

Um Método Alternativo e Inteligente para o Monitoramento Remoto das Variações de Tensão de Curta Duração em um Sistema de Distribuição de Energia

SEL0409 – Qualidade da Energia Elétrica

Aluno: *Fernando Bambozzi Bottura*

Orientador: *Prof. Dr. Mário Oleskovicz*

Organização da Apresentação

- Introdução
- Redes Neurais Artificiais (RNAs)
- Sistema Elétrico de Distribuição
- Obtenção da Base de Treinamento para as RNAs
- Treinamento e Definição da Topologia das RNAs
- Resultados
- Conclusões



Parte I



Parte II



Parte III

Introdução

- **Objetivo do Trabalho:**

- Obter o monitoramento remoto dos níveis de tensão eficaz em pontos de interesse num SD de energia;
- Complementar o processo convencional de medição das variações de tensão;
- Utilizar Redes Neurais Artificiais (RNA) para realizar o monitoramento.

- **Motivação:**

- Crescente exigência pela QEE;
- Consolidação de normatizações no âmbito nacional e internacional;
- Manter níveis aceitáveis de QEE requer o ***monitoramento dos distúrbios***.
 - Problema de alta complexidade e investimento financeiro relativamente alto;
 - Ocorrência dos distúrbios de QEE possui caráter estocástico;

Introdução

- **Estudos e Pesquisas Atuais:**

- Ferramentas de inteligência artificial como: RNAs, Lógica *Fuzzy*, Sistemas Neuro-*Fuzzy*, Algoritmos Genéticos;
- Permitem mapear processos de difícil solução analítica;
- Propiciam soluções eficientes ao monitoramento dos distúrbios de QEE;

- **Monitoramento Remoto Proposto:**

- Com o medidor de QEE presente na subestação do sistema, estima-se os níveis de tensões eficazes em um (ou mais) ponto(s) do mesmo;
- RNAs quantificam os níveis de tensões eficazes nos pontos remotos;
- Necessária a obtenção da base de treinamento para as RNAs (simulação computacional do SD).

Redes Neurais Artificiais – RNA

- **Aspectos Gerais**

- Primeiros trabalhos publicados há mais de 50 anos;
- Inspiração neurobiológica;
- Modelar matematicamente a maneira como o cérebro humano resolve problemas de alta especificidade e complexidade → Processamento paralelo

- **Aplicações diversas:**


- Classificação de padrões e reconhecimento de padrões (*Perceptron Multicamadas, Kohonen*);
- Aproximação de funções (*PMC, RBF*);
- Ação preditiva (*TDNN – Time Delay Neural Network*);
- Memórias associativas (Hopfield);

- ***Reconhecimento e avaliação de distúrbios de QEE***

Redes Neurais Artificiais – RNA

- **Conceito Fundamental: Conhecimento Adquirido**

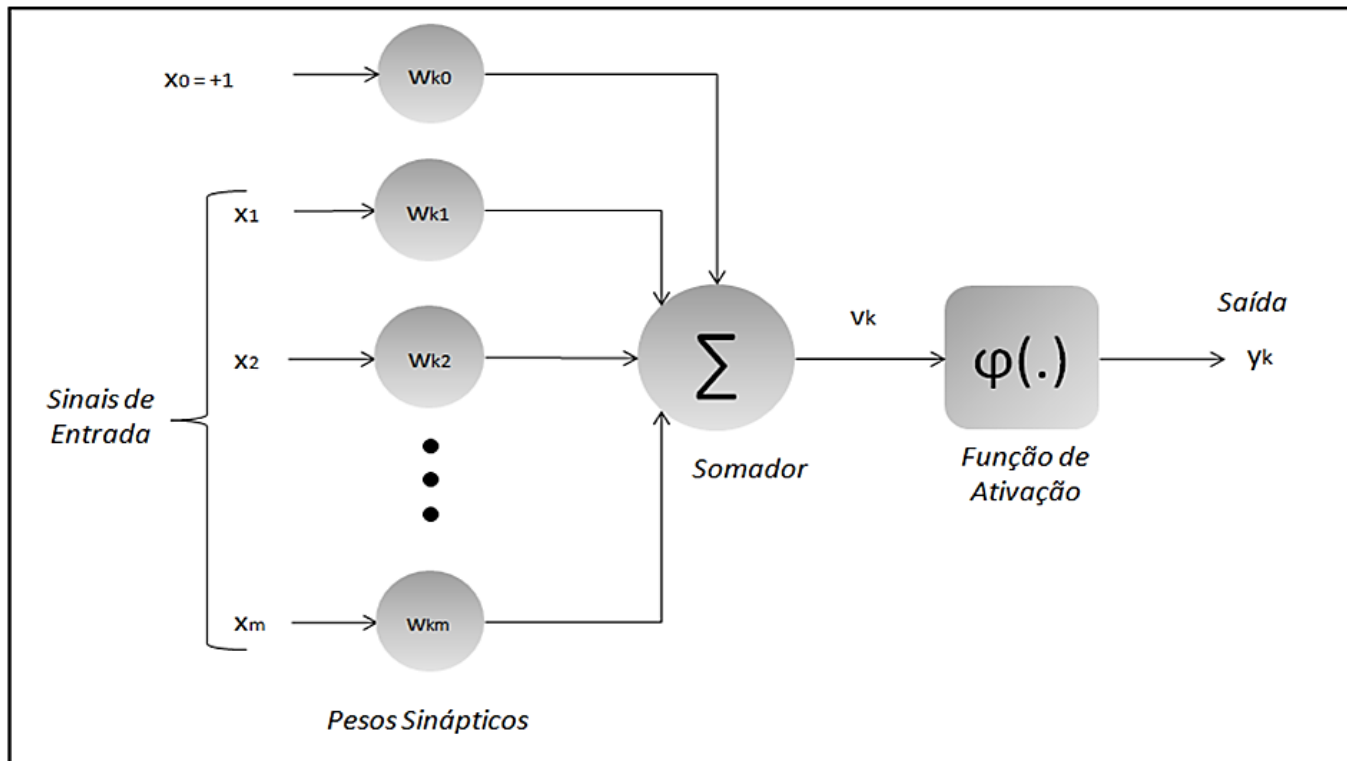
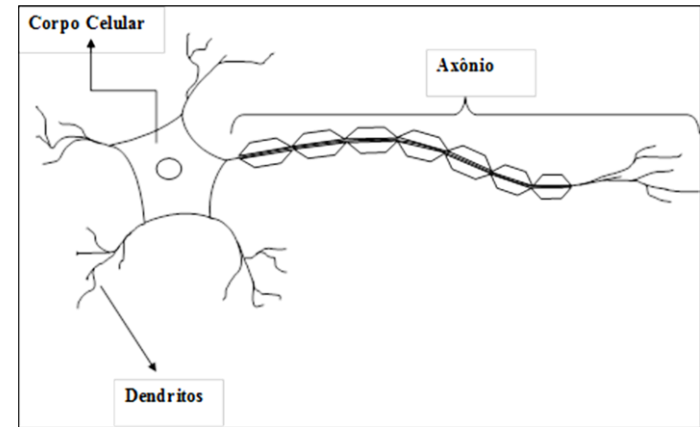
- RNAs armazenam conhecimento adquirido, interagindo com o ambiente via um algoritmo de aprendizagem;
- Modificação da matriz de pesos sinápticos;
- Aprendizagem supervisionada requer apresentar pares de entrada-saída às redes;
- Generalização de respostas para entradas desconhecidas.



