

ÍNDICE

1. Introdução	1
2. Parte Teórica	1
3. Técnicas quantitativas de previsão	3
Séries Temporais	3
Decomposição	3
Modelo de média móvel.....	4
Modelo de Suavizamento Exponencial.....	4
Resumo dos pontos fortes e fracos	5
Medidas de precisão do modelo.....	6
Erro médio (viés).....	6
Erro absoluto médio.....	7
Erro absoluto médio percentual	7
Tracking Signal	7
Seleção das medidas de precisão do modelo	8
Cálculo das quantidades enviadas	8
Estudo de caso Perrin Frères	8
MODELOS CAUSAIS	9
EXERCÍCIO: A FUNÇÃO DEMANDA DO TRANSPORTE AÉREO NO BRASIL.	9
4.2. Elasticidade cruzada da demanda.....	12
4. ÁRVORE METODOLÓGICA.....	12
Escolha da Técnica de Previsão.....	19

1. Introdução

O objetivo deste trabalho é mostrar os principais pontos teóricos e práticos na previsão de demanda.

2. Parte Teórica

Basicamente, existem duas famílias de métodos de previsão: quantitativo e qualitativo. O método quantitativo se preocupa basicamente em ajustar um modelo formalizado de previsão aos dados históricos da empresa, de forma a projetar as vendas futuras. O método qualitativo preocupa-se em chegar a uma previsão de vendas a partir de julgamentos pessoais e subjetivos de quem esteja fazendo a previsão.

O esquema a seguir mostra a divisão das técnicas de previsão:

Quando da realização de previsões para séries temporais onde encontramos os fatores de tendência, ciclicidade e sazonalidade agregados a série, deve-se utilizar a técnica da decomposição destes fatores para podermos realizar um estudo diferenciado em cada um deles, podendo utilizar a regressão para prever a tendência e sobre esta previsão, utilizar os índices sazonais que capturaram a sazonalidade e ciclicidade da série.

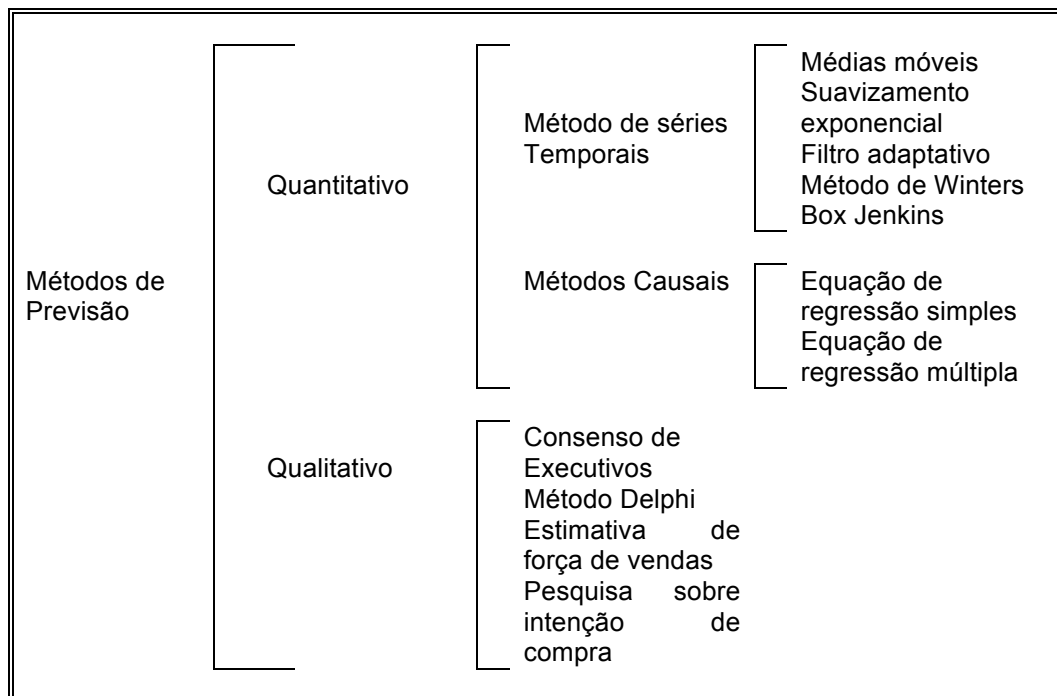
A decomposição tradicional de séries temporais assume quatro componentes: Tendência, Sazonalidade, Ciclicidade e Distúrbio.

Para capturarmos a tendência e a ciclicidade de uma série temporal é necessário a utilização de um suavizamento através da média móvel.

Uma maneira de modificar a influencia dos dados passados é decidir o quão longínqua estarão as observações que serão inclusas para o cálculo da média. O termo média móvel é usado para descrever este procedimento porque a cada nova observação, uma nova média é computada, desprezando a mais velha observação e incluindo a mais recente. Esta média móvel será então a previsão para o próximo período. Notando que o número de dados em cada cálculo da média permanece constante e inclui a mais recente informação.

Existe ainda a necessidade da centralização das médias para períodos pares, que nada mais é que o cálculo da média de dois pontos consecutivos para cada ponto calculado.

O suavizamento da série permite a visualização da tendência pois transforma uma série “nervosa” em uma curva amena, sem grande picos.



A captura da tendência é feita pela obtenção das médias dos índices sazonais dos períodos em questão. Esta média permite ainda que se possa isolar a variação sazonal.

A aplicação de tais conceitos poderá ser explicada mais detalhadamente no decorrer do trabalho.

