

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA**

**MÉTODO DE PREVISÃO DE DEMANDA APLICADA AO PLANEJAMENTO DA
PRODUÇÃO DE INDUSTRIAS DE ALIMENTOS.**

**DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE FEDERAL DE SANTA CATARINA
PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA MECÂNICA.**

DARLENE CAVALHEIRO

FLORIANÓPOLIS, ABRIL DE 2003.

**MÉTODO DE PREVISÃO DE DEMANDA APLICADA AO PLANEJAMENTO DA
PRODUÇÃO DE INDUSTRIAS DE ALIMENTOS.**

DARLENE CAVALHEIRO

ESTA DISSERTAÇÃO FOI JULGADA PARA A OBTENÇÃO DO TÍTULO DE

MESTRE EM ENGENHARIA

**ESPECIALIDADE ENGENHARIA MECÂNICA E APROVADA EM SUA FORMA
FINAL PELO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA**

ABELARDO ALVES DE QUEIROZ, Ph.D. – ORIENTADOR

JOSÉ A. B. DA CUNHA NETO, Dr. – COORDENADOR DO CURSO

BANCA EXAMINADORA

FERNANDO A. FORCELLINI, Dr. Eng. (UFSC)

GLÁUCIA M. F. DE ARAGÃO, Dr. (EQA-UFSC)

CARLOS HENRIQUE AHRENS, Dr. Eng. (UFSC)

DEDICATÓRIA

Aos meus Pais.

AGRADECIMENTOS

A minha Família!

Ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Santa Catarina.

A CAPES, pelo apoio financeiro.

Ao meu orientador Professor Abelardo, por me aceitar como orientanda, pela ajuda, conselhos e paciência.

Aos Professores Gláucia, Ahrens e Forcellini por aceitarem avaliar meu trabalho.

Aos amigos e colegas do grupo de trabalho: Àdrian, Celso, Cristiane, Hamilton, Gilberto, Gustavo, Marisol e Priscila.

As empresas Bunge Alimentos, Novo Mel e Amoratto e em especial as pessoas de contato, Alexandra, Tatiana e Renato, respectivamente, que contribuíram para este trabalho, viabilizando os dados utilizados no mesmo.

A todos, por tudo...Muito Obrigada!

SUMÁRIO

LISTA DE FIGURAS.....	vii
LISTA DE TABELAS.....	x
RESUMO.....	xi
ABSTRACT.....	xii
CAPÍTULO 1.....	1
1 Introdução.....	1
1.1 Objetivos.....	2
1.1.1 Objetivo principal.....	2
1.1.2 Objetivos específicos.....	2
1.2 Justificativa.....	3
1.3 Estrutura do trabalho.....	3
CAPÍTULO 2.....	4
2 Revisão bibliográfica.....	4
2.1 Indústria de alimentos.....	4
2.2 Administração da produção.....	6
2.3 Planejamento e controle da produção.....	8
2.4 Gestão da demanda.....	11
2.5 Previsão da demanda.....	12
2.5.1 Sistemas de previsão de vendas.....	13
2.5.2 Avaliação da previsão.....	14
2.5.3 Previsões agregadas e desagregadas.....	18
2.6 Métodos de previsão.....	19
2.6.1 Análise de séries temporais.....	20
2.6.2 Métodos de análise de séries temporais.....	22
2.7 Sazonalidade.....	27
2.7.1 Teste para sazonalidade.....	28
2.7.2 Amplitude da sazonalidade.....	29
2.7.3 Métodos para previsão de séries temporais sazonais.....	30
2.8 Softwares de previsão de demanda.....	36
2.8.1 Pacotes computacionais estatísticos de uso genérico.....	36
2.8.2 Pacotes computacionais específicos.....	37

