadi e Saen (2014)	Ferramenta para avaliação da gestão de cadeias de suprimento verdes	Amplio
Shafiee, Lotfi e Saleh (2014)	Avaliação de desempenho de cadeias de suprimento baseada no BSC	Amplio
Ahi e Searcy (2015)	Avaliação da sustentabilidade de cadeias de suprimento	Amplio
Bukhori, Widodo e Ismoyowati (2015)	Avaliação de desempenho de cadeias de suprimento de aves domésticas	Amplio
Chithambaranathan et al. (2015)	Avaliação do desempenho ambiental de cadeias de suprimento de serviços	Desempenho ambiental
Nikfarjam et al. (2015)	Medição da eficiência de cadeias de suprimento baseada em uma abordagem híbrida	Amplio
Tajbakhsh e Hassini (2015)	Avaliação da sustentabilidade de cadeias de suprimento	Amplio
Supeekit, Somboonwiwat e Kritchanhai (2016)	Abordagem para avaliar o desempenho da cadeia de suprimento interna de um hospital interno	Amplio
Ahi, Jaber e Searcy (2016)	Modelo multidimensional para avaliar o desempenho de cadeias de suprimento sustentáveis	Amplio

Autor(es)	Breve descrição do estudo	Escopo
Haghighi, Torabi e Ghasemi (2016)	Abordagem integrada para avaliação de desempenho de cadeias de suprimento sustentáveis	Amplio
Tavana et al. (2016)	Modelo para medição do desempenho de cadeias de suprimento em três níveis	Amplio
Uygun e Dede (2016)	Avaliação do desempenho de gestão de cadeias de suprimento “verdes” integrando técnicas de decisão multicritério	Desempenho ambiental

Fonte: Proposto pelo autor.

Quadro 6 – Modelos de avaliação de desempenho de cadeias de suprimento coletados no *Emerald*

Autor(es)	Breve descrição do estudo	Escopo
Chan e Qi (2003)	Avaliação de desempenho de cadeias de suprimento baseada em números <i>fuzzy</i> e comparação par a par	Amplio
Chan et al. (2003)	Medição de desempenho de cadeias de suprimento baseada em lógica <i>fuzzy</i>	Amplio
Sharma e Bhagwat (2007)	Medição do desempenho da gestão de cadeias de suprimento baseada na perspectiva do BSC	Amplio
Wong e Wong (2007)	Sistema de medição de desempenho de cadeias de suprimento baseado em DEA	Amplio
Theeranuphattana e Tang (2008)	Medição de desempenho da gestão de cadeias de suprimento baseada no SCOR [®]	Amplio
Varma, Wadhwa e Deshmukh (2008)	Avaliação do desempenho de cadeias de suprimento de petróleo baseada na combinação entre BSC e AHP	Amplio
Yang (2009)	Avaliação do desempenho de cadeias de suprimento baseada em números <i>fuzzy</i> e no método AHP	Amplio
Ip et al. (2011)	Modelagem do desempenho e da estabilidade de cadeias de suprimento	Amplio
Jalalvand et al. (2011)	Avaliação e comparação do desempenho de cadeias de suprimento de um mesmo setor	Amplio
Bai et al. (2012)	Avaliação da gestão de cadeias de suprimento baseada em medidas ecológicas sustentáveis	Amplio
Fattahi, Nookabadi e Kadivar (2013)	Medição de desempenho de cadeias de suprimento de carne	Amplio
Vaidya e Hudnurkar (2013)	Avaliação multicritério do desempenho de cadeias de suprimento	Amplio
Sahu, Datta e Mahapatra (2014)	Avaliação de desempenho e <i>benckmarking</i> entre cadeias de suprimento	Amplio
Kumar e Banerjee (2014)	Medição do desempenho da colaboração em cadeias de suprimento	Colaboração
Varsei et al. (2014)	Avaliação da sustentabilidade de cadeias de suprimento baseada em indicadores multidimensionais	Amplio

Autor(es)	Breve descrição do estudo	Escopo
Arif-Uz-Zaman e Ahsan (2014)	Medição de desempenho de cadeias de suprimento <i>lean</i>	Amplio
Chithambaranathan, Subramanian e Palaniappan (2015)	Um modelo para análise do desempenho dos membros de uma cadeia de suprimento	Amplio
Kumar, Mukherjee e Adlakha (2015)	Avaliação de desempenho dinâmico de um processo de cadeia de suprimento de uma indústria farmacêutica	Amplio
Pungchompoo e Sopadang (2015)	Avaliação do desempenho de cadeias de suprimento de camarão	Amplio
Sahu, Datta e Mahapatra (2015)	Avaliação de desempenho e <i>benchmarking</i> de cadeias de suprimento	Amplio
Shabani e Saen (2015)	Avaliação de desempenho e identificação de <i>benchmarks</i> de cadeias de suprimento <i>green</i>	Desempenho ambiental

Fonte: Proposto pelo autor.

Quadro 7 – Modelos de avaliação de desempenho de cadeias de suprimento coletados no *IEEEExplore*

Autor(es)	Breve descrição do estudo	Escopo
Chen et al. (2005)	Modelagem e avaliação do desempenho de cadeias de suprimento	Amplio
Albuquerque et al. (2010)	Avaliação do desempenho de estoque e logística de distribuição de cadeias de suprimento	Amplio
Agami, Saleh e Rasmy (2012)	Avaliação de desempenho e identificação dos indicadores críticos visando à melhoria de desempenho	Amplio
Agami, Saleh e Rasmy (2014)	Abordagem baseada em lógica <i>fuzzy</i> para gestão de desempenho de cadeias de suprimento	Fatores externos

Fonte: Proposto pelo autor.

Quadro 8 – Modelos de avaliação de desempenho de cadeias de suprimento coletados no *Scopus*

Autor(es)	Breve descrição do estudo	Escopo
Halman e Voordijk (2012)	Modelo balanceado para medição de desempenho de cadeias de suprimento de construção civil	Amplio
Yang e Jiang (2012)	Modelo hierárquico para avaliação do desempenho global de cadeias de suprimento	Amplio
Bai e Sarkis (2013)	Medição do desempenho de cadeias com foco na avaliação da flexibilidade da logística reversa	Flexibilidade
Behrouzi e Wong (2013)	Avaliação de cadeias de suprimento <i>lean</i>	Amplio
Gou, Shen e Chai (2013)	Método hierárquico de avaliação do desempenho de cadeias de suprimento de serviços de restauração	Amplio
Li (2013)	Modelo integrado para avaliação de sistemas de produção em cadeias de suprimento de ciclo fechado	Amplio

Autor(es)	Breve descrição do estudo	Escopo
Vinodh et al. (2013)	Avaliação da agilidade de cadeias de suprimento usando valores linguísticos	Amplo
Wang (2013)	Avaliação do desempenho de cadeias de suprimento de produtos agrícolas	Amplo
Jakhar e Barua (2014)	Modelo integrado para avaliação de desempenho de cadeias de suprimento e apoio à tomada de decisão	Amplo
Abolghasemi et al. (2015)	Abordagem baseada no SCOR® para avaliação de desempenho e gestão de riscos de cadeia de suprimento	Amplo
Sha et al. (2015)	Avaliação da eficiência de cadeias de suprimento	Eficiência
Xiyao e Hankun (2015)	Método de avaliação de desempenho de cadeias de suprimento de alimentos	Amplo

Fonte: Proposto pelo autor.

Quadro 9 – Modelos de avaliação de desempenho de cadeias de suprimento coletados no *Google Scholar*

Autor(es)	Breve descrição do estudo	Escopo
Chan (2003)	Medição de desempenho de cadeias de suprimento baseada em fatores quantitativos e qualitativos	Amplo
Sellito e Mendes (2006)	Avaliação comparativa do desempenho de cadeias de suprimento baseada no AHP	Amplo
Liang et al. (2006)	Avaliação da eficiência de cadeias de suprimento	Eficiência
Bhagwat e Sharma (2007)	Avaliação de práticas e estratégias de gestão de cadeias de suprimento	Amplo
Bhagwat e Sharma (2009)	Modelo integrado para otimização do desempenho global de cadeias de suprimento	Amplo
Golparvar e Seifbarghy (2009)	Priorização de ações para melhoria do desempenho de cadeias baseada em SCOR® e TOPSIS	Amplo
Jassbi, Seyedhosseini e Pilevari (2010)	Avaliação da agilidade de cadeias de suprimento	Agilidade
Seyedhosseini, Jassbi e Pilevari (2010)	Avaliação da agilidade de cadeias de suprimento	Agilidade
Avinash e Prakash (2011)	Sistema de medição de desempenho de gestão de cadeias de suprimento	Amplo
Clivillé e Berrah (2012)	Medição do desempenho global de cadeias de suprimento baseada no modelo SCOR®	Amplo
Dey e Cheffi (2013)	Comparação do desempenho de cadeias de suprimento verdes	Desempenho ambiental
Kocaoglu, Gülsün e Tanya (2013)	Avaliação de estratégias de gestão de cadeias de suprimento baseada no SCOR®	Amplo
Bhattacharya et al. (2014)	Medição de desempenho de cadeias de suprimento verdes usando BSC e <i>fuzzy</i> ANP	Desempenho ambiental

Autor(es)	Breve descrição do estudo	Escopo
Khamseh e Zahmatkesh (2015)	Avaliação de desempenho de cadeias de suprimento usando análise por envoltório de dados robusta	Amplo
Omar et al. (2015)	Modelo para avaliação qualitativa de responsividade de cadeias de suprimento	Responsividade
Omrani e Keshavarz (2015)	Avaliação de desempenho de uma cadeia de suprimento de navio	Amplo
Sellitto et al. (2015)	Modelo baseado no SCOR® para medição do desempenho de cadeias de suprimento de calçados	Amplo
Ashrafuzzaman et al. (2016)	Modelo baseado no QFD (<i>Quality Function Deployment</i>) para medir o desempenho de cadeias de suprimento	Amplo
Massami e Myamba (2016)	Avaliação do desempenho de cadeias de suprimento de produtos de couro	Amplo
Panjehfouladgaran e Yusuff (2016)	Medição de desempenho de cadeias de suprimento de fabricantes de luvas de borracha	Amplo
Ramana, Rao e Kumar (2016)	Avaliação de cadeias de suprimento usando os métodos multicritério	Amplo

Fonte: Proposto pelo autor.

O Quadro 10 sugere uma classificação dos modelos quantitativos de avaliação de desempenho de cadeias de suprimento baseada em cinco tipos, definidos de acordo com a natureza da(s) técnica(s) adotada. Sob a perspectiva dessa classificação, as técnicas de tomada de decisão multicritério (MCDM) são o tipo mais comumente adotado (50,5 %), seguido pelos métodos de programação matemática (21,5 %), inteligência artificial (11,8 %), simulação (5,4 %) e técnicas estatísticas (5,4 %). Também foi identificada a combinação de técnicas MCDM com métodos de programação matemática (4,3 %) e com técnicas de inteligência artificial (1,1 %).

Quadro 10 – Classificação dos modelos quantitativos de avaliação de cadeias de suprimento


Tipo	Técnicas usadas
MCDM	AHP, <i>fuzzy</i> AHP, <i>fuzzy</i> ANP (<i>Analytic Network Process</i>), MACBETH, TOPSIS, <i>fuzzy</i> TOPSIS, método <i>fuzzy</i> baseado no operador LOWGA (<i>Linguistic Ordered Weighted Geometric Averaging</i>) modificado, Two-tuple, teoria de utilidade multiatributo <i>fuzzy</i> , DEMATEL (<i>Decision Making Trial and Evaluation Laboratory</i>), ELECTRE (<i>Elimination and Choice Expressing Reality</i>), PROMETHEE, VIKOR (<i>Visekriterijumska Optimizacija I Kompromisno Resenje</i>), <i>fuzzy</i> VIKOR, média ponderada <i>fuzzy</i> , modelo hierárquico analítico, teoria dos conjuntos <i>rough</i> , teoria dos sistemas <i>grey</i> , avaliação <i>fuzzy</i> multiestágio e novo método MCDM baseado em comparações.
Programação matemática	DEA, programação linear, programação não linear, programação por metas, programação <i>rough</i> , matriz de transformação de custo e otimização multiobjetivo.
Inteligência artificial	Mineração de dados, sistemas de inferência <i>fuzzy</i> , algoritmo genético, redes neurais artificiais e ANFIS (<i>Adaptive Network-based Fuzzy Inference System</i>).
Estocásticos	Teoria de probabilidade, ARIMA (<i>Auto Regressive Integrated Moving Average</i>), abordagem estocástica- <i>fuzzy</i> integrada e redes de Petri estocásticas
Simulação	Simulação de eventos discretos, método de agregação cíclico, redes Bayesianas, teorias das filas e sistemas dinâmicos.

Fonte: Proposto pelo autor.

A Figura 17 apresenta a frequência de uso de todas as técnicas quantitativas identificadas. Como algumas técnicas não possuem um nome definido, são pouco conhecidas e tiveram somente uma ocorrência na amostra, estas foram agrupadas como “métodos baseados na teoria dos conjuntos *fuzzy*” ou “novo método MCDM”. Enquanto 63,4% dos modelos analisados são baseados em uma única técnica, 36,6 % utilizam duas ou mais técnicas combinadas (por exemplo, adotam o método AHP para ponderar os indicadores e o método TOPSIS para avaliar o desempenho da cadeia). Como pode ser visto na Figura 17, foram identificadas mais de 40 técnicas no total. A mais utilizada dentre aquelas aplicadas isoladamente é o método AHP, seguido por DEA e inferência *fuzzy*. Quanto às técnicas aplicadas de forma combinada, as mais exploradas são AHP, DEA e programação linear. A variedade de técnicas usadas ajuda a incorporar novas funcionalidades aos sistemas de avaliação de desempenho de cadeias de suprimento. Enquanto técnicas como o AHP permitem realizar uma análise comparativa visando ao *benchmarking* entre os valores de desempenho alcançados por cada cadeia, técnicas como teoria das filas e redes de petri permitem compreender o comportamento de alguns indicadores de desempenho ao longo do tempo por modelar o comportamento dinâmico dos elos e dos fluxos da cadeia. Já os modelos baseados em inferência *fuzzy* permitem

melhor compreensão e análise das relações de causa e efeito entre os indicadores devido ao uso de regras de inferência de fácil interpretação, o que justifica seu uso em sistemas de predição de desempenho.

Figura 17 - Listagem de técnicas identificadas e frequência de uso




Fonte: Proposto pelo autor.

Dentre os 93 modelos, 64 (68,8 %) utilizam alguma abordagem para lidar com incerteza. Nota-se um grande interesse dos pesquisadores pelas técnicas baseadas em lógica *fuzzy*, uma vez que estas correspondem a 31,2% do total. Isso pode estar

relacionado à capacidade das abordagens *fuzzy* de apoiar problemas que envolvem variáveis qualitativas, ausência de informação, valores imprecisos e julgamentos subjetivos, que são muitos frequentes na avaliação de desempenho de cadeias de suprimento. Conforme mostra a Figura 18, além da lógica *fuzzy*, há outras abordagens para lidar com incerteza nesse domínio de problema. A mais frequente delas é a comparação pareada entre os elementos do problema (indicadores e / ou cadeias). Outras abordagens menos utilizadas são baseadas em *rough set theory*, probabilidade, *grey system theory* e *2-tuple*.

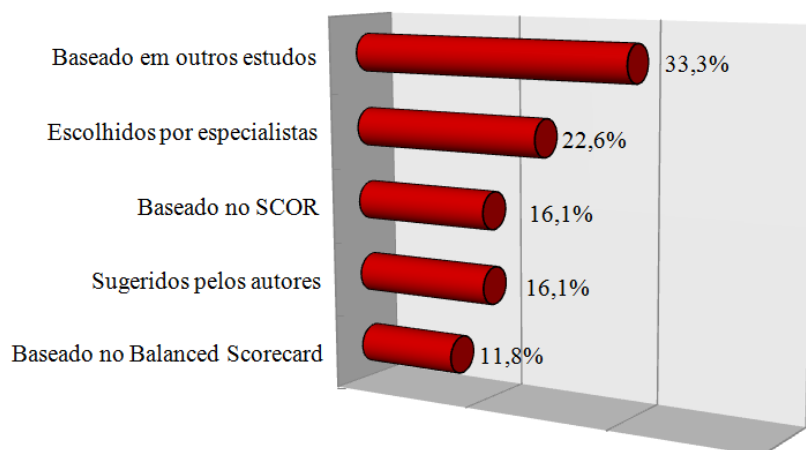
Figura 18 – Abordagens utilizadas pelos modelos analisados para lidar com incerteza



Fonte: Proposto pelo autor.

Os modelos analisados também se distinguem em relação ao tipo de estratégia competitiva adotada pela cadeia de suprimento. A maioria dos estudos não considera uma estratégia específica (79,6 %), enquanto outros adotam estratégias do tipo sustentável (8,6 %), *green* (5,4 %), ágil (3,2 %), *lean* (2,2 %) e flexível (1,1 %). Em relação aos indicadores de desempenho adotados em cada modelo, não foi possível mapear a frequência desses indicadores devido à grande quantidade identificada. Todavia, foi possível identificar a fonte de origem dos indicadores adotados. Conforme ilustra a Figura 19, cerca de 33,3 % dos modelos tiveram seus indicadores escolhidos a partir de outros estudos da literatura, enquanto 22,6 % foram selecionados com base na opinião de especialistas e 16,1 % foram definidos pelos próprios autores sem apresentar evidências de como isso foi feito. Há também modelos que utilizam os indicadores do SCOR[®] (16,1 %) e do BSC (11,8 %).


Figura 19 – Fonte dos indicadores de desempenho utilizados nos modelos analisados



Fonte: Proposto pelo autor.

Quanto aos valores de desempenho alcançados pela(s) cadeia(s) avaliada em cada indicador, conforme ilustra a Figura 20, mais da metade dos estudos estima tais valores com base na opinião de um conjunto de especialistas (55,4%). Na maioria dos casos, esse conjunto de especialistas é composto por funcionários de compras, qualidade, logística e / ou vendas da empresa-foco avaliada. Em alguns casos, também inclui funcionários de fornecedores, de distribuidores ou ainda clientes finais da cadeia.

Figura 20 - Fonte dos dados para quantificação do desempenho da(s) cadeia(s) avaliada em cada modelo



Fonte: Proposto pelo autor.


Além da maioria dos estudos estimar os valores de desempenho de forma aproximada com base em julgamentos subjetivos, 29,7% dos modelos analisados utilizam dados simulados, geralmente gerados aleatoriamente. Nota-se que somente 6,8% dos modelos utilizam dados reais provenientes do histórico de desempenho da empresa, enquanto outros 6,8 % usam dados históricos combinados com estimativas baseadas na

opinião de especialistas. Esses dados parecem reforçar a dificuldade já relatada em outros estudos para se obter dados reais sobre o desempenho dos processos de gestão de cadeias de suprimento.

2.6.4 Aplicação e validação dos modelos

Enquanto 38 estudos (40,9 %) realizam aplicações simuladas dos modelos propostos, 55 (59,1 %) apresentam aplicações reais ou exemplos que são baseados em cenários e informações reais, geralmente provenientes do julgamento de especialistas. Conforme mostra a Figura 21, dentre as aplicações reais, o setor automotivo apresenta maior destaque, com 11 estudos. Outros setores bastante frequentes incluem o alimentício, eletroeletrônico e o setor químico. Acredita-se que o grande número de aplicações na indústria automotiva se deva ao fato de este setor ser tradicionalmente pioneiro na adoção de práticas de gestão e de medição de desempenho de fornecedores e de cadeias de suprimento. Já a grande incidência de aplicações de medição de desempenho na indústria alimentícia parece estar relacionada à necessidade dessas cadeias de garantir uma logística eficiente para evitar a perda de produtos perecíveis.

Figura 21 - Aplicações reais de acordo com o setor da cadeia de suprimento

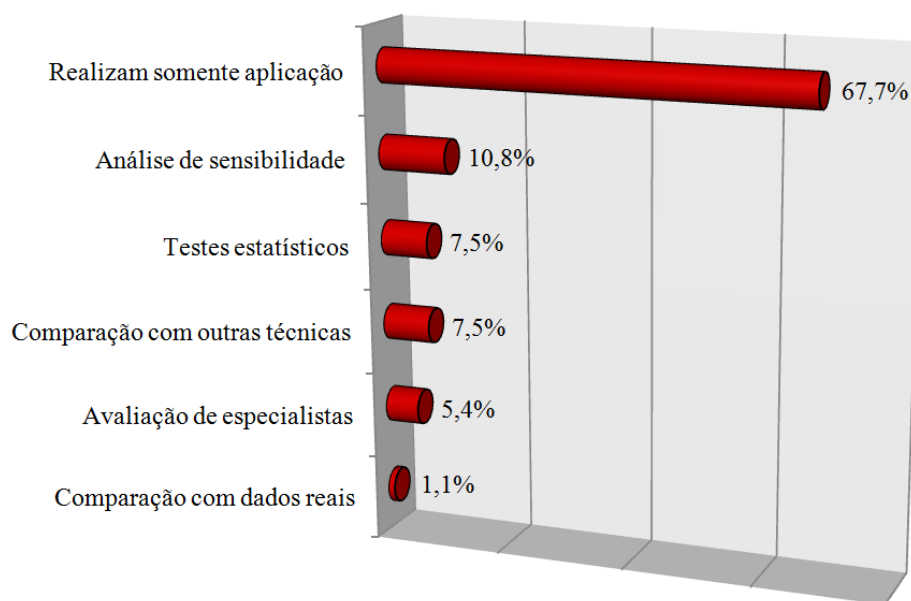


Fonte: Proposto pelo autor.

Diferentes estratégias são usadas para validar os modelos propostos e para demonstrar sua adequação à avaliação de desempenho de cadeias de suprimento. Conforme mostra a Figura 22, enquanto a maioria (67,2 %) dos estudos realiza somente uma aplicação e não adota nenhuma técnica específica para validação do modelo, 10,8% realiza experimentos de análise de sensibilidade das respostas obtidas. Isso é feito a partir

da análise dos efeitos gerados na(s) variável(is) de saída a partir de variações nos valores das variáveis de entrada do modelo. Somente 7,5 % realizam experimentos envolvendo técnicas estatísticas como teste de hipótese, análise de superfície de resposta e análise de variância para verificar a consistência das respostas do modelo, ao passo que 5,4 % utilizam a opinião de especialistas para este propósito. Finalmente, somente 7,5 % dos estudos comparam os resultados fornecidos pelo modelo proposto com os valores fornecidos por técnicas diferentes.

Figura 22 – Abordagens utilizadas para validação dos modelos



Fonte: Proposto pelo autor.

2.6.5 Análise crítica e oportunidades de pesquisa

A realização de um levantamento sistematizado de artigos que propõem modelos quantitativos para avaliação de desempenho de cadeias de suprimento permitiu identificar algumas oportunidades para pesquisas futuras. Em relação às estratégias competitivas consideradas pelos modelos revisados, constatou-se que poucos modelos focam na avaliação das estratégias ágeis, *lean* e flexível. Nesse sentido, novos estudos podem ser desenvolvidos a fim de testar a utilização de técnicas ainda não aplicadas em ambientes que adotam essas estratégias competitivas, bem como para avaliar a adequação de uso das técnicas às particularidades dos ambientes em questão.

Embora as estratégias sustentável e *green* tenham sido as mais adotadas, vários modelos baseados nestas estratégias competitivas incluem somente métricas de desempenho relacionadas a aspectos ambientais e sociais (UYSAL; 2012; VARSEI et al., 2014; CHITHAMBARANATHAN et al., 2015a; UYGUN; DEDE, 2016), sem

considerar fatores relacionados à gestão, como a efetividade dos processos logísticos, serviço ao cliente, riscos, colaboração e níveis de inventário. Além disso, o uso de modelos baseados em uma única dimensão de desempenho (GONG, 2008; JAIN et al., 2008; JASSBI et al., 2010; SEYEDHOSSEINI et al., 2010; CHUU, 2011; BAI; SARKIS, 2013; KUMAR; BANERJEE, 2014, CHITHAMBARANATHAN et al., 2015a) não parece adequado para situações reais, uma vez que estes proveem uma visão limitada do desempenho global da(s) cadeia(s) de suprimento avaliada. Portanto, sugere-se que aplicações futuras desses modelos incluam outras dimensões e métricas de desempenho alinhadas com os processos de negócio e os objetivos estratégicos da cadeia de suprimento avaliada. Estudos futuros também podem desenvolver modelos voltados para os setores agrícola, governamental, moveleiro, calçadista e naval, os quais vem recebendo pouca atenção.

Outra observação referente à seleção dos indicadores de desempenho se refere aos modelos que utilizam métricas extraídas *Balanced Scorecard* (BSC), que foi desenvolvido para avaliação de desempenho no contexto intraorganizacional. Nesse grupo estão incluídos os modelos propostos por Sharma e Bhagwat (2007), Bhagwat e Sharma (2007), Varma, Wadhwa e Deshmukh (2008), Yang (2009), Albuquerque et al. (2010), Halman e Voordijk (2012) e Fan et al. (2013). Autores como Estampe et al. (2013) alertam que o BSC foi desenvolvido para avaliação de entidades autônomas e por isso não considera a complexidade das relações existentes em cadeias de suprimento. Outra restrição apontada por esses autores é que a adoção dos indicadores do BSC não permite a realização de *benchmarking* externo entre cadeias de suprimento. Embora os modelos que adotam os indicadores do SCOR[®] não sofram dessa limitação, com exceção dos modelos propostos por Ganga e Carpinetti (2011) e Agami, Saleh e Rasmy (2014), todos os outros utilizam técnicas que não são capazes de modelar os relacionamentos não lineares que existem entre alguns dos indicadores dos níveis 1 e 2.

A respeito da abrangência da avaliação de desempenho ao longo dos elos da(s) cadeia(s) avaliada, a maioria dos estudos realiza a avaliação sob a perspectiva da empresa foco em relação ao seu próprio desempenho e ao desempenho de seus fornecedores e clientes de primeira camada (BERRAH; CLIVILLE, 2007, YEH; CHEN, CHI, 2007; THEERANUPHATTANA; TANG, 2008; OLUGU; WONG, 2012; BEHROUZI; WONG, 2013; VINODH et al., 2013; ARIF-UZ-ZAMAN; AHSAN, 2014). Entretanto, há estudos que possuem um escopo de avaliação mais amplo, considerando quatro ou mais camadas da cadeia (BAS, 2013; FATTAHI; NOOKABADI; KADIVAR, 2013;

TAVANA et al., 2013; MIRHEDAYATIAN; AZADI; SAEN, 2014). Em outra via, há estudos que avaliam somente o desempenho intraorganizacional, sem incluir métricas relacionadas ao ambiente externo (TAVANA et al., 2013, MIRHEDAYATIAN; AZADI; SAEN, 2014). Portanto, estudos futuros devem considerar a ampliação do escopo de avaliação de desempenho ao longo da cadeia, incluindo métricas que representem o desempenho global das diferentes camadas sob avaliação.

Uma constatação interessante é que 51 modelos (68,9% do total) são baseados em técnicas voltadas para problemas que envolvem incerteza. Acredita-se que a ampla adoção dessas técnicas se deva à necessidade de considerar o peso relativo dos indicadores de desempenho e de usar indicadores qualitativos (como nível de confiança, colaboração e comunicação) na avaliação de cadeias de suprimento. A adoção dessas técnicas também pode estar relacionada ao fato de que, na maioria das aplicações, os valores de desempenho da cadeia são avaliados de forma aproximada com base em julgamentos numéricos ou linguísticos de especialistas, uma vez que há grande dificuldade de coleta de dados reais. As técnicas adequadas para modelagem de incerteza utilizam recursos como números intervalares, funções de pertinência e comparação pareada para quantificar valores imprecisos. Embora as técnicas baseadas em comparação pareada sejam as mais recorrentes, tais abordagens limitam a quantidade de indicadores ou de cadeias de suprimento que podem ser comparados simultaneamente, uma vez que os seres humanos possuem limitações em sua capacidade cognitiva que lhes impedem de julgar comparativamente mais de nove alternativas de modo consistente (MILLER, 1994).

Apesar de terem sido identificadas aplicações de mais de 40 técnicas diferentes, ainda há algumas técnicas que não foram testadas no apoio à avaliação de desempenho de cadeias de suprimento. Estudos futuros podem considerar o uso de técnicas como ORESTE (*Organization Rangement Et Synthese De Donnes Relationnelles*), ANP (*Analytic Network Process*), SMART (*Simple Multi Attribute Rating Technique*), *intuitionistic fuzzy sets* e *hesitant fuzzy sets*. O método *fuzzy* QFD também pode ser aplicado na ponderação das métricas de desempenho, de modo a considerar o relacionamento destas métricas com os requisitos competitivos das cadeias avaliadas. Outra sugestão para estudos futuros consiste no uso do método *fuzzy* TOPSIS para construir modelos de avaliação de desempenho envolvendo *benchmarking* entre cadeias de suprimento. Nessas possíveis aplicações, os *benchmarks* em cada métrica seriam dados pela solução ideal positiva *fuzzy*, enquanto o método da distância euclidiana (CHEN,

2000) poderia ser aplicado para estimar a lacuna entre o desempenho real e o desempenho desejado em cada métrica.

Com relação aos modelos de avaliação com uma abordagem preditiva, verifica-se a oportunidade de desenvolver novos modelos baseados nas métricas do SCOR® em combinação com sistemas ANFIS e com redes neurais artificiais, seja do tipo perceptron multicamada (MLP) ou redes de função de base radial, permitindo assim a adaptação do modelo preditivo ao ambiente de uso com base em dados históricos. Outra sugestão para estudos futuros consiste na aplicação de redes neurais de entradas atrasadas (*Time Delay Neural Network*, TDNN) para analisar e projetar a estabilidade ao longo do tempo das métricas de desempenho adotadas.

Por último, embora existam alguns trabalhos que comparem os resultados da aplicação de uma técnica em particular com os resultados obtidos usando outras técnicas (YET et al., 2007, XU et al., 2009, CHUU, 2011, WU et al., 2012, WANG, 2013, KUMAR et al., 2015, XIYAO; HANKUN, 2015), não foram identificados estudos que apontem as vantagens e limitações de uso de diferentes técnicas quando usadas para apoiar a avaliação de desempenho de cadeias de suprimento. Uma vez que a adequação das técnicas usadas depende do alinhamento de suas características com os requisitos do domínio de problema em questão, verifica-se a necessidade de desenvolver estudos que avaliem a adequabilidade de diferentes técnicas considerando o contexto de avaliação de desempenho de cadeias de suprimento. Visando obter embasamento teórico e técnico para realizar o primeiro estudo desse tipo, são discutidos a seguir diversos aspectos referentes às técnicas que serão avaliadas.

Capítulo 3

MODELAGEM DE SISTEMAS INTELIGENTES

3.1 APRESENTAÇÃO DO CAPÍTULO

Inicialmente, este capítulo apresenta um breve histórico da evolução dos chamados sistemas inteligentes (do inglês *intelligent systems*), destacando as principais correntes de pensamento existentes neste campo da inteligência artificial. Em seguida, três tipos de sistemas inteligentes são detalhados: redes neurais artificiais, sistemas *fuzzy* e sistemas neuro-*fuzzy*. São apresentados os conceitos fundamentais para o entendimento desses sistemas, suas particularidades, aplicações, operações matemáticas, procedimentos algorítmicos e limitações. Também são apresentadas algumas recomendações para modelagem de redes neurais perceptron de múltiplas camadas e sistemas neuro-*fuzzy*. Finalmente, é feita uma revisão sobre os estudos comparativos já realizados entre redes perceptron de múltiplas camadas e sistemas neuro-*fuzzy*. Os conceitos e discussões apresentados neste capítulo são fundamentais para entender o processo de desenvolvimento e o funcionamento dos modelos de predição de desempenho desenvolvidos neste estudo, bem como a análise comparativa que será realizada entre eles.

3.2 BREVE HISTÓRICO DA INTELIGÊNCIA ARTIFICIAL

De acordo com a definição apresentada em Rich (1988), a inteligência artificial se refere ao estudo de como fazer os computadores realizarem tarefas em que, no momento, as pessoas são melhores. Embora o termo “inteligência artificial” (IA, ou *Artificial Intelligence*) só tenha sido mencionado oficialmente em 1956, em uma conferência de pesquisadores realizada no Dartmouth College, nos Estados Unidos, algumas das correntes de pensamento que embasaram seu desenvolvimento surgiram na década de 1930 (BITTENCOURT, 2006).

A IA pode ser dividida em três linhas de pensamento: a simbólica (ou cognitiva), a conexionista e a evolutiva. A linha conexionista procura desenvolver sistemas que simulem o comportamento inteligente do cérebro por meio da imitação de seus componentes e processos. O primeiro modelo conexionista foi proposto em 1943 com base em teorias da neurologia. Esse modelo consistia de um neurônio artificial que foi

aplicado em um problema de classificação de padrões. Modelos conexionistas trabalham com variáveis contínuas e realizam operações numéricas. Uma vantagem dos modelos conexionistas é a facilidade de inserção de novos conhecimentos obtidos a partir de julgamentos de especialistas ou por meio de métodos automáticos de aprendizagem (SILVA; SPATI; FLAUZINO, 2010).

Ao contrário da IA conexionista, a IA simbólica apoiava-se em modelos da psicologia cognitiva da época, que investigava como ocorria o aprendizado através do processo de percepção humano de uma forma simbólica e abstrata, sem considerar os processos cerebrais do ponto de vista da neurologia. Na década de 1950 surgiram os primeiros modelos simbólicos, baseados em regras de produção e lógica de predicados, que apresentavam um bom desempenho em problemas bastante específicos. Esses sistemas modelavam o conhecimento através de unidades discretas (símbolos que representam dados ou conceitos), os quais eram processados por meio de regras lógicas inseridas no modelo. Desta forma, os sistemas simbólicos alcançavam um comportamento considerado inteligente, embora a “inteligência” contida neles dependesse das regras criadas pelo programador e não da capacidade de raciocínio do sistema em si. Na década de 1950 também foi proposto o teste de Turing, que pode ser visto como o primeiro método para avaliação da capacidade de inteligência de um sistema computacional (BITTENCOURT, 2006).

Os avanços alcançados inicialmente pelos estudos em IA causaram grande entusiasmo e otimismo por parte dos pesquisadores na época. Em 1956, alguns estudiosos da área previam que em cerca de 10 anos seria possível construir máquinas totalmente inteligentes. Contudo, como tal previsão subestimava a complexidade da modelagem de problemas reais usando as técnicas da época e desconsiderava as limitações na capacidade de processamento dos computadores, esta obviamente não foi realizada e causou grande decepção e desinteresse nos patrocinadores das pesquisas relacionadas. Ainda na década de 1960, outra decepção quanto aos resultados da IA foi causada pelo desempenho insatisfatório dos sistemas de tradução automática de textos (BITTENCOURT, 2006).

Nas décadas de 1960 e 1970, visando superar as limitações dos sistemas inteligentes existentes na época, foram desenvolvidos novos formalismos para representação de conhecimento. Para superar as limitações da lógica de primeira ordem utilizada pelos sistemas simbólicos, foram desenvolvidas lógicas não convencionais para permitir a representação de crenças, incoerências e incompletudes. Exemplos são a lógica

modal, a lógica de exceções e a lógica *fuzzy*, sendo que esta última recebeu diversas aplicações nas décadas seguintes (BITTENCOURT, 2006; REZENDE, 2003).

Já na década de 1980, um avanço da IA que chamou a atenção dos empresários se refere ao desenvolvimento dos chamados sistemas especialistas. Todavia, embora tais sistemas apresentassem ótimos resultados em aplicações bastante específicas, a distribuição comercial era inviabilizada porque cada problema a ser tratado requeria uma implementação particular. Por causa disso, ao invés de sistemas especialistas, as empresas optaram por comercializar ferramentas para construção de sistemas especialistas dotadas de mecanismos de inferência. Todavia, essas ferramentas não alcançaram sucesso de mercado devido à dificuldade de programá-las e de se adquirir o conhecimento que era necessário para modelar um problema real, por mais simples que ele fosse (BITTENCOURT, 2006).

Outra linha da IA surgida por volta da década de 1960 é conhecida como abordagem evolutiva, uma vez que esta é baseada em mecanismos evolutivos presentes na natureza, como a auto-organização e o comportamento adaptativo. Na década de 1980 surgiram os primeiros *softwares* comerciais que implementavam métodos evolutivos. Exemplos desses métodos são os algoritmos genéticos e os autômatos celulares. Outro marco dessa década foi a reascensão do interesse dos pesquisadores pela abordagem conexionista, quando grandes projetos surgiram sob o financiamento do governo nos Estados Unidos e no Japão (BITTENCOURT, 2006).

Nos anos 1990, houve avanços significativos em várias áreas da IA, tais como aprendizagem de máquinas, agentes inteligentes, robótica, mineração de dados, raciocínio envolvendo incerteza, entre outras. Embora muitos avanços tenham sido alcançados ao longo de várias décadas de pesquisa, ainda não existe uma teoria unificada que oriente os estudos na área, pois ainda não há consenso entre os pesquisadores em relação a vários conceitos fundamentais (BITTENCOURT, 2006).

Atualmente as técnicas de IA ainda estão distantes da capacidade de processamento humana. Muitas pesquisas vêm desenvolvendo aplicações de técnicas existentes em problemas que ainda não haviam sido explorados, com destaque para a área de gestão de operações. Outros estudos vêm buscando superar as limitações das técnicas por meio da combinação entre métodos já existentes, permitindo assim usufruir de vantagens específicas de cada um. Exemplos desses estudos envolvem a combinação de lógica *fuzzy* com algoritmos genéticos e com redes neurais artificiais.


Dada a diversidade de tipos de sistemas inteligentes existentes na literatura, este capítulo foca somente naqueles que são utilizados de alguma forma neste estudo. Portanto, a seguir são descritas três técnicas de inteligência artificial que vem sendo exploradas no apoio à tomada de decisão na área de gestão de operações: redes neurais artificiais, sistemas *fuzzy* e sistemas neuro-*fuzzy*.

3.3 REDES NEURAIS ARTIFICIAIS

Os modelos computacionais conhecidos como redes neurais artificiais foram desenvolvidos a partir da inspiração no sistema nervoso de seres vivos. No cérebro humano, o processamento de informações é feito por elementos biológicos interligados, denominados neurônios, que trabalham paralelamente a fim de produzir ações para cada uma de suas funções (como pensar e memorizar). De forma similar, o processamento de informações em uma rede neural artificial (RNA, ou *Artificial Neural Network*) é feito por um conjunto de neurônios artificiais que são interligados por diversas conexões sinápticas (HAYKIN, 2001; SILVA; SPATI, FLAUZINO, 2010).

A Figura 23 exemplifica a estrutura de uma rede neural biológica (a) e de uma rede neural computacional (b) conhecida como perceptron multicamada (PMC). Neste exemplo, podem ser visualizadas as unidades de processamento (neurônios) e as diversas conexões sinápticas existentes entre elas. No caso da rede neural computacional, a estrutura da rede pode ser subdividida em camada de entrada, camada(s) intermediária(s) e camada de saída, cada uma composta por uma quantidade definida de neurônios (HAYKIN, 2001; SILVA; SPATI, FLAUZINO, 2010).

Figura 23 - Exemplo de rede neural biológica (a) e de uma rede neural artificial (b)



Fonte: Silva, Spati e Flauzino (2010)

Conforme o histórico relatado por Haykin (2001) e Silva, Spati e Flauzino (2010), a primeira publicação na área de neurocomputação data de 1943. Neste estudo,

McCulloch e Pitts (1943) propuseram a primeira concepção de um neurônio artificial. Alguns anos mais tarde, Hebb (1949) propôs o primeiro método de treinamento para uma rede neural, conhecido como regra de Hebb. A partir disso, ao longo das décadas de 1950 e 1960, surgiram novos estudos que desenvolveram estruturas de rede e métodos de treinamento que são usados até os dias de hoje. Um deles é o modelo perceptron (ROSENBLAT, 1958), que foi inspirado na retina e projetado para ser aplicado em problemas de identificação de padrões. Outro modelo que surgiu na mesma época é conhecido como *adaline*, uma abreviação para *adaptive linear element* (WIDROW; HOFF, 1960). Assim como o perceptron, este modelo é adequado para o uso em problemas de classificação de padrões envolvendo duas classes.

Os avanços alcançados por esses estudos pioneiros geraram grande interesse na comunidade acadêmica. Isso contribuiu para um aumento expressivo da quantidade de pesquisadores de RNAs ao longo da década de 1960. Porém, em 1969, um estudo foi publicado demonstrando as limitações das principais topologias de rede existentes, que até então eram compostas por apenas uma camada neural. Neste estudo, Minsky e Papert (1969) demonstraram que as redes perceptron e *adaline* não eram capazes de mapear o relacionamento entre as variáveis de entrada e saída de problemas envolvendo funções lógicas simples, tais como a função "ou-exclusivo" (X_{OR}). Essa limitação se estende para todos os problemas de classificação de padrões cujas classes não são linearmente separáveis. Com isso, muitos pesquisadores perderam o interesse pelo tema, o que fez com que não ocorressem avanços consideráveis ao longo da década de 1970 (HAYKIN, 2001; SILVA; SPATI, FLAUZINO, 2010).

Contudo, em 1982, Hopfield propôs uma topologia de rede com uma arquitetura inovadora, denominada arquitetura recorrente, cuja capacidade de memorização por meio do armazenamento de informações na estrutura da rede ampliou as possibilidades de aplicação das RNAs (HOPFIELD, 1982). Em 1986, Rumelhart, Hinton e Williams (1986) propuseram um método de treinamento que ainda é o mais usado até os dias atuais. Este algoritmo, denominado *backpropagation*, se mostrou adequado para treinar redes com mais de uma camada neural e resolver problemas considerados complexos, inclusive o problema da função lógica X_{OR} . No final dos anos 1980, os avanços alcançados por Hopfield (1982) e Rumelhart, Hinton e Williams (1986), juntamente com as novas descobertas sobre o sistema nervoso biológico e o aumento na capacidade de processamento dos computadores, impulsionaram muitos pesquisadores a retomar o interesse pela área de neurocomputação. A partir da década de 1990, surgiram novas

estruturas de rede, métodos de treinamento mais otimizados e diversas aplicações práticas em várias áreas do conhecimento.

Atualmente as RNAs possuem aplicações nas áreas de engenharia, finanças, medicina, farmácia, química, biologia, ecologia, entre outros. Também há várias aplicações em controle de processos e no apoio à tomada de decisão em indústrias de diversos setores. Na indústria aeroespacial, as RNAs são utilizadas no desenvolvimento de estratégias de controle para veículos aéreos não tripulados (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010). De acordo com Silva, Spati e Flauzino (2010), a maioria das aplicações de RNAs encontradas na literatura se concentram em aproximação de funções, otimização, controle de processos, reconhecimento e classificação de padrões, sistemas de previsão, agrupamento de dados e memórias associativas.

Os modelos de RNA atualmente existentes são dotados de capacidades que emulam um comportamento inteligente. Uma dessas capacidades é a adaptação por experiência, que possibilita a aquisição de conhecimento por meio de experimentação. A partir da apresentação de um conjunto de amostras ou medidas relacionadas ao comportamento do problema modelado, os parâmetros internos da rede são ajustados por um método de treinamento, que extrai o relacionamento existente entre as variáveis de entrada e saída da rede. Após o treinamento, a rede alcança a capacidade de generalização, estando assim apta para estimar soluções que até então eram desconhecidas (HAYKIN, 2001; SILVA; SPATI, ;FLAUZINO, 2010).

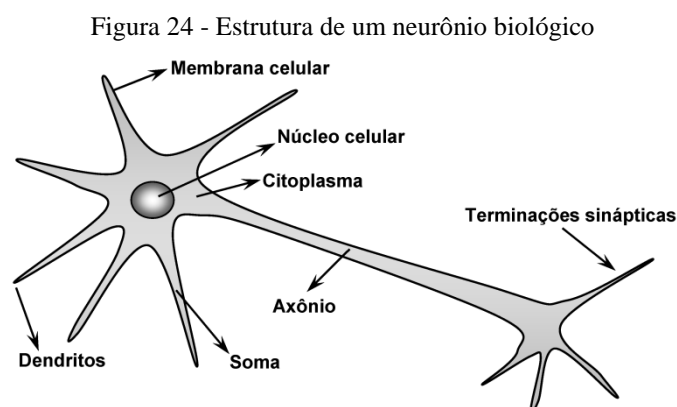
Outras capacidades das RNAs que imitam o sistema nervoso biológico são o armazenamento distribuído e a tolerância a falhas. Uma vez que o conhecimento extraído sobre o problema é armazenado de forma distribuída entre os vários neurônios da rede, caso alguma parte da sua estrutura interna seja corrompida, a grande quantidade de interconexões entre os neurônios permite que novos neurônios assumam as funções daqueles corrompidos. Desta forma, a rede torna-se um sistema tolerante a falhas (SILVA; SPATI; FLAUZINO, 2010).

Para explicar os procedimentos matemáticos e computacionais envolvidos na implementação das RNAs, as subseções a seguir apresentam os fundamentos necessários ao entendimento do processo de modelagem e uso de redes neurais artificiais. A Subseção 3.3.1 detalha o modelo matemático de um neurônio artificial. A Subseção 3.3.2 descreve as principais arquiteturas de RNA. A Subseção 3.3.3 se concentra nas estratégias de treinamento usadas pelos modelos de RNAs. A Subseção 3.4 detalha o tipo de RNA que é adotado nesta pesquisa. Ao longo dessa subseção, são discutidos alguns dos métodos

de treinamento usados por este tipo de rede, sua aplicação em problemas de aproximação funcional, algumas recomendações para modelagem e limitações deste tipo de rede.

3.3.1 O neurônio artificial

Em uma rede neural, os neurônios artificiais se constituem como unidades básicas de processamento de dados, cuja estrutura e funcionamento são inspirados no neurônio biológico dos seres vivos (SILVA; SPATI, FLAUZINO, 2010). Conforme ilustra a Figura 24, um neurônio biológico é composto por três partes principais: dendritos, corpo celular e axônio.



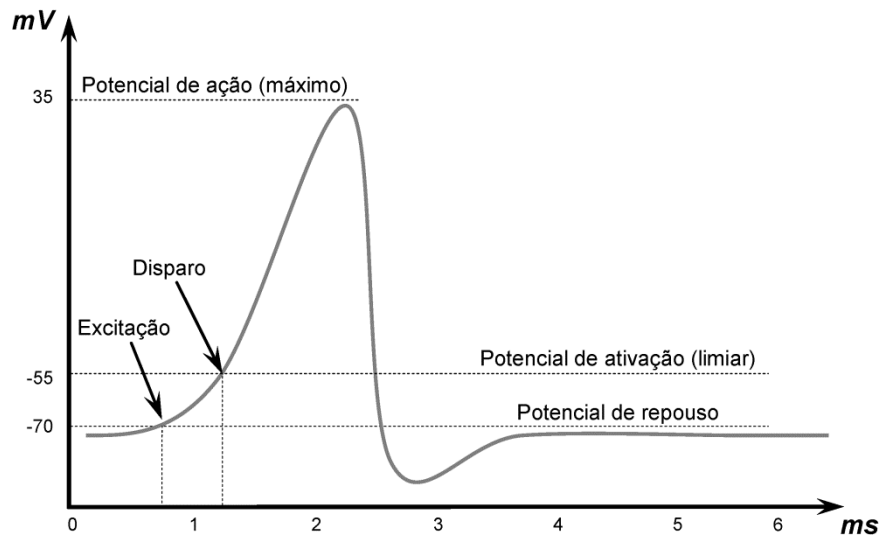
Fonte: Silva, Spati e Flauzino (2010)

A principal função dos dendritos é captar os estímulos provenientes de outros neurônios da rede ou do meio externo, onde os mesmos podem estar em contato. Tais estímulos representam os sinais de entrada do neurônio. O corpo celular é composto por organelas citoplasmáticas (núcleo, mitocôndria, centríolo, lisossomo, entre outras). Sua função é processar as informações provenientes dos dendritos para produzir um potencial de ativação que, dependendo de sua magnitude, poderá disparar um impulso elétrico ao longo do axônio. Esta resposta aos estímulos recebidos será transmitida a outros neurônios por meio das terminações sinápticas. Desta forma, o sinal de saída de um neurônio poderá servir como sinal de entrada para outro neurônio (SILVA; SPATI, FLAUZINO, 2010).

Conforme mostra a Figura 25, a ativação de um neurônio provoca uma variação em seu estado de energia. Antes de receber um sinal de entrada, o neurônio encontra-se em repouso, com um potencial de ativação representado por um valor negativo ($mV \leq -70$). Ao receber um sinal, ocorre um aumento de sua energia de ativação e o neurônio entra em estado de excitação. Dependendo da magnitude do sinal e do limiar de ativação do neurônio, o seu estado de excitação conduzirá ao disparo de um impulso elétrico que

elevará seu estado de energia para um potencial de ação máximo. O valor do potencial de ação nesta etapa geralmente é de aproximadamente 35 mV, independentemente se o neurônio for do tipo receptor, associativo ou motor. Contudo, a duração do sinal de disparo costuma ser variante. Após o processo de excitação, o potencial de ação de um neurônio retornará novamente ao seu estado de repouso (HAYKIN, 2001; SILVA; SPATI, FLAUZINO, 2010).


Figura 25 - Etapas de variação do potencial de ação do neurônio



Fonte: Silva, Spati e Flauzino (2010)

Os componentes estruturais e o processo de ativação de um neurônio artificial e de um neurônio biológico são bastante similares. A Figura 26 ilustra a estrutura de um neurônio artificial.

Figura 26- Estrutura de um neurônio artificial



Fonte: Silva, Spati e Flauzino (2010)

Como pode ser visto, um neurônio artificial é composto por sete elementos básicos (HAYKIN, 2001; SILVA; SPATI, FLAUZINO, 2010), sendo eles:

i. **Sinais de entrada** (x_1, x_2, \dots, x_n): consistem em medidas que representam os valores assumidos pelas variáveis de entrada da rede. Esses valores de entrada geralmente advêm do meio externo e são obtidos por meio de coleta de dados e medição;

ii. **Pesos sinápticos** (w_1, w_2, \dots, w_n): referem-se aos pesos das conexões existentes entre os neurônios. Na prática, estes pesos são valores que ponderam cada uma das variáveis de entrada da rede, permitindo quantificar seus respectivos níveis de importância em relação à funcionalidade de um determinado neurônio;

iii. **Combinador linear** (Σ): quando um conjunto de dados é apresentado a um neurônio artificial, após a ponderação dos sinais de entrada pelos seus respectivos pesos sinápticos, o combinador linear tem a função de agregar todos os valores de entrada para então fornecer um valor de potencial de ativação (u);


iv. **Limiar de ativação** (θ): esta variável costuma ser ajustada durante o treinamento da rede. Sua função é definir qual será o patamar adequado para que o valor gerado pelo combinador linear possa disparar um valor rumo à saída do neurônio;

v. **Potencial de ativação** (u): conforme mostra a Equação 1, o valor desta variável é calculado por meio da diferença entre o valor gerado pelo combinador linear e o limiar de ativação. Sua função é especificar se o neurônio produzirá um potencial excitatório ($u \geq \theta$) ou inibitório ($u < \theta$);

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (1)$$

vi. **Função de ativação** (g): A função de ativação deve limitar o valor de saída do neurônio a uma faixa de valores apropriados, que serão definidos pela sua própria imagem funcional. Existem vários tipos de funções de ativação e a escolha de uma função adequada depende do modelo de rede neural adotado, bem como da aplicação realizada. A Figura 27 apresenta exemplos de quatro funções de ativação. A função degrau bipolar, mostrada na Figura 27 (a) e na Equação 2, é usada em redes perceptron. A função linear, representada na Figura 27 (b) e Equação 3, é usada por redes perceptron de múltiplas camadas e por redes de base radial em problemas envolvendo aproximação de funções. Já as funções de ativação logística e tangente hiperbólica, mostradas respectivamente nas Figuras 27 (c) e (d), e nas Equações 4 e 5, são comumente usadas em redes perceptron de múltiplas camadas.

Figura 27 - Funções de ativação do tipo degrau bipolar (a), linear (b), logística (c) e tangente hiperbólica (d)



Fonte: Silva, Spati e Flauzino (2010)

$$g(u) = \begin{cases} 1, & \text{se } u > 0 \\ 0, & \text{se } u = 0 \\ -1, & \text{se } u < 0 \end{cases} \quad (2)$$

$$g(u) = u \quad (3)$$

$$g(u) = \frac{1}{1+e^{-\beta u}} \quad (4)$$

$$g(u) = \frac{1-e^{-\beta u}}{1+e^{-\beta u}} \quad (5)$$

vii. **Sinal de saída** (y): É o valor final produzido pelo neurônio, calculado por meio da função de ativação adotada, conforme representa a Equação 6. Dependendo da estrutura da rede, o sinal de saída pode servir como sinal de entrada para outros neurônios que estejam ligados sequencialmente.

$$y = g(u) \quad (6)$$


Embora cada neurônio artificial atue como uma unidade independente de processamento, a maioria dos modelos de rede neural usados atualmente costuma ser composta por mais de um neurônio. A forma como os neurônios estão organizados em cada modelo de rede determina sua arquitetura.

3.3.2 Arquiteturas de redes neurais artificiais

A arquitetura de uma rede neural artificial se refere à forma como os seus neurônios constituintes estão dispostos e interligados entre si. Ao longo da evolução da neurocomputação, diversas arquiteturas foram propostas. Esta subseção foca em quatro arquiteturas que se destacam por embasar os modelos de rede neural mais utilizados (SILVA; SPATI, FLAUZINO, 2010).

Conforme mostra a Figura 28 (a), a arquitetura *feedforward* de camada simples é composta por uma camada de entrada e somente uma camada de neurônios artificiais, que é a camada de saída da rede. Nesta arquitetura, o fluxo de informações segue uma única direção, da camada de entrada para a camada de saída. No exemplo mostrado, a rede é composta de n variáveis de entrada e m variáveis de saída. A quantidade de saídas que a rede deve fornecer determina a quantidade de neurônios a serem utilizados na camada de saída da rede. Exemplos de modelos de rede que utilizam a arquitetura *feedforward* de camada simples são perceptron e *adaline* (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

Figura 28 - Arquitetura *feedforward* de camada simples (a) e *feedforward* de camadas múltiplas (b)

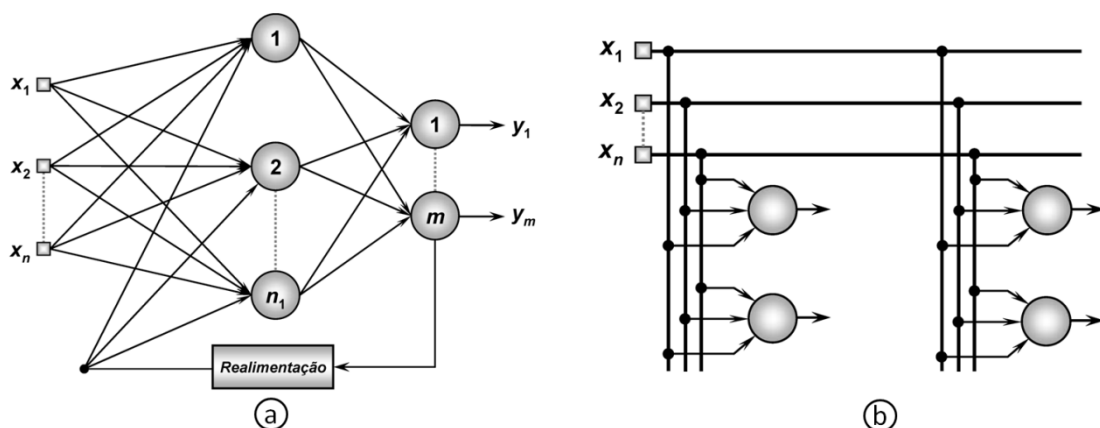


Fonte: Silva, Spati e Flauzino (2010)

Já a arquitetura *feedforward* de camadas múltiplas, mostrada na Figura 28 (b), é composta de pelo menos uma camada intermediária de neurônios artificiais e é usada por modelos de rede como perceptron de múltiplas camadas e redes de base radial. Assim como na arquitetura de *feedforward* de camada simples, a quantidade de neurônios contidos na última camada equivale à quantidade de sinais de saída. Já a quantidade de neurônios que compõem a(s) camada(s) escondida costuma ser diferente do número de variáveis de entrada da rede. O número de camadas intermediárias usadas em uma determinada rede e a quantidade de neurônios contidos em cada uma das camadas dependem diretamente do tipo e da complexidade do problema a ser modelado, bem como da quantidade e da qualidade dos dados sobre o problema (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

Conforme ilustra a Figura 29 (a), a arquitetura recorrente (ou realimentada) se diferencia por permitir a realimentação de sinais entre os neurônios da rede, ou seja, ao menos um sinal produzido pelos neurônios da camada de saída é usado como sinal de entrada para a camada intermediária. Desta forma, os modelos de rede que utilizam esta arquitetura, como as redes Hopfield e perceptron de múltiplas camadas com realimentação, são capazes de produzir os valores de saída atuais da rede considerando também os valores de saída anteriores. Tal particularidade permite a estas redes a realização de processamento dinâmico de informações, podendo assim ser aplicadas em sistemas cujo comportamento varia em relação ao tempo (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

Figura 29 - Arquiteturas recorrente (a) e arquitetura reticulada (b)



Fonte: Silva, Spati e Flauzino (2010)

Conforme exemplificado na Figura 29 (b), as redes com arquitetura reticulada são aquelas que consideram a disposição espacial dos neurônios dentro de uma mesma camada como um meio para otimizar a extração de características do problema. Desta

forma, a estrutura topológica da rede e a disposição dos neurônios são definidas de acordo com o objetivo da aplicação. Outra característica desta arquitetura é que os sinais de entrada são enviados a todos os neurônios da rede. O modelo mais representativo dessa arquitetura são as redes Kohonen (SILVA; SPATI; FLAUZINO, 2010).

Diante da existência de uma variedade de arquiteturas de RNAs, a escolha de uma arquitetura apropriada depende do tipo de aplicação a ser modelada. Enquanto as redes de arquitetura *feedforward* de camada simples são adequadas para problemas de classificação de padrões envolvendo duas classes, as redes *feedforward* de camadas múltiplas são apropriadas para a modelagem de problemas de aproximação de funções, bem como para classificação de padrões envolvendo mais de duas classes. As redes de arquitetura recorrente são usadas em problemas de previsão e em controle de processos. Já as redes com arquitetura reticulada são adequadas para modelar problemas de reconhecimento de padrões e de agrupamento de dados (*clustering*) (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

3.3.3 Treinamento de redes neurais artificiais

Um aspecto muito importante das RNAs, que está diretamente relacionado às suas capacidades de aprendizado e generalização de soluções, refere-se ao processo de treinamento adotado para ajustar a rede. O treinamento de uma RNA consiste na aplicação de alguns procedimentos sequenciados que visam mapear o comportamento de um problema, a partir da apresentação sucessiva de um conjunto de amostras representativas do mesmo, com o propósito final de tornar a rede apta para generalizar soluções. O mapeamento (ou extração de informações) do problema é feito por meio do ajuste dos parâmetros livres de cada neurônio da rede (pesos sinápticos e o limiar de ativação). A quantidade de vezes em que o conjunto de amostras de treinamento é apresentado à rede, denominada de número de épocas, serve como um parâmetro para avaliar a eficiência do processo de treinamento (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

Para permitir o treinamento e também a validação da rede, o conjunto total de amostras costuma ser dividido em subconjunto de treinamento, formado por cerca de 60 a 90% do total de amostras, e subconjunto de teste, composto por 10 a 40% do total. Após a rede ter aprendido o relacionamento entre as variáveis de entrada e saída, os valores de entrada das amostras do subconjunto de teste são usados para testar sua capacidade de generalização de soluções, ou seja, para verificar o quão eficazmente a rede consegue

estimar valores de saída para situações até então desconhecidas por ela (SILVA; SPATI; FLAUZINO, 2010).

Há vários métodos usados no treinamento de redes neurais. Alguns exemplos são a regra de Hebb (que é aplicada em redes do tipo perceptron), a regra delta (usada em redes *adaline*), o algoritmo competitivo (utilizado em redes Kohonen) e o algoritmo *backpropagation* (usado em redes perceptron múltiplas camadas). Além dos procedimentos matemáticos, tais métodos se diferem principalmente pelas estratégias de treinamento utilizadas. As principais estratégias de treinamento são o treinamento supervisionado, treinamento não supervisionado, treinamento com reforço, treinamento *off-line* e treinamento *online* (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

No treinamento supervisionado, ao se apresentar os valores de entrada para a rede, também é apresentado o respectivo valor de saída desejado para cada amostra. Desta forma, o método de treinamento se comporta como um professor que ensina a resposta correta para a rede em cada cenário representado pelas amostras. Já o treinamento não supervisionado é aplicado quando os valores de saída desejados para cada amostra de treinamento não são conhecidos ou não estão disponíveis. Neste sentido, somente os valores de entrada são apresentados à rede, que irá se auto-organizar visando à identificação de particularidades do conjunto total de amostras e à identificação de subconjuntos de amostras com características em comum (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

A estratégia de treinamento com reforço é uma variação do treinamento supervisionado em que não há propriamente um valor de saída desejada para cada amostra, sendo utilizadas informações quantitativas ou qualitativas sobre o problema que permitam à rede avaliar se a resposta produzida por ela é satisfatória ou não. Nestas condições, o processo de treinamento é feito por tentativa e erro. Todavia, quando uma resposta produzida frente a uma amostra é considerada satisfatória, os parâmetros livres da rede são ajustados de modo a reforçar a condição comportamental atual da rede (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

Já o treinamento *off-line* utiliza de lotes de amostras e realiza o ajuste dos parâmetros livres somente após a apresentação de todo o conjunto de amostras. Desta forma, os ajustes realizados na rede consideram o total de desvios existentes entre as saídas das amostras de treinamento e os valores desejados. Ao contrário desta estratégia, o treinamento *online* ajusta os parâmetros livres da rede somente após a apresentação de cada uma das amostras de treinamento. Tal estratégia é adequada principalmente para

mapear problemas cujo comportamento varia de forma muito rápida (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

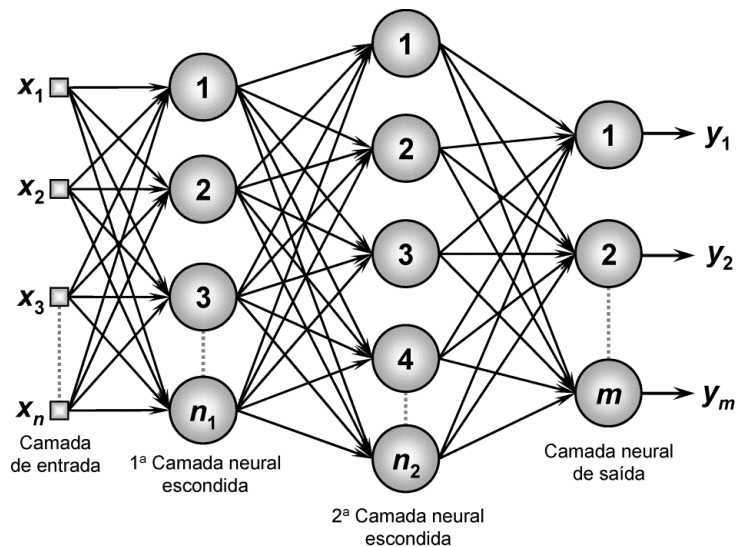
Posto que existem diversos métodos com diferentes estratégias de treinamento de RNAs, este estudo descreve em detalhe somente aquele que é usado nos modelos computacionais estudados nesta pesquisa, denominado *backpropagation*. Todavia, antes de apresentar esse método, alguns conceitos referentes às redes PMC são discutidos.

3.4 REDES PERCEPTRON DE MÚLTIPLAS CAMADAS

A tipologia de RNA conhecida como perceptron de múltiplas camadas (PMC) é a mais versátil quanto à aplicabilidade, uma vez que apresenta alto desempenho em diversos problemas que envolvem aproximação de funções, previsão de séries temporais, reconhecimento de padrões e controle de processos (AKKOÇ, 2012; APICHOTTANAKUL; PATHUMNAKUL; PIEWTHONGNGAM, 2012; MOOSMAYER et al., 2013).

As redes PMC são caracterizadas pela existência de pelo menos uma camada neural intermediária (também chamada de camada escondida), situada entre a camada neural de entrada e a respectiva camada neural de saída. A Figura 30 ilustra uma rede PMC composta por duas camadas escondidas. Neste caso, os sinais de saída produzidos pela primeira camada escondida servem como entrada para a segunda camada. A camada neural de saída é composta por diversos neurônios e cada um destes representa uma das saídas do problema a ser mapeado. Durante o estágio de uso da rede, os sinais de entrada sempre são propagados da entrada em direção à saída (SILVA; SPATI; FLAUZINO, 2010; AKKOÇ, 2012). Assim como em outros modelos de RNAs, a camada de entrada do PMC é responsável pelo recebimento dos dados de entrada na rede, os quais devem ser representativos do problema modelado. As camadas escondidas estão incumbidas de extrair as características do problema e armazená-las em seus neurônios. Os neurônios das camadas escondidas também realizam a maioria das operações de processamento da rede. Finalmente, a partir das saídas fornecidas pelos neurônios da segunda camada escondida, a camada de saída produz e apresenta os resultados finais (AKKOÇ, 2012).

Figura 30 - Estrutura de uma rede PMC com duas camadas intermediárias



Fonte: Silva, Spati e Flauzino (2010)

Por serem capazes de mapear qualquer função linear e não linear utilizando apenas uma camada neural intermediária, as redes PMC são frequentemente aplicadas em dois tipos de problemas que envolvem a estimação de valores futuros pela rede: problemas de previsão e de predição. O Quadro 11 lista alguns exemplos de aplicação de redes PMC em problemas relacionados. De acordo com Kar et al. (2014), tanto os problemas de predição quanto os de previsão envolvem a estimação de eventos e condições futuras relacionados a elementos chave dos processos organizacionais de tomada de decisão. Porém, enquanto o termo previsão costuma ser usado quando são estimados valores para determinados tempos futuros específicos, o termo predição se aplica para estimativas mais gerais de valores ao longo de um período de tempo. Nas aplicações em problemas de previsão, as redes PMC atuam como sistemas variantes no tempo, ou seja, a rede estima os valores futuros de uma determinada variável a partir de um conjunto de registros históricos dos valores desta variável em instantes de tempo especificados ($t = 1, \dots, n$). Um exemplo é a aplicação em previsão de demanda de itens em uma empresa de manufatura realizada por Aburto e Weber (2007). Nas aplicações em problemas de predição, a rede mapeia uma função de interesse a partir da quantificação das relações de causa e efeito entre as variáveis de entrada e de saída. Este é o caso da aplicação apresentada por Apichottanakul, Pathumnakul e Piewthongngam (2012) na predição do tamanho dos porcos criados por fornecedores de uma indústria de carnes.

Quadro 11 - Aplicações de redes PMC em problemas de predição

Proposto por	Escopo
Aburto e Weber (2007)	Sistema de controle de inventário baseado em previsão de demanda
Efendigil, Öñüt e Kahraman (2009)	Previsão de demanda em cadeias de suprimento
Apichottanakul, Pathumnakul e Piewthongngam (2013)	Predição do tamanho de porcos criados pelas fazendas fornecedoras de uma indústria de carnes, para apoiar decisões sobre a atribuição de pedidos de compra
Goel, Singh e Aseri (2013)	Predição de genes em cadeias de DNA
Moosmayer et al. (2013)	Predição de resultados de negociação de preço em um contexto <i>business-to-business</i>
Zhao et al. (2015)	Modelo para análise de pontuação de crédito
Bagheripour (2014)	Predição de permeabilidade de rochas
Jaipuria e Mahapatra (2014)	Método de previsão de demanda para redução do efeito chicote
Brock e Davis (2015)	Estimativa da disponibilidade de mercadorias em um supermercado
Lee e Ou-Yang (2009)	Predição de preços de orçamento de fornecedores no processo de seleção de fornecedores

Fonte: Proposto pelo autor.