3. Técnicas quantitativas de previsão

As técnicas quantitativas de previsão podem ser divididas em duas categorias: as séries temporais e os modelos causais. A principal diferença está nas premissas dos modelos: os modelos causais procuram relações do tipo “causa e efeito” para explicar o comportamento da variável. Já as séries temporais se baseiam na hipótese de que o futuro será uma continuação ou repetição do passado.

Séries Temporais

As séries temporais tratam a previsão como uma caixa preta, não considerando fatores externos, mas somente o padrão existente nos dados históricos.

Decomposição

Os métodos de suavizamento não se preocupam em dividir os diferentes componentes dos dados, isolando cada um deles. Já os modelos de decomposição procuram aumentar a precisão e o entendimento da demanda através da identificação e separação de cada componente da demanda. Os três principais componentes são: tendência, sazonalidade e ciclicidade, além da aleatoriedade.

A sazonalidade existe quando ocorrem flutuações na demanda, de acordo com um padrão relativamente constante de período para período, apresentando picos e vales de demanda sempre nos mesmos períodos.

A diferença entre ciclicidade e sazonalidade é que esta última se repete em períodos relativamente constantes (ano, mês, semana) enquanto a ciclicidade tem durações mais longas que variam de ciclo a ciclo e está em geral ligada a ciclos econômicos.

A tendência está presente quando existem aumentos ou decréscimos consecutivos na demanda. Isso ocorre em geral quando um mercado está em expansão, um produto é lançado, está substituindo outro ou quando uma empresa está conquistando participação de mercado e nos casos inversos.

Existem várias abordagens para a decomposição. O conceito básico de separação dos componentes é empírico e consiste em:

- Primeiro remover a sazonalidade;
- Depois a tendência;
- E finalmente o ciclo.

Na literatura são descritas duas classes de modelos de decomposição: uma aditiva, na qual os componentes são somados e outra multiplicativa em que eles são multiplicados. Veja a equação (1) – Modelo de Decomposição Aditivo e a equação (2) – Modelo de Decomposição Multiplicativo, onde:

- X_t é a demanda no instante t
- I_t é o componente de sazonalidade no instante t
- T_t é o componente de tendência no instante t
- C_t é o componente de ciclicidade no instante t
- E_t é o componente de aleatoriedade no instante t

$$X_t = I_t + T_t + C_t + E_t \quad (1)$$

$$X_t = I_t * T_t * C_t * E_t \quad (2)$$

Ponto Forte

- A lógica de dividir os dados em tendência, ciclicidade, sazonalidade e aleatoriedade tem um grande apelo intuitivo, o que facilita sua validação e entendimento junto aos usuários

Ponto Fraco

- O componente cíclico é de difícil determinação e previsão

Modelo de média móvel

Os modelos de média móvel são úteis nas previsões de curto prazo para diversos itens devido à sua simplicidade e baixo custo. É indicado para produtos com um histórico de pequenas flutuações. Como pode ser visto na equação (3), quanto maior o número de períodos considerados, maior será o suavizamento, ou seja, menor será o peso de cada período. Com isso, as variações bruscas são suavizadas.

$$P_t = \frac{D_{t-1} + D_{t-2} + D_{t-3} + \dots + D_{t-n}}{n} \quad (3)$$

O problema apontado no modelo de média móvel é quando existe uma tendência nas vendas. Isso é facilmente entendido quando visualizamos o gráfico de vendas e notamos que a tendência para o próximo mês é de aumento e a previsão é feita com base nos dados dos meses anteriores, que são mais baixos. É como se a previsão estivesse sempre “correndo atrás da demanda”.

Pontos fortes

- Adequado para quando existe um grande número de itens para prever
- Adequado para itens com demanda estável
- Suavizam variações aleatórias

Pontos fracos

- Requerem um grande histórico
- Tem resposta lenta para variações na demanda

Modelo de Suavizamento Exponencial

Existem vários modelos de suavizamento exponencial. O mais popular deles é o Modelo de Winter, que considera variações relacionadas à tendência e a sazonalidade. Sua formulação básica está apresentada da equação (4) até a equação (8).

$$B_t = a * \left(\frac{D_t}{I_{t-L}} \right) + (1-a) * (B_{t-1} + T_{t-1}) \quad (4)$$

$$T_t = b * (B_t - B_{t-1}) + (1-b) * T_{t-1} \quad (5)$$

$$I_t = g * \left(\frac{D_t}{B_t} \right) + (1-g) * I_{t-L} \quad (6)$$

$$P_t = (B_{t-1} + T_{t-1}) * I_{t-L} \quad (7)$$

$$P_{t+m} = (B_t + T_t * m) * I_{t-L+m} \quad (8)$$

B_t = valor da base no instante t

L = número de períodos em que a sazonalidade se repete. Por exemplo, L será 12 se a previsão for mensal e a sazonalidade anual.

a = constante de suavizamento

b = constante de suavizamento da tendência

g = constante de suavizamento da sazonalidade

I_t = índice de sazonalidade no instante t

T_t = índice da tendência no instante t

D_t = valor realizado no instante t

P_t = previsão para o instante t

m = períodos de previsão. Se o tamanho do período for um mês e m for 3, então está se fazendo uma previsão para daqui a 3 meses.

A determinação das constantes pode ser feita utilizando métodos não-lineares de otimização. Uma outra forma para o ajuste das constantes é fazer-lo por políticas. Se a demanda daquele item tem um comportamento estável, assume-se a pequeno (entre 0,05 e 0,15), para evitar que variações aleatórias afetem as previsões.

Já se sua demanda não tem um comportamento muito estável, em geral aumenta-se a (entre 0,15 e 0,30), para que a previsão acompanhe as mudanças na demanda. O mesmo tipo de análise deve ser feita para determinar b e g .