CAPÍTULO 3.....	39
3 Método proposto.....	39
3.1 Análise dos dados de entrada.....	41
3.2 Verificação da significância da sazonalidade.....	43
3.2.1 Exemplo de verificação da significância da sazonalidade.....	46
3.3 Aplicação do modelo.....	50
3.3.1 Análise dos componentes da demanda.....	50
3.3.2 Previsão da demanda.....	52
3.4 Operacionalização do modelo utilizando planilhas de cálculo.....	54
3.4.1 Dados de entrada.....	54
3.4.2 Cálculo da tendência.....	54
3.4.3 Cálculo da sazonalidade.....	54
3.4.4 Previsão.....	55
3.5 Exemplo da aplicação do modelo.....	56
3.5.1 Análise dos componentes da demanda.....	56
3.5.2 Previsão da demanda.....	58
CAPÍTULO 4.....	59
4 Validação teórica do modelo proposto.....	59
CAPÍTULO 5.....	68
5 Aplicação do método de previsão de demanda proposto.....	68
5.1 Empresa A.....	69
5.2 Empresa B.....	87
5.3 Empresa C.....	100
CAPÍTULO 6.....	103
6 Conclusões e sugestões.....	103
6.1 Conclusões.....	103
6.2 Sugestões para trabalhos futuros.....	105
Referências bibliográficas.....	106
Anexo 1.....	110
Anexo 2.....	113
Anexo 3.....	122
Anexo 4.....	125

LISTA DE FIGURAS

Figura 1.	Modelo geral da administração da produção. Slack et al (1997).....	7
Figura 2.	Visão global das atividades de planejamento e controle da produção. Davis <i>et al</i> (1997).....	9
Figura 3.	Gerenciamento da demanda no sistema de planejamento e controle da produção. Vollmann <i>et al</i> (1997)	11
Figura 4.	Relação entre acurácia e custo da previsão. (Montgomery & Johnson , 1976).....	15
Figura 5.	Componentes da série temporal.....	22
Figura 6.	Sazonalidade aditiva e sazonalidade multiplicativa.	30
Figura 7.	Fluxograma do método de previsão de demanda proposto.	40
Figura 8.	Vendas de refrigerante B e tendência global.	47
Figura 9.	Dados de sazonalidade.....	49
Figura 10.	Gráfico de vendas mensais de refrigerante B em centenas de caixas.....	56
Figura 11.	Regressão linear para obtenção dos fatores multiplicativos da sazonalidade.	57
Figura 12.	Vendas mensais de refrigerante A.....	60
Figura 13.	Vendas mensais de refrigerante B.	60
Figura 14.	Vendas mensais de champanhe.	61
Figura 15.	Vendas mensais de tapetes.	61
Figura 16.	Vendas mensais de caixas de papelão.	62
Figura 17.	Vendas de passagens aéreas internacionais.	62
Figura 18.	Previsão de vendas de refrigerante A.	63
Figura 19.	Previsão de vendas de refrigerante B.	63
Figura 20.	Previsão de vendas de champanhe.	64
Figura 21.	Previsão de vendas de tapetes.....	64
Figura 22.	Previsão de vendas de caixas de papelão.....	65
Figura 23.	Previsão de vendas de passagens aéreas internacionais.	65
Figura 24.	Vendas mensais do produto M40.	70
Figura 25.	Vendas mensais do produto M330.	71
Figura 26.	Vendas mensais do produto M800.	71
Figura 27.	Vendas mensais do produto MC280.....	72
Figura 28.	Vendas mensais do produto M3.5.	72
Figura 29.	Vendas mensais do produto M25.	73

Figura 30.	Vendas mensais do produto MP.	73
Figura 31.	Vendas mensais do produto MA.	74
Figura 32.	Vendas mensais do produto MAP.	74
Figura 33.	Vendas mensais do produto MG.	75
Figura 34.	Vendas mensais do produto MGP.	76
Figura 35.	Vendas mensais do produto SP.	76
Figura 36.	Vendas mensais do produto GR.	77
Figura 37.	Vendas mensais do produto P30.	77
Figura 38.	Vendas mensais do produto P20.	78
Figura 39.	Vendas mensais do produto U.	78
Figura 40.	Vendas mensais do produto SPM.	79
Figura 41.	Vendas mensais do produto M1.	79
Figura 42.	Previsão de vendas para o produto M330.	80
Figura 43.	Previsão de vendas para o produto M25.	81
Figura 44.	Previsão de vendas para o produto MP.	81
Figura 45.	Previsão de vendas para o produto MA.	82
Figura 46.	Previsão de vendas para o produto MAP.	82
Figura 47.	Previsão de vendas para o produto MG.	83
Figura 48.	Previsão de vendas para o produto MGP.	83
Figura 49.	Previsão de vendas para o produto SP.	84
Figura 50.	Previsão de vendas para o produto U.	84
Figura 51.	Vendas mensais da marca Remo para a região Oceânia.	89
Figura 52.	Vendas mensais da marca Surfe para a região Europa.	90
Figura 53.	Vendas mensais da marca Surfe para a região África.	90
Figura 54.	Vendas mensais da linha Turmalina para o estado Tocantins.	91
Figura 55.	Vendas mensais da linha Quartzo para o estado São Paulo.	91
Figura 56.	Vendas mensais da linha Topázio para o estado Rio Grande do Sul.	92
Figura 57.	Vendas mensais da linha Topázio para o estado Ceará.	92
Figura 58.	Vendas mensais da linha Quartzo para o estado Acre.	93
Figura 59.	Previsão de vendas para Oceânia_Remo.	93
Figura 60.	Previsão de vendas para Europa_Surfe.	94
Figura 61.	Previsão de vendas para África_Surfe.	94
Figura 62.	Previsão de vendas para Tocantins_Turmalina.	95