Como já mencionado anteriormente, o processo de treinamento das redes PMC é do tipo supervisionado, ou seja, a resposta desejada para cada amostra é apresentada à rede para que a mesma realize ajustes internos a fim de minimizar o erro entre o resultado fornecido e o valor desejado. O algoritmo *backpropagation* foi o primeiro método de aprendizagem usado no treinamento das redes PMC, sendo bastante usado até a atualidade.

3.4.1 O método de aprendizagem *backpropagation*

O método de aprendizagem *backpropagation*, também denominado regra delta generalizada, foi desenvolvido a partir do método de aprendizagem usado pelas redes *adaline*, conhecido como regra delta, algoritmo LMS (*least mean square*) ou método do gradiente descendente (BILGEHAN, 2011). Esse método é adotado por cerca de 75% das aplicações de redes neurais na área de negócios (AKKOÇ, 2012). Conforme ilustra a Figura 31, o *backpropagation* é dividido em duas fases. Na primeira fase, denominada *forward*, os valores das amostras do conjunto de treinamento (x_1, x_2, \dots, x_n) são inseridos nas entradas da rede e propagados camada a camada até a produção das respectivas saídas. Em seguida, as respostas produzidas pela rede para cada amostra $\{Y(k)\}$ são comparadas

com as respectivas respostas desejadas $\{d(k)\}$. O objetivo principal do algoritmo *backpropagation* consiste em minimizar o erro quadrático $E(k)$ resultante dessa comparação entre as saídas desejadas e as respostas da rede (BILGEHAN, 2011). Na fase *forward*, o objetivo consiste somente em gerar um conjunto de saídas considerando os pesos atuais da rede, para que o erro quadrático seja calculado e, no passo seguinte, minimizado ao longo de uma série de iterações (HAYKIN, 2001).


Figura 31 - Fluxo dos dados em uma rede PMC durante as duas fases do *backpropagation*



Fonte: Silva, Spati e Flauzino (2010)

Na segunda fase do treinamento, denominada *backward* (ou propagação reversa), o objetivo é ajustar os pesos das conexões sinápticas e os limiares de todos os neurônios da rede em função do erro quadrático obtido na fase anterior. Os ajustes são feitos de modo a se aproximar de um vetor de pesos ótimo (w^*), tal que o erro quadrático $E(w^*)$ produzido sobre todas as amostras seja o mínimo possível (EFENDIGIL; ÖNÜT; KAHRAMAN, 2009). A interpretação geométrica do processo de minimização de $E(w)$, também chamado de processo de convergência da rede, é ilustrada na Figura 32. Partindo da configuração inicial dos pesos $w(0)$, nota-se que a cada iteração do processo de convergência, os pesos e os limiares de ativação são incrementados à razão de $-\eta \cdot \frac{\partial E(w)}{\partial w}$. Como o objetivo do algoritmo é minimizar $E(w)$, os passos para o ajuste do vetor de pesos devem ser efetuados na direção oposta àquela do gradiente $\frac{\partial E(w)}{\partial w}$. Por isso, a variação que deve ser incrementada ao vetor de pesos (e também ao limiar de ativação) possui um sinal negativo. O parâmetro η se refere à taxa de aprendizagem e determina a rapidez com que a rede se aproximará do ponto de minimização de $E(w)$. Para este parâmetro, normalmente são adotados valores maiores que zero e menores que um (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).


Figura 32 - Minimização do erro quadrático médio ao longo do processo de treinamento



Fonte: Silva, Spati e Flauzino (2010)

Como o *backpropagation* utiliza do gradiente $\frac{\partial E(w)}{\partial w}$ no processo de ajuste dos pesos, uma premissa para seu uso é que as funções de ativação adotadas sejam contínuas e diferenciáveis em todo o seu domínio de definição. As funções de ativação logística e tangente hiperbólica são amplamente usadas em redes PMC por atenderem a esses requisitos (SILVA; SPATI; FLAUZINO, 2010).

Para detalhar os cálculos realizados pelo *backpropagation*, é necessário definir inicialmente algumas variáveis que são usadas no processo de treinamento. A Figura 33 resgata o exemplo de rede PMC apresentado nas Figuras 30 e 31, destacando a notação matemática usada neste estudo para designar algumas das variáveis. Nessa figura, são representados os sinais de entrada (x_1, x_2, \dots, x_n), as matrizes de pesos sinápticos (W_{ji}^L) que ligam os neurônios (j) de cada camada (L) aos neurônios de sua camada antecessora (i), as entradas ponderadas (I_j^L) dos neurônios e as saídas produzidas por cada um (Y_j^L). Na etapa *forward*, como mostra a Equação 7, os sinais de entrada (x_i) são ponderados pelos pesos da primeira camada intermediária $W_{ji}^{(1)}$, gerando assim o vetor $I_j^{(1)}$. Posteriormente, esse vetor de entradas ponderado é modificado por uma função de ativação, como sugere a Equação 8. Conforme mostram as Equações 9, 10, 11 e 12, na segunda camada intermediária e na camada de saída são feitos procedimentos similares. Contudo, nestes casos, os sinais de entrada dessas das camadas se referem às saídas das camadas interiores (SILVA; SPATI; FLAUZINO, 2010).

Figura 33 - Minimização do erro quadrático médio usando o algoritmo *backpropagation*

Fonte: Silva, Spati e Flauzino (2010)

$$I_j^{(1)} = \sum_{i=0}^{n_1} W_{ji}^{(1)} x_i \quad (7)$$

$$Y_j^{(1)} = g(I_j^{(1)}) \quad (8)$$

$$I_j^{(2)} = \sum_{i=0}^{n_2} W_{ji}^{(2)} Y_i^{(1)} \quad (9)$$

$$Y_j^{(2)} = g(I_j^{(2)}) \quad (10)$$

$$I_j^{(3)} = \sum_{i=0}^{n_3} W_{ji}^{(3)} Y_i^{(2)} \quad (11)$$

$$Y_j^{(3)} = g(I_j^{(3)}) \quad (12)$$

Conforme discutido anteriormente, após a produção dos resultados finais pelos neurônios da camada de saída da rede $\{Y_j^{(3)}\}$, calcula-se o erro quadrático utilizando estes valores e as saídas desejadas para cada amostra $\{d_j(k)\}$. No caso da topologia mostrada na Figura 33, como existem n_3 neurônios na última camada, o cálculo do erro considerará a soma dos desvios resultantes da diferença entre os valores desejados e as respostas produzidas por cada neurônio, conforme mostra a Equação 13 (SILVA; SPATI, FLAUZINO, 2010).

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_3} (d_j(k) - Y_j^{(3)}(k))^2 \quad (13)$$

Considerando o uso de p amostras ao longo de cada época de treinamento, o erro quadrático médio (E_{qm}) é calculado ao final de cada iteração por meio da Equação 14. O valor de E_{qm} serve como um parâmetro para medir a evolução do desempenho global do algoritmo rumo à minimização da função erro. Quando a diferença entre os módulos do erro quadrático médio de duas iterações consecutivas for menor que o parâmetro de precisão requerida (ε), como representado na Equação 15, o valor do gradiente usado no ajuste dos pesos estará se aproximando de zero, o que indica que a função erro $\{E(w)$, Figura 32} já foi suficientemente minimizada e que um ponto ótimo foi alcançado. Portanto, quando isso acontece, o processo de treinamento é encerrado e a rede estará apta para generalizar soluções desconhecidas (SILVA; SPATI, FLAUZINO, 2010).

$$E_{qm} = \frac{1}{p} \sum_{k=1}^p E(k) \quad (14)$$

$$|E_{qm}^{atual} - E_{qm}^{anterior}| \leq \varepsilon \quad (15)$$

Caso a diferença entre os valores de E_{qm}^{atual} e $E_{qm}^{anterior}$ seja maior que a precisão requerida, a rede inicia a fase de propagação reversa para efetuar o ajuste dos pesos das conexões sinápticas e dos limiares de ativação de todos os seus neurônios, camada a camada. Como esse ajuste é feito em função do gradiente $\frac{\partial E(w)}{\partial w}$, o *backpropagation* requer a derivação de algumas funções para se chegar à expressão exata que será usada no ajuste dos pesos. Tais procedimentos de derivação partem da camada de saída e seguem até a primeira camada escondida. Considerando o gradiente do erro na camada de saída $\{\nabla E^{(3)}\}$ e aplicando a ele a regra de derivação em cadeia, obtém-se a Equação 16 (SILVA; SPATI, FLAUZINO, 2010).

$$\nabla E^{(3)} = \frac{\partial E}{\partial w_{ji}^{(3)}} = \frac{\partial E}{\partial Y_j^{(3)}} \cdot \frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} \cdot \frac{\partial I_j^{(3)}}{\partial w_{ji}^{(3)}} \quad (16)$$

Resolvendo separadamente cada um dos termos da Equação 16 com base nas Equações 11, 12 e 13, são obtidas as Equações 17, 18 e 19. Substituindo os termos dessas Equações na Equação 16, obtém-se a Equação 20 para o cálculo do gradiente da camada de saída. Nas Equações 18 e 20, $g'(\cdot)$ se refere à derivada de primeira ordem da função de ativação adotada (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

$$\frac{\partial E}{\partial Y_j^{(3)}} = -(d_j - Y_j^{(3)}) \quad (17)$$

$$\frac{\partial I_j^{(3)}}{\partial W_{ji}^{(3)}} = Y_i^{(2)} \quad (18)$$

$$\frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} = g'(I_j^{(3)}) \quad (19)$$

$$\frac{\partial E}{\partial W_{ji}^{(3)}} = -(d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}) \cdot Y_i^{(2)} \quad (20)$$

Considerando que o ajuste de pesos da matriz $W_{ji}^{(3)}$ deve ser feito na direção oposta ao gradiente para que o erro seja minimizado, a variação a ser incrementada nessa matriz a cada iteração do algoritmo é apresentada na Equação 21. Nessa equação, o vetor $\delta_j^{(3)}$ representa o gradiente local de cada um dos neurônios da camada de saída e pode ser obtido por meio da Equação 22. Portanto, com base nas Equações 21 e 22, define-se o procedimento iterativo de ajuste dos pesos das conexões sinápticas dos neurônios da camada de saída, que é representado pela Equação 23 (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

$$\Delta W_{ji}^{(3)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(3)}} = \eta \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (21)$$

$$\delta_j^{(3)} = (d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}) \quad (22)$$

$$W_{ji}^{(3)}(t+1) = W_{ji}^{(3)}(t) + \eta \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (23)$$

Como os valores desejados para as saídas das camadas intermediárias não são conhecidos, os ajustes nestas camadas são feitos por meio de estimativas dos erros produzidos pelos neurônios de suas respectivas camadas sucessoras, após estas já terem sido devidamente ajustadas. No caso da segunda camada intermediária, os ajustes nos pesos são iniciados logo após a conclusão dos ajustes na camada de saída. Analogamente, os ajustes na matriz de pesos da primeira camada escondida só serão feitos após a conclusão dos ajustes na segunda camada intermediária. Em ambos os casos, os ajustes são feitos utilizando os valores dos pesos já ajustados. Esse processo de retropropagação

do erro referente aos desvios entre as respostas produzidas pela camada de saída e os respectivos valores desejados é a essência do método *backpropagation* (SILVA; SPATI; FLAUZINO, 2010).

Para o ajuste da segunda camada escondida, aplicando novamente a regra de derivação em cadeia, o valor do gradiente do erro na segunda camada $\{\nabla E^{(2)}\}$ pode ser obtido conforme a Equação 24. Adotando procedimentos similares aos usados na derivação do gradiente da camada de saída e utilizando das Equações 9 e 10, chega-se à expressão mostrada na Equação 25.

$$\nabla E^{(2)} = \frac{\partial E}{\partial W_{ji}^{(2)}} = \frac{\partial E}{\partial Y_j^{(2)}} \cdot \frac{\partial Y_j^{(2)}}{\partial I_j^{(2)}} \cdot \frac{\partial I_j^{(2)}}{\partial W_{ji}^{(2)}} \quad (24)$$

$$\frac{\partial E}{\partial W_{ji}^{(2)}} = -(\sum_{k=1}^{n_3} \delta_k^{(3)} \cdot W_{kj}^{(3)}) \cdot g'(I_j^{(2)}) \cdot Y_i^{(1)} \quad (25)$$

Considerando que o ajuste da matriz $W_{ji}^{(2)}$ também deve ser feito na direção oposta ao gradiente para minimizar o erro, a Equação 26 determina a variação a ser incrementada nessa matriz a cada iteração do algoritmo. O vetor $\delta_j^{(2)}$, que representa o gradiente local de cada um dos neurônios da segunda camada intermediária, pode ser obtido por meio da Equação 27. A partir das Equações 26 e 27, obtém-se o procedimento iterativo de ajuste dos pesos das conexões dos neurônios da segunda camada intermediária mostrado na Equação 28 (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

$$\Delta W_{ji}^{(2)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(2)}} = \eta \cdot \delta_j^{(2)} \cdot Y_i^{(1)} \quad (26)$$

$$\delta_j^{(2)} = (\sum_{k=1}^{n_3} \delta_k^{(3)} \cdot W_{kj}^{(3)}) \cdot g'(I_j^{(2)}) \quad (27)$$

$$W_{ji}^{(2)}(t+1) = W_{ji}^{(2)}(t) + \eta \cdot \delta_j^{(2)} \cdot Y_i^{(1)} \quad (28)$$

Por último, para o ajuste da primeira camada escondida, aplicando a regra de derivação em cadeia sobre o gradiente $\nabla E^{(1)}$, obtém-se a Equação 29. Adotando procedimentos similares aos usados na derivação de $\nabla E^{(3)}$ e $\nabla E^{(2)}$ e utilizando as Equações 7 e 8, obtém-se a expressão mostrada na Equação 30. A Equação 31 determina a variação a ser incrementada na matriz $W_{ji}^{(1)}$ para o ajuste dos pesos a cada iteração do

algoritmo. Nessa equação, o vetor $\delta_j^{(1)}$ se refere o gradiente local de cada um dos neurônios da segunda camada intermediária, podendo ser obtido pela Equação 32. Finalmente, o procedimento iterativo de ajuste dos pesos das conexões dos neurônios da primeira camada intermediária, que é a última a ser ajustada durante o treinamento da rede, é representado na Equação 33 (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

$$\nabla E^{(1)} = \frac{\partial E}{\partial W_{ji}^{(1)}} = \frac{\partial E}{\partial Y_j^{(1)}} \cdot \frac{\partial Y_j^{(1)}}{\partial I_j^{(1)}} \cdot \frac{\partial I_j^{(1)}}{\partial W_{ji}^{(1)}} \quad (29)$$

$$\frac{\partial E}{\partial W_{ji}^{(1)}} = -(\sum_{k=1}^{n_2} \delta_k^{(2)} \cdot W_{kj}^{(2)}) \cdot g'(I_j^{(1)}) \cdot x_i \quad (30)$$

$$\Delta W_{ji}^{(1)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(1)}} = \eta \cdot \delta_j^{(1)} \cdot x_i \quad (31)$$

$$\delta_j^{(1)} = (\sum_{k=1}^{n_2} \delta_k^{(2)} \cdot W_{kj}^{(2)}) \cdot g'(I_j^{(1)}) \quad (32)$$

$$W_{ji}^{(1)}(t+1) = W_{ji}^{(1)}(t) + \eta \cdot \delta_j^{(1)} \cdot x_i \quad (33)$$

Visando fornecer uma visão holística do processo de treinamento apresentado nesta subseção, o Quadro 12 sintetiza os passos do algoritmo *backpropagation* para o treinamento de uma rede PMC com duas camadas intermediárias. Nesse quadro, os passos 6.2.1 a 6.2.3 executam a fase *forward* e os passos 6.2.4 a 6.2.9 a fase *backward*.

Quadro 12 - Algoritmo usado durante o treinamento de uma rede PMC

Início
<1> Obter o conjunto de amostras de treinamento $\{x(k)\}$;
<2> Associar a saída desejada $\{d(k)\}$ a cada amostra obtida;
<3> Iniciar o vetor $W_{ji}^{(1)}$, $W_{ji}^{(2)}$ e $W_{ji}^{(3)}$ com valores aleatórios pequenos;
<4> Especificar a taxa de aprendizagem $\{\eta\}$ e a precisão requerida $\{\epsilon\}$;
<5> Iniciar o contador de número de épocas;
<6> Repetir as instruções:
<6.1> $E_M^{\text{anterior}} \leftarrow E_M$;
<6.2> Para todas as amostras de treinamento $\{x(k) \text{ e } d(k)\}$, fazer:
<6.2.1> Obter $I_j^{(1)}$ e $Y_j^{(1)}$ (conforme as Equações 7 e 8);
<6.2.2> Obter $I_j^{(2)}$ e $Y_j^{(2)}$ (conforme as Equações 9 e 10);
<6.2.3> Obter $I_j^{(3)}$ e $Y_j^{(3)}$ (conforme as Equações 11 e 12);

<p><6.2.4> Determinar $\delta_j^{(3)}$ (conforme a Equação 22);</p> <p><6.2.5> Ajustar $W_{ji}^{(3)}$ (conforme a Equação 23);</p> <p><6.2.6> Determinar $\delta_j^{(2)}$ (conforme a Equação 27);</p> <p><6.2.7> Ajustar $W_{ji}^{(2)}$ (conforme a Equação 28);</p> <p><6.2.8> Determinar $\delta_j^{(1)}$ (conforme a Equação 32);</p> <p><6.2.9> Ajustar $W_{ji}^{(1)}$ (conforme a Equação 33);</p> <p><6.3> Obter $Y_j^{(3)}$ usando os pesos já ajustados (conforme <6.2.1>, <6.2.2> e <6.2.3>)</p> <p><6.4> $E_M^{\text{atual}} \leftarrow E_M$;</p> <p><6.5> época \leftarrow época + 1;</p> <p>Até que $E_M^{\text{atual}} - E_M^{\text{anterior}} \leq \varepsilon$</p> <p>Fim</p>
--

Fonte: Silva, Spati e Flauzino (2010)

Já o Quadro 13 sintetiza o algoritmo usado após o treinamento de uma rede PMC com duas camadas intermediárias, na chamada fase de operação (ou fase de uso). Nota-se que os procedimentos executados nesta fase são bastante similares àqueles usados na fase *forward* do *backpropagation*.

Quadro 13 - Algoritmo usado na fase de operação de uma rede PMC

<p>Início</p> <p><1> Obter uma amostra $\{x\}$;</p> <p><2> Assumir os valores de $W_{ji}^{(1)}$, $W_{ji}^{(2)}$ e $W_{ji}^{(3)}$ já ajustados no treinamento;</p> <p><3> Executar as seguintes instruções:</p> <p><3.1> Obter $I_j^{(1)}$ e $Y_j^{(1)}$ (conforme as Equações 7 e 8);</p> <p><3.2> Obter $I_j^{(2)}$ e $Y_j^{(2)}$ (conforme as Equações 9 e 10);</p> <p><3.3> Obter $I_j^{(3)}$ e $Y_j^{(3)}$ (conforme as Equações 11 e 12);</p> <p><4> Disponibilizar as saídas da rede, as quais são dadas pelos elementos contidos em $Y_j^{(3)}$;</p> <p>Fim</p>

Fonte: Silva, Spati e Flauzino (2010)


Os passos do algoritmo *backpropagation* e as fórmulas apresentadas nessa subseção podem ser facilmente adaptados para serem usados no treinamento de redes PMC com configuração topológica diferente daquela do exemplo mostrado na Figura 33. Por exemplo, ao utilizar um PMC com apenas uma camada intermediária, o ajuste dos pesos na camada de saída poderia ser feito com as mesmas equações apresentadas para $W_{ji}^{(3)}$. Já o ajuste da primeira camada escondida utilizaria das equações apresentadas para $W_{ji}^{(2)}$.

Algumas variações do *backpropagation* surgiram ao longo das décadas de 1980 e 1990 a fim de tornar mais eficiente o processo de convergência das redes PMC. Uma delas é o método de inserção do termo de *momentum*, que se diferencia do *backpropagation* por incrementar um parâmetro que pondera o quanto as matrizes de pesos foram alteradas entre duas iterações sucessivas. Sendo L uma camada genérica da rede, a expressão que determina o ajuste dos pesos utilizando o termo de *momentum* é representada na Equação 34. Nessa equação, α se refere à taxa de *momentum*, cujo valor pode ser especificado entre zero e um. Quando α é definido como zero, a Equação 34 se torna equivalente àquelas usadas no ajuste dos pesos usando o *backpropagation* tradicional. Em outros casos, quando α é especificado com um valor maior que zero, sua contribuição acelerará o processo de minimização da função, tornando o treinamento da rede mais rápido. Silva, Spati, e Flauzino (2010) apontam que a adoção do termo de *momentum* permite acelerar a convergência da rede à razão de $\eta/(1 - \alpha)$.

$$W_{ji}^{(L)}(t + 1) = W_{ji}^{(L)}(t) + \alpha \cdot (W_{ji}^{(L)}(t) - W_{ji}^{(L)}(t - 1)) + \eta \cdot \delta_j^{(L)} \cdot Y_i^{(L-1)} \quad (34)$$

Na Equação 34, o bloco $\alpha (W_{ji}^{(L)}(t) - W_{ji}^{(L)}(t - 1))$ é chamado de termo de *momentum* (TM) e $\eta \delta_j^{(L)} Y_i^{(L-1)}$ é denominado o termo de aprendizagem (TA). Conforme ilustra a Figura 34, quando os valores das matrizes de peso estiverem longe do mínimo da função erro, onde se encontram os valores ótimos para os pesos (W^{OT}), haverá uma grande variação na função erro entre duas iterações consecutivas. Nessa situação, tal variação se deve principalmente à contribuição de TM, havendo também uma pequena contribuição de TA. Em outra situação, quando os valores das matrizes de peso estiverem próximos do mínimo da função erro, a variação da função erro será pequena, havendo uma grande contribuição de TA e uma pequena contribuição de TM (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

Figura 34 - Minimização do erro quadrático médio usando o método de inserção de termo de *momentum*



Fonte: Silva, Spati e Flauzino (2010)

O método *resilient-propagation* é outro algoritmo que deriva do *backpropagation* e visa acelerar o processo de convergência da rede. Esse algoritmo não considera a derivada parcial das funções de ativação no ajuste dos pesos para evitar que o processo de treinamento se torne lento quando os valores de saída do neurônio estiverem próximos da região de saturação, pois neste caso seriam ajustados usando valores de gradiente próximos de zero. Desta forma, o método *resilient-propagation* ajusta os parâmetros adaptativos usando somente o sinal de variação da função erro, não considerando as magnitudes do gradiente dessa função (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010).

Outra variação do *backpropagation* que visa melhorar o desempenho do treinamento de redes PMC é o método de Levenberg-Marquart. Esse método é baseado no método dos mínimos quadrados para modelos não lineares. Ao invés de minimizar a função do erro quadrático médio, é feito um procedimento iterativo para minimização de uma função $V(z)$ em relação a um vetor paramétrico z , que objetiva o cálculo de uma matriz de derivadas de primeira ordem (matriz Jacobiana) que permitirá o ajuste dos pesos. Apesar de bastante complexo, esse procedimento consegue acelerar a convergência do algoritmo *backpropagation* em cerca de 10 a 100 vezes (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010).

Além dos métodos apresentados, existem diversos outros que podem ser usados no treinamento de redes PMC. A escolha de um método adequado é importante não só pela influência na velocidade do treinamento, mas pode afetar a capacidade de generalização da rede. Desta forma, dependendo do nível de precisão de resposta requerido pela aplicação, pode ser requerida a avaliação de diferentes algoritmos de treinamento para a rede visando à escolha da melhor alternativa. Uma forma de avaliar o desempenho individual dos métodos de treinamento é o uso da técnica de validação cruzada, que é discutida na Subseção 3.4.3 deste capítulo.

Conforme já foi discutido, após a finalização do processo treinamento, a rede está apta a produzir respostas para situações até então desconhecidas. A subseção a seguir detalha como funciona o processo de produção das saídas da rede quando estas são aplicadas em problemas de aproximação funcional, como no caso da modelagem das relações de causa e efeito entre os indicadores do modelo SCOR[®].

3.4.2 O uso de redes PMC como um aproximador funcional


Um tipo de aplicação recorrente das redes PMC é voltado para problemas de aproximação de funções (ou aproximação funcional). Na modelagem de problemas desse tipo, o objetivo da rede é mapear uma função matemática, que determina o comportamento de um processo ou de um sistema, com base em diversas medições efetuadas ao longo do tempo em suas entradas e saídas (HAYKIN, 2001; SILVA; SPATI, FLAUZINO, 2010).

Assumindo que a função de ativação adotada nos neurônios da camada de saída seja contínua e limitada em sua imagem, uma topologia de PMC constituída de apenas uma camada intermediária é capaz de mapear qualquer função contínua no espaço das funções reais. Todavia, pode ser mais viável utilizar mais de uma camada intermediária visando melhorar o desempenho da rede e reduzir sua estrutura topológica, diminuindo assim a quantidade total de neurônios. Redes PMC com duas ou mais camadas também devem ser adotadas quando o objetivo é mapear funções algébricas em que há descontinuidade no domínio (SILVA; SPATI, FLAUZINO, 2010; TSOUKALAS; UHRIG, 2007).

Para exemplificar o funcionamento de uma rede PMC como um aproximador funcional, a Figura 35 (a) apresenta um exemplo em que a rede é composta por apenas uma camada intermediária. Conforme ilustra a Figura 35 (b), nesta rede são usadas funções de ativação do tipo logística nos neurônios da camada intermediária e do tipo

linear na camada de saída. O termo λ_i representa a matriz de pesos do neurônio da camada de saída após esta já ter sido ajustada por meio do processo de treinamento (SILVA; SPATI, FLAUZINO, 2010).

Figura 35 - Exemplo de uma rede PMC aplicada em problemas de aproximação funcional



Fonte: Silva, Spati e Flauzino (2010)


Conforme representam as Equações 35 e 36, o resultado do mapeamento de uma função y será composto por meio da superposição das funções de ativação dos neurônios da camada escondida $\{g_i^{(1)}(u_i^{(1)})\}$, ponderadas pelos valores de λ_i . Desta forma, o papel do neurônio da camada de saída consiste somente em fazer uma combinação linear dessas funções de ativação ponderadas.

$$y(x_1, x_2, \dots, x_n) = \sum_{i=1}^{n_1} \lambda_i \cdot g_i^{(1)}(u_i^{(1)}) \quad (35)$$

$$u_i^{(1)} = \sum_{j=1}^n w_{ij}^{(1)} \cdot x_j - \theta_i \quad (36)$$

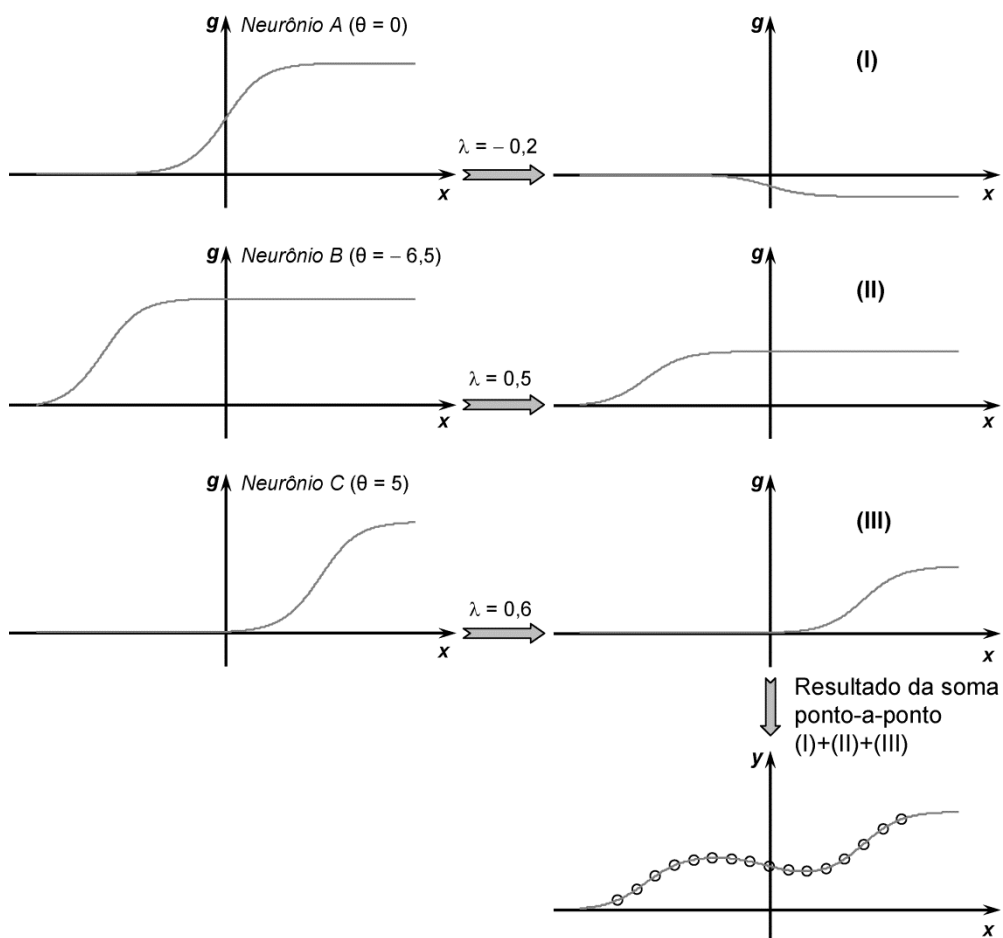
Suponha que se deseja implementar uma rede PMC para mapear o comportamento da função y , mostrada na Figura 36, usando a rede mostrada na Figura 35 (SILVA; SPATI; FLAUZINO, 2010). Para essa situação, a Figura 37 apresenta uma possível representação de como seria feita a combinação linear das funções de ativação logística provenientes dos neurônios da camada intermediária (neurônios A, B e C).

Figura 36 - Exemplo de uma função a ser mapeada por uma rede PMC



Fonte: Silva, Spati e Flauzino (2010)

Figura 37 - Exemplo de processo de mapeamento de uma função por uma rede PMC



Fonte: Silva, Spati e Flauzino (2010)

Analisando a Figura 37, é possível notar que os limiares de ativação desses neurônios $\{\theta_i\}$, já ajustados durante o treinamento, são responsáveis pela translação das funções de ativação ao longo de seu domínio de definição. Já a matriz de pesos dos neurônios da camada de saída, representada por λ_i , está incumbida de fazer o escalonamento dessas funções de ativação por meio do processo de ponderação. Ao fazer a combinação linear das funções de ativação ponderadas, o neurônio da camada de saída

estará efetuando uma soma ponto a ponto das funções ponderadas dos neurônios A, B e C (SILVA; SPATI, FLAUZINO, 2010). Portanto, por meio do uso dos mecanismos apresentados, o neurônio da camada de saída implementa uma operação que mapeia o comportamento da função ilustrada na Figura 36.

Embora o teorema da aproximação universal ajude na determinação da quantidade de camadas intermediárias necessárias para o mapeamento de uma função específica, a determinação da quantidade de neurônios que devem ser usados em cada camada intermediária é um processo complexo, que geralmente é realizado de forma empírica. A subseção a seguir foca no processo de definição da configuração topológica e em outros aspectos relevantes para a modelagem de redes PMC.

3.4.3 Modelagem de redes PMC

Diversos cuidados são requeridos na modelagem de RNAs para se obter um modelo adequado, confiável e com resultados suficientemente precisos. Uma vez que a modelagem de redes PMC envolve a definição e avaliação de diversas topologias candidatas para escolher a configuração e os valores adequados para alguns parâmetros da rede, o desenvolvimento dessas redes costuma ser complexo e às vezes demorado. Por exemplo, em uma aplicação realizada por Akkoç (2012) para apoiar a análise de pontuação de crédito em uma empresa de cartão de crédito, foram desenvolvidos e avaliados 270 modelos de rede para determinar a configuração topológica mais adequada. Visando esclarecer as diretrizes e técnicas que suportam o processo de desenvolvimento de redes PMC quando aplicadas em problemas de aproximação funcional, os principais aspectos referentes à parametrização da rede, à escolha da configuração topológica mais apropriada, à organização das amostras e a outros assuntos relevantes à modelagem são discutidos a seguir.

Conforme descreve o Quadro 14, durante o treinamento de uma rede PMC, é necessário especificar os valores a serem adotados pelos parâmetros referentes à taxa de aprendizagem (η), à precisão requerida (ϵ), às matrizes de pesos sinápticos de cada camada neural ($W_{ij}^{(L)}$) e ao limiar de ativação de cada neurônio (θ_j). Se o algoritmo de inserção de termo de *momentum* for usado durante o treinamento, o valor da taxa de *momentum* (α) também deverá ser especificado. Também há a opção de se determinar um número máximo de épocas como critério de parada do treinamento para evitar que este consuma muito tempo. Embora a escolha dos valores desses parâmetros seja feita

empiricamente, a seleção dos valores candidatos costuma ser apoiada por dados encontrados na literatura relacionada, principalmente em livros sobre RNA e em artigos que relatam aplicações destas redes.

Quadro 14 - Aspectos a serem definidos na modelagem de uma rede PMC

Aspectos a serem definidos	Função	Recomendação
Matriz de pesos de cada camada ($W_{ij}^{(L)}$) e limiar de ativação de cada neurônio (θ_j)	Embora os valores usados na fase de operação sejam determinados após o treinamento, os valores iniciais destes parâmetros devem ser especificados a fim de ponderar as entradas durante a fase <i>forward</i> do processo de aprendizagem	$0 \leq W_{ij}^{(L)} \leq 1$ e $0 \leq \theta_j \leq 1$ (SILVA; SPATI, FLAUZINO, 2010)
Taxa de aprendizagem (η)		$0 < \eta < 1$ (SILVA; SPATI, FLAUZINO, 2010) $\eta = 0,03$ (BILGEHAN, 2011)
Taxa de aprendizagem quando for usado o método de inserção do termo de <i>momentum</i> :	Determina a rapidez com que a rede se aproximará do ponto de minimização da função erro	$0,05 < \eta < 0,75$ (SILVA; SPATI, FLAUZINO, 2010), $0,01$ (AKKOÇ, 2012) $\eta = 0,3$ (ABURTO, WEBER, 2007) $\eta = 0,5$ (EFENDIGIL; ÖNUT; KAHRAMAN, 2009)
Taxa de <i>momentum</i> (α)	Determina a magnitude da contribuição do termo de <i>momentum</i> no processo de minimização da função erro durante o treinamento	$0 \leq \alpha \leq 0,9$ (SILVA; SPATI, FLAUZINO, 2010) $\alpha = 0,1$ (ABURTO, WEBER, 2007) $\alpha = 0,7$ (EFENDIGIL; ÖNUT; KAHRAMAN, 2009) $\alpha = 0,9$ (BILGEHAN, 2011; AKKOÇ, 2012)
Precisão requerida (ε)	Mede a aproximação rumo a um ponto de mínimo da função erro e serve como critério de parada para o <i>backpropagation</i> durante o treinamento	$\varepsilon = 0$ (quando não há informações suficientes para defini-la) $\varepsilon = 0,01$ (EFENDIGIL; ÖNUT; KAHRAMAN, 2009) $\varepsilon = 0,00001$ (BILGEHAN, 2011)
Número máximo de épocas	Serve como critério de parada do algoritmo de treinamento quando não é possível alcançar a precisão requerida	10.000 (AKKOÇ, 2012) 5.000 (BILGEHAN, 2011) 1.000 (EFENDIGIL; ÖNUT; KAHRAMAN, 2009)

Fonte: Proposto pelo autor.

Para apoiar a escolha dos valores dos parâmetros dos modelos, além da seleção de valores a partir da literatura, também podem ser feitos testes empíricos visando aperfeiçoar os valores adotados. Esses testes costumam ser feitos durante o treinamento a partir da comparação do desempenho da rede ou da agilidade do treinamento mediante o uso de diferentes configurações paramétricas. Dependendo da quantidade de parâmetros a serem definidos e da quantidade de valores sendo testados para cada um, tais testes podem consumir bastante tempo.

Outra definição muito importante na modelagem de RNAs se refere à escolha da melhor configuração topológica para a rede. A configuração topológica de uma RNA diz respeito à quantidade de camadas neurais usadas e de neurônios presentes em cada camada. A escolha de uma configuração topológica apropriada influencia o desempenho na fase de uso da rede e depende de diversos fatores, incluindo a complexidade do problema a ser mapeado, o algoritmo de treinamento utilizado, a qualidade das amostras usadas no processo de treinamento e a forma como as matrizes de pesos foram iniciadas (SILVA; SPATI; FLAUZINO, 2010).

Uma das técnicas mais utilizadas para apoiar a escolha de uma configuração topológica apropriada para uma RNA, de um algoritmo de treinamento adequado e dos valores dos parâmetros apresentados no Quadro 14, é denominada validação cruzada (ou *cross-validation*). O objetivo desta técnica é avaliar a capacidade de generalização de cada uma das topologias candidatas quando aplicadas a um conjunto de amostras diferente daquele usado durante o treinamento (AKKOÇ, 2012, MOOSMAYER et al., 2013). As topologias candidatas podem variar quanto aos valores dos parâmetros usados, número de camadas, quantidades de neurônios em cada camada e método de treinamento. O número de neurônios usados na camada intermediária de cada topologia candidata pode ser definido em função do número de entradas da rede. Neste sentido, sendo n a quantidade de variáveis de entrada, as quantidades de neurônios a serem testadas na camada intermediária das topologias candidatas podem ser definidas por $2n$, $2n \pm 1$ e $2n \pm 2$ (HECHT-NIELSEN, 1990). O algoritmo mostrado no Quadro 15 descreve em detalhes os passos da técnica de validação cruzada.

Quadro 15 - Passos da técnica de validação cruzada

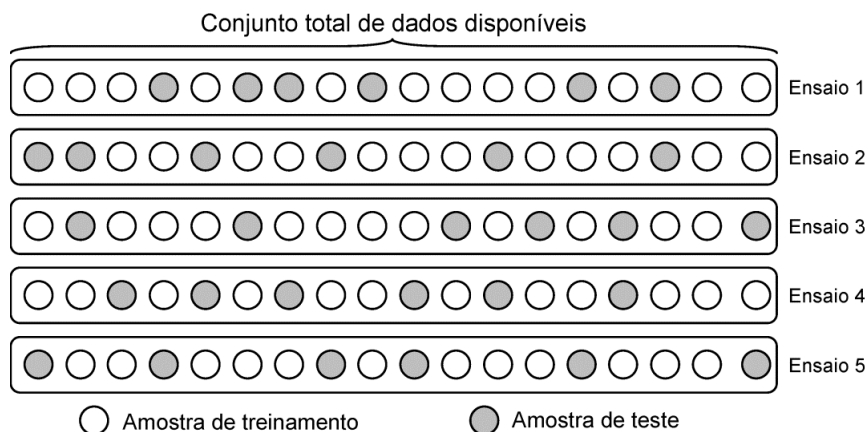
<p>Início</p> <p><1> Definir as topologias candidatas para o problema;</p> <p><2> Disponibilizar os subconjuntos de treinamento e de teste;</p> <p><3> Aplicar o algoritmo de treinamento do PMC para todas as topologias candidatas usando o subconjunto de treinamento;</p> <p><4> Aplicar o subconjunto de teste nas topologias candidatas (já treinadas) visando avaliar a capacidade de generalização;</p> <p><5> Obter o desempenho global de cada topologia candidata em função de seu desempenho nos ensaios realizados;</p> <p><6> Selecionar a topologia candidata que obteve o melhor desempenho global;</p> <p><7> Se o desempenho global desta melhor topologia candidata estiver de acordo com a precisão requerida ao problema,</p> <p style="padding-left: 40px;"><7.1> Então: terminar o processo de validação cruzada;</p> <p style="padding-left: 40px;"><7.2> Senão: especificar novo conjunto de topologias candidatas e voltar ao passo <3>;</p> <p>Fim</p>

Fonte: Silva, Spati e Flauzino (2010)

Há diferentes formas de empregar a validação cruzada durante a seleção da melhor topologia de rede. Alguns dos métodos mais comuns são conhecidos como validação cruzada por amostragem aleatória, validação cruzada usando k -partições e validação cruzada por unidade (SILVA; SPATI; FLAUZINO, 2010; BERGMEIR; BENÍTEZ, 2012). Estes métodos atuam principalmente sobre a organização das amostras para que o passo <2> do algoritmo de validação cruzada possa ser executado.

Conforme ilustra a Figura 38, o método de validação por amostragem aleatória (*random subsampling cross-validation*) é composto por diversos ensaios. Em cada um deles, o conjunto total de amostras é dividido em subconjunto de treinamento, composto por cerca de 60 a 90% do total de amostras, e subconjunto de teste, formado pela seleção aleatória de 10 a 40% das amostras. A seleção aleatória do subconjunto de teste deve considerar todas as amostras, independentemente de algumas já terem sido selecionadas em ensaios prévios. Também é de suma importância garantir que a distribuição dos dados usados no subconjunto de treinamento seja representativa de todo o intervalo numérico das variáveis envolvidas (SILVA; SPATI; FLAUZINO, 2010).

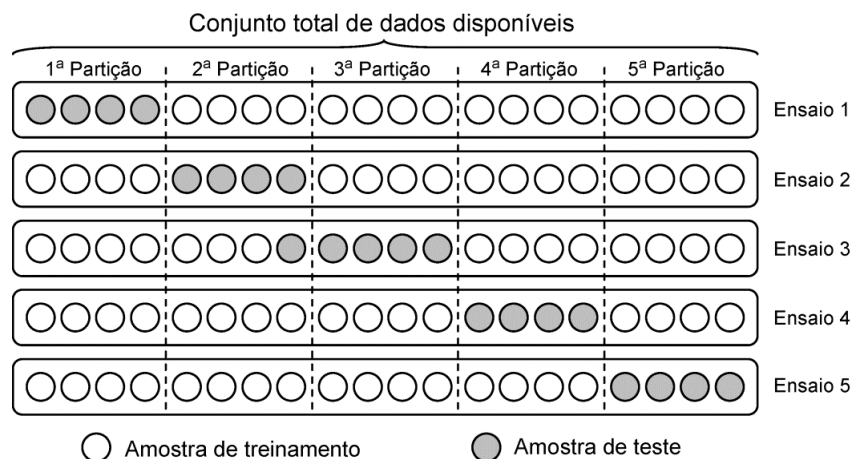
Figura 38 - Método de validação cruzada usando amostragem aleatória



Fonte: Silva, Spati e Flauzino (2010)

A quantidade de amostras necessárias ao treinamento é pelo menos duas vezes o número de parâmetros de pesos sinápticos da rede. Contudo, é preferível utilizar uma quantidade de amostras que seja no mínimo quatro vezes a quantidade de pesos da rede (APICHOTTANAKUL; PATHMNAKUL; PIEWTHONGNGAM; 2012). Enquanto o subconjunto de treinamento é utilizado para realizar os ajustes referentes à aprendizagem da rede, o subconjunto de teste é aplicado somente na etapa de avaliação da capacidade de generalização da rede. Para avaliar a capacidade de generalização de cada topologia candidata, a partir da apresentação dos valores de entrada do subconjunto de teste à rede já treinada, compara-se os valores de saída produzidos pela rede com os respectivos valores desejados para cada amostra (MOOSMAYER et al., 2013).

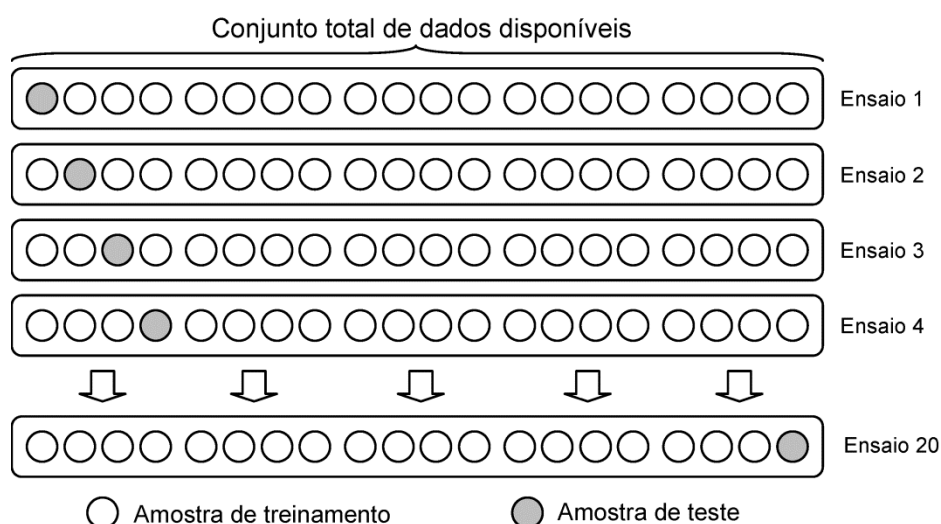
Conforme exemplifica a Figura 39, o método de validação cruzada denominado *k*-partições (*k-fold cross-validation*) subdivide o conjunto total de amostras em *k* partições (no exemplo, $k=5$) a fim de utilizar “*k*-1” partições como amostras de treinamento e as demais como amostras de teste. O processo de treinamento da rede deve ser executado *k* vezes, de modo que todas as partições sejam utilizadas uma vez como subconjunto de teste. O valor usualmente adotado para o parâmetro *k* varia entre 5 e 10, dependendo da quantidade total de amostras disponíveis. Assim como nos demais métodos de validação cruzada, o desempenho global de cada topologia candidata é obtido em função do desempenho individual alcançado em cada ensaio realizado (SILVA; SPATI; FLAUZINO, 2010).

Figura 39 - Método de validação cruzada usando k -partições

Fonte: Silva, Spati e Flauzino (2010)

Quanto ao terceiro e último método, denominado de validação cruzada por unidade (*leave-one-out cross validation*) e representado na Figura 40, este utiliza uma única amostra no subconjunto de teste, sendo menos usual que os anteriores. Esse método, pode ser visto como um caso particular do método de k -partições, em que o valor de k é igual ao número total de amostras. O método de validação cruzada por unidade executa o processo de treinamento diversas vezes, até que todas as amostras sejam individualmente usadas como subconjunto de teste. O número de ensaios a serem realizados equivale à quantidade total de amostras, o que contribui para que este método possua elevada complexidade computacional (SILVA; SPATI; FLAUZINO, 2010).

Figura 40 - Método de validação cruzada por unidade



Fonte: Silva, Spati e Flauzino (2010)


Devido ao conjunto total de amostras ser particionado diversas vezes ao longo do treinamento das topologias candidatas, independentemente do método utilizado para organizar as amostras, em cada ensaio é formado um novo subconjunto de teste e,

consequentemente, um novo subconjunto de treinamento. Como o desempenho global das topologias candidatas é avaliado em função do desempenho obtido em cada ensaio, o uso de pacotes de dados diferentes em cada ensaio permite minimizar a influência das características desses dados sobre a avaliação da capacidade de generalização (SILVA; SPATI; FLAUZINO, 2010).

Durante a aplicação da validação cruzada, uma prática bastante utilizada consiste em executar diversos treinamentos a cada ensaio, inicializando as matrizes de peso de forma aleatória em cada um deles. Ao inicializar as matrizes de peso várias vezes, minimiza-se a probabilidade de a função erro estacionar em um ponto de mínimo local durante a execução do *backpropagation*, o que poderia prejudicar a capacidade de generalização da rede (SILVA; SPATI; FLAUZINO, 2010). Após executar todos os treinamentos e respectivos testes de generalização previstos para um determinado ensaio, devem ser selecionados os valores das matrizes de peso que forneçam o menor erro quando aplicadas no subconjunto de teste.

No exemplo apresentado na Figura 41, em um dado ensaio composto por 3 treinamentos, ao realizar o primeiro treinamento do PMC, as matrizes dos pesos sinápticos representadas por $W^{(a)}$ foram inicializadas aleatoriamente e em seguida foram gradativamente ajustadas até o ponto de mínimo local representado por $p^{(1)}$, quando o treinamento foi então finalizado. No segundo treinamento, os valores das matrizes de peso foram iniciados no ponto $W^{(b)}$ e ajustados até alcançarem o ponto de mínimo $p^{(2)}$. Como o ponto $p^{(2)}$ fornece um erro menor que o ponto $p^{(1)}$, os valores ajustados das matrizes de peso no segundo treinamento tendem a produzir resultados mais satisfatórios que aqueles que seriam obtidos em $p^{(1)}$ (e também em $p^{(3)}$). Caso isso aconteça, a capacidade de generalização alcançada no segundo treinamento deve ser a representante do desempenho alcançado pela topologia candidata no ensaio mostrado (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

Figura 41 - Exemplo de pontos de mínimos locais na função erro



Fonte: Silva, Spati e Flauzino (2010)

Além da validação cruzada, a literatura sobre RNAs também apresenta outras técnicas para determinar a configuração topológica apropriada para um dado problema. Por exemplo, para determinar a quantidade de neurônios presentes na única camada escondida de uma rede PMC, pode-se usar o método de Kolmogorov ou o método de Flether-Gloss (SILVA; SPATI; FLAUZINO, 2010). O método de Kolmogorov determina a quantidade de neurônios da camada escondida (n_1) em função da quantidade de entradas da rede (n) a partir da aplicação direta da Equação 37. Já o método de Flether-Gloss, mostrado na Equação 38, além do número de entradas da rede, considera também a quantidade de neurônios na camada intermediária (n_2).


$$n_1 = 2 \cdot n + 1 \quad (37)$$

$$2 \cdot \sqrt{n} + n_2 \leq n_1 \leq 2 \cdot n + 1 \quad (38)$$

Quando comparados com os métodos de validação cruzada, os métodos de Kolmogorov e Flether-Gloss são mais simples e proveem mais agilidade ao processo de modelagem por não requerem a realização de vários ensaios durante o processo de treinamento. Contudo, a validação cruzada tende a garantir melhores resultados por considerar diferentes alternativas de configuração topológica durante a escolha da mais apropriada. Independentemente da técnica aplicada na seleção da configuração topológica da rede, alguns procedimentos devem ser efetuados durante o processo de treinamento visando garantir a produção de resultados satisfatórios pela rede.

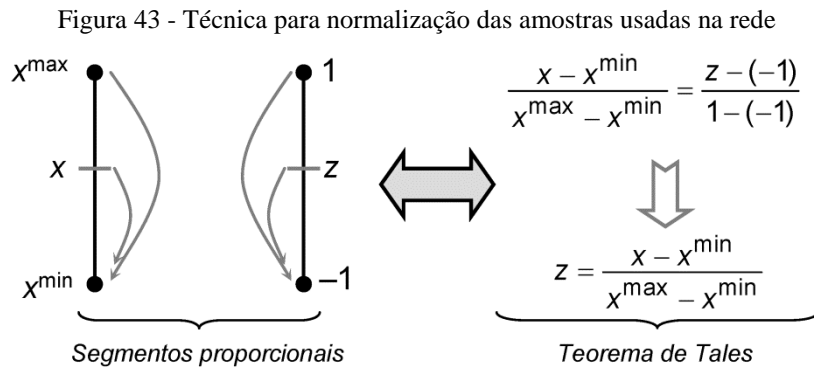
Para assegurar que a rede será capaz de generalizar soluções adequadas ao longo de todo o domínio de definição de sua(s) variável(is) de saída, é necessário incluir no subconjunto de treinamento todas as amostras que contenham os valores mínimos e máximos das variáveis de entrada e de saída. Caso isso não seja feito e se tais amostras forem apresentadas à rede por meio do subconjunto de teste, o PMC tentará generalizar valores que não fazem parte do domínio de definição de suas variáveis, gerando assim resultados insatisfatórios. Para exemplificar tal situação, a Figura 42 apresenta um exemplo de uma aplicação em que um PMC foi treinado para mapear uma função seno. Nesse exemplo, os valores de entrada das amostras utilizadas no treinamento variam entre 0 e 10. Analisando a curva estimada pelo PMC usando o subconjunto de teste, verifica-se que somente os valores dentro do domínio de definição das variáveis de entrada são estimados precisamente (SILVA; SPATI; FLAUZINO, 2010).

Figura 42 - Aplicação de um PMC no mapeamento de uma função seno



Fonte: Silva, Spati e Flauzino (2010)


Outro procedimento referente à preparação dos dados que serão apresentadas à rede consiste na normalização de todas as amostras de acordo com as funções de ativação usadas nos neurônios da(s) camada(s) intermediária(s) da rede. A normalização das amostras deve ser efetuada nas etapas de treinamento, de validação e também de operação da rede, podendo utilizar de várias técnicas. A técnica de normalização mais comum, exemplificada na Figura 43, é baseada no princípio dos segmentos proporcionais. No exemplo mostrado, o valor de uma amostra (x), definido no intervalo $[x^{min}, x^{max}]$, é convertido para um domínio entre -1 e 1, mantendo a mesma proporção entre os valores (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).



Fonte: Silva, Spati e Flauzino (2010)

Conforme representa a Figura 44, os limites mínimo (x^{\min}) e máximo (x^{\max}) utilizados na normalização são definidos de acordo com as faixas de valores da região de variação dinâmica das funções de ativação usadas nas camadas intermediárias do PMC. Como no exemplo mostrado as camadas intermediárias da rede utilizam funções de ativação do tipo logística, os valores mínimos e máximos a serem usados na normalização das amostras são definidos respectivamente como -1 e 1 para as entradas e 0 e 1 para as saídas (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

Figura 44 - Domínio de normalização para a função de ativação logística




Fonte: Silva, Spati e Flauzino (2010)

O último aspecto discutido nesta subseção se refere a dois problemas que podem ocorrer durante o processo de modelagem. O primeiro deles, chamado de *overfitting*, consiste em uma situação em que ocorre aprendizagem excessiva da rede. O *overfitting* ocorre principalmente devido ao uso de topologias de rede com quantidades exageradas de neurônios ou de camadas intermediárias. A topologia inadequada acaba memorizando excessivamente as características das amostras usadas no treinamento, passando a decorar as respostas esperadas para cada amostra apresentada. Por causa disso, os valores obtidos para o erro quadrático médio tendem a ser muito baixos durante o treinamento e altos durante a etapa de testes da capacidade de generalização. No exemplo mostrado na Figura 45, a topologia 1 é composta por 20 neurônios e apresenta o problema de *overfitting*. Já a

topologia 2 é formada por 10 neurônios e não sofre *overfitting*. Embora a topologia 1 consiga estimar com exatidão os valores de saída desejados durante o treinamento, o erro produzido quando são consideradas as amostras de teste costuma ser alto. No caso da topologia 2, apesar de apresentar um erro maior que a topologia 1 na fase de treinamento, esta é capaz de se aproximar mais dos valores desejados das amostras de teste, estimando assim as saídas de forma satisfatória (HAYKIN, 2001; SILVA; SPATI; FLAUZINO, 2010).

Figura 45 - Comportamento de um PMC operando em situação de *overfitting*



Fonte: Silva, Spati e Flauzino (2010)

Em uma situação contrária ao *overfitting*, quando o número de neurônios usados na rede for muito reduzido, tal topologia pode ser insuficiente para mapear o comportamento do problema em questão, causando um problema de *underfitting*. Quando o *underfitting* ocorre, o erro quadrático médio será bastante elevado tanto na fase de treinamento quanto na fase de testes. Uma forma de minimizar a chance de ocorrência do *underfitting* e do *overfitting* é a adoção da técnica de validação cruzada para aperfeiçoar a configuração topológica da rede, a qual foi utilizada neste estudo.

Em suma, a partir das discussões apresentadas nesta subseção, verifica-se que durante o processo de modelagem de uma rede PMC é fundamental:

- i. Escolher valores adequados para os parâmetros taxa de aprendizagem (η), precisão requerida (ε), matrizes de pesos sinápticos de cada camada neural ($W_{ij}^{(L)}$) e limiares de ativação (θ_j);

- ii. Aplicar a técnica de validação cruzada para escolha da configuração topológica mais adequada. Os métodos de Kolmogorov e Flether-Gloss podem ser usados em conjunto com essa técnica para definir a configuração das topologias candidatas;
- iii. Executar diversos treinamentos a cada ensaio, inicializando as matrizes de peso de forma aleatória em cada um deles;
- iv. Incluir no subconjunto de treinamento todas as amostras que contenham os valores mínimos e máximos das variáveis de entrada e de saída;
- v. Normalizar os valores de todas as amostras utilizadas nas etapas de treinamento, teste e de operação.

3.4.4 Limitações de redes neurais artificiais

Embora as RNAs apresentem algumas vantagens de uso perante outras técnicas existentes, como a adaptação por experiência, capacidade de generalização, armazenamento distribuído e tolerância a falhas, tais redes também vêm recebendo algumas críticas devido a suas limitações. Um dos pontos mais criticados se refere ao processo de treinamento e validação, que costuma consumir muito tempo na tentativa de se alcançar uma configuração topológica adequada, principalmente quando a quantidade de parâmetros a serem otimizados leva a um grande número de combinações a serem testadas. Além disso, não há nenhuma garantia de que a execução de diversos ciclos de treinamento minimizará a função do erro médio quadrático até um ponto de ótimo global, conforme ilustrado na Figura 41 da Subseção 3.4.3 (AKKOÇ, 2012).

Outra crítica bastante frequente se deve ao fato de as RNAs funcionarem como uma caixa preta, cujo conhecimento que embasa o cálculo dos resultados está armazenado na forma de medidas puramente numéricas (AKKOÇ, 2012; APICHOTTANAKUL; PATHMNAKUL; PIEWTHONGNGAM; 2012). Também há autores que criticam o fato de as redes neurais não serem capazes de identificar a importância relativa de potenciais variáveis de entrada (AKKOÇ, 2012), já que os valores dos pesos sinápticos alcançados pela rede não necessariamente representam os pesos das variáveis de entrada. Além disso, as RNAs não possuem uma interface de interação com usuário, o que contribui para dificultar seu uso por não especialistas (DIDEHKHANI; JASSBI; PILEVARI, 2009).

Por último, outra limitação das RNAs se deve à incapacidade de representar matematicamente medidas aproximadas e considerar a incerteza associada a certas informações sobre o problema. Tal limitação faz com que as RNAs não sejam devidamente adequadas para modelar variáveis qualitativas representadas por valores

linguísticos (AKKOÇ, 2012). Para suprir algumas das limitações discutidas, alguns estudos vêm explorando a combinação de RNAs com técnicas baseadas em lógica *fuzzy*. A combinação mais frequente é feita com os sistemas de inferência *fuzzy*, que serão discutidos nas subseções a seguir.

3.5 SISTEMAS DE INFERÊNCIA FUZZY

Na tentativa de alcançar um melhor desempenho na resolução de problemas complexos, os sistemas de inferência *fuzzy* procuram se aproximar da forma de raciocínio dos seres humanos, imitando seu funcionamento por meio de um mecanismo de inferência baseado nas relações de causa e efeito entre variáveis categóricas e pela consideração da incerteza associada aos valores destas variáveis. Por meio do armazenamento do conhecimento sobre o problema em uma base de regras de decisão, este tipo de sistema permite estimar saídas para problemas de diversos tipos, tais como aqueles envolvendo controle de processos, classificação de padrões, aproximação funcional de funções lineares e não lineares, entre outros (ZIMMERMANN, 1991). Na área de gestão de operações, podem ser encontradas diversas aplicações voltadas para o apoio a práticas de gestão da qualidade (YAQIONG; MAN; ZHANG, 2011), gestão de desempenho de cadeias de suprimento (GANGA; CARPINETTI, 2011), qualificação de fornecedores (LIMA JUNIOR; OSIRO; CARPINETTI, 2013), avaliação contínua de fornecedores (OSIRO; LIMA JUNIOR; CARPINETTI, 2014) e classificação de inventário (LIMA JUNIOR; CERVI; CARPINETTI, 2014). Antes de descrever as arquiteturas de sistemas de inferência, são apresentados alguns conceitos fundamentais sobre a teoria dos conjuntos *fuzzy*.

3.5.1 Fundamentos da teoria dos conjuntos *fuzzy*


A teoria dos conjuntos *fuzzy* (*Fuzzy Set Theory*) foi proposta por Zadeh (1965) e vem sendo usada na modelagem de sistemas compostos por elementos cujas fronteiras são consideradas incertas, sendo definidas por meio de propriedades subjetivas ou atributos imprecisos. A adequação da teoria dos conjuntos *fuzzy* à modelagem de sistemas que envolvem incerteza se deve principalmente à lógica que define o grau de inclusão (ou de pertinência) dos elementos em conjuntos *fuzzy*. A lógica *fuzzy* modela um conjunto *fuzzy* \tilde{A} por meio de uma função de pertinência $\mu_A(x): X \rightarrow [0.0, 1.0]$, para permitir níveis parciais de inclusão. Ou seja, ao contrário da teoria clássica dos conjuntos, em que um

conjunto é definido por uma função característica $\mu_A(x): X \rightarrow \{0,0, 1,0\}$, a teoria dos conjuntos *fuzzy* considera valores no intervalo contínuo $[0,0, 1,0]$ para $\mu_A(x)$, admitindo-se assim a existência de níveis intermediários entre os valores de pertencimento “falso” (0.0) e “verdadeiro” (1.0) (PEDRYCZ; GOMIDE, 2007; ZADEH, 1965). Desta forma, conforme representa a Equação 39, cada um dos valores dos elementos do eixo x dentro do domínio do conjunto *fuzzy* \tilde{A} é representado por um valor *crisp* (x) e um grau de pertencimento $\mu_A(x)$ (KAHRAMAN, 2008).


$$\tilde{A} = \{x, \mu_A(x) / x \in X\} \quad (39)$$

Os números *fuzzy* são constituídos por conjuntos *fuzzy* que atendem às propriedades de convexidade geométrica e de normalidade (ao menos um ponto do conjunto deve apresentar $\mu_A(x)$ igual a 1). A representação de grandezas associadas a julgamentos tais como “em torno de 50”, “perto de 70” e “aproximadamente 100” pode ser feita por meio de números *fuzzy* (ZIMMERMANN, 1991; KAHRAMAN, 2008). A forma de um número *fuzzy* é definida por meio do comportamento de $\mu(x)$. Conforme ilustra a Figura 46, um número *fuzzy* triangular é descrito por sua função de pertinência que constitui segmentos lineares na forma de um triângulo, podendo ser escrito na forma (l, m, u) , em que m denota um valor *crisp* formal para o conjunto *fuzzy*, l é o limite inferior e u é o limite superior (PEDRYCZ; GOMIDE, 2007). Outro tipo bastante comum consiste no número *fuzzy* trapezoidal, mostrado na Figura 47, cuja função linear é caracterizada por 4 parâmetros (a, m, n, b) .

Figura 46 - Número *fuzzy* triangular




Fonte: Zimmermann (1991)

Figura 47 - Número *fuzzy* trapezoidal

Fonte: Zimmermann (1991)

Funções de pertinência não lineares também são usadas em aplicações envolvendo a teoria dos conjuntos *fuzzy*. Um exemplo deste tipo de função que é comumente usada em aplicações envolvendo inferência *fuzzy* é a função gaussiana, ilustrada na Figura 48 (PEDRYCZ; GOMIDE, 2007; KAHARAMAN, 2008). Nessa função, a corresponde à altura do pico da curva, b é a posição central e c controla a largura.


Figura 48 - Número *fuzzy* com função do tipo gaussiana

Fonte: Zimmermann (1991)

Em sistemas de inferência *fuzzy* e em outros métodos de tomada de decisão baseados em lógica *fuzzy*, números *fuzzy* são usados para modelar um tipo de variável chamado de variável linguística, cujas características intrínsecas requerem um tratamento diferenciado. Uma variável linguística é aquela cujos valores são sentenças definidas em linguagem natural ou artificial, permitindo distinguir qualificações por meio de faixas de gradações (ZADEH, 1973). O uso de variáveis linguísticas requer a definição de um conjunto de termos linguísticos para mensurar seus valores de forma adequada. Conforme ilustra o exemplo da Figura 49, por meio da modelagem *fuzzy*, o desempenho de uma cadeia de suprimento em um indicador qualitativo como “nível de confiança entre os elos”

pode ser medido por meio dos termos linguísticos “muito baixo”, “baixo”, “médio”, “alto” e “muito alto”.

Figura 49 - Exemplo de escala linguística composta por números fuzzy triangulares

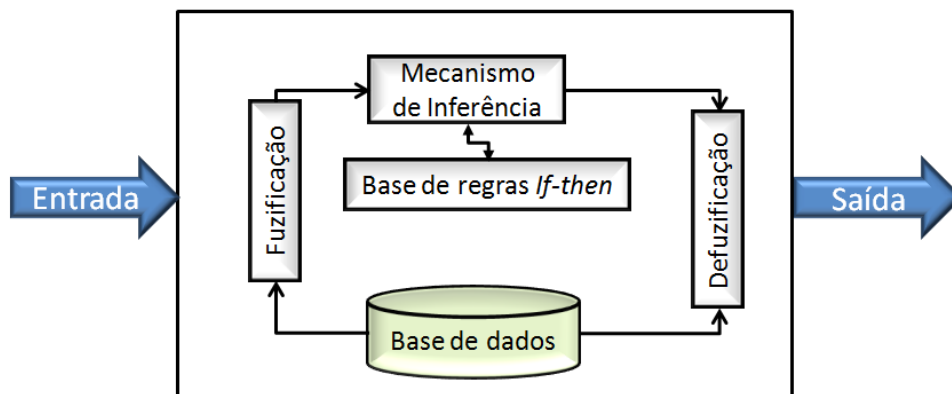


Fonte: Proposto pelo autor.

3.5.2 Arquiteturas de sistemas de inferência fuzzy

A combinação de alguns recursos da teoria dos conjuntos *fuzzy* em uma estrutura lógica constitui um sistema de inferência *fuzzy*. O primeiro sistema de inferência *fuzzy* foi proposto por Mamdani e Assilian (1975) e sofreu algumas modificações desde a versão original. A adaptação mais importante foi proposta por Takagi e Sugeno (1985). Como pode ser visto na Figura 50, a estrutura do sistema de inferência proposto por Mamdani e Assilian (1975) é constituída por cinco elementos principais: interface de fuzificação, base de regras, mecanismo de inferência, base de dados e interface de desfuzificação.

Figura 50 – Estrutura do sistema de inferência proposto Mamdani e Assilian (1975)



Fonte: Zimmermann (1991)

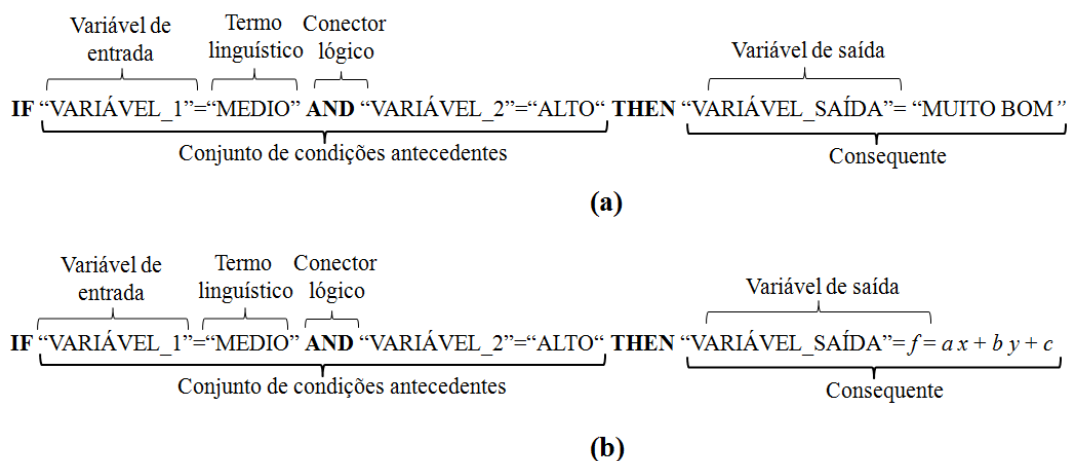
Quando um conjunto de valores numéricos de entrada é apresentado a um sistema de inferência *fuzzy*, o processo de fuzificação converte cada valor em uma ou mais partições *fuzzy*. Em problemas de tomada de decisão e de avaliação de desempenho, geralmente tais partições correspondem a termos linguísticos. Considerando o exemplo da Figura 49, suponha que o desempenho de uma cadeia de suprimento em relação à confiança entre os elos seja representado pela pontuação 6,0. Ao ser apresentado ao sistema e convertido para um formato linguístico, tal valor será considerado “alto” com nível de pertinência $\mu_A(x)$ igual a 0,4, e simultaneamente será considerado “médio” com $\mu_M(x)$ equivalente a 0,6. Ressalta-se que tal representação não se refere a uma situação probabilística, uma vez que é assumido que o valor 6 pertence de fato ao conjunto dos valores altos e simultaneamente pertence ao conjunto dos valores médios.