Em geral, é desaconselhada a utilização de valores de a grandes (maior que 0,5), pois isso pode tornar o modelo muito reativo, ou seja, toda variação da demanda é incorporada à previsão. Isso ocorre, uma vez que o valor de a multiplica diretamente o valor da última demanda.

Pontos fortes

- fácil de entender e usar
- distribui a importância dos dados ao longo do tempo
- visa a eliminação de flutuações aleatórias e isola a média e a tendência
- necessita do armazenamento de apenas 2 dados históricos de demanda. Isso é uma vantagem em especial quando existe a necessidade de prever uma quantidade muito grande de produtos
- boa relação de custo benefício nas situações de muitos itens

Pontos fracos

- fraco resultado para previsões de médio e longo prazo
- previsões podem ter grandes erros devido a variações aleatórias nos dados recentes

Resumo dos pontos fortes e fracos

Técnica	Pontos Fortes	Pontos Fracos
Decomposição	Lógica intuitiva facilita sua validação e seu entendimento junto aos usuários	O componente cíclico é de difícil determinação

Média Móvel	Adequado quando existe um grande número de itens para prever Adequado para itens com demanda estável Suavizam variações aleatórias	Requerem um grande histórico Tem resposta lenta para variações na demanda
Suavizamento Exponencial	Fácil de entender e de usar Visa a eliminação de flutuações aleatórias e isola a média e a tendência Necessita do armazenamento de apenas 2 dados históricos de demanda Boa relação de custo benefício nas situações de muitos itens	Fraco resultado para previsões de médio e longo prazo Previsões podem ter grandes erros devido a variações aleatórias nos dados recentes

Medidas de precisão do modelo

As medidas de precisão da previsão são úteis no processo de seleção de modelos e no seu monitoramento. De acordo com KRESS; SNYDER (1994), uma boa medida de precisão deve atender para:

- facilidade de entendimento
- uma unidade que possibilite comparação das várias previsões, como, por exemplo, os erros percentuais
- ponderação que se dá ao erro de previsão de cada período, num sentido de análise de evolução

As diferentes medidas de precisão têm como base o Erro, que é definido como a diferença entre a demanda real e a previsão:

$$e_i = y_i - \hat{y}_i = D_i - P_i \quad (9)$$

A grande dificuldade para mensurar a precisão da previsão está na escolha da medida, já que não existe uma medida padronizada. A seguir, exploraremos as medidas de precisão mais comuns.

Erro médio (viés)

A medida de viés busca identificar distorções no modelo de previsão, que geram previsões sistematicamente maiores que a demanda real ou sistematicamente menores. Ou, em outras palavras, a medida de viés visa identificar ocasiões em que as previsões foram sistematicamente otimistas ou pessimistas.

$$E_M = \frac{\sum_{i=1}^n e_i}{n} \quad (10)$$

Uma previsão pode ser considerada como livre de viés se o erro médio for próximo de zero.

O cuidado que deve ser tomado com essa medida é o de evitar que n seja muito grande, pois isso poderia causar a perda de sensibilidade do indicador.

Erro absoluto médio

O erro absoluto médio avalia qual a magnitude dos erros que estão sendo cometidos. Diferente da medida do viés, o E_{AM} não considera a direção do erro, mas apenas sua magnitude.

$$E_{AM} = \frac{\sum_{i=1}^n |e_i|}{n} \quad (11)$$

Erro absoluto médio percentual

O erro absoluto médio percentual proporciona uma medida da magnitude do erro assim como o E_{AM} . Além disso, tem a grande vantagem de ser uma medida relativa possibilitando a comparação da precisão entre dois itens diferentes.

$$E_{AMP} = \frac{E_{AM}}{\frac{\sum_{i=1}^n D_i}{n}} \quad (12)$$

Tracking Signal

O viés existe quando a demanda acumulada difere da previsão acumulada. A questão é saber distinguir se essa diferença é devida a aleatoriedade da demanda ou se existe viés na previsão.

Embora existam vários tipos de Tracking Signal, o mais usado deles é o representado pela equação abaixo.

$$\text{Tracking Signal} = \frac{n * E_M}{E_{AM}} \quad (13)$$

Na tabela abaixo, os erros apresentados são comparados com relação a sua facilidade de entendimento, unidade de medida e tipo de erro avaliado.

Medida	Facilidade de entendimento	Unidade de medida	Tipo de erro

Erro médio	Fácil	Unidades	Viés
Erro absoluto médio	Intermediário	Unidades	Magnitude
Erro absoluto médio percentual	Intermediário	Porcentagem	Magnitude
Tracking Signal	Difícil	Adimensional	Viés e Magnitude

Seleção das medidas de precisão do modelo

No sistema de suprimentos, precisamos de medidas de precisão que sejam fáceis de entender, que meçam o viés e a magnitude dos erros e que permitam comparações entre as precisões de várias previsões. Por isso, decidimos usar como medidas o Erro Médio, o Erro Absoluto Médio e o Erro Absoluto Médio Percentual, calculando-os todo mês utilizando os erros dos doze meses anteriores (n=12). O Tracking Signal foi descartado por ser uma medida de difícil análise.

Cálculo das quantidades enviadas

De posse das previsões de demanda podemos realizar os cálculos dos momentos de entrega e de lote econômico. Quando analistas de suprimentos precisam se decidir a respeito da quantidade de materiais a ser enviadas em sistemas de lote padrão, não há uma fórmula única que se aplique a todas as situações. Cada situação exige uma análise baseada nas características desse sistema de estoque em particular. Aqui, desenvolvemos estimativas das quantidades ótimas de entrega para dois modelos de estoque: Modelo I – lote econômico de entrega (LEE), Modelo II – LEE com perdas (LEEP) e Modelo III – LEEP com custo de entrega variável (LEEPCEV).