Redes Neurais Artificiais – RNA

○ Modelo Matemático do Neurônio Artificial

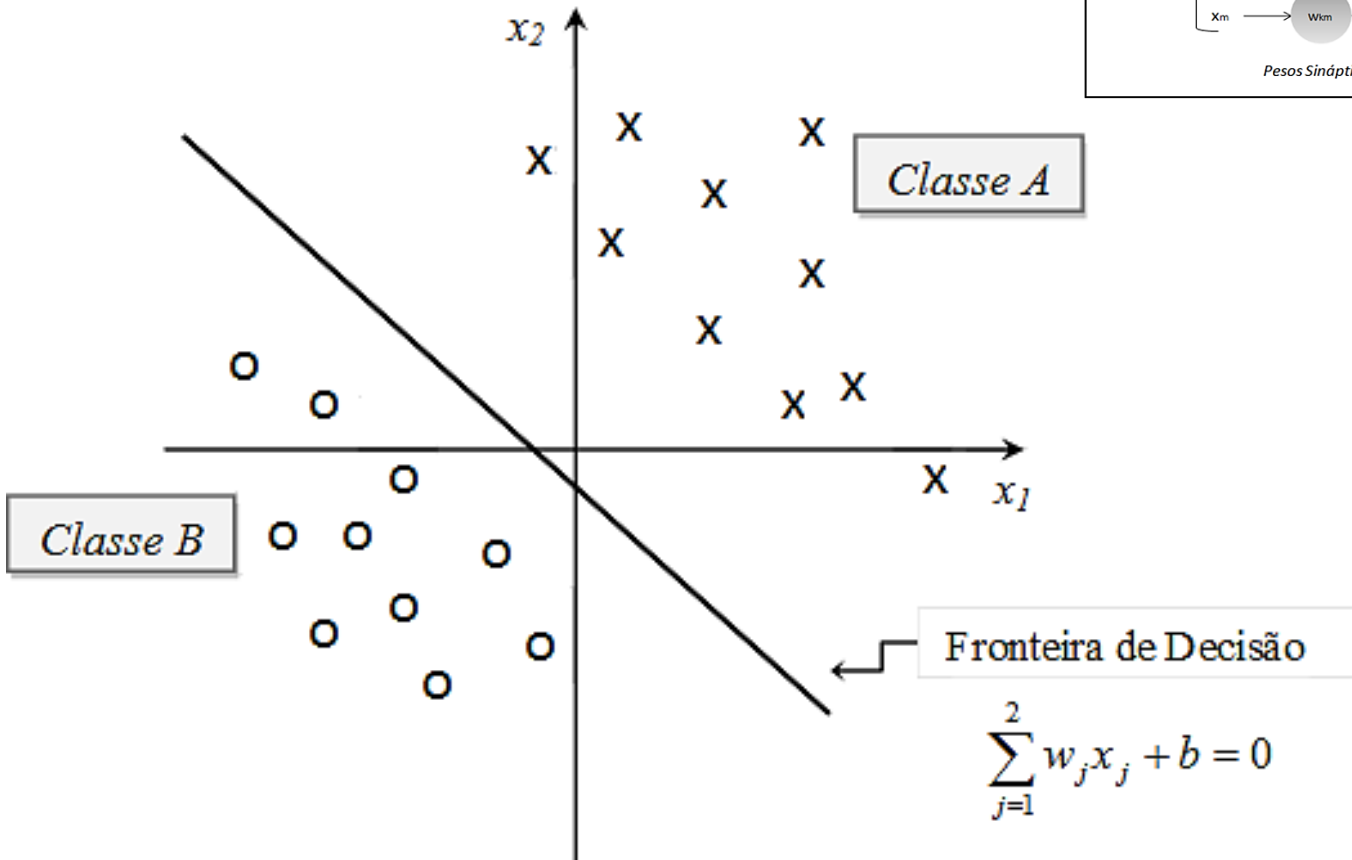
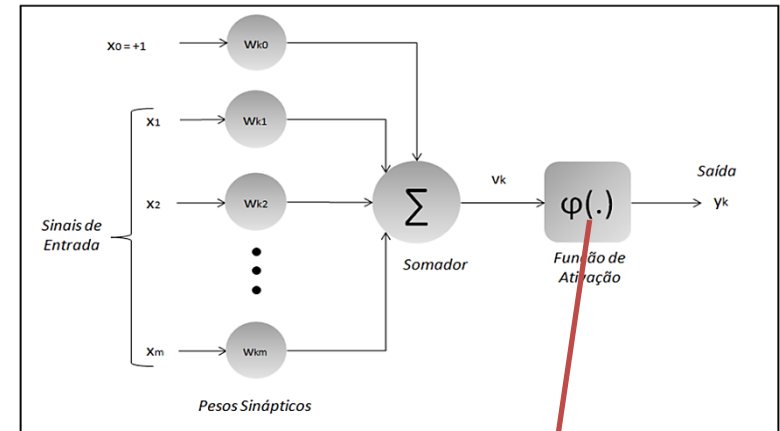
- Unidade fundamental de processamento
- 3 elementos básicos → pesos sinápticos, somador e função de ativação



Redes Neurais Artificiais – RNA

○ *Perceptron* de Rosemblatt

- Classificador de padrões;
- Padrões linearmente separáveis.




Função de Ativação

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ -1, & \text{se } v < 0 \end{cases}$$