Após a fuzificação, os valores fuzificados são aplicados a um conjunto de regras de inferência que estabelecem relações de causa e efeito entre as variáveis de entrada e de saída. As regras de inferência que melhor representam os valores de entrada fuzificados serão então ativadas, determinando assim um conjunto de hipóteses sobre o comportamento do problema modelado. Os conjuntos *fuzzy* resultantes do processamento nas regras ativadas são agregados em um único conjunto para gerar o valor de saída do sistema. Finalmente, o conjunto *fuzzy* resultante da agregação é convertido em um valor *crisp* por meio do uso de um operador de defuzificação e posteriormente é apresentado ao usuário do sistema (MAMDANI; ASSILIAN, 1975).

Tanto no sistema de inferência proposto por Mamdani e Assilian (1975) quanto no sistema proposto por Takagi e Sugeno (1985), as variáveis de entrada e saída estão relacionadas por meio de uma base de regras de inferência que armazena informações sobre o problema modelado. A Figura 51 ilustra a estrutura de duas regras de inferência

com duas variáveis de entrada e uma de saída. Essas regras possuem uma estrutura do tipo *if-then* (se-então), ou seja, na primeira parte da regra são definidas um conjunto de condições antecedentes que descrevem um cenário específico do problema modelado, e na segunda parte é especificada qual deve ser a resposta do sistema para a variável de saída frente às condições antecedentes apresentadas (MAMDANI; ASSILIAN, 1975; PEDRYCZ; GOMIDE, 2007). Na arquitetura de Mamdani e Assilian (1975) os consequentes das regras são representados por termos linguísticos, os quais são definidos durante a modelagem do sistema com base em um conjunto de julgamentos feitos por um ou mais especialistas que possuam conhecimento sobre o domínio do problema. Já na arquitetura de Takagi e Sugeno (1985) esses consequentes são definidos como funções polinomiais, cujos valores dos coeficientes (a , b e c) são ajustados pelo algoritmo dos mínimos quadrados com base em um conjunto de dados (amostras ou medições) extraídos do problema. Tais particularidades fazem com que os sistemas de Mamdani e Assilian (1975) sejam mais apropriados para problemas de tomada de decisão, enquanto os sistemas de Takagi e Sugeno (1985) são mais adequados para lidar com problemas de aproximação funcional.

Figura 51 - Exemplo de regra de inferência das arquiteturas de Mamdani e Assilian (a) e de Takagi e Sugeno (b)




Fonte: Proposto pelo autor.

Quando um conjunto de valores de entrada é apresentado ao sistema, como cada valor de entrada costuma ser convertido em mais de um termo linguístico, a combinação dos termos ativados acionará mais de uma regra de inferência simultaneamente, de modo a considerar que mais de um cenário é verdadeiro frente às amostras apresentadas. A Figura 52 apresenta um exemplo de um sistema de inferência do tipo proposto por Mamdani e Assilian (1975), composto por 3 variáveis de entrada, representadas

respectivamente nas 3 primeiras colunas, e uma de saída, representada na última coluna. A quantidade de regras do sistema é dada pela quantidade de termos linguísticos das variáveis de entrada elevada pelo número de variáveis de entrada. Cada variável possui 3 termos linguísticos, definidos no intervalos $[0,1]$, formando assim uma base com 27 regras de inferência, sendo cada regra representada em uma linha. A desfuzificação da região final de saída é feita utilizando o operador centro de área.

Figura 52 - Exemplo de sistema de inferência



Fonte: Proposto pelo autor.

Como pode ser visto nessa figura, a partir da apresentação dos valores de entrada 0,08, 0,70 e 0,85, representados pelas linhas vermelhas verticais, são ativados os termos linguísticos destacados em amarelo. Como no processo de inferência são ativadas somente as regras em que todos os termos linguísticos antecedentes foram ativados na fuzificação, somente as regras 5, 7 e 8 serão acionadas para fornecer uma contribuição individual, que é representada pelo conjunto *fuzzy* destacado em azul na quarta coluna.

As contribuições dessas regras são agregadas para formar a saída final do sistema, que é ilustrada na última linha da quarta coluna.

A manipulação dos termos linguístico em cada regra ativada requer a utilização de operadores matemáticos de conjuntos *fuzzy*. A maioria dos métodos de tomada de decisão baseados em lógica *fuzzy* (por exemplo, *fuzzy* TOPSIS, *fuzzy* AHP e *fuzzy* QFD) manipula os valores *fuzzy* das variáveis utilizando operações algébricas *fuzzy* em função de x . Por outro lado, os sistemas de inferência propostos por Mamdani e Assilian (1975) e Takagi e Sugeno (1985) realizam as operações de processamento em função de $\mu(x)$ e utilizam para isso diferentes tipos de operadores *fuzzy*. Detalhes sobre as operações realizadas e os operadores adotados são discutidos a seguir.

3.5.3 Operações em sistemas de inferência *fuzzy*

Em sistemas de inferência *fuzzy*, os operadores utilizados na manipulação dos dados incluem operadores do tipo t-norma, t-conorma (ou s-norma), operadores de composição, de agregação e de desfuzificação. Operadores t-norma são utilizados para generalizar as operações de agregação de conjuntos *fuzzy* baseadas no conectivo lógico “AND” durante o processamento das regras de inferência $\{\mu_A(x) \text{ AND } \mu_B(y)\}$. Os conectivos “AND” representam o relacionamento lógico entre os termos linguísticos das variáveis de entrada que foram ativados durante a fuzificação (parte antecedente da regra). Para determinar um valor resultante deste tipo de operação, usa-se um operador t-norma como o mínimo (ou “min”, Equação 40), Lukasiewicz t-norma (ou diferença limitada, Equação 41), produto drástico (Equação 42), produto algébrico (Equação 43), produto Hamacher (Equação 44) ou Einstein t-norma (Equação 45) (KLEMENT; MESIAR; PAP, 2000; SMOLÍKOVÁ; WAHOWIAK, 2002).

$$\min\{\mu_A(x), \dots, \mu_B(y)\} \quad (40)$$

$$\min\{\mu_A(x) + \mu_B(y), 1.0\} \quad (41)$$

$$\min\{\mu_A(x), \mu_B(y)\} \text{ if } \max\{\mu_A(x), \mu_B(y)\} = 1, \text{ else } = 0 \quad (42)$$

$$\mu_A(x) \cdot \mu_B(y) \quad (43)$$

$$\frac{\mu_A(x) \cdot \mu_B(y)}{\{\mu_A(x) + \mu_B(y) - \mu_A(x) \cdot \mu_B(y)\}} \quad (44)$$

$$\frac{\mu_A(x) \cdot \mu_B(y)}{1 + \{1 - \mu_A(x)\} \{1 - \mu_B(y)\}} \quad (45)$$

Já os operadores t-conorma são usados para generalizar as operações envolvendo o conectivo “OR” $\{\mu_A(x) \text{ OR } \mu_B(y)\}$. Alguns exemplos desse tipo de operador são *maximum* (ou *max*), soma limitada (Lukasiewicz t-conorma, ou *bounded sum*), soma drástica (*drastic sum*), soma probabilística (*probabilistic sum*) e Einstein t-conorma (CORDÓN; HERRERA; PEREGRIN, 1997; PEDRYCZ; GOMIDE, 2007), representados respectivamente nas Equações 46 a 50.

$$\max \{\mu_A(x), \dots, \mu_B(y)\} \quad (46)$$

$$\max(\mu_A(x) + \mu_B(y) - 1.0, 0.0) \quad (47)$$

$$\max(\mu_A(x), \mu_B(y)) \text{ if } \min(\mu_A(x), \mu_B(y)) = 0, \text{ else } = 1 \quad (48)$$

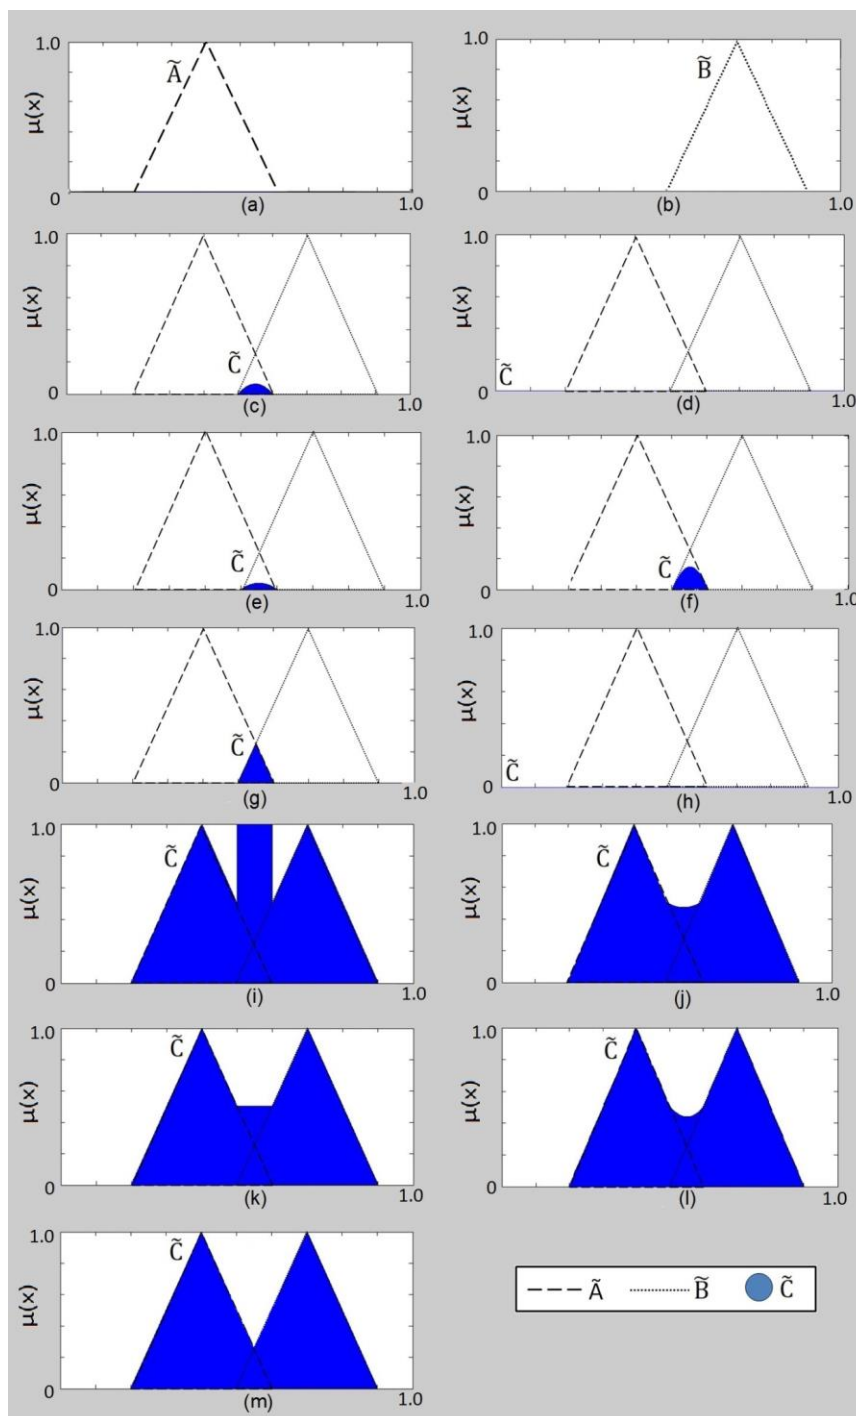
$$\mu_A(x) + \mu_B(y) - \mu_A(x) \cdot \mu_B(y) \quad (49)$$

$$\frac{\mu_A(x) + \mu_B(y)}{1 + \mu_A(x) \cdot \mu_B(y)} \quad (50)$$

Para ilustrar o comportamento desses operadores t-norma e t-conorma, a Figura 53 mostra um exemplo em que os números *fuzzy* triangulares \tilde{A} (0,20, 0,40, 0,60) e \tilde{B} (0,50, 0,70, 0,90) são agregados para formar o conjunto resultante \tilde{C} usando diferentes operadores. Os valores de \tilde{A} e \tilde{B} são mostrados nas Figuras 53 (a) e (b) respectivamente. Abaixo delas, são mostrados os valores de \tilde{C} , representando a operação $\mu_A(x) \text{ AND } \mu_B(y)$, de acordo com os operadores t-norma produto algébrico (c), produto drástico (d), Einstein t-norma (e), produto Hamacher (f), mínimo (g) e Lukasiewicz t-norma (h). Em seguida, são mostrados os valores de \tilde{C} referentes à operação $\mu_A(x) \text{ OR } \mu_B(y)$ de acordo os operadores t-conorma soma drástica (i), Einstein t-conorma (j), Lukasiewicz t-conorma (k), soma probabilística (l) e máximo (m). A partir da análise dos resultados mostrados nos gráficos, é possível notar que os operadores t-norma possuem um comportamento não compensatório, enquanto os operadores t-conorma são completamente compensatórios. Desta forma, no caso dos operadores t-norma, para cada valor em x , a existência de um valor de grau de pertinência alto em um dos conjuntos

fuzzy não é capaz de compensar nem parcialmente o valor baixo do outro elemento, gerando assim regiões *fuzzy* com graus de pertinência baixos, muitas vezes tendendo a zero. Por outro lado, analisando o comportamento dos operadores t-conorma, para cada valor em x , a existência de um valor de grau de pertinência alto em um dos conjuntos *fuzzy* já é o suficiente para produzir um grau de pertinência da mesma magnitude ou superior. Devido a tais comportamentos, em problemas de tomada de decisão, o uso de operadores t-norma representa um comportamento pessimista por parte dos tomadores de decisão enquanto o uso de t-conormas representa um comportamento otimista (LI et al., 2004).

Figura 53 - Agregação do conjunto *fuzzy* \tilde{A} e do conjunto \tilde{B} para gerar o conjunto resultante \tilde{C} de acordo com os operadores produto algébrico (c), produto drástico (d), Einstein t-norma (e), produto Hamacher (f), mínimo (g), Lukasiewicz t-norma (h), soma drástica (i), Einstein t-conorma (j), Lukasiewicz t-conorma (k), soma probabilística (l) e máximo (m)



Fonte: Proposto pelo autor.

No sistema de inferência proposto por Mamdani e Assilian (1975), em cada regra de inferência ativada, após a computação das operações lógicas da parte antecedente, o mecanismo de inferência cria uma relação de implicação R entre o conjunto *fuzzy* resultante das operações lógicas e o consequente da regra. Os graus de pertinência dos

elementos do conjunto de entrada A (x) e dos elementos do conjunto de saída B (y) são relacionados utilizando um operador de implicação. Exemplos de operadores de implicação incluem os operadores produto algébrico, “max-min” e mínimo, conforme representam respectivamente as Equações 51 a 53 (PEDRYCZ; GOMIDE, 2007). A saída de cada regra é determinada a partir da composição de relacionamentos entre um conjunto *singleton* (criado na fuzificação) e a relação de implicação R . Para isso, usa-se operadores como o “max-min”, “max-prod” e “max-media”, conforme representam respectivamente as Equações 54 a 56 (PEDRYCZ; GOMIDE, 2007).

$$\mu_{R_{A \rightarrow B}}(x, y) = \{\mu_A(x) * \mu_B(y)\} \quad (51)$$

$$\mu_{R_{A \rightarrow B}}(x, y) = \max \{1 - \mu_A(x), \min \{\mu_A(x), \mu_B(y)\}\} \quad (52)$$

$$\mu_{R_{A \rightarrow B}}(x, y) = \min \{\mu_A(x), \mu_B(y)\} \quad (53)$$

$$S \circ R(x, y) = \max \left\{ \min \left(\mu_S(x, y), \mu_R(y, z) \right) \right\} \quad (54)$$

$$S \bullet R(x, z) = \max \{ \mu_S(x, y) * \mu_R(y, z) \} \quad (55)$$

$$S \oplus R = \max \left\{ \frac{1}{2} (\mu_S(x, y) + \mu_R(y, z)) \right\} \quad (56)$$

Diferentemente dos sistemas de inferência da arquitetura de Mamdani e Assilian (1975), nos sistemas da arquitetura Takagi e Sugeno (1985) o cálculo da contribuição individual de cada regra de inferência ativada utiliza os valores *crisp* apresentados à entrada do sistema (x e y) para ponderar os parâmetros fixos da função polinomial do consequente, conforme representa a Equação 57. Como a função polinomial y_{R_i} relaciona os valores de entrada à saída da regra, este tipo de sistema não requer a utilização de operadores de implicação nem de composição de relações.

$$y_{R_i} = f(x, y)_{R_i} = a \cdot x + b \cdot y + c \quad (57)$$

Tanto nos sistemas da arquitetura de Mamdani e Assilian (1975) quanto da arquitetura de Takagi e Sugeno (1985), as contribuições advindas das regras ($\mu_{R_i}(x)$) devem ser agregadas em um único conjunto *fuzzy* utilizando um operador de agregação. Nos sistemas da arquitetura de Mamdani e Assilian (1975) frequentemente é usado

operador de agregação máximo, representado na Equação 58. Já na arquitetura de Takagi e Sugeno (1985), o operador de agregação média ponderada, representado na Equação 59, é tido como padrão (REZENDE, 2003). Nessas Equações, m é a quantidade de regras de inferência contidas na base e w_j se refere ao grau de pertinência gerado por meio das operações lógicas entre os termos linguísticos ativados em uma dada regra, que é usado como parâmetro para ponderação do valor de contribuição desta regra (y_{R_i}).

$$AG(.) = \max\{\mu_{R_1}(x), \mu_{R_2}(x), \dots, \mu_{R_m}(x)\} \quad (58)$$

$$AG(.) = \frac{\sum_{j=1}^m w_j y_{R_j}}{\sum_{j=1}^m w_j} \quad (59)$$

Por último, para gerar a saída final do sistema na arquitetura de Mamdani e Assilian (1975), a interface de desfuzificação converte os valores de saída *fuzzy* resultante da agregação das regras ativadas para o formato *crisp*. O operador centro de área é amplamente usado na desfuzificação devido ao seu maior comprometimento com a solução, uma vez que considera regiões *fuzzy* com valores de pertinência baixos durante o cálculo do valor *crisp* de saída. O operador de desfuzificação centro de área é mostrado na Equação 60, em que n é o número de pontos de discretização do conjunto *fuzzy* A . Outros exemplos de operadores de desfuzificação são métodos dos máximos (MoM) e primeiro dos máximos (FoM), representados nas Equações 61 e 62 respectivamente, em que m é o número de pontos com valor máximo na função de pertinência μ_A (ZIMMERMANN, 1991).

$$CDA = \frac{\sum_{k=1}^n \mu_A(x_k) x_k}{\sum_{k=1}^n \mu_A(x_k)} \quad (60)$$

$$MoM = \frac{1}{m} \sum_{k=1}^m x_k \quad (61)$$

$$FoM = \frac{\text{Min}\{\text{Max}\{\mu_A\}\}}{x} \quad (62)$$

Como a operação de agregação nos sistemas da arquitetura de Takagi e Sugeno (1985) consiste em somar as contribuições das funções representativas de cada regra a fim de se obter um valor final de saída, o resultado direto da agregação de funções produzirá um valor *crisp* que é a própria saída. Desta forma, esta arquitetura não requer

a utilização de um operador de desfuzificação. Visando sintetizar as operações apresentadas nesta subseção, os Quadros 16 e 17 apresentam os passos algorítmicos dos sistemas de inferência propostos por Mamdani e Assilian (1975) e por Takagi e Sugeno (1985).

Quadro 16 - Algoritmo do sistema de inferência proposto por Mamdani e Assilian (1975)

Início

- <1> Apresentar um conjunto de valores de entrada *crisp* às variáveis de entrada;
- <2> Fuzificar os valores de entrada;
- <3> Verificar quais regras de inferência são ativadas pelos valores de entrada fuzificados;
- <4> Determinar a saída de cada regra de inferência ativada usando os termos linguísticos consequentes;
- <5> Combinar as contribuições individuais de todas as regras ativadas a fim de se produzir uma resposta final;
- <6> Desfuzificar o conjunto *fuzzy* resultante do passo <5>;
- <7> Apresentar os valores de saída em formato *crisp*.

Fim

Fonte: Proposto pelo autor.

Quadro 17 - Algoritmo do sistema de inferência proposto por Takagi e Sugeno (1985)

Início

- <1> Apresentar um conjunto de valores de entrada *crisp* às variáveis de entrada;
- <2> Fuzificar os valores de entrada;
- <3> Verificar quais regras de inferência são ativadas pelos valores de entrada fuzificados;
- <4> Determinar a saída de cada regra de inferência ativada usando as funções y_i do consequente;
- <5> Combinar as saídas de todas as regras ativadas a fim de se produzir uma resposta final;
- <6> Apresentar os valores de saída em formato *crisp*.

Fim

Fonte: Proposto pelo autor.

3.5.4 Limitações de sistemas de inferência fuzzy

Apesar de os sistemas de inferência *fuzzy* serem capazes de representar informações linguísticas e de auxiliar a tomada de decisão em cenários de incerteza, estes sistemas possuem algumas limitações, sendo a maioria delas decorrentes das dificuldades causadas pela complexidade do processo de modelagem.

Uma limitação inerente aos sistemas de inferência do tipo proposto por Mamdani e Assilian (1975) consiste no fato de estes não possuírem um mecanismo para adquirir conhecimento de forma automática, não sendo capazes de autoajustar os consequentes da base de regras de inferência. Como a base de regras deve ser parametrizada manualmente

a partir de julgamentos de especialistas, dependendo da quantidade de regras contidas na base, a quantidade de julgamentos requerida para o ajuste pode tornar a coleta de dados exaustiva, tanto na fase de projeto quanto em possíveis atualizações do sistema. Para evitar que isso aconteça, deve-se adotar uma quantidade balanceada de variáveis de entrada e de termos linguísticos usados em cada variável (TSOUKALAS; UHRIG, 2007).

Enquanto os sistemas de inferência da arquitetura de Mamdani e Assilian (1975) têm seu ajuste dificultado pelo tempo requerido para a coleta de dados dos especialistas e ajuste manual de todas as regras de decisão, a dificuldade nos sistemas da arquitetura de Takagi e Sugeno (1985) está em se obter um conjunto de dados representativos de todas as variáveis do modelo, a partir de medições ou de amostras do comportamento do processo ou sistema modelado, que seja suficientemente completo. Quando não há um histórico de amostras, dependendo do tipo de aplicação, o tempo decorrido entre a coleta dos dados da primeira e da última amostra pode ser demasiadamente longo.

Uma dificuldade que afeta principalmente os sistemas do tipo proposto por Mamdani e Assilian (1975) é que a escolha dos operadores usados pode consumir muito tempo devido à diversidade de combinações possíveis entre os todos os operadores candidatos. Essa escolha é importante por impactar diretamente sobre as respostas produzidas e sobre o desempenho do sistema como um todo. É muito difícil garantir que a configuração de operadores usada será a melhor possível, dada a complexidade de se avaliar todas as possíveis combinações de operadores.

Outra dificuldade inerente aos sistemas de inferência *fuzzy* consiste em fazer algumas escolhas empíricas acerca das variáveis linguísticas de entrada e saída, tais como a quantidade de termos usados em cada variável, o formato e os valores dos parâmetros das funções de pertinência *fuzzy* que representarão os termos linguísticos. Quanto mais variáveis forem utilizadas, mais tempo poderá ser consumido na realização de tais parametrizações durante a modelagem. Para tornar a modelagem mais eficiente e equilibrar a quantidade de regras do sistema de inferência, uma estratégia recomendada na literatura consiste em utilizar três termos para as variáveis de entrada e cinco termos para a variável de saída (ALTROCK, 1995).

Diante das dificuldades relacionadas aos processos de ajuste das regras de inferência e à definição dos valores *fuzzy* das funções de pertinência dos sistemas de inferência *fuzzy*, na literatura vem sendo propostos modelos computacionais híbridos, que combinam capacidades das redes neurais artificiais com sistemas de inferência *fuzzy*, na tentativa de contornar tais dificuldades.

3.6 SISTEMAS DE INFERÊNCIA NEURO-FUZZY

Na literatura há diferentes modelos computacionais que combinam capacidades das redes neurais artificiais com recursos da lógica *fuzzy*, os quais costumam ser chamados genericamente de sistemas neuro-*fuzzy*. A maioria destes modelos é baseada em uma interpretação *fuzzy* das RNAs ou consiste em versões neurais dos sistemas *fuzzy*. Neste sentido, há sistemas baseados na estrutura de sistemas de inferência *fuzzy* que preservam as propriedades matemáticas de redes neurais de base radial, bem como modelos baseados em neurônios artificiais que implementam operações lógicas equivalentes aos operadores t-norma e t-conorma (REZENDE, 2003). Exemplos de sistemas neuro-*fuzzy* incluem o ANFIS (*Adaptative Network Fuzzy Inference System*), NEFCLASS (*Neuro-fuzzy Classification*), FSOM (*Fuzzy Self Organized Map*) e NFH (*Neuro-Fuzzy Hierárquico*). As subseções a seguir focam no tipo de sistema neuro-*fuzzy* mais difundido, conhecido como sistema ANFIS.

3.6.1 Sistemas ANFIS

ANFIS (*Adaptive-Neuro-network-based Fuzzy Inference System*) é um tipo de sistema inteligente, proposto por Jang (1993), que é baseado em algumas características das redes neurais de base radial e na estrutura de sistemas de inferência do tipo proposto por Takagi e Sugeno (1985). Modelos ANFIS são dotados de mecanismos de aprendizagem supervisionada e de regras de inferência que visam aproximar a forma de pensamento humana, cujo consequente é dado por uma função polinomial (TSOUKALAS; UHRIG, 2007; JASSBI; SEYEDHOSSEINI; PILEVARI, 2010). Como tais sistemas apresentam alto desempenho em problemas de previsão de resultados e em aplicações em tempo real, na literatura cada vez mais estes vêm sendo explorados na resolução de diversos tipos de problema, conforme exemplifica o Quadro 18. Uma revisão detalhada sobre as aplicações de sistemas ANFIS nas áreas de manufatura, sistemas elétricos e eletrônicos, controle de tráfego, processamento de imagens e sistemas médicos pode ser encontrada em Kar, Das e Ghosh (2014).

Quadro 18 – Listagem de aplicações de sistemas ANFIS

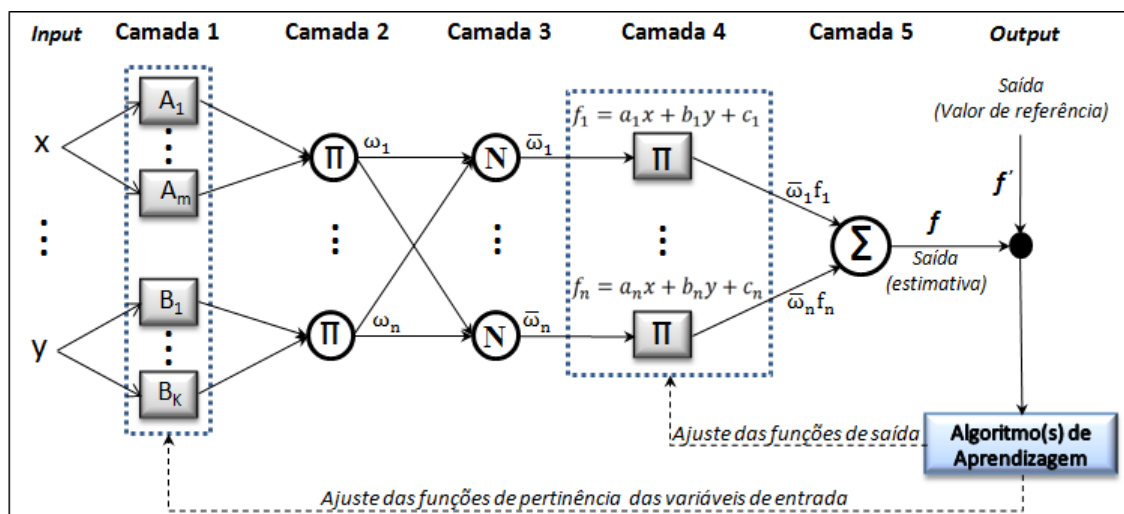
Proposto por	Aplicação
Akkoç (2012)	Análise de pontuação de crédito em uma empresa de cartão de crédito
Ay e Kisi (2014)	Avaliação da qualidade de água
Bagheri, Peyhani e Akbari (2014)	Previsão de preços no mercado financeiro
Efendigil e Önüt (2012)	Previsão de demanda para cadeias de suprimento multiestágios
Göktepe, Agar e Lav (2004)	Predição de propriedades mecânicas de pavimentos flexíveis
Güneri, Ertay e Yücel (2011)	Seleção de fornecedores em uma empresa têxtil
Khoshnevisan et al. (2014)	Predição do rendimento de grãos de trigo com base em entradas de energia
Srinivasan e Malliga (2010)	Predição do rendimento de plantações de <i>jatropha</i> (uma planta usada na produção de biocombustíveis)

Fonte: Proposto pelo autor.

Os sistemas ANFIS se baseiam na equivalência matemática e funcional dos sistemas de Takagi e Sugeno (1985) com as redes de função de base radial (RBF). As funções de ativação gaussianas utilizadas na camada intermediária em redes RBF podem ser vistas como as funções de pertinência dos termos linguísticos das variáveis de entrada de um sistema de inferência. Já a função de ativação linear usada na camada de saída, que faz uma combinação linear das saídas dos neurônios da camada intermediária, é equivalente ao operador de agregação que soma os resultados das funções polinomiais representativas de cada regra nos sistemas de Takagi e Sugeno (1985), produzindo a saída do sistema sem requerer operações de desfuzificação (REZENDE, 2003).

Como mostra a Figura 54, a estrutura de um ANFIS é composta por cinco camadas. Cada unidade neural (ou nó) dentro da mesma camada desempenha funções do mesmo tipo. Os nós representados por círculos são chamados nós fixos e os nós representados por quadrados são denominados nós adaptativos. Os nós adaptativos são ajustados usando um conjunto de amostras durante o treinamento do sistema, e suas saídas dependem de parâmetros modificáveis dentro de cada nó. Diferentemente dos modelos de redes neurais, as conexões entre os nós de camadas diferentes não apresentam pesos sinápticos (JANG, 1993).


Figura 54 - Exemplo de estrutura de um ANFIS



Fonte: Jang (1993)

Assim como nos sistemas de inferência tradicionais, na camada de entrada (camada 1) são definidas algumas funções de pertinência para particionar o espaço das variáveis de entrada. As Figuras 55 (a) e (b) exemplificam a representação das funções de pertinência das variáveis de entrada usando funções gaussianas, que costumam ser as mais adotadas para tal propósito. Os parâmetros que definem o centro e o suporte de cada uma destas funções são chamados de parâmetros de premissa (JANG, 1993).

Figura 55 - Exemplo de particionamento das variáveis de entrada em um sistema ANFIS



Fonte: Proposto pelo autor.

Na camada 1 do sistema ANFIS, o objetivo é fuzificar os valores de entrada do sistema (x e y), ou seja, converter um conjunto de valores numéricos *crisp* em um ou mais conjuntos *fuzzy* equivalentes. A saída desta camada consiste em um conjunto de valores de pertinência correspondentes ao nível de ativação de cada um dos termos linguísticos, $\{\mu_{A_1}(x), \dots, \mu_{A_m}(x)\}$ e $\{\mu_{B_1}(y), \dots, \mu_{B_m}(y)\}$.

A camada 2 é composta pela parte antecedente de um conjunto de regras de inferência, constituídas a partir das possíveis combinações entre os termos linguísticos da primeira camada. Conforme ilustra a Figura 56, as regras de inferência dos sistemas ANFIS são similares às regras de um sistema de inferência de Takagi e Sugeno (1985) de

primeira ordem. A primeira e a última regra do sistema ANFIS podem ser descritas conforme as Figuras 56 (a) e (b), respectivamente (JANG, 1993).

Figura 56 – Regras de inferência em um sistema ANFIS

$$\text{IF } x = A_1 \text{ AND } y = B_1 \text{ THEN } f_1 = a_1x + b_1y + c \quad (\text{a})$$

$$\text{IF } x = A_m \text{ AND } y = B_k \text{ THEN } f_n = a_nx + b_ny + c \quad (\text{b})$$

Fonte: Jang (1993)

O objetivo da camada 2 é, em cada regra, compor os relacionamentos lógicos entre os termos linguísticos ativados de cada variável de entrada visando determinar o grau de ativação da própria regra $\{\omega_i\}$, também chamado de peso da regra. Cada unidade ou nó presente nessa camada corresponde a uma regra. Em cada regra, um operador *T-norma* é usado para obter o seu nível de ativação. Neste cálculo, podem ser usados os operadores produto algébrico (Equação 43) e mínimo (Equação 40).

A camada 3 se dedica exclusivamente à normalização dos pesos das regras ativadas. A Equação 63 representa o cálculo de normalização realizado nessa camada.

$$\bar{\omega}_i = \frac{\omega_i}{\omega_1 + \dots + \omega_1 + \dots + \omega_n} \quad (63)$$


A camada 4 é composta por nós adaptativos que fornecem as contribuições advindas de cada regra por meio de um polinômio f_i , referente à parte conseqüente das regras de inferência (Figura 56), parametrizado usando os valores *crisp* das variáveis de entrada. Cada polinômio f_i pode ser constituído por uma função linear, configurando-se assim um sistema Takagi-Sugeno de ordem 1, ou por uma constante, constituindo-se como um sistema Takagi-Sugeno de ordem 0. A saída de cada nó na camada 4 é um produto simples entre o polinômio e o peso da regra ativada. Por último, a camada 5 realiza a agregação das saídas de cada nó da camada 4 por meio de uma soma ponderada, de acordo com a Equação 64, fornecendo a saída final do sistema (JANG, 1993).

$$f = \sum_{i=1}^n \bar{\omega}_i \cdot f_i \quad (64)$$

Para fornecer uma visão geral sobre o processo de inferência em um ANFIS, a Figura 57 ilustra um exemplo em que são usadas duas variáveis de entrada, cujo domínio

é particionado por funções de pertinência triangulares. A partir da apresentação dos valores numéricos x e y às variáveis de entrada, são ativadas as partições A_1 , A_2 , B_1 e B_2 na fuzificação, com diferentes graus de pertinência para cada uma. Os valores de ω_1 e ω_2 são dados pelas operações lógicas na parte antecedente das regras de inferência entre $\mu(x)_{A_1}$ e $\mu(y)_{B_1}$, e entre $\mu(x)_{A_2}$ e $\mu(y)_{B_2}$, respectivamente. A combinação das partições ativadas aciona duas regras de inferência, cujas saídas são f_1 e f_2 , que são ponderadas pelos valores de ω_1 e ω_2 , produzindo a saída final f .

Figura 57 – Representação do funcionamento de um sistema ANFIS



Fonte: Bilgehan (2011)

3.6.2 Treinamento de sistemas ANFIS

Similarmente às redes PMC, a eficiência do treinamento de um ANFIS é avaliada por meio de sua capacidade de generalizar resultados mediante a apresentação de amostras desconhecidas pelo sistema. Por isso, deve-se dividir o conjunto total de amostras em subconjunto de treinamento e subconjunto de teste, para que este último seja usado na avaliação da capacidade de generalização. O percentual de amostras recomendado para cada grupo também é similar às redes PMC, sendo cerca de 60 a 90% para o treinamento e de 10 a 40% para a validação da rede (TSOUKALAS; UHRIG, 2007).

Há diferentes métodos que podem ser usados para conduzir o treinamento de modelos ANFIS. O método de treinamento originalmente proposto por Jang (1993) consiste em um algoritmo híbrido que combina o procedimento de minimização do erro do algoritmo *backpropagation* (gradiente descendente) com o método dos mínimos

quadrados (*Least Mean Squares* - LMS), que também é usado no sistema de inferência proposto por Takagi e Sugeno (1985). Assim como o *backpropagation*, o método de treinamento supervisionado usado no ANFIS é dividido em duas etapas, denominadas *forward* (propagação adiante) e *backward* (propagação reversa).

Visando ao ajuste dos parâmetros adaptativos da rede, estes são divididos em dois grupos, denominados S_1 e S_2 . O grupo S_1 é composto pelos parâmetros das funções de pertinência usadas no particionamento das variáveis de entrada. S_2 é formado pelos coeficientes dos polinômios usados nos consequentes das regras de inferência (representados por a , b e c na Figura 57). Na etapa *forward*, o objetivo é ajustar os parâmetros S_2 usando o método dos mínimos quadrados. Para isso, fixam-se os valores iniciais dos parâmetros de S_1 , definidos com base no conhecimento dos especialistas ou por meio de um particionamento simétrico, enquanto são ajustados os parâmetros de S_2 . Para cada regra ativada pelos valores de entrada, deve-se selecionar na base de amostras um subconjunto de amostras (valores de entrada e saída) cujos valores ativam todos os termos da parte antecedente desta regra. Em seguida, deve-se realizar uma regressão linear entre as amostras selecionadas para determinar um vetor β que fornecerá os valores referentes aos parâmetros a , b e c da função linear do consequente da regra em questão. A Equação 65 fornece a solução do método LMS usando uma matriz de entrada X e um vetor de saída Y (JANG, 1993).

$$\beta = (X^T \cdot X)^{-1} \cdot X^T \cdot Y \quad (65)$$

Após o ajuste dos parâmetros dos consequentes das regras de inferência, a etapa *backward* é iniciada visando ao ajuste dos parâmetros de S_1 com base no erro produzido a partir da diferença entre os valores de saída gerados pela rede e os valores desejados para cada amostra. O ajuste dos parâmetros pode ser feito imediatamente após a apresentação de cada amostra (treinamento *online*) ou após a apresentação de todo o conjunto de amostras (treinamento *offline*). Assim como as conexões sinápticas das redes PMC, os parâmetros da função de pertinência das partições *fuzzy* de entrada (parâmetros de observação) são ajustados em função dos valores do erro, da taxa de aprendizagem (η) e dos valores de entrada apresentados ao sistema. Como esse ajuste depende da derivação da função de pertinência das partições, as variáveis de entrada devem utilizar funções de pertinência totalmente diferenciáveis (JANG, 1993). O procedimento matemático de

minimização do erro quadrático médio usando o gradiente descendente é similar àquele usado nas redes PMC, discutido na Subseção 3.4.1 deste capítulo.

Para sintetizar a sequência de operações e procedimentos requeridos pelos sistemas ANFIS, os Quadros 19 e 20 apresentam os passos algorítmicos referentes ao treinamento e ao uso destes sistemas. Nesse algoritmo, somente o número de épocas é utilizado como critério de parada do processo de treinamento supervisionado.

Quadro 19 - Passos algorítmicos da fase de treinamento de um ANFIS

Início

- <1> Obter o conjunto de amostras de treinamento $\{x(k)\}$;
 - <2> Associar a saída desejada $\{d(k)\}$ a cada amostra obtida;
 - <3> Especificar o valor de η e o número máximo de épocas de treinamento;
 - <4> Definir os parâmetros das partições de entrada usando julgamentos de especialistas ou particionando os universos de discurso simetricamente;
 - <5> Definir os parâmetros dos consequentes das regras de inferência como sendo zero;
 - <6> Para todas as amostras de treinamento $\{x(k)$ e $d(k)\}$, fazer:
 - <6.1> Fuzificar $x(k)$ para obter o grau de ativação dos termos linguísticos na camada 1;
 - <6.2> Obter o grau de ativação de cada regra de inferência na camada 2 $\{\omega_i\}$;
 - <6.3> Normalizar os pesos das regras ativadas para obter $\bar{\omega}_i$ (Equação 63);
 - <6.4> Ajustar os parâmetros dos consequentes das regras ativadas usando o método dos mínimos quadrados (Equação 65);
 - <6.5> Na camada 4, determinar a saída de cada regra de inferência ativada (f_i);
 - <6.6> Na camada 5, combinar as contribuições individuais de todas as regras ativadas a fim de se produzir uma resposta final (Equação 64);
 - <7> Repetir as instruções:
 - <7.1> $E_M^{anterior} \leftarrow E_M$;
 - <7.2> Para todas as amostras de treinamento $\{x(k)$ e $d(k)\}$, fazer:
 - <7.2.1> Obter um valor de saída $\{y(k)\}$ usando os parâmetros já ajustados (conforme <6.1>, <6.2>, <6.3>, <6.5> e <6.6>);
 - <7.2.2> Calcular o erro quadrático para cada nó adaptativo da camada 1 (Equação 13);
 - <7.2.3> Ajustar os parâmetros das partições de entrada usando o gradiente do erro e a taxa de aprendizagem;
 - <7.3> Calcular o erro quadrático médio (E_M);
 - <7.4> $E_M^{atual} \leftarrow E_M$;
 - <7.5> época \leftarrow época + 1;
- Até que época > número máximo de épocas;

Fim

Fonte: Proposto pelo autor.

Quadro 20 - Passos algorítmicos da fase de uso de um ANFIS

<p>Início</p> <p><1> Apresentar um conjunto de valores de entrada ao sistema;</p> <p><2> Fuzificar os valores de entrada na camada 1;</p> <p><3> Obter o grau de ativação de cada regra de inferência na camada 2;</p> <p><4> Normalizar os pesos das regras ativadas;</p> <p><5> Determinar a saída de cada regra de inferência ativada;</p> <p><6> Combinar as contribuições individuais de todas as regras ativadas a fim de se produzir uma resposta final;</p> <p><7> Apresentar os valores de saída.</p> <p>Fim</p>

Fonte: Proposto pelo autor.

Além do método de treinamento híbrido sintetizado no Quadro 19, Jang (1993) também sugere as seguintes abordagens para o ajuste dos parâmetros adaptativos de ANFIS:

- i. Usar somente o método gradiente descendente para atualizar todos os nós adaptativos do sistema;
- ii. Aplicar o método dos mínimos quadrados para definir os valores iniciais dos parâmetros dos consequentes e então usar o método do gradiente descendente para ajustar todos os parâmetros da rede;
- iii. Usar um método aproximado, baseado no método dos mínimos quadrados, que lineariza os parâmetros de premissa e usa o algoritmo filtro de Kalman para atualizar todos os parâmetros da rede.

Além dos métodos sugeridos por Jang (1993), outros métodos de treinamento para ANFIS vêm sendo propostos na literatura. Enquanto alguns métodos foram desenvolvidos especificamente para serem usados em sistemas *neuro-fuzzy*, outros são adaptados daqueles utilizados em redes neurais artificiais. Um exemplo é o algoritmo Levenberg-Marquardt, que foi usado por Bilgehan et al. (2011) em uma aplicação de ANFIS para a estimação de carga crítica. Embora já existam vários métodos de treinamento alternativos, o mais utilizado continua sendo o método híbrido proposto na versão original do ANFIS (KAR; DAS; GHOSH, 2014).

3.6.3 Modelagem de sistemas ANFIS

Na modelagem de sistemas ANFIS, a técnica de validação cruzada (discutida na seção 3.4.3) costuma ser adotada para definir a configuração topológica mais apropriada dentre um conjunto de topologias candidatas e escolher valores adequados para alguns

parâmetros. Os parâmetros ótimos a serem escolhidos por meio da avaliação das topologias candidatas geralmente incluem a forma das partições *fuzzy* das variáveis, os valores dos parâmetros usados no treinamento do sistema e o(s) critério(s) de parada. A aplicação da técnica de validação cruzada também pode ajudar a escolher um operador t-norma apropriado, testar diferentes alternativas de algoritmo de treinamento, bem como avaliar o desempenho de topologias candidatas contendo um número reduzido de regras de inferência. O Quadro 21 sintetiza as definições a serem feitas na fase de modelagem de um ANFIS.

Quadro 21 - Aspectos a serem definidos na modelagem de sistemas ANFIS

Aspectos a serem definidos	Função	Recomendações
Número de partições <i>fuzzy</i> usadas por cada variável	Definir a granularidade das variáveis <i>fuzzy</i> usadas	3 (EFENDIGIL, 2009; BILGEHAN, 2011; AKKOÇ, 2011)
Forma das funções de pertinência <i>fuzzy</i> (ou partições) das variáveis de entrada	Determinar a representação quantitativa e o comportamento das variáveis	Gaussiana (JANG, 1993; BILGEHAN, 2011; AKKOÇ, 2011) Triangular (JANG, 1993) Trapezoidal (JANG, 1993)
Valores iniciais das partições das variáveis de entrada	Determinar a representação quantitativa e o comportamento das variáveis	Dividir o universo de discurso da variável pelo número de partições adotadas e alocar uma partição a cada subespaço, gerando assim partições simétricas (WANG; WENDEL, 1992)
Valores iniciais dos coeficientes dos polinômios das regras de inferência	Define um ponto de partida para os coeficientes que serão ajustados durante o processo de treinamento	0 (Valor padrão da ferramenta <i>fuzzy toolbox</i> do MATLAB)
Operador dos conectivos lógicos da parte antecedente de cada regra	Realiza uma operação de agregação entre os graus de pertinência das partições ativadas na fuzificação	Produto algébrico (JANG, 1993; EFENDIGIL; ÖNUT; KAHRAMAN, 2009; GÜNERI; ERTAY; YÜCEL, 2011) Mínimo (JANG, 1993)
Operador de agregação das funções polinomiais dos consequentes	Agrega as contribuições individuais das regras ativadas em uma única saída	Média ponderada (JANG, 1993; EFENDIGIL; ÖNUT; KAHRAMAN, 2009;

Aspectos a serem definidos	Função	Recomendações
		GÜNERI; ERTAY; YÜCEL, 2011)
Taxa de aprendizagem do sistema (η)	Determina a rapidez com que a rede se aproximará do ponto de minimização da função erro	$0 < \eta < 1$ (SILVA; SPATI; FLAUZINO, 2010) $\eta = 0,1$ (JANG, 1993) $\eta = 0,01$ (Valor padrão da ferramenta <i>fuzzy toolbox</i> do MATLAB)
Precisão requerida (ε)	Mede a aproximação rumo a um ponto de mínimo da função erro e serve como critério de parada para o <i>backpropagation</i>	$\varepsilon = 0,0$ (GÜNERI; ERTAY; YÜCEL, 2011) $\varepsilon = 0,01$ (EFENDIGIL; ÖNÜT, KAHRAMAN, 2009) $\varepsilon = 0,00001$ (BILGEHAN, 2011)
Número máximo de épocas	Serve como critério de parada do algoritmo de treinamento quando não é possível alcançar a precisão requerida	500 (AKKOÇ, 2011) 200 (BILGEHAN et al., 2011) 40 (GÜNERI; ERTAY; YÜCEL, 2011)

Fonte: Proposto pelo autor.

Assim como na modelagem de redes neurais artificiais, a escolha dos valores (ou da configuração) dos parâmetros a serem avaliados é feita empiricamente e costuma ser apoiada pelo conhecimento de especialistas no domínio do problema e por sugestões apresentadas na literatura específica (JANG, 1993). Além do uso da validação cruzada para selecionar a melhor topologia candidata, uma avaliação da adequação das respostas do modelo desenvolvido também pode ser feita por meio da visualização tridimensional do comportamento da função que representa a variável de saída do modelo, traçada em função dos valores de duas variáveis de entrada. *Softwares* que contêm uma ferramenta específica para a modelagem de ANFIS, como o MATLAB® (*fuzzy toolbox*), costumam dispor de tal recurso.

Um ponto relevante na composição do subconjunto de treinamento é garantir que a distribuição dos dados usados seja representativa de todo o intervalo numérico das variáveis envolvidas. Desta forma, deve-se assegurar que os valores mínimos e máximos de todas as variáveis de entrada e de saída estão contidos dentro das amostras do subconjunto de treinamento (SILVA; SPATTI; FLAUZINO, 2010).

Durante a definição da quantidade de partições *fuzzy* para cada variável de entrada, é importante balancear a quantidade de partições usadas. Se muitas partições forem

adotadas, haverá um grande número de combinações possíveis entre elas e consequentemente o número de regras de inferência também será alto. Isso dificulta o treinamento do sistema, que passa a requerer maior quantidade de amostras para ajustar todas as regras. Para um ANFIS em que todas as variáveis de entrada são particionadas usando a mesma quantidade de termos linguísticos, a quantidade de regras de inferência q é dada pela Equação 66, em que i é o número de variáveis de entrada e p é o número de partições adotadas (SRINIVASAN; MALLIGA, 2010). Analisando essa equação, nota-se que a adoção de uma quantidade reduzida de variáveis de entrada também contribui para minimizar a quantidade de regras de inferência do sistema. Ao adotar uma quantidade moderada de variáveis de entrada e de partições *fuzzy*, uma quantidade menor de amostras será requerida para treinamento do sistema, já que o tamanho do subconjunto de treinamento deve ser sempre maior que o número de parâmetros adaptativos contidos no sistema (GÜNERI; ERTAY; YÜCEL, 2011).

$$q = p^i \quad (66)$$

Para definir o intervalo das partições *fuzzy* das variáveis, Wang e Wendel (1992) sugerem que seja usado o conhecimento de especialistas e, quando este não estiver disponível, os valores iniciais podem ser obtidos dividindo simetricamente o universo de discurso da variável pelo número de termos linguísticos adotados. Ressalta-se que, estes valores serão melhorados posteriormente durante o treinamento. Embora esse procedimento tenha sido proposto originalmente para sistemas de inferência da arquitetura de Takagi e Sugeno (1985), sua simplicidade e bom desempenho contribuem para que este seja adotado também na modelagem de sistemas ANFIS.

Outro procedimento requerido pelos sistemas ANFIS consiste na normalização dos valores das amostras apresentadas ao sistema durante as fases de treinamento, validação e uso. A técnica de normalização mais usada nesses casos é a mesma apresentada na Figura 43 da Subseção 3.4.3, a qual mantém a proporção entre os valores após a normalização. A normalização dos dados de cada variável deve considerar o universo de discurso em que esta foi definida. Por questões de simplificação, costuma-se definir as variáveis *fuzzy* no intervalo $[0, 1]$ (SILVA; SPATTI; FLAUZINO, 2010).

Por último, ressalta-se que, assim como as redes PMC, o ANFIS pode utilizar como critério de parada do treinamento um valor de precisão (ou tolerância) requerida (ϵ), especificado pelo desenvolvedor, e / ou um número de épocas máximo. O

estabelecimento de número máximo de épocas como critério de parada evita que o sistema consuma muito tempo no processo de convergência e diminui a probabilidade de ocorrência de *overfitting* (SILVA; SPATTI; FLAUZINO, 2010). Caso não seja conhecido um valor de precisão requerida para a aplicação em questão, o valor de ε deve ser configurado como zero. Desta forma, se esse valor de precisão não puder ser alcançado, o treinamento se encerrará quando este atingir o valor especificado para o número de épocas (GÜNERI; ERTAY; YÜCEL, 2011).

Sintetizando as recomendações apresentadas nesta subseção, conclui-se que durante o processo de modelagem de um sistema ANFIS é necessário:

- i. Aplicar a técnica de validação cruzada para escolher a configuração de sistema mais adequada;
- ii. Escolher valores apropriados para os parâmetros taxa de aprendizagem (η) e número de épocas de treinamento;
- iii. Definir o número de partições *fuzzy* de cada variável, bem como a forma e os valores de cada função de pertinência;
- iv. Normalizar os valores de todas as amostras utilizadas nas etapas de treinamento, teste e de operação;
- v. Incluir no subconjunto de treinamento todas as amostras que contenham os valores mínimos e máximos das variáveis de entrada e de saída.

3.6.4 Limitações de sistemas ANFIS

Embora os sistemas ANFIS apresentem vantagens provenientes tanto das redes neurais quanto dos sistemas de inferência *fuzzy*, tais sistemas também combinam algumas limitações que derivam destes métodos. Uma limitação relacionada à estrutura do sistema do ANFIS original é o fato de possuir apenas uma variável de saída, cujas funções de pertinência devem ser do mesmo tipo (linear ou constante). Ainda que a maioria das aplicações relatadas na literatura apresente apenas uma variável de saída, há situações que podem requerer dois ou mais nós na camada de saída, como em problemas de classificação de padrões com mais de duas classes. Atualmente já existem versões estendidas do ANFIS, como o MANFIS (*Multi output Adaptive Neuro-Fuzzy Inference System*), que permite a utilização de mais de um nó na camada de saída da rede, superando assim essa limitação (ROLIM et al., 2012).

Apesar dos sistemas ANFIS possuírem a vantagem de modelar o conhecimento a respeito de um problema por meio da estruturação em regras de inferência *fuzzy* e assim

proverem uma melhor interpretabilidade que as redes neurais artificiais, uma crítica frequente aos sistemas neuro-*fuzzy* se deve justamente à perda de interpretabilidade após o final do treinamento da rede. Como os parâmetros das funções de pertinência das variáveis são ajustados visando à minimização do erro quadrático médio, a forma das funções de pertinência resultantes podem não transmitir um sentido semântico quando comparado com a configuração inicial das partições, fazendo com que o conhecimento embutido no sistema seja difícil de entender (REZENDE, 2003; PAIVA; DOURADO, 2004).

Por último, os sistemas ANFIS também são criticados pelo seu método de treinamento híbrido. Como esse tipo de sistema geralmente possui três parâmetros adaptativos em cada partição *fuzzy* usada em cada variável de entrada e mais alguns parâmetros adaptativos dos consequentes das regras de inferência, a complexidade computacional do treinamento pode ser alta, contribuindo para o aumento do tempo consumido em cada época de treinamento. Além disso, embora o uso do método dos mínimos quadrados permita encontrar valores ótimos para os parâmetros dos consequentes das regras de inferência, o uso do *backpropagation* na minimização da função erro quadrático não garante o alcance de um ponto de mínimo global. Embora não haja garantias de que o uso de algoritmos alternativos para o treinamento de sistemas ANFIS evite a convergência em mínimos locais, a adoção de outros métodos de treinamento pode tornar o processo de aprendizagem mais rápido (BILGEHAN et al., 2011).

3.7 ESTUDOS COMPARATIVOS ENTRE REDES PMC E ANFIS

O Quadro 22 apresenta uma listagem de todos os estudos comparativos entre redes perceptron de múltiplas camadas (PMC) e sistemas ANFIS encontrados na literatura. A principal finalidade da realização desse tipo de estudo é avaliar qual das técnicas avaliadas se mostra mais adequada para determinados domínios de problema. Como pode ser visto, há poucos estudos considerando problemas da área de gestão de operações. O único estudo comparativo relacionado à gestão de cadeia de suprimento considerou um contexto de problema de previsão de demanda (EFENDIGIL; ÖNUT; KAHRAMAN, 2009), não havendo assim estudos deste tipo no contexto de predição de desempenho.

Quadro 22 – Estudos comparativos envolvendo redes PMC e sistemas ANFIS

Proposto por	Técnicas comparadas	Domínio de problema	Parâmetros de comparação	Melhor desempenho
Akkoç (2012)	PMC, ANFIS, análise discriminante linear e regressão logística	Análise de pontuação de crédito em uma empresa de cartão de crédito	Índice de precisão média	ANFIS
Areerachakul (2012)	ANFIS e PMC	Estimativa de DBO (demanda bioquímica de oxigênio) na superfície da água	R e RMSE	PMC
Ay e Kisi (2014)	PMC, ANFIS, regressão multilinear, redes de função de base radial – RBF e <i>k-means</i> integrado com PMC.	Avaliação da qualidade de água (modelagem de DBO)	RMSE, MAE e R ²	PMC
Bilgehan (2011)	ANFIS e PMC	Estimativa de carga crítica em elementos estruturais	RMSE, MBE e R ²	ANFIS
Efendigil, Önut e Kahraman (2009)	ANFIS e PMC	Suporte à decisão para previsão de demanda em cadeias de suprimento	MAPE	ANFIS
Göktepe, Agar e Lav (2004)	ANFIS e PMC	Predição de propriedades mecânicas de pavimentos flexíveis	R ²	PMC
Khoshnevisan et al. (2014)	ANFIS e PMC	Predição do rendimento de grãos de trigo com base em entradas de energia	R ² , RMSE e MAPE	ANFIS
Özkan e Inal (2014)	ANFIS e PMC	Tomada de decisão multicritério para seleção de fornecedores	RMSE, MAE e R ²	ANFIS

Fonte: Proposto pelo autor.

Por meio da análise dos estudos mostrados no Quadro 22, foram observadas algumas características comuns que ajudaram a embasar o desenvolvimento da presente pesquisa, sendo elas:

- i. Todos os estudos encontrados realizam uma aplicação real ou simulada das técnicas a serem comparadas considerando o contexto de um problema específico;
- ii. Na maioria deles, um conjunto de testes é feito para avaliar diferentes configurações paramétricas para cada sistema (topologias candidatas) e selecionar a melhor;

- iii. O desempenho das técnicas é avaliado por meio de parâmetros quantitativos relacionados à sua capacidade de generalização;
- iv. Parâmetros estatísticos como o índice de correlação (R^2), erro de percentagem média absoluta (*Mean Absolute Percentage Error* – MAPE), erro médio quadrático (*Root Mean Square Error* – RMES), erro médio absoluto (*Mean Absolute Error* – MAE) e erro de desvio médio (*Mean Bias Error* – MBE) são utilizados para comparar os resultados e eleger qual é o melhor método.

Outra constatação feita a partir dos dados do Quadro 17 é que enquanto as redes PMC apresentam melhor capacidade de generalização em alguns problemas, os sistemas ANFIS as superam em outros. Conforme evidencia os resultados desses estudos comparativos, a adequação e a capacidade de generalização de cada técnica variam conforme as características do problema modelado. Neste sentido, considerando o potencial que as redes PMC e os sistemas ANFIS possuem para apoiar a predição de desempenho de cadeias de suprimento usando os indicadores do SCOR[®], o desenvolvimento de modelos para esta finalidade faz necessário um novo estudo para avaliar a adequabilidade de ambas as técnicas quando aplicadas neste domínio de problema. Seguindo a abordagem metodológica dos estudos comparativos existentes, o capítulo a seguir foca na construção e na aplicação dos sistemas de predição de desempenho usando as técnicas de inteligência computacional avaliadas neste estudo.

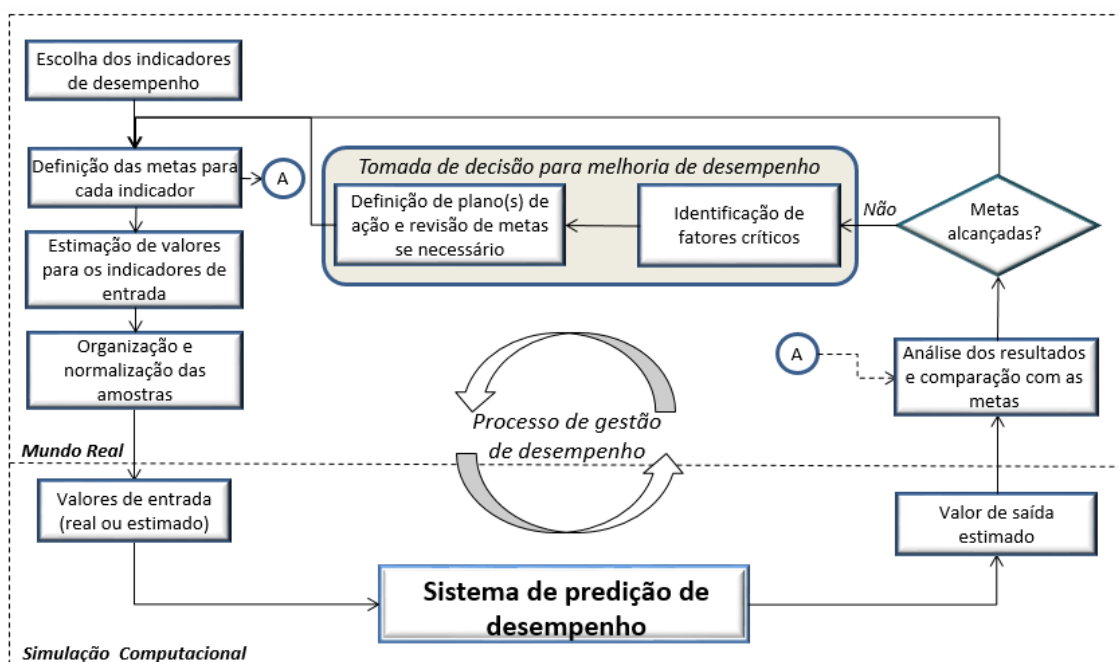
Capítulo 4

MODELOS PROPOSTOS PARA PREDIÇÃO DE DESEMPENHO

4.1 APRESENTAÇÃO DO MODELO TEÓRICO

O modelo teórico proposto foi desenvolvido com base em Unahabhokha, Platts e Tan (2007), De Waal (2007), Ganga e Carpinetti (2011) e SCC (2012). Conforme ilustra a Figura 58, o modelo visa dar suporte à gestão de desempenho de uma empresa-foco e de sua(s) cadeia(s) de suprimento imediata por meio de um conjunto de ações de planejamento, controle e melhoria das atividades organizacionais, que são apoiadas pelo uso de um sistema de predição de desempenho. Esse sistema de predição é composto por sete sistemas computacionais que são aplicados ao longo dos níveis 1 e 2 da hierarquia de indicadores de desempenho do modelo SCOR®.

Figura 58 - Modelo proposto para apoiar a predição de desempenho de cadeias de suprimento



Fonte: Proposto pelo autor.

Para conduzir o processo de gestão de desempenho ilustrado na Figura 58, primeiramente é necessário traduzir os objetivos estratégicos de desempenho em planos de ação tangíveis e de curto prazo para cada unidade de negócio. Caso a empresa ainda não possua um sistema de avaliação de desempenho implantado, é necessário fazer a escolha de um conjunto de indicadores de desempenho do SCOR® que estejam alinhados com seus objetivos de desempenho. Como na prática a empresa-foco precisa desenvolver

e implementar mecanismos para coletar dados e medir cada um dos indicadores adotados, o uso de indicadores que excedem as necessidades da cadeia imediata pode consumir muito tempo dos funcionários da empresa e requerer investimentos financeiros consideráveis, o que tende a dificultar ou até mesmo inviabilizar o processo de avaliação destes indicadores. Neste sentido, conforme sugerido pelo próprio modelo SCOR[®], a empresa-foco deve priorizar a seleção dos indicadores de desempenho que são críticos para seus processos de gestão, ou seja, aqueles indicadores que precisam ser controlados porque impactam fortemente sobre o desempenho global, ou porque seus resultados se apresentam abaixo do esperado e precisam ser melhorados prioritariamente. O modelo SCOR[®] recomenda que seja adotado ao menos um indicador para cada atributo de desempenho, a fim de garantir assim que os processos de tomada de decisão envolvendo a cadeia sejam balanceados (SCC, 2012).

Após a escolha dos indicadores, é necessário definir metas de desempenho para cada indicador. Os valores dessas metas traduzem o "desempenho desejado pela organização". Para tornar possível a adaptação do sistema de predição de desempenho ao ambiente de uso, a empresa-foco da cadeia deve desenvolver procedimentos e / ou sistemas para coletar ou estimar os valores numéricos das amostras dos indicadores adotados. O SCOR[®] (SCC, 2012) ressalta que os dados necessários para avaliação de alguns indicadores do nível 2, como *accounts payable* e *accounts receivable*, já são capturados por outros sistemas tradicionais da organizacional. Contudo, a quantificação do desempenho da maioria dos indicadores é feita com base em estimativas e dados de eventos históricos.

Após a obtenção dos dados, estes devem ser tabulados considerando as variáveis de entrada e saída de cada sistema computacional. Recomenda-se que 70 a 90% do conjunto total de amostras (dados de desempenho) seja usado no treinamento dos modelos computacionais e o restante seja aplicado em experimentos de predição para validação dos mesmos. Os valores das variáveis de entrada e saída dos modelos computacionais devem estar distribuídos no intervalo [0,1]. Para normalizar os dados de cada uma das variáveis das amostras (x_i), a Equação 67 deve ser utilizada.

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (67)$$

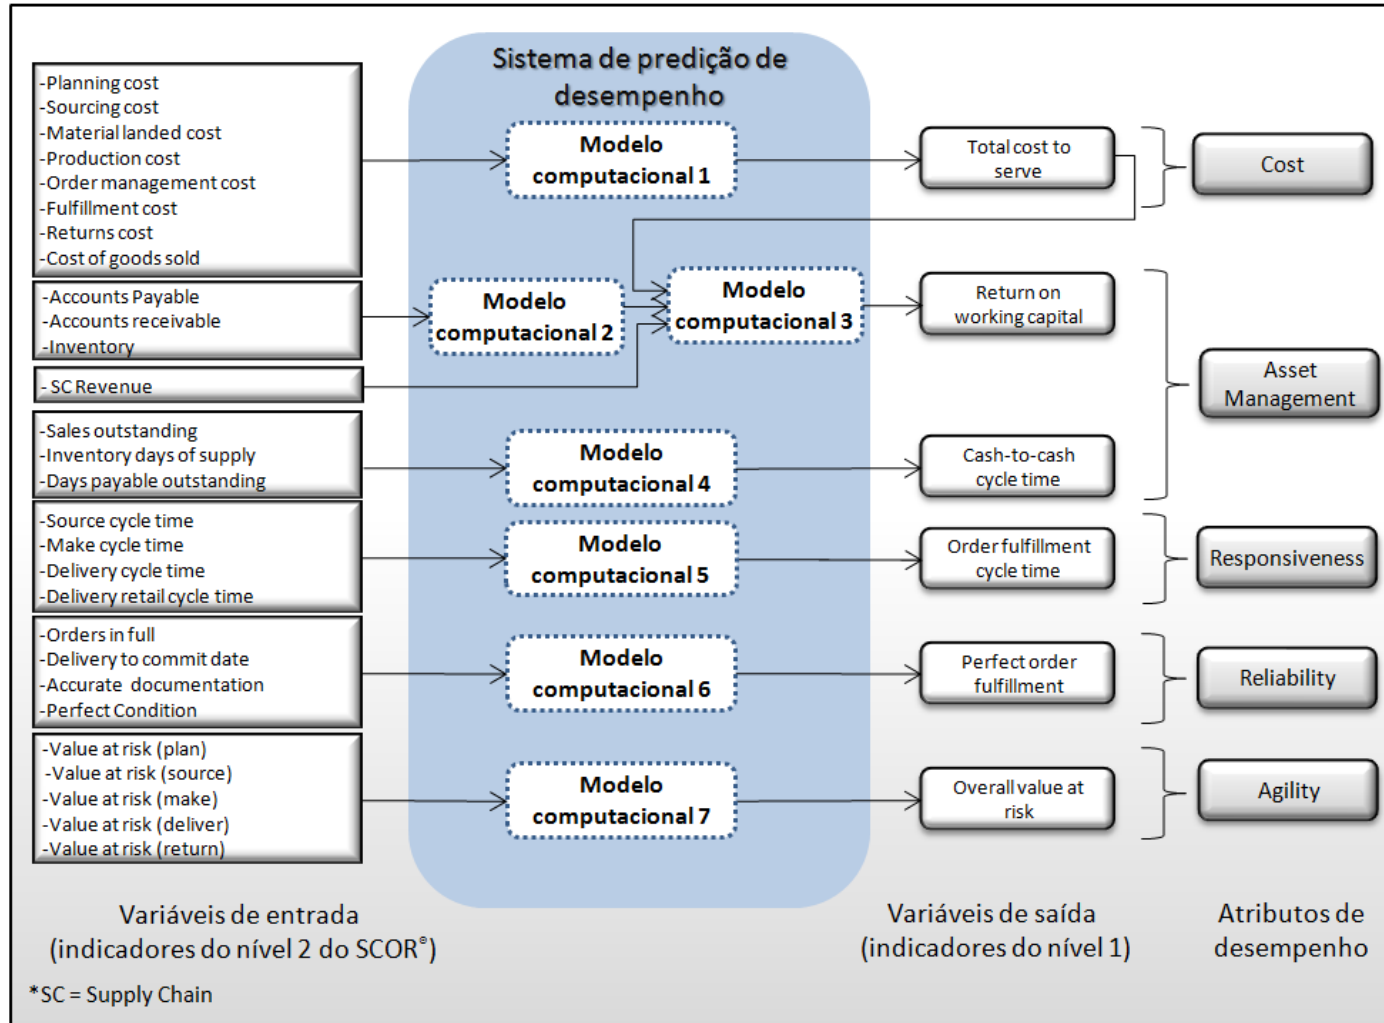
Durante e após a execução das atividades previstas nos planos de ação usados na gestão dos processos de negócio, os gestores devem garantir que os resultados de

desempenho sejam registrados para servirem como base para estimativa dos valores de entrada do sistema de predição de desempenho. Os dados gerados pelo sistema de predição devem ser usados na elaboração de relatórios a fim de fornecer aos gestores um *feedback* sobre os planos de ação implementados. A partir de uma análise minuciosa dos resultados de indicadores financeiros e não financeiros, seguida por uma comparação com as metas estabelecidas, o gestor deve identificar quais são as áreas que estão necessitando de melhoria ou de ações corretivas.