Estudo de caso Perrin Frères

Com o objetivo de atender a administração da empresa e aos requisitos do banco ao qual a companhia utilizava, no final do outono de 1972, a fábrica de champanhe de Perrin Freres estava preparando o seu plano financeiro para o ano seguinte. Devido a alta sazonalidade da demanda de champanhe, a maioria das fábricas recorrem a bancos para financiar suas necessidades de capital de giro. Por motivo das recentes dificuldades financeiras, as quais outras empresas do setor enfrentam, o banco requisitou uma série de relatórios antes de aprovar o empréstimo da Perrin Freres para o próximo ano.

Para elaboração dos referidos relatórios, existe a necessidade de previsão dos gastos mensais de operações financeiras e o atraso nestes recebimentos. Uma boa aproximação para tais cálculos, seria obter a previsão mensal da indústria e então aplicar as divisões de mercado da empresa, para determinar o nível de vendas que se poderia esperar alcançar.

Esta aproximação tem um benefício adicional, pois além de ajudar a encontrar as necessidades requeridas pelo banco, poderá ser utilizada como base para algumas outras atividades.

Foi então requisitado a previsão de vendas mensais de champanhe francesa. Conseguiu-se apenas um histórico das vendas como mostrado na tabela abaixo.

Mês	Ano								
	1964	1965	1966	1967	1968	1969	1970	1971	1972
Jan	2815	2541	3113	3375	3633	4016	2639	3934	4348
Fev	1672	2473	3006	3088	4292	3957	2899	3162	3564
Mar	2753	3031	4047	3718	4154	4510	3328	4286	4577
Abr	2722	3255	3523	4514	4124	4276	3740	4876	4733
Mai	2946	3776	3937	4530	4647	4959	2929	5020	5312
Jun	3036	3230	3988	4539	4755	4677	3986	4852	4298
Jul	2282	3028	3260	3663	3965	3523	4217	4632	1431
Ago	2212	1759	1573	4643	1723	1821	1733	1639	
Set	2922	3595	3529	4739	5048	5222	5221	5931	
Out	4301	4474	5211	5425	6922	6872	6424	6981	
Nov	5764	6838	7914	8314	9858	10803	9842	9585	
Dez	7312	8357	9254	10651	11331	13916	13075	12578	

Bibliografia

Wonnacott, T. H., Introductory Statistics for Business and Economics – 4th. Edition.
Makridakis, S. , Forecasting : Methods and Applications – 2th. Edition.

MODELOS CAUSAIS

EXERCÍCIO: A FUNÇÃO DEMANDA DO TRANSPORTE AÉREO NO BRASIL.

Faremos um exercício para mostrar a importância da pesquisa sobre preços pelo lado da demanda (consumidor ou B2B, B2C etc) (*). Como já ressaltamos anteriormente, para simplificação da análise muitas vezes considera-se apenas o preço como variável explicativa da quantidade demandada, sabendo-se que a demanda por um produto ou serviço é uma função multivariada; i.e. outras variáveis afetam a quantidade demandada - qualidade, gostos, hábitos, sazonalidade etc. Este tema será o objeto do capítulo 6 – Estratégia de Preços e Marketing.

Ponto importante a considerar é que a Demanda é uma variável que “antecipa”, que “antevê” qual seria a quantidade demandada frente a uma variação de preços.

Consideremos a quantidade de passageiros transportados pela modalidade aérea, no Brasil, entre 1995 e 2002. Consideremos como preço de cada ano (preço médio de um ano), como sendo o faturamento de todas as empresas de transporte aeroviário divididas pela quantidade transportada, e transformada em moeda constante do período (Base =1995). Os dois conjuntos de dados são apresentados na tabela a seguir:

ano=>	1995	1996	1997	1998	1999	2000	2001	2002
Preço médio [R\$/passageiro]	227	231	200	185	201	190	183	160
Passageiros Transportados	18.860	19.084	20.970	23.499	21.773	22.054	28.065	25.850

Fonte?

Observe-se que a quantidade de passageiros transportados (consumo) é temporalmente “passada”. No linguajar da economia é “ex post”. Trata-se do consumo real verificado naquele período.

A construção de uma função demanda, portanto, só poderia ser uma “estimação” de como preços afetariam a quantidade demandada. No linguajar adequado seria “ex ante”. Portanto a Função Demanda que iremos construir com os dados da tabela acima será uma estimativa (uma *proxy*), usando os dados passados de consumo (transporte de passageiros entre 1995 e 2002).

Para se construir graficamente a Função Demanda, são necessários os seguintes passos:


- 1.) “Classificar” a quantidade de passageiros transportados (da quantidade menor para a maior).
- 2.) Fazer o Gráfico Preço x Quantidade, omitindo os anos. Este é um exemplo de “cross section” (Makridakis (XXXX)).
- 3.) Achar a linha de tendência (Por exemplo, usar uma função linear). Esta função estimada será considerada a Função Demanda de transporte aéreo no Brasil no período de 1995 e 2002, considerando um modelo linear de estimação.

Para se calcular a elasticidade-preço da demanda, será necessário, ainda:

- 4.) Reconstruir os dados, usando agora a equação da reta obtida (A Função Demanda).
- 5.) Calcular a elasticidade-preço da demanda no arco, como segue:

$$e = [(Q2 - Q1)/(Q2+Q1)/2] / \{(P2 - P1)/(P1+P2)/2\}$$

Apresentamos abaixo o gráfico obtido com preço x quantidade da tabela acima:



Com a utilização da regra (4) acima, e da utilização de um modelo linear se obtém (matematicamente) a seguinte Função Demanda:

$$P = 337,48 - 0,0062 \cdot Q$$

ou

$$Q = 54.432 - 161,3 \cdot P$$

Observe-se que é uma função biunívoca, pois preço “explica” a quantidade, e a quantidade “explica” o preço.