Redes Neurais Artificiais – RNA

- **Redes *Perceptron* de Múltiplas Camadas**

Única Camada



Múltiplas Camadas



- **Algoritmos de Treinamento para Redes *Perceptron* Multicamadas**

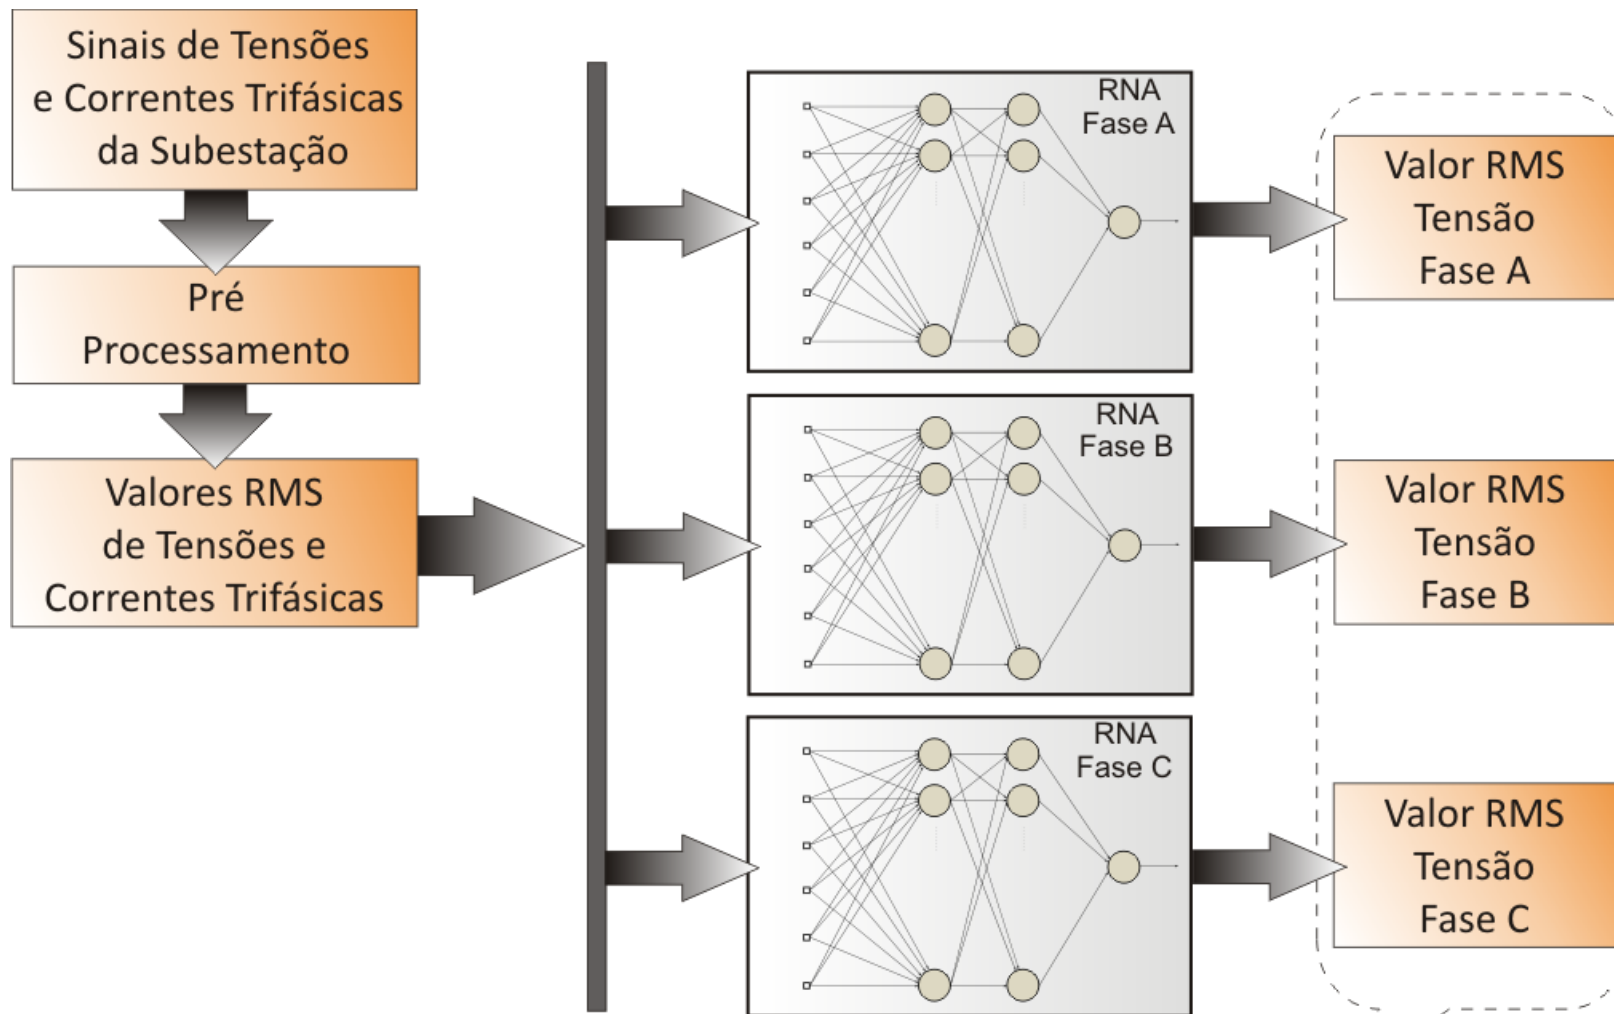
- ***Backpropagation:***

- Pesos ajustados na direção oposta do gradiente da função de erro quadrático (Descida do Gradiente).

- ***Levenberg-Marquardt:***

- Função de ajuste dos pesos que combina o método da Descida do Gradiente com o Método de Newton (convergência mais rápida).


Redes Neurais Artificiais – RNA



Tensões RMS no Ponto Remoto


Sistema de Distribuição - SD

- Disposição geográfica dos alimentadores pertencentes à subestação da concessionária regional



- **Alguns parâmetros para a modelagem computacional do sistema de distribuição:**
 - Equivalente do sistema;
 - Dados do transformador de potência da subestação;
 - Parâmetros dos condutores utilizados;
 - Dados das cargas alocadas no alimentador

Sistema de Distribuição - SD



Obtenção da Base de Treinamento

- **Simulação das Situações de Falta**

- Obter boa variedade de distâncias de faltas em relação ao ponto monitorado;
- Simuladas faltas fase A-terra;
- 20 pontos de faltas dispostos ao longo do sistema de distribuição foram selecionados.