Posteriormente, um *feedback* deve ser fornecido aos funcionários sobre os resultados alcançados, relatando quais metas foram alcançadas e discutindo quais ajustes são necessários nos planos de ação para superar a lacuna existente entre o desempenho previsto e o desempenho desejado. Para isso, reuniões periódicas devem ser realizadas com superiores e subordinados visando ao levantamento das causas dos resultados do desempenho abaixo do esperado e o desenvolvimento de soluções. A realização de reuniões também poderá ajudar a identificar fraquezas do negócio e melhorar a transparência e a visibilidade do negócio. Todas as informações relevantes geradas durante as reuniões devem ser registradas para análise e para o aprendizado futuro. A predição dos valores dos indicadores de nível 1 e a revisão dos planos de ação elaborados deve ser feita ao menos mensalmente (DE WAAL, 2007). Caso a revisão dos planos de ação não conduza a resultados satisfatórios por um período de quatro meses, recomenda-se uma reavaliação das metas estabelecidas para cada indicador e das estratégias adotadas pela cadeia imediata (DE WAAL, 2007).

Em relação à arquitetura do sistema de predição de desempenho proposto, a Figura 59 representa as variáveis de entrada e saída utilizadas pelos modelos computacionais. Cada um dos modelos computacionais tem o papel de modelar quantitativamente os relacionamentos de causa e efeito entre os indicadores do nível 2 (variáveis de entrada) e os indicadores do nível 1 (variáveis de saída). Neste sentido, no sistema de predição proposto, foram incluídos somente os indicadores de nível 1 que podem ser calculados usando fórmulas objetivas, englobando assim seis dentre os dez indicadores de nível 1 do SCOR®. O Quadro 23 descreve as variáveis de entrada (x_i) e saída (y) de cada modelo computacional e a respectiva unidade de medida, definida conforme o SCOR® (SCC, 2012). Uma descrição mais detalhada dos indicadores de desempenho usados neste estudo é apresentada no Apêndice A.

Figura 59 - Arquitetura do sistema de predição de desempenho



Fonte: Proposto pelo autor.

Quadro 23 – Detalhamento das variáveis de entrada e saída do sistema de predição de desempenho

Variáveis		Descrição	Unidade de medida
Modelo 1	x1	Sourcing cost: o custo total associado com o gerenciamento de pedidos, recebimento, inspeção e armazenagem de produtos, mercadorias e serviços.	Unid. monetária ou percentual de <i>total cost to serve</i>
	x2	Planning cost: o custo total de pessoal, automação, patrimônio e despesas gerais associadas aos processos de planejamento.	Unid. monetária ou percentual de <i>total cost to serve</i>
	x3	Material landed cost: o custo total associado com a aquisição de componentes e produtos e sua disponibilização no local de uso.	Unid. monetária ou percentual de <i>total cost to serve</i>
	x4	Production cost: o custo total associado com o gerenciamento e execução dos processos de produção (separação de materiais, montagem, testes, embalagem, movimentação e disposição).	Unid. monetária ou percentual de <i>total cost to serve</i>
	x5	Order management cost: o custo total de pessoal, automação e patrimônio para responder perguntas e cotações, dar entrada, manter, rastrear e faturar pedidos.	Unid. monetária ou percentual de <i>total cost to serve</i>
	x6	Fullfilment cost: o custo total de pessoal, automação, patrimônio e despesas gerais associado com o cumprimento de pedidos, incluindo custos com manuseio físico de produtos.	Unid. monetária ou percentual de <i>total cost to serve</i>
	x7	Returns cost: o custo total de disposição de materiais retornados devido a erros de planejamento, problemas na qualidade do fornecedor, na entrega ou produção.	Unid. monetária ou percentual de <i>total cost to serve</i>
	x8	Cost of goods sold: o custo de materiais diretos, mão de obra e despesas gerais associadas com a aquisição ou produção de produtos acabados.	Unid. monetária ou percentual de <i>total cost to serve</i>
	y	Total cost to serve: refere-se à soma dos custos diretos e indiretos da cadeia para entregar produtos e serviços aos clientes.	Unidade monetária
Modelo 2	x1	Inventory: refere-se à quantidade de estoque expressa em dólares.	Unidade monetária
	x2	Accounts receivable: consiste no montante de contas a receber expresso em dólares.	Unidade monetária
	x3	Accounts Payable: o montante adquirido de materiais e mão de obra que estão para ser pagos (contas a pagar).	Unidade monetária
	y	Quantifica o denominador usado no cálculo do indicador <i>return on working capital</i> no PMC 3.	Unidade monetária
M o	x1	Variável de saída (y) do PMC 2.	Unidade monetária

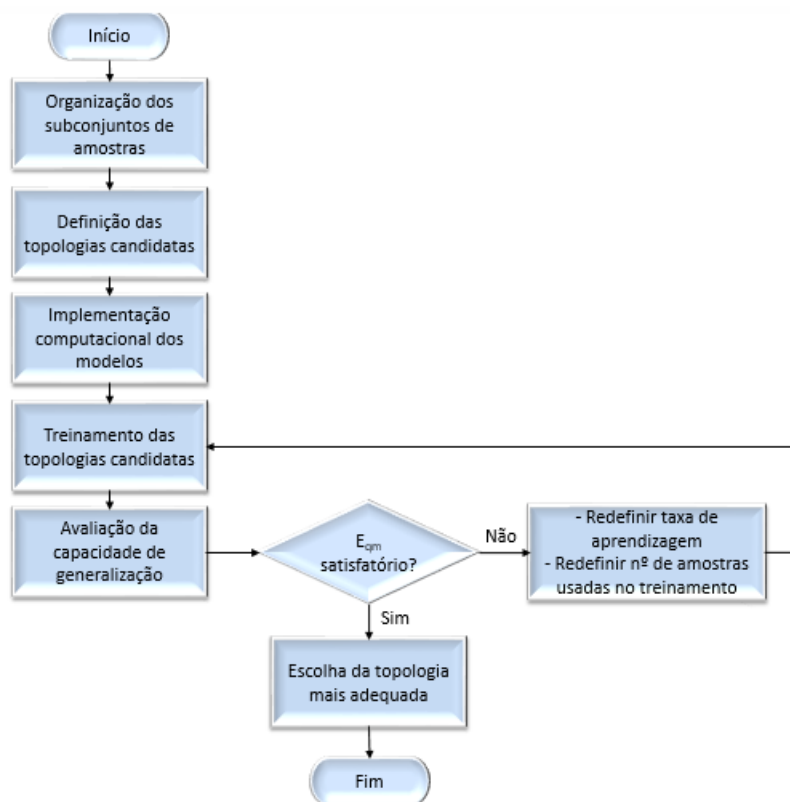
Variáveis		Descrição	Unidade de medida
	x ₂	Supply chain revenue: é a receita gerada pela operação da cadeia de suprimento, não incluindo receita não operacional, como investimentos e vendas de prédios de escritório.	Unidade monetária
	x ₃	Total cost to serve: é o indicador de saída do PMC 1.	Unidade monetária
	y	Return on working capital: quantifica o retorno obtido a partir do investimento de capital em patrimônio(s) fixo(s).	Adimensional
Modelo 4	x ₁	Days sales outstanding: o tempo decorrido entre a data de venda e o recebimento do pagamento dos clientes.	Dias
	x ₂	Inventory days of supply: a quantidade de inventário expressa em dias de vendas (por exemplo, se são vendidos 2 itens por dia e há 20 itens em estoque, x_2 equivalerá a $20/2=10$ dias de vendas).	Dias
	x ₃	Days payable outstanding: o tempo decorrido entre a compra de materiais, mão de obra e/ou conversão de recursos até o pagamento (período médio de pagamento).	Dias
	y	Cash-to-cash cycle time: o tempo gasto para um investimento retornar para a empresa (ex. tempo decorrido entre a compra de matéria-prima para cumprir um pedido e o recebimento do pagamento deste).	Adimensional
Modelo 5	x ₁	Source cycle time: É a soma do tempo despendido para identificar fontes de suprimento, selecionar o fornecedor, efetuar negociação, programar entregas, receber produto, verificar, transferir produto e autorizar pagamento ao fornecedor .	Dias
	x ₂	Make cycle time: É a soma do tempo despendido na finalização da engenharia de manufatura, programação de atividades da produção, descarga de material, produção, teste, empacotamento e liberação do produto acabado.	Dias
	x ₃	Delivery cycle time: Considera o tempo de ciclo de determinação da data de entrega, o tempo de ciclo de consolição do pedido, de programação da instalação, de montagem de carga, de definição de rota, de selecionar transportadora e taxar carga, de recebimento do produto, de separação do produto, de empacotamento, de geração da documentação de embarque e carregamento de veículo, de tempo do produto a bordo, de receber e verificar o produto, de instalar o produto.	Dias
	x ₄	Delivey retail cycle time: O tempo de ciclo médio despendido na aquisição, negociação e venda de produtos aos varejistas.	Dias
	y	Order fulfillment cycle time: Refere-se ao tempo de ciclo médio consumido para atender os pedidos dos clientes. Para cada pedido individual, o ciclo se inicia desde o recebimento do pedido e finaliza com a aceitação do pedido pelo cliente.	Dias

Variáveis		Descrição	Unidade de medida
Modelo 6	x1	Orders delivered in full: avalia se todos os itens do pedido forem entregues nas quantidades especificadas pelo cliente.	Adimensional
	x2	Delivery performance to customer commit date: avalia se o pedido foi entregue na data combinada com o cliente e no local correto.	Adimensional
	x3	Documentation accuracy: avalia a documentação do pedido em relação à precisão e atualização dos dados. Para o pedido ser considerado perfeito neste indicador, o cliente deve estar de acordo com a documentação de embarque, de pagamento, de conformidade e com qualquer outra documentação requerida;	Adimensional
	x4	Perfect condition: Avalia se o pedido foi entregue em condições perfeitas, ou seja, sem danos, atendendo às especificações, instalado corretamente e sem retorno para reparos ou substituições dentro do período de garantia.	Adimensional
	y	Perfect order fulfillment: refere-se ao percentual de pedidos que tenham sido entregues na data combinada pelo cliente, sem danos e com documentação completa e precisa.	Adimensional
Modelo 7	x1	Value at risk (plan): VAR é um indicador mede a exposição de uma organização a eventos de risco em uma cadeia de suprimento. Um evento de risco se refere a qualquer falha de processo ou ruptura que pode impactar negativamente no custo e no desempenho da cadeia. O indicador “ <i>value at risk (plan)</i> ” refere-se à soma dos riscos monetizados relacionados ao processo “ <i>plan</i> ”.	Unidade monetária
	x2	Value at risk (source): é a soma dos riscos monetizados relacionados ao processo “ <i>source</i> ”.	Unidade monetária
	x3	Value at risk (make): é a soma dos riscos monetizados relacionados ao processo “ <i>make</i> ”.	Unidade monetária
	x4	Value at risk (deliver): é a soma dos riscos monetizados relacionados ao processo “ <i>deliver</i> ”.	Unidade monetária
	x5	Value at risk (return): é a soma dos riscos monetizados relacionados ao processo “ <i>return</i> ”.	Unidade monetária
	y	Overall value at risk: consiste na soma das probabilidades de eventos de risco que podem impactar nos processos da cadeia (<i>plan, source, make, deliver and return</i>) multiplicada pelo impacto monetário desses eventos.	Unidade monetária

Fonte: Proposto pelo autor.

Com o propósito de se obter um conjunto de modelos computacionais com uma maior capacidade de predição de desempenho, deve-se utilizar a técnica de validação cruzada para orientar a modelagem e a implementação computacional do sistema de predição de desempenho. Conforme discutido anteriormente, o uso dessa abordagem auxilia na determinação de uma configuração topológica adequada para cada modelo computacional e também ajuda a escolher um conjunto de valores adequados para os parâmetros de cada sistema (WANG; LI; LI, 2015; WONG, 2015). A Figura 60 sugere um esquema de aplicação da técnica de validação cruzada para apoiar a modelagem e a implementação computacional das redes PMC. Essa sequência de etapas foi proposta a partir de Silva, Spatti e Flauzinho (2010). Contudo, as ações a serem tomadas caso o valor do E_{qm} não seja satisfatório, foram sugeridas com base exclusivamente nos resultados obtidos ao longo das centenas de treinamentos e dos diversos testes empíricos realizados durante a execução desta pesquisa.

Figura 60 – Etapas de aplicação da técnica de validação cruzada na modelagem das redes PMC



Fonte: Proposto pelo autor.

Conforme a sequência ilustrada na Figura 60, para aplicar a técnica de validação cruzada na modelagem de redes PMC, deve-se inicialmente obter um conjunto de amostras representativas dos valores de desempenho dos indicadores de cada sistema de predição, normalizá-los (usando a Equação 67) e dispô-los conforme os padrões do

software usado para o treinamento. Além disso, o conjunto total de amostras deve ser subdividido nos subconjuntos de treinamento, de teste e de validação. Neste estudo, baseando-se nas configurações padrões usadas pelo *software* MATLAB (MATHWORKS, 2015), utilizou-se 70% das amostras para treinamento, 15% para teste e 15% para validação.

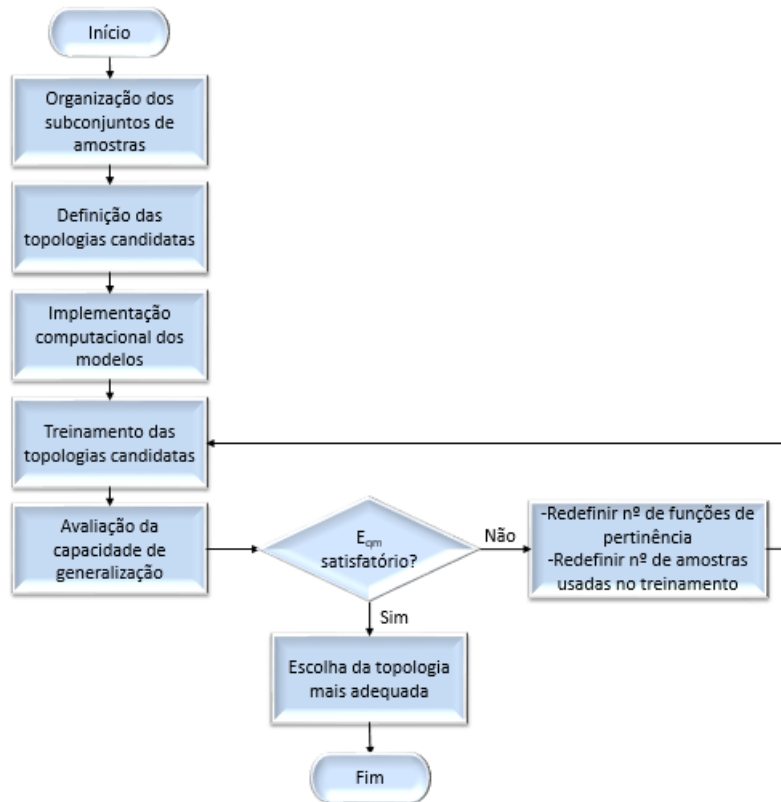
Após a organização das amostras, define-se um conjunto de topologias candidatas a partir da variação na quantidade de neurônios da camada intermediária e do tipo de função de ativação de cada modelo. Posteriormente, deve-se construir os modelos computacionais e realizar um ou mais treinamentos para cada topologia candidata. Ressalta-se que, para a realização desta etapa, é necessário especificar um ou mais critérios de parada para o processo de treinamento, tais como o número máximo de épocas e a tolerância requerida.

Ao final de cada treinamento, a partir da apresentação dos valores de entrada do subconjunto de validação, deve-se avaliar a capacidade de generalização de cada topologia candidata por meio do erro quadrático médio, calculado a partir da comparação entre os valores de saída desejados (presentes no subconjunto de validação) e os valores de saída estimados pelo modelo computacional. Se uma ou mais topologias candidatas apresentar um valor de E_{qm} que atenda ao nível de tolerância requerido (1×10^{-3}), escolhe-se então a configuração topológica mais adequada, ou seja, aquela com menor valor de E_{qm} . Caso contrário, recomenda-se testar valores diferentes para a taxa de aprendizagem e reiniciar o processo de treinamento. Se ainda assim não for possível a obtenção de um valor satisfatório para o E_{qm} na etapa de validação, recomenda-se o aumento do número de amostras utilizadas no subconjunto de treinamento.

Conforme ilustra a Figura 61, o esquema de aplicação da técnica de validação cruzada sugerido para apoiar o desenvolvimento dos sistemas de predição de desempenho baseados em ANFIS é bastante similar àquele apresentado na Figura 60. Novamente, a sequência das etapas foi proposta com base em Silva, Spatti e Flauzinho (2010) e as ações a serem tomadas caso o valor do E_{qm} não seja satisfatório foram sugeridas segundo os resultados dos testes realizados. A única diferença está nas ações a serem tomadas caso o valor do E_{qm} não seja satisfatório. Nesse caso, quando nenhuma das topologias candidatas alcançar o nível de precisão requerido durante a etapa de validação, recomenda-se aumentar ou diminuir o número de funções de pertinência usadas pelas variáveis de entrada. Se a variação na quantidade de funções de pertinência não contribuir para a

obtenção de um erro satisfatório, recomenda-se o aumento da quantidade de amostras usadas no treinamento.

Figura 61 – Etapas de aplicação da técnica de validação cruzada na modelagem dos sistemas ANFIS



Fonte: Proposto pelo autor.

4.2 IMPLEMENTAÇÃO COMPUTACIONAL DOS MODELOS BASEADOS EM REDES PMC

4.2.1 Organização das amostras

Conforme descrito na Subseção 1.6 do Capítulo 1, para as variáveis de entrada, os valores das amostras foram gerados de forma aleatória e definidos dentro de um universo de discurso normalizado entre 0 e 1 (conforme a Equação 67). No caso das variáveis de saída de cada amostra, os valores foram calculados conforme as fórmulas sugeridas pelo modelo SCOR[®] para cada indicador de nível 1, mostradas no Apêndice A. Para assegurar a adequação da disposição dos dados dentro do espaço amostral de cada variável, alguns gráficos de dispersão foram elaborados para melhor visualizar a distribuição das amostras a serem usadas em cada um dos modelos computacionais.

Em relação à determinação da quantidade de amostras a serem usadas no treinamento de cada modelo computacional, com base em Apichottanakul, Pathmnakul e Piewthongngam (2012), definiu-se inicialmente que esse valor seria equivalente a quatro

vezes o número de conexões sinápticas existentes em cada modelo. Contudo, a partir da realização de vários testes empíricos, percebeu-se que tal quantidade de amostras não seria suficiente para ajustar as redes. Neste sentido, a quantidade de amostras de treinamento foi aumentada gradativamente durante os processos de treinamento, até que fossem alcançados resultados satisfatórios. A Tabela 1 especifica a quantidade total de amostras utilizada para cada modelo, destacando também o número de amostras componentes dos subconjuntos de treinamento, validação e teste. O conjunto total de amostras foi dividido de modo a atribuir 70% dos dados ao subconjunto de treinamento, 15% para o subconjunto de validação e 15% para o subconjunto de teste. Enquanto o subconjunto de teste é usado para avaliar a capacidade de generalização da rede após o fim do treinamento, o subconjunto de validação é usado somente para verificar se o erro quadrático médio está decrescendo de fato ao longo das épocas de treinamento. Na literatura analisada não foi encontrada nenhuma referência sobre esse tipo de verificação.

Tabela 1 – Quantidade de amostras utilizadas nos modelos de predição PMC

Modelo	Conjunto total	Subconjunto de treinamento	Subconjunto de validação	Subconjunto de teste
PMC 1	1000	700	150	150
PMC 2	500	350	75	75
PMC 3	500	350	75	75
PMC 4	500	350	75	75
PMC 5	500	350	75	75
PMC 6	300	210	45	45
PMC 7	500	350	75	75

Fonte: Proposto pelo autor.

4.2.2 Definição das topologias candidatas aos modelos PMC

Conforme mostra o Quadro 24, nesta pesquisa foram construídas e avaliadas 10 alternativas de configuração topológica para cada modelo PMC, totalizando 70 modelos de redes neurais artificiais. A configuração das topologias de rede foi definida conforme as características do problema de predição de desempenho abordado neste estudo. Como cada modelo computacional tem o papel de prever os valores de apenas um indicador de desempenho, todas as topologias candidatas possuem apenas um neurônio na camada de saída. Uma vez que uma topologia constituída de apenas uma camada intermediária é capaz de mapear qualquer função contínua no espaço das funções reais, todos os modelos foram estruturados com apenas uma camada intermediária, variando a quantidade de neurônios presentes nesta camada e os tipos de função de ativação usadas nos neurônios. As quantidades de neurônios testadas na camada intermediária foram definidas de acordo com Hecht-Nielsen (1990), baseando-se na quantidade de variáveis de entrada em cada modelo (x_n). Já as funções de ativação foram definidas de acordo com Silva, Spatti e Flauzino (2010). As funções logística e tangente hiperbólica foram escolhidas por serem contínuas e diferenciáveis em todo o domínio de definição. A função linear foi usada no neurônio da camada de saída porque seu papel na aplicação realizada (aproximação funcional) é fazer uma combinação linear das saídas dos neurônios da camada intermediária.

Quadro 24 – Topologias candidatas definidas para os modelos baseados em redes PMC

Modelo	Configuração topológica	Quantidade de camadas intermediárias	Neurônios na camada intermediária	Função de ativação na camada intermediária	Função na camada de saída
Modelo PMC 1	Alternativa 1	1	$x_n - 2 = 6$	Logística	Linear
	Alternativa 2	1	$x_n - 1 = 7$	Logística	Linear
	Alternativa 3	1	$x_n = 8$	Logística	Linear
	Alternativa 4	1	$x_n + 1 = 9$	Logística	Linear
	Alternativa 5	1	$x_n + 2 = 10$	Logística	Linear
	Alternativa 6	1	$x_n - 2 = 6$	Tangente hiperbólica	Linear
	Alternativa 7	1	$x_n - 1 = 7$	Tangente hiperbólica	Linear
	Alternativa 8	1	$x_n = 8$	Tangente hiperbólica	Linear
	Alternativa 9	1	$x_n + 1 = 9$	Tangente hiperbólica	Linear
	Alternativa 10	1	$x_n + 2 = 10$	Tangente hiperbólica	Linear
Modelo PMC 2	Alternativa 1	1	$x_n - 2 = 1$	Logística	Linear
	Alternativa 2	1	$x_n - 1 = 2$	Logística	Linear
	Alternativa 3	1	$x_n = 3$	Logística	Linear

Modelo	Configuração topológica	Quantidade de camadas intermediárias	Neurônios na camada intermediária	Função de ativação na camada intermediária	Função na camada de saída
	Alternativa 4	1	$x_n + 1 = 4$	Logística	Linear
	Alternativa 5	1	$x_n + 2 = 5$	Logística	Linear
	Alternativa 6	1	$x_n - 2 = 1$	Tangente hiperbólica	Linear
	Alternativa 7	1	$x_n - 1 = 2$	Tangente hiperbólica	Linear
	Alternativa 8	1	$x_n = 3$	Tangente hiperbólica	Linear
	Alternativa 9	1	$x_n + 1 = 4$	Tangente hiperbólica	Linear
	Alternativa 10	1	$x_n + 2 = 5$	Tangente hiperbólica	Linear
Modelo PMC 3	Alternativa 1	1	$x_n - 2 = 1$	Logística	Linear
	Alternativa 2	1	$x_n - 1 = 2$	Logística	Linear
	Alternativa 3	1	$x_n = 3$	Logística	Linear
	Alternativa 4	1	$x_n + 1 = 4$	Logística	Linear
	Alternativa 5	1	$x_n + 2 = 5$	Logística	Linear
	Alternativa 6	1	$x_n - 2 = 1$	Tangente hiperbólica	Linear
	Alternativa 7	1	$x_n - 1 = 2$	Tangente hiperbólica	Linear
	Alternativa 8	1	$x_n = 3$	Tangente hiperbólica	Linear
	Alternativa 9	1	$x_n + 1 = 4$	Tangente hiperbólica	Linear
	Alternativa 10	1	$x_n + 2 = 5$	Tangente hiperbólica	Linear
Modelo PMC 4	Alternativa 1	1	$x_n - 2 = 1$	Logística	Linear
	Alternativa 2	1	$x_n - 1 = 2$	Logística	Linear
	Alternativa 3	1	$x_n = 3$	Logística	Linear
	Alternativa 4	1	$x_n + 1 = 4$	Logística	Linear
	Alternativa 5	1	$x_n + 2 = 5$	Logística	Linear
	Alternativa 6	1	$x_n - 2 = 1$	Tangente hiperbólica	Linear
	Alternativa 7	1	$x_n - 1 = 2$	Tangente hiperbólica	Linear
	Alternativa 8	1	$x_n = 3$	Tangente hiperbólica	Linear
	Alternativa 9	1	$x_n + 1 = 4$	Tangente hiperbólica	Linear
	Alternativa 10	1	$x_n + 2 = 5$	Tangente hiperbólica	Linear
Modelo PMC 5	Alternativa 1	1	$x_n - 2 = 2$	Logística	Linear
	Alternativa 2	1	$x_n - 1 = 3$	Logística	Linear
	Alternativa 3	1	$x_n = 4$	Logística	Linear
	Alternativa 4	1	$x_n + 1 = 5$	Logística	Linear
	Alternativa 5	1	$x_n + 2 = 6$	Logística	Linear
	Alternativa 6	1	$x_n - 2 = 2$	Tangente hiperbólica	Linear
	Alternativa 7	1	$x_n - 1 = 3$	Tangente hiperbólica	Linear
	Alternativa 8	1	$x_n = 4$	Tangente hiperbólica	Linear
	Alternativa 9	1	$x_n + 1 = 5$	Tangente hiperbólica	Linear

Modelo	Configuração topológica	Quantidade de camadas intermediárias	Neurônios na camada intermediária	Função de ativação na camada intermediária	Função na camada de saída
	Alternativa 10	1	$x_n + 2 = 6$	Tangente hiperbólica	Linear
Modelo PMC 6	Alternativa 1	1	$x_n - 2 = 2$	Logística	Linear
	Alternativa 2	1	$x_n - 1 = 3$	Logística	Linear
	Alternativa 3	1	$x_n = 4$	Logística	Linear
	Alternativa 4	1	$x_n + 1 = 5$	Logística	Linear
	Alternativa 5	1	$x_n + 2 = 6$	Logística	Linear
	Alternativa 6	1	$x_n - 2 = 2$	Tangente hiperbólica	Linear
	Alternativa 7	1	$x_n - 1 = 3$	Tangente hiperbólica	Linear
	Alternativa 8	1	$x_n = 4$	Tangente hiperbólica	Linear
	Alternativa 9	1	$x_n + 1 = 5$	Tangente hiperbólica	Linear
	Alternativa 10	1	$x_n + 2 = 6$	Tangente hiperbólica	Linear
Modelo PMC 7	Alternativa 1	1	$x_n - 2 = 3$	Logística	Linear
	Alternativa 2	1	$x_n - 1 = 4$	Logística	Linear
	Alternativa 3	1	$x_n = 5$	Logística	Linear
	Alternativa 4	1	$x_n + 1 = 6$	Logística	Linear
	Alternativa 5	1	$x_n + 2 = 7$	Logística	Linear
	Alternativa 6	1	$x_n - 2 = 3$	Tangente hiperbólica	Linear
	Alternativa 7	1	$x_n - 1 = 4$	Tangente hiperbólica	Linear
	Alternativa 8	1	$x_n = 5$	Tangente hiperbólica	Linear
	Alternativa 9	1	$x_n + 1 = 6$	Tangente hiperbólica	Linear
	Alternativa 10	1	$x_n + 2 = 7$	Tangente hiperbólica	Linear

Fonte: Proposto pelo autor.

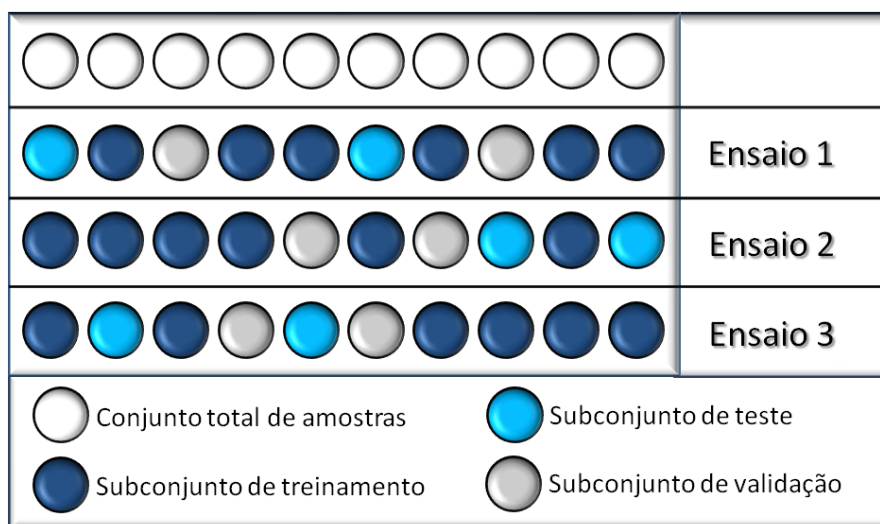
4.2.3 Planejamento do processo de treinamento dos modelos PMC

Com o propósito de minimizar a influência do método de treinamento sobre o desempenho das técnicas comparadas, optou-se por utilizar o método de treinamento supervisionado tradicionalmente mais empregado em cada técnica. De acordo com o estudo de Tkáč e Verner (2016), que revisou 412 publicações envolvendo a aplicação de RNAs e identificou o uso de oito diferentes métodos de treinamento, o *backpropagation* é o método mais utilizado em RNAs, sendo adotado por mais da metade dos estudos analisados. Portanto, para treinar os modelos PMC, foi escolhida a versão original do algoritmo *backpropagation* (RUMELHART; HINTON; WILLIAMS, 1986; BILGEHAN, 2011). Quando comparado com outros métodos de treinamento existentes, tais como o método termo de *momentum*, uma das vantagens do algoritmo original do

backpropagation consiste no uso de uma quantidade menor de parâmetros, o que diminui a complexidade do processo de modelagem.

A seleção das amostras para compor cada um dos subconjuntos de treinamento foi feita usando o método de amostragem aleatória (*random subsampling cross-validation*), descrito na Subseção 3.4.3 do Capítulo 3. Desta forma, conforme ilustra a Figura 62, durante o treinamento dos modelos computacionais, foram gerados três subconjuntos de amostras diferentes (formados aleatoriamente, a partir do mesmo conjunto de dados) para o treinamento de cada grupo de topologias candidatas. Cada subconjunto de treinamento gerado foi utilizado em um ensaio, totalizando assim três ensaios por topologia candidata. Em cada ensaio, além de variar as amostras usadas no treinamento, teste e validação, são modificados aleatoriamente os valores iniciais para os pesos das conexões sinápticas e para o limiar de ativação. A principal vantagem da realização desses múltiplos ensaios para o treinamento de cada topologia candidata é minimizar o efeito da distribuição das amostras e dos valores iniciais dos pesos sobre a capacidade de generalização da rede. Dessa forma, ao realizar três ensaios para cada topologia, aumenta-se a probabilidade de a função erro estacionar em um ponto de mínimo local mais próximo do ponto de mínimo global.

Figura 62 – Representação do particionamento do conjunto de amostras utilizado neste estudo



Fonte: Proposto pelo autor.

Em relação aos critérios de parada adotados para o *backpropagation*, a tolerância requerida (ϵ) durante o treinamento foi parametrizada com valor zero, uma vez que se deseja obter modelos com que realizem a predição dos indicadores com a maior exatidão possível. Como tal nível de precisão é idealizado e difícil de ser alcançado na prática, também foi usado como critério de parada o número máximo de épocas de treinamento,

definido como 20.000. Quanto à definição do valor de precisão requerido para o E_{qm} na etapa de teste dos modelos computacionais, com base no estudo de Fan et al. (2013), que apresenta a única aplicação encontrada de redes PMC na avaliação de desempenho de cadeias de suprimento, determinou-se que somente serão aceitáveis valores de E_{qm} menores que 1×10^{-3} , uma vez que no estudo de Fan et al. (2013) foram obtidos valores de até 5×10^{-3} para o erro quadrático médio.

Em relação à taxa de aprendizagem (η), esta foi escolhida por meio de alguns testes usando duas das configurações alternativas dos modelos PMC 2 e 3. Foram testados os valores 0,01, 0,03, 0,05, 0,10 e 0,50. Como a melhor capacidade de generalização foi alcançada usando o valor 0,03, este foi adotado como o valor inicial padrão para a taxa de aprendizagem de todas os modelos. Contudo, no caso dos modelos PMC 1, 5 e 7, após a realização dos treinamentos utilizando $\eta = 0,03$, nenhuma das topologias candidatas alcançou a precisão requerida durante a avaliação da capacidade de generalização da rede. Nessas situações, seguindo o esquema de aplicação da técnica de validação cruzada apresentado na Figura 60, alterou-se o valor taxa de aprendizagem e reiniciou-se o processo de treinamento de todas as topologias candidatas. Esse processo iterativo foi repetido até que fosse alcançado por cada modelo um valor satisfatório para o E_{qm} na etapa de teste. Dessa forma, foram definidas taxas de aprendizagem específicas para cada modelo, de modo a contribuir para a melhoria de sua capacidade de generalização.

4.2.4 Resultados do treinamento e da validação dos modelos PMC

A implementação computacional dos 70 modelos de redes neurais PMC apresentados neste estudo foi feita usando um módulo *toolbox* do *software* MATLAB, chamado *nntool*. A Tabela 2 apresenta os resultados alcançados após a realização de diversos ensaios envolvendo o treinamento e a validação das topologias candidatas ao modelo de rede PMC 1, que tem o papel de prever os valores do indicador *total cost to serve*. Foram calculados os erros quadráticos médios (*Mean Square Error*, MSE) alcançados durante o treinamento (E_{qm} treinamento) e durante o teste da capacidade de generalização (E_{qm} teste) para todos os ensaios realizados, conforme a fórmula apresentada no Apêndice B. Além disso, calculou-se o valor médio do E_{qm} obtido na etapa de treinamento e de teste ao longo dos três ensaios realizados com cada topologia candidata. Conforme foi discutido anteriormente, a melhor topologia candidata para cada modelo é aquela com menor valor médio do E_{qm} na etapa de teste. Inicialmente, as topologias candidatas ao modelo PMC 1 foram treinadas usando $\eta = 0,03$. No entanto,

como o menor valor médio alcançado para o E_{qm} de teste foi $6,08 \times 10^{-3}$, testou-se o uso dos valores $\eta = 0,01$ e $\eta = 0,05$, obtendo-se assim resultados satisfatórios quando $\eta = 0,05$. Portanto, os resultados apresentados na Tabela 2 foram calculados considerando $\eta = 0,05$.

Tabela 2 – Resultados obtidos pelas topologias candidatas ao modelo PMC 1


Topologias		E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$5,372 \times 10^{-3}$	$6,021 \times 10^{-2}$
	Ensaio 2	$1,067 \times 10^{-2}$	$1,830 \times 10^{-2}$
	Ensaio 3	$8,555 \times 10^{-3}$	$1,111 \times 10^{-2}$
	Média	$8,199 \times 10^{-3}$	$2,987 \times 10^{-2}$
Alternativa 2	Ensaio 1	$1,130 \times 10^{-2}$	$2,347 \times 10^{-2}$
	Ensaio 2	$1,000 \times 10^{-2}$	$4,801 \times 10^{-2}$
	Ensaio 3	$4,750 \times 10^{-3}$	$4,875 \times 10^{-3}$
	Média	$8,683 \times 10^{-3}$	$2,545 \times 10^{-2}$
Alternativa 3	Ensaio 1	$8,676 \times 10^{-3}$	$1,062 \times 10^{-2}$
	Ensaio 2	$1,603 \times 10^{-3}$	$1,126 \times 10^{-3}$
	Ensaio 3	$1,036 \times 10^{-2}$	$1,739 \times 10^{-2}$
	Média	$6,880 \times 10^{-3}$	$3,915 \times 10^{-3}$
Alternativa 4	Ensaio 1	$1,020 \times 10^{-2}$	$1,435 \times 10^{-2}$
	Ensaio 2	$1,456 \times 10^{-2}$	$1,539 \times 10^{-2}$
	Ensaio 3	$1,095 \times 10^{-2}$	$1,011 \times 10^{-2}$
	Média	$1,190 \times 10^{-2}$	$1,328 \times 10^{-2}$
Alternativa 5	Ensaio 1	$9,771 \times 10^{-3}$	$1,780 \times 10^{-2}$
	Ensaio 2	$9,122 \times 10^{-3}$	$1,758 \times 10^{-2}$
	Ensaio 3	$1,139 \times 10^{-2}$	$2,599 \times 10^{-2}$
	Média	$1,009 \times 10^{-2}$	$2,046 \times 10^{-2}$
Alternativa 6	Ensaio 1	$3,234 \times 10^{-3}$	$5,073 \times 10^{-3}$
	Ensaio 2	$4,059 \times 10^{-3}$	$1,445 \times 10^{-3}$
	Ensaio 3	$1,854 \times 10^{-3}$	$4,608 \times 10^{-3}$
	Média	$3,049 \times 10^{-3}$	$3,709 \times 10^{-3}$
Alternativa 7	Ensaio 1	$2,236 \times 10^{-3}$	$4,208 \times 10^{-4}$
	Ensaio 2	$2,610 \times 10^{-3}$	$4,663 \times 10^{-4}$
	Ensaio 3	$1,740 \times 10^{-3}$	$2,543 \times 10^{-4}$
	Média	$2,195 \times 10^{-3}$	$3,805 \times 10^{-4}$
Alternativa 8	Ensaio 1	$1,899 \times 10^{-3}$	$5,404 \times 10^{-4}$
	Ensaio 2	$6,002 \times 10^{-3}$	$2,167 \times 10^{-3}$
	Ensaio 3	$5,483 \times 10^{-3}$	$3,037 \times 10^{-3}$
	Média	$4,461 \times 10^{-3}$	$1,915 \times 10^{-3}$
Alternativa 9	Ensaio 1	$2,644 \times 10^{-3}$	$5,656 \times 10^{-4}$

Topologias		E_{qm} treinamento	E_{qm} teste
	Ensaio 2	$6,738 \times 10^{-3}$	$5,063 \times 10^{-3}$
	Ensaio 3	$1,440 \times 10^{-3}$	$1,091 \times 10^{-3}$
	Média	$3,607 \times 10^{-3}$	$2,240 \times 10^{-3}$
Alternativa 10	Ensaio 1	$1,947 \times 10^{-3}$	$2,406 \times 10^{-4}$
	Ensaio 2	$8,197 \times 10^{-3}$	$7,846 \times 10^{-3}$
	Ensaio 3	$4,734 \times 10^{-3}$	$2,981 \times 10^{-3}$
	Média	$4,959 \times 10^{-3}$	$3,689 \times 10^{-3}$

Fonte: Proposto pelo autor.

De acordo com os dados da Tabela 2, a configuração topológica de rede que apresentou a menor média de erros quadráticos médios na etapa de teste ($3,805 \times 10^{-4}$) foi a alternativa 7. Este valor é considerado satisfatório por ser menor que o E_{qm} máximo estabelecido para a etapa de teste ($1,0 \times 10^{-3}$). Por apresentar o melhor desempenho, a configuração topológica representada pela alternativa 7 foi a escolhida. Desta forma, o modelo PMC 1 terá sete neurônios na camada intermediária, que utilizarão funções de ativação do tipo tangente hiperbólica. A Figura 63 mostra o processo de minimização do erro quadrático médio ao longo de um dos treinamentos da rede escolhida, destacando também o processo de minimização do erro produzido pela apresentação do subconjunto de validação à rede.

Figura 63 - Minimização do erro quadrático médio (MSE) do modelo PMC 1



Fonte: Proposto pelo autor.

Conforme ilustrado na Figura 59 (p. 166), os modelos PMC 2 e 3 são usados em conjunto para prever os valores do indicador *return on working capital*. Enquanto o modelo PMC 2 realiza as operações com os indicadores de nível 2 (*inventory*, *accounts receivable* e *accounts payable*), o modelo PMC 3 utiliza a saída do PMC 2, juntamente com os valores dos indicadores *supply chain revenue* e *total cost to serve*, para prever

o valor de *return on working capital*. A Tabela 3 apresenta os resultados obtidos para as topologias candidatas ao modelo de rede PMC 2. Esses valores foram obtidos utilizando o valor da taxa de aprendizagem inicial padrão, ou seja, $\eta = 0,03$. Como a alternativa 6 apresentou o menor valor médio de E_{qm} na etapa de teste ($2,208 \times 10^{-4}$), esta foi considerada a configuração topológica mais adequada para o modelo PMC 2. Portanto, o modelo de rede PMC 2 utilizará de apenas um neurônio na camada intermediária com função de ativação tangente hiperbólica. A Figura 64 ilustra o processo de minimização do erro quadrático médio da rede escolhida para o modelo PMC 2 ao longo de um dos treinamentos realizados.


Tabela 3 - Resultados obtidos pelas topologias candidatas ao modelo PMC 2

Topologias		E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$1,180 \times 10^{-3}$	$1,077 \times 10^{-3}$
	Ensaio 2	$1,046 \times 10^{-3}$	$1,675 \times 10^{-3}$
	Ensaio 3	$1,013 \times 10^{-3}$	$7,788 \times 10^{-4}$
	Média	$1,080 \times 10^{-3}$	$1,177 \times 10^{-3}$
Alternativa 2	Ensaio 1	$1,449 \times 10^{-3}$	$1,713 \times 10^{-3}$
	Ensaio 2	$1,779 \times 10^{-3}$	$2,934 \times 10^{-3}$
	Ensaio 3	$4,270 \times 10^{-3}$	$2,739 \times 10^{-3}$
	Média	$2,499 \times 10^{-3}$	$2,462 \times 10^{-3}$
Alternativa 3	Ensaio 1	$2,374 \times 10^{-3}$	$5,226 \times 10^{-3}$
	Ensaio 2	$1,280 \times 10^{-3}$	$1,070 \times 10^{-3}$
	Ensaio 3	$1,653 \times 10^{-3}$	$3,958 \times 10^{-3}$
	Média	$1,769 \times 10^{-3}$	$3,418 \times 10^{-3}$
Alternativa 4	Ensaio 1	$1,793 \times 10^{-3}$	$3,175 \times 10^{-3}$
	Ensaio 2	$1,457 \times 10^{-3}$	$4,827 \times 10^{-3}$
	Ensaio 3	$2,575 \times 10^{-3}$	$3,912 \times 10^{-3}$
	Média	$1,942 \times 10^{-3}$	$3,971 \times 10^{-3}$
Alternativa 5	Ensaio 1	$1,320 \times 10^{-3}$	$2,155 \times 10^{-4}$
	Ensaio 2	$1,628 \times 10^{-3}$	$6,385 \times 10^{-4}$
	Ensaio 3	$1,226 \times 10^{-3}$	$2,329 \times 10^{-4}$
	Média	$1,391 \times 10^{-3}$	$3,623 \times 10^{-4}$
Alternativa 6	Ensaio 1	$1,049 \times 10^{-3}$	$1,673 \times 10^{-4}$
	Ensaio 2	$1,215 \times 10^{-3}$	$2,639 \times 10^{-4}$
	Ensaio 3	$7,518 \times 10^{-4}$	$2,313 \times 10^{-4}$
	Média	$1,005 \times 10^{-3}$	$2,208 \times 10^{-4}$
Alternativa 7	Ensaio 1	$1,401 \times 10^{-3}$	$2,193 \times 10^{-4}$
	Ensaio 2	$1,745 \times 10^{-3}$	$1,299 \times 10^{-3}$
	Ensaio 3	$1,078 \times 10^{-3}$	$4,348 \times 10^{-4}$

Topologias		E_{qm} treinamento	E_{qm} teste
Alternativa 8	Média	$1,408 \times 10^{-3}$	$6,510 \times 10^{-4}$
	Ensaio 1	$1,489 \times 10^{-3}$	$6,982 \times 10^{-4}$
	Ensaio 2	$1,873 \times 10^{-3}$	$1,585 \times 10^{-3}$
	Ensaio 3	$1,695 \times 10^{-3}$	$8,793 \times 10^{-4}$
	Média	$1,686 \times 10^{-3}$	$1,054 \times 10^{-3}$
Alternativa 9	Ensaio 1	$1,757 \times 10^{-3}$	$1,356 \times 10^{-3}$
	Ensaio 2	$9,664 \times 10^{-4}$	$7,327 \times 10^{-4}$
	Ensaio 3	$1,516 \times 10^{-3}$	$8,438 \times 10^{-4}$
	Média	$1,413 \times 10^{-3}$	$9,775 \times 10^{-4}$
Alternativa 10	Ensaio 1	$2,420 \times 10^{-3}$	$3,624 \times 10^{-3}$
	Ensaio 2	$1,223 \times 10^{-3}$	$1,774 \times 10^{-3}$
	Ensaio 3	$1,410 \times 10^{-3}$	$1,202 \times 10^{-3}$
	Média	$1,684 \times 10^{-3}$	$2,200 \times 10^{-3}$

Fonte: Proposto pelo autor.

Figura 64 - Minimização do erro quadrático médio (MSE) do modelo PMC 2



Fonte: Proposto pelo autor.

A Tabela 4 apresenta os resultados obtidos pelas topologias candidatas ao modelo de rede PMC 3, responsáveis pela predição dos valores do indicador *return on working capital*. A alternativa 8 apresentou o melhor desempenho quanto à capacidade de generalização, alcançando um valor médio de E_{qm} na etapa de teste igual a $8,393 \times 10^{-4}$. Os resultados apresentados na Tabela 4 foram obtidos utilizando $\eta = 0,03$. Apesar do valor médio do E_{qm} de teste estar dentro da faixa aceitável, na tentativa de melhorar os resultados obtidos para o modelo PMC 3, foram realizados mais alguns treinamentos

considerando $\eta = 0,01$ e $\eta = 0,05$. Todavia, obteve-se valores ainda mais altos para o E_{qm} de teste. Portanto, baseando-se nos resultados obtidos considerando $\eta = 0,03$, a configuração topológica do modelo PMC 3 deverá utilizar três neurônios na camada intermediária, com a função de ativação tangente hiperbólica. A Figura 65 mostra o processo de minimização do erro quadrático médio durante um dos treinamentos da rede escolhida.


Tabela 4 - Resultados obtidos pelas topologias candidatas ao modelo PMC 3

Topologias		E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$2,370 \times 10^{-3}$	$6,434 \times 10^{-3}$
	Ensaio 2	$2,463 \times 10^{-3}$	$6,021 \times 10^{-3}$
	Ensaio 3	$2,463 \times 10^{-3}$	$6,021 \times 10^{-3}$
	Média	$2,432 \times 10^{-3}$	$6,159 \times 10^{-3}$
Alternativa 2	Ensaio 1	$1,662 \times 10^{-3}$	$4,358 \times 10^{-3}$
	Ensaio 2	$1,429 \times 10^{-3}$	$3,378 \times 10^{-3}$
	Ensaio 3	$1,431 \times 10^{-3}$	$3,377 \times 10^{-3}$
	Média	$1,507 \times 10^{-3}$	$3,704 \times 10^{-3}$
Alternativa 3	Ensaio 1	$3,594 \times 10^{-3}$	$5,843 \times 10^{-3}$
	Ensaio 2	$1,024 \times 10^{-3}$	$3,538 \times 10^{-3}$
	Ensaio 3	$1,018 \times 10^{-3}$	$3,535 \times 10^{-3}$
	Média	$1,879 \times 10^{-3}$	$4,305 \times 10^{-3}$
Alternativa 4	Ensaio 1	$2,436 \times 10^{-3}$	$3,805 \times 10^{-3}$
	Ensaio 2	$1,888 \times 10^{-3}$	$6,553 \times 10^{-3}$
	Ensaio 3	$1,753 \times 10^{-3}$	$6,416 \times 10^{-3}$
	Média	$2,026 \times 10^{-3}$	$5,591 \times 10^{-3}$
Alternativa 5	Ensaio 1	$3,466 \times 10^{-3}$	$9,263 \times 10^{-3}$
	Ensaio 2	$3,494 \times 10^{-3}$	$6,484 \times 10^{-3}$
	Ensaio 3	$4,122 \times 10^{-3}$	$1,222 \times 10^{-2}$
	Média	$3,694 \times 10^{-3}$	$9,322 \times 10^{-3}$
Alternativa 6	Ensaio 1	$3,107 \times 10^{-3}$	$4,975 \times 10^{-3}$
	Ensaio 2	$1,047 \times 10^{-3}$	$5,078 \times 10^{-3}$
	Ensaio 3	$5,243 \times 10^{-3}$	$2,283 \times 10^{-3}$
	Média	$3,132 \times 10^{-3}$	$4,112 \times 10^{-3}$
Alternativa 7	Ensaio 1	$1,114 \times 10^{-3}$	$1,164 \times 10^{-3}$
	Ensaio 2	$1,340 \times 10^{-2}$	$1,492 \times 10^{-2}$
	Ensaio 3	$8,370 \times 10^{-4}$	$1,136 \times 10^{-3}$
	Média	$5,126 \times 10^{-3}$	$5,74 \times 10^{-3}$
Alternativa 8	Ensaio 1	$6,290 \times 10^{-4}$	$9,272 \times 10^{-4}$
	Ensaio 2	$6,720 \times 10^{-4}$	$6,597 \times 10^{-4}$
	Ensaio 3	$9,580 \times 10^{-4}$	$9,309 \times 10^{-4}$

Topologias		E_{qm} treinamento	E_{qm} teste
	Média	$7,53 \times 10^{-4}$	$8,393 \times 10^{-4}$
Alternativa 9	Ensaio 1	$9,682 \times 10^{-4}$	$3,417 \times 10^{-3}$
	Ensaio 2	$4,696 \times 10^{-4}$	$3,351 \times 10^{-3}$
	Ensaio 3	$5,514 \times 10^{-4}$	$2,975 \times 10^{-3}$
	Média	$6,631 \times 10^{-4}$	$3,248 \times 10^{-3}$
Alternativa 10	Ensaio 1	$1,434 \times 10^{-3}$	$3,346 \times 10^{-3}$
	Ensaio 2	$6,893 \times 10^{-4}$	$3,793 \times 10^{-3}$
	Ensaio 3	$6,963 \times 10^{-4}$	$2,721 \times 10^{-3}$
	Média	$9,399 \times 10^{-4}$	$3,287 \times 10^{-3}$

Fonte: Proposto pelo autor.

Figura 65 - Minimização do erro quadrático médio (MSE) do modelo PMC 3



Fonte: Proposto pelo autor.

A Tabela 5 apresenta os resultados alcançados pelas topologias candidatas ao modelo de rede PMC 4, o qual é incumbido da predição dos valores do indicador *cash-to-cash cycle time*. Estes valores foram obtidos considerando a taxa de aprendizagem $\eta = 0,03$. Nesse caso, a alternativa 6 alcançou o melhor desempenho na etapa de teste, obtendo o valor médio de E_{qm} de $1,591 \times 10^{-4}$. Portanto, o modelo PMC 4 terá apenas um neurônio na camada intermediária e utilizará a função de ativação tangente hiperbólica. O processo de minimização do erro quadrático médio durante um dos treinamentos da rede com melhor desempenho é mostrado na Figura 66.


Tabela 5 - Resultados obtidos pelas topologias candidatas ao modelo PMC 4

Topologias		E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$5,181 \times 10^{-3}$	$2,457 \times 10^{-3}$
	Ensaio 2	$3,140 \times 10^{-3}$	$8,839 \times 10^{-4}$
	Ensaio 3	$9,433 \times 10^{-4}$	$3,612 \times 10^{-4}$
	Média	$3,088 \times 10^{-3}$	$1,234 \times 10^{-3}$
Alternativa 2	Ensaio 1	$9,593 \times 10^{-3}$	$5,342 \times 10^{-3}$
	Ensaio 2	$8,657 \times 10^{-3}$	$3,598 \times 10^{-3}$
	Ensaio 3	$4,776 \times 10^{-3}$	$6,264 \times 10^{-3}$
	Média	$7,681 \times 10^{-3}$	$5,068 \times 10^{-3}$
Alternativa 3	Ensaio 1	$6,054 \times 10^{-3}$	$7,430 \times 10^{-3}$
	Ensaio 2	$3,880 \times 10^{-3}$	$3,251 \times 10^{-3}$
	Ensaio 3	$2,753 \times 10^{-3}$	$6,736 \times 10^{-3}$
	Média	$4,229 \times 10^{-3}$	$5,806 \times 10^{-3}$
Alternativa 4	Ensaio 1	$2,138 \times 10^{-3}$	$1,817 \times 10^{-3}$
	Ensaio 2	$3,836 \times 10^{-3}$	$7,680 \times 10^{-3}$
	Ensaio 3	$2,502 \times 10^{-3}$	$3,091 \times 10^{-3}$
	Média	$2,825 \times 10^{-3}$	$4,196 \times 10^{-3}$
Alternativa 5	Ensaio 1	$1,190 \times 10^{-3}$	$1,177 \times 10^{-3}$
	Ensaio 2	$2,519 \times 10^{-3}$	$3,181 \times 10^{-3}$
	Ensaio 3	$1,093 \times 10^{-2}$	$8,270 \times 10^{-3}$
	Média	$1,601 \times 10^{-3}$	$4,209 \times 10^{-3}$
Alternativa 6	Ensaio 1	$9,351 \times 10^{-4}$	$1,826 \times 10^{-4}$
	Ensaio 2	$1,423 \times 10^{-3}$	$1,900 \times 10^{-4}$
	Ensaio 3	$6,010 \times 10^{-4}$	$1,048 \times 10^{-4}$
	Média	$9,864 \times 10^{-4}$	$1,591 \times 10^{-4}$
Alternativa 7	Ensaio 1	$3,077 \times 10^{-3}$	$1,669 \times 10^{-3}$
	Ensaio 2	$2,749 \times 10^{-3}$	$1,945 \times 10^{-3}$
	Ensaio 3	$2,751 \times 10^{-3}$	$3,228 \times 10^{-3}$
	Média	$2,859 \times 10^{-3}$	$2,281 \times 10^{-3}$
Alternativa 8	Ensaio 1	$3,448 \times 10^{-3}$	$2,142 \times 10^{-3}$
	Ensaio 2	$4,681 \times 10^{-3}$	$1,030 \times 10^{-3}$
	Ensaio 3	$2,615 \times 10^{-3}$	$2,106 \times 10^{-3}$
	Média	$3,581 \times 10^{-3}$	$1,759 \times 10^{-3}$
Alternativa 9	Ensaio 1	$3,730 \times 10^{-3}$	$1,572 \times 10^{-3}$
	Ensaio 2	$3,815 \times 10^{-3}$	$2,724 \times 10^{-3}$
	Ensaio 3	$2,597 \times 10^{-3}$	$1,048 \times 10^{-3}$
	Média	$3,381 \times 10^{-3}$	$1,781 \times 10^{-3}$
Alternativa 10	Ensaio 1	$1,495 \times 10^{-3}$	$1,059 \times 10^{-3}$
	Ensaio 2	$1,078 \times 10^{-3}$	$3,192 \times 10^{-3}$

Topologias	E_{qm} treinamento	E_{qm} teste
Ensaio 3	$1,361 \times 10^{-3}$	$1,083 \times 10^{-3}$
Média	$1,311 \times 10^{-3}$	$1,778 \times 10^{-3}$

Fonte: Proposto pelo autor.

Figura 66 - Minimização do erro quadrático médio (MSE) do modelo PMC 4



Fonte: Proposto pelo autor.

Os resultados obtidos pelas topologias candidatas ao modelo de rede PMC 5, responsável pela predição dos valores do indicador *order fulfillment cycle time*, são mostrados na Tabela 6. Esses resultados foram calculados considerando $\eta = 0,05$. A alternativa 10 se mostrou a melhor configuração topológica dentre as avaliadas, já que alcançou o melhor desempenho na etapa de teste, com o valor médio de E_{qm} de $5,116 \times 10^{-4}$. Diante disso, o modelo PMC 5 possuirá seis neurônios na camada intermediária e utilizará a função de ativação tangente hiperbólica. A Figura 67 ilustra o processo de minimização do erro quadrático médio durante um dos treinamentos do modelo representado pela alternativa 10.


Tabela 6 - Resultados obtidos pelas topologias candidatas ao modelo PMC 5

Topologias	E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$9,512 \times 10^{-4}$
	Ensaio 2	$1,122 \times 10^{-3}$
	Ensaio 3	$9,513 \times 10^{-4}$
	Média	$1,008 \times 10^{-3}$
Alternativa 2	Ensaio 1	$2,158 \times 10^{-3}$
	Ensaio 2	$1,929 \times 10^{-3}$
	Ensaio 3	$2,157 \times 10^{-3}$
	Média	$2,081 \times 10^{-3}$
Alternativa 3	Ensaio 1	$1,884 \times 10^{-3}$
		$5,717 \times 10^{-2}$

Topologias		E_{qm} treinamento	E_{qm} teste
	Ensaio 2	$1,860 \times 10^{-3}$	$5,568 \times 10^{-2}$
	Ensaio 3	$1,883 \times 10^{-3}$	$5,716 \times 10^{-2}$
	Média	$1,8757 \times 10^{-3}$	$5,667 \times 10^{-3}$
Alternativa 4	Ensaio 1	$2,042 \times 10^{-3}$	$3,767 \times 10^{-3}$
	Ensaio 2	$1,021 \times 10^{-3}$	$2,777 \times 10^{-3}$
	Ensaio 3	$2,115 \times 10^{-3}$	$2,327 \times 10^{-3}$
	Média	$1,726 \times 10^{-3}$	$2,957 \times 10^{-3}$
Alternativa 5	Ensaio 1	$4,096 \times 10^{-3}$	$6,223 \times 10^{-2}$
	Ensaio 2	$3,565 \times 10^{-3}$	$1,664 \times 10^{-2}$
	Ensaio 3	$4,096 \times 10^{-3}$	$6,222 \times 10^{-2}$
	Média	$4,187 \times 10^{-3}$	$4,703 \times 10^{-2}$
Alternativa 6	Ensaio 1	$3,489 \times 10^{-4}$	$1,664 \times 10^{-3}$
	Ensaio 2	$3,114 \times 10^{-4}$	$2,051 \times 10^{-3}$
	Ensaio 3	$2,009 \times 10^{-4}$	$2,242 \times 10^{-3}$
	Média	$2,871 \times 10^{-4}$	$1,986 \times 10^{-3}$
Alternativa 7	Ensaio 1	$1,344 \times 10^{-3}$	$7,001 \times 10^{-4}$
	Ensaio 2	$4,910 \times 10^{-4}$	$9,559 \times 10^{-4}$
	Ensaio 3	$1,546 \times 10^{-3}$	$8,083 \times 10^{-4}$
	Média	$1,127 \times 10^{-3}$	$8,214 \times 10^{-4}$
Alternativa 8	Ensaio 1	$3,460 \times 10^{-4}$	$1,576 \times 10^{-3}$
	Ensaio 2	$2,071 \times 10^{-3}$	$4,765 \times 10^{-3}$
	Ensaio 3	$5,456 \times 10^{-4}$	$2,867 \times 10^{-3}$
	Média	$9,875 \times 10^{-4}$	$3,069 \times 10^{-3}$
Alternativa 9	Ensaio 1	$1,157 \times 10^{-3}$	$1,139 \times 10^{-3}$
	Ensaio 2	$4,503 \times 10^{-4}$	$2,145 \times 10^{-3}$
	Ensaio 3	$4,554 \times 10^{-4}$	$1,793 \times 10^{-3}$
	Média	$6,876 \times 10^{-4}$	$1,692 \times 10^{-3}$
Alternativa 10	Ensaio 1	$6,954 \times 10^{-4}$	$4,476 \times 10^{-4}$
	Ensaio 2	$8,1013 \times 10^{-4}$	$5,073 \times 10^{-4}$
	Ensaio 3	$9,755 \times 10^{-4}$	$5,798 \times 10^{-4}$
	Média	$8,2701 \times 10^{-4}$	$5,116 \times 10^{-4}$

Fonte: Proposto pelo autor.

Figura 67 – Minimização do erro quadrático médio (MSE) do modelo PMC 5



Fonte: Proposto pelo autor.

A Tabela 7 apresenta os resultados obtidos pelas topologias candidatas ao modelo PMC 6, o qual é responsável pela predição dos valores do indicador *perfect order fulfillment*. Os valores apresentados foram obtidos usando o valor da taxa de aprendizagem igual a 0,03. A alternativa 7 obteve o menor valor médio de E_{qm} , equivalente a $1,432 \times 10^{-8}$. Portanto, o modelo PMC 6 será composto de três neurônios na camada intermediária e utilizará a função de ativação tangente hiperbólica. A Figura 68 ilustra o processo de minimização do erro quadrático médio durante um dos treinamentos do modelo representado pela alternativa 7.


Tabela 7 - Resultados obtidos pelas topologias candidatas ao modelo PMC 6

Topologias		E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$1,922 \times 10^{-3}$	$3,018 \times 10^{-4}$
	Ensaio 2	$2,683 \times 10^{-3}$	$2,739 \times 10^{-4}$
	Ensaio 3	$1,013 \times 10^{-3}$	$1,953 \times 10^{-4}$
	Média	$1,873 \times 10^{-3}$	$2,57 \times 10^{-4}$
Alternativa 2	Ensaio 1	$1,240 \times 10^{-3}$	$6,105 \times 10^{-4}$
	Ensaio 2	$6,205 \times 10^{-5}$	$2,799 \times 10^{-7}$
	Ensaio 3	$1,039 \times 10^{-3}$	$8,573 \times 10^{-4}$
	Média	$7,8035 \times 10^{-4}$	$4,8936 \times 10^{-4}$
Alternativa 3	Ensaio 1	$1,574 \times 10^{-3}$	$3,344 \times 10^{-4}$
	Ensaio 2	$9,593 \times 10^{-4}$	$4,248 \times 10^{-4}$
	Ensaio 3	$1,860 \times 10^{-3}$	$1,122 \times 10^{-3}$
	Média	$1,4644 \times 10^{-3}$	$6,2707 \times 10^{-4}$
Alternativa 4	Ensaio 1	$4,301 \times 10^{-4}$	$4,557 \times 10^{-5}$
	Ensaio 2	$3,871 \times 10^{-4}$	$1,218 \times 10^{-4}$

Topologias		E_{qm} treinamento	E_{qm} teste
	Ensaio 3	$4,634 \times 10^{-4}$	$5,191 \times 10^{-4}$
	Média	$4,2687 \times 10^{-4}$	$2,2882 \times 10^{-4}$
Alternativa 5	Ensaio 1	$1,193 \times 10^{-3}$	$5,349 \times 10^{-4}$
	Ensaio 2	$7,427 \times 10^{-4}$	$2,343 \times 10^{-4}$
	Ensaio 3	$1,245 \times 10^{-4}$	$1,421 \times 10^{-6}$
	Média	$4,8673 \times 10^{-4}$	$2,5687 \times 10^{-4}$
Alternativa 6	Ensaio 1	$2,277 \times 10^{-4}$	$1,040 \times 10^{-5}$
	Ensaio 2	$9,997 \times 10^{-6}$	$9,901 \times 10^{-8}$
	Ensaio 3	$1,977 \times 10^{-4}$	$6,231 \times 10^{-6}$
	Média	$1,4513 \times 10^{-4}$	$5,5767 \times 10^{-6}$
Alternativa 7	Ensaio 1	$9,990 \times 10^{-6}$	$5,697 \times 10^{-10}$
	Ensaio 2	$9,998 \times 10^{-6}$	$1,743 \times 10^{-9}$
	Ensaio 3	$4,2709 \times 10^{-5}$	$4,0661 \times 10^{-8}$
	Média	$2,089 \times 10^{-5}$	$1,432 \times 10^{-8}$
Alternativa 8	Ensaio 1	$4,060 \times 10^{-4}$	$4,751 \times 10^{-5}$
	Ensaio 2	$4,496 \times 10^{-4}$	$9,675 \times 10^{-5}$
	Ensaio 3	$2,291 \times 10^{-4}$	$1,794 \times 10^{-5}$
	Média	$3,6157 \times 10^{-5}$	$5,4067 \times 10^{-5}$
Alternativa 9	Ensaio 1	$2,945 \times 10^{-4}$	$2,818 \times 10^{-5}$
	Ensaio 2	$2,198 \times 10^{-4}$	$1,908 \times 10^{-5}$
	Ensaio 3	$1,341 \times 10^{-4}$	$2,369 \times 10^{-6}$
	Média	$2,1613 \times 10^{-3}$	$1,6543 \times 10^{-5}$
Alternativa 10	Ensaio 1	$1,029 \times 10^{-4}$	$1,084 \times 10^{-6}$
	Ensaio 2	$7,756 \times 10^{-5}$	$1,654 \times 10^{-6}$
	Ensaio 3	$3,284 \times 10^{-5}$	$1,228 \times 10^{-7}$
	Média	$7,11 \times 10^{-5}$	$9,536 \times 10^{-7}$

Fonte: Proposto pelo autor.

Figura 68 – Minimização do erro quadrático médio (MSE) do modelo PMC 6



Fonte: Proposto pelo autor.

Na Tabela 8 são mostrados os resultados alcançados pelas topologias candidatas ao modelo PMC 7, cujo propósito é prever os valores do indicador *overall value at risk*. Todas as topologias candidatas ao modelo PMC 7 foram inicialmente treinadas utilizando um valor de taxa de aprendizagem igual a 0,03. Como nenhuma delas produziu um valor de E_{qm} satisfatório na etapa de teste, os testes foram refeitos considerando $\eta = 0,01$ e $\eta = 0,05$. Desta forma, os valores mostrados na Tabela 8 foram obtidos usando $\eta = 0,05$. A alternativa 6 alcançou o menor valor médio de E_{qm} de teste, igual a $6,9297 \times 10^{-5}$, apresentando assim o melhor desempenho dentre as alternativas avaliadas. Assim, o modelo PMC 7 será composto de três neurônios na camada intermediária e utilizará a função de ativação tangente hiperbólica. A Figura 69 ilustra o processo de minimização do erro quadrático médio durante um dos treinamentos do modelo representado pela alternativa 6.