E, fazendo o cálculo da elasticidade-preço da demanda no arco, tem-se:

$$e = -1,32$$

A elasticidade-preço da demanda de transporte aéreo no Brasil é um número adimensional, razoavelmente superior à unidade, cuja interpretação econômica é a de que para cada 1 % de queda de preço a quantidade aumenta em 1,32 %.

Vamos interpretar estes resultados:

Imagine-se que queira se instalar no mercado brasileiro mais uma empresa (ofertante) de transporte aéreo. Isto significará que haverá um deslocamento da curva de oferta para a direita. Portanto, o mercado admitirá “comprar” mais transporte aéreo se houver diminuição de preços. Se houver uma diminuição de 1% no preço (~ R\$ 1,60), haverá um aumento de aproximadamente 1,32 % de passageiros transportados (~ 400 mil/ano).

Imagine-se a importância estratégica de tal informação. Uma empresa poderia competir neste mercado, baixando o preço em apenas R\$ 1,60, e vendendo aproximadamente 400 mil viagens a mais.

Claro que a Função Demanda aqui construída pode estar muito agregada, o que exigiria uma maior segmentação para verificar com mais detalhe quais “mercados” poderiam ser analisados: ponte aérea Rio/Sp, longa distância, transporte regional etc., o que daria a visão dos “negócios”, acima apontada.

Outro ponto importante que devemos destacar, e que será à frente aprofundado, é sobre a forma da receita de uma firma quando o preço (constante) não é dado pelo mercado (equilíbrio entre oferta e demanda), e sim dado somente pela função demanda [Preço = f (Quantidade)]. Neste caso, a forma da curva de receita (Gráfico XXX) seria uma função não linear. Isto é importante, porque muitas das firmas têm algum grau de monopólio, isto é, podem aumentar vendas, diminuindo seus preços. Daí a importância

também da estimação da função demanda, pois esta informação possibilitará construir o gráfico de ponto de equilíbrio quando a firma pode produzir mais diminuindo seus preços, o que pode em algumas situações, aumentar o lucro total.

4.2. Elasticidade cruzada da demanda

Dados os valores de preço x quantidade (transporte aéreo, calcular elasticidade-preço da demanda (aéreo) em cada ponto, e no arco. e calcular a elasticidade-preço demanda cruzada (dados a quantidade de transporte aéreo e preço do modal rodoviário)

Tire conclusões sobre um possível aumento da **Oferta** (Quantidade x preços) de transporte aéreo

	Aéreo	Rodo
Q	P a	P r
18860	221	110
19084	219	120
20970	207	160
21773	202	175
22054	201	180
23499	192	200
25850	177	220
28065	163	240

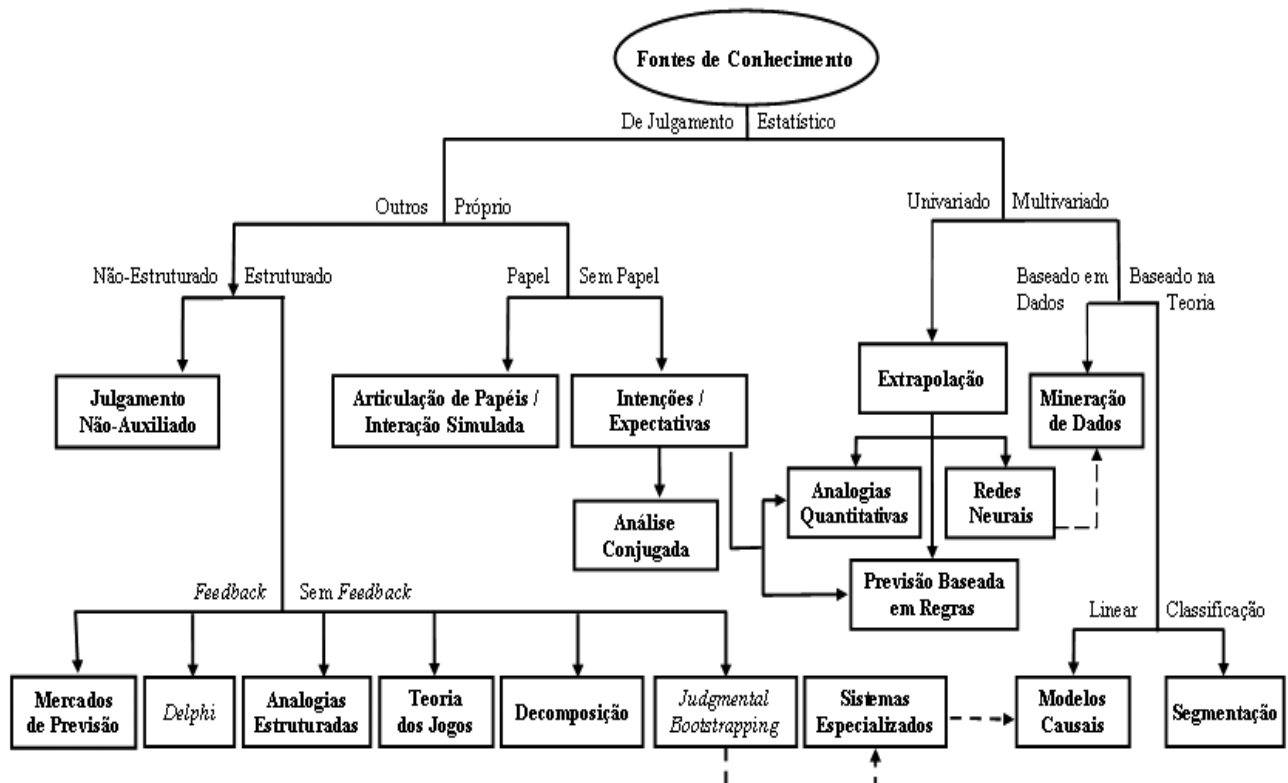
4. ÁRVORE METODOLÓGICA

Armstrong apresenta uma forma prática de se escolher a melhor técnica de previsão a ser utilizada. Conforme se caminha ao longo deste diagrama, respondendo a simples perguntas contidas nos balões, vai se chegando a uma das categorias de métodos apresentadas na “Árvore de Metodologia”.