- **Parâmetros variados para cada ponto de aplicação do defeito:**

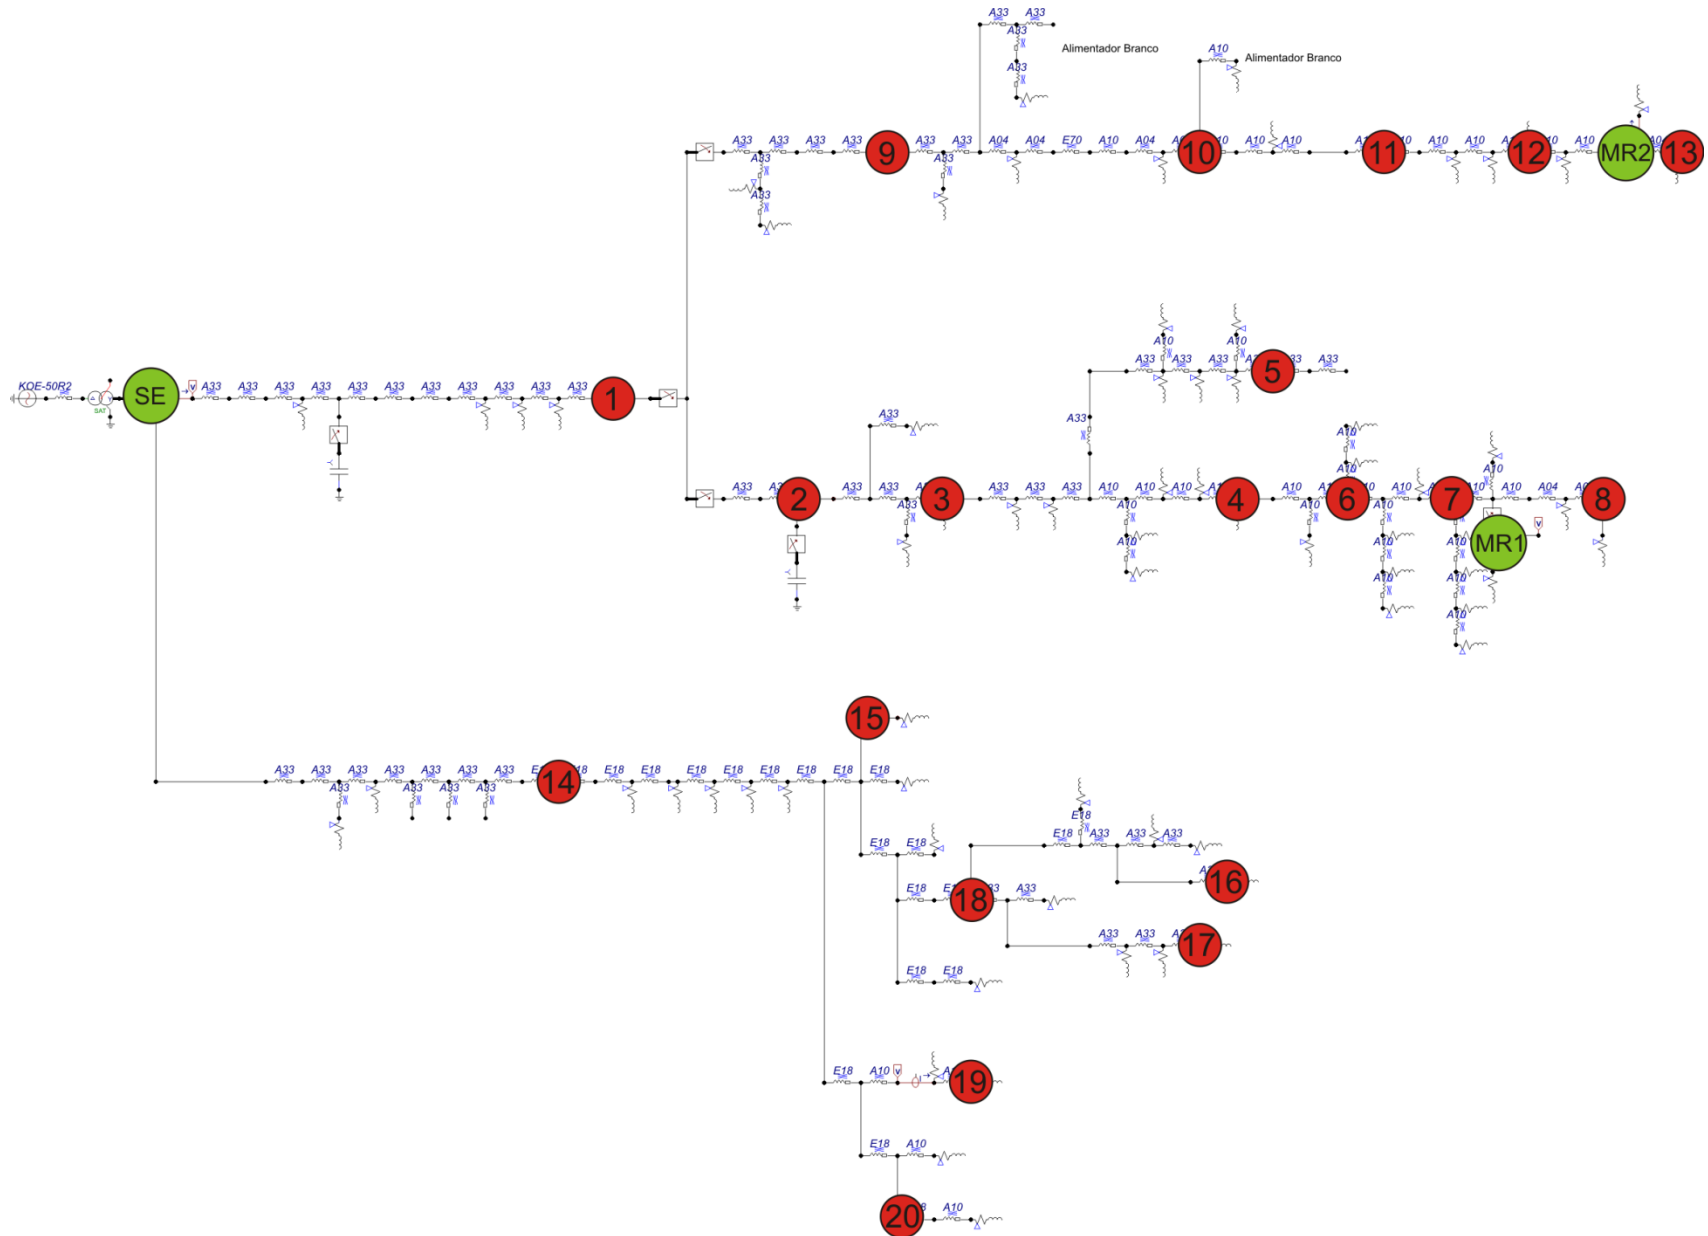
- Impedância: 0, 10, 20, 30 e 40 (Ω);

- Ângulo de falta: 0 e 90 ($^\circ$);

- Total de 10 casos para cada ponto;

- Total de casos simulados: $20 \times 10 = 200$ casos de faltas.

Obtenção da Base de Treinamento



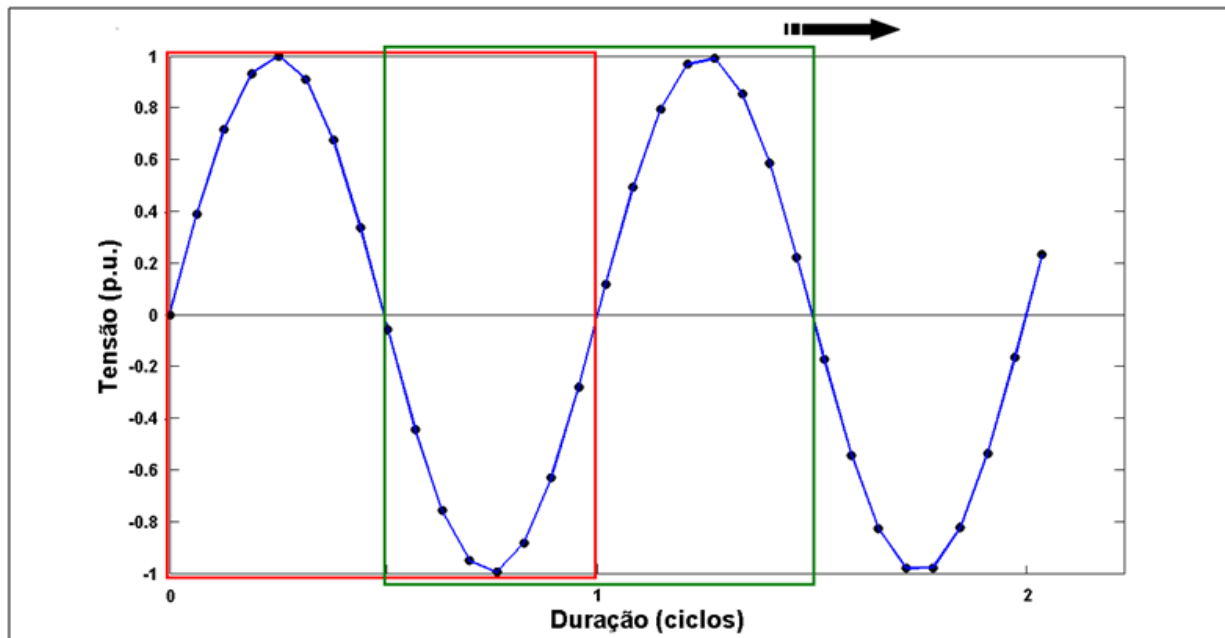
Obtenção da Base de Treinamento

- **Padrão de ativação das RNA (padrões de entrada)**

- 1 caso de falta → 9 ciclos dos sinais medidos na subestação;
- Selecionados 3 ciclos precedentes e 6 ciclos subsequentes ao instante de início de cada falta;

- **Pré processamento:**

- Janela deslizante de 1 ciclo, com deslocamento de $\frac{1}{2}$ ciclo;
- A cada passo da janela → cálculo do valor eficaz (*RMS*);



Exemplo

- Freq. Fundamental: 60Hz
- 16 amostras/ciclo
- Sinal: 2 ciclos
- Total: 3 valores RMS

Obtenção da Base de Treinamento

- **Padrões de entrada**

1 caso de falta = 9 ciclos = 17 valores RMS

200 casos = $200 \times 17 = 3.400$ valores de entrada para cada RNA

- **Padrões de saída**

- As saídas associadas a cada entrada foram obtidas da mesma forma, porém, medindo-se o valor eficaz da tensão no(s) ponto(s) remoto(s).