Tabela 8 - Resultados obtidos pelas topologias candidatas ao modelo PMC 7

Topologias	E_{qm} treinamento	E_{qm} teste	
Alternativa 1	Ensaio 1	$1,380 \times 10^{-3}$	$8,28 \times 10^{-4}$
	Ensaio 2	$1,384 \times 10^{-3}$	$1,43 \times 10^{-3}$
	Ensaio 3	$1,467 \times 10^{-3}$	$8,04 \times 10^{-4}$
	Média	$1,4103 \times 10^{-3}$	$1,0207 \times 10^{-3}$
Alternativa 2	Ensaio 1	$1,29 \times 10^{-3}$	$1,15 \times 10^{-3}$
	Ensaio 2	$2,088 \times 10^{-3}$	$2,02 \times 10^{-3}$
	Ensaio 3	$1,889 \times 10^{-3}$	$1,44 \times 10^{-3}$

Topologias		E_{qm} treinamento	E_{qm} teste
	Média	$1,7556 \times 10^{-3}$	$1,5367 \times 10^{-3}$
Alternativa 3	Ensaio 1	$2,52 \times 10^{-3}$	$2,19 \times 10^{-3}$
	Ensaio 2	$1,467 \times 10^{-3}$	$8,51 \times 10^{-4}$
	Ensaio 3	$2,548 \times 10^{-3}$	$1,99 \times 10^{-3}$
	Média	$2,1783 \times 10^{-3}$	$1,677 \times 10^{-3}$
Alternativa 4	Ensaio 1	$2,52 \times 10^{-3}$	$3,138 \times 10^{-3}$
	Ensaio 2	$4,002 \times 10^{-3}$	$5,49 \times 10^{-3}$
	Ensaio 3	$2,634 \times 10^{-3}$	$3,79 \times 10^{-3}$
	Média	$3,052 \times 10^{-3}$	$4,139 \times 10^{-3}$
Alternativa 5	Ensaio 1	$1,34 \times 10^{-3}$	$1,542 \times 10^{-3}$
	Ensaio 2	$2,703 \times 10^{-3}$	$5,85 \times 10^{-3}$
	Ensaio 3	$2,519 \times 10^{-3}$	$3,76 \times 10^{-3}$
	Média	$2,187 \times 10^{-3}$	$3,7173 \times 10^{-3}$
Alternativa 6	Ensaio 1	$2,914 \times 10^{-4}$	$5,05 \times 10^{-5}$
	Ensaio 2	$5,069 \times 10^{-4}$	$7,089 \times 10^{-5}$
	Ensaio 3	$1,07 \times 10^{-4}$	$8,65 \times 10^{-5}$
	Média	$3,0177 \times 10^{-4}$	$6,9297 \times 10^{-5}$
Alternativa 7	Ensaio 1	$7,836 \times 10^{-4}$	$2,74 \times 10^{-4}$
	Ensaio 2	$2,86 \times 10^{-2}$	$3,11 \times 10^{-4}$
	Ensaio 3	$2,099 \times 10^{-4}$	$1,54 \times 10^{-4}$
	Média	$9,9645 \times 10^{-3}$	$2,463 \times 10^{-4}$
Alternativa 8	Ensaio 1	$6,20 \times 10^{-4}$	$1,85 \times 10^{-4}$
	Ensaio 2	$5,31 \times 10^{-4}$	$2,15 \times 10^{-4}$
	Ensaio 3	$4,623 \times 10^{-4}$	$1,05 \times 10^{-4}$
	Média	$5,3776 \times 10^{-4}$	$1,6833 \times 10^{-4}$
Alternativa 9	Ensaio 1	$1,167 \times 10^{-3}$	$3,88 \times 10^{-4}$
	Ensaio 2	$7,479 \times 10^{-4}$	$1,65 \times 10^{-4}$
	Ensaio 3	$9,38 \times 10^{-4}$	$3,33 \times 10^{-4}$
	Média	$9,5097 \times 10^{-4}$	$2,953 \times 10^{-4}$
Alternativa 10	Ensaio 1	$7,11 \times 10^{-4}$	$1,77 \times 10^{-4}$
	Ensaio 2	$1,043 \times 10^{-3}$	$4,98 \times 10^{-4}$
	Ensaio 3	$1,311 \times 10^{-3}$	$7,53 \times 10^{-4}$
	Média	$1,022 \times 10^{-3}$	$4,76 \times 10^{-4}$

Fonte: Proposto pelo autor.

Figura 69 – Minimização do erro quadrático médio (MSE) do modelo PMC 7



Fonte: Proposto pelo autor.

4.2.5 Síntese dos resultados da implementação computacional dos modelos PMC

A Tabela 9 sintetiza os resultados obtidos a partir do treinamento e do teste das topologias de redes neurais candidatas aos modelos de predição do tipo PMC. Por meio da análise dos valores médios calculados para o E_{qm} na etapa de teste, verifica-se que todos eles são menores que o valor limite definido ($1,0 \times 10^{-3}$). Assim, diante dessa capacidade de predição de desempenho satisfatória, conclui-se que as redes neurais artificiais são adequadas para modelar quantitativamente os relacionamentos de causa e efeito entre os indicadores do SCOR[®].

Tabela 9 – Síntese dos resultados da implementação computacional dos modelos PMC

Modelo de Predição	Melhor configuração topológica	Taxa de aprendizagem utilizada	Neurônios na camada intermediária	Tipo de função de ativação na camada intermediária	E_{qm} teste (MSE)
PMC 1	Alternativa 7	0,05	7	Tangente hiperbólica	$3,805 \times 10^{-4}$
PMC 2	Alternativa 6	0,03	1	Tangente hiperbólica	$2,208 \times 10^{-4}$
PMC 3	Alternativa 8	0,03	3	Tangente hiperbólica	$8,393 \times 10^{-4}$
PMC 4	Alternativa 6	0,03	1	Tangente hiperbólica	$1,591 \times 10^{-4}$
PMC 5	Alternativa 10	0,05	6	Tangente hiperbólica	$5,116 \times 10^{-4}$
PMC 6	Alternativa 7	0,03	3	Tangente hiperbólica	$1,432 \times 10^{-8}$
PMC 7	Alternativa 6	0,05	3	Tangente hiperbólica	$6,9297 \times 10^{-5}$

Fonte: Proposto pelo autor.

Embora a quantidade de neurônios usados nas camadas intermediárias de cada modelo seja diferente, na maioria dos modelos mostrou-se mais adequado utilizar uma

quantidade de neurônios menor que o número de variáveis de entrada. Outra constatação é que a função tangente hiperbólica produziu melhores resultados que a função logística em todos os modelos PMC implementados.

Dentre as configurações topológicas selecionadas, aquela correspondente ao PMC 3 apresentou a menor capacidade de predição. Mesmo utilizando dois modelos de rede (PMC 2 e 3) para calcular o valor do indicador *return on working capital*, não foi possível obter um alto índice de precisão na predição deste indicador. Isso pode ser atribuído ao fato de que, dentre os modelos implementados para prever os valores dos indicadores de nível 1 do SCOR®, somente o modelo PMC 3 está incumbido de modelar um relacionamento não linear entre as variáveis de entrada e saída, o que é mais complexo e difícil de quantificar precisamente.

Sobre a aplicação da técnica de validação cruzada, com o objetivo de alcançar um E_{qm} satisfatório na etapa de teste, foi necessário aumentar consideravelmente o número de amostras usadas no treinamento em relação à quantidade inicial definida para cada modelo (aproximadamente quatro vezes o número de pesos sinápticos da rede). Após reiniciar diversas vezes os processos de treinamento usando uma quantidade de amostras cada vez maior, verificou-se que os melhores resultados eram obtidos usando uma quantidade de amostras aproximadamente dez vezes maior que a quantidade inicialmente definida com base na literatura. Desta forma, ressalta-se que os valores mostrados na Tabela 1 da seção 4.2.1 (p. 172) não foram definidos arbitrariamente, posto que foram resultantes de um longo e iterativo processo de modelagem e simulação computacional.

Além do dimensionamento do número de amostras usadas no processo de treinamento, outro fator que contribuiu para a repetição do treinamento de vários modelos foi a necessidade de ajustar o valor da taxa de aprendizagem. Conforme o esquema mostrado na Figura 59 (p. 165), como os modelos PMC 1, 5 e 7 não alcançaram uma capacidade de predição satisfatória quando utilizando o valor padrão inicial definido para a taxa de aprendizagem ($\eta = 0,03$), foi necessário redefinir o valor desse parâmetro e reiniciar o treinamento. Desta forma, nesses três modelos, o uso de $\eta = 0,05$ produziu resultados mais satisfatórios, aumentando significativamente a capacidade de predição.

Na tentativa de melhorar a precisão das estimativas na etapa de teste, além de redimensionar a quantidade de amostras e variar o valor da taxa de aprendizagem, nas topologias referentes ao modelo PMC 3 foi testado o uso das funções de ativação logística e tangente hiperbólica na camada de saída. Contudo, como a adoção de ambas as funções

produziu resultados piores do que aqueles anteriormente gerados utilizando a função de ativação linear, manteve-se o uso da função de ativação linear nos neurônios da camada de saída de todos os modelos PMC.

Portanto, embora na Subseção 4.2.3 tenham sido apresentados os resultados de apenas 210 processos de treinamento e de teste, foram realizados mais de 400 treinamentos de modelos de rede neural para que fosse possível ajustar a taxa de treinamento, definir uma quantidade adequada de amostras e alcançar uma capacidade de predição satisfatória na etapa de teste.

4.3 IMPLEMENTAÇÃO COMPUTACIONAL DOS MODELOS BASEADOS EM ANFIS

4.3.1 Organização das amostras

Os subconjuntos de amostras utilizados no treinamento dos modelos ANFIS são iguais em tamanho e conteúdo aos subconjuntos usados no treinamento dos modelos PMC, cujo o processo de organização das amostras está descrito na Subseção 4.2.1 deste capítulo. Além de poupar tempo na modelagem e no treinamento, a adoção de subconjuntos de amostras idênticos àqueles usados no treinamento dos modelos PMC tem o objetivo de minizar a influência das características das amostras sobre a avaliação da capacidade de predição de cada técnica. Desta forma, no processo de aprendizagem supervisionada dos modelos ANFIS, manteve-se a definição dos valores das amostras no universo de discurso $[0, 1]$ e o uso de 70% dos dados para o subconjunto de treinamento, 15% para o subconjunto de validação e 15% para o subconjunto de teste.

4.3.2 Definição das topologias candidatas aos modelos ANFIS

O Quadro 25 descreve as configurações topológicas definidas para os 56 modelos ANFIS implementados neste estudo. Como pode ser visto, para cada modelo ANFIS, foram testadas 8 alternativas de configuração topológica, constituídas a partir da variação do tipo de função de pertinência das variáveis de entrada, do operador responsável por efetuar as operações do tipo “AND” na parte antecedente das regras de decisão, e também do tipo de consequente usado nestas regras.

Quadro 25 – Alternativas avaliadas para definição da configuração topológica dos sistemas ANFIS

Modelo de predição	Topologias candidatas	Tipo de função de pertinência	Operador para os conectivos lógicos	Tipo de consequente das regras de inferência
Modelo ANFIS 1	Alternativa 1	Triangular	Mínimo	Função linear
	Alternativa 2	Triangular	Mínimo	Valor <i>crisp</i> constante
	Alternativa 3	Triangular	Produto	Função linear
	Alternativa 4	Triangular	Produto	Valor <i>crisp</i> constante
	Alternativa 5	Gaussiana	Mínimo	Função linear
	Alternativa 6	Gaussiana	Mínimo	Valor <i>crisp</i> constante
	Alternativa 7	Gaussiana	Produto	Função linear
	Alternativa 8	Gaussiana	Produto	Valor <i>crisp</i> constante
Modelo ANFIS 2	Alternativa 1	Triangular	Mínimo	Função linear
	Alternativa 2	Triangular	Mínimo	Valor <i>crisp</i> constante
	Alternativa 3	Triangular	Produto	Função linear
	Alternativa 4	Triangular	Produto	Valor <i>crisp</i> constante
	Alternativa 5	Gaussiana	Mínimo	Função linear
	Alternativa 6	Gaussiana	Mínimo	Valor <i>crisp</i> constante
	Alternativa 7	Gaussiana	Produto	Função linear
	Alternativa 8	Gaussiana	Produto	Valor <i>crisp</i> constante
Modelo ANFIS 3	Alternativa 1	Triangular	Mínimo	Função linear
	Alternativa 2	Triangular	Mínimo	Valor <i>crisp</i> constante
	Alternativa 3	Triangular	Produto	Função linear
	Alternativa 4	Triangular	Produto	Valor <i>crisp</i> constante
	Alternativa 5	Gaussiana	Mínimo	Função linear
	Alternativa 6	Gaussiana	Mínimo	Valor <i>crisp</i> constante
	Alternativa 7	Gaussiana	Produto	Função linear
	Alternativa 8	Gaussiana	Produto	Valor <i>crisp</i> constante
Modelo ANFIS 4	Alternativa 1	Triangular	Mínimo	Função linear
	Alternativa 2	Triangular	Mínimo	Valor <i>crisp</i> constante
	Alternativa 3	Triangular	Produto	Função linear
	Alternativa 4	Triangular	Produto	Valor <i>crisp</i> constante
	Alternativa 5	Gaussiana	Mínimo	Função linear
	Alternativa 6	Gaussiana	Mínimo	Valor <i>crisp</i> constante
	Alternativa 7	Gaussiana	Produto	Função linear
	Alternativa 8	Gaussiana	Produto	Valor <i>crisp</i> constante
Modelo ANFIS 5	Alternativa 1	Triangular	Mínimo	Função linear
	Alternativa 2	Triangular	Mínimo	Valor <i>crisp</i> constante
	Alternativa 3	Triangular	Produto	Função linear

Modelo de predição	Topologias candidatas	Tipo de função de pertinência	Operador para os conectivos lógicos	Tipo de consequente das regras de inferência
	Alternativa 4	Triangular	Produto	Valor <i>crisp</i> constante
	Alternativa 5	Gaussiana	Mínimo	Função linear
	Alternativa 6	Gaussiana	Mínimo	Valor <i>crisp</i> constante
	Alternativa 7	Gaussiana	Produto	Função linear
	Alternativa 8	Gaussiana	Produto	Valor <i>crisp</i> constante
Modelo ANFIS 6	Alternativa 1	Triangular	Mínimo	Função linear
	Alternativa 2	Triangular	Mínimo	Valor <i>crisp</i> constante
	Alternativa 3	Triangular	Produto	Função linear
	Alternativa 4	Triangular	Produto	Valor <i>crisp</i> constante
	Alternativa 5	Gaussiana	Mínimo	Função linear
	Alternativa 6	Gaussiana	Mínimo	Valor <i>crisp</i> constante
	Alternativa 7	Gaussiana	Produto	Função linear
	Alternativa 8	Gaussiana	Produto	Valor <i>crisp</i> constante
Modelo ANFIS 7	Alternativa 1	Triangular	Mínimo	Função linear
	Alternativa 2	Triangular	Mínimo	Valor <i>crisp</i> constante
	Alternativa 3	Triangular	Produto	Função linear
	Alternativa 4	Triangular	Produto	Valor <i>crisp</i> constante
	Alternativa 5	Gaussiana	Mínimo	Função linear
	Alternativa 6	Gaussiana	Mínimo	Valor <i>crisp</i> constante
	Alternativa 7	Gaussiana	Produto	Função linear
	Alternativa 8	Gaussiana	Produto	Valor <i>crisp</i> constante

Fonte: Proposto pelo autor.

Assim como no desenvolvimento dos modelos PMC, as escolhas feitas na modelagem se basearam nas características do problema de predição de desempenho baseada nos indicadores do SCOR[®]. Neste sentido, todas as topologias candidatas aos modelos ANFIS possuem apenas uma variável de saída. No particionamento das variáveis de entrada, foram avaliadas funções triangulares e gaussianas por estas serem mais sensíveis a variações nos valores dos indicadores de desempenho. Com base em Altrock (1995), a quantidade de funções de pertinência usadas nas variáveis de entrada foi definida inicialmente como três. Todavia, conforme previsto no processo de validação cruzada representado na Figura 61 da Subseção 4.1, o valor desse parâmetro sofreu variações ao longo do processo de implementação computacional diante da necessidade de se obter uma melhor capacidade de predição e de se evitar um número excessivo de regras de decisão.

Para efetuar as operações do tipo “AND”, com base em Jang (1993), testou-se os operadores mínimo (Equação 40, p. 139) e produto algébrico (Equação 43). Em relação ao tipo de consequente das regras de inferência, testou-se o uso de funções lineares e de valores *crisp* constantes. Seguindo o modelo ANFIS original proposto por Jang (1993), utilizou-se o operador média ponderada (Equação 58) para agregar os resultados das regras em todos os modelos ANFIS implementados.

4.3.3 Planejamento do processo de treinamento dos modelos ANFIS

Conforme mencionado na Subseção 4.2.3 deste capítulo, para treinar os modelos ANFIS, adotou-se o método tradicionalmente usado neste tipo de sistema, proposto na publicação original dos sistemas ANFIS (JANG, 1993), que é uma combinação entre o *backpropagation*, usado nos modelos PMC, e o método dos mínimos quadrados. Enquanto o *backpropagation* é usado para ajustar os parâmetros das funções de pertinência das variáveis de entrada (parâmetros de premissa), o método dos mínimos quadrados é usado para ajustar os parâmetros do consequente de cada uma das regras de inferência.

Os subconjuntos de amostras utilizados no treinamento dos modelos ANFIS foram os mesmos utilizados no treinamento dos modelos PMC. Dessa forma, a seleção das amostras para compor os subconjuntos de treinamento também foi feita usando o método de amostragem aleatória (*random subsampling cross-validation*), com três ensaios por topologia candidata. Em cada ensaio, há variação apenas das amostras utilizadas em cada subconjunto. Diferentemente dos modelos PMC, os modelos ANFIS não possuem parâmetros adaptivos cujos valores iniciais sejam definidos aleatoriamente.

Em relação à taxa de aprendizagem, foi adotado o valor $\eta = 0,01$ em todos os ensaios realizados. O principal motivo desta escolha foi que, na ferramenta *fuzzy toolbox* do MATLAB, utilizada nesta etapa do estudo, o valor da taxa de aprendizagem é definido por padrão como 0,01 e não é possível escolher outro valor. Apesar dessa falta de flexibilidade da ferramenta computacional, o uso de $\eta = 0,01$ produziu resultados satisfatórios e não houve a necessidade de adotar um valor diferente.

Sobre os critérios de parada adotados para o algoritmo de treinamento, assim como no treinamento dos modelos PMC, o valor de ε foi parametrizado como 0 (zero). Quanto ao número máximo de épocas, escolheu-se inicialmente o mesmo valor usado no treinamento dos modelos PMC (20.000 épocas). Contudo, após a realização de diversos treinamentos, percebeu-se que o processo de convergência dos modelos ANFIS requer

uma quantidade muito menor de épocas, estabilizando na maioria das vezes ao longo de uma ou duas dezenas de épocas. Diante disso, com a finalidade de poupar tempo durante o processo de treinamento dos modelos ANFIS, todavia sem causar prejuízo na precisão alcançada por estes, adotou-se o valor 200 como o número máximo de épocas de treinamento.

Por último, sobre o critério de aceitação da capacidade de predição dos modelos ANFIS, baseando-se em Jassbi, Seyedhosseini e Pilevari (2010) e em Fan et al., (2013), foi adotado o mesmo valor usado na implementação dos modelos PMC. Portanto, o valor máximo aceitável para o E_{qm} na etapa de teste foi definido como 1×10^{-3} .

4.3.4 Resultados do treinamento e da validação dos modelos ANFIS

Conforme descrito no Quadro 25, um conjunto de 56 topologias candidatas aos modelos ANFIS foi implementado, sendo realizados três ensaios de treinamento e teste por topologia. O número de funções de pertinência usado em cada variável de entrada foi definido inicialmente como três. Como o modelo de predição ANFIS 1 possui 8 variáveis de entrada, 6.561 regras de decisão (3^8) foram geradas para cada sistema. Contudo, em todas as tentativas de treinamento realizadas usando tais modelos, o número excessivo de parâmetros em cada sistema aumentou drasticamente o tempo computacional do processo de aprendizagem, de modo que o processamento de uma época passou a consumir mais de 10 minutos. Além de consumir muito tempo no treinamento, o uso de três funções de pertinência nas variáveis de entrada implicou em uma sobrecarga de processamento que gerou alguns travamentos no sistema operacional. Diante do exposto, optou-se por reconstruir os modelos ANFIS 1 utilizando apenas 2 funções de pertinência para cada variável de entrada, totalizando assim 256 regras (2^8).

A Tabela 10 apresenta os resultados obtidos por meio da implementação computacional das topologias candidatas ao modelo ANFIS 1, cujo o papel é a predição dos valores do indicador *total cost to serve*. Os valores apresentados na Tabela 10 foram computados utilizando 2 funções de pertinência nas variáveis de entrada. Novamente, foram calculados o E_{qm} de treinamento, o E_{qm} de teste e os valores médios obtidos ao longo dos três ensaios realizados para cada topologia candidata. Dentre as topologias candidatas ao modelo ANFIS 1, a alternativa 4 foi a que alcançou a menor média dos erros quadráticos médios na etapa de teste, equivalente a $4,4936 \times 10^{-11}$. Esse valor é muito superior ao nível de precisão mínimo requerido neste estudo. Desta forma, o

modelo ANFIS 1 deve utilizar funções de pertinência do tipo triangular nas variáveis de entrada, operador produto algébrico e consequente do tipo constante.

Tabela 10 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 1

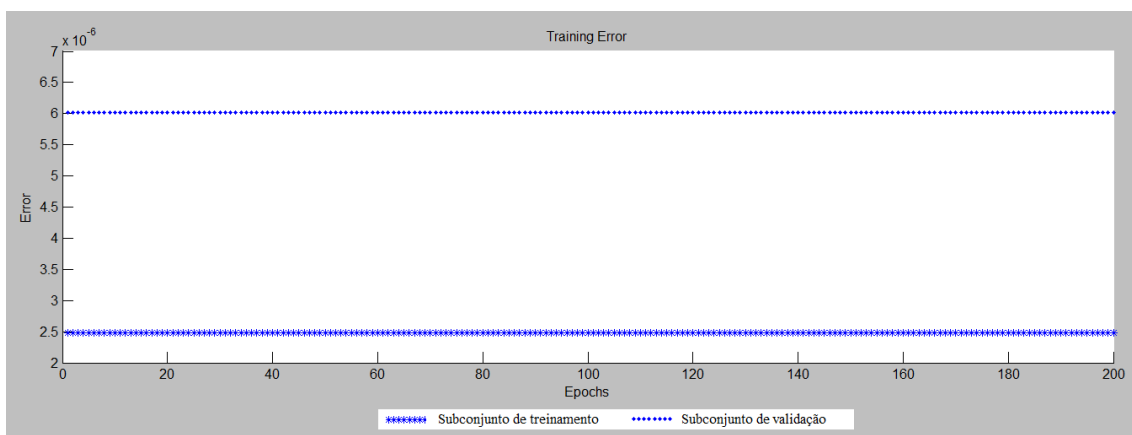
Topologias		E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$2,2970 \times 10^{-10}$	$4,6066 \times 10^{-4}$
	Ensaio 2	$2,4939 \times 10^{-10}$	$1,1757 \times 10^{-5}$
	Ensaio 3	$3,0702 \times 10^{-10}$	$3,6126 \times 10^{-5}$
	Média	$2,6105 \times 10^{-10}$	$1,0611 \times 10^{-6}$
Alternativa 2	Ensaio 1	$1,5941 \times 10^{-1}$	$1,8456 \times 10^{-1}$
	Ensaio 2	$1,4454 \times 10^{-1}$	$4,4474 \times 10^{-1}$
	Ensaio 3	$1,1557 \times 10^{-1}$	$8,6676 \times 10^{-1}$
	Média	$1,3923 \times 10^{-1}$	$4,5675 \times 10^{-1}$
Alternativa 3	Ensaio 1	$1,4087 \times 10^{-11}$	$5,7573 \times 10^{-5}$
	Ensaio 2	$4,4410 \times 10^{-11}$	$1,0138 \times 10^{-5}$
	Ensaio 3	$4,8186 \times 10^{-11}$	$1,2412 \times 10^{-5}$
	Média	$3,3481 \times 10^{-11}$	$2,2704 \times 10^{-5}$
Alternativa 4	Ensaio 1	$6,1400 \times 10^{-12}$	$7,0997 \times 10^{-11}$
	Ensaio 2	$7,0358 \times 10^{-12}$	$2,5835 \times 10^{-11}$
	Ensaio 3	$7,5873 \times 10^{-12}$	$4,3580 \times 10^{-11}$
	Média	$6,9080 \times 10^{-12}$	$4,4936 \times 10^{-11}$
Alternativa 5	Ensaio 1	$4,5947 \times 10^{-9}$	$7,5592 \times 10^{-4}$
	Ensaio 2	$7,2959 \times 10^{-10}$	$1,8695 \times 10^{-4}$
	Ensaio 3	$1,4759 \times 10^{-9}$	$1,0541 \times 10^{-4}$
	Média	$1,9717 \times 10^{-9}$	$2,6455 \times 10^{-3}$
Alternativa 6	Ensaio 1	$7,9603 \times 10^{-4}$	1,7636
	Ensaio 2	$1,1561 \times 10^{-1}$	$3,9835 \times 10^{-1}$
	Ensaio 3	$1,5084 \times 10^{-1}$	$5,7625 \times 10^{-1}$
	Média	$6,3605 \times 10^{-2}$	$8,2100 \times 10^{-1}$
Alternativa 7	Ensaio 1	$9,4992 \times 10^{-11}$	$1,5510 \times 10^{-2}$
	Ensaio 2	$7,9631 \times 10^{-10}$	$1,9227 \times 10^{-3}$
	Ensaio 3	$7,5295 \times 10^{-10}$	$2,0240 \times 10^{-3}$
	Média	$4,7528 \times 10^{-10}$	$1,1400 \times 10^{-3}$
Alternativa 8	Ensaio 1	$2,8721 \times 10^{-7}$	$1,5821 \times 10^{-3}$
	Ensaio 2	$4,0796 \times 10^{-5}$	$7,6498 \times 10^{-5}$
	Ensaio 3	$4,0311 \times 10^{-5}$	$2,4768 \times 10^{-4}$
	Média	$1,9573 \times 10^{-5}$	$4,5882 \times 10^{-4}$

Fonte: Proposto pelo autor.

A Figura 70 mostra o processo de minimização do erro ao longo de um do treinamentos da topologia escolhida para o modelo ANFIS 1, destacando também o


processo de minimização do erro produzido pela apresentação do subconjunto de validação à rede. Nessa figura, bem como nas outras que contemplam o processo de minimização do erro durante o treinamento dos modelos ANFIS, o valor do erro apresentado no eixo y se refere à raiz do erro quadrático médio (*Root Mean Square Error*, RMSE), e não ao erro quadrático médio (MSE) como apresentado nas figuras referentes aos modelos PMC. Não foi possível gerar gráficos da minimização do erro quadrático médio porque a ferramenta computacional utilizada na implementação não oferece essa funcionalidade. Em relação à avaliação da capacidade de generalização do modelo ANFIS 1, a Figura 71 mostra uma comparação entre os valores esperados (*testing data*) e os valores estimados (*FIS output*) pelo modelo computacional utilizando o subconjunto de teste, composto por 150 amostras. Devido ao alto nível de precisão do modelo em questão, as amostras comparadas se sobrepõem graficamente e não é possível visualizar os desvios entre os valores comparados.

Figura 70 – Processo de minimização do erro (RMSE) do modelo ANFIS 1



Fonte: Proposto pelo autor.

Figura 71 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 1



Fonte: Proposto pelo autor.

A Tabela 11 sintetiza os resultados do treinamento e do teste da capacidade de predição das topologias candidatas ao modelo ANFIS 2. Assim como na modelagem das

redes PMC, os modelos ANFIS 2 e 3 são responsáveis por prever os valores do indicador *return on working capital*. Enquanto o modelo ANFIS 2 realiza operações com os indicadores *inventory*, *accounts receivable* e *accounts payable*, o modelo ANFIS 3 utiliza a saída do ANFIS 2, bem como os valores dos indicadores *supply chain revenue* e *total cost to serve*, para prever o valor do indicador *return on working capital*. Na implementação dos modelos ANFIS 2, testou-se o uso de 2, 3, 4 e 5 funções de pertinência nas variáveis de entrada, sendo que os modelos com 5 funções de pertinência apresentaram os melhores resultados. Portanto, os valores mostrados na Tabela 11 foram calculados usando 5 funções de pertinência nas variáveis de entrada. Novamente, a alternativa 4 foi a configuração topológica que apresentou a menor média dos erros quadráticos médios na etapa de teste, igual a $5,8447 \times 10^{-15}$, o que representa um erro baixíssimo. Desta forma, o modelo ANFIS 2 utilizará funções de pertinência do tipo triangular nas variáveis de entrada, operador produto algébrico e consequente do tipo constante.

Tabela 11 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 2


Topologias		E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$2,5245 \times 10^{-11}$	$2,5245 \times 10^{-11}$
	Ensaio 2	$5,1205 \times 10^{-11}$	$5,1205 \times 10^{-11}$
	Ensaio 3	$4,7251 \times 10^{-11}$	$4,7251 \times 10^{-11}$
	Média	$4,0340 \times 10^{-11}$	$4,0340 \times 10^{-11}$
Alternativa 2	Ensaio 1	$5,8809 \times 10^{-3}$	$5,8809 \times 10^{-3}$
	Ensaio 2	$5,1788 \times 10^{-3}$	$5,1788 \times 10^{-3}$
	Ensaio 3	$5,9463 \times 10^{-3}$	$5,9463 \times 10^{-3}$
	Média	$5,6632 \times 10^{-3}$	$5,6632 \times 10^{-3}$
Alternativa 3	Ensaio 1	$6,3071 \times 10^{-12}$	$6,3071 \times 10^{-12}$
	Ensaio 2	$8,3651 \times 10^{-13}$	$8,3651 \times 10^{-13}$
	Ensaio 3	$6,7774 \times 10^{-13}$	$6,7774 \times 10^{-13}$
	Média	$2,0062 \times 10^{-12}$	$2,0062 \times 10^{-12}$
Alternativa 4	Ensaio 1	$7,2106 \times 10^{-15}$	$7,2106 \times 10^{-15}$
	Ensaio 2	$4,8284 \times 10^{-15}$	$4,8284 \times 10^{-15}$
	Ensaio 3	$5,6175 \times 10^{-15}$	$5,6175 \times 10^{-15}$
	Média	$5,8447 \times 10^{-15}$	$5,8447 \times 10^{-15}$
Alternativa 5	Ensaio 1	$4,8281 \times 10^{-10}$	$4,8281 \times 10^{-10}$
	Ensaio 2	$3,2249 \times 10^{-10}$	$3,2249 \times 10^{-10}$
	Ensaio 3	$2,6962 \times 10^{-10}$	$2,6962 \times 10^{-10}$
	Média	$3,5283 \times 10^{-10}$	$3,5283 \times 10^{-10}$
Alternativa 6	Ensaio 1	$2,4887 \times 10^{-3}$	$2,4887 \times 10^{-3}$

Topologias		E_{qm} treinamento	E_{qm} teste
	Ensaio 2	$2,4586 \times 10^{-3}$	$2,4586 \times 10^{-3}$
	Ensaio 3	$2,4743 \times 10^{-3}$	$2,4743 \times 10^{-3}$
	Média	$2,4738 \times 10^{-3}$	$2,4738 \times 10^{-3}$
Alternativa 7	Ensaio 1	$2,9467 \times 10^{-10}$	$2,9467 \times 10^{-10}$
	Ensaio 2	$1,2159 \times 10^{-10}$	$1,2159 \times 10^{-10}$
	Ensaio 3	$3,3394 \times 10^{-10}$	$3,3394 \times 10^{-10}$
	Média	$2,3991 \times 10^{-10}$	$2,3991 \times 10^{-10}$
Alternativa 8	Ensaio 1	$7,4720 \times 10^{-7}$	$7,4720 \times 10^{-7}$
	Ensaio 2	$5,4873 \times 10^{-6}$	$5,4873 \times 10^{-6}$
	Ensaio 3	$1,0933 \times 10^{-5}$	$1,0933 \times 10^{-5}$
	Média	$4,7138 \times 10^{-6}$	$4,7138 \times 10^{-6}$

Fonte: Proposto pelo autor.


A Figura 72 representa o processo de minimização da raiz do erro quadrático médio ao longo de um dos treinamentos da topologia escolhida para o modelo ANFIS 2. Já a Figura 73 mostra os resultados da avaliação da capacidade de generalização do modelo ANFIS 2, comparando os valores esperados (*testing data*) com os valores estimados (*FIS output*) de 75 amostras.

Figura 72 – Processo de minimização do erro (RMSE) do modelo ANFIS 2



Fonte: Proposto pelo autor.

Figura 73 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 2



Fonte: Proposto pelo autor.


A Tabela 12 apresenta os resultados do treinamento e do teste das topologias candidatas ao modelo ANFIS 3. Os valores apresentados na Tabela 10 foram computados utilizando 4 funções de pertinência nas variáveis de entrada, pois esta configuração apresentou melhores resultados que o uso de 2, 3 ou 5 funções. Dentre as topologias candidatas avaliadas, a alternativa 7 foi a que alcançou a menor média dos erros quadráticos médios na etapa de teste, equivalente a $3,6508 \times 10^{-7}$, atingindo assim um nível de precisão satisfatório. Portanto, no modelo ANFIS 3 serão usadas funções de pertinência do tipo gaussiana nas variáveis de entrada, bem como o operador produto algébrico e consequente do tipo linear. A Figura 74 ilustra o processo de minimização da raiz do erro quadrático médio durante um dos treinamentos da topologia selecionada para o modelo ANFIS 3. A Figura 75 mostra os resultados da comparação entre os valores esperados (*testing data*) e os valores estimados (*FIS output*) de 75 amostras. Novamente, a sobreposição das amostras evidencia a alta capacidade de predição desse modelo.

Tabela 12 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 3

Topologias		E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$5,7547 \times 10^{-5}$	$2,1874 \times 10^{-6}$
	Ensaio 2	$1,7665 \times 10^{-4}$	$1,0126 \times 10^{-4}$
	Ensaio 3	$1,1638 \times 10^{-4}$	$4,8629 \times 10^{-4}$
	Média	$1,1141 \times 10^{-4}$	$1,2540 \times 10^{-4}$
Alternativa 2	Ensaio 1	$1,1418 \times 10^{-3}$	$1,4078 \times 10^{-3}$
	Ensaio 2	$6,1415 \times 10^{-4}$	$5,6482 \times 10^{-4}$
	Ensaio 3	$1,7879 \times 10^{-3}$	$3,2309 \times 10^{-3}$
	Média	$1,1302 \times 10^{-3}$	$1,5504 \times 10^{-3}$
Alternativa 3	Ensaio 1	$6,4262 \times 10^{-6}$	$5,7003 \times 10^{-5}$
	Ensaio 2	$1,7665 \times 10^{-4}$	$1,0126 \times 10^{-4}$
	Ensaio 3	$1,6132 \times 10^{-4}$	$1,3444 \times 10^{-4}$
	Média	$9,0421 \times 10^{-5}$	$9,4790 \times 10^{-5}$
Alternativa 4	Ensaio 1	$1,5603 \times 10^{-3}$	$2,0106 \times 10^{-3}$
	Ensaio 2	$6,1415 \times 10^{-4}$	$5,6482 \times 10^{-4}$
	Ensaio 3	$6,8833 \times 10^{-4}$	$1,2844 \times 10^{-3}$
	Média	$9,1039 \times 10^{-4}$	$1,2121 \times 10^{-3}$
Alternativa 5	Ensaio 1	$8,9529 \times 10^{-5}$	$2,7789 \times 10^{-4}$
	Ensaio 2	$1,7474 \times 10^{-4}$	$1,2410 \times 10^{-4}$
	Ensaio 3	$2,1756 \times 10^{-4}$	$1,6989 \times 10^{-4}$
	Média	$1,5568 \times 10^{-4}$	$1,8536 \times 10^{-4}$
Alternativa 6	Ensaio 1	$2,3474 \times 10^{-3}$	$2,3310 \times 10^{-3}$
	Ensaio 2	$4,2267 \times 10^{-3}$	$3,4466 \times 10^{-3}$
	Ensaio 3	$3,8988 \times 10^{-3}$	$6,6476 \times 10^{-3}$
	Média	$3,4380 \times 10^{-3}$	$3,9489 \times 10^{-3}$
Alternativa 7	Ensaio 1	$8,0089 \times 10^{-8}$	$6,4786 \times 10^{-7}$
	Ensaio 2	$2,1120 \times 10^{-7}$	$2,6104 \times 10^{-7}$
	Ensaio 3	$1,7221 \times 10^{-7}$	$2,4684 \times 10^{-7}$
	Média	$1,4888 \times 10^{-7}$	$3,6508 \times 10^{-7}$
Alternativa 8	Ensaio 1	$1,6410 \times 10^{-4}$	$1,2814 \times 10^{-4}$
	Ensaio 2	$1,2221 \times 10^{-4}$	$9,1252 \times 10^{-5}$
	Ensaio 3	$1,4552 \times 10^{-4}$	$1,5997 \times 10^{-4}$
	Média	$1,4342 \times 10^{-4}$	$1,2485 \times 10^{-4}$

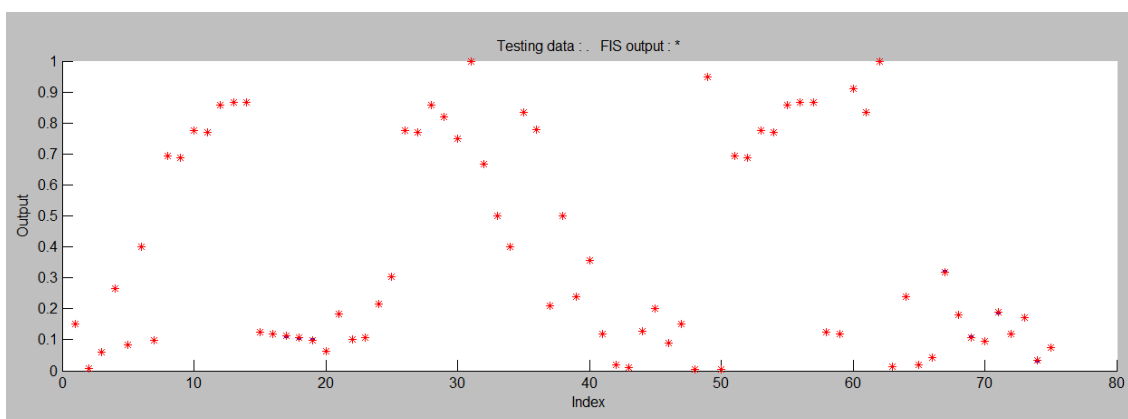
Fonte: Proposto pelo autor.

Figura 74 – Processo de minimização do erro (RMSE) do modelo ANFIS 3



Fonte: Proposto pelo autor.

Figura 75 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 3



Fonte: Proposto pelo autor.

A Tabela 13 apresenta os resultados obtidos pelas topologias candidatas ao modelo ANFIS 4 em relação ao processo de treinamento e teste da capacidade de generalização. Essas topologias estão incumbidas de prever o valor do indicador *cash-to-cash cycle time*. Para computar os valores apresentados na Tabela 13, em cada variável de entrada foram utilizadas 3 funções de pertinência. A alternativa 4 alcançou a menor média dos erros quadráticos médios na etapa de teste ($1,1935 \times 10^{-13}$), embora a configuração topológica representada pela alternativa 3 também tenha atingido um nível de precisão bastante satisfatório ($4,8616 \times 10^{-13}$). Portanto, no modelo ANFIS 4 serão usadas funções de pertinência do tipo triangular nas variáveis de entrada, operador do tipo produto algébrico e consequente do tipo constante nas regras de inferência. A Figura 76 mostra o processo de minimização da raiz do erro quadrático médio durante um dos


treinamentos da alternativa 4. Já a Figura 77 mostra os resultados da comparação entre os valores esperados (*testing data*) e os valores estimados (*FIS output*) para 75 amostras.

Tabela 13 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 4

Topologias		E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$7,1145 \times 10^{-12}$	$2,1425 \times 10^{-11}$
	Ensaio 2	$7,0522 \times 10^{-12}$	$2,5514 \times 10^{-11}$
	Ensaio 3	$6,4760 \times 10^{-12}$	$1,7528 \times 10^{-11}$
	Média	$6,8779 \times 10^{-12}$	$2,1364 \times 10^{-11}$
Alternativa 2	Ensaio 1	$4,6872 \times 10^{-4}$	$9,4108 \times 10^{-4}$
	Ensaio 2	$5,3787 \times 10^{-4}$	$5,9219 \times 10^{-4}$
	Ensaio 3	$5,1357 \times 10^{-4}$	$6,6332 \times 10^{-4}$
	Média	$5,0631 \times 10^{-4}$	$7,2481 \times 10^{-4}$
Alternativa 3	Ensaio 1	$2,8518 \times 10^{-13}$	$5,6369 \times 10^{-13}$
	Ensaio 2	$2,9495 \times 10^{-13}$	$5,2432 \times 10^{-13}$
	Ensaio 3	$2,5078 \times 10^{-13}$	$3,8053 \times 10^{-13}$
	Média	$2,7664 \times 10^{-13}$	$4,8616 \times 10^{-13}$
Alternativa 4	Ensaio 1	$1,0435 \times 10^{-13}$	$1,1152 \times 10^{-13}$
	Ensaio 2	$1,0050 \times 10^{-13}$	$1,2548 \times 10^{-13}$
	Ensaio 3	$1,0197 \times 10^{-13}$	$1,2128 \times 10^{-13}$
	Média	$1,0227 \times 10^{-13}$	$1,1935 \times 10^{-13}$
Alternativa 5	Ensaio 1	$9,1518 \times 10^{-12}$	$3,6354 \times 10^{-11}$
	Ensaio 2	$2,5207 \times 10^{-11}$	$8,8443 \times 10^{-11}$
	Ensaio 3	$1,4485 \times 10^{-11}$	$2,0780 \times 10^{-11}$
	Média	$1,5607 \times 10^{-11}$	$4,4410 \times 10^{-11}$
Alternativa 6	Ensaio 1	$2,1706 \times 10^{-4}$	$3,0172 \times 10^{-4}$
	Ensaio 2	$2,4044 \times 10^{-4}$	$2,8036 \times 10^{-4}$
	Ensaio 3	$2,2500 \times 10^{-4}$	$1,8890 \times 10^{-4}$
	Média	$2,2740 \times 10^{-4}$	$2,5449 \times 10^{-4}$
Alternativa 7	Ensaio 1	$1,1468 \times 10^{-11}$	$4,3001 \times 10^{-11}$
	Ensaio 2	$1,2194 \times 10^{-11}$	$3,6713 \times 10^{-11}$
	Ensaio 3	$1,1870 \times 10^{-11}$	$2,6363 \times 10^{-11}$
	Média	$1,1842 \times 10^{-11}$	$3,5011 \times 10^{-11}$
Alternativa 8	Ensaio 1	$9,5828 \times 10^{-7}$	$1,1278 \times 10^{-6}$
	Ensaio 2	$9,3937 \times 10^{-7}$	$9,4920 \times 10^{-7}$
	Ensaio 3	$1,0233 \times 10^{-6}$	$9,9072 \times 10^{-5}$
	Média	$9,7333 \times 10^{-7}$	$1,5973 \times 10^{-5}$


Fonte: Proposto pelo autor.

Figura 76 – Processo de minimização do erro (RMSE) do modelo ANFIS 4



Fonte: Proposto pelo autor.

Figura 77 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 4



Fonte: Proposto pelo autor.


A Tabela 14 sintetiza os resultados obtidos a partir do treinamento e do teste das topologias candidatas ao modelo ANFIS 5, responsável pela predição dos valores do indicador *order fulfillment cycle time*. Para calcular os valores apresentados nessa tabela, utilizou-se 2 funções de pertinência para cada variável de entrada, uma vez que essa configuração produziu o menor erro ao mesmo tempo em que evitou o uso de uma grande de regras de inferência. Mais uma vez, a alternativa 4 alcançou a menor média dos erros quadráticos médios na etapa de teste ($1,68 \times 10^{-10}$), embora as configurações topológicas representadas pelas alternativas 1, 3, 5 e 7 também tenham alcançado uma alta capacidade de generalização. Diante disso, o modelo ANFIS 4 utilizará funções de pertinência do tipo triangular nas variáveis de entrada, operador do tipo produto algébrico e consequente do tipo constante. A Figura 78 mostra o processo de minimização da raiz do erro quadrático médio durante um dos treinamentos da alternativa 4. Já a Figura 79 mostra os resultados da comparação dos valores esperados (*testing data*) com os valores estimados (*FIS output*) para 75 amostras.

Tabela 14 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 5

Topologias		E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$1,1278 \times 10^{-10}$	$2,8686 \times 10^{-10}$
	Ensaio 2	$1,3062 \times 10^{-10}$	$1,6825 \times 10^{-10}$
	Ensaio 3	$1,2381 \times 10^{-10}$	$1,6812 \times 10^{-10}$
	Média	$1,2229 \times 10^{-10}$	$2,0424 \times 10^{-10}$
Alternativa 2	Ensaio 1	$1,3312 \times 10^{-3}$	$4,0420 \times 10^{-3}$
	Ensaio 2	$1,8006 \times 10^{-3}$	$1,8602 \times 10^{-3}$
	Ensaio 3	$1,8812 \times 10^{-3}$	$1,4560 \times 10^{-3}$
	Média	$1,6617 \times 10^{-3}$	$2,3317 \times 10^{-3}$
Alternativa 3	Ensaio 1	$1,2221 \times 10^{-10}$	$2,7576 \times 10^{-10}$
	Ensaio 2	$1,4441 \times 10^{-10}$	$1,5188 \times 10^{-10}$
	Ensaio 3	$1,3882 \times 10^{-10}$	$1,6731 \times 10^{-10}$
	Média	$1,3498 \times 10^{-10}$	$1,9474 \times 10^{-10}$
Alternativa 4	Ensaio 1	$1,4378 \times 10^{-10}$	$2,3614 \times 10^{-10}$
	Ensaio 2	$1,6440 \times 10^{-10}$	$1,4083 \times 10^{-10}$
	Ensaio 3	$1,5720 \times 10^{-10}$	$1,3575 \times 10^{-10}$
	Média	$1,5501 \times 10^{-10}$	$1,6800 \times 10^{-10}$
Alternativa 5	Ensaio 1	$1,0750 \times 10^{-10}$	$2,9162 \times 10^{-10}$
	Ensaio 2	$1,3074 \times 10^{-10}$	$1,7967 \times 10^{-10}$
	Ensaio 3	$1,2535 \times 10^{-10}$	$1,5455 \times 10^{-10}$
	Média	$1,2099 \times 10^{-10}$	$2,0461 \times 10^{-10}$
Alternativa 6	Ensaio 1	$4,0739 \times 10^{-4}$	$5,8792 \times 10^{-4}$
	Ensaio 2	$4,4054 \times 10^{-4}$	$4,8382 \times 10^{-4}$
	Ensaio 3	$4,5531 \times 10^{-4}$	$3,8557 \times 10^{-4}$
	Média	$4,3418 \times 10^{-4}$	$4,8223 \times 10^{-4}$
Alternativa 7	Ensaio 1	$1,0580 \times 10^{-10}$	$3,0793 \times 10^{-10}$
	Ensaio 2	$1,2807 \times 10^{-10}$	$1,6796 \times 10^{-10}$
	Ensaio 3	$1,1244 \times 10^{-10}$	$1,5723 \times 10^{-10}$
	Média	$1,1525 \times 10^{-10}$	$2,0589 \times 10^{-10}$
Alternativa 8	Ensaio 1	$2,0130 \times 10^{-6}$	$3,5661 \times 10^{-6}$
	Ensaio 2	$2,0584 \times 10^{-6}$	$2,4420 \times 10^{-6}$
	Ensaio 3	$2,0366 \times 10^{-6}$	$1,9904 \times 10^{-6}$
	Média	$2,0359 \times 10^{-6}$	$2,6265 \times 10^{-6}$


Fonte: Proposto pelo autor.

Figura 78 – Processo de minimização do erro (RMSE) do modelo ANFIS 5



Fonte: Proposto pelo autor.

Figura 79 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 5



Fonte: Proposto pelo autor.

A Tabela 15 mostra os resultados obtidos pelas topologias candidatas ao modelo ANFIS 6 durante o treinamento e o teste da capacidade de generalização. Essas topologias realizam a predição do indicador *perfect order fulfillment*. Após testar o uso de 2, 3 e 4 funções de pertinência nas variáveis de entrada, optou-se por manter o uso de 2 funções por esta configuração produzir melhores resultados. Apesar de todas as configurações topológicas avaliadas terem alcançado um alto nível de precisão nas estimativas, a alternativa 7 apresentou a menor média dos erros quadráticos médios na etapa de teste ($1,9203 \times 10^{-16}$). Portanto, o modelo ANFIS 6 será composto de funções de pertinência do tipo gassiana nas variáveis de entrada, operador do tipo produto algébrico e regras de inferência com consequente do tipo função linear. A Figura 80 ilustra o processo de minimização da raiz do erro quadrático médio durante um dos treinamentos da configuração topológica selecionada. A Figura 81 mostra os resultados da comparação entre os valores esperados (*testing data*) e os valores estimados (*FIS output*) de 45


amostras. Mais uma vez, os valores representados na figura se sobrepõem devido à alta precisão das estimativas fornecidas.

Tabela 15 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 6

		$E_{qm \text{ treinamento}}$	$E_{qm \text{ teste}}$
Alternativa 1	Ensaio 1	$1,5638 \times 10^{-16}$	$1,7002 \times 10^{-16}$
	Ensaio 2	$1,7224 \times 10^{-16}$	$2,3247 \times 10^{-16}$
	Ensaio 3	$1,6582 \times 10^{-16}$	$2,0492 \times 10^{-16}$
	Média	$1,6475 \times 10^{-16}$	$2,0165 \times 10^{-16}$
Alternativa 2	Ensaio 1	$1,4644 \times 10^{-15}$	$1,5025 \times 10^{-15}$
	Ensaio 2	$1,6196 \times 10^{-15}$	$2,0625 \times 10^{-15}$
	Ensaio 3	$1,6126 \times 10^{-15}$	$1,9195 \times 10^{-15}$
	Média	$1,5647 \times 10^{-15}$	$1,8201 \times 10^{-15}$
Alternativa 3	Ensaio 1	$1,5495 \times 10^{-16}$	$1,6973 \times 10^{-16}$
	Ensaio 2	$1,6814 \times 10^{-16}$	$2,2267 \times 10^{-16}$
	Ensaio 3	$1,6233 \times 10^{-16}$	$1,9152 \times 10^{-16}$
	Média	$1,6176 \times 10^{-16}$	$1,9404 \times 10^{-16}$
Alternativa 4	Ensaio 1	$1,3251 \times 10^{-15}$	$1,4553 \times 10^{-15}$
	Ensaio 2	$1,4349 \times 10^{-15}$	$1,7454 \times 10^{-15}$
	Ensaio 3	$1,4132 \times 10^{-15}$	$1,5832 \times 10^{-15}$
	Média	$1,3906 \times 10^{-15}$	$1,5924 \times 10^{-15}$
Alternativa 5	Ensaio 1	$1,6407 \times 10^{-16}$	$3,0755 \times 10^{-16}$
	Ensaio 2	$3,1325 \times 10^{-16}$	$3,9422 \times 10^{-16}$
	Ensaio 3	$3,0772 \times 10^{-16}$	$3,2775 \times 10^{-16}$
	Média	$2,5653 \times 10^{-16}$	$3,4220 \times 10^{-16}$
Alternativa 6	Ensaio 1	$2,6997 \times 10^{-15}$	$2,8216 \times 10^{-15}$
	Ensaio 2	$3,3519 \times 10^{-15}$	$5,2894 \times 10^{-15}$
	Ensaio 3	$3,0917 \times 10^{-15}$	$4,1878 \times 10^{-15}$
	Média	$3,0418 \times 10^{-15}$	$4,0348 \times 10^{-15}$
Alternativa 7	Ensaio 1	$1,6083 \times 10^{-16}$	$1,7812 \times 10^{-16}$
	Ensaio 2	$1,7056 \times 10^{-16}$	$2,0996 \times 10^{-16}$
	Ensaio 3	$1,6734 \times 10^{-16}$	$1,8871 \times 10^{-16}$
	Média	$1,6622 \times 10^{-16}$	$1,9203 \times 10^{-16}$
Alternativa 8	Ensaio 1	$1,3562 \times 10^{-15}$	$1,4930 \times 10^{-15}$
	Ensaio 2	$1,4664 \times 10^{-15}$	$1,7706 \times 10^{-15}$
	Ensaio 3	$1,4473 \times 10^{-15}$	$1,5968 \times 10^{-15}$
	Média	$1,4229 \times 10^{-15}$	$1,6182 \times 10^{-15}$


Fonte: Proposto pelo autor.

Figura 80 – Processo de minimização do erro (RMSE) do modelo ANFIS 6



Fonte: Proposto pelo autor.

Figura 81 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 6



Fonte: Proposto pelo autor.


Por último, a Tabela 16 mostra os resultados do treinamento e do teste das topologias candidatas ao modelo ANFIS 7, responsável pela predição dos valores do indicador *overall value at risk*. Nesse caso, o uso de 2 funções de pertinência nas variáveis de entrada também produziu melhores resultados. Novamente, a alternativa 4 apresentou a menor média dos erros quadráticos médios na etapa de teste ($9,4665 \times 10^{-10}$). Diante desses resultados, o modelo ANFIS 7 será formado por funções de pertinência do tipo triangular nas variáveis de entrada, operador produto algébrico e consequente do tipo constante. A Figura 82 representa o processo de minimização da raiz do erro quadrático médio durante um dos treinamentos da alternativa 4. Já a Figura 83 ilustra os resultados da comparação dos valores esperados com os valores estimados para 45 amostras. Nesse caso, também é alcançada uma alta precisão das estimativas.

Tabela 16 - Resultados alcançados pelas topologias candidatas ao modelo ANFIS 7

		E_{qm} treinamento	E_{qm} teste
Alternativa 1	Ensaio 1	$2,6530 \times 10^{-10}$	$6,7952 \times 10^{-9}$
	Ensaio 2	$2,8880 \times 10^{-10}$	$3,1206 \times 10^{-9}$
	Ensaio 3	$2,7882 \times 10^{-10}$	$3,1363 \times 10^{-9}$
	Média	$2,7756 \times 10^{-10}$	$4,1946 \times 10^{-9}$
Alternativa 2	Ensaio 1	$1,7975 \times 10^{-3}$	$2,4090 \times 10^{-3}$
	Ensaio 2	$1,8225 \times 10^{-3}$	$2,4771 \times 10^{-3}$
	Ensaio 3	$1,5088 \times 10^{-3}$	$2,4694 \times 10^{-3}$
	Média	$1,7065 \times 10^{-3}$	$2,4517 \times 10^{-3}$
Alternativa 3	Ensaio 1	$5,1688 \times 10^{-10}$	$1,8907 \times 10^{-9}$
	Ensaio 2	$4,3991 \times 10^{-10}$	$1,3282 \times 10^{-9}$
	Ensaio 3	$4,4669 \times 10^{-10}$	$1,4622 \times 10^{-9}$
	Média	$4,6719 \times 10^{-10}$	$1,5515 \times 10^{-9}$
Alternativa 4	Ensaio 1	$2,7344 \times 10^{-10}$	$1,0255 \times 10^{-9}$
	Ensaio 2	$6,1138 \times 10^{-10}$	$9,8138 \times 10^{-10}$
	Ensaio 3	$6,2620 \times 10^{-10}$	$8,3822 \times 10^{-10}$
	Média	$4,8820 \times 10^{-10}$	$9,4665 \times 10^{-10}$
Alternativa 5	Ensaio 1	$2,5306 \times 10^{-10}$	$8,7529 \times 10^{-9}$
	Ensaio 2	$2,6722 \times 10^{-10}$	$4,6266 \times 10^{-9}$
	Ensaio 3	$2,5078 \times 10^{-10}$	$3,0898 \times 10^{-9}$
	Média	$2,5697 \times 10^{-10}$	$5,2399 \times 10^{-9}$
Alternativa 6	Ensaio 1	$8,4774 \times 10^{-4}$	$1,2014 \times 10^{-3}$
	Ensaio 2	$8,5790 \times 10^{-4}$	$1,1349 \times 10^{-3}$
	Ensaio 3	$7,9885 \times 10^{-4}$	$1,0989 \times 10^{-3}$
	Média	$8,3463 \times 10^{-4}$	$1,1446 \times 10^{-3}$
Alternativa 7	Ensaio 1	$2,8060 \times 10^{-10}$	$2,9519 \times 10^{-8}$
	Ensaio 2	$2,7602 \times 10^{-10}$	$6,1181 \times 10^{-9}$
	Ensaio 3	$3,0342 \times 10^{-10}$	$6,2836 \times 10^{-9}$
	Média	$2,8656 \times 10^{-10}$	$1,2049 \times 10^{-8}$
Alternativa 8	Ensaio 1	$1,2697 \times 10^{-6}$	$1,6960 \times 10^{-6}$
	Ensaio 2	$1,5398 \times 10^{-6}$	$2,0538 \times 10^{-6}$
	Ensaio 3	$1,5633 \times 10^{-6}$	$2,1144 \times 10^{-6}$
	Média	$1,4544 \times 10^{-6}$	$1,9502 \times 10^{-6}$


Fonte: Proposto pelo autor.

Figura 82 – Processo de minimização do erro (RMSE) do modelo ANFIS 7



Fonte: Proposto pelo autor.

Figura 83 – Comparação entre os valores esperados e os valores estimados pelo modelo ANFIS 7



Fonte: Proposto pelo autor.

4.3.5 Síntese dos resultados da implementação computacional dos modelos ANFIS

A Tabela 17 resume os resultados da implementação computacional das topologias candidatas aos modelos de predição ANFIS. Novamente, o modelo de predição 3 apresentou a menor capacidade de generalização de resultados dentre os modelos computacionais implementados. Todavia, como os valores médios calculados para o E_{qm} na etapa de teste de todos os modelos são menores que o valor limite definido na Subseção 4.2.3 ($1,0 \times 10^{-3}$), conclui-se que o uso de sistemas do tipo ANFIS conduz a uma capacidade de generalização de resultados adequada para a aplicação proposta.

Tabela 17 – Síntese dos resultados da implementação computacional dos modelos ANFIS

Modelo de predição	Melhor configuração topológica	Tipo de função nas variáveis de entrada	Tipo de consequente	Operador para conectivos lógicos	Nº de funções nas variáveis de entrada	Nº de regras de inferência	E_{qm} teste (MSE)
ANFIS 1	Alternativa 4	Triangular	Constante	Produto algébrico	2	256	$4,4936 \times 10^{-11}$
ANFIS 2	Alternativa 4	Triangular	Constante	Produto algébrico	5	125	$5,8447 \times 10^{-15}$
ANFIS 3	Alternativa 7	Gaussiana	Função linear	Produto algébrico	4	64	$3,6508 \times 10^{-7}$
ANFIS 4	Alternativa 4	Triangular	Constante	Produto algébrico	3	27	$1,1935 \times 10^{-13}$
ANFIS 5	Alternativa 4	Triangular	Constante	Produto algébrico	2	16	$1,68 \times 10^{-10}$
ANFIS 6	Alternativa 7	Gaussiana	Função linear	Produto algébrico	2	16	$1,9203 \times 10^{-16}$
ANFIS 7	Alternativa 4	Triangular	Constante	Produto algébrico	2	32	$9,4665 \times 10^{-10}$

Fonte: Proposto pelo autor.

Na maioria dos modelos ANFIS implementados, a configuração topológica representada pela alternativa 4 forneceu estimativas mais precisas. Consequentemente, dentre os 7 modelos ANFIS selecionados, 5 utilizam funções de pertinência do tipo triangular nas variáveis de entrada e consequente do tipo constante nas regras de decisão, enquanto 2 modelos são compostos por funções de pertinência do tipo gaussiana e consequente do tipo função linear. Todos os modelos ANFIS utilizam o operador produto algébrico, uma vez que este forneceu melhores resultados que o operador mínimo.

Durante a aplicação da técnica de validação cruzada na implementação dos modelos ANFIS, diferentemente da etapa de implementação dos modelos PMC, não foi necessário ajustar a quantidade de amostras usadas no treinamento nem o valor da taxa de aprendizagem, uma vez que a adoção dos mesmos subconjuntos de amostras utilizados na implementação dos modelos PMC e do valor de $\eta = 0,01$ se mostraram escolhas viáveis. Considerando o processo cíclico de melhoria da capacidade de predição dos modelos ANFIS (Figura 61), os treinamentos foram refeitos apenas para escolher o número de funções de pertinência das variáveis de entrada que produzisse o menor erro. Isso contribuiu para que o tempo consumido na etapa de implementação dos modelos ANFIS fosse consideravelmente menor que o tempo dispendido na implementação dos modelos PMC.

Conforme mostra a Tabela 17, a maioria dos modelos ANFIS apresentou resultados mais precisos quando foram usadas apenas 2 funções de pertinência *fuzzy* nas variáveis de entrada, e não 3, como definido inicialmente com base na literatura. Para exemplificar a magnitude da melhoria na precisão, no caso do modelo ANFIS 5, o uso de 2 funções de pertinência ao invés de 3 diminuiu a ordem de grandeza do erro de 10^{-6} para 10^{-10} . No caso do modelo ANFIS 3, que apresentou o segundo menor erro dentre os modelos de predição ANFIS, o uso de uma quantidade maior de funções de pertinência (5) contribuiu para o alcance de uma alta capacidade de generalização de resultados. Nesse sentido, parece não haver uma clara relação entre a capacidade de predição de cada modelo e o número de funções de pertinência ou de regras de inferência. Dessa forma, verifica-se que, para o desenvolvimento de modelos de predição ANFIS, não é possível fornecer diretrizes quanto à determinação de um número ideal de funções de pertinência ou de regras de inferência, uma vez que estes parâmetros dependerão principalmente das características dos dados e das variáveis da aplicação proposta.

Capítulo 5

AVALIAÇÃO DA ADEQUABILIDADE DOS MODELOS DE PREDIÇÃO

5.1 DEFINIÇÃO DOS PARÂMETROS DE AVALIAÇÃO

O principal objetivo da avaliação da adequabilidade dos modelos de predição de desempenho apresentada neste estudo é analisar como as características intrínsecas às redes neurais PMC e aos sistemas neuro-*fuzzy* ANFIS podem contribuir e / ou dificultar a predição de desempenho de cadeias de suprimento baseada nos indicadores do modelo SCOR[®]. Nesse estudo, a adequabilidade pode ser entendida como a capacidade do modelo de ser adequado para a aplicação proposta, avaliada com base no alinhamento entre as características da técnica usada e as particularidades do domínio de problema em questão (HANINE et al., 2016).

A avaliação apresentada nas subseções a seguir foi baseada em um conjunto de parâmetros quantitativos e qualitativos. A definição desses parâmetros foi baseada em alguns estudos sobre avaliação e predição de desempenho (BOURNE et al., 2002; NUDURUPATI; BITITCI, 2005; UNAHABHOKHA; PLATTS; TAN, 2007; BRAZ; SCAVARDA; MARTINS, 2011); avaliação de desempenho de cadeias de suprimento (CUTHBERTSON; PIOTROWICZ, 2011), seleção e avaliação de fornecedores (DE BOER WEGEN; TELGEN, 1998), aplicações de redes PMC e ANFIS em outros domínios de problema (GÖKTEPE; AGAR; LAV, 2004; EFENDIGIL; ÖNUT; KAHARAMAN, 2009; BILGEHAN, 2011; AKKOÇ, 2012) e estudos comparativos que avaliam a adequação de técnicas de tomada de decisão a requisitos de problemas específicos (LIMA JUNIOR; OSIRO; CARPINETTI, 2014; ORTÍZ; FELIZZOLA; ISAZA, 2015; HANINE et al., 2016; GITINAVARD; MOUSAVI; VAHDANI, 2016; YAVUZ, 2016). Buscou-se também considerar requisitos que, ao serem atendidos, tendem a facilitar o processo de desenvolvimento, implantação e uso destes sistemas de predição em situações reais. Dessa forma, foram definidos os seguintes parâmetros de avaliação da adequabilidade dos modelos PMC e ANFIS à predição de desempenho de cadeias de suprimento:

- **Capacidade de predição de desempenho:** avalia quantitativamente a capacidade dos modelos de fornecer estimativas precisas e também verifica se existe diferença significativa entre estas estimativas e os valores esperados para cada amostra. Nos estudos que apresentam aplicações e comparações entre redes PMC e ANFIS, a avaliação da capacidade de predição é o parâmetro de avaliação mais utilizado, e é feita

com base em medidas como o erro quadrático médio (*Mean Square Error*, MSE), raiz do erro quadrático médio (*Root Mean Square Error*, RMSE), erro médio percentual absoluto (*Mean Absolute Percentage Error* – MAPE), índice de correlação (R^2), entre outros (EFENDIGIL; ÖNUT; KAHARAMAN, 2009; BILGEHAN, 2011). Também há estudos que realizam testes de hipótese (CHEN et al., 2005; JASSBI; SEYEDHOSSEINI; PILEVARI, 2010) e análise de superfície de resposta (PANJEHFOULADGARAN; YUSUFF, 2016). Neste estudo, para quantificar a diferença entre as estimativas fornecidas pelos modelos de previsão de desempenho e dados esperados para cada amostra, adotou-se as medidas RMSE e MAE, cujas fórmulas de cálculo estão detalhadas no Apêndice B. Para investigar se há diferença significativa entre os dados estimados e os valores esperados por cada técnica, foram realizados testes de hipótese com amostras pareadas (teste *t* emparelhado). O índice de correlação de Pearson (*R*) também foi usado para mensurar o grau da relação entre os valores desejados e os valores estimados por cada técnica;

- **Complexidade do processo de modelagem:** Refere-se à quantidade de decisões que precisam ser tomadas na etapa de modelagem, tais como a escolha dos valores dos parâmetros internos e de elementos da configuração topológica dos sistemas computacionais. A avaliação da complexidade do processo de modelagem também compreende fatores como a quantidade de dados e o tempo requeridos para o treinamento dos modelos computacionais (GÖKTEPE; AGAR; LAV, 2004). Considera-se que a complexidade do processo de modelagem seja um fator crítico para a adoção de sistemas de previsão de desempenho, pois ela influencia diretamente no esforço, tempo total e custos de desenvolvimento e implantação destes sistemas (BOURNE et al., 2002);
- **Quantidade de variáveis de entrada:** Avalia qualitativamente os efeitos da quantidade de variáveis de entrada dos sistemas de previsão sobre o processo de modelagem e o uso. Esse parâmetro foi definido com base nos estudos comparativos entre técnicas multicritério apresentados em Lima Junior, Osiro e Carpinetti (2014), Hanine et al. (2016) e Yavuz (2016), e se mostra importante por ajudar a determinar a quantidade máxima de indicadores de tendência que podem ser usados para prever o valor de um indicador de resultado;
- **Adequação a mudanças das métricas e alternativas avaliadas:** devido à possível necessidade de atualizar o sistema de previsão de desempenho ao longo do tempo (NUDURUPATI; BITITCI, 2005; BRAZ; SCAVARDA; MARTINS, 2011), é

desejável que as técnicas usadas permitam a inclusão ou a exclusão de indicadores. Caso o sistema de predição seja usado para fazer um *benchmarking* entre diferentes cadeias de suprimento, internas ou externas à empresa foco, também é necessário que as técnicas permitam a inclusão e a exclusão de alternativas sem gerar alterações na pontuação final e na ordenação relativa entre elas (*ranking*). Diante disso, essa avaliação foca nos efeitos produzidos pela inclusão e exclusão de indicadores de desempenho e de cadeias de suprimento nos sistemas de predição de desempenho. Esse parâmetro também é considerado nos estudos comparativos apresentados por Lima Junior, Osiro e Carpinetti (2014), Ortíz, Felizzola e Isaza (2015), Gitinavard, Mousavi e Vahdani (2016) e Yavuz (2016);

- **Modelagem de incerteza:** no contexto de predição de desempenho de cadeias de suprimento, considera-se que um dos fatores que contribuem para a incerteza determinística na tomada de decisão se refere à falta de precisão dos valores das variáveis que são apresentados aos modelos durante as etapas de treinamento e uso. Essa falta de precisão nos valores dos indicadores de desempenho pode ser causada pela ausência de dados históricos reais sobre o desempenho da cadeia avaliada, pela existência de informações conflitantes, pela dificuldade de avaliar alguns aspectos qualitativos do desempenho ou pela impressão individual (subjetividade) que os tomadores de decisão possuem a respeito dos elementos do problema e que é transmitida ao modelo de decisão por meio dos julgamentos fornecidos para a parametrização do sistema e quantificação do desempenho da(s) cadeia(s) avaliada (DE BOER WEGEN; TELGEN, 1998; CUTHBERTSON; PIOTROWICZ, 2011). Nesse sentido, esse parâmetro avalia a capacidade dos modelos PMC e ANFIS de apoiar a tomada de decisão sob incerteza determinística. Sua escolha foi baseada nos estudos comparativos entre técnicas de tomada de decisão multicritério apresentados por Lima Junior, Osiro e Carpinetti (2014) e Hanine et al. (2016);
- **Interpretabilidade dos dados:** Um dos fatores que pode impedir a adoção e o uso de sistemas de predição de desempenho é a falta de entendimento por parte de seus usuários sobre como os valores das variáveis são representados e calculados. A interpretabilidade dos dados é um parâmetro que visa analisar como as características das técnicas avaliadas podem ajudar ou dificultar o entendimento dos valores dos indicadores de entrada e saída dos sistemas de predição de desempenho (AKKOÇ, 2012);

A seguir, as subseções 5.2 a 5.7 apresentam os resultados da avaliação da adequabilidade das redes PMC e dos sistemas ANFIS no apoio à predição de desempenho de

cadeias de suprimento. Ao final deste capítulo, a Subseção 6.8 sintetiza as vantagens e limitações de uso de ambos os tipos de modelo de predição.