Armstrong J. Principles of forecasting: A Handbook for researchers and practitioners. Boston. Kluger Academic Publishers. 2001

Os Níveis

De acordo com o nível em que cada ramificação da “Árvore Metodológica” ocorra, têm-se as seguintes divisões de acordo com as características de cada categoria de métodos de previsão, seguidas das respectivas descrições:



re, têm-se as seguintes divisões de acordo com as características de cada categoria de métodos de previsão, seguidas das respectivas descrições:

- **Primeiro Nível**

- **Estatístico**

- Aplicável quando dados numéricos relevantes estão disponíveis.

- **De Julgamento**

- Aplicável quando os dados disponíveis são inadequados para análises quantitativas ou informações qualitativas tendem a aumentar a precisão, relevância ou aceitabilidade das previsões.

- **Segundo Nível**

- **Próprio**

- Divisão relacionada a intenções ou expectativas que as pessoas têm sobre seus comportamentos, sendo ambas úteis quando (a) pode-se obter respostas de uma amostra representativa, (b) as respostas obtidas são baseadas em bons conhecimentos, (c) não há razões para se mentir, (d) novas informações não tendem a modificar o comportamento. As intenções são mais limitadas do que as expectativas, sendo mais úteis quando (e) o evento é importante, (f) o comportamento é planejado, (g) o respondente

pode cumprir o planejado de forma independente (sem depender de acordos com outras pessoas, por exemplo).

- **Outros**

Ramificação relacionada à existência de conhecimento sobre o comportamento esperado de outras pessoas ou de organizações.

- **Univariado**

Aplicável quando dados históricos sobre o comportamento a ser previsto estão disponíveis. !

- **Multivariado**

Aplicável quando dados sobre as variáveis que devem afetar o comportamento a ser previsto estão disponíveis.

- **Terceiro Nível**

- **Não-Estruturado**

Aplicável quando a informação é utilizada de maneira informal.

- **Estruturado**

Aplicável quando métodos formais são utilizados para analisar a informação. Regras de análise são pré-determinadas e então seguidas rigorosamente.

- **Papel**

Relacionada a representações de papéis por pessoas que interagem entre si, defendendo diferentes posições. A adoção dos métodos sob esta divisão pressupõe o conhecimento sobre o papel representado.

- **Sem Papel**

Aplicável quando a interação entre diferentes pontos de vista não tende a influenciar o comportamento das pessoas, ou quando o conhecimento sobre os papéis influentes não está disponível, ou quando há muitos atores defendendo diferentes papéis (pontos de vista).

- **Baseado em Dados**

Relacionada à indisponibilidade de experiência ou de teorias aplicáveis, devendo-se tentar inferir relações através dos dados.

- **Baseado em Teoria**

Aplicável quando conhecimentos teóricos e experiência oferecem informações úteis sobre relacionamentos relevantes para a previsão.

- **Quarto Nível**

- **Feedback**

Relacionada aos métodos que fazem uso de procedimentos formais para solicitar, ponderar e combinar previsões feitas por pessoas. Estes

procedimentos devem ser desenvolvidos prioritariamente para a obtenção de previsões, devendo ser rigorosamente seguidos.

- **Sem Feedback**

Diz respeito aos métodos que fazem uso de procedimentos formais para auxiliar as pessoas a reter e organizar informações sobre a situação de previsão. Estas informações são então analisadas seguindo regras pré-estabelecidas.

- **Linear**

Aplicável quando o problema pode ser modelado por parâmetros lineares.

- **Classificação**

Útil quando a situação de previsão sofre influências de diversos grupos que agem em diferentes direções em resposta a uma mudança.

As Categorias

Conforme se pode observar na “Árvore de Metodologias”, o corpo de conhecimentos sobre métodos de previsão sofre ramificações segundo as divisões descritas anteriormente, originando categorias. Cada categoria engloba um ou mais tipos de métodos de previsão, que possuem características em comum. A seguir, são apresentadas descrições generalizadas de cada categoria, de acordo com as suas propriedades oriundas das divisões da árvore:

Articulação de Papéis / Interação Simulada

> De Julgamento > Próprio > Papel

Na articulação de papéis, pessoas são escolhidas para pensar de forma consistente ao papel e à situação descritos a elas. Se há interações entre estas pessoas, cada uma representando um diferente papel, com a intenção de se prever o comportamento dos protagonistas reais, tem-se a interação simulada. Ou seja, as pessoas atuam em interações prospectivas de uma maneira realista. Dessa forma, as decisões tomadas pelos articuladores de papéis são utilizadas como previsões das decisões reais.

Intenções / Expectativas

> De Julgamento > Próprio > Sem Papel

Os métodos de previsão desta categoria buscam estruturar entrevistas com pessoas para obter destas suas intenções ou expectativas sobre comportamentos futuros, próprios ou da companhia à qual pertencem. Os dados coletados através destas pesquisas são então analisados para que previsões sejam geradas.