70% para o treinamento → 2.380 pares de vetores entrada /saída

30% para validação → 1.020 pares de vetores entrada /saída

Treinamento e Definição da Topologia

- **Realizado em duas Etapas:**
 - **Etapa 1:** Treinamento com o algoritmo *Backpropagation*
 - **Etapa 2:** Treinamento com o algoritmo *Levenberg-Marquardt*

Etapa 1: *Backpropagation*

- Treinamento da rede da fase A, aumento gradativo do número de neurônios nas camadas ocultas;
- Análise do desempenho (Validação Cruzada):
 - Erro entre a saída desejada, no ponto remoto MR1, e a resposta fornecida pela RNA (**conjunto de teste**)

Treinamento e Definição da Topologia

- **Critério de parada:** Erro Médio Quadrático = 10^{-6} e/ou Máximo de 6.000 épocas.

15



40

| Topologia 6-10-5-1 | | | | | |
|--------------------|-----------------------|-------------------------------|-------------------------------|---------------------------|--------------------------------------|
| Ensaio | erro<0,005p.u. (%) | 0,005≤ erro <0,015p.u. (%) | 0,015≤ erro ≤0,025p.u. (%) | erro ≤0,025p.u. (%) | Magnitude do maior erro (p.u.) |
| 1 | 3,73 | 8,63 | 9,41 | 21,76 | 0,346 |
| 2 | 10,1 | 46,57 | 6,96 | 63,63 | 0,31 |
| 3 | 31,47 | 4,02 | 8,14 | 43,63 | 0,314 |
| 4 | 32,94 | 9,8 | 20,59 | 63,33 | 0,257 |
| 5 | 40,39 | 9,71 | 15,29 | 65,39 | 0,372 |
| Médias | 23,73 | 15,75 | 12,08 | 51,55 | 0,32 |

Fase A

| Topologia 6-25-15-1 | | | | | |
|---------------------|-----------------------|-------------------------------|-------------------------------|---------------------------|--------------------------------------|
| Ensaio | erro<0,005p.u. (%) | 0,005≤ erro <0,015p.u. (%) | 0,015≤ erro ≤0,025p.u. (%) | erro ≤0,025p.u. (%) | Magnitude do maior erro (p.u.) |
| 1 | 44,41 | 16,96 | 11,86 | 73,24 | 0,315 |
| 2 | 36,08 | 16,86 | 14,31 | 67,25 | 0,62 |
| 3 | 35,59 | 18,92 | 14,8 | 69,31 | 0,401 |
| 4 | 36,86 | 22,65 | 13,53 | 73,04 | 0,888 |
| 5 | 43,43 | 14,61 | 14,9 | 72,94 | 0,231 |
| Médias | 39,27 | 18 | 13,88 | 71,16 | 0,491 |

Fase A

- **Critério de parada:** Erro Médio Quadrático = 10^{-6} e/ou Máximo de **20.000 épocas.**

| Topologia 6-25-15-1 | | | | | |
|---------------------|-----------------------|-------------------------------|-------------------------------|---------------------------|--------------------------------------|
| Ensaio | erro<0,005p.u. (%) | 0,005≤ erro <0,015p.u. (%) | 0,015≤ erro ≤0,025p.u. (%) | erro ≤0,025p.u. (%) | Magnitude do maior erro (p.u.) |
| 1 | 41,57 | 13,24 | 17,35 | 72,16 | 0,447 |
| 2 | 43,04 | 22,84 | 7,06 | 72,94 | 0,611 |
| 3 | 42,35 | 19,8 | 11,67 | 73,82 | 0,218 |
| 4 | 47,55 | 17,94 | 10,1 | 75,59 | 0,578 |
| 5 | 34,9 | 24,12 | 16,47 | 75,49 | 0,666 |
| Médias | 41,88 | 19,59 | 12,53 | 74 | 0,504 |

Fase A

Treinamento e Definição da Topologia

Fase B

| Topologia 6-25-15-1 | | | | | |
|---------------------|-----------------------|-------------------------------|-------------------------------|------------------------|-----------------------------------|
| Ensaio | erro<0,005p.u. (%) | 0,005≤ erro <0,015p.u. (%) | 0,015≤ erro ≤0,025p.u. (%) | erro ≤0,025p.u. (%) | Magnitude do maior erro (p.u.) |
| 1 | 42,75 | 24,22 | 9,9 | 76,86 | 0,184 |
| 2 | 45,39 | 20,98 | 14,8 | 81,18 | 0,284 |
| 3 | 47,55 | 13,24 | 15,39 | 76,18 | 0,264 |
| 4 | 40,39 | 25,88 | 14,8 | 81,08 | 0,195 |
| 5 | 45,69 | 17,45 | 13,73 | 76,86 | 0,239 |
| Médias | 44,35 | 20,35 | 13,73 | 78,43 | 0,230 |

Fase C

| Topologia 6-25-15-1 | | | | | |
|---------------------|-----------------------|-------------------------------|-------------------------------|------------------------|-----------------------------------|
| Ensaio | erro<0,005p.u. (%) | 0,005≤ erro <0,015p.u. (%) | 0,015≤ erro ≤0,025p.u. (%) | erro ≤0,025p.u. (%) | Magnitude do maior erro (p.u.) |
| 1 | 51,47 | 24,51 | 10,49 | 86,47 | 0,240 |
| 2 | 57,84 | 18,92 | 9,51 | 86,27 | 0,174 |
| 3 | 46,47 | 26,76 | 11,47 | 84,71 | 0,2 |
| 4 | 47,16 | 26,18 | 13,14 | 86,47 | 0,278 |
| 5 | 60,29 | 18,33 | 9,51 | 88,14 | 0,163 |
| Médias | 52,65 | 22,94 | 10,82 | 86,41 | 0,211 |

Os resultados do treinamento *Backpropagation* levaram ao estudo dos efeitos do algoritmo de *Levenberg-Marquardt*

Treinamento e Definição da Topologia

Etapa 2: Treinamento com o algoritmo *Levenberg-Marquardt*

Critério de parada: Erro Médio Quadrático = 10^{-6} e/ou Máximo de 800 épocas.

Fase A

| Topologia 6-10-5-1 | | | | | |
|--------------------|-------------------------|---------------------------------|---------------------------------|-------------------------|-----------------------------------|
| Ensaio | erro < 0,005p.u. (%) | 0,005 ≤ erro < 0,015p.u. (%) | 0,015 ≤ erro ≤ 0,025p.u. (%) | erro ≤ 0,025p.u. (%) | Magnitude do maior erro (p.u.) |
| 1 | 70,2 | 18,43 | 5,88 | 94,51 | 3,696 |
| 2 | 70,29 | 18,63 | 5,98 | 94,9 | 0,336 |
| 3 | 69,61 | 18,82 | 5,29 | 93,73 | 0,621 |
| 4 | 69,41 | 20,2 | 3,53 | 93,14 | 0,974 |
| 5 | 73,53 | 11,37 | 8,53 | 93,43 | 0,362 |
| Médias | 70,61 | 17,49 | 5,84 | 93,94 | 1,198 |