Figura 63.	Previsão de vendas para São Paulo_Quartzo.....	95
Figura 64.	Previsão de vendas para Rio Grande do Sul_Topázio.....	96
Figura 65.	Previsão de vendas para Ceará_Topázio.	96
Figura 66.	Previsão de vendas para Acre_Quartzo.....	97
Figura 67.	Vendas mensais de sorvete (R\$).....	101
Figura 68.	Previsão de vendas de sorvete (R\$).....	102

LISTA DE TABELAS

Tabela 1.	Dados para análise de variância. (Adaptado de Montgomery, 1997).....	44
Tabela 2.	Vendas mensais de refrigerante B [centenas de caixas]......	47
Tabela 3.	Estimativa da tendência $\hat{T}(t)$	48
Tabela 4.	Valores de sazonalidade mais erro.	48
Tabela 5.	Dados de sazonalidade utilizados na análise de variância.....	48
Tabela 6.	Resumo da análise de variância e do teste F para os dados analisados.....	49
Tabela 7.	Previsão da demanda de refrigerantes B [em centenas de caixas] para três períodos de tempo à frente.	58
Tabela 8.	Comparação entre o modelo proposto e os métodos clássicos utilizando o MAD....	66
Tabela 9.	Comparação entre o modelo proposto e os métodos clássicos utilizando o MSE....	67
Tabela 10.	Comparação entre o modelo proposto e os métodos clássicos utilizando o MAPE.....	67
Tabela 11.	Resultados da verificação da significância da sazonalidade da empresa A.	69
Tabela 12.	Resultados e comparação entre os métodos utilizando MAD.	85
Tabela 13.	Resultados e comparação entre os métodos utilizando MSE.	86
Tabela 14.	Resultados e comparação entre os métodos utilizando MAPE.	86
Tabela 15.	Resultados da verificação da significância da sazonalidade da empresa B.....	88
Tabela 16.	Resultados e comparação entre os métodos utilizando MAD.	97
Tabela 17.	Resultados e comparação entre os métodos utilizando MSE.	98
Tabela 18.	Resultados e comparação entre os métodos utilizando MAPE.	98
Tabela 19.	Resultados da verificação da significância da sazonalidade da empresa C.....	101
Tabela 20.	Resultados e comparação entre os métodos através das medidas de acurácia. ...	102

RESUMO

Nas últimas décadas, a economia brasileira tem experimentado um período de baixa inflação e relativa estabilidade, o que leva à demanda de vendas e produção mais previsíveis. Por várias décadas, a turbulência da economia e as dificuldades de previsão impediam o pleno desenvolvimento e aplicação de técnicas de planejamento. Num cenário econômico relativamente estável e ainda com a globalização da economia, as empresas têm se preocupado mais com o planejamento de suas operações, podendo agora se beneficiar melhor das práticas de previsão e tornarem-se mais competitivas. A indústria de alimentos constitui um dos setores mais importantes da economia nacional e, assim como as indústrias de outros setores, necessita planejar sua produção, cujos produtos são sensíveis a sazonalidade de oferta e demanda, perecíveis e de grande diversidade. O presente trabalho propõe um método para gerar dados de previsão da demanda, os quais serão aplicados no planejamento da produção de médio a curto prazo. O método compreende três etapas: análise dos dados históricos de demanda, verificação da sazonalidade e aplicação do modelo matemático. Na primeira etapa os dados são analisados qualitativamente. A etapa seguinte consiste na verificação da significância da sazonalidade presente nos dados de vendas através da análise de variância de um único fator e teste F. A última etapa do método é a aplicação do modelo ou