5.2 CAPACIDADE DE PREDIÇÃO DE DESEMPENHO

A avaliação da capacidade de predição de desempenho permite conhecer qual técnica é mais eficaz para mapear quantitativamente as funções referentes às relações de causa e efeito entre os indicadores de desempenho do modelo SCOR[®]. A avaliação da capacidade de predição de desempenho dos modelos PMC e ANFIS foi conduzida utilizando a melhor configuração topológica encontrada para cada modelo na etapa de validação cruzada. Também foram utilizados os mesmos parâmetros e subconjuntos de amostras treinamento da etapa de validação cruzada, que estão detalhados ao longo do Capítulo 4. Em relação à composição dos subconjuntos de teste, foram geradas aleatoriamente 30 amostras dos valores das variáveis para cada um dos sete modelos de predição de desempenho. Esses valores foram usados para o cálculo das medidas RMSE e MAE (Apêndice B, p. 289) e para a realização dos testes de hipótese. Também foi calculado o coeficiente de correlação linear de Pearson (R) visando avaliar a relação entre os valores esperados e as estimativas geradas por cada modelo. Quando $R=1$, significa que existe uma correlação linear perfeita positiva entre as duas variáveis analisadas, de forma que alguma variação nos valores de uma variável gera sempre uma alteração proporcional nos valores da outra variável. Quando $R=-1$, há uma correlação linear negativa perfeita entre as duas variáveis, ou seja, se uma aumenta, a outra sempre diminui. Se $R=0$, as duas variáveis não dependem linearmente uma da outra (MONTGOMERY; RUNGER, 2009).

Visando verificar se existe diferença significativa entre os valores de desempenho esperados (calculados com base no SCOR[®]) e os valores estimados por cada técnica, foram feitos diversos testes de hipótese. Os testes foram conduzidos usando o teste t emparelhado, que é um caso especial de teste t usado quando as observações nas duas populações de interesse são coletadas em pares. Sendo a média da população 1 representada por μ_1 e a média da população 2 dada por μ_2 , tomando as diferenças entre cada par de observações como $D_j = X_j - Y_j$, tal que $j = 1, 2, \dots, n$, o procedimento do teste t emparelhado consiste em analisar se a média das diferenças (μ_D) entre duas populações equivale a um valor especificado Δ_0 . Se não houver diferença significativa entre as duas populações, então a média das diferenças deve ser zero ($\mu_D = \Delta_0 = 0$). Portanto, conforme mostra o Quadro 26, para um teste t emparelhado com nível de significância α , a hipótese nula será dada por $H_0: \mu_D = 0$, pressupondo que as diferenças D_j das n observações seguem uma distribuição normal. Já a hipótese alternativa é representada por H_1 :

$\mu_D \neq 0$. Na estatística de teste T_0 , o parâmetro μ_D é estimado pela média amostral das diferenças (\bar{D}), enquanto s_D e s_D^2 são dados respectivamente pelo desvio padrão e pela variância amostral das diferenças (MONTGOMERY; RUNGER, 2009). Para testar o critério de rejeição, utiliza-se o valor tabelado $t_{\alpha/2, n-1}$, obtido conforme com o número de graus de liberdade ($n-1$) e o nível de significância adotado (α). Os resultados também podem ser analisados usando o valor p (*p-value*), sendo que se o valor p for maior que o nível de significância (α) adotado para o teste, deve-se aceitar a hipótese nula. O valor p também pode ser entendido como o menor valor do nível de significância para o qual a hipótese nula seria rejeitada (MONTGOMERY; RUNGER, 2009).

Quadro 26 – Descrição do teste t emparelhado

Hipótese nula:	$H_0: \mu_D = 0$
Hipótese alternativa:	$H_1: \mu_D \neq 0$
Estatística de teste:	$T_0 = \frac{\bar{D} - \Delta_0}{s_D/\sqrt{n}}$
Sendo:	$s_D^2 = \frac{\sum_{i=1}^n (D_i - \bar{D})^2}{n-1}$
Critério de rejeição (teste bicaudal):	$t_0 < -t_{\alpha/2, n-1}$ ou $t_0 > t_{\alpha/2, n-1}$

Fonte: Proposto pelo autor.

A Tabela 18 descreve as hipóteses avaliadas em cada teste. Em todos eles, foi adotado o nível de significância $\alpha = 0,01$. Na Tabela 18, para cada um dos sete modelos de predição, μ_{E-PMC} representa a média das diferenças entre os valores esperados, calculados com base no SCOR[®], e as estimativas fornecidas pelos modelos PMC; $\mu_{E-ANFIS}$ consiste na média das diferenças entre os valores desejados e as estimativas calculadas pelos modelos ANFIS; $\mu_{PMC-ANFIS}$ consiste na média das diferenças entre os valores estimados pelos modelos PMC e os valores dados pelos modelos ANFIS.

Tabela 18 – Descrição dos testes de hipótese realizados

Número do teste	Hipótese nula	Hipótese alternativa
1	$H_0: \mu_{E1-PMC1} = 0$	$H_1: \mu_{E1-PMC1} \neq 0$
2	$H_0: \mu_{E1-ANFIS1} = 0$	$H_1: \mu_{E1-ANFIS1} \neq 0$
3	$H_0: \mu_{PMC1-ANFIS1} = 0$	$H_1: \mu_{PMC1-ANFIS1} \neq 0$
4	$H_0: \mu_{E2-PMC2} = 0$	$H_1: \mu_{E2-PMC2} \neq 0$
5	$H_0: \mu_{E2-ANFIS2} = 0$	$H_1: \mu_{E2-ANFIS2} \neq 0$
6	$H_0: \mu_{PMC2-ANFIS2} = 0$	$H_1: \mu_{PMC2-ANFIS2} \neq 0$
7	$H_0: \mu_{E3-PMC3} = 0$	$H_1: \mu_{E3-PMC3} \neq 0$
8	$H_0: \mu_{E3-ANFIS3} = 0$	$H_1: \mu_{E3-ANFIS3} \neq 0$
9	$H_0: \mu_{PMC3-ANFIS3} = 0$	$H_1: \mu_{PMC3-ANFIS3} \neq 0$
10	$H_0: \mu_{E4-PMC4} = 0$	$H_1: \mu_{E4-PMC4} \neq 0$

Número do teste	Hipótese nula	Hipótese alternativa
11	$H_0: \mu_{E4-PMC4} = 0$	$H_1: \mu_{E4-PMC4} \neq 0$
12	$H_0: \mu_{PMC4-ANFIS4} = 0$	$H_1: \mu_{PMC4-ANFIS4} \neq 0$
13	$H_0: \mu_{E5-PMC5} = 0$	$H_1: \mu_{E5-PMC5} \neq 0$
14	$H_0: \mu_{E5-ANFIS5} = 0$	$H_1: \mu_{E5-ANFIS5} \neq 0$
15	$H_0: \mu_{PMC5-ANFIS5} = 0$	$H_1: \mu_{PMC5-ANFIS5} \neq 0$
16	$H_0: \mu_{E6-PMC6} = 0$	$H_1: \mu_{E6-PMC6} \neq 0$
17	$H_0: \mu_{E6-ANFIS6} = 0$	$H_1: \mu_{E6-ANFIS6} \neq 0$
18	$H_0: \mu_{PMC6-ANFIS6} = 0$	$H_1: \mu_{PMC6-ANFIS6} \neq 0$
19	$H_0: \mu_{E7-PMC7} = 0$	$H_1: \mu_{E7-PMC7} \neq 0$
20	$H_0: \mu_{E7-ANFIS7} = 0$	$H_1: \mu_{E7-ANFIS7} \neq 0$
21	$H_0: \mu_{PMC7-ANFIS7} = 0$	$H_1: \mu_{PMC7-ANFIS7} \neq 0$

Fonte: Proposto pelo autor.

A Tabela 19 resume os resultados dos testes de predição dos valores do indicador *total cost to serve*, os quais foram feitos usando os modelos PMC 1 e ANFIS 1. Nessa tabela, são mostrados os valores de saída esperados, os respectivos valores estimados pelos modelos PMC 1 e ANFIS 1 e as medidas de erro calculadas para cada uma das 30 amostras. A última linha da Tabela 19 também apresenta os valores médios das medidas de erro. Como pode ser visto, assim como nos experimentos realizados durante a validação cruzada, o sistema de predição de desempenho baseado em ANFIS forneceu estimativas mais próximas dos valores esperados para o indicador *total cost to serve*, alcançando um MAE de $2,60 \times 10^{-7}$ e RMSE de $4,91 \times 10^{-7}$, enquanto o sistema baseado em PMC obteve respectivamente os valores $1,04 \times 10^{-3}$ e $1,30 \times 10^{-3}$.

Tabela 19 – Resultados dos testes de predição do indicador *total cost to serve*

Valores esperados	Valores de saída estimados		Medidas de erro (PMC 1)		Medidas de erro (ANFIS 1)	
	PMC 1	ANFIS 1	MAE	RMSE	MAE	RMSE
0,59000	0,59074	0,59000	7,38E-04	5,44E-07	0,00E+00	0,00E+00
0,42000	0,41896	0,42000	1,04E-03	1,08E-06	0,00E+00	0,00E+00
0,46875	0,46855	0,46875	2,00E-04	4,00E-08	2,00E-07	4,00E-14
0,51750	0,51766	0,51750	1,63E-04	2,64E-08	0,00E+00	0,00E+00
0,50625	0,50551	0,50625	7,37E-04	5,44E-07	0,00E+00	0,00E+00
0,64625	0,64746	0,64625	1,21E-03	1,47E-06	1,00E-06	1,00E-12
0,61625	0,61739	0,61625	1,14E-03	1,29E-06	0,00E+00	0,00E+00
0,44750	0,44685	0,44750	6,50E-04	4,22E-07	0,00E+00	0,00E+00
0,36125	0,36074	0,36125	5,13E-04	2,63E-07	0,00E+00	0,00E+00
0,46750	0,46645	0,46750	1,05E-03	1,10E-06	7,00E-07	4,90E-13
0,60750	0,60895	0,60750	1,45E-03	2,10E-06	0,00E+00	0,00E+00
0,68125	0,68139	0,68125	1,38E-04	1,89E-08	1,00E-06	1,00E-12

Valores esperados	Valores de saída estimados		Medidas de erro (PMC 1)		Medidas de erro (ANFIS 1)	
	PMC 1	ANFIS 1	MAE	RMSE	MAE	RMSE
0,59750	0,59924	0,59750	1,74E-03	3,02E-06	1,90E-06	3,61E-12
0,46500	0,46400	0,46500	1,00E-03	1,00E-06	0,00E+00	0,00E+00
0,37250	0,36995	0,37250	2,55E-03	6,50E-06	0,00E+00	0,00E+00
0,51875	0,51916	0,51875	4,12E-04	1,70E-07	3,40E-07	1,16E-13
0,41875	0,41840	0,41875	3,50E-04	1,23E-07	1,60E-07	2,56E-14
0,58500	0,58791	0,58500	2,91E-03	8,48E-06	6,30E-07	3,97E-13
0,50625	0,50615	0,50625	1,00E-04	1,00E-08	2,10E-07	4,41E-14
0,34875	0,34626	0,34875	2,49E-03	6,19E-06	1,40E-07	1,96E-14
0,45750	0,45569	0,45750	1,81E-03	3,29E-06	1,76E-07	3,09E-14
0,56250	0,56406	0,56250	1,56E-03	2,44E-06	0,00E+00	0,00E+00
0,34875	0,34878	0,34875	2,50E-05	6,25E-10	4,25E-07	1,81E-13
0,59750	0,59934	0,59750	1,84E-03	3,38E-06	4,04E-07	1,63E-13
0,49375	0,49441	0,49375	6,62E-04	4,39E-07	3,00E-07	9,02E-14
0,50000	0,49964	0,50000	3,62E-04	1,31E-07	1,00E-07	1,00E-14
0,61625	0,61754	0,61625	1,29E-03	1,66E-06	0,00E+00	0,00E+00
0,63000	0,63209	0,63000	2,09E-03	4,36E-06	0,00E+00	0,00E+00
0,33125	0,33125	0,33125	0,00E+00	0,00E+00	0,00E+00	0,00E+00
0,50500	0,50590	0,50500	9,00E-04	8,10E-07	1,00E-07	1,00E-14
		Média	1,04E-03	1,30E-03	2,60E-07	4,91E-07

Fonte: Proposto pelo autor.

As Tabelas 20 a 22 apresentam os resultados dos testes de hipótese envolvendo as médias dos valores esperados e das estimativas fornecidas por cada técnica. Essas tabelas também mostram o valor do índice de correlação linear de Pearson (R), a média e a variância de cada população analisada. Ao analisar os dados da Tabela 20, observa-se que o valor da estatística t_0 está dentro da região de aceitação da hipótese nula, ou seja - $t_{\alpha/2, n-1} < t_0 < t_{\alpha/2, n-1}$. Além disso, o valor do p -value para uma distribuição bicaudal (0,4574) é maior do que o valor do nível de significância adotado (0,01), podendo-se concluir que não há diferença significativa entre os valores esperados para o indicador *total cost to serve* e os dados estimados pelo modelo PMC 1. Os resultados apresentados na Tabela 21 indicam que também não existe diferença significativa entre os valores esperados para esse indicador e as estimativas do ANFIS 1. A partir da análise dos resultados da Tabela 22, conclui-se que também não há diferença significativa entre os dados estimados pelos modelos PMC 1 e ANFIS 1. Embora as duas técnicas forneçam estimativas positivamente correlacionadas aos valores desejados, os valores estimados pelos modelos ANFIS apresentaram o maior índice de correlação R , equivalente a 1.

Tabela 20 – Resultado do teste de hipótese 1

	Valores esperados	Estimativas do PMC 1
Média	0,5061667	0,506347
Variância	0,0095927	0,009781
Número de amostras	30	30
Correlação de Pearson (R)	0,9999586	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-0,753174	
P($T \leq t$) bi-caudal (p -value)	0,4574166	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,7563859	

Fonte: Proposto pelo autor.

Tabela 21 – Resultado do teste de hipótese 2

	Valores esperados	Estimativas do ANFIS 1
Média	0,5061667	0,506167
Variância	0,0095927	0,009593
Número de amostras	30	30
Correlação de Pearson (R)	1	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-1,990629	
P($T \leq t$) bi-caudal (p -value)	0,05602	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,7563859	

Fonte: Proposto pelo autor.

Tabela 22 – Resultado do teste de hipótese 3

	Estimativas do PMC 1	Estimativas do ANFIS 1
Média	0,506347	0,506167
Variância	0,009781	0,009593
Número de amostras	30	30
Correlação de Pearson (R)	0,9999586	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	0,7516071	
P($T \leq t$) bi-caudal (p -value)	0,4583441	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,7563859	

Fonte: Proposto pelo autor.

Na Tabela 23 são apresentados os resultados dos testes de predição realizados usando os modelos PMC 2 e ANFIS 2, responsáveis pelo cálculo de algumas operações referentes ao indicador *return on working capital*. Novamente, o sistema de predição de desempenho baseado

em ANFIS calculou estimativas mais precisas, cujo os valores do MAE e RMSE equivalem respectivamente a $2,71 \times 10^{-7}$ e $3,66 \times 10^{-7}$. Já os valores do MAE e RMSE obtidos pelo modelo PMC 2 foram $5,58 \times 10^{-3}$ e $6,20 \times 10^{-3}$. As Tabelas 24 a 26 mostram os resultados dos testes de hipótese 4 a 6. A análise desses dados sugere que a hipótese nula deve ser aceita nesses três testes e que não existe diferença significativa entre os valores esperados para o indicador *return on working capital* e os dados estimados pelos modelos PMC 2 e ANFIS 2, uma vez que a estatística t_0 está compreendida na faixa de aceitação da hipótese nula e que o valor obtido para o *p-value* é maior do que o nível de significância. Outra constatação é que os valores fornecidos pelo modelo ANFIS apresentam maior correlação com os valores esperados para cada amostra.

Tabela 23 – Resultados dos testes de predição usando os modelos PMC 2 e ANFIS 2

Valores esperados	Valores de saída estimados		Medidas de erro (PMC 2)		Medidas de erro (ANFIS 2)	
	PMC 2	ANFIS 2	MAE	RMSE	MAE	RMSE
0,73867	0,74368	0,73867	5,01E-03	2,51E-05	1,91E-07	3,67E-14
0,56367	0,57178	0,56367	8,11E-03	6,58E-05	1,42E-07	2,02E-14
0,50500	0,50647	0,50500	1,47E-03	2,16E-06	2,53E-08	6,39E-16
0,46800	0,46484	0,46800	3,16E-03	9,99E-06	2,16E-07	4,65E-14
0,41900	0,41014	0,41900	8,86E-03	7,85E-05	5,08E-07	2,58E-13
0,23900	0,23480	0,23900	4,20E-03	1,76E-05	1,11E-07	1,22E-14
0,55867	0,56630	0,55867	7,63E-03	5,83E-05	4,63E-07	2,15E-13
0,27600	0,26646	0,27600	9,54E-03	9,10E-05	2,23E-07	4,97E-14
0,21400	0,21478	0,21400	7,80E-04	6,08E-07	4,69E-07	2,20E-13
0,58833	0,59816	0,58833	9,83E-03	9,66E-05	1,77E-09	3,13E-18
0,48000	0,47760	0,48000	2,40E-03	5,76E-06	9,01E-07	8,11E-13
0,79800	0,79050	0,79800	7,50E-03	5,63E-05	3,04E-07	9,26E-14
0,51133	0,51324	0,51133	1,91E-03	3,64E-06	5,06E-08	2,56E-15
0,43800	0,43073	0,43800	7,27E-03	5,29E-05	8,19E-07	6,71E-13
0,26067	0,25309	0,26067	7,58E-03	5,74E-05	1,17E-07	1,36E-14
0,50333	0,50435	0,50333	1,02E-03	1,03E-06	5,73E-07	3,28E-13
0,56867	0,57685	0,56867	8,18E-03	6,70E-05	4,01E-08	1,61E-15
0,54933	0,55569	0,54933	6,36E-03	4,04E-05	3,38E-07	1,14E-13
0,43800	0,43193	0,43800	6,07E-03	3,68E-05	1,35E-07	1,82E-14
0,57433	0,58288	0,57433	8,55E-03	7,31E-05	4,38E-08	1,92E-15
0,56233	0,56974	0,56233	7,41E-03	5,49E-05	3,73E-07	1,39E-13
0,24333	0,23856	0,24333	4,77E-03	2,28E-05	5,13E-07	2,63E-13
0,43433	0,42779	0,43433	6,54E-03	4,28E-05	1,73E-07	2,98E-14
0,53933	0,54515	0,53933	5,82E-03	3,38E-05	4,06E-08	1,65E-15
0,53133	0,53616	0,53133	4,83E-03	2,33E-05	7,57E-07	5,73E-13
0,22233	0,22127	0,22233	1,06E-03	1,13E-06	1,31E-07	1,71E-14

Valores esperados	Valores de saída estimados		Medidas de erro (PMC 2)		Medidas de erro (ANFIS 2)	
	PMC 2	ANFIS 2	MAE	RMSE	MAE	RMSE
0,55633	0,56352	0,55633	7,19E-03	5,17E-05	5,43E-08	2,95E-15
0,48133	0,47906	0,48133	2,27E-03	5,17E-06	1,80E-07	3,25E-14
0,78733	0,78249	0,78733	4,84E-03	2,35E-05	2,59E-08	6,73E-16
0,72333	0,73067	0,72333	7,34E-03	5,38E-05	2,21E-07	4,88E-14
		Média	5,58E-03	6,20E-03	2,71E-07	3,66E-07

Fonte: Proposto pelo autor.

Tabela 24 – Resultado do teste de hipótese 4

	Valores esperados	Estimativas do PMC 2
Média	0,492444	0,492956
Variância	0,025341	0,02624
Número de amostras	30	30
Correlação de Pearson (R)	0,999386	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-0,44603	
P($T \leq t$) bi-caudal (p -value)	0,658886	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756386	

Fonte: Proposto pelo autor.

Tabela 25 – Resultado do teste de hipótese 5

	Valores esperados	Estimativas do ANFIS 2
Média	0,492444	0,492444
Variância	0,025341	0,025341
Número de amostras	30	30
Correlação de Pearson (R)	1	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	0,44914	
P($T \leq t$) bi-caudal (p -value)	0,656669	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756386	

Fonte: Proposto pelo autor.

Tabela 26 – Resultado do teste de hipótese 6

	Estimativas do PMC 2	Estimativas do ANFIS 2
Média	0,492956	0,492444
Variância	0,02624	0,025341

Número de amostras	30	30
Correlação de Pearson (R)	0,999386	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	0,446063	
P($T \leq t$) bi-caudal (p -value)	0,658865	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756386	

Fonte: Proposto pelo autor.

A Tabela 27 mostra os resultados dos testes de predição dos valores do indicador *return on working capital*. Os valores do MAE e RMSE para o modelo de predição PMC 3 foram $2,07 \times 10^{-2}$ e $2,31 \times 10^{-2}$, respectivamente. O modelo ANFIS 3, que apresentou estimativas mais precisas do que o PMC 3, alcançou um MAE de $7,60 \times 10^{-4}$ e $1,13 \times 10^{-3}$. As Tabelas 28 a 30 apresentam os resultados dos testes de hipótese 7 a 9. Novamente, é possível inferir que não há diferença significativa entre os valores esperados e as estimativas fornecidas pelos modelos PMC 3 e ANFIS 3. Os dados dessas tabelas também sugerem que os valores fornecidos pelo modelo ANFIS 3 possuem maior correlação com os valores desejados que o PMC 3.

Tabela 27 – Resultados dos testes de predição do indicador *return on working capital*

Valores esperados	Valores de saída estimados		Medidas de erro (PMC 3)		Medidas de erro (ANFIS 3)	
	PMC 3	ANFIS 3	MAE	RMSE	MAE	RMSE
0,16071	0,18589	0,16115	2,52E-02	6,34E-04	4,37E-04	1,91E-07
0,28261	0,30522	0,28234	2,26E-02	5,11E-04	2,73E-04	7,46E-08
0,03614	0,07262	0,03590	3,65E-02	1,33E-03	2,40E-04	5,77E-08
0,12712	0,09898	0,12638	2,81E-02	7,92E-04	7,39E-04	5,46E-07
0,03900	0,07203	0,03849	3,30E-02	1,09E-03	5,09E-04	2,59E-07
0,24483	0,25937	0,24540	1,45E-02	2,11E-04	5,77E-04	3,33E-07
0,06465	0,07652	0,06431	1,19E-02	1,41E-04	3,39E-04	1,15E-07
0,21087	0,18548	0,21089	2,54E-02	6,45E-04	1,79E-05	3,19E-10
0,13529	0,11498	0,13571	2,03E-02	4,13E-04	4,17E-04	1,74E-07
0,13721	0,13766	0,13742	4,51E-04	2,03E-07	2,10E-04	4,39E-08
0,11695	0,09723	0,11725	1,97E-02	3,89E-04	2,99E-04	8,94E-08
0,08370	0,07792	0,08346	5,77E-03	3,33E-05	2,31E-04	5,32E-08
0,01781	0,05610	0,01828	3,83E-02	1,47E-03	4,73E-04	2,23E-07
0,09412	0,11737	0,09299	2,33E-02	5,41E-04	1,12E-03	1,26E-06
0,00000	-0,02517	-0,00267	2,52E-02	6,33E-04	2,67E-03	7,10E-06
0,12073	0,08354	0,11864	3,72E-02	1,38E-03	2,09E-03	4,37E-06
0,00426	0,01009	0,00468	5,84E-03	3,41E-05	4,20E-04	1,76E-07
0,06197	0,08452	0,06395	2,26E-02	5,09E-04	1,98E-03	3,91E-06
0,02353	0,01882	0,02633	4,71E-03	2,22E-05	2,80E-03	7,86E-06

Valores esperados	Valores de saída estimados		Medidas de erro (PMC 3)		Medidas de erro (ANFIS 3)	
	PMC 3	ANFIS 3	MAE	RMSE	MAE	RMSE
0,00256	-0,01432	0,00528	1,69E-02	2,85E-04	2,72E-03	7,38E-06
0,00595	0,01912	0,00786	1,32E-02	1,73E-04	1,91E-03	3,65E-06
0,04333	0,07305	0,04294	2,97E-02	8,83E-04	3,89E-04	1,52E-07
0,04000	0,07259	0,03984	3,26E-02	1,06E-03	1,55E-04	2,41E-08
0,04301	0,07337	0,04343	3,04E-02	9,22E-04	4,17E-04	1,74E-07
0,10455	0,08824	0,10476	1,63E-02	2,66E-04	2,10E-04	4,39E-08
0,06941	0,07798	0,06971	8,57E-03	7,34E-05	2,99E-04	8,94E-08
0,11493	0,08874	0,11469	2,62E-02	6,86E-04	2,31E-04	5,32E-08
0,00455	-0,00293	0,00439	7,48E-03	5,59E-05	1,55E-04	2,41E-08
0,06064	0,07637	0,06090	1,57E-02	2,47E-04	2,66E-04	7,06E-08
0,08036	0,10360	0,08057	2,32E-02	5,40E-04	2,16E-04	4,66E-08
		Média	2,07E-02	2,31E-02	7,60E-04	1,13E-03

Fonte: Proposto pelo autor.

Tabela 28 – Resultado do teste de hipótese 7

	Valores esperados	Estimativas do PMC 3
Média	0,084359208	0,089499
Variância	0,0051804	0,005169
Número de amostras	30	30
Correlação de Pearson (R)	0,949422244	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-1,23043503	
P($T \leq t$) bi-caudal (p -value)	0,228421841	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756385902	

Fonte: Proposto pelo autor.

Tabela 29 – Resultado do teste de hipótese 8

	Valores esperados	Estimativas do ANFIS 3
Média	0,084359208	0,08451
Variância	0,0051804	0,005155
Número de amostras	30	30
Correlação de Pearson (R)	0,99987659	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-0,723273346	
P($T \leq t$) bi-caudal (p -value)	0,475305686	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756385902	

Fonte: Proposto pelo autor.

Tabela 30 – Resultado do teste de hipótese 9

	Estimativas do PMC 3	Estimativas do ANFIS 3
Média	0,089498967	0,08451
Variância	0,005169236	0,005155
Número de amostras	30	30
Correlação de Pearson (R)	0,950035704	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	1,203076572	
P($T \leq t$) bi-caudal (p -value)	0,238676842	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756385902	

Fonte: Proposto pelo autor.

A Tabela 31 apresenta os resultados dos testes de predição do indicador *cash-to-cash cycle time*. Nesses testes, a precisão alcançada pelo modelo ANFIS 4 foi consideravelmente maior do que o PMC 4, posto que os valores do MAE e RMSE para o modelo PMC 4 foram respectivamente $1,00 \times 10^{-2}$ e $1,47 \times 10^{-2}$, enquanto para o modelo ANFIS foram equivalentes a $3,02 \times 10^{-7}$ e $3,43 \times 10^{-7}$. As Tabelas 32 a 34 apresentam os resultados dos testes de hipótese 10 a 12. Novamente, os valores de t_0 estão na região de aceitação da hipótese nula. Portanto, não há diferença significativa entre os valores esperados para o indicador *cash-to-cash cycle time* e as estimativas fornecidas pelos modelos PMC 3 e ANFIS 3. Ademais, as estimativas calculadas pelo ANFIS 4 possuem maior correlação linear com os valores desejados.

Tabela 31 – Resultados dos testes de predição do indicador *cash-to-cash cycle time*

Valores esperados	Valores de saída estimados		Medidas de erro (PMC 4)		Medidas de erro (ANFIS 4)	
	PMC 4	ANFIS 4	MAE	RMSE	MAE	RMSE
0,57037	0,57736	0,57036969	6,99E-03	4,89E-05	3,10E-07	9,62E-14
0,54815	0,55342	0,54814793	5,27E-03	2,78E-05	6,97E-08	4,86E-15
0,39259	0,38232	0,392593247	1,03E-02	1,06E-04	2,47E-07	6,09E-14
0,38519	0,37360	0,385184635	1,16E-02	1,34E-04	3,65E-07	1,33E-13
0,80000	0,79108	0,800000435	8,92E-03	7,96E-05	4,35E-07	1,89E-13
0,34074	0,32773	0,34074115	1,30E-02	1,69E-04	1,50E-07	2,24E-14
0,55556	0,55873	0,555555995	3,17E-03	1,01E-05	5,15E-09	2,65E-17
0,49630	0,49675	0,496296527	4,54E-04	2,06E-07	5,27E-07	2,78E-13
0,37778	0,36679	0,377777901	1,10E-02	1,21E-04	9,89E-08	9,77E-15
0,60741	0,61864	0,607406738	1,12E-02	1,26E-04	2,62E-07	6,87E-14
0,11111	0,15210	0,111111042	4,10E-02	1,68E-03	4,19E-08	1,75E-15
0,56296	0,56711	0,562963014	4,15E-03	1,72E-05	1,40E-08	1,95E-16
0,55556	0,56218	0,555555781	6,62E-03	4,39E-05	2,19E-07	4,81E-14
0,60000	0,60825	0,599999431	8,25E-03	6,81E-05	5,69E-07	3,24E-13
0,48148	0,47998	0,481481487	1,50E-03	2,25E-06	4,87E-07	2,37E-13
0,51852	0,52143	0,518519244	2,91E-03	8,47E-06	2,44E-07	5,94E-14
0,40000	0,39063	0,400000315	9,37E-03	8,78E-05	3,15E-07	9,89E-14
0,48889	0,48569	0,488889393	3,20E-03	1,02E-05	3,93E-07	1,54E-13
0,91852	0,86442	0,918518668	5,41E-02	2,93E-03	3,32E-07	1,10E-13
0,40000	0,38960	0,399999622	1,04E-02	1,08E-04	3,78E-07	1,43E-13
0,33333	0,31927	0,333332615	1,41E-02	1,98E-04	3,85E-07	1,48E-13
0,57778	0,58379	0,577777944	6,01E-03	3,61E-05	5,58E-08	3,11E-15
0,53333	0,53472	0,533333196	1,39E-03	1,92E-06	1,96E-07	3,86E-14
0,35556	0,34412	0,35555568	1,14E-02	1,31E-04	3,20E-07	1,02E-13
0,49630	0,49517	0,496296337	1,13E-03	1,27E-06	3,37E-07	1,14E-13
0,42963	0,42033	0,429630369	9,30E-03	8,65E-05	3,69E-07	1,36E-13
0,68148	0,69151	0,681481461	1,00E-02	1,01E-04	4,61E-07	2,12E-13
0,57037	0,57568	0,570369436	5,31E-03	2,82E-05	5,64E-07	3,18E-13
0,64444	0,65379	0,644444504	9,35E-03	8,73E-05	5,04E-07	2,54E-13
0,28148	0,27262	0,281480593	8,86E-03	7,85E-05	4,07E-07	1,66E-13
		Média	1,00E-02	1,47E-02	3,02E-07	3,43E-07

Fonte: Proposto pelo autor.

Tabela 32 – Resultado do teste de hipótese 10

	Valores esperados	Estimativas do PMC 4
Média	0,5004938	0,498627
Variância	0,024429059	0,023336088
Número de amostras	30	30
Correlação de Pearson (R)	0,995626103	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	0,687222752	
P($T \leq t$) bi-caudal (p -value)	0,497401895	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756385902	

Fonte: Proposto pelo autor.

Tabela 33 – Resultado do teste de hipótese 11

	Valores esperados	Estimativas do ANFIS 4
Média	0,5004938	0,500493813
Variância	0,024429059	0,024429069
Número de amostras	30	30
Correlação de Pearson (R)	1	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-0,198174732	
P($T \leq t$) bi-caudal (p -value)	0,844291045	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756385902	

Fonte: Proposto pelo autor.

Tabela 34 – Resultado do teste de hipótese 12

	Estimativas do PMC 4	Estimativas do ANFIS 4
Média	0,498627	0,500493813
Variância	0,023336088	0,024429069
Número de amostras	30	30
Correlação de Pearson (R)	0,995626139	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-0,687229631	
P($T \leq t$) bi-caudal (p -value)	0,497397625	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756385902	

Fonte: Proposto pelo autor.

Na Tabela 35 são mostrados os resultados dos testes de predição do indicador *order fulfillment cycle time*. Os valores do MAE e do RMSE calculados para o modelo ANFIS 5 foram $1,17 \times 10^{-5}$ e $1,55 \times 10^{-5}$, o que indica que sua capacidade de predição é superior ao PMC 5, cujo MAE e RMSE equivalem a $1,46 \times 10^{-2}$ e $1,74 \times 10^{-2}$. As Tabelas 36 a 38 apresentam os resultados dos testes de hipótese 13 a 15. A análise desses resultados sugere que as estimativas computadas pelo modelo ANFIS possuem maior correlação com os valores desejados e que não existe diferença significativa entre os valores esperados para o indicador *order fulfillment cycle time* e os valores estimados pelos modelos PMC 5 e ANFIS 5.

Tabela 35 – Resultados dos testes de predição do indicador *order fulfillment cycle time*

Valores esperados	Valores de saída estimados		Medidas de erro (PMC 5)		Medidas de erro (ANFIS 5)	
	PMC 5	ANFIS 5	MAE	RMSE	MAE	RMSE
0,492	0,48218	0,49200	9,82E-03	9,64E-05	1,44E-06	2,08E-12
0,408	0,41123	0,40798	3,23E-03	1,04E-05	2,27E-05	5,14E-10
0,567	0,55276	0,56699	1,42E-02	2,03E-04	1,22E-05	1,49E-10
0,400	0,40920	0,40001	9,20E-03	8,46E-05	5,16E-06	2,67E-11
0,525	0,52188	0,52498	3,12E-03	9,73E-06	1,85E-05	3,44E-10
0,217	0,19163	0,21704	2,54E-02	6,44E-04	4,33E-05	1,88E-09
0,400	0,41976	0,40000	1,98E-02	3,90E-04	1,55E-06	2,40E-12
0,808	0,77730	0,80802	3,07E-02	9,42E-04	1,96E-05	3,84E-10
0,608	0,63665	0,60802	2,87E-02	8,21E-04	1,70E-05	2,90E-10
0,292	0,31022	0,29200	1,82E-02	3,32E-04	8,45E-07	7,14E-13
0,725	0,70233	0,72500	2,27E-02	5,14E-04	3,02E-06	9,09E-12
0,308	0,30977	0,30801	1,77E-03	3,13E-06	1,47E-05	2,17E-10
0,525	0,51628	0,52500	8,72E-03	7,60E-05	1,19E-06	1,42E-12
0,575	0,56998	0,57500	5,02E-03	2,52E-05	3,86E-06	1,49E-11
0,233	0,26309	0,23301	3,01E-02	9,05E-04	5,95E-06	3,54E-11
0,900	0,90799	0,90000	7,99E-03	6,38E-05	7,34E-07	5,38E-13
0,900	0,90799	0,89998	7,99E-03	6,38E-05	1,72E-05	2,96E-10
0,600	0,60147	0,60000	1,47E-03	2,16E-06	2,05E-06	4,19E-12
0,500	0,51529	0,49999	1,53E-02	2,34E-04	5,73E-06	3,29E-11
0,200	0,19563	0,19999	4,37E-03	1,91E-05	7,08E-06	5,01E-11
0,850	0,84503	0,85001	4,97E-03	2,47E-05	7,88E-06	6,22E-11
0,450	0,43565	0,45002	1,44E-02	2,06E-04	2,07E-05	4,29E-10
0,333	0,33335	0,33297	3,50E-04	1,22E-07	3,14E-05	9,85E-10
0,842	0,82815	0,84199	1,38E-02	1,92E-04	9,71E-06	9,43E-11
0,350	0,32709	0,35001	2,29E-02	5,25E-04	1,35E-05	1,81E-10
0,258	0,28615	0,25799	2,82E-02	7,92E-04	5,20E-06	2,70E-11
0,858	0,83395	0,85799	2,41E-02	5,78E-04	1,21E-05	1,46E-10

Valores esperados	Valores de saída estimados		Medidas de erro (PMC 5)		Medidas de erro (ANFIS 5)	
	PMC 5	ANFIS 5	MAE	RMSE	MAE	RMSE
0,683	0,66718	0,68299	1,58E-02	2,50E-04	5,92E-06	3,50E-11
0,792	0,76188	0,79203	3,01E-02	9,07E-04	2,72E-05	7,41E-10
0,608	0,59362	0,60801	1,44E-02	2,07E-04	1,45E-05	2,12E-10
		Média	1,46E-02	1,74E-02	1,17E-05	1,55E-05

Fonte: Proposto pelo autor.

Tabela 36 – Resultado do teste de hipótese 13

	Valores esperados	Estimativas do PMC 5
Média	0,540233	0,537156
Variância	0,048603	0,046103
Número de amostras	30	30
Correlação de Pearson (R)	0,997129	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	0,965497	
P($T \leq t$) bi-caudal (p -value)	0,342279	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756386	

Fonte: Proposto pelo autor.

Tabela 37 – Resultado do teste de hipótese 14

	Valores esperados	Estimativas do ANFIS 5
Média	0,540233	0,540235
Variância	0,048603	0,048602
Número de amostras	30	30
Correlação de Pearson (R)	1	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-0,52546	
P($T \leq t$) bi-caudal (p -value)	0,60326	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756386	

Fonte: Proposto pelo autor.

Tabela 38 – Resultado do teste de hipótese 15

	Estimativas do PMC 5	Estimativas do ANFIS 5
Média	0,537156	0,540235
Variância	0,046103	0,048602
Número de amostras	30	30
Correlação de Pearson (R)	0,997128	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-0,96572	
P($T \leq t$) bi-caudal (p -value)	0,34217	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,756386	

Fonte: Proposto pelo autor.

A Tabela 39 mostra os resultados dos testes de predição feitos usando os modelos PMC 6 e ANFIS 6, os quais são incumbidos de predizer os valores do indicador *perfect order fulfillment*. Enquanto os valores do MAE e do RMSE alcançados pelo PMC 6 foram $2,35 \times 10^{-4}$ e $2,60 \times 10^{-4}$, respectivamente, o modelo ANFIS 6 obteve $1,00 \times 10^{-9}$ e $3,16 \times 10^{-9}$, fornecendo assim estimativas consideravelmente mais precisas. Nas Tabelas 40 a 42, que apresentam os resultados referentes aos testes de hipótese 16 a 18, é possível verificar que não existe diferença significativa entre os valores esperados para o indicador *perfect order fulfillment* e as estimativas computadas pelos modelos PMC 6 e ANFIS 6. Os valores estimados pelo sistema de predição baseado em ANFIS se mostraram perfeitamente correlacionados com o conjunto de valores esperados, com o valor de R igual a 1.

Tabela 39 – Resultados dos testes de predição do indicador *perfect order fulfillment*

Valores esperados	Valores de saída estimados		Medidas de erro (PMC 6)		Medidas de erro (ANFIS 6)	
	PMC 6	ANFIS 6	MAE	RMSE	MAE	RMSE
0,25	0,25018	0,25000	1,75E-04	3,06E-08	0,00E+00	0,00E+00
0,25	0,25030	0,25000	3,00E-04	9,00E-08	0,00E+00	0,00E+00
0,25	0,25030	0,25000	3,00E-04	9,00E-08	0,00E+00	0,00E+00
0,25	0,25030	0,25000	3,00E-04	9,00E-08	0,00E+00	0,00E+00
0,25	0,25018	0,25000	1,75E-04	3,06E-08	0,00E+00	0,00E+00
0,25	0,25018	0,25000	1,75E-04	3,06E-08	0,00E+00	0,00E+00
0,50	0,49980	0,50000	2,00E-04	4,00E-08	0,00E+00	0,00E+00
0,50	0,49985	0,50000	1,50E-04	2,25E-08	0,00E+00	0,00E+00
0,50	0,49980	0,50000	2,00E-04	4,00E-08	0,00E+00	0,00E+00
0,50	0,49980	0,50000	2,00E-04	4,00E-08	0,00E+00	0,00E+00
0,50	0,49980	0,50000	2,00E-04	4,00E-08	0,00E+00	0,00E+00
0,50	0,49980	0,50000	2,00E-04	4,00E-08	0,00E+00	0,00E+00
0,50	0,49980	0,50000	2,00E-04	4,00E-08	1,00E-08	1,00E-16

Valores esperados	Valores de saída estimados		Medidas de erro (PMC 6)		Medidas de erro (ANFIS 6)	
	PMC 6	ANFIS 6	MAE	RMSE	MAE	RMSE
0,50	0,49980	0,50000	2,00E-04	4,00E-08	0,00E+00	0,00E+00
0,50	0,49980	0,50000	2,00E-04	4,00E-08	0,00E+00	0,00E+00
0,50	0,49980	0,50000	2,00E-04	4,00E-08	0,00E+00	0,00E+00
0,75	0,75055	0,75000	5,50E-04	3,03E-07	0,00E+00	0,00E+00
0,75	0,75018	0,75000	1,75E-04	3,06E-08	0,00E+00	0,00E+00
0,75	0,75018	0,75000	1,75E-04	3,06E-08	0,00E+00	0,00E+00
0,75	0,75018	0,75000	1,75E-04	3,06E-08	0,00E+00	0,00E+00
0,75	0,75055	0,75000	5,50E-04	3,03E-07	0,00E+00	0,00E+00
0,75	0,75055	0,75000	5,50E-04	3,03E-07	0,00E+00	0,00E+00
0,75	0,75018	0,75000	1,75E-04	3,06E-08	0,00E+00	0,00E+00
0,75	0,74975	0,75000	2,50E-04	6,25E-08	1,00E-08	1,00E-16
0,75	0,75018	0,75000	1,75E-04	3,06E-08	0,00E+00	0,00E+00
0,75	0,75018	0,75000	1,75E-04	3,06E-08	1,00E-08	1,00E-16
0,75	0,75020	0,75000	2,00E-04	4,00E-08	0,00E+00	0,00E+00
0,75	0,75018	0,75000	1,75E-04	3,06E-08	0,00E+00	0,00E+00
0,75	0,75018	0,75000	1,75E-04	3,06E-08	0,00E+00	0,00E+00
0,75	0,75018	0,75000	1,75E-04	3,06E-08	0,00E+00	0,00E+00
		Média	2,35E-04	2,60E-04	1,00E-09	3,16E-09

Fonte: Proposto pelo autor.

Tabela 40 – Resultado do teste de hipótese 16

	Valores esperados	Estimativas do PMC 6
Média	0,56666667	0,566755
Variância	0,03850575	0,0385238
Número de amostras	30	30
Correlação de Pearson (R)	0,99999922	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-1,94420097	
P($T \leq t$) bi-caudal (p -value)	0,06162924	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,7563859	

Fonte: Proposto pelo autor.

Tabela 41 – Resultado do teste de hipótese 17

	Valores esperados	Estimativas do ANFIS 6
Média	0,56666667	0,56666667
Variância	0,03850575	0,03850575
Número de amostras	30	30
Correlação de Pearson (R)	1	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-1,79505494	
P($T \leq t$) bi-caudal (p -value)	0,08307466	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,7563859	

Fonte: Proposto pelo autor.

Tabela 42 – Resultado do teste de hipótese 18

	Estimativas do PMC 6	Estimativas do ANFIS 6
Média	0,566755	0,56668879
Variância	0,0385238	0,03850995
Número de amostras	30	30
Correlação de Pearson (R)	0,99999916	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	1,41473446	
P($T \leq t$) bi-caudal (p -value)	0,16779464	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,7563859	

Fonte: Proposto pelo autor.

A Tabela 43 apresenta os resultados dos testes de predição do indicador *overall value at risk*. O modelo ANFIS alcançou a melhor precisão, obtendo os valores do MAE e do RMSE equivalentes a $2,67 \times 10^{-5}$ e $3,24 \times 10^{-5}$, os quais são mais baixos do que aqueles alcançados pelo modelo PMC 7, iguais a $9,09 \times 10^{-3}$ e $1,06 \times 10^{-2}$, respectivamente. As Tabelas 44 a 46 apresentam os resultados dos testes de hipótese 19 a 21. Novamente, a hipótese nula deve ser aceita nos três testes, não existindo assim diferença significativa entre os valores esperados para o indicador *overall value at risk* e os valores estimados pelos modelos PMC 2 e ANFIS 2. As estimativas calculadas pelo modelo ANFIS 7 apresentaram correlação positiva e perfeita com os valores esperados para o indicador *overall value at risk*, com R igual a 1.

Tabela 43 – Resultados dos testes de predição do indicador *overall value at risk*

Valores desejados	Valores de saída estimados		Medidas de erro (PMC 7)		Medidas de erro (ANFIS 7)	
	PMC 7	ANFIS 7	MAE	RMSE	MAE	RMSE
0,92144	0,92582	0,92141	4,38E-03	1,92E-05	3,34E-05	1,11E-09
0,88957	0,90422	0,88959	1,47E-02	2,15E-04	2,08E-05	4,33E-10
0,75624	0,76460	0,75627	8,36E-03	6,99E-05	3,09E-05	9,54E-10
0,49281	0,48209	0,49280	1,07E-02	1,15E-04	7,13E-06	5,08E-11
0,76679	0,78078	0,76676	1,40E-02	1,96E-04	2,58E-05	6,66E-10
0,81403	0,82900	0,81403	1,50E-02	2,24E-04	1,95E-06	3,80E-12
0,72701	0,71776	0,72703	9,25E-03	8,56E-05	1,87E-05	3,49E-10
0,19299	0,19058	0,19299	2,41E-03	5,81E-06	8,10E-07	6,55E-13
0,20839	0,21072	0,20837	2,33E-03	5,43E-06	2,45E-05	6,01E-10
0,44841	0,45243	0,44845	4,02E-03	1,62E-05	3,67E-05	1,35E-09
0,31979	0,33857	0,31984	1,88E-02	3,53E-04	5,22E-05	2,73E-09
0,12638	0,10677	0,12642	1,96E-02	3,85E-04	3,69E-05	1,36E-09
0,15747	0,14346	0,15748	1,40E-02	1,96E-04	5,48E-06	3,00E-11
0,89701	0,90978	0,89698	1,28E-02	1,63E-04	2,64E-05	6,99E-10
0,64495	0,64005	0,64488	4,90E-03	2,40E-05	7,05E-05	4,97E-09
0,71325	0,70036	0,71329	1,29E-02	1,66E-04	3,72E-05	1,38E-09
0,91747	0,92426	0,91745	6,79E-03	4,61E-05	2,03E-05	4,11E-10
0,88493	0,89981	0,88494	1,49E-02	2,21E-04	9,80E-06	9,60E-11
0,62769	0,62335	0,62774	4,34E-03	1,88E-05	4,53E-05	2,05E-09
0,90093	0,90935	0,90090	8,42E-03	7,09E-05	3,01E-05	9,07E-10
0,27522	0,26227	0,27520	1,30E-02	1,68E-04	1,80E-05	3,24E-10
0,45124	0,46407	0,45126	1,28E-02	1,65E-04	1,68E-05	2,83E-10
0,29322	0,29760	0,29329	4,38E-03	1,92E-05	6,55E-05	4,28E-09
0,16166	0,14564	0,16166	1,60E-02	2,57E-04	3,62E-07	1,31E-13
0,03904	0,04782	0,03904	8,78E-03	7,71E-05	1,05E-06	1,09E-12
0,47511	0,47191	0,47509	3,20E-03	1,02E-05	2,00E-05	4,00E-10
0,72637	0,72874	0,72636	2,37E-03	5,62E-06	1,28E-05	1,65E-10
0,91821	0,92403	0,91825	5,82E-03	3,39E-05	3,97E-05	1,57E-09
0,63908	0,63824	0,63903	8,40E-04	7,06E-07	5,43E-05	2,94E-09
0,71347	0,71640	0,71343	2,93E-03	8,58E-06	3,69E-05	1,36E-09
		Média	9,09E-03	1,06E-02	2,67E-05	3,24E-05

Fonte: Proposto pelo autor.

Tabela 44 – Resultado do teste de hipótese 19

	Valores esperados	Estimativas do PMC 7
Média	0,5700057	0,5716828
Variância	0,0820219	0,0849261
Número de amostras	30	30
Correlação de Pearson (<i>R</i>)	0,9994789	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-0,8670054	
P($T \leq t$) bi-caudal (<i>p-value</i>)	0,3930565	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,7563859	

Fonte: Proposto pelo autor.

Tabela 45 – Resultado do teste de hipótese 20

	Valores esperados	Estimativas do ANFIS 7
Média	0,5700057	0,5700068
Variância	0,0820219	0,0820179
Número de amostras	30	30
Correlação de Pearson (<i>R</i>)	1	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	-0,1844201	
P($T \leq t$) bi-caudal (<i>p-value</i>)	0,8549675	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,7563859	

Fonte: Proposto pelo autor.

Tabela 46 – Resultado do teste de hipótese 21

	Estimativas do PMC 7	Estimativas do ANFIS 7
Média	0,5716828	0,5700068
Variância	0,0849261	0,0820179
Número de amostras	30	30
Correlação de Pearson (<i>R</i>)	0,9994793	
Hipótese da diferença de média	0	
Graus de liberdade	29	
Stat (t_0)	0,8664719	
P($T \leq t$) bi-caudal (<i>p-value</i>)	0,3933441	
t crítico bi-caudal ($t_{\alpha/2, n-1}$)	2,7563859	

Fonte: Proposto pelo autor.

A Tabela 47 resume os resultados alcançados pelos modelos na avaliação da capacidade de predição de desempenho. Para efeito de comparação, também são mostrados os valores do MSE da etapa de teste da validação cruzada para a escolha das configurações topológicas. Os resultados permitem concluir que os modelos ANFIS são capazes de fornecer estimativas mais precisas do que os modelos PMC. Ao comparar aos valores obtidos na etapa de validação cruzada (Capítulo 4) com os resultados dos testes de predição feitos nesta seção, os quais utilizaram subconjuntos de testes diferentes daqueles usados na validação cruzada, nota-se que tanto os modelos PMC quanto ANFIS apresentaram variações do MSE com magnitudes de até 10^{-2} , evidenciando que a capacidade de predição também depende dos dados apresentados ao sistema durante o uso.

Tabela 47 – Resultados obtidos quanto à capacidade de predição de desempenho

Modelo de predição	PMC		ANFIS	
	MSE na etapa de teste (validação cruzada, Capítulo 4)	MSE na etapa de teste (resultados desta seção)	MSE na etapa de teste (validação cruzada, Capítulo 4)	MSE na etapa de teste (resultados desta seção)
1	$3,805 \times 10^{-4}$	$1,7 \times 10^{-6}$	$4,4936 \times 10^{-11}$	$2,4 \times 10^{-13}$
2	$2,208 \times 10^{-4}$	$3,8 \times 10^{-5}$	$5,8447 \times 10^{-15}$	$1,3 \times 10^{-13}$
3	$8,393 \times 10^{-4}$	$5,3 \times 10^{-4}$	$3,6508 \times 10^{-7}$	$1,3 \times 10^{-6}$
4	$1,591 \times 10^{-4}$	$2,2 \times 10^{-4}$	$1,1935 \times 10^{-13}$	$1,2 \times 10^{-13}$
5	$5,116 \times 10^{-4}$	$3,0 \times 10^{-4}$	$1,68 \times 10^{-10}$	$2,4 \times 10^{-10}$
6	$1,432 \times 10^{-8}$	$6,8 \times 10^{-8}$	$1,9203 \times 10^{-16}$	$1,0 \times 10^{-17}$
7	$6,9297 \times 10^{-5}$	$1,1 \times 10^{-4}$	$9,4665 \times 10^{-10}$	$1,0 \times 10^{-9}$

Fonte: Proposto pelo autor.

Nos testes de predição apresentados ao longo desta seção, dentre os modelos ANFIS, as estimativas mais precisas foram computadas pelo modelo ANFIS 6, o qual realiza uma operação de soma entre os valores binários de seus quatro indicadores de entrada. Já o modelo ANFIS 3, incumbido de modelar um relacionamento não linear entre as variáveis de entrada e saída, assim como na etapa de validação cruzada, apresentou a menor capacidade de predição dentre os modelos ANFIS avaliados. Quanto aos modelos de predição baseados em redes PMC, o PMC 6 apresentou as estimativas com menor erro, enquanto o PMC 3 apresentou as estimativas mais destoantes. Acredita-se que essa similaridade nos resultados se deva às particularidades das funções que representam os relacionamentos entre as variáveis de entrada e saída desses modelos e às características da distribuição dos dados usados no processo de treinamento.

Em todos os testes de hipótese realizados, considerando o nível de significância 0,01, os resultados sugerem a aceitação da hipótese nula, indicando que: não existe diferença significativa entre os dados esperados para cada indicador e os dados estimados pelos modelos

de predição PMC; não existe diferença significativa entre os dados esperados e as estimativas calculadas pelos modelos ANFIS e; também não existe diferença significativa entre as estimativas computadas pelos modelos PMC e aquelas calculadas pelos modelos ANFIS. Como os modelos ANFIS alcançaram valores mais baixos para o RMSE e o MAE, estes se mostram mais adequados para modelar quantitativamente as relações de causa e efeito entre os indicadores de desempenho do SCOR[®] e fornecer estimativas de desempenho com maior precisão.

5.3 COMPLEXIDADE DO PROCESSO DE MODELAGEM

Antes de optar pelo uso de uma determinada técnica, é importante analisar o esforço que será requerido para a criação e treinamento de cada tipo de modelo. Esse esforço está diretamente associado à quantidade de elementos que necessitam ser definidos por meio de testes na etapa de validação cruzada, incluindo a seleção da configuração topológica mais adequada e a definição dos valores dos parâmetros internos dos sistemas computacionais e do tamanho dos subconjuntos de treinamento. Em situações em que é necessário decidir sobre as especificações de muitos elementos do sistema de predição, a grande quantidade de combinações entre os elementos a serem avaliados pode implicar em um alto número de testes, o que prejudica a agilidade do processo de desenvolvimento do sistema.

O Quadro 27 sintetiza todos os elementos que precisam ser definidos durante a modelagem de sistemas de predição PMC e ANFIS, subdividindo-os entre definições relacionadas à configuração topológica e ao processo de treinamento. Como pode ser visto no Quadro 27, o processo de definição da configuração topológica dos modelos PMC exige a escolha de uma quantidade menor de elementos. Enquanto as definições requeridas nos modelos PMC são voltadas às unidades de processamento do sistema (número de neurônios na camada intermediária, tipo das funções de ativação dos neurônios da camada intermediária e da camada de saída), nos modelos ANFIS os esforços focam no ajuste das variáveis de entrada e saída (número e forma das funções de pertinência *fuzzy* das variáveis de entrada e tipo de função do consequente das regras) e na escolha de um operador *t*-norma. Embora o uso de sistemas ANFIS também implique na construção de um conjunto de regras de inferência a partir das combinações entre os termos linguísticos das variáveis de entrada, este aspecto não foi considerado no Quadro 21 por não requerer testes computacionais e pela possibilidade de ser feito de forma muito rápida usando ferramentas computacionais.

Quadro 27 – Definições necessárias à modelagem de sistemas de predição PMC e ANFIS

	PMC	ANFIS
Definições relacionadas à configuração topológica do modelo	Número de neurônios na camada intermediária	Número de funções de pertinência <i>fuzzy</i> das variáveis de entrada
	Tipo de função de ativação dos neurônios da camada intermediária	Forma das funções de pertinência <i>fuzzy</i> das variáveis de entrada
	Tipo de função de ativação do neurônio da camada de saída	Tipo de função do consequente das regras
	---	Operador <i>t</i> -norma para computar as operações do conectivo “AND”
Definições relacionadas ao processo de treinamento	Tamanho do subconjunto de treinamento	Tamanho do subconjunto de treinamento
	Método de treinamento	Método de treinamento
	Taxa de aprendizagem	Taxa de aprendizagem
	Critério(s) de parada	Critério(s) de parada
	Valores iniciais do limiar de ativação e dos pesos das conexões entre os neurônios	Valores iniciais das funções de pertinência e dos parâmetros dos consequentes das regras de inferência

Fonte: Proposto pelo autor.

Sobre as definições a serem feitas na etapa de treinamento dos modelos de predição, tanto os modelos PMC quanto ANFIS requerem a escolha de um método (ou algoritmo) de aprendizagem e a definição do tamanho do subconjunto de treinamento, do valor da taxa de aprendizagem e de um ou mais critérios de parada do processo de treinamento. Todas essas escolhas costumam ser feitas a partir dos resultados dos testes da validação cruzada e com o apoio de estudos da literatura. Quanto aos demais elementos envolvidos no processo de treinamento de cada tipo de modelo, estes não são definidos por meio da validação cruzada e consequentemente não contribuem de forma significativa para o aumento da complexidade do processo de modelagem. No caso dos modelos PMC, é necessário especificar os valores iniciais dos pesos das conexões entre os neurônios e dos limiares de ativação de cada neurônio. Isso pode ser feito por meio da atribuição de valores aleatórios entre 0 e 1, ou por meio da atribuição de um mesmo valor a todos os parâmetros. Em relação à modelagem dos sistemas de predição ANFIS, deve-se definir os valores iniciais das funções de pertinência das variáveis de entrada e dos parâmetros dos consequentes das regras de inferência. Os valores iniciais dos parâmetros das funções de pertinência podem ser atribuídos de forma instantânea usando ferramentas computacionais que realizem o particionamento simétrico do universo de discurso normalizado das variáveis de entrada. Sobre a definição dos valores iniciais dos parâmetros dos consequentes das regras de inferência, uma vez que estes serão ajustados usando o método dos mínimos

quadrados, costuma-se atribuir o valor zero para todos estes parâmetros. Portanto, os modelos PMC e ANFIS requerem um esforço similar em relação às definições envolvidas no processo de treinamento.

O Quadro 28 apresenta a quantidade de parâmetros adaptativos presentes nos modelos de predição propostos por este estudo, calculada de acordo com as equações mostradas no Apêndice C (p. 290), e também mostra o tempo médio gasto no treinamento dos modelos computacionais usando um computador com processador “Intel quad-core i5 2.50 Ghz” e 6 *Gigabytes* de memória RAM. Os parâmetros adaptativos dos modelos PMC incluem os limiares de ativação presentes nos neurônios e os pesos das conexões sinápticas. Nos modelos ANFIS, os parâmetros adaptativos estão localizados nos consequentes das regras de inferência e nas funções de pertinência das variáveis de entrada.

Quadro 28 – Número de parâmetros adaptativos dos modelos de predição PMC e ANFIS e tempo consumido no ajuste destes parâmetros

	Modelos de predição						
	1	2	3	4	5	6	7
	Número de parâmetros adaptativos dos modelos						
PMC	21	26	21	16	13	13	15
ANFIS	304	170	228	54	40	88	62
	Tempo médio consumido no treinamento (em segundos)						
PMC	620 s	328 s	350 s	289 s	295 s	213 s	307 s
ANFIS	549 s	84 s	9 s	9 s	7 s	13 s	14 s

Fonte: Proposto pelo autor.

Ainda que o treinamento dos modelos de predição baseados em ANFIS requeira o ajuste de muito mais parâmetros adaptativos do que os modelos PMC, o treinamento dos modelos ANFIS dispendeu menos em todos os processos de treinamento computacionais realizados. Isso pode ser atribuído ao tempo de convergência dos métodos de aprendizagem usados em cada técnica. Como o processo de convergência usando a versão original do método *backpropagation* nos modelos PMC se mostrou mais lento, o número de épocas adotado como critério de parada foi 10 vezes maior do que aquele adotado para o algoritmo de treinamento dos sistemas ANFIS. Conforme pode ser visto nas Figuras 63, 64 e 68 (Subseção 4.2.4 do Capítulo 4), no caso dos modelos PMC 1, 2 e 6, a minimização do erro quadrático médio ocorreu ao longo das 20.000 épocas de treinamento, enquanto o modelo ANFIS 3 (Figura 74), cuja convergência foi a mais demorada dentre os modelos ANFIS desenvolvidos, consumiu cerca de 50 épocas até a estabilização. Portanto, considerando o tempo consumido por ambos

os modelos no processo de treinamento, conclui-se que o método de aprendizagem usado nos modelos ANFIS é mais eficiente do que dos modelos PMC.

Outro aspecto importante referente ao treinamento dos modelos de predição PMC e ANFIS consiste na quantidade de amostras que são requeridas por cada técnica para alcançar um determinado nível de precisão nas estimativas fornecidas. Caso os sistemas de predição de desempenho sejam compostos pelos indicadores do modelo SCOR[®], as amostras podem ser geradas utilizando as fórmulas de cálculo sugeridas por este modelo, não requerendo assim esforços consideráveis. Contudo, em aplicações reais usando indicadores cujos relacionamentos de causa e efeito não estejam explicitados quantitativamente, caso não exista um histórico de informações de desempenho, será necessário coletar periodicamente amostras reais dos valores dos indicadores de entrada e saída dos sistemas de predição. Nessas situações, a quantidade de amostras necessárias ao treinamento e os investimentos para coleta destes dados podem dificultar ou inviabilizar a implantação do sistema de predição de desempenho. Embora tenha sido adotada a mesma quantidade de amostras para o treinamento dos modelos de predição ANFIS e PMC, os testes realizados durante a definição do tamanho dos subconjuntos de treinamento mostraram que os modelos de predição ANFIS são capazes de alcançar um nível de precisão igual ou superior aos modelos PMC usando uma quantidade menor de amostras de treinamento. Nesse sentido, nas situações em que é necessário coletar os dados para o treinamento do sistema de predição, a adoção de sistemas ANFIS se mostra mais adequada por dispendir menos tempo e recursos para a obtenção dos dados, contribuindo assim para a agilidade do desenvolvimento e implantação do sistema.

O Quadro 29 resume os resultados da avaliação da complexidade da modelagem dos sistemas de predição PMC e ANFIS. Diante desses resultados, conclui-se que os sistemas ANFIS utilizam uma maior quantidade de parâmetros adaptativos que os modelos PMC e requerem a definição de um número maior de elementos relacionados à configuração topológica. Entretanto, o processo de ajuste dos modelos ANFIS ao ambiente de uso tende a ser mais ágil, já que estes exigem uma menor quantidade de amostras de treinamento e consomem menos tempo no processo de convergência do algoritmo de aprendizagem.

Quadro 29 – Síntese dos resultados da avaliação da complexidade do processo de modelagem dos sistemas de predição PMC e ANFIS

	PMC	ANFIS
Nº de escolhas relacionadas à configuração topológica do modelo	Menor	Maior
Nº de definições relacionadas ao processo de treinamento	Igual	
Quantidade de parâmetros adaptativos	Menor	Maior
Tempo médio consumido no treinamento	Maior	Menor
Quantidade de dados requeridos no treinamento	Maior	Menor

Fonte: Proposto pelo autor.

5.4 QUANTIDADE DE VARIÁVEIS DE ENTRADA

Uma das críticas mais frequentemente apontadas na literatura sobre redes neurais e sistemas neuro-*fuzzy* se refere ao uso de um pequeno número de variáveis de entrada (KHOSHNEVISAN et al., 2014). Uma vez que a quantidade máxima de variáveis de entrada usada em sistemas de predição ANFIS e PMC depende de diversos fatores e por isso não pode ser definida com exatidão, a discussão apresentada nesta subseção busca analisar qualitativamente os efeitos da quantidade de variáveis de entrada dos sistemas de predição de desempenho sobre o processo de modelagem e uso. As informações apresentadas poderão ajudar o desenvolvedor do sistema de predição a balancear a quantidade de indicadores de tendência que serão usados para prever o valor de um indicador de resultado.

O Quadro 30 sintetiza algumas informações referentes aos modelos PMC e ANFIS desenvolvidos na etapa de validação cruzada. Dentre os modelos de predição desenvolvidos, o maior número de variáveis de entrada foi usado no modelo 1, o qual possui oito indicadores de tendência. Devido ao maior número de variáveis de entrada, esse também é o modelo de predição que demandou maior quantidade de amostras de treinamento. O número máximo de variáveis de entrada que podem ser usados mantendo um determinado nível de precisão das estimativas também é influenciado pelo tipo de relacionamento existente entre as variáveis de entrada e de saída. Enquanto os modelos que quantificam relacionamentos lineares são capazes de comportar um maior número de entradas, os modelos que quantificam relacionamentos não lineares, como o PMC 3 e o ANFIS 3, possibilitam o uso de uma quantidade menor de variáveis de entrada e costumam fornecer estimativas menos precisas.

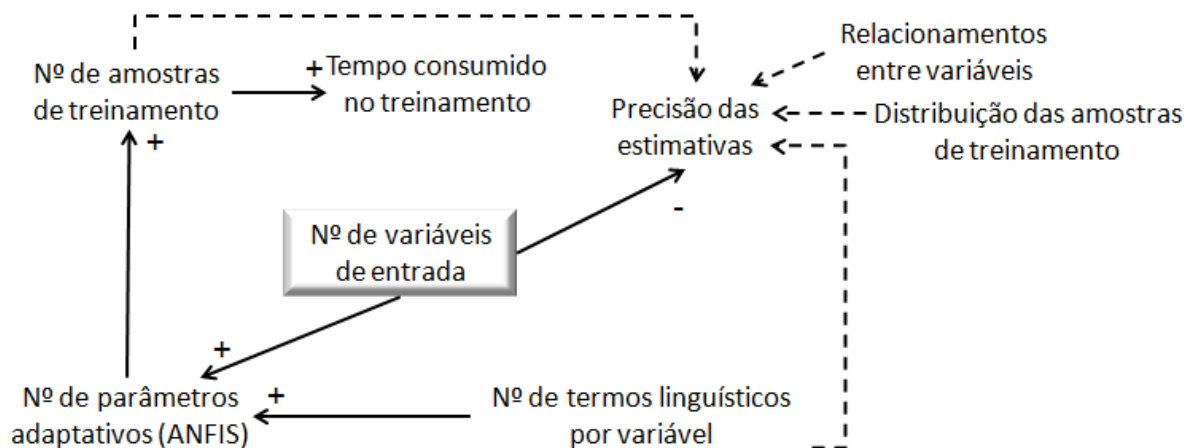
Quadro 30 – Síntese de algumas informações sobre os modelos PMC e ANFIS

Modelo	Nº de variáveis de entrada	Operações entre as variáveis de entrada	Tipo de relacionamento	Quantidade de amostras de treinamento	MSE médio na etapa de teste (PMC)	MSE médio na etapa de teste (ANFIS)
1	8	Soma	Linear	700	$3,805 \times 10^{-4}$	$4,4936 \times 10^{-11}$
2	3	Soma e subtração	Linear	350	$2,208 \times 10^{-4}$	$5,8447 \times 10^{-15}$
3	3	Subtração e divisão	Não linear	350	$8,393 \times 10^{-4}$	$3,6508 \times 10^{-7}$
4	4	Soma e subtração	Linear	350	$1,591 \times 10^{-4}$	$1,1935 \times 10^{-13}$
5	4	Soma	Linear	350	$5,116 \times 10^{-4}$	$1,68 \times 10^{-10}$
6	4	Soma	Linear	210	$1,432 \times 10^{-8}$	$1,9203 \times 10^{-16}$
7	5	Soma	Linear	350	$6,9297 \times 10^{-5}$	$9,4665 \times 10^{-10}$

Fonte: Proposto pelo autor.