15



Fase A

| Topologia 6-25-20-1 | | | | | |
|---------------------|-------------------------|---------------------------------|---------------------------------|-------------------------|-----------------------------------|
| Ensaio | erro < 0,005p.u. (%) | 0,005 ≤ erro < 0,015p.u. (%) | 0,015 ≤ erro ≤ 0,025p.u. (%) | erro ≤ 0,025p.u. (%) | Magnitude do maior erro (p.u.) |
| 1 | 80,1 | 12,16 | 1,76 | 94,02 | 0,556 |
| 2 | 80,98 | 9,22 | 3,43 | 93,63 | 4,582 |
| 3 | 77,84 | 9,8 | 5,2 | 92,84 | 1,499 |
| 4 | 82,45 | 8,82 | 2,16 | 93,43 | 0,759 |
| 5 | 81,18 | 9,12 | 3,73 | 94,02 | 0,585 |
| Médias | 81,81 | 8,97 | 2,94 | 93,73 | 0,672 |

40

Treinamento e Definição da Topologia

- Treinamento para as Fase *B* e *C*

Fase *B*

| Topologia 6-25-20-1 | | | | | |
|---------------------|-----------------------|-------------------------------|-------------------------------|------------------------|-----------------------------------|
| Ensaio | erro<0,005p.u. (%) | 0,005≤ erro <0,015p.u. (%) | 0,015≤ erro ≤0,025p.u. (%) | erro ≤0,025p.u. (%) | Magnitude do maior erro (p.u.) |
| 1 | 86,67 | 6,37 | 3,33 | 96,37 | 4,83 |
| 2 | 79,31 | 9,9 | 6,37 | 95,59 | 0,667 |
| 3 | 81,67 | 9,02 | 6,08 | 96,76 | 1,192 |
| 4 | 81,86 | 12,65 | 2,35 | 96,86 | 0,652 |
| 5 | 82,65 | 9,41 | 3,24 | 95,29 | 1,026 |
| Médias | 82,43 | 9,47 | 4,27 | 96,18 | 1,673 |

Fase *C*

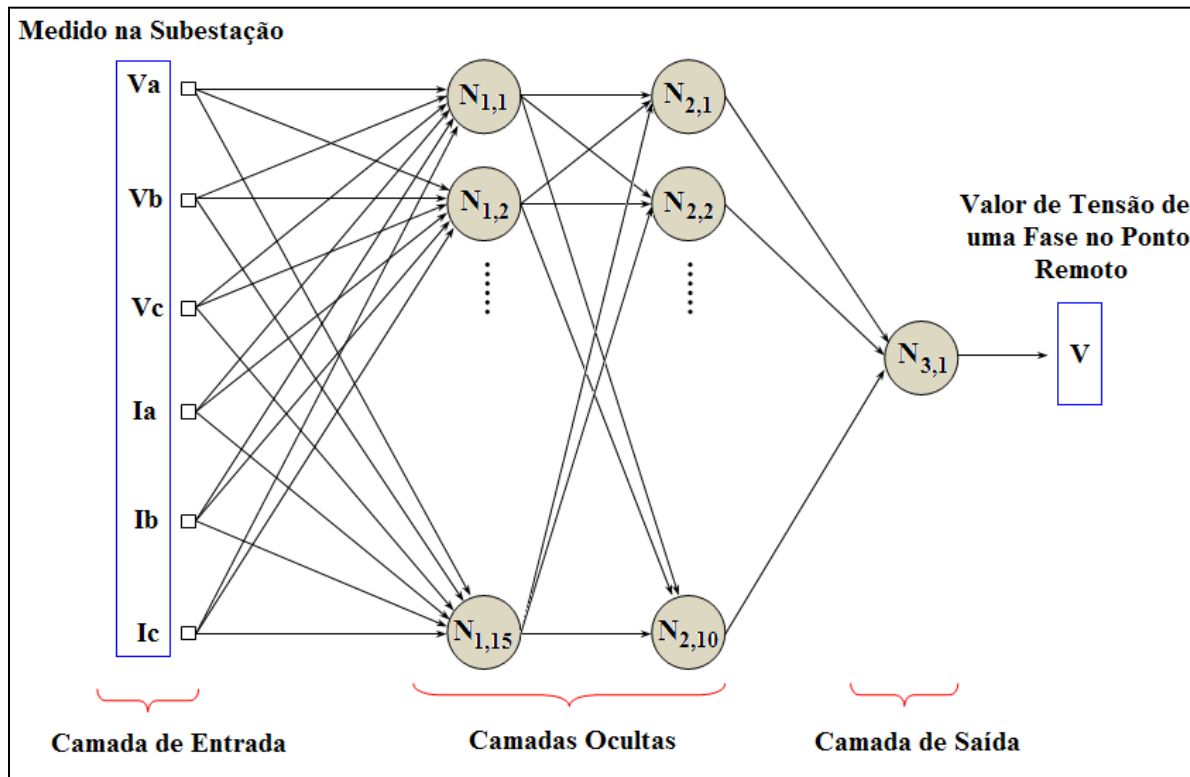
| Topologia 6-25-20-1 | | | | | |
|---------------------|-----------------------|-------------------------------|-------------------------------|------------------------|-----------------------------------|
| Ensaio | erro<0,005p.u. (%) | 0,005≤ erro <0,015p.u. (%) | 0,015≤ erro ≤0,025p.u. (%) | erro ≤0,025p.u. (%) | Magnitude do maior erro (p.u.) |
| 1 | 88,33 | 5,59 | 1,18 | 95,1 | 0,364 |
| 2 | 87,65 | 8,14 | 1,57 | 97,35 | 0,58 |
| 3 | 88,33 | 5,59 | 1,18 | 95,1 | 0,364 |
| 4 | 88,14 | 7,94 | 1,27 | 97,35 | 0,476 |
| 5 | 87,94 | 7,55 | 2,55 | 98,04 | 0,704 |
| Médias | 88,08 | 6,96 | 1,55 | 96,59 | 0,497 |

Treinamento e Definição da Topologia

- Escolha da topologia para as 3 fases

| Arquitetura da RNA | Fase A $e \leq 0,025pu$ (%) | Fase B $e \leq 0,025pu$ (%) | Fase C $e \leq 0,025pu$ (%) |
|--------------------|-----------------------------------|-----------------------------------|-----------------------------------|
| (6-15-10-1) | 93,76 | 96,8 | 96,16 |
| (6-25-20-1) | 93,72 | 96,18 | 96,59 |