Análise Conjugada

> De Julgamento > Próprio > Sem Papel

Os métodos baseados em análise conjugada obtêm informações relativas às preferências de consumidores ou de outros atores sobre uma dada situação (um novo produto, por exemplo), utilizando combinações de características (como a relação entre

consumo e potência de um veículo) e pedindo-se às pessoas que considerem relações de troca entre aspectos conflitantes. Então, análises de regressão são utilizadas para se prever as características desejadas para o objeto em estudo.

Analogias Quantitativas

> *De Julgamento* > *Próprio* > *Sem Papel*
> *Estatístico* > *Univariado*

As analogias quantitativas partem da identificação, por parte de especialistas, de situações análogas para as quais séries temporais ou dados transversais estão disponíveis. Então, cada situação análoga é avaliada quanto à sua similaridade em relação à situação de previsão e os dados obtidos são utilizados para prevê-la.

Previsão Baseada em Regras

> *De Julgamento* > *Próprio* > *Sem Papel*
> *Estatístico* > *Univariado*

Nesta categoria, conhecimentos contextuais de especialistas e técnicas estatísticas são combinados utilizando-se um sistema especializado para a extrapolação de séries temporais. Assim, a maioria das características de uma série é identificada por análises automatizadas, porém especialistas identificam alguns fatores, como forças causais atuando sobre tendências.

Julgamento Não-Auxiliado

> *De Julgamento* > *Outros* > *Não-Estruturado*

Os métodos de julgamento não-auxiliado contam com especialistas que refletem sobre uma situação e predizem como as pessoas irão se comportar. Os especialistas podem ter acesso a dados e conselhos, mas suas previsões não são auxiliadas por métodos formais de previsão, fazendo destes os métodos mais comumente utilizados pois são rápidos, baratos quando poucas previsões são necessárias e podem ser aplicados nos casos onde pequenas mudanças são esperadas.

Mercados de Previsão

> *De Julgamento* > *Outros* > *Estruturado* > *Feedback*

Estes métodos baseiam-se em mercados de previsão onde pessoas realizam apostas sobre o que irá acontecer no futuro. Estes mercados podem ser muito úteis quando a informação é bastante dispersa como em pesquisas eleitorais, por exemplo.

Delphi

> *De Julgamento* > *Outros* > *Estruturado* > *Feedback*

A técnica *Delphi* faz uso de grupos estruturados para obter e combinar julgamentos de especialistas, onde uma pessoa controla a troca de informações entre partes anônimas em rodadas de interação. No final, uma média das estimativas é tomada como o julgamento do grupo.

Analogias Estruturadas

> *De Julgamento* > *Outros* > *Estruturado* > *Sem Feedback*

Nas analogias estruturadas, um especialista lista analogias para a situação de previsão, descreve similaridades e diferenças, avalia a semelhança e associa cada

decisão análoga (ou resultado) com a decisão potencial dada a situação de previsão. O resultado obtido pela analogia melhor avaliada é utilizado como previsão.

Teoria dos Jogos

> *De Julgamento > Outros > Estruturado > Sem Feedback*

Apesar de sua intenção não ser a de servir como ferramenta para previsão, a teoria dos jogos é um método simples para modelar a interação entre atores, sendo efetivo para analisar todos os dados disponíveis para que se possa entender melhor como decisões são tomadas de forma independente, dadas as premissas do modelo.

Decomposição

> *De Julgamento > Outros > Estruturado > Sem Feedback*

Os métodos de decomposição abordam um problema em partes. As partes podem ter relações multiplicativas (vendas do mercado e a fatia do mercado para estimar as vendas de uma empresa, por exemplo) ou aditivas (como estimativas para cada um dos produtos a fim de se obter as vendas totais).

Judgmental Bootstrapping

> *De Julgamento > Outros > Estruturado > Sem Feedback*

Esta técnica, através de análise de regressão, constrói um modelo a partir dos conhecimentos de especialistas e dos fatores por estes utilizados para se fazer as previsões. O *Judgmental Bootstrapping* é útil quando as opiniões dos especialistas são válidas, porém os dados são escassos, e onde os fatores-chave não variam ao longo dos dados históricos. Em outras palavras, esta técnica busca meios de prever o que um especialista pode prever, construindo um modelo de seu processo de previsão.

Sistemas Especialistas

> *De Julgamento > Outros > Estruturado > Sem Feedback*

Os sistemas especializados buscam inferir regras derivadas dos conhecimentos utilizados por especialistas, obtendo informações de diversas fontes como pesquisas, entrevistas, análises de protocolo e artigos. Apesar de terem características similares ao *Judgmental Bootstrapping*, os sistemas especializados tentam representar diretamente o processo de previsão de um especialista enquanto o primeiro tenta inferir quais procedimentos constituem este processo.

Extrapolação

> *Estatístico > Univariado*

As técnicas de extrapolção usam dados de séries temporais ou dados transversais similares para gerar previsões. Como exemplos, pode-se citar a suavização exponencial e os modelos de difusão.

Redes Neurais

> *Estatístico > Univariado*

As redes neurais dizem respeito a uma técnica de modelagem baseada no comportamento observado de neurônios biológicos e utilizada para imitar o desempenho de um sistema. Consistem de um conjunto de elementos inicialmente conectados segundo um padrão aleatório que, baseados em respostas operacionais,

se moldam nos padrões necessários para se obter os resultados desejados. Dessa forma, todos os métodos de previsão que fazem uso de redes neurais, encaixam-se nesta categoria.