A Figura 84 apresenta um diagrama de influências entre alguns elementos referentes aos modelos de predição ANFIS. Nesse diagrama, os sinais posicionados no final das setas contínuas indicam o efeito do aumento do elemento de origem sobre o elemento de destino. As setas pontilhadas indicam efeitos que, dependendo de uma série de fatores, podem ser positivos ou negativos. Conforme ilustra a Figura 84, o aumento do número de variáveis de entrada e dos termos linguísticos usados nestas variáveis provoca a elevação do número de parâmetros adaptativos contidos no modelo. Consequentemente, o aumento do número de variáveis de entrada tende a diminuir a precisão das estimativas fornecidas pelo modelo, que passa a requerer uma quantidade maior de amostras de treinamento para o ajuste dos parâmetros adaptativos. O aumento do tamanho do subconjunto de treinamento pode elevar a precisão das estimativas, mas também aumenta o tempo decorrido até a convergência do algoritmo de aprendizagem e pode impactar sobre o tempo a ser investido na coleta de dados e no desenvolvimento do sistema. É importante ressaltar também que um aumento exagerado da quantidade de amostras de treinamento pode causar um efeito contrário, resultando na diminuição da precisão das estimativas. Outras estratégias que permitem aumentar o número de variáveis de entrada mantendo o nível de precisão das estimativas consistem: em balancear a quantidade de funções de pertinência (ou termos linguísticos) usadas nas variáveis de entrada por meio do processo de validação cruzada e; melhorar a qualidade das amostras de treinamento, incluindo valores representativos dos pontos extremos e de toda a faixa de valores do domínio de definição de cada variável de entrada.

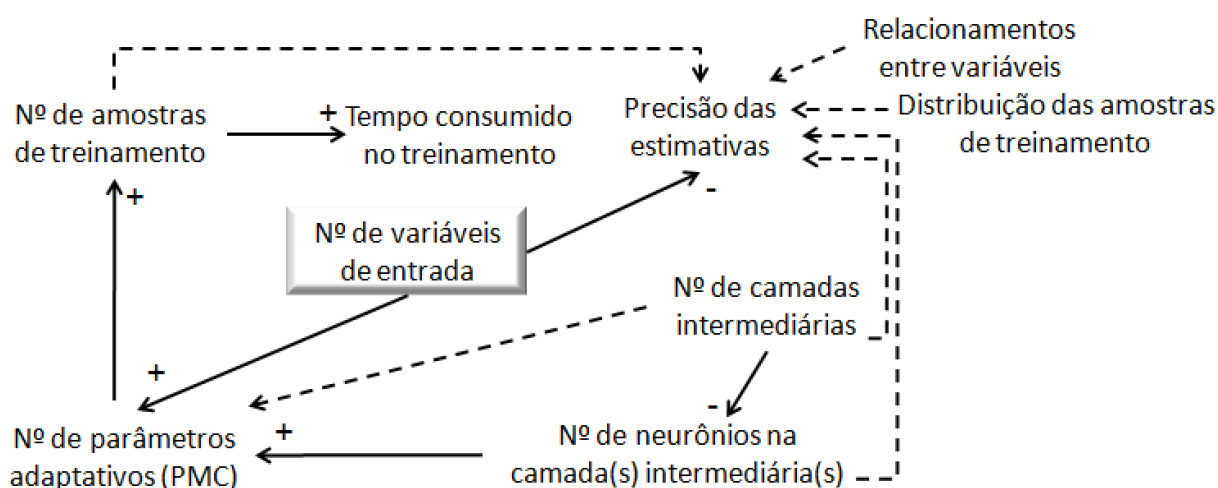
Figura 84 – Diagrama de influências entre elementos referentes aos modelos de predição ANFIS



Fonte: Proposto pelo autor.

A Figura 85 mostra um diagrama de influências entre alguns elementos relativos aos modelos de predição PMC. Similarmente à Figura 84, o aumento da quantidade de variáveis de entrada e do número de neurônios na camada intermediária resulta em um maior número de parâmetros adaptativos, diminuindo a precisão das estimativas fornecidas pelo modelo e passando a requerer uma quantidade maior de amostras de treinamento. Assim como nos modelos de predição ANFIS, a melhoria da qualidade das amostras de treinamento pode elevar a precisão das estimativas calculadas pelos modelos PMC. O redimensionamento do tamanho do subconjunto de treinamento também tem o potencial de melhorar a precisão das estimativas, embora contribua para o aumento do tempo decorrido até a convergência do algoritmo de aprendizagem e impacte sobre o tempo investido na coleta de amostras e no treinamento do sistema de predição. Uma alternativa que permite aumentar o número de variáveis de entrada mantendo o nível de precisão das estimativas, porém utilizando a mesma quantidade de amostras sem elevar consideravelmente o número de parâmetros adaptativos e o tempo de treinamento, consiste em inserir mais camadas intermediárias na estrutura da rede neural e diminuir o número de neurônios usados nestas camadas, com o apoio da técnica de validação cruzada.

Figura 85 – Diagrama de influências entre elementos relativos aos modelos de predição PMC



Fonte: Proposto pelo autor.

Outra solução plausível que possibilita aumentar a quantidade de indicadores de tendência usados nos modelos de predição PMC e ANFIS se refere ao uso de sistemas arrançados em cascata, de modo que a saída de um sistema sirva como entrada para o sistema posterior. Um exemplo desse arranjo pode ser visto na Figura 59 (p. 165), na qual algumas das entradas do modelo 3 são constituídas pelas saídas dos modelos 1 e 2. Outro exemplo de arranjo em cascata que possibilitou diminuir a quantidade total de regras de inferência do modelo é apresentado em Lima Junior, Osiro e Carpinetti (2013).

Diante do exposto, conclui-se que apesar da quantidade de variáveis de entrada dos modelos de predição PMC e ANFIS ser limitada, há diversas estratégias disponíveis que permitem aumentar o número de indicadores de tendência usados sem afetar significativamente a precisão das estimativas. Os resultados da implementação computacional mostraram que, em modelos de predição de desempenho incumbidos de quantificar relacionamentos de causa e efeito lineares, é possível utilizar oito variáveis de entrada e alcançar um nível de precisão satisfatório. Embora o uso dessa quantidade de indicadores de tendência para prever um indicador de resultado pareça suficiente, pode haver situações em que a limitação na quantidade de variáveis de entrada nos sistemas de predição PMC e ANFIS inviabilize sua adoção, já que existem técnicas de decisão multicritério como TOPSIS, *Fuzzy* TOPSIS e *Fuzzy* QFD que, apesar de não serem capazes de modelar relacionamentos de causa e efeito não lineares, não limitam a quantidade de variáveis de entrada.

Por último, ressalta-se que os resultados apresentados nesta subseção foram obtidos com base nos testes realizados durante a implementação computacional, que por sua vez foi apoiada pela revisão da literatura. As análises referentes à quantidade de variáveis de entrada podem ser generalizadas para outros domínios de problema envolvendo aproximação funcional, porém

não se pode afirmar se são aplicáveis a problemas de classificação de padrões, agrupamento de dados e previsão de séries temporais.

5.5 ADEQUAÇÃO A MUDANÇAS DAS MÉTRICAS E ALTERNATIVAS

Posto que a atualização do sistema de predição de desempenho pode implicar na inclusão ou exclusão de alguns indicadores, é importante analisar o efeito da inclusão e da exclusão de variáveis de entrada nestes sistemas. Tanto nos modelos PMC quanto nos modelos ANFIS, a inclusão ou exclusão de indicadores de tendência implica na necessidade de reprojeter o sistema de predição, o que inclui a revisão da configuração topológica do sistema e a realização de uma nova série de treinamentos, usando um novo conjunto de amostras que contenha valores representativos das novas variáveis de entrada. Além disso, no caso dos modelos ANFIS, as alterações das variáveis de entradas invalidam todo o conjunto de regras de decisão do sistema, por isso também é necessário reconstruí-las.

Em ambos os tipos de modelo de predição de desempenho, a inclusão e a exclusão de alternativas (cadeias de suprimento avaliadas pelo sistema de predição) pode ser feita sem afetar a estrutura dos modelos computacionais. Entretanto, como as pontuações das alternativas devem ser normalizadas dividindo-as pela pontuação de maior valor, sempre que uma nova alternativa com pontuação superior em algum indicador for inserida, o procedimento de normalização dos valores de entrada irá diminuir estes valores e conseqüentemente também diminuirá as pontuações de saída das alternativas. Analogamente, caso seja excluída alguma alternativa que apresente um desempenho superior em um ou mais indicadores, os valores de entrada e a pontuação de saída estimada para as demais alternativas também serão maiores. Todavia, desde que os valores de saída sejam reconvertidos para sua escala de valores reais por meio da reversão da normalização, multiplicando as pontuações finais das alternativas pelo valor máximo do indicador de saída definido na etapa de treinamento, essa variação nos valores de pontuação final não implicará em nenhum prejuízo na precisão e interpretação das estimativas. Além disso, as mudanças das alternativas nos modelos de predição ANFIS e PMC não alteram a ordenação relativa dada pelo ranqueamento das pontuações de saída, o que possibilita que estes modelos sejam usados para apoiar processos de *benchmarking* cujo objetivo seja obter o posicionamento relativo entre diferentes cadeias.

Portanto, conclui-se que ambos os modelos são parcialmente adequados para suportar as mudanças de alternativas e métricas, já que ambos são capazes de lidar com a inclusão ou exclusão de alternativas sem causar efeitos indesejáveis, mas não se mostram flexíveis nas situações em que é preciso atualizar as métricas do sistema de predição de desempenho.

5.6 MODELAGEM DE INCERTEZA

A discussão apresentada nessa subseção analisa a adequação dos modelos de predição PMC e ANFIS para apoiar a tomada de decisão em situações de predição de desempenho de cadeias de suprimento que envolvem incerteza determinística. Conforme mencionado anteriormente, essa incerteza é caracterizada pela imprecisão dos valores das variáveis que são apresentados aos modelos durante as etapas de treinamento e uso, podendo ser resultante da ausência de dados históricos, existência de informações conflitantes, subjetividade dos tomadores de decisão e / ou dificuldade de avaliação de aspectos qualitativos de desempenho.

Os modelos de predição ANFIS contam com dois principais recursos que os tornam adequados para apoiar a tomada de decisão em situações que envolvem incerteza: a representação *fuzzy* das variáveis de entrada e; a forma de processamento da base de regras de inferência. A representação dos valores em formato *fuzzy* permite a quantificação da imprecisão devido à lógica que define o grau de inclusão (ou de pertinência) dos elementos nos conjuntos *fuzzy*, possibilitando a representação matemática de julgamentos aproximados. Além disso, a possibilidade de representar as variáveis *fuzzy* usando termos linguísticos é especialmente útil para modelar indicadores qualitativos e para lidar com a subjetividade do tomador de decisão, uma vez que os valores dos vértices dos conjuntos *fuzzy* podem ser escolhidos de modo a representar sua visão particular sobre o comportamento dos indicadores e sobre o desempenho da cadeia. Os modelos ANFIS possibilitam que as faixas de valores *fuzzy* correspondentes a cada termo linguístico sejam modeladas levando em conta o rigor de avaliação e a experiência do tomador de decisão.

Em relação às regras de inferência dos sistemas de predição ANFIS, sua estrutura é capaz de representar um conjunto de hipóteses sobre o comportamento do problema modelado a partir da combinação de todos os valores categóricos (ou termos linguísticos) possíveis para cada variável de entrada. O modo de funcionamento dos sistemas de predição ANFIS procura imitar o raciocínio humano por meio do estabelecimento de relações de causa e efeito entre as variáveis e da consideração de cenários incertos. Quando um conjunto de valores numéricos de entrada é apresentado ao sistema, a combinação dos termos ativados tende a acionar mais de uma regra de inferência simultaneamente, de modo a considerar que mais de um cenário é verdadeiro frente às amostras apresentadas e que a existência de cada cenário possui um grau de verdade específico, quantificado pelo grau de ativação da regra correspondente. O valor de saída do sistema será calculado considerando a combinação de todos os cenários ativados, ponderados pelos seus respectivos graus de verdade. Apesar de serem capazes de representar e

processar informações em formato linguístico, os modelos ANFIS não possibilitam que os tomadores de decisão forneçam os valores de desempenho da cadeia de suprimento usando julgamentos linguísticos.

Ao contrário dos modelos ANFIS, os modelos PMC representam as variáveis e processam as informações em formato *crisp* (numérico), não possuindo nenhum mecanismo para lidar com a subjetividade dos tomadores de decisão nem para representar valores imprecisos ou cenários aproximados. Diante disso, conclui-se que somente os modelos ANFIS se mostram adequados para o uso em situações de predição de desempenho de cadeias de suprimento que envolvem incerteza determinística.

5.7 INTERPRETABILIDADE DOS DADOS

A avaliação da interpretabilidade dos dados analisa como a forma de representação e de cálculo dos indicadores dos sistemas de predição de desempenho pode ajudar ou dificultar o entendimento dos valores estimados.


Quanto à forma de representação dos valores dos indicadores de entrada e saída, os modelos de predição PMC e os modelos ANFIS utilizam um conjunto contínuo de valores numéricos reais distribuídos ao longo do domínio de definição da variável. Essa forma de representação é de fácil entendimento e não requer conhecimento sobre nenhuma teoria matemática específica. Entretanto, caso as variáveis estejam definidas no intervalo $[0, 1]$, a normalização dos valores calculados para as variáveis de saída é indispensável para interpretar se o nível de desempenho estimado está abaixo ou acima do esperado.

Nos sistemas de predição baseados em redes PMC, uma limitação se deve ao fato de as redes neurais artificiais funcionarem como uma caixa preta, uma vez que estas não possuem uma interface com o usuário, sendo muito difícil extrair o conhecimento armazenado na rede e entendê-lo na forma de medidas puramente numéricas (AKKOÇ, 2012). Os valores dos pesos sinápticos das conexões das variáveis de entrada com os neurônios da camada intermediária não podem ser interpretados como o peso (ou nível de importância relativa) destas variáveis, sendo que alguns dos pesos destas conexões sinápticas consistem em valores negativos. Portanto, como a forma de cálculo dos indicadores de resultado nas redes neurais artificiais não é transparente, as saídas produzidas pela rede frente à apresentação de um conjunto de valores de entrada não podem ser explicadas por nenhuma regra lógica, o que dificulta a justificação das decisões tomadas a partir das respostas da rede (AKKOÇ, 2012; APICHOTTANAKUL; PATHMNAKUL; PIEWTHONGNGAM, 2012).

Nos modelos de predição ANFIS, o cálculo dos valores de saída é mais transparente do que nos modelos de predição PMC devido à existência da base de regras de inferência. Como as variáveis de entrada são parametrizadas por meio de valores linguísticos facilmente interpretáveis, a combinação destes valores linguísticos na forma de regras de decisão fornece ao gestor uma melhor compreensão dos cenários do problema modelado. A possibilidade de visualizar as regras ativadas frente à apresentação de determinados valores de entrada, com o auxílio de ferramentas computacionais como *fuzzy toolbox* do MATLAB, permite ao gestor identificar as regras de decisão que justificam os valores de saída fornecidos pelo sistema. Contudo, para entender a forma de processamento dos modelos ANFIS, é necessário que o gestor tenha conhecimentos sobre lógica e inferência *fuzzy*.

A Figura 86 ilustra a base de regras do modelo de predição ANFIS 7, formado por 5 variáveis de entrada, representadas nas 5 primeiras colunas, e uma de saída, posicionada na última coluna. Cada variável de entrada possui 2 termos linguísticos (“baixo” e “alto”), totalizando 32 regras, representadas nas linhas. Os termos linguísticos e os parâmetros dos consequentes das regras foram ajustados por meio do processo de treinamento supervisionado. A partir da apresentação dos valores de entrada 1; 0,5; 0,5; 0,5 e 1, representados pelas linhas vermelhas verticais, são ativados os termos linguísticos destacados em amarelo. As regras ativadas foram as de número 18, 20, 22, 24, 26, 28, 30 e 32. As contribuições individuais de cada uma delas são representadas pelas regiões *crisp* destacadas em azul marinho na sexta coluna. A agregação dos valores representados por essas regiões usando média ponderada (pelo grau de ativação da regra) gera o valor do indicador de resultado.


Figura 86 – Base de regras ajustada do modelo de predição ANFIS 7



Fonte: Proposto pelo autor.

Alguns autores apontam que o ajuste dos conjuntos *fuzzy* na etapa de treinamento dos modelos ANFIS leva à diminuição ou perda da interpretabilidade dos termos linguísticos das variáveis de entrada (PAIVA; DOURADO, 2004). Dentre os modelos de predição ANFIS implementados nesta pesquisa, os que utilizam funções de pertinência do tipo triangular não tiveram nenhuma alteração em relação aos valores iniciais definidos pelo particionamento simétrico do domínio de definição das variáveis. Entretanto, no caso dos modelos ANFIS 3 e 6, que utilizam funções gaussianas, o ajuste das funções de pertinência durante o processo de treinamento alterou significativamente as funções de pertinência de algumas variáveis de entrada. A Figura 87 mostra as funções de pertinência de duas variáveis de entrada do modelo ANFIS 3 após o processo de treinamento.

Figura 87 – Funções de pertinência de duas variáveis do modelo ANFIS 3 após o treinamento



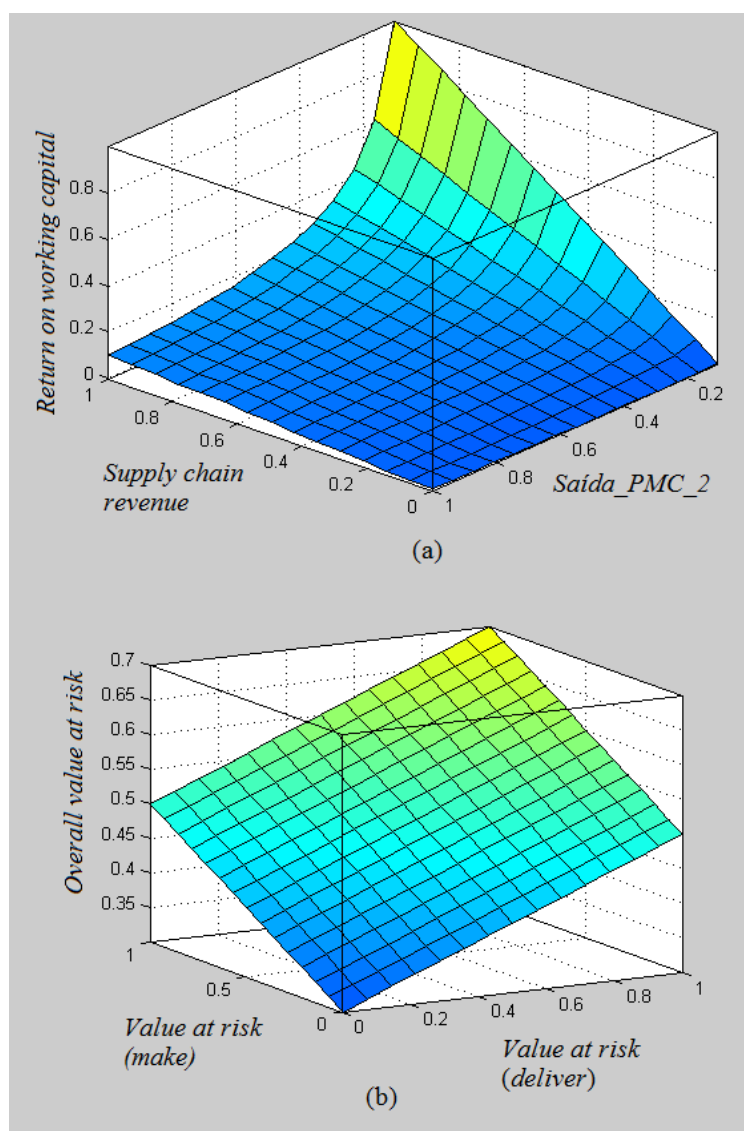
Fonte: Proposto pelo autor.

Enquanto o indicador *supply chain revenue* mantém um particionamento simétrico entre os termos linguísticos (Figura 87a), todas as funções de pertinência da segunda variável

(indicador de saída do modelo 2) foram deslocadas à esquerda (Figura 87b). Além disso, as funções referentes aos termos linguísticos “médio” e “alto” foram alargadas, em contraste com a função do termo “baixo”, que passou a ser mais estreita. Já o ponto em que o grau de pertinência do termo “muito baixo” é máximo foi deslocado para fora do domínio de definição da variável. Apesar dessas alterações, a posição relativa entre os termos linguísticos ainda é a mesma, de modo que a interpretação do significado semântico destes não fica prejudicada.

Outro recurso oferecido pela ferramenta computacional *fuzzy toolbox* MATLAB que favorece o entendimento do comportamento do indicador de resultado é a visualização do gráfico da superfície de resposta da variável de saída do modelo. A análise das funções representadas nestes gráficos permite avaliar os efeitos de interação entre os indicadores de desempenho. A Figura 88 mostra a superfície de resposta dos modelos de predição ANFIS 3 (a) e ANFIS 7 (b), gerada a partir da combinação dos valores de duas de suas variáveis de entrada. Na Figura 88a, pode-se perceber a relação não linear entre a variável “saída_PMC_2” e o indicador “*return on working capital*”, bem como a relação linear entre *chain revenue* e “*return on working capital*”. Conforme os valores da variável “saída_PMC_2” ultrapassam 0,5, o efeito do aumento destes valores sobre a variável de saída é cada vez menor. Já a Figura 88b mostra que o aumento dos valores dos indicadores *value at risk (make)* e *value at risk (delivery)* contribui linearmente para o aumento do indicador *overall value at risk*.

Figura 88 – Gráficos de superfície de resposta dos modelos de predição ANFIS 3 (a) e ANFIS 7 (b)



Fonte: Proposto pelo autor.

Em suma, a forma de representação numérica dos valores dos indicadores nos modelos de predição PMC e ANFIS se mostra adequada por ser facilmente interpretável. Porém, os modelos ANFIS apresentam recursos que tornam o processo de cálculo dos indicadores de saída mais transparente do que nos modelos PMC, permitindo a identificação das regras que justificam os resultados da predição e o entendimento do comportamento da variável de saída a partir da interação entre as variáveis de entrada.

5.8 SÍNTESE DAS VANTAGENS E LIMITAÇÕES DOS MODELOS DE PREDIÇÃO

O Quadro 31 apresenta uma síntese dos resultados apresentados ao longo deste capítulo, listando as vantagens e limitações dos modelos de predição de desempenho baseados em redes neurais do tipo PMC e em sistemas neuro-*fuzzy* do tipo ANFIS. Tanto os modelos ANFIS

quanto PMC se mostram adequados para suportar mudanças no conjunto de alternativas e inadequados para a realização de mudanças das métricas. Os modelos PMC se mostraram mais adequados do que os modelos ANFIS no que tange a complexidade da definição da configuração topológica. Em contrapartida, os modelos ANFIS se sobressaíram em relação à capacidade de predição, complexidade do treinamento, quantidade de variáveis de entrada, suporte à tomada de decisão sob incerteza e interpretabilidade dos dados.

Quadro 31 – Síntese dos resultados da avaliação da adequabilidade dos modelos PMC e ANFIS

	Vantagens		Limitações	
	PMC	ANFIS	PMC	ANFIS
Capacidade de predição	- Satisfatória.	- Satisfatória. - Fornece estimativas mais precisas que o PMC.	- Fornece estimativas menos precisas que o ANFIS. - Menor capacidade de predição em modelos com relacionamentos não lineares entre as variáveis. - O nível de precisão das estimativas varia de acordo com o conjunto de dados apresentados ao sistema.	- Menor capacidade de predição em modelos com relacionamentos não lineares entre as variáveis. - O nível de precisão das estimativas varia de acordo com o conjunto de dados apresentados ao sistema.
Complexidade da definição da configuração topológica	- Requer a definição de menos elementos do que os modelos PMC.	---	- Necessidade de muitos treinamentos para definir os elementos estruturais e os valores dos parâmetros.	- Necessidade de muitos treinamentos para definir os elementos estruturais e os valores dos parâmetros. - Requer a definição de mais elementos do que os modelos PMC.
Complexidade do treinamento	---	- O processo de convergência do algoritmo de aprendizagem é mais rápido que do PMC. Portanto, a etapa de treinamento consome menos tempo. - A quantidade de dados requerida para o treinamento é menor que no PMC.	- O processo de convergência do algoritmo de aprendizagem é mais demorado do ANFIS. Assim, a etapa de treinamento consome mais tempo. - A quantidade de dados requerida para o treinamento é maior que no ANFIS.	---
Quantidade de variáveis de entrada	- Há estratégias que possibilitam aumentar o número de variáveis de	- Capaz de alcançar maior precisão que o PMC quando são usadas muitas variáveis.	- A quantidade de variáveis de entrada é limitada.	- A quantidade de variáveis de entrada é limitada.

	Vantagens		Limitações	
	PMC	ANFIS	PMC	ANFIS
	entrada sem prejudicar a precisão das estimativas.	- Há estratégias que possibilitam aumentar o número de variáveis de entrada sem prejudicar a precisão das estimativas.		
Mudanças das alternativas	- Pode ser feita sem gerar alterações no resultados e sem comprometer a o estrutura do sistema.	- Pode ser feita sem gerar alterações no resultados e sem comprometer a o estrutura do sistema.	---	---
Mudanças das métricas	---	---	- O sistema precisa ser refeito quando ocorrem mudanças das métricas.	- O sistema precisa ser refeito quando ocorrem mudanças das métricas.
Suporte à tomada de decisão sob incerteza	---	- Lida com incerteza por meio da representação <i>fuzzy</i> das variáveis de entrada e da forma de processamento da base de regras.	- Não provê suporte à tomada de decisão sob incerteza.	---
Interpretabilidade dos dados	- A representação dos valores dos indicadores de entrada e saída é de fácil interpretação.	- A representação dos valores dos indicadores de entrada e saída é de fácil interpretação. - O procedimento de cálculo das variáveis de saída é mais transparente do nos modelos PMC, permitindo a identificação das regras que justificam os resultados da predição. - O comportamento do indicador de resultado pode ser visualizado por meio do gráfico de superfície de resposta usando a ferramenta <i>fuzzy toolbox</i> MATLAB.	- O procedimento de cálculo das variáveis de saída não é transparente, sendo muito difícil, ou talvez impossível, extrair o conhecimento armazenado na rede e entendê-lo na forma de medidas puramente numéricas.	- O entendimento do procedimento de cálculo das variáveis de saída requer que o gestor domine lógica e inferência <i>fuzzy</i> .

Fonte: Proposto pelo autor..

Os valores do MSE nos testes de predição utilizando os modelos PMC variaram aproximadamente entre 10^{-4} e 10^{-8} , enquanto os valores do MSE usando modelos ANFIS foram de 10^{-6} a 10^{-17} . Em ambos os tipos de modelo, uma desvantagem de uso é que o nível de precisão das estimativas fornecidas variou conforme o conjunto de dados apresentados ao sistema e o tipo de relacionamento modelado entre as variáveis de entrada e saída, sendo que a capacidade de predição foi menor em situações que envolvem indicadores com relacionamentos não lineares. Um fator que pode dificultar a adoção dos modelos PMC e ANFIS em aplicações reais é que ambos requerem a realização de vários testes computacionais para a escolha da configuração topológica e dos valores de parâmetros do sistema. Apesar da quantidade de elementos a serem definidos nos modelos PMC ser menor que nos modelos ANFIS, a quantidade de dados necessária para o treinamento e o tempo consumido nos processos de aprendizagem são maiores. Esse resultado está alinhado com as conclusões obtidas por Göktepe, Agar e Lav (2004), que constatou que o uso de ANFIS é mais adequado do que de redes PMC em situações que existem poucos dados.

Ainda que neste estudo tenham sido desenvolvidos modelos de predição de desempenho com até oito indicadores de entrada, a quantidade de indicadores de tendência que podem ser usados para prever o valor de um indicador de resultado nos modelos PMC e ANFIS é limitada. Todavia, há algumas estratégias que podem ser adotadas para tentar aumentar o número de variáveis de entrada sem afetar significativamente o nível de precisão das estimativas fornecidas.

Sobre a capacidade de suportar mudanças das variáveis de entrada, uma desvantagem que afeta os modelos PMC e ANFIS é a dificuldade de atualizar o sistema de predição de desempenho quando é necessário incluir ou excluir indicadores de desempenho, já que isso implica em reprojeter o sistema, de modo revisar sua configuração topológica e realizar uma nova série de treinamentos usando um novo conjunto de amostras que contenha valores representativos das novas variáveis de entrada. Entretanto, ambos os tipos de modelo de predição permitem incluir e excluir alternativas sem gerar alterações na pontuação final e na ordenação relativa entre elas, o que os torna adequados para apoiar processos de *benchmarking* entre diferentes cadeias de suprimento, internas ou externas à empresa foco.

Ao contrário dos modelos de predição PMC, os modelos ANFIS se mostram adequados para apoiar a tomada de decisão sob incerteza, sendo capazes de representar valores imprecisos, modelar indicadores qualitativos e lidar com a subjetividade dos julgamentos de especialistas do domínio de problema. Além disso, nos modelos ANFIS, a forma de cálculo dos valores dos indicadores de saída é mais transparente que nos modelos PMC, propiciando que o gestor

identifique as regras de decisão que justificam os resultados da predição e conheça o comportamento do indicador de saída a partir dos efeitos de interação das variáveis de entrada.

Ao comparar o nível de adequabilidade dos modelos PMC e ANFIS à predição de desempenho baseada no SCOR[®] considerando os aspectos avaliados, os modelos ANFIS apresentam mais vantagens e menos limitações em relação ao PMC. Portanto, ainda que os modelos de predição de desempenho do tipo PMC tenham apresentado uma capacidade de predição satisfatória e atendido a alguns dos requisitos desse domínio de problema, a adoção de modelos de predição de desempenho ANFIS se mostra mais vantajosa principalmente pela obtenção de resultados mais precisos; por exigir menos tempo no desenvolvimento do sistema; requerer maior quantidade de dados de desempenho para o treinamento do sistema; ser capaz de lidar com a subjetividade dos especialistas, modelar variáveis qualitativas e valores aproximados e; por propiciar recursos que permitam ao gestor entender como os resultados foram calculados.

Capítulo 6

CONCLUSÃO

6.1 CONCLUSÃO

Este estudo propôs dois tipos de sistemas de predição de desempenho de cadeias de suprimento, baseados na combinação entre indicadores provenientes do modelo SCOR® (versão 11) e técnicas de inteligência computacional. Um dos tipos de sistemas de predição de desempenho utiliza redes neurais perceptron de múltiplas camadas (PMC) para modelar quantitativamente as relações de causa e efeito entre os indicadores de nível 2 (variáveis de entrada) e os de nível 1 (variáveis de saída). O outro tipo usa sistemas neuro-*fuzzy* ANFIS para modelar essas relações entre os mesmos indicadores. Cada tipo de sistema de predição de desempenho é composto por sete sistemas computacionais. A fim de escolher uma configuração topológica adequada para cada um dos modelos computacionais que compõem os dois sistemas de predição de desempenho, aplicou-se a técnica de validação cruzada usando o método de amostragem aleatória para a organização dos subconjuntos de treinamento e teste. No total, 70 modelos computacionais do tipo PMC foram implementados e avaliados de acordo o nível de precisão alcançado por suas estimativas. Analogamente, foram implementados e avaliados 56 modelos de predição do tipo ANFIS com o propósito de selecionar uma configuração topológica adequada para cada um dos sete modelos baseados nesta técnica. Visando minimizar a influência das características dos dados das amostras e dos valores iniciais de alguns parâmetros sobre a capacidade dos sistemas predição, os 126 modelos construídos foram treinados três vezes, totalizando assim 378 processos de treinamento. Para ambos os tipos de sistema de predição, a escolha das configurações topológicas adequadas foi feita com base no desempenho médio alcançado na etapa de teste ao longo dos três treinamentos.

Os resultados da implementação computacional dos modelos PMC mostraram que o uso da função tangente hiperbólica produziu os melhores resultados e que na maioria dos modelos é mais adequado utilizar uma quantidade de neurônios menor que o número de variáveis de entrada. Já os resultados da implementação dos modelos ANFIS indicam que o uso do operador produto algébrico é mais adequado para realizar as operações representadas pelos conectivos lógicos “AND”. Além disso, os resultados sugerem que na maioria dos modelos ANFIS, é mais adequado adotar apenas duas funções de pertinência do tipo triangular para modelar as variáveis de entrada, bem como utilizar valores constantes para quantificar os consequentes das regras de

inferência. Essas constatações vão de encontro com o estudo de Efendigil, Önüt e Kahraman (2009), que concluíram que a função tangente hiperbólica é a mais adequada para os neurônios da camada intermediária do PMC e que os modelos ANFIS produzem melhores resultados usando duas funções de pertinência nas variáveis de entrada e o operador produto algébrico.

Após a escolha das configurações topológicas dos modelos de predição de desempenho, a adequabilidade dos modelos PMC e ANFIS foi avaliada considerando o alinhamento das características das técnicas usadas com algumas particularidades desse domínio de problema, de modo a analisar como as características intrínsecas aos modelos PMC e ANFIS podem contribuir e / ou dificultar a predição de desempenho de cadeias de suprimento. Para conduzir a avaliação da adequabilidade dos modelos, foram considerados aspectos qualitativos e quantitativos, definidos por meio dos parâmetros: capacidade de predição de desempenho, complexidade do processo de modelagem em relação à definição da configuração topológica e ao processo de treinamento, quantidade de variáveis de entrada, adequação a mudanças das métricas e alternativas avaliadas, adequação à modelagem de incerteza e interpretabilidade dos dados. Esses parâmetros são relevantes para a predição de desempenho de cadeias de suprimento por estarem diretamente associados ao nível de precisão das estimativas fornecidas por cada técnica, ao esforço e tempo requeridos para o desenvolvimento de cada tipo de sistema de predição, à facilidade de atualização das métricas do sistema, à consistência dos resultados fornecidos quando novas cadeias são incluídas na avaliação, bem como à possibilidade de representar valores imprecisos e subjetivos e de entender como os resultados do sistema são calculados.

Ainda que os modelos PMC e ANFIS tenham apresentado uma capacidade de predição de desempenho satisfatória, os modelos ANFIS apresentam mais vantagens e menos limitações frente aos modelos PMC. Enquanto os modelos PMC se mostraram mais adequados do que os modelos ANFIS apenas em relação à complexidade da definição da configuração topológica, os modelos ANFIS se destacaram em relação à capacidade de predição, complexidade do treinamento, quantidade de variáveis de entrada, suporte à tomada de decisão sob incerteza e interpretabilidade dos dados. Portanto, dentre as duas técnicas avaliadas para apoiar a predição de desempenho de cadeias de suprimento, o uso de modelos ANFIS se mostra mais adequado principalmente por estes consumirem menor tempo no desenvolvimento e treinamento do sistema, possuírem capacidade de lidar com a subjetividade dos especialistas, modelar variáveis qualitativas e valores aproximados, bem como disporem de regras de decisão que propiciam um melhor entendimento ao gestor sobre como as variáveis de saída são calculadas, ajudando assim a justificar os resultados da predição de desempenho e os processos de tomada de decisão.

Uma limitação que afeta os modelos de predição de desempenho baseados em PMC e ANFIS se refere à ocorrência de variação da precisão das estimativas de acordo com as características dos dados apresentados ao sistema e com o tipo de relacionamento modelado entre as variáveis, uma vez que a capacidade de predição é mais baixa em aplicações envolvendo indicadores com relacionamentos não lineares. Outros complicadores que podem dificultar a adoção dos modelos de predição propostos são: a necessidade de realizar demasiados treinamentos para definir os elementos estruturais e os valores dos parâmetros de cada modelo computacional; a limitação na quantidade de indicadores de tendência que podem ser usados para prever o valor de um indicador de resultado e; a dificuldade de atualizar o sistema de predição de desempenho quando é necessário incluir ou excluir indicadores de desempenho, já que isso implica em reprojetar e treinar novamente os modelos usando novos subconjuntos de amostras.

Dentre as contribuições deste estudo para a literatura sobre gestão de desempenho de cadeias de suprimento, destacam-se as seguintes:

- **Proposição de novos sistemas de predição de desempenho de cadeias de suprimento:** uma das contribuições deste estudo consiste na proposição de novos sistemas de predição de desempenho, desenvolvidos com base na combinação de redes neurais PMC e sistemas neuro-*fuzzy* ANFIS com os indicadores do modelo SCOR[®]. Os sistemas de predição propostos podem ser de grande utilidade para gestores que desejem obter uma visão prospectiva do negócio a partir da comparação entre o desempenho estimado e o desempenho almejado para cada indicador de resultado. A ampla abrangência dos indicadores do SCOR[®] contribui para que o sistema de predição ajude a detectar as áreas do negócio que apresentam desempenho crítico, fornecendo subsídios para o planejamento de ações corretivas e o direcionamento de esforços focados no alcance de melhores resultados. O uso dos sistemas de predição propostos também permite aos gestores realizar simulações de cenários fictícios para avaliar a efetividade de possíveis estratégias de gestão de cadeias de suprimento. Quando comparados com os modelos de avaliação de desempenho baseados em PMC (FAN et al., 2013) e ANFIS (DIDEHKHANI; JASSBI; PILEVARI, 2009; JASSBI; SEYEDHOSSEINI; PILEVARI, 2010; CÔRREA; DA SILVEIRA, 2012), os sistemas propostos apresentam a vantagem de utilizar um conjunto de indicadores padronizados e mundialmente utilizados, o que tende a facilitar a comunicação e a integração dos dados de desempenho ao longo dos elos da cadeia. Outra vantagem é a possibilidade de usar os dados da base *SCORmark* para realizar *benchmarking* em nível global, a partir da

comparação das estimativas de desempenho obtidas com os valores alcançados por outras cadeias, seguido pelo estabelecimento de metas e de planos de ações de melhoria. Ao contrário dos modelos baseados na combinação entre os indicadores do SCOR[®] e métodos de tomada de decisão multicritério, os sistemas propostos por este estudo são capazes de modelar relacionamentos não lineares entre os indicadores de tendência e de resultados. Outra vantagem sobre esses modelos é a possibilidade de adaptação ao cenário de uso de forma automatizada, utilizando um método de aprendizagem supervisionado, que possibilita mapear o comportamento das variáveis e armazená-lo internamente na estrutura do modelo. Diferentemente dos modelos baseados nas técnicas AHP (SELLITO; MENDES, 2006; SELLITTO et al., 2015; BUKHORI; WIDODO; ISMOYOWATI, 2015) e TOPSIS (GOLPARVAR; SEIFBARGHY, 2009; KOCAOGLU; GÜLSÜN; TANYA, 2013), que podem apresentar um problema de inversão no ranqueamento quando novas alternativas são incluídas, nos modelos PMC e ANFIS a adição de novas alternativas não afeta os resultados das demais cadeias avaliadas. Além disso, ao contrário das abordagens comparativas baseadas em AHP – *Analytic Hierarchy Process* (SELLITO; MENDES, 2006; SELLITTO et al., 2015; BUKHORI; WIDODO; ISMOYOWATI, 2015), *MACBETH - Measuring Attractiveness by a Categorical Based Evaluation Technique* (CLIVILLÉ; BERRAH, 2012), entre outras técnicas (CHAN; QI, 2003; THEERANUPHATTANA; TANG, 2008; YANG; JIANG, 2012), que restringem a avaliação de desempenho a apenas 9 alternativas para não comprometer a consistência dos julgamentos dos tomadores de decisão, os modelos propostos não limitam a quantidade de cadeias de suprimento que podem ser avaliadas simultaneamente. Em relação aos modelos baseados em inferência *fuzzy* (GANGA; CARPINETTI, 2011; AGAMI et al., 2014), uma vantagem é que os modelos propostos apresentam uma capacidade adaptativa que permite que estes sejam ajustados ao ambiente de uso por meio de dados históricos, não requerendo a parametrização manual das variáveis *fuzzy* e dos consequentes das regras de decisão;

- **Avaliação da adequabilidade de redes neurais PMC e sistemas neuro-*fuzzy* ANFIS à predição de desempenho de cadeias de suprimento:** esse é o primeiro estudo da literatura acadêmica a avaliar a adequação de técnicas quantitativas às características da predição de desempenho de cadeias de suprimento, considerando um conjunto de parâmetros quantitativos e qualitativos propostos com base na literatura. Essa avaliação permitiu identificar vantagens e limitações de uso das redes neurais PMC e dos sistemas neuro-*fuzzy* ANFIS, o que é útil para ajudar pesquisadores e desenvolvedores de

sistemas especialistas a escolher uma técnica adequada para aplicação nesse domínio de problema. Os resultados da avaliação técnicas podem ser generalizados para outros domínios de problema envolvendo aproximação funcional. O conjunto de parâmetros propostos também pode ser adotado e adaptado por gestores e desenvolvedores para avaliar a adequabilidade de outras técnicas quantitativas no apoio à medição ou à predição de desempenho de cadeias de suprimento;

- **Recomendações sobre o processo de modelagem computacional:** A realização deste estudo também permitiu identificar particularidades do processo de modelagem e treinamento de sistemas ANFIS e PMC, quando aplicados à predição de desempenho de cadeias de suprimento usando os indicadores do SCOR[®]. Além de demonstrar a aplicação da técnica de validação de cruzada para a escolha das melhores configurações topológicas para os modelos de predição, as simulações computacionais realizadas permitiram fornecer recomendações sobre: a quantidade de dados necessários aos processos de treinamento de ambos os tipos de modelo; os tipos de função de ativação a serem usados nos neurônios dos modelos PMC; os operadores *fuzzy* usados nos conectivos lógicos das regras; os tipos de função de pertinência usados nas variáveis de entrada e; o tipo de consequente usado nas regras de inferência. Os Apêndices D e E sintetizam as recomendações relacionadas ao desenvolvimento de sistemas de predição de desempenho sugeridas por este estudo com base na revisão da literatura e na realização das simulações computacionais;
- **Mapeamento dos modelos quantitativos de avaliação de desempenho de cadeias de suprimento:** Outra contribuição desta pesquisa consiste em um levantamento bibliográfico sobre o uso de técnicas quantitativas na avaliação de desempenho de cadeias de suprimento. A revisão sistematizada da literatura sobre modelos quantitativos de avaliação de desempenho de cadeias de suprimento permitiu traçar um panorama do estado da arte deste tema de pesquisa, descrevendo os modelos existentes em relação ao escopo de avaliação, indicadores adotados, estratégia competitiva considerada, técnicas quantitativas usadas, origem dos dados, abordagem para modelagem de incerteza, formas de validação dos resultados, entre outros. Além disso, possibilitou a identificação de algumas lacunas de pesquisa sobre este tema;

Por último, outra contribuição desta pesquisa consiste no estabelecimento de uma interface entre a literatura das áreas de inteligência computacional, gestão de desempenho e gestão de cadeias de suprimento, posto que ainda há poucos estudos que integrem conceitos e

técnicas provenientes destas áreas visando ao avanço dos sistemas de avaliação de desempenho de cadeias de suprimento.

6.2 DIFICULDADES ENCONTRADAS

Uma das principais dificuldades encontradas para a condução deste estudo se deve à complexidade de definição do tamanho e da distribuição dos dados referentes aos subconjuntos de amostras usadas no treinamento dos modelos PMC e ANFIS. Na tentativa de que os modelos computacionais apresentassem estimativas mais precisas, foi necessário realizar muitos testes de simulação computacional envolvendo tentativa e erro, aumentando ou diminuindo o tamanho dos subconjuntos de treinamentos para cada modelo e tentando gerar amostras com valores representativos de todo o domínio de definição das variáveis de entradas. Outra dificuldade encontrada se refere à necessidade de fazer de muitos treinamentos para definir uma configuração topológica adequada para cada modelo computacional. Aliado a isso, a lentidão do processo de treinamento de alguns modelos PMC contribuiu para que as etapas de modelagem e simulação computacional consumissem mais tempo do que o planejado.

6.3 LIMITAÇÕES DA PESQUISA

Uma limitação desta pesquisa consiste em ter utilizado apenas um método de aprendizagem para treinar cada tipo de modelo de predição. Optou-se por utilizar apenas o método de aprendizagem originalmente proposto para cada técnica para não duplicar o número de treinamentos que seriam necessários para a condução desta pesquisa, que chegaria a 756 treinamentos caso dois métodos de aprendizagem fossem testados para cada técnica. O uso de métodos de aprendizagem diferentes daqueles usados neste estudo pode afetar os resultados da avaliação da adequabilidade das técnicas quanto à capacidade de predição e a complexidade de definição da configuração topológica e do treinamento.

Outra limitação se refere ao uso de dados simulados ao invés de dados reais. O uso de dados históricos do desempenho de cadeias de suprimento possibilitaria ajustar o universo de discurso das variáveis dos modelos de predição usando valores mais realísticos. Além disso, caso fosse possível o acesso de acadêmicos à base de dados *SCORmark*, poderia-se simular cenários de *benchmarking* entre cadeias de suprimento e analisar se existe diferença significativa entre as estimativas fornecidas pelos sistemas computacionais e os dados reais da base *SCORmark*.

6.4 SUGESTÕES PARA PESQUISAS FUTURAS

Estudos futuros podem implementar os modelos de predição propostos por esta pesquisa na forma de sistemas especialistas, com interface gráfica e outros elementos necessários a usuários não especialistas em redes neurais e sistemas neuro-*fuzzy*, e aplicá-los a situações reais de predição de desempenho de cadeias de suprimento, avaliando também sua facilidade de uso. Pesquisas futuras também poderão testar o uso de redes PMC e sistemas neuro-*fuzzy* ANFIS combinados com outros indicadores de desempenho, cujas relações de relações de causa e efeito não sejam conhecidas, visando à predição de desempenho organizacional ou de cadeias de suprimento. Outras sugestões para estudos futuros definidas a partir da realização da revisão sistematizada da literatura são:

- Aplicação de técnicas que ainda não foram testadas no apoio à avaliação de desempenho de cadeias de suprimento, como ORESTE (*Organization Rangement Et Synthese De Donnes Relationnelles*), SMART (*Simple Multi Attribute Rating Technique*), *intuitionistic fuzzy sets*, *hesitant fuzzy sets* e QFD (*Quality Function Deployment*);
- Aplicação do método *fuzzy* TOPSIS na realização de *benchmarking* entre cadeias de suprimento;
- Criação e avaliação de um novo modelo de predição de desempenho de cadeias de suprimento, baseados nas métricas do SCOR[®] em combinação com redes neurais artificiais do tipo função de base radial (RBF);
- Aplicação de redes neurais de entradas atrasadas (*Time Delay Neural Network*, TDNN) para analisar de forma prospectiva a estabilidade das métricas de desempenho de cadeias de suprimento adotadas;
- Desenvolvimento de modelos quantitativos focados na avaliação de desempenho de cadeias ágeis, enxutas e flexíveis;
- Realização de aplicações voltadas para setores que vêm recebendo pouca atenção, como os setores agrícola, governamental, moveleiro e naval;
- Desenvolvimento de modelos que ampliem o escopo da avaliação de desempenho ao longo da cadeia, incluindo métricas que representem o desempenho global das diferentes camadas sob avaliação.

•

REFERÊNCIAS¹

- ABOLGHASEMI, M.; KHODAKARAMI, V.; TEHRANIFARD, H. A new approach for supply chain risk management: Mapping SCOR into Bayesian network. **Journal of Industrial Engineering and Management**, v. 8, n. 1, p. 280-302, 2015.
- ABURTO, L.; WEBER, R. Improved supply chain management based on hybrid demand forecasts. **Applied Soft Computing**, v. 7, p.136-144, 2007.
- AGAMI, N.; SALEH, M.; RASMY, M. A Hybrid Dynamic Framework for Supply Chain Performance Improvement. **IEEE Systems Journal**, v.6, n.3, p.1932-8184, 2012.
- AGAMI, N.; SALEH, M.; RASMY, M. An Innovative Fuzzy Logic Based Approach for Supply Chain Performance Management. **IEEE Systems Journal**, v.8, n.2, p.336-342, 2014.
- AHI, P.; JABER, M.Y.; SEARCY, C. A comprehensive multidimensional framework for assessing the performance of sustainable supply chains. **Applied Mathematical Modelling**, 2016. doi: 10.1016/j.apm.2016.07.001
- AHI, P.; SEARCY, C. A comparative literature analysis of definitions for green and sustainable supply chain management. **Journal of Cleaner Production**, v. 52, p. 329-341, 2013.
- AHI, P.; SEARCY, C. Assessing sustainability in the supply chain: A triple bottom line approach. **Applied Mathematical Modelling**, v.39, n. 10-11, p. 2882-2896, 2015.
- AKKOÇ, S. An empirical comparison of conventional techniques, neural networks and the three stage hybrid Adaptive Neuro Fuzzy Inference System (ANFIS) model for credit scoring analysis: The case of Turkish credit card data. **European Journal of Operational Research**, v.222, p.168-178, 2012.
- ALBUQUERQUE, G.A; MACIEL, P.R.M.; LIMA, R. M. F.; ZIMMERMAN, A. Automatic Modeling for Performance Evaluation of Inventory and Outbound Distribution. **IEEE Transactions on Systems, Man, and Cybernetics**, v.40, n.5, p.1025-1044, 2010.
- ALTROCK, C. V. **Fuzzy Logic and Neurofuzzy - Applications in Business and Finance**. 1 ed. Prentice Hall: USA, 1995.
- AMARATUNGA, D.; BALDRY, D.; SARSHAR, M. Process Improvement Through Performance Measurement: The Balanced Scorecard Methodology. **School of Construction and Property Management, University of Salford**, v. 50, n. 5, p.179-189, 2001.
- APICHOTTANAKUL, A.; PATHUMNAKUL, S.; PIEWTHONGNGAM, K. The role of pig size prediction in supply chain planning. **Biosystems Engineering**, v.113, p.298-307, 2012.
- APICS, American Production and Inventory Control Society. **Benchmark your Supply Chain: Close Performance Gaps**. Disponível em: <<http://www.apics.org/sites/apics-supply-chain-council/products-and-services/benchmarking>>. Acesso em: 4 de mar. 2016.
- APICS, American Production and Inventory Control Society. **APICS Dictionary**, 9 ed. APICS – The Educational Society for Resource Management: Alexandria: 1998.
- AREERACHAKUL, S. Comparison of ANFIS and ANN for Estimation of Biochemical Oxygen Demand Parameter in Surface Water. **International Journal of Chemical and Biological Engineering**, v.6, p.286-290, 2012.
- ARIF-UZ-ZAMAN, K.; AHSAN, A.M.M.N. Lean supply chain performance measurement. **International Journal of Productivity and Performance Management**, v.63, n.5, p.588 - 612, 2014.
- ASHRAFUZZAMAN, M.; AL-MARUF, A.; MAHBUBUL, I.M.; ABDUL MALEK, A.B.M.; MUKADDES, A.M.M. Quality function deployment approach to measure supply chain performance: a case study on garments accessories industries. **International Journal of Industrial and Systems Engineering**, v. 22, n. 1, p. 96-120, 2016.
- AVINASH, S.; PRAKASH, K. A framework for performance measurement system of supply chain management. **International Journal of Advanced Engineering Technology**, v.2, n.4, p.182-190, 2011.

¹ De acordo com a Associação Brasileira de Normas Técnicas. NBR 6023

- AY, M.; KISI, O. Modelling of chemical oxygen demand by using ANNs, ANFIS and k-means clustering techniques. **Journal of Hydrology**, v. 511, p. 279-289, 2014.
- AZFAR, K. R. W.; KHAN, N.; GABRIEL, H. F. Performance measurement: A conceptual framework for supply chain practices. **Procedia - Social and Behavioral Sciences**, v. 150, p. 803-812, 2014.
- BAGHERI, A.; PEYHANI, H. M.; AKBARI, M. Financial forecasting using ANFIS networks with Quantum-behaved Particle Swarm Optimization. **Expert Systems with Applications**, v. 41, n. 14, p. 6235-6250, 2014.
- BAGHERIPOUR, P. Committee neural network model for rock permeability prediction. **Journal of Applied Geophysics**, v. 104, p. 142-148, 2014.
- BAI, C.; SARKIS, J. Flexibility in reverse logistics: a framework and evaluation approach. **Journal of Cleaner Production**, v.47, p.306-318, 2013.
- BAI, C.; SARKIS, J.; WEI, X.; KOH, L. Evaluating ecological sustainable performance measures for supply chain management. **Supply chain management: An International Journal**, v.17, n.1, p.78-92, 2012.
- BALFAQIH, H.; NOPIAH, Z.M.; SAIBANI, NIZARROYANI; AL-NORY; M. T. Review of supply chain performance measurement systems: 1998-2015. **Computers in Industry**, v. 82, p. 135-150, 2016.
- BAS, E. The integrated framework for analysis of electricity supply chain using an integrated SWOT-fuzzy TOPSIS methodology combined with AHP: The case of Turkey. **Electrical Power and Energy Systems**, v.44, n.1, p.897-907, 2013.
- BEAMON, B. M. Measuring supply chain performance. **International Journal of Operations & Production Management**, v. 19, n. 3-4, p. 275-292, 1999.
- BEHROUZI, F.; WONG, K.Y. An integrated stochastic-fuzzy modeling approach for supply chain leanness evaluation. **The International Journal of Advanced Manufacturing Technology**, v.68, n.5-8, p.1677-1696, 2013.
- BERGMEIR, C.; BENÍTEZ, J. M. On the use of cross-validation for time series predictor evaluation. **Information Sciences**, v. 191, p. 192-213, 2012.
- BERRAH, L; CLIVILLE, V. Towards an aggregation performance measurement system model in a supply chain context . **Computers in Industry**, v.58, n.7, p.709-719, 2007.
- BERTRAND, J.W.M.; FRANSOO, J. Operations management research methodologies using quantitative modeling. **International Journal of Operations and Production Management**, v. 22, n. 2, p.241-264, 2002.
- BHAGWAT, R.. SHARMA, M.K. An application of the integrated AHP-PGP model for performance measurement of supply chain management. **Production Planning & Control**, v.20, n.8, p.678-690, 2009.
- BHAGWAT, R.; SHARMA, M.K. Performance measurement of supply chain management using the analytical hierarchy process. **Production Planning & Control**, v.18, n.8, p.666-680, 2007.
- BHASKAR, V.; LALLEMENT, P. Activity routing in a distributed supply chain: Performance evaluation with two inputs. **Journal of Network and Computer Applications**, v.31, n.4, p.402-428, 2008.
- BHATTACHARYA, A.; MOHAPATRA, P.; KUMAR, V.; DEY, P.K.; BRADY, M.; TIWARI, M.K.; NUDURUPATI, S.S. Green supply chain performance measurement using fuzzy ANP-based balanced scorecard: a collaborative decision-making approach. **Production Planning & Control**, v.25, n.8, p.698-714, 2014.
- BILGEHAN, M. Comparison of ANFIS and NN models – with a study in critical buckling load estimation. **Applied Soft Computing**, v. 11, p. 3779-3791, 2011.
- BITITCI, U.; MENDIBIL, K.; MARTINEZ, V.; ALBORES, P. Measuring and managing extended enterprise. **International Journal of Operations & Production Management**, v.25, n.4, p.333-353, 2006.
- BITTENCOURT, G. **Inteligência artificial – ferramentas e teoria**. 3 ed. Editora da UFSC: Florianópolis, 2006.
- BOURNE, M.; NEELY, A.; PLATTS, K.; MILLS, J. The success and failure of performance measurement initiatives. **International Journal of Operations & Production Management**, v. 22, n. 11, p. 1288-1310, 2002.

- BOWERSOX, D. J.; COOPER, M. B.; CLOSS, D. J. **Gestão Logística de Cadeia de Suprimentos**. Porto Alegre: Bookman, 2006.
- BRAZ, R. G. F.; SCAVARDA, L. F.; MARTINS, R. A. Reviewing and improving performance measurement systems: An action research. **International Journal Production Economics**, v. 133, p. 751-760, 2011.
- BROCK III, L. G.; DAVIS, L. B. Estimating available supermarket commodities for food bank collection in the absence of information. **Expert Systems with Applications**, v. 42, n. 7, p. 3450-3461, 2014.
- BUKHORI, I.B.; WIDODO, K.H.; ISMOYOWATI, D. Evaluation of Poultry Supply Chain Performance in XYZ Slaughtering House Yogyakarta using SCOR and AHP Method. **Agriculture and Agricultural Science Procedia**, v.3, p.221 – 225, 2015.
- CAI, J.; LIU, X.; XIAO, Z.; LIU, L. Improving supply chain performance management: A systematic approach to analyzing iterative KPI accomplishment. **Decision Support Systems**, v.46, n.2, p.512–521, 2009.
- CHAN, F. T. S.; NAYAK, A.; RAJ, R.; CHONG, A. Y.-L.; MANOJ, T. An innovative supply chain performance measurement system incorporating Research and Development (R&D) and marketing policy. **Computers & Industrial Engineering**, v. 69, p. 64-70, 2014.
- CHAN, F.S.T. Performance Measurement in a Supply Chain. **International Journal of Advanced Manufacturing Technology**, v.21, n., p.534–548, 2003.
- CHAN, F.T.S.; QI, H.J. An innovative performance measurement method for supply chain management. **Supply chain management: An International Journal**, v.8, n.3, p.123-110, 2003.
- CHAN, F.T.S.; QI, H.J.; CHAN, H.K.; LAU, H.C.W.; IP, R.W.L. A conceptual model of performance measurement for supply chain. **Management Decision**, v.41, n.7, p.635-642, 2003.
- CHEN, C. T. Extensions of the TOPSIS for group decision-making under fuzzy environment. **Fuzzy Sets and Systems**, v. 114, p. 1–9, 2000.
- CHEN, C.; YAN, H. Network DEA model for supply chain performance evaluation. **European Journal of Operational Research**, v.213, n.1, p.147–155, 2011.
- CHEN, H.; AMODEO, L.; CHU, F.; LABADI, K. Modeling and Performance Evaluation of Supply Chains Using Batch Deterministic and Stochastic Petri Nets. **IEEE Transactions on Automation Science and Engineering**, v.20, n.2, p.1545-5955, 2005.
- CHITHAMBARANATHAN, P.; SUBRAMANIAN, N.; GUNASEKARAN, A.; PALANIAPPAN, P.L.K. Service supply chain environmental performance evaluation using grey based hybrid MCDM approach. **International Journal of Production Economics**, doi:10.1016/j.jclepro.2014.07.054, 2015.
- CHITHAMBARANATHAN, P.; SUBRAMANIAN, N.; PALANIAPPAN, P.L.K. An innovative framework for performance analysis of members of supply chains. **Benchmarking: An International Journal**, v.22, n.2, p.309-334, 2015.
- CHO, D. W.; LEE, Y. H.; ANH, S. H.; HWANG, M. K. A framework for measuring the performance of service supply chain management. **Computer & Industrial Engineering**, v. 62, p. 801-818, 2012.
- CHRISTOPHER, M.; RYALS, L. Supply chain strategy: its impact on shareholder value. **The International Journal of Logistics Management**, v. 10, n. 1, 1999.
- CHUU, S. Interactive group decision-making using a fuzzy linguistic approach for evaluating the flexibility in a supply chain. **European Journal of Operational Research**, v.213, n.1, p.279–289, 2011.
- CLIVILLÉ, V.; BERRAH, L. Overall performance measurement in a supply chain: towards a supplier-prime manufacturer based model. **Journal of Intelligent Manufacturing**, v.23, n.6, p.2459–2469, 2012.
- COMELLI, M.; FÉNIÈS, P.; TCHERNEV, N. A combined financial and physical flows evaluation for logistic process and tactical production planning: Application in a company supply chain. **International Journal of Production Economics**, v.112, n.1, p.77–95, 2008.
- CORDÓN, O.; HERRERA, F.; PEREGRIN, A. Applicability of the fuzzy operators in the design of fuzzy logic controllers. **Fuzzy Sets and Systems**, v. 86, p.15-41, 1997.

- CORRÊA, S. J. C.; DA SILVEIRA, A. M. Computational Intelligence Applied to Competitiveness Evaluation of Supply Chains: An Adaptive Neuro-Fuzzy Model. **Intelligent Data Engineering and Automated Learning**, v. 7435, p. 658-669, 2012.
- COSKUN, S.; OZGUR, L.; POLAT, O.; GUNGOR, A. A model proposal for green supply chain network design based on consumer segmentation. **Journal of Cleaner Production**, 2015. doi: 10.1016/j.jclepro.2015.02.063.
- CUTHBERTSON, R.; PIOTROWICZ, W. Performance measurement systems in supply chains. **International Journal of Productivity and Performance Management**, v. 60, n. 6, p. 583-602, 2011.
- DE BOER, L.; WEGEN, L. V. D.; TELGEN, J. Outranking methods in support of supplier selection. **European Journal of Purchasing & Supply Management**, v. 4, p. 109-118, 1998.
- DE WAAL, A. **Strategic Performance Management: A Managerial and Behavioural Approach**. Palgrave MacMillan: New York, 2007.
- DEY, P.K.; CHEFFI, W. Green supply chain performance measurement using the analytic hierarchy process: a comparative analysis of manufacturing organisations. **Production Planning & Control**, v.24, n.8-9, p.702-720, 2013.
- DIDEHKHANI, H., JASSBI, J., PILEVARI, N. Assessing flexibility in supply chain using adaptive neuro fuzzy inference system. In: IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL ENGINEERING AND ENGINEERING MANAGEMENT (IEEM 2009), Hong-Kong, 2009. **Proceedings...** Hong Kong, IEEE, 2009.
- EFENDIGIL, T.; ÖNÜT, S. An integration methodology based on fuzzy inference systems and neural approaches for multi-stage supply-chains. **Computers & Industrial Engineering**, v. 62, n. 2, p. 554-569, 2012.
- EFENDIGIL, T.; ÖNÜT, S.; KAHRAMAN, C. A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis. **Expert Systems with Applications**, v. 36, p. 6697-6707, 2009.
- EKSOZ, C.; MANSOURI, A.; BOURLAKIS, M. Collaborative forecasting in the food supply chain: A conceptual framework. **International Journal of Production Economics**, v. 158, p. 120-135, 2014.
- EL-BAZ, M. A. Fuzzy performance measurement of a supply chain in manufacturing companies. **Expert Systems with Applications**, v.38, n.6, p.6681-6688, 2011.
- EROL, I.; SENCER, S.; SARI, R. A new fuzzy multi-criteria framework for measuring sustainability performance of a supply chain. **Ecological Economics**, v.70, n.6, p.1088-1100, 2011.
- ESTAMPE, D.; LAMOURI, S.; PARIS, J.; BRAHIM-DJELLOUL, S. A framework for analysing supply chain performance evaluation models. **International Journal of Production Economics**, v. 142, n. 2, p. 247-258, 2013.
- FAN, X.; ZHANG, S.; WANG, L.; YANG, Y.; HAPESHI, K. An Evaluation Model of Supply Chain Performances Using 5DBSC and LMBP Neural Network Algorithm. **Journal of Bionic Engineering**, v.10, n.3, p.383-395, 2013.
- FATTAHI, F.; NOOKABADI, A.S.; KADIVAR, M. A model for measuring the performance of the meat supply chain. **British Food Journal**, v.115, n.8, p.1090-1111, 2013.
- FOLAN, P.; BROWNE, J. A review of performance measurement: Towards performance management. **Computers in Industry**, v. 56, n. 7, p. 663-680, 2005.
- GANGA, G. M. D. **Proposta de um modelo de simulação baseado em lógica fuzzy e no SCOR para prever o desempenho da empresa-foco em cadeias de suprimentos**. Tese (Doutorado). Escola de Engenharia de São Carlos – Universidade de São Paulo, São Carlos, 2010.
- GANGA, G. M. D.; CARPINETTI, L. C. R. A fuzzy logic approach to supply chain performance management. **International Journal of Production Economics**, v. 134, p. 177-187, 2011.
- GATTORNA, J. **Dynamic supply chains: Delivering Value Through People**. Financial Times Prentice Hall: London, 2010.
- GOEL, N.; SINGH, S.; ASERI, T. C. A comparative analysis of soft computing for gene prediction. **Analytical Biochemistry**, v. 438, n. 1, p. 14-21, 2013.

- GÖKTEPE, A. B.; AGAR, E.; LAV, A. H. Comparison of Multilayer Perceptron and Adaptive Neuro-Fuzzy System on backcalculating the mechanical properties of flexible pavements. **ARI The Bulletin of the Istanbul Technical University**, v. 54, n. 3, p. 65-77, 2004.
- GOLPARVAR, M.; SEIFBARGHY, M. Application of SCOR Model in an Oil- producing Company. **Journal of Industrial Engineering**, v.4, p.59- 69, 2009.
- GONG, Z. An economic evaluation model of supply chain flexibility. **European Journal of Operational Research**, v.184, n.2, p.745–758, 2008.
- GOU, J.; SHEN, G.; CHAI, R. Model of service-oriented catering supply chain performance evaluation. **Journal of Industrial Engineering and Management**, v.6, n.1, p.215-226, 2013.
- GUNASEKARAN, A.; PATEL, C.; MCGAUGHEY, R. E. A framework for supply chain performance measurement. . **International Journal of Production Economics**, v. 87, n.3, p. 333-347, 2004.
- GUNASEKARAN, A.; PATEL, C.; TIRTIROGLU, E. Performance measures and metrics in a supply chain environment. **International Journal of Operations & Production Management**, v. 21, n. 1-2, p. 71-87, 2001.
- GÜNERI, A. F.; ERTAY, T.; YÜCEL, A. An approach based on ANFIS input selection and modeling for supplier selection problem. **Expert Systems with Applications**, v. 38, n. 12, p. 14907-14917, 2011.
- HAGHIGHI, S.M.; TORABI, S.A.; GHASEMI, R. An integrated approach for performance evaluation in sustainable supply chain networks (with a case study). **Journal of Cleaner Production**, v. 137, n. 20, p. 579-597, 2016.
- HALMAN, J.I.M.; VOORDIJK, J.T. Balanced Framework for Measuring Performance of Supply Chains in House Building . **Journal of construction engineering and management**, v.138, n.12, p.1444-1450, 2012.
- HANDFIELD, R.B.; NICHOLS, E.L. **Introduction to Supply Chain Management**. Prentice-Hall: Englewood Cliffs, 1999.
- HAYKIN, S. **Redes Neurais – princípios e prática**. 2 ed. Bookman: Porto Alegre, 2001.
- HEBB, D.O. **The organization of behavior: a neuropsychological theory**. Wiley: New York, 1949.
- HECHT-NIELSEN, R. Neurocomputing. Addison-Wesley Publishing: Menlo Park, 1990.
- HECKAMANN, I.; COMES, T.; NICKEL, S. A critical review on supply chain risk – Definition, measure and modeling. **Omega**, v. 52, p. 119-132, 2015.
- HELMUTH, C. A.; CRAIGHEAD, C. W.; CONNELLY, B. L.; COLLIER, D. Y.; HANNA, J. B. Supply chain management research: Key elements of study design and statistical testing. **Journal of Operations Management**, 2015. doi:10.1016/j.jom.2014.12.001.
- IP, W.H.; CHAN, S.L.; LAM, C.Y. Modeling supply chain performance and stability. **Management & Data Systems**, v.111, n.8, p.1332-1354, 2011.
- JAIN, V.; BENYOUCEF, L.; DESHMUKH, S.G. A new approach for evaluating agility in supply chains using Fuzzy Association Rules Mining. **Engineering Applications of Artificial Intelligence**, v.21, n.3, p.367–385, 2008.
- JAIPURIA, S.; MAHAPATRA, S. S. An improved demand forecasting method to reduce bullwhip effect in supply chains. **Expert Systems with Applications**, v. 41, n. 5, p. 2395-2408, 2014.
- JAIPURIA, S.; MAHAPATRA, S. S. An improved demand forecasting method to reduce bullwhip effect in supply chains. **Expert Systems with Applications**, v. 41, n. 5, p. 2395-2408, 2014.
- JAKHAR, S.K.; BARUA, M.K. An integrated model of supply chain performance evaluation and decision-making using structural equation modelling and fuzzy AHP. **Production Planning & Control**, v.25, n.11, p.938-957, 2014.
- JALALVAND, F.; TEIMOURY, E.; MAKUI, A.; ARYANEZHAD, M.B.; JOLAI, F. A method to compare supply chains of an industry. **Supply chain management: An International Journal**, v.16, n.2, p.82-97, 2011.
- JANG, J.S.R. ANFIS: adaptive-network-based fuzzy inference system. **IEEE Transactions on Systems, Man, and Cybernetics**. v. 23, n. 3, p. 665–685, 1993.