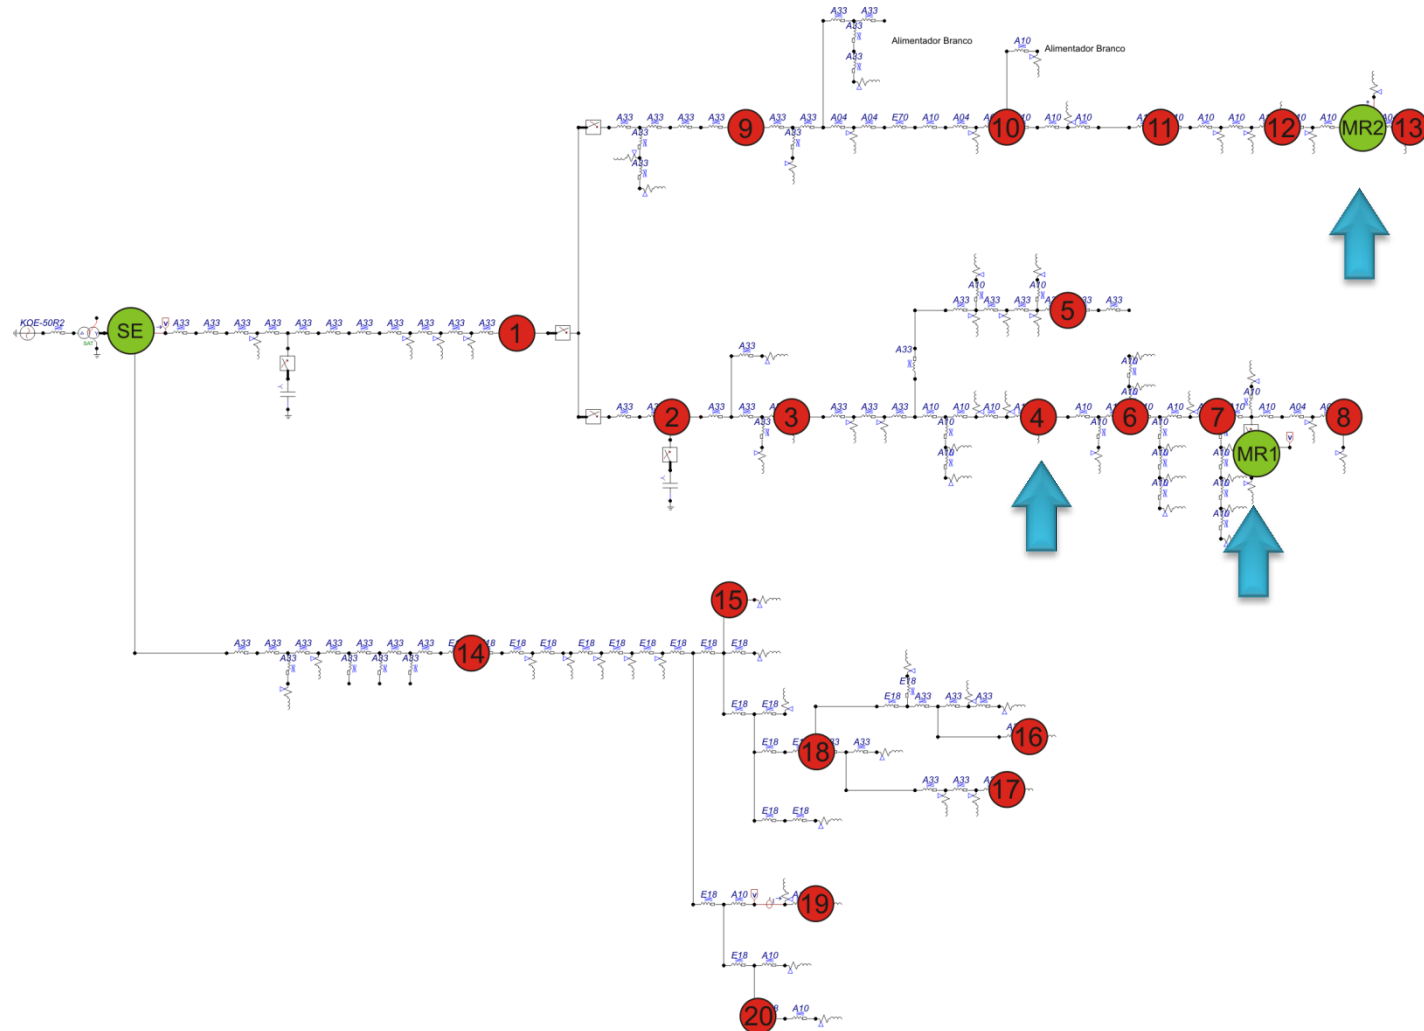
Optou-se pela topologia 6 – 15 – 10 – 1 →
Menor esforço computacional!



Treinamento e Definição da Topologia


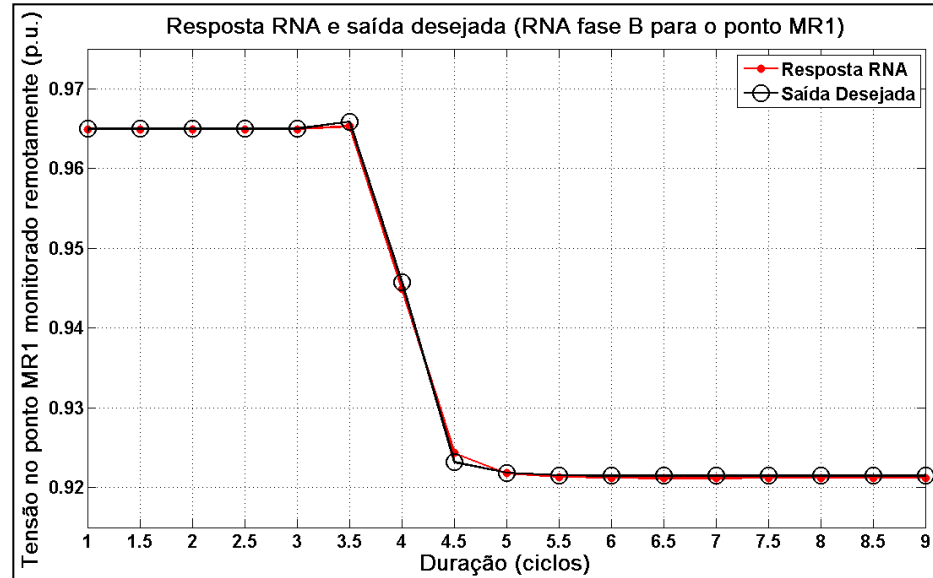
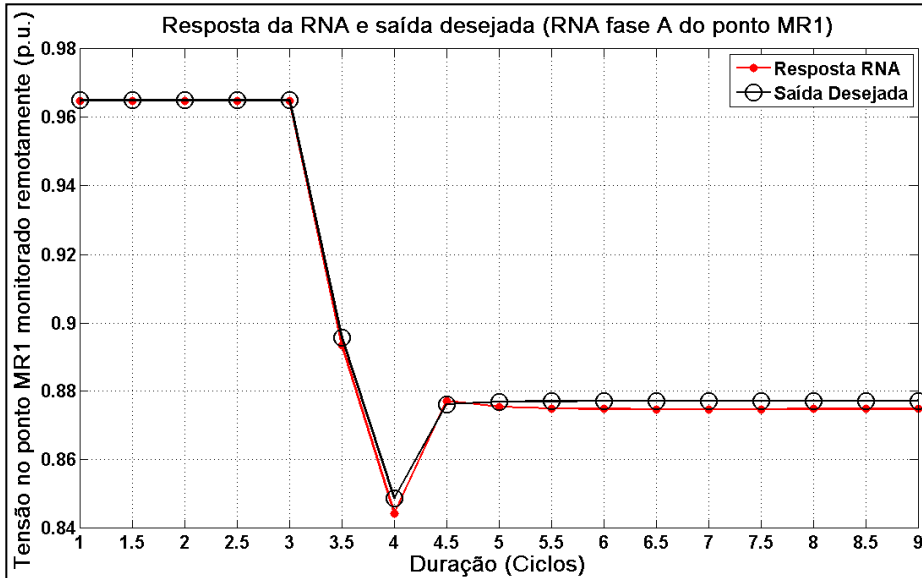
☐ Análise de um caso de falta simulada

- Falta em **4**, com impedância de 30Ω , e ângulo de incidência de falta de 90° ;
- Pontos observados no sistema: **MR1** e **MR2**;