Mineração de Dados

> *Estatístico > Univariado*

> *Estatístico > Multivariado > Baseado em Dados*

As técnicas que envolvem a mineração de dados deixam que os dados falem por si próprios, não considerando, em geral, conhecimentos teóricos. Frawley; Piatetsky-Shapiro; Matheus (1992) definem a mineração de dados como "a obtenção não trivial de informações implícitas, desconhecidas e potencialmente úteis a partir de dados".

Modelos Causais

> *Estatístico > Multivariado > Baseado na Teoria > Linear*

> *De Julgamento > Outros > Estruturado > Sem Feedback*

Em modelos causais, teoria, pesquisa e conhecimentos contextuais especializados são utilizados para especificar relacionamentos entre uma variável a ser prevista e variáveis explanatórias. No caso de modelos econométricos, a análise de regressão é comumente usada para estimar os coeficientes do modelo, fazendo com que estes sejam consistentes com a teoria envolvida.

Segmentação

> *Estatístico > Multivariado > Baseado na Teoria > Classificação*

Os métodos desta categoria baseiam-se em modelos onde pessoas, organizações ou quaisquer outros tipos de atores são divididos em categorias para que previsões sejam elaboradas separadamente. Assim, mudanças podem ser previstas examinando-se a reação de cada ator individual. Devido ao fato de que diferentes tipos de atores respondem de diferentes maneiras a uma mudança, estes métodos têm grande apelo intuitivo.

Escolha da Técnica de Previsão

Wheelwright; Makridakis (1989) apresentam três aspectos principais relacionados com a escolha da melhor técnica a ser utilizada para a atividade de previsão: a relação com as circunstâncias para a tomada de decisão; as características dos diversos métodos de previsão e; a quantidade disponível de dados históricos.

Quanto às circunstâncias envolvidas na tomada de decisão, Wheelwright; Makridakis (1989) relacionam cinco pontos que merecem atenção no processo de escolha da técnica de previsão mais adequada:

- O horizonte de tempo. O período de tempo em que uma decisão terá impacto e para o qual se dará uma tarefa de planejamento afeta a seleção do método de previsão mais apropriado. De maneira geral, pode-se dividir os horizontes de tempo em prazo imediato (menos de um mês), curto prazo (um a três meses), médio prazo (de três meses a dois anos) e longo prazo (mais de dois anos).
- O nível de detalhe. Na maioria dos casos, as empresas subdividem as tarefas de decisão, o que facilita a abordagem de acordo com o nível de detalhe requerido. Em uma situação específica, ao se escolher uma técnica de previsão, deve-se atentar ao nível de detalhe necessário para que a previsão seja útil na tomada de decisão.
- Quantidade de variáveis a serem previstas. Em situações onde uma única variável é objeto da atividade de previsão (vendas de um produto específico, por exemplo), métodos mais complexos e detalhados podem ser adotados em comparação com situações onde centenas ou milhares de variáveis devem ser previstas.
- Controle e planejamento. Ao se controlar o comportamento de uma determinada variável, deve-se ter a habilidade de prever e reconhecer, prematuramente, mudanças nos padrões básicos de sua evolução no tempo. Sob a ótica do planejamento, geralmente se assume que os padrões existentes irão continuar no futuro e, portanto, a ênfase maior está na identificação do padrão e a extrapolação deste para o futuro.
- Estabilidade. Nos cenários de previsão extremamente estáveis ao longo do tempo (ambiente econômico de uma país desenvolvido, por exemplo), métodos de previsão podem ser adotados e verificados periodicamente para se determinar o quanto estes estão sendo apropriados. Já em cenários de previsão pouco confiáveis, são necessários métodos que podem ser adaptados continuamente a dados e informações mais recentes.

Com relação às características dos diversos métodos de previsão, pode-se destacar cinco pontos:

- O horizonte de tempo. Aqui dois aspectos são relevantes. Primeiro é o fato de que, geralmente, métodos qualitativos são muito mais utilizados para previsões de longo prazo, enquanto métodos quantitativos são mais apropriados para previsões de médio e curto prazo. O segundo é o número de períodos para os

quais a previsão é desejada. Algumas técnicas são apropriadas somente para prever um ou dois períodos adiante, enquanto outros podem ser utilizados para prever vários períodos no futuro.

- O padrão dos dados. Intrínseca à maioria dos métodos de previsão, está a premissa relacionada ao tipo de padrão encontrado nos dados utilizados. Devido ao fato de os métodos variarem de habilidade na identificação de padrões diferentes, é importante associar um padrão presumido dos dados à técnica apropriada.
- Tipo do modelo. A maioria dos métodos assume um modelo para obtenção da previsão. Este modelo pode ser uma série onde o tempo é visto como o elemento importante na determinação de mudanças no padrão ou pode ser estatístico em sua natureza – como nas análises de regressão. Há também outros, como modelos causais, onde a previsão é dependente da ocorrência de um número de diferentes eventos. A importância dos modelos reside no fato de que as premissas intrínsecas a estes são diferentes e que suas capacidades de previsão variam conforme o cenário de tomada de decisão.
- Custos. Em geral, os custos envolvidos nas atividades de previsão envolvem quatro elementos: desenvolvimento, armazenamento, operação e oportunidade em relação a outras técnicas que poderiam ter sido aplicadas. A variação de custo tem importante impacto na atratividade de diferentes métodos para diferentes situações.
- Precisão. Inversamente relacionada ao nível de detalhe requerido está a precisão requerida. Ou seja, quanto maior o nível de detalhe de uma previsão, menor será a precisão obtida.

Ainda, devido ao fato dos diferentes métodos de previsão se basearem em dados históricos disponíveis, deve-se considerar o quanto de dados se possui, quais informações estes contêm e qual o custo de se obter outros dados cujas informações trazem um benefício compensatório.