- JASSBI, J.; SEYEDHOSSEINI, S. M.; PILEVARI, N. An Adaptive Neuro Fuzzy Inference System for Supply Chain Agility Evaluation. **International Journal Of Industrial Engineering & Production Research**, v. 20, n. 4, p. 187-196. 2010.
- JOSHI, R; BANWET, D.K.; SHANKAR, R. A Delphi-AHP-TOPSIS based benchmarking framework for performance improvement of a cold chain. **Expert Systems with Applications**, v.38, n.8, p.10170–10182, 2011.
- KAHRAMAN, C. (Ed.). **Fuzzy Multicriteria Decision Making-Theory and Applications with Recent Developments**. Springer Science: Turkey, 2008.
- KAPLAN, R.S.; NORTON, D.P. The balanced scorecard – measures that drive performance. **Harvard Business Review**, v. 70, n. 1, p.71-79. 1992.
- KAPLAN, R.S.; NORTON, D.P. Using the Balance Scorecard as a strategic management system. **Harvard Business Review**, v. 74, n. 1, p.75-85, 1996.
- KAR, S.; DAS, S.; GHOSH, P. K. Applications of neuro fuzzy systems: A brief review and future outline. **Applied Soft Computing**, v. 15, p. 243-259, 2014.
- KHAMSEH, A.A.; ZAHMATKESH, D. Supply chain performance evaluation using robust data envelopment analysis. **Uncertain Supply Chain Management**, v. 3, n. 3, p. 311-320, 2015.
- KHOSHNEVISAN, B.; RAFIEE, S.; OMID, M.; MOUSAZADEH, H. Development of an intelligent system based on ANFIS for predicting wheat grain yield on the basis of energy inputs. **Information processing in agriculture**, v. 1, p.14–22, 2014.
- KIM, J.H.; YOUN, S.; ROH, J.J. Green supply chain management orientation and firm performance: evidence from South Korea. **International Journal of Services and Operations Management**, v. 8, n. 3, p. 283–304, 2011.
- KITCHENHAM, B.A; CHARTERS, S. Guidelines for performing Systematic Literature Reviews. **Software Engineering Technical Report EBSE-2007-01**, 2007.
- KLEMENT, E.P.; MESIAR, R.; PAP, E. **Triangular Norms**. Springer: Netherlands, 2000.
- KO, M.; TIWARI, A.; MEHNEN, J. A review of soft computing applications in supply chain management. **Applied Soft Computing**, v. 10, p. 661-674, 2010.
- KOCAOGLU, B.; GÜLSÜN, B.; TANYA, M. A SCOR based approach for measuring a benchmarkable supply chain performance. **Journal of Intelligent Manufacturing**, v.24, n., p.113-132, 2013.
- KUMAR, A.; MUKHERJEE, K.; ADLAKHA, A. Dynamic performance assessment of a supply chain process: A case from pharmaceutical supply chain in India. **Business Process Management Journal**, v. 21, n. 4, p. 743-770, 2015.
- KUMAR, D.; SINGH, J.; SINGH, O. P. A fuzzy logic based decision support system for the evaluation of supplier in supply chain management practices. **Mathematical and Computer Modelling**, v.57, n.11_12, p.2945–2960, 2012.
- KUMAR, G; BANERJEE, R.N. Supply chain collaboration index: an instrument to measure the depth of collaboration. **Benchmarking: An International Journal**, v.21, n.2, p.184 - 204, 2014.
- LAMBERT, D.M.; COOPER, M.C.; PAGH, J.D. Supply Chain Management: Implementation Issues and Research Opportunities. **The International Journal of Logistics Management**, v. 9, n. 2, p. 1-20, 1998.
- LAPIDE, L. What about measuring supply chain performance? **Achieving Supply Chain Excellence through Technology**, v. 2, p. 287-297, 2000.
- LEBAS, M. J. Performance measurement and performance management. **International Journal of Production Economics**, v. 41, n. 1-3, p. 23-35, 1995.
- LEE, C. C.; OU-YANG, C. A neural networks approach for forecasting the supplier's bid prices in supplier selection negotiation process. **Expert Systems with Applications**, v. 36, n. 2, p. 2961-2970, 2009.
- LI, C. An integrated approach to evaluating the production system in closed-loop supply chains. **International Journal of Production Research**, v.51, n.13, p.4045–4069, 2013.

- LI, J.; BUTLER-PURRY, K. L.; BENNER, C. L.; RUSSEL, B. D.; LANGARI, R. Selecting a Fuzzy Aggregation Operator for the Multi-Criteria Fault Location Problem. *In: IEEE Power Systems Conference and Exposition, 6th*, 2004, Atlanta. **Proceedings...** Atlanta: IEEE, 2004.
- LIANG, L.; YANG, F.; COOK, W.D.; ZHU, J. DEA models for supply chain efficiency evaluation. **Annals of Operations Research**, v.145, n., p.35–49, 2006.
- LIMA JUNIOR, F.R.; CERVI, A.F.C.; CARPINETTI, L.C.R. Uma metodologia multicritério baseada em inferência fuzzy para classificação ABC de estoques. **Pesquisa Operacional para o Desenvolvimento**, v. 6, p. 343-366, 2014.
- LIMA JUNIOR, F.R.; OSIRO, L.; CARPINETTI, L. C. R. A comparison between Fuzzy AHP and Fuzzy TOPSIS methods to supplier selection. **Applied Soft Computing**, v. 21, p. 194-209, 2014.
- LIMA JUNIOR, F.R.; OSIRO, LAURO; CARPINETTI, L.C.R. A fuzzy inference and categorization approach for supplier selection using compensatory and non-compensatory decision rules. **Applied Soft Computing**, v. 13, p. 4133-4147, 2013.
- LOHMAN, C.; FORTUIN, L; WOUTERS, MARC. Designing a performance measurement system: a case study. **European Journal of Operational Research**, v. 156, p. 267-286, 2004.
- LUMMUS, R. R.; VOKURKA, R. J. Defining supply chain management: a historical perspective and practical guidelines. **Industrial Management & Data Systems**, v. 99, n. 1, p. 11-17, 1999.
- LYNCH, R.; CROSS, K. **Measure-up – The essential guide to measuring business performance**. Mandarin: London, 1991a.
- LYNCH, R.; CROSS, K. **Measure-up – Yardsticks for continuous improvement**. Blackwell business: Cambridge, 1991b.
- MAMDANI, E. H.; ASSILIAN, S. An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller. **International Journal of Man-Machine Studies**, v.7, n.1, p.1-13, 1975.
- MARCHAND, D.; RAYMOND, L. Researching performance measurement systems – An information system perspective. **International Journal of Operations and Production Management**, v. 28, n.7, p. 663-686, 2008.
- MASSAMI, E.P.; MYAMBA, B.M.. Fuzzy analysis and evaluation of supply chain performance: a focus on leather products in Tanzania. **International Journal of Logistics Systems and Management**, v. 23, n. 3, p. 299-313, 2016.
- MATHWORKS. Site de suporte do *software* MATLAB. Disponível em: <<http://www.mathworks.com/help/nnet/ref/trainingd.html>>. Acesso em 20 de fevereiro de 2015.
- MCCULLOCH, W.S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v.5, p.115-133, 1943.
- MELNYK, S. A.; NARASIMHAN, R.; DECAMPOS, H. A. Supply chain design: issues, challenges, frameworks and solutions. **International Journal of Production Research**, v. 52, n. 7, p. 1887-1896, 2014.
- MENTZER, J.T.; WITT, W.; KEEBLER, J.S.; MIN, S.; NIX, N.; SMITH, C.D. Defining supply chain management. **Journal of Business Logistics**, v. 22, n. 2, p. 1-25, 2001.
- MILLER, G.A. The Magical Number Seven, Plus or Minus Two Some Limits on Our Capacity for Processing Information. **Psychological Review**, v. 101, n. 2, p. 343-352, 1994.
- MINSKY, M.L.; PAPERT, S.A. **Perceptrons: an introduction to computational geometry**. The MIT Press: Massachusetts, 1969.
- MIRHEDAYATIAN, S.M.; AZADI, M.; SAEN, R.F. A novel network data envelopment analysis model for evaluating green supply chain management. **International Journal of Production Economics**, v.147, n.21-22, p.544–554, 2014.
- MONTGOMERY, D.C.; RUNGER, G.C. **Estatística aplicada e probabilidade para engenheiros**. 4 ed. LTC: Rio de Janeiro, 2009.

- MOOSMAYER, D. C.; CHONG, A. Y.; LIU, M. J.; SCHUPPAR, B. A neural network approach to predicting price negotiation outcomes in business-to-business contexts. **Expert Systems with Applications**, v.40, p.3028-3035, 2013.
- NAINI, S. G. J.; ALIAHMADI, A. R.; JAFARI-ESKANDARI, M. Designing a mixed performance measurement system for environmental supply chain management using evolutionary game theory and balanced scorecard: A case study of an auto industry supply chain. **Resources, Conservation and Recycling**, v.55, n.6, p.593–603, 2011.
- NEELY, A. The performance measurement revolution: why now and what next? **International Journal of Operations & Production Management**, v. 19, n.2, p. 205-228, 1999.
- NEELY, A.; ADAMS, C.; KENNERLEY, M.; **The performance prism: the scorecard for measuring and managing business success**. Prentice Hall: London, 2002.
- NEELY, A.; GREGORY, M.; PLATTS, K. Performance Measurement system design: a literature review and research agenda. **International Journal of Operations and Production Management**, v. 15, n. 4, p. 80-166. 1995.
- NEELY, A.; MILLS, J.; PLATTS, K.; RICHARDS, H.; GREGORY, M.; BOURNE, M.; KENNERLEY, M. Performance measurement system design: developing and testing a process-based approach. **International Journal of Operations & Production Management**, v. 20, n. 10, p. 1119-1145, 2000.
- NIKFARJAM, H.; ROSTAMY-MALKHALIFEH, M.; MAMIZADEH-CHATGHAYEH, S. Measuring supply chain efficiency based on a hybrid approach. **Transportation Research Part D: Transport and Environment**, v. 39, p. 141–150, 2015.
- NUDURUPATI, S. S.; BITITCI, U. S. Implementation and impact of IT enabled performance measurement. **Production Planning and Control**, v. 16, n. 2, p. 152-162, 2005.
- NUDURUPATI, S. S.; BITITCI, U. S.; KUMAR, V.; CHAN, F. T. S. State of the art literature review on performance measurement. **Computers & Industrial Engineering**, v. 60, p. 279-290, 2011.
- OLUGU, E.U.; WONG, K.Y. An expert fuzzy rule-based system for closed-loop supply chain performance assessment in the automotive industry. **Expert Systems with Applications**, v.39, n.1, p.375–384, 2012.
- OMAR, A.S.; WAWERU, M.; RIMIRU, R. Fuzzy Logic Framework for Qualitative Evaluation of Supply Chain Responsiveness. **The International Journal of Engineering And Science**, v. 4, n. 8, p. 37-48, 2015.
- OMRANI, H.; KESHAVARZ, M. A performance evaluation model for supply chain of shipping company in Iran: an application of the relational network DEA. **Maritime Policy & Management**, v. 43, n. 1, p. 121-135, 2015.
- ORTÍZ, M. A.; FELIZZOLA, H. A.; ISAZA, S. N. A contrast between DEMATEL-ANP e ANP methods for six sigma project selection: a case study in healthcare industry. **Medical Informatics & Decision Making**, v.15, 2015.
- OSIRO, L.; LIMA JUNIOR, F.R.; CARPINETTI, L.C.R. A fuzzy logic approach to supplier evaluation for development. **International Journal of Production Economics**, v. 153, p. 95-112, 2014.
- OSIRO, L.; LIMA, R.H.P.; LIMA JUNIOR, F.R.; CARPINETTI, L.C.R. Proposta de uso de Redes Neurais Artificiais em uma matriz de Portfólio de Compras. In: Encontro Nacional de Engenharia de Produção (ENEGEP), 33., 2013, Salvador. **Anais do XXXIII ENEGEP**. Salvador: ABEPRO, 2013.
- ÖZKAN, G.; INAL, M. Comparison of neural network application for fuzzy and ANFIS approaches for multi-criteria decision making problems. **Applied Soft Computing**, v. 24, p. 232-238, 2014.
- PAIVA, R.P.; DOURADO, A. Interpretability and learning in neuro-fuzzy systems. **Fuzzy Sets and Systems**, v. 147, p. 17-38, 2004.
- PANJEHFOULADGARAN, H.; YUSUFF, R. Fuzzy performance measurement for supply chain management in Malaysian rubber glove manufacturer. **International Journal of Logistics Systems and Management**, v. 24, n. 2, p. 178-199, 2016.
- PEDRYCZ, W. GOMIDE, F. **Fuzzy Systems Engineering – Toward Human-Centric Computing**. John Wiley & Sons: New Jersey, 2007.

- PUNGCHOMPOO, S.; SOPADANG, A. Confirmation and evaluation of performance measurement model for the Thai frozen shrimp chain. **Business Process Management Journal**, v. 21, n. 4, p. 837-856, 2015.
- RAMANA, D.V.; RAO, K.N.; KUMAR, J.S. Evaluation of Supply Chains of the Organizations through Dematel/AHP. **International Journal of Innovative Research & Development**, v. 5, n. 5, p. 110-115, 2016.
- REZENDE, S.O. **Sistemas Inteligentes: Fundamentos e Aplicações**. 1 ed. Barueri: Manole, 2003.
- RICH, E. **Inteligência Artificial**. McGraw-Hill: São Paulo, 1988.
- ROLIM, C.O.; SCHUBERT, R.; ROSSETTO, A.G.M; LEITHARDT, V. R. Q; GEYER, C. F. R; WESTPHALL C. Comparison of a Multi output Adaptative NeuroFuzzy Inference System (MANFIS) and Multi Layer Perceptron (MLP) in Cloud Computing. *In: XXX Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, 2012, Ouro Preto. X Workshop em Clouds e Aplicações - WCGA. Ouro Preto. SBC, 2012.
- ROSENBLAT, F. The perceptron: a probabilistic model for information storage and organization in brain. **Psychological Review**, v.65, p.386-408, 1958.
- RUMELHART, D.; HINTON, G.; WILLIAMS, R. Learning Internal Representations by Error Propagation. **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**, Foundations MIT Press Cambridge Massachusetts, p.318-362, 1986.
- SAHU, A.K.; DATTA, S.; MAHAPATRA, S.S. Supply chain performance benchmarking using grey-MOORA approach. **Grey Systems: Theory and Application**, v.4, n.1, p.24-55, 2014.
- SAHU, S.K.; DATTA, S.; MAHAPATRA, S.S. Appraisalment and benchmarking of supply chain performance extent. **Grey Systems: Theory and Application**, v. 5, n. 1, p. 2-30, 2015.
- SAMPAIO, R. F.; MANCINI, M. C. Estudos de Revisão Sistemática: Um guia para síntese criteriosa da evidência científica. **Revista Brasileira de Fisioterapia**, v. 11, n. 1, p. 83-89, 2007.
- SARODE, A. D.; SUNNAPWAR, V. K.; KHODKE, P. M. A literature review for identification of performance measures for establishing a framework for performance measurement in supply chains. **The International Journal of Applied Management and Technology**, v. 6, n. 3, p. 241-273, 2008.
- SCC, Supply Chain Council. **Supply Chain Operations Reference Model**, version 11.0. Supply Chain Council, 2012.
- SELLITO, M.A.; MENDES, L.W. Avaliação comparativa do desempenho de três cadeias de suprimentos em manufatura. **Produção**, v.16, n.3, p.552-568, 2006.
- SELLITTO, M.A.; PEREIRA, G.M.; BORCHARDT, M.; SILVA, R.; VIEGAS, C.V. A SCOR-based model for supply chain performance measurement: application in the footwear industry. **International Journal of Production Research**, v. 53, n. 16, p. 4917-4926, 2015.
- SEURING, S. A review of modeling approaches for sustainable supply chain management. **Decision Support Systems**, v. 54, n. 4, p. 1513-1520, 2013.
- SEYEDHOSSEINI, S. M.; JASSBI, J.; PILEVARI. Application of adaptive neuro fuzzy inference system in measurement of supply chain agility: Real case study of a manufacturing company. **African Journal of Business Management**, v.4, n.1, p.83-96, 2010.
- SHA, M.; ZHEN, L.; CUI, X.; GUO, S. Supply Chains' Efficiency Evaluation Based on Network DEA CCR Model and BCC Model. **Journal of Information & Computational Science**, v. 12, n. 7, p. 2857-2869, 2015.
- SHABANI, A.; SAEN, R.F. Developing a novel data envelopment analysis model to determine prospective benchmarks of green supply chain in the presence of dual-role factor. **Benchmarking: An International Journal**, v. 22, n. 4, p. 711-730, 2015.
- SHAFIEE, M.; LOTFI, F.H.; SALEH, H. Supply chain performance evaluation with data envelopment analysis and balanced scorecard approach. **Applied Mathematical Modelling**, v.38, n.-, p.5092-5112, 2014.
- SHARMA, M.K.; BHAGWAT, R. An integrated BSC-AHP approach for supply chain management evaluation. **Measuring Business Excellence**, v.11, n.3, p.57-68, 2007.

- SHEPHERD, C.; GÜNTER, H. Measuring supply chain performance: current research and future directions. **International Journal of Productivity and Performance Management**, v. 55, n. 3-4, p. 242-258, 2006.
- SILVA, I. N.; SPATI, D. H., FLAUZINO, R. A. 2010. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010. 399 p.
- SIMATUPANG, T. M.; SRIDHARAN, R. Benchmarking supply chain collaboration: An empirical study. **Benchmarking: An International Journal**, v. 11, n. 5, p. 484-503, 2004.
- SLACK, N. **Vantagem competitiva em manufatura**. 2 ed. São Paulo: Atlas, 2002.
- SMOLÍKOVÁ, R.; WAHOWIAK, M.P. Aggregation operators for selection problems. **Fuzzy Sets and Systems**, v. 131, p. 23-34, 2002.
- SOUTHARD, P.B.; PARENTE, D.H. A model for internal benchmarking: when and how?. **Benchmarking: An International Journal**, v. 14, n. 2, p. 161-71, 2007.
- SRINIVASAN, S.P.; MALLIGA, P. A new approach of adaptive Neuro Fuzzy Inference System (ANFIS) modeling for yield prediction in the supply chain of Jatropha. *In: International Conference on Industrial Engineering and Engineering Management*, 17th, 2010, Xiamen. **Proceedings...** Xiamen: IEEE, 2010.
- SUPEEKIT, T.; SOMBOONWIWAT, T.; KRITCHANCHAI, D. DEMATEL-modified ANP to evaluate internal hospital supply chain performance. **Computers & Industrial Engineering**, 2016. doi: 10.1016/j.cie.2016.07.019
- SWEENEY, E. Towards a unified definition of supply chain management: The four fundamentals. **International Journal of Applied Logistics**, v. 2, n. 3, p. 30-48, 2011.
- TAJBAKSH, A.; HASSINI, E. A data envelopment analysis approach to evaluate sustainability in supply chain networks. **Journal of Cleaner Production**, v.105, p.74-85, 2015.
- TAKAGI, T.; SUGENO, M. Fuzzy Identification of Systems and Its Applications to Modeling and Control. **IEEE Transactions, Man, and Cybernetics**, v. 15, p. 116–132, 1985.
- TAVANA, M.; KAVIANI, M.A.; DI CAPRIO, D.; RAHPEYMA, B. A two-stage data envelopment analysis model for measuring performance in three-level supply chains. **Measurement**, v. 78, p. 322-333, 2016.
- TAVANA, M.; MIRZAGOLTABAR, H.; MIRHEDAYATIAN, S.M.; SAEN, R. F.; AZADI, M. A new network epsilon-based DEA model for supply chain performance evaluation. **Computers & Industrial Engineering**, v.66, n.2, p.501–513, 2013.
- THEERANUPHATTANA, A.; TANG, J. C. S. A conceptual model of performance measurement for supply chains: alternative considerations. **Journal of Manufacturing Technology Management**, v. 19, n. 1, p. 125-148, 2008.
- TKÁC, M.; VERNER, R. Artificial neural networks in business: Two decades of research. **Applied Soft Computing**, v. 38, p. 788–804, 2016.
- TSOUKALAS, L. H. UHRIG, R. E. **Fuzzy and Neural Approaches in Engineering**. John Wiley & Sons Inc.: New York, 2007. 587 pg.
- TSOULFAS, G.T.; PAPPIS, C. P. A model for supply chains environmental performance analysis and decision making. **Journal of Cleaner Production**, v.16, n.15, p.1647–1657, 2008.
- UNAHABHOKHA, C.; PLATTS, K.; TAN, H. T. Predictive performance measurement system: A fuzzy expert system approach. **Benchmarking: An International Journal**, v. 14, n. 1, p. 77-91, 2007.
- UYGUN, Ö.; DEDE, A. Performance evaluation of green supply chain management using integrated fuzzy multi-criteria decision making techniques. **Computers & Industrial Engineering**, 2016. doi: 10.1016/j.cie.2016.02.020
- UYVAL, F. An integrated model for sustainable performance measurement in supply chain. **Procedia - Social and Behavioral Sciences**, v.62, p.689 – 694, 2012.

- VAIDYA, O.; HUDNURKAR, M. Multi-criteria supply chain performance evaluation: An Indian chemical industry case study. **International Journal of Productivity and Performance Management**, v.62, n.3, p.293-316, 2013.
- VARMA, S.; WADHWA, S.; DESHMUKH, S.G. Evaluating petroleum supply chain performance: Application of analytical hierarchy process to balanced scorecard. **Asia Pacific Journal of Marketing and Logistics**, v.20, n.3, p.343-356, 2008.
- VARSEI, M.; SOOSAY, C.; FAHIMNIA, B.; SARKIS, J. Framing sustainability performance of supply chains with multidimensional indicators. **Supply chain management: An International Journal**, v.19, n.3, p.242-257, 2014.
- VINODH, S.; DEVADASAN, S.R.; VIMAL, K.E.K.; KUMAR, D. Design of agile supply chain assessment model and its case study in an Indian automotive components manufacturing organization paper. **Journal of Manufacturing Systems**, v.32, n.4, p. 620-631, 2013.
- WANG, H. Research on supply chain performance evaluation of fresh agricultural products. **INMATEH - Agricultural Engineering**, v.40, n.2, p.36-42, 2013.
- WANG, Y.; LU, J.; LI, Y. Measure for data partitioning in $m \times 2$ cross-validation. **Pattern Recognition Letters**, v.65, pp. 211-217, 2015.
- WIDROW; B.; HOFF, M.E. Adaptive switching circuits. *In: IRE Wescon Convention Record, 1th*, 1960, New York. **Proceedings...** New York: IRE Wescon, 1960.
- WONG, T. **Performance evaluation of classification algorithms by k -fold and leave-one-out cross validation**. *Pattern Recognition*, v. 48, n. 9, p. 2839-2846, 2015.
- WONG, W.P.; WONG, K.Y. Supply chain performance measurement system using DEA modeling. **Industrial Management & Data Systems**, v.107, n.3, p.361-381, 2007.
- WU, Y.; DONG, M.; FAN, T.; LIU, S. Performance evaluation of supply chain networks with assembly structure under system disruptions. **Computers & Operations Research**, v.1, n.39, p.3229-3243, 2012.
- XIYAO, Z.; HANKUN, Y. A Novel Evaluation Indicator System and Evaluation Method for Supply Chain Performance of Food Production. **Advance Journal of Food Science and Technology**, v. 7, n. 4, p. 255-259, 2015.
- XU, J.; LI, BIN; WU, D. Rough data envelopment analysis and its application to supply chain performance evaluation. **International Journal Production Economics**, v.122, n.2, p.628-638, 2009.
- YANG, J. Integrative performance evaluation for supply chain system based on logarithm triangular fuzzy number-AHP method. **Kybernetes**, v.38, n.10, p.1760-1770, 2009.
- YANG, J.; JIANG, H. Fuzzy Evaluation on Supply Chains' Overall Performance Based on AHM and M(1,2,3). **Journal of software**, v.12, n.7, p.2779-2786, 2012.
- YANG, Z. A fuzzy ANP-based approach to information sharing capability evaluation of supply chain partners. **International Review on Computers and Software**, v.7, n. 2, pp. 688-694, 2012.
- YAQIONG; L.; MAN, L.; ZHANG, W. Fuzzy theory applied in quality management of distributed manufacturing system: A literature review and classification. **Engineering Applications of Artificial Intelligence**, v.24, p.266-277, 2011.
- YAVUZ, V.A. An Analysis of Job Change Decision Using a Hybrid Mcdm Method: A Comparative Analysis. **International Journal of Business and Social Research**, v. 6, n. 3, p. 60-75, 2016.
- YEH, D.; CHEN, C.; CHI, M. A modified two-tuple FLC model for evaluating the performance of SCM: By the Six Sigma DMAIC process . **Applied Soft Computing**, v.7, n.3, p.1027-1034, 2007.
- ZADEH, L. A. Fuzzy Sets. **Information and Control**, v. 8, p. 338-353, 1965.
- ZHAO, Z.; XU, S.; KANG, B. H.; KABIR, M. M. J.; LIU, Y.; WASINGER, R. Investigation and improvement of multi-layer perceptron neural networks for credit scoring. **Expert Systems with Applications**, v.42, n. 7, p. 3508-3516, 2015.

ZHAO, Z.; XU, S.; KANG, B. H.; KABIR, M. M. J.; LIU, Y.; WASINGER, R. Investigation and improvement of multi-layer perceptron neural networks for credit scoring. **Expert Systems with Applications**, v. 42, n. 7, p. 3508-3516, 2015.

ZIMMERMANN, H. J. **Fuzzy set theory and its applications**. 2. ed. Boston: Kluwer Academic, 1991.

APÊNDICE A - Detalhamento dos Indicadores do SCOR®

Quadro A1 – Detalhamento do indicador *total cost to serve* e de seus indicadores componentes

Nome do indicador: <i>Total cost to serve</i>
Atributo associado: <i>Cost</i>
Código no SCOR®: CO 1.001
<p>Descrição: A soma dos custos da cadeia para entregar produtos e serviços aos clientes, incluindo o custo de planejamento, custo de terceirização de materiais, produtos e serviços, custo para produzir, manufaturar, remanufaturar e reparar e produtos e serviços (se aplicável), custo de gerenciamento de pedido, retorno de clientes, custo para entregar produtos e serviços no local combinado. Esse indicador inclui dois tipos de custo:</p> <ul style="list-style-type: none"> - Custos diretos: Custos que podem ser diretamente atribuídos para o atendimento de pedidos. Por exemplo, custo de materiais utilizados e / ou entregues, todos os custos de mão de obra direta da cadeia, entre outros; - Custos indiretos: Custos necessários para a operação da cadeia de suprimento. Por exemplo, custo para arrendar e manter equipamentos, depreciação de inventário, custos de retornos e danos, entre outros.
<p>Fórmula: <i>Total cost to serve = planning cost + sourcing cost + material landed cost + production cost + order management cost + production cost + order management cost + fulfillment cost + return cost</i></p>
Unidade de medida: Unidades monetárias
<p>Detalhamento: O indicador <i>total cost to serve</i> é composto pelos seguintes indicadores do nível 2:</p> <ol style="list-style-type: none"> i. <i>Planning cost</i> (CO 2.001): É o custo total de pessoal, automação, ativos e despesas gerais associadas com os processos de planejamento da cadeia de suprimento. Isso inclui atividades associadas com organização, preparação e participação em reuniões de planejamento, coleta e análise de dados estatísticos de demanda, coleta, agregação e julgamento de dados de suprimento e gestão de dados de planejamento. Esse indicador é calculado a partir da soma de indicadores do nível 3, sendo eles custo de mão de obra para planejamento, custo de automação para planejamento, custo de planejamento de equipamentos, planta e propriedade, custos de planejamento de governança, riscos e despesas gerais; ii. <i>Sourcing cost</i> (CO 2.002): Refere-se ao custo total associado com gerenciamento de pedidos, recebimento, inspeção e armazenagem de materiais, produtos e serviços. Esses custos incluem custos de mão de obra para gerenciamento de terceirização de materiais, gerenciamento do desempenho de fornecedores, gerenciamento de pedidos de compra, manuseio de material, inspeção, armazenagem e despesas gerais com terceirização, como automação, facilidades e materiais indiretos. Esse indicador é calculado pela soma dos indicadores do nível 3 relacionados a custos de mão de obra investida em aquisição, custo de automação para suporte à aquisição, custo de terceirização de equipamento, planta, propriedade, custo de terceirização governança e despesas gerais; iii. <i>Material landed cost</i> (CO 2.003): Diz respeito ao custo total associado com a compra e a disponibilização no local de uso de materiais, produtos e mercadorias. Esses custos incluem o

- preço dos materiais comprados, frete, garantia e outros custos (impostos de importação e exportação, tarifas e outras taxas associadas com a terceirização e entrega de produto ou *commodity* no local de uso. Esse indicador é calculado pela soma dos indicadores associados a custos com materiais comprados, custos com transporte de materiais, custo com taxas, tarifas, impostos e custos com risco;
- iv. *Production cost* (CO 2.004): O custo total associado com o gerenciamento e a execução dos processos de produção, incluindo atividades de programação da produção, separação de materiais e produtos, execução de atividades sobre o produto (montagem, desmontagem, processamento químico, reparos, entre outros), execução de diagnósticos, testes, empacotamento, movimentação e armazenagem de materiais e produtos. O custo dos materiais usados na produção não estão inclusos nesse indicador. Pode ser calculado por meio da soma entre custos de mão de obra direta de produção, custos com automação da produção, custos com equipamentos, planta e propriedade para a produção e custos com despesas gerais, inventário, risco e governança associados com a produção;
- v. *Order management cost* (CO 2.005): Refere-se ao custo total com pessoal, automação e ativos para responder a perguntas e cotações, entrada e manutenção de pedido, programação de transporte, rastreamento de pedido, entrega, instalação e faturamento. Pode incluir o custo de gerenciamento de crédito ao cliente. É calculado pela soma dos custos com mão de obra, automação, equipamentos, planta, propriedade, governança, riscos e despesas gerais associadas com o gerenciamento de pedidos;
- vi. *Fulfillment cost* (CO 2.006): É o custo total de pessoal, automação, ativos e despesas gerais associado com o atendimento de pedidos (incluindo o manuseio físico do produto, como estocagem, separação, empacotamento e expedição). Esse indicador abrange o custo de transporte de produtos entre locações e o retorno de devoluções, mas não abrange o custo de materiais e serviços adquiridos). O cálculo é feito pela soma dos custos com mão de obra, aluguel de facilidade, equipamentos, automação, impostos, tarifas, taxas, alfândega, centros de distribuição, armazéns e equipamentos para manuseio e transporte de produtos
- vii. *Returns cost* (CO 2.007): É o custo total de materiais retornados devido a erros de planejamento, de qualidade dos fornecedores, de produção, de gerenciamento de pedidos e de entrega. Esses custos podem ser descritos como o custo para reparar uma entrega imperfeita feita ao cliente. É calculado por meio da soma dos custos de restituição e descontos, custos de disposição e custos com despesas gerais de retorno;
- viii. *Cost of goods sold* (CO 2.008): É o custo de materiais diretos, mão de obra direta e despesas gerais associadas com a produção ou terceirização de produtos acabados. Custo de materiais diretos incluem os custos de materiais ou produtos comprados e pode incluir o custo de transportes, taxas e garantia requeridos para trazer os materiais até o ponto de uso. Esse indicador pode ser calculado pela soma dos indicadores de nível 3 associados a custo de mão de obra direta, custo de materiais diretos e custo de despesas gerais.

Quadro A2 – Detalhamento do indicador *return on working capital* e de seus indicadores componentes

Nome do indicador: <i>Return on working capital</i>
Atributo associado: <i>Asset management efficiency</i>
Código no SCOR®: AM. 1.3
Descrição: Avalia a magnitude do investimento relativo ao capital de giro de uma empresa em relação à receita gerada a partir da cadeia de suprimento. Seus indicadores componentes incluem contas a receber, contas a pagar, inventário, receita da cadeia de suprimento, custo de produtos vendidos e custo de gestão de cadeias de suprimento. Os dados necessários para a avaliação desse indicador tipicamente já são coletados pelos sistemas de informação transacionais do negócio. É medido pela divisão do lucro pela quantidade calculada de capital de giro.
Fórmula: <i>Return on working capital</i> = $\frac{[\textit{supply chain revenue}] - [\textit{total cost to serve}]}{[\textit{Inventory}] + [\textit{Accounts receivable}] - [\textit{accounts payable}]}$
Unidade de medida: Adimensional
Detalhamento: Esse indicador é calculado a partir dos seguintes indicadores do nível 2: i. <i>Accounts payable (payables outstanding – AM.2.6)</i> : É a quantidade de materiais comprados, mão de obra e / ou conversão de recursos que estão para ser pagos (contas a pagar), medida em unidades monetárias. Esse indicador é calculado como a média móvel de cinco pontos de valores de contas a pagar; ii. <i>Accounts receivable (sales outstanding – AM.2.7)</i> : Refere-se às contas a pagar em aberto, expressa em dólares. Esse indicador é calculado como a média móvel de cinco pontos de valores de contas a receber; iii. <i>Inventory (AM.2.8)</i> : É a quantidade de estoque (inventário) expressa em dólares. Seu valor é calculado como a média móvel de cinco pontos de inventário a um custo padrão; Para esses três indicadores, o cálculo é feito usando a média móvel em torno de cinco pontos de valores, sendo quatro desses valores baseados em dados históricos dos trimestres anteriores e um deles baseado em uma projeção para o próximo trimestre. Além desses indicadores, no cálculo de <i>return on working capital</i> também são considerados os indicadores <i>supply chain revenue</i> (AM.2.4), que quantifica a receita gerada pela operação da cadeia, e <i>total cost to serve</i> (CO 1.001), detalhado no Quadro A1.

Fonte: Baseado em SCC (2012)

Quadro A3 – Detalhamento do indicador *cash-to-cash cycle time* e de seus indicadores componentes

Nome do indicador: <i>Cash-to-cash cycle time</i>
Atributo associado: <i>Asset management efficiency</i>
Código no SCOR®: AM 1.1
Descrição: É o tempo gasto para um investimento retornar para a companhia, contado a partir da compra de matéria prima. Para o caso de serviços, esse indicador representa o tempo do ponto em que a companhia paga pelo recurso consumido na execução de um serviço até o tempo que a companhia recebe o pagamento do cliente por tal serviço.

Fórmula: $Cash - to - cash\ cycle\ time = [Inventory\ days\ of\ supply] + [Days\ sales\ outstanding] - [Days\ payable\ outstanding]$
Unidade de medida: Dias
Detalhamento: Esse indicador é usado para medir quão eficientemente a empresa-foco gerencia seu capital de giro, podendo ser calculado a partir dos seguintes indicadores componentes do nível 2: <ul style="list-style-type: none"> i. <i>Days sales outstanding</i> (AM 2.1): É o tempo decorrido entre a execução de uma venda e o recebimento do pagamento dos clientes, expresso em dias; ii. <i>Inventory days of supply</i> (AM 2.2): A quantidade de inventário expressa em dias de vendas (ex. se são vendidos 2 itens por dia e há 20 itens em estoque, esse indicador equivalerá a $20/2=10$ dias de vendas); iii. <i>Days payable outstanding</i> (AM 2.3): Os dias decorridos entre a compra de materiais, mão de obra e/ou conversão de recursos até o pagamento (período médio de pagamento).

Fonte: Baseado em SCC (2012)

Quadro A4 – Detalhamento do indicador *order fulfillment cycle time* e de seus indicadores componentes

Nome do indicador: <i>Order fulfillment cycle time</i>
Atributo associado: <i>Responsiveness</i>
Código no SCOR®: RS 1.1
Descrição: Refere-se ao tempo de ciclo médio consumido para atender os pedidos dos clientes. Para cada pedido individual, o tempo de ciclo se inicia desde o recebimento do pedido e finaliza com a aceitação do pedido pelo cliente.
Fórmula: $[sum\ actual\ cycle\ times\ for\ all\ orders\ delivered] / [total\ number\ of\ orders\ delivered]$
Unidade de medida: Dias
Detalhamento: O valor deste indicador depende diretamente do tempo de ciclo de cada pedido, o qual deve englobar o tempo de processo de atendimento do pedido e o tempo de permanência do pedido (<i>order fulfillment dwell time</i>). O tempo de processo de atendimento do pedido é definido por meio da soma dos valores de quatro indicadores do nível 2 do SCOR®: <ul style="list-style-type: none"> i. <i>Source cycle time</i> (RS 2.1): É a soma do tempo despendido para identificar fontes de suprimento, selecionar o fornecedor, efetuar negociação, programar entregas de produto, receber produto, verificar, transferir produto e autorizar pagamento ao fornecedor; ii. <i>Make cycle time</i> (RS 2.2): É a soma do tempo despendido na finalização da engenharia de manufatura, programação de atividades da produção, descarga de material, produção, teste, empacotamento e liberação do produto acabado; iii. <i>Delivery cycle time</i> (RS 2.3): É calculado pela fórmula “máximo {[tempo de ciclo de determinação da data de entrega + (tempo de ciclo da consolidação do pedido + tempo de ciclo da programação da instalação) + tempo de ciclo de montagem de carga + tempo de ciclo de definição de rota + tempo de ciclo de selecionar transportadora e taxar carga] + tempo de recebimento do produto} + tempo de ciclo de separação do produto + tempo de ciclo de empacotamento + tempo de ciclo de geração da documentação de embarque e carregamento de veículo + tempo de ciclo do produto a bordo + tempo de ciclo de receber e verificar o produto + tempo de ciclo de instalar o

<p>produto”. Nesta fórmula, a função “máximo” indica que algumas atividades dos processos relacionados a esses indicadores podem ocorrer em paralelo e portanto aquela que consumir mais tempo é que determinará o tempo de ciclo;</p> <p>iv. <i>Delivery retail cycle time</i> (RS 2.4): O tempo de ciclo médio despendido nos processos de aquisição, negociação e venda de produtos aos varejistas. Pode ser calculado por meio da soma entre o tempo de ciclo de gerar programação de estocagem + tempo de ciclo de recebimento do produto + tempo de ciclo de separação de produtos + tempo de ciclo de armazenagem + tempo de ciclo de preenchimento do “carrinho” de compras + tempo de ciclo de conferência + tempo de ciclo de instalação.</p> <p>Já o tempo de permanência se refere a qualquer tempo de espera durante o processo de atendimento do pedido em que não são executadas atividades. O SCOR® que esse tempo de permanência costuma ser imposto por requisitos dos clientes, e é diferente do tempo de espera sem valor agregado que pode ocorrer por ineficiências da organização.</p>

Fonte: Baseado em SCC (2012)

Quadro A5 – Detalhamento do indicador *perfect order fulfillment* e de seus indicadores componentes

Nome do indicador: <i>Perfect order fulfillment</i>
Atributo associado: <i>Reliability</i>
Código no SCOR®: RL 1.1
Descrição: Refere-se ao percentual de pedidos que tenham sido entregues na data combinada pelo cliente, sem danos e com documentação completa e precisa.
Fórmula: $[total\ perfect\ orders] / [total\ number\ of\ orders] \times 100\%$
Unidade de medida: Percentual
<p>Detalhamento: O valor deste indicador depende essencialmente da quantidade alcançada de pedidos perfeitos (<i>total perfect orders</i>), que por sua vez depende de quatro indicadores de desempenho do nível 2:</p> <p>i. <i>% of orders delivered in full</i> (RL 2.1): Uma entrega é considerada completa se todos os itens do pedido forem entregues nas quantidades especificadas pelo cliente;</p> <p>ii. <i>Delivery performance to customer commit date</i> (RL 2.2): Este indicador avalia se o pedido foi entregue na data combinada com o cliente e no local correto;</p> <p>iii. <i>Documentation accuracy</i> (RL 2.3): Avalia a documentação do pedido em relação à precisão e atualização dos dados. Para o pedido ser considerado perfeito neste indicador, o cliente deve estar de acordo com a documentação de embarque, de pagamento, de conformidade e com qualquer outra documentação requerida;</p> <p>iv. <i>Perfect condition</i> (RL 2.4): Avalia se o pedido foi entregue em condições perfeitas, ou seja, sem danos, atendendo às especificações, instalado corretamente e sem retorno para reparos ou substituições dentro do período de garantia.</p> <p>Ao avaliar o desempenho da cadeia em relação a esses itens, cada indicador do nível 2 recebe o valor um (1) se este foi julgado perfeito, caso contrário é atribuído zero (0). Se a soma dos valores desses indicadores for igual a 4, então o pedido em questão foi perfeitamente atendido.</p>

Fonte: Baseado em SCC (2012)

Quadro A6 – Detalhamento do indicador *overall value at risk* (VAR) e de seus indicadores componentes

Nome do indicador: <i>Overall value at risk</i> (VAR)
Atributo associado: <i>Agility</i>
Código no SCOR®: AG 1.4
Descrição: É a soma das probabilidades de eventos de risco que podem impactar nos processos da cadeia (<i>plan, source, make, deliver and return</i>) vezes o impacto monetário desses eventos. VAR é um indicador tradicionalmente usado pelo setor financeiro e mede a exposição de uma organização a eventos de risco em uma cadeia de suprimento. Um evento de risco se refere a qualquer falha de processo ou ruptura que pode impactar negativamente no custo e no desempenho da cadeia, desde os fornecedores dos fornecedores, até os clientes dos clientes, incluindo o ambiente global em que eles operam.
Fórmula: $Supply\ chain\ risk\ VAR(\$) = VAR(\$ (plan)) + VAR(\$ (source)) + VAR(\$ (make)) + VAR(\$ (deliver)) + VAR(\$ (return))$ Em que: VAR = Probabilidade de um evento de risco × Impacto monetário do evento
Unidade de medida: Unidade monetária
Detalhamento: Para o cálculo desse indicador, os seguintes dados são requeridos: i. Probabilidade de falhas dos processos: deve ser calculada usando dados históricos referentes a atrasos de entrega, falhas de qualidade, falhas de máquinas e outros eventos que conduzam a um desempenho abaixo do esperado; ii. Probabilidade de eventos de risco externos: refere-se à probabilidade de desastres como terremotos e furacões e pode ser calculada com base em dados de pesquisas ou opinião de especialistas; iii. Impacto do risco: É uma estimativa monetária fornecida por especialistas das funções do negócio que avalia o reflexo de um evento de risco até a normalidade ser reestabelecida. O cálculo do indicador <i>Overall value at risk</i> depende dos valores dos seguintes indicadores do nível 2: VAR <i>plan</i> (AG 2.15), VAR <i>source</i> (AG 2.16), VAR <i>make</i> (AG 2.17), VAR <i>deliver</i> (AG 2.18) e VAR <i>return</i> (AG 2.19). Outro indicador do nível 2 é denominado <i>supplier's / customer's / product's risk rating</i> (AG 2.14). Esse indicador pode ser usado para avaliar o risco associado com cada fornecedor e ranqueá-los de acordo com o pior desempenho. O risco associado a clientes e produtos também pode ser medido com base em indicadores como rentabilidade, crescimento de volume, retornos e reclamações.

Fonte: Baseado em SCC (2012)

Quadro A7 – Detalhamento do indicador *upside supply chain flexibility* e de seus indicadores componentes

Nome do indicador: <i>Upside supply chain flexibility</i>
Atributo associado: <i>Agility</i>
Código no SCOR®: AG 1.1

<p>Descrição: Refere-se ao número de dias requeridos para alcançar um aumento sustentável não planejado de 20 % nas quantidades entregues.</p>
<p>Fórmula: Não há uma fórmula de cálculo objetiva para este indicador. Tanto ele quanto os indicadores de flexibilidade componentes do nível 2 (<i>upside source flexibility</i>, <i>upside make flexibility</i>, <i>upside deliver flexibility</i>, <i>upside source return flexibility</i> e <i>upside deliver return flexibility</i>) são calculados com base em suposições ou baseados em eventos históricos. O valor do indicador <i>order fulfillment cycle time</i> deve ser equivalente ao tempo decorrido entre a ocorrência de um evento não planejado e o alcance do aumento sustentável em relação a cada um dos indicadores componentes. O aumento de 20% é sugerido pelo SCOR® para viabilizar o <i>benchmarking</i>, porém o próprio modelo alerta que este valor meta pode ser inalcançável para algumas organizações e insuficiente para outras. Vale ressaltar que o novo nível operacional deve ser alcançado sem aumentar significativamente o custo por unidade.</p>
<p>Unidade de medida: Dias</p>
<p>Detalhamento: O tempo total decorrido entre a ocorrência de um evento e o alcance da meta de aumento sustentável nas quantidades entregues não é necessariamente igual à soma dos indicadores componentes, pois algumas atividades podem ocorrer simultaneamente. Algumas restrições que devem ser consideradas para estimar o valor dos indicadores componentes são apontadas a seguir.</p> <ol style="list-style-type: none"> i. <i>Upside source flexibility</i> (AG 2.1): Refere-se ao número de dias requeridos para alcançar um aumento sustentável de 20% nas quantidades de matéria-prima adquiridas. Algumas restrições que devem ser consideradas referem-se ao volume de aquisição adicional (determinado de acordo com as restrições a seguir), ao capital adicional requerido, tempo necessário para encontrar recursos adicionais, tempo requerido para negociações e tempo necessário para recrutar, contratar e / ou treinar pessoal adicional para preencher a lacuna entre a quantidade de horas subutilizadas e a força de trabalho necessária para alcançar o aumento pretendido; ii. <i>Upside make flexibility</i> (AG 2.2): Consiste no número de dias requerido para alcançar um aumento sustentável não planejado de 20 % na quantidade produzida supondo que não existem restrições de matéria-prima. Algumas restrições a serem consideradas são o volume adicional de produção (determinado de acordo com as restrições a seguir), utilização da capacidade interna atual, disponibilidade de capital atual, tempo necessário para recrutar, contratar e / ou treinar mão de obra adicional para preencher a lacuna entre a quantidade de horas subutilizadas e a força de trabalho necessária para alcançar o aumento almejado, e tempo requerido para obter ativos ou capacidade produtiva para preencher a lacuna entre a capacidade dos ativos subutilizada e os ativos necessários para alcançar o aumento pretendido; iii. <i>Upside deliver flexibility</i> (AG 2.3): Refere-se ao número de dias requeridos para alcançar um aumento sustentável de 20% na quantidade de produtos entregues. As restrições a serem consideradas incluem volume de entrega adicional (determinado de acordo com as restrições a seguir), utilização da capacidade interna atual, disponibilidade de capital atual, tempo requerido para obter facilidades e recursos complementares (terceirizados ou arrendados) para sustentar o aumento desejado nas quantidades entregues, tempo requerido para obter ativos ou capacidade produtiva para preencher a lacuna entre a capacidade dos ativos subutilizada e os ativos necessários para alcançar o aumento desejado nas quantidades entregues, e tempo necessário para recrutar,

<p>contratar e / ou treinar mão de obra adicional para preencher a lacuna entre a quantidade de horas subutilizadas e a força de trabalho necessária para alcançar o aumento almejado;</p> <p>iv. <i>Upside source return flexibility</i> (AG 2.4): Diz respeito ao número de dias requeridos para alcançar um aumento sustentável de 20% na quantidade de matéria-prima retornada para os fornecedores. Algumas restrições para este indicador são o volume de retorno adicional ao fornecedor (determinado de acordo com as restrições a seguir), disponibilidade de força de trabalho das funções compras e logística, tempo necessário para alcançar e manter o tempo de ciclo atual do pedido de retorno ao fornecedor, utilização da capacidade interna atual, disponibilidade de capital atual, tempo requerido para obter facilidades e recursos complementares (terceirizados ou arrendados) para sustentar o aumento desejado nas quantidades retornadas, tempo necessário para recrutar, contratar e / ou treinar mão de obra adicional para preencher a lacuna entre a quantidade de horas subutilizadas e a força de trabalho necessária para alcançar o aumento almejado nas quantidades retornadas para o fornecedor, tempo requerido para obter ativos ou capacidade produtiva para preencher a lacuna entre a capacidade dos ativos subutilizada e os ativos necessários para alcançar o aumento desejado nas quantidades retornadas;</p> <p>v. <i>Upside deliver return flexibility</i> (AG 2.5): Refere-se ao número de dias requeridos para alcançar um aumento sustentável de 20% na quantidade de produtos acabados de clientes. As restrições incluem volume adicional de retorno do cliente (determinado de acordo com as restrições a seguir), disponibilidade de força de trabalho das funções compras e logística, utilização da capacidade interna atual, disponibilidade de capital atual, tempo necessário para alcançar e manter o tempo de ciclo atual do pedido de retorno do cliente, tempo requerido para obter facilidades e recursos complementares (terceirizados ou arrendados) para sustentar o aumento desejado nas quantidades retornadas dos clientes, e tempo requerido para obter ativos ou capacidade produtiva para preencher a lacuna entre a capacidade dos ativos subutilizada e os ativos necessários para alcançar o aumento desejado nas quantidades retornadas de clientes, e tempo necessário para recrutar, contratar e / ou treinar mão de obra adicional para preencher a lacuna entre a quantidade de horas subutilizadas e a força de trabalho necessária para alcançar o aumento desejado nas quantidades retornadas dos clientes;</p>

Fonte: Baseado em SCC (2012)

Quadro A8 – Detalhamento do indicador *upside supply chain adaptability* e de seus indicadores componentes

Nome do indicador: <i>Upside supply chain adaptability</i>
Atributo associado: <i>Agility</i>
Código no SCOR®: AG 1.2
Descrição: Consiste no percentual máximo de aumento nas quantidades entregues aos clientes que pode ser alcançada em 30 dias.
Fórmula: O valor desse indicador e seus indicadores componentes do nível 2 (<i>upside source adaptability, upside make adaptability, upside deliver adaptability, upside source return adaptability e upside deliver return adaptability</i>) são calculados com base em suposições ou em eventos históricos.

O valor do indicador *upside supply chain adaptability* será definido pelo menor valor de desempenho alcançado entre seus indicadores componentes. O novo nível operacional deve ser alcançado sem aumentar significativamente o custo por unidade;

Unidade de medida: Percentual

Detalhamento: Os indicadores do nível 2 que determinam o valor do indicador *upside supply chain adaptability* são:

- i. *Upside source adaptability* (AG 2.6): Refere-se ao percentual máximo de aumento nas quantidades de material adquiridas e recebidas em 30 dias. Alguns elementos a serem considerados na estimativa desse valor são o volume de compra adicional (determinado de acordo com as restrições a seguir), a disponibilidade de capital atual, a quantidade de capital que será necessária para aumentar as quantidades adquiridas, o tempo despendido em negociações com os fornecedores, o tempo de ciclo do pedido de compra e a quantidade de pessoal que precisa ser recrutada, selecionada e treinada para preencher a lacuna entre a força de trabalho subutilizada e a mão de obra necessária para aumentar e sustentar as quantidades adquiridas no período de 30 dias;
- ii. *Upside make adaptability* (AG 2.7): Consiste no maior percentual de aumento nas quantidades produzidas que pode ser alcançado em 30 dias, considerando que não haja restrições de matéria-prima. Algumas restrições que devem ser consideradas na estimativa desse indicador são o volume adicional de produção (determinado de acordo com as restrições a seguir), utilização da capacidade interna, novo tempo de ciclo de manufatura considerando o aumento nas quantidades produzidas, disponibilidade de capital, a quantidade de mão de obra que pode ser recrutada e treinada para preencher a lacuna entre a mão de obra subutilizada e a mão de obra necessária para aumentar de forma sustentável as quantidades produzidas em 30 dias, quantidade de recursos terceirizados que podem ser obtidos para aumentar e sustentar as quantidades produzidas em 30 dias e a quantidade de capital que pode ser obtido para preencher a lacuna entre a capacidade dos ativos subutilizada e os ativos necessários para alcançar o aumento desejado nas quantidades produzidas por 30 dias;
- iii. *Upside deliver adaptability* (AG 2.8): É o percentual máximo de aumento nas quantidades entregues que pode ser alcançado em 30 dias supondo que não existam restrições de disponibilidade de produtos acabados. As restrições a serem consideradas na determinação desse indicador incluem o volume de entrega adicional (determinado de acordo com as restrições a seguir), utilização da capacidade interna, novo tempo de ciclo de logístico considerando o aumento nas quantidades produzidas, disponibilidade de capital, quantidade de mão de obra que pode ser recrutada e treinada para preencher a lacuna entre a mão de obra subutilizada e a mão de obra necessária para aumentar de forma sustentável as quantidades entregues em 30 dias, quantidade de recursos terceirizados que podem ser obtidos para aumentar e sustentar as quantidades entregues em 30 dias e quantidade de capital que pode ser obtido para preencher a lacuna entre a capacidade dos ativos subutilizada e os ativos necessários para alcançar o aumento desejado nas quantidades entregues por 30 dias;
- iv. *Upside source return adaptability* (AG 2.9): Refere-se ao percentual máximo de aumento de retorno de matérias primas para fornecedores que pode ser alcançado em 30 dias. Alguns elementos a serem considerados na estimativa desse valor são o volume de retorno adicional (a ser determinado conforme as restrições a seguir), utilização da capacidade interna, novo tempo de ciclo de retorno

<p>ao fornecedor considerando o aumento nas quantidades retornadas, disponibilidade de capital, disponibilidade de mão de obra para as funções de logística e compras, quantidade de mão de obra que pode ser recrutada e treinada para preencher a lacuna entre a mão de obra subutilizada e a mão de obra necessária para aumentar de forma sustentável as quantidades retornadas em 30 dias, quantidade de recursos terceirizados que podem ser obtidos para aumentar e sustentar as quantidades retornadas em 30 dias e a quantidade de capital que pode ser obtido para preencher a lacuna entre a capacidade dos ativos subutilizada e os ativos necessários para alcançar o aumento desejado nas quantidades retornadas durante o período de 30 dias;</p> <p>v. <i>Upside deliver return adaptability</i> (AG 2.10): É o percentual máximo de aumento de retorno de produtos acabados de clientes que pode ser alcançado em 30 dias. Algumas restrições a serem consideradas na estimativa desse valor são o volume adicional de retorno do cliente (a ser determinado conforme as restrições a seguir), utilização da capacidade interna, novo tempo de ciclo de processamento de pedido de retorno do cliente, novo tempo de ciclo do retorno considerando o aumento nas quantidades retornadas, disponibilidade de capital, disponibilidade de mão de obra para as funções de logística e serviço ao cliente, quantidade de mão de obra que pode ser recrutada e treinada para preencher a lacuna entre a mão de obra subutilizada e a mão de obra necessária para aumentar de forma sustentável as quantidades retornadas de clientes em 30 dias, quantidade de recursos terceirizados que podem ser obtidos para aumentar e sustentar as quantidades retornadas em 30 dias e a quantidade de capital que pode ser obtido para preencher a lacuna entre a capacidade dos ativos subutilizada e os ativos necessários para aumentar as quantidades retornadas dos clientes durante o período de 30 dias.</p>
--

Fonte: Baseado em SCC (2012)

Quadro A9 – Detalhamento do indicador *upside supply chain adaptability* e de seus indicadores componentes

Nome do indicador: <i>Downside supply chain adaptability</i>
Atributo associado: <i>Agility</i>
Código no SCOR®: AG 1.3
Descrição: Refere-se a menor redução nas quantidades pedidas (antes da entrega) que pode ser alcançada durante 30 dias, sem implicar em penalidades de custo ou estoque.
Fórmula: O valor desse indicador e seus indicadores componentes do nível 2 (<i>downside source adaptability</i> , <i>downside make adaptability</i> e <i>downside deliver adaptability</i>) são calculados com base em suposições ou em eventos históricos. O valor do indicador <i>upside supply chain adaptability</i> será definido pelo menor valor de desempenho alcançado entre seus indicadores componentes.
Unidade de medida: Percentual
Detalhamento: Os indicadores do nível 2 que determinam o valor do indicador <i>downside supply chain adaptability</i> são: <ul style="list-style-type: none"> i. <i>Downside source adaptability</i> (AG 2.11): Refere-se ao percentual de redução nas quantidades de matéria-prima que pode ser alcançado antes da entrega, sem implicar em penalidades de custo ou estoque. Alguns elementos a serem considerados na estimativa desse valor são o volume de compra

- reduzido (a ser determinado conforme as restrições a seguir), disponibilidade de capital atual, tempo despendido em negociações com os fornecedores, tempo de ciclo do pedido de compra, quantidade de pessoal que precisa ser demitido ou desviado para outras atividades para preencher a lacuna entre a força de trabalho subutilizada e a mão de obra necessária para reduzir de forma sustentável as quantidades adquiridas no período de 30 dias e quantidade de inventário (matéria-prima e produto acabado) que pode ser retornada, vendida ou desviada sem penalidades de custo ou inventário para sustentar uma diminuição nas quantidades compradas durante 30 dias;
- ii. *Downside make adaptability* (AG 2.12): Consiste no maior percentual de redução nas quantidades de produzidas que pode ser alcançado em 30 dias, sem penalidades de inventário ou custo. Alguns fatores que devem ser considerados na estimativa desse indicador são o volume adicional de produção (a ser determinado conforme as restrições a seguir), utilização da capacidade interna, requisitos de capital atual, novo tempo de ciclo de manufatura considerando a diminuição nas quantidades produzidas, quantidade de pessoal que precisa ser demitido ou desviado para outras atividades para preencher a lacuna entre a força de trabalho subutilizada e a mão de obra necessária para reduzir de forma sustentável as quantidades produzidas em 30 dias, quantidade de recursos terceirizados que podem ser reincididos para diminuir as quantidades produzidas em 30 dias e a quantidade de ativos que pode ser realocada ou vendida sem penalidades para diminuir as quantidades produzidas por 30 dias;
- iii. *Downside deliver adaptability* (AG 2.13): É o percentual máximo de redução nas quantidades de entregues (antes da entrega) que pode ser alcançado em 30 dias sem implicar em penalidades de inventário ou custo. As restrições a serem consideradas na determinação desse indicador incluem o volume de entrega reduzido (determinado conforme os elementos a seguir), utilização da capacidade interna, requisitos de capital atual, novo tempo de ciclo de logístico considerando a diminuição nas quantidades entregues, quantidade de mão de obra que pode ser demitida para diminuir de forma sustentável as quantidades entregues em 30 dias, quantidade de recursos terceirizados que podem ser reincididos para diminuir as quantidades entregues em 30 dias e quantidade de ativos que pode ser realocada ou vendida sem penalidades para sustentar a diminuição nas quantidades entregues por 30 dias.

Fonte: Baseado em SCC (2012)

Quadro A10 – Detalhamento do indicador *return on supply chain fixed assets* e de seus indicadores componentes

Nome do indicador: <i>Return on supply chain fixed assets</i>
Atributo associado: <i>Asset management efficiency</i>
Código no SCOR®: AM.1.2
Descrição: Mede o retorno que uma organização recebe sobre seu capital investido em ativos fixos na cadeia de suprimento. Isso inclui os ativos fixos usados nos processos <i>plan, source, make, deliver e return</i> . Os dados requeridos para a avaliação desse indicador tipicamente já são capturados pelos sistemas de informação transacionais do negócio.

Fórmula: $\text{Return on supply chain fixed assets} = \frac{([\text{supply chain revenue}] - [\text{total cost to serve}])}{[\text{supply chain fixed assets}]}$
Unidade de medida: Adimensional
Detalhamento: Esse indicador é calculado a partir do indicador de nível 2: i. <i>Supply chain fixed assets</i> (AM.2.5): É a soma dos custos associados aos processos <i>plan</i> , <i>source</i> , <i>deliver</i> e <i>return fixed assets</i> ; Além desse indicador, no cálculo de <i>return on supply chain fixed assets</i> também são considerados os indicadores <i>supply chain revenue</i> (AM.2.4), que quantifica a receita gerada pela operação da cadeia, e <i>total cost to serve</i> (CO 1.001), detalhado no Quadro A1.

Fonte: Baseado em SCC (2012)

APÊNDICE B – Equações das Estatísticas Usadas neste Estudo

Quadro B1 – Fórmulas do MSE, RMSE, MAPE e R "Quadro B1 – Fórmulas do MSE, RMSE, MAPE e R"

Estatística	Fórmula	Detalhamento
Erro quadrático médio (<i>Mean Square Error, MSE</i>)	$MSE = \frac{1}{n} \sum_{t=1}^n (y_r - y_e)^2$	Nessas equações, n é o número de amostras, y_r é o valor real de saída para uma amostra e y_e é o valor de saída estimado para esta amostra.
Raiz do erro quadrático Médio (<i>Root Mean Square Error, RMSE</i>)	$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_r - y_e)^2}$	
Erro médio absoluto (<i>Mean Absolute Error – MAE</i>)	$MAE = \frac{1}{n} \sum_{t=1}^n y_r - y_e $	
Índice de correlação linear de Pearson (R)	$R = \frac{\sum_{t=1}^n (y_r - \bar{y}_r)(y_e - \bar{y}_e)}{\sqrt{[\sum_{t=1}^n (y_r - \bar{y}_r)^2][\sum_{t=1}^n (y_e - \bar{y}_e)^2]}}$	y_r e y_e representa os valores de cada variável envolvida no teste; \bar{y}_r e \bar{y}_e são as médias aritméticas.

Fonte: Adaptado de Montgomery e Runger (2009) e Bergmeir e Benítez (2012)

APÊNDICE C – Equações para o cálculo da quantidade de parâmetros adaptativos dos modelos PMC e ANFIS

As Equações 67 e 68 foram desenvolvidas pelo autor deste estudo para calcular o número de parâmetros adaptativos dos modelos de predição de desempenho PMC e ANFIS. Conforme mostra a Equação 67, o número de parâmetros adaptativos de um modelo PMC (NPA_{PMC}) é obtido pela soma entre a quantidade de limiares de ativação presentes na rede ($N_{limiares}$) e a quantidade de conexões sinápticas existentes. A quantidade de conexões sinápticas é calculada considerando a quantidade de variáveis de entrada (n) e o número de neurônios presentes na camada intermediária ($N_{neur_cam_int}$) e na camada de saída ($N_{neur_cam_saida}$).

$$NPA_{PMC} = N_{limiares} + \sum_{i=1}^n N_{neur_cam_int} + N_{neur_cam_int} \times N_{neur_cam_saida} \quad (67)$$

Em relação ao número de parâmetros adaptativos de um modelo PMC (NPA_{ANFIS}), este é dado pela soma entre a quantidade de parâmetros adaptativos do consequente de todas as regras e o número total de parâmetros das funções de pertinência das variáveis de entrada. Na Equação 68, cada regra de inferência é representada por r (sendo $r = 1, \dots, t$), as variáveis de entrada são indicadas por i ($i = 1, \dots, n$), o número de funções de pertinência de cada variável é referido como j ($j = 1, \dots, m$), $N_{par_função_{ji}}$ é o número de parâmetros adaptativos da função de pertinência j da variável i e $N_{par_consequente_r}$ consiste no número de parâmetros adaptativos do consequente da regra r .

$$NPA_{ANFIS} = \sum_{i=1}^n \sum_{j=1}^m N_{par_função_{ji}} + \sum_{r=1}^t N_{par_consequente_r} \quad (68)$$

APÊNDICE D – Recomendações para o desenvolvimento de sistemas de predição de desempenho PMC

A seguir é apresentado um guia com informações para apoiar a modelagem, o treinamento e o uso de sistemas de predição baseados em redes PMC. Essas recomendações são baseadas na literatura sobre redes neurais e nos resultados obtidos ao longo desta pesquisa.

Recomendações para a modelagem de sistemas de predição PMC:

- Escolha da configuração topológica adequada usando validação cruzada: p. 124 (3º parágrafo); p. 171 (1º parágrafo); p. 175 (1º parágrafo);
- Definição da quantidade de camadas intermediárias: p. 103 (1º parágrafo); p. 119 (4º parágrafo); p. 247 (1º parágrafo);
- Definição da quantidade de neurônios na camada intermediária: p. 124 (3º parágrafo); p. 129 (1º parágrafo); p. 175 (1º parágrafo); p. 193 (1º parágrafo);
- Escolha da função de ativação dos neurônios da camada intermediária: p. 100 (6º parágrafo); p. 110 (1º parágrafo); p. 175 (1º parágrafo); p. 193 (1º parágrafo);
- Escolha da função de ativação dos neurônios da camada de saída: p. 100 (6º parágrafo); p. 175 (1º parágrafo); p. 194 (4º parágrafo);
- Aumento do número de variáveis de entrada: p. 245 (1º parágrafo); p. 247 (1º parágrafo).

Recomendações para o treinamento de sistemas de predição PMC:

- Escolha dos critérios de parada do *backpropagation*: p. 123 (Quadro 14); p. 160 (1º parágrafo); p. 178 (2º parágrafo);
- Escolha do valor da taxa de aprendizagem: p. 123 (Quadro 14); p. 179 (2º parágrafo); p. 193 (Tabela 9);
- Normalização dos valores das amostras de treinamento: p. 130 (2º parágrafo); p. 164 (2º parágrafo);
- Distribuição dos dados das amostras de treinamento: p. 125 (2º parágrafo); p. 130 (1º parágrafo); p. 173 (1º parágrafo);
- Organização dos processos de treinamento: p. 125 (2º parágrafo); p. 128 (2º parágrafo); p. 178 (1º parágrafo);

- Tamanho do subconjunto de amostras de treinamento: p. 126 (1º parágrafo); p. 173 (2º parágrafo); p. 247 (1º parágrafo).

Recomendações para o uso de sistemas de predição PMC:

- Normalização dos valores das amostras de uso: p. 130 (2º parágrafo); p. 165 (2º parágrafo); p. 249 (2º parágrafo);
- Inclusão e exclusão de alternativas ou de métricas: p. 249 (1º parágrafo).

APÊNDICE E – Recomendações para o desenvolvimento de sistemas de predição de desempenho ANFIS

Apresenta-se a seguir um guia com informações para apoiar a modelagem, o treinamento e o uso de sistemas de predição de desempenho baseados em ANFIS. Essas recomendações são baseadas na literatura sobre redes neurais e nos resultados obtidos ao longo desta pesquisa.

Recomendações para a modelagem de sistemas de predição ANFIS:

- Escolha da configuração topológica adequada usando validação cruzada: p. 155 (3º parágrafo); p. 170 (3º parágrafo); p. 194 (3º parágrafo);
- Definição da quantidade de termos linguísticos das variáveis de entrada: p. 156 (Quadro 21); p. 158 (1º parágrafo); p. 201 (1º parágrafo); p. 214 (Tabela 17);
- Definição da forma das funções de pertinência: p. 156 (Quadro 21); p.158 (2º parágrafo); p. 214 (Tabela 17);
- Definição do tipo de consequente das regras de inferência: p. 150 (3º parágrafo); p. 194 (3º parágrafo); p. 214 (Tabela 17);
- Definição dos valores iniciais dos parâmetros dos consequentes: p. 156 (Quadro 21);
- Criação da base de regras de inferência: p. 137 (3º parágrafo); p. 250 (1º parágrafo);
- Escolha de operador T-norma para as operações do tipo “AND”: p. 140 (2º parágrafo); p. 156 (Quadro 21); p. 214 (Tabela 17);
- Aumento do número de variáveis de entrada: p. 244 (1º parágrafo); p. 245 (1º parágrafo).

Recomendações para o treinamento de sistemas de predição ANFIS

- Escolha dos critérios de parada do algoritmo de treinamento: p. 156 (Quadro 21); p. 197 (5º parágrafo); p. 242 (2º parágrafo);
- Escolha do valor da taxa de aprendizagem: p. 156 (Quadro 21); p. 197 (4º parágrafo);
- Normalização dos valores das amostras de treinamento: p. 129 (2º parágrafo); p. 158 (3º parágrafo); p.164 (2º parágrafo);

- Distribuição dos dados das amostras de treinamento: p. 124 (2º parágrafo); p. 129 (1º parágrafo); p. 157 (2º parágrafo); p. 172 (2º parágrafo);
- Organização dos processos de treinamento: p. 124 (2º parágrafo); p. 177 (1º parágrafo); p. 197 (3º parágrafo);
- Tamanho do subconjunto de amostras de treinamento: p. 125 (1º parágrafo); p. 194 (2º parágrafo); p. 245 (1º parágrafo).

Recomendações para o uso de sistemas de predição ANFIS:

- Normalização dos valores das amostras de uso: p. 129 (2º parágrafo); p. 164 (2º parágrafo); p. 248 (2º parágrafo);
- Inclusão e exclusão de alternativas ou de métricas: p. 248 (1º parágrafo).