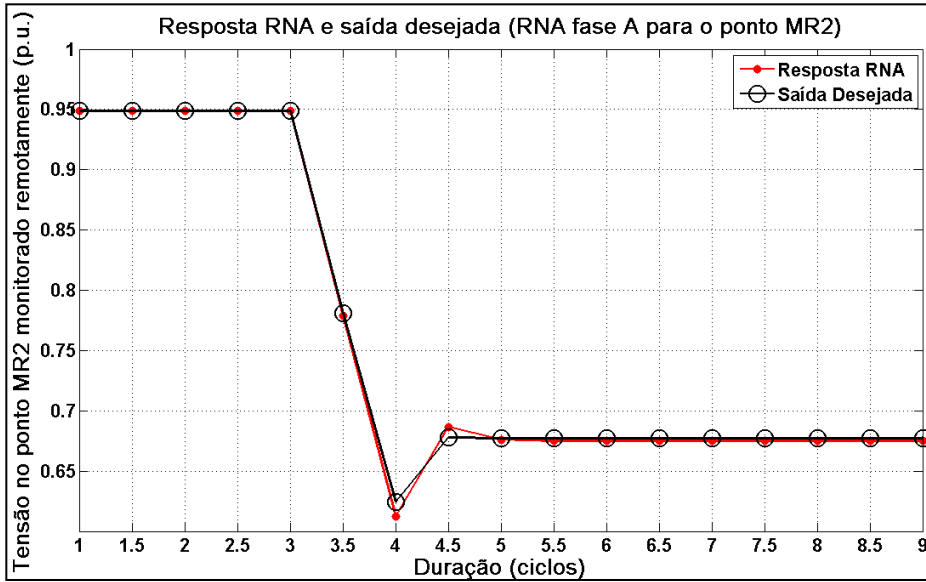
Resultados

MR1 V?



Resultados

MR2 V?



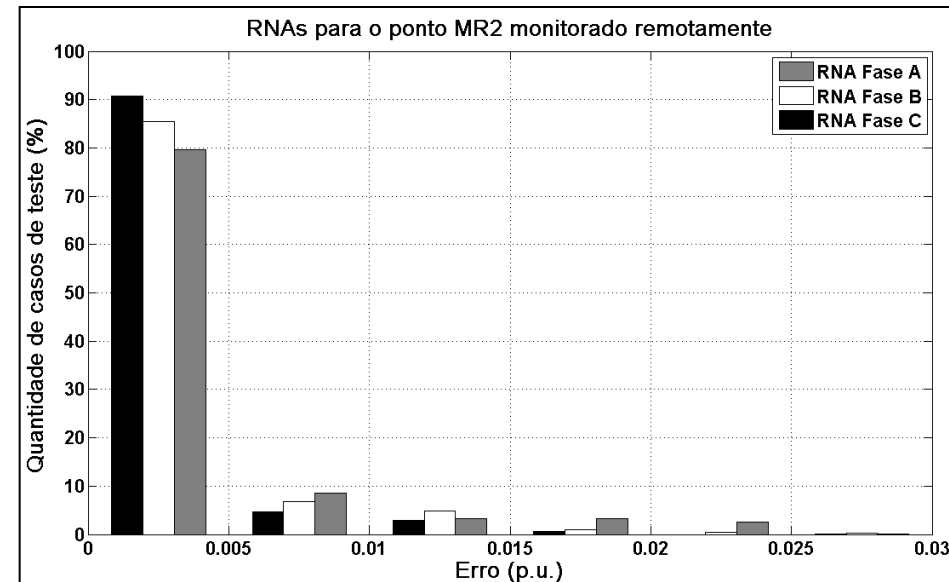

Resultados

- Análise dos Histogramas de erros

- MR1 (<math><0,03\text{p.u.}</math>)
 - Fase A: 98,73%
 - Fase B: 98,82%
 - Fase C: 99,22%

- MR2 (<math><0,03\text{p.u.}</math>)
 - Fase A : 97,35%
 - Fase B : 98,73%
 - Fase C : 99,02%

- Fato Importante!
 - *80% a 90% dos casos de teste situam-se na faixa de erro inferior a 0,005p.u.*



Conclusões

- Elevado índice de acerto das RNA:
 - Em geral, mais de 98% dos casos de teste permaneceram com erros inferiores e/ou iguais a 0,03p.u. (3%), fornecendo indícios da alta fidelidade das medidas fornecidas pelas RNA;
- Logo, foi possível apresentar um método alternativo para se monitorar remotamente as tensões em pontos de interesse do SD a partir de dados coletados na SE;
- Os resultados revelam que as RNA aprenderam o comportamento do SD de maneira a generalizar respostas (tensões trifásicas monitoradas);
- Apresenta-se como uma técnica complementar que pode ser utilizada juntamente com medidores físicos de QEE;

Publicações e Continuação da Pesquisa.

- Divulgação dos primeiros resultados
 - BOTTURA, F. B. Um método alternativo e inteligente para o monitoramento remoto das variações de tensão de curta duração em um sistema de distribuição de energia elétrica. Trabalho de Conclusão de Curso (Engenharia Elétrica) – EESC, USP. São Carlos, 2010.
 - BOTTURA, F. B. ; BRANCO, H. M. G. C. ; OLESKOVICZ, M. . Avaliação e Monitoramento das Variações de Tensão ao Longo de um Sistema de Distribuição de Energia Elétrica Empregando Redes Neurais Artificiais. In: IX Conferência Brasileira sobre Qualidade da Energia Elétrica - CBQEE, 2011, Cuiabá - MT. IX Conferência Brasileira sobre Qualidade da Energia Elétrica - CBQEE, 2011.
- TCC – Fabrício Silva Pires de Camargo (2012)
 - Generalização de uma topologia de RNA para quaisquer pontos MR;
 - Sistematização da metodologia para ser aplicada em qualquer SD.
- CAMARGO, F. S. P. Uma estimação alternativa, remota e continuada das variações de tensão em um sistema de distribuição utilizando redes neurais artificiais. Trabalho de Conclusão de Curso (Engenharia Elétrica) – EESC, USP. São Carlos, 2012.
- BOTTURA, F. B. ; CAMARGO, F. S. P. ; OLESKOVICZ, M. ; SANTOS, R. C. . Monitoramento remoto do perfil da tensão eficaz em cargas dispostas em um sistema de distribuição utilizando redes neurais artificiais. In: X Conferência Brasileira sobre Qualidade da Energia Elétrica - X CBQEE, 2013, Araxá. X Conferência Brasileira sobre Qualidade da Energia Elétrica - X CBQEE, 2013.

Publicações e Continuação da Pesquisa.

- TCC – Daniel Ferreira Lima (2014)
 - Atualização do banco de dados para os 11 tipos de faltas;
 - Aplicação da metodologia sistematizada por Camargo (2012);
 - Definição de uma nova topologia de RNA para atender os novos casos de falta;
 - Estudo preliminar da influência das posições de faltas simuladas
 - Mais recentemente novos resultados sobre o treinamento e formação do banco de dados.
 - Em submissão ao IEEE Power & Energy Society General Meeting 2016, Boston, EUA.
- LIMA, D. F.; O monitoramento remoto da tensão trifásica frente às situações de curto-circuito em um sistema de distribuição via redes neurais artificiais. Trabalho de Conclusão de Curso (Engenharia Elétrica) – EESC, USP. São Carlos, 2014.
- LIMA, D. F. ; BOTTURA, F. B. ; OLESKOVICZ, M. . Redes PMC aplicadas ao monitoramento remoto da tensão trifásica frente às situações de curtos-circuitos em um sistema de distribuição. In: XI Conferência Brasileira sobre Qualidade da Energia Elétrica - CBQEE, 2015, Campina Grande. XI Conferência Brasileira sobre Qualidade da Energia Elétrica - CBQEE, 2015.

Um Método Alternativo e Inteligente para o Monitoramento Remoto das Variações de Tensão de Curta Duração em um Sistema de Distribuição de Energia

Obrigado pela Atenção!

Fernando B. Bottura

[fernando.bottura@usp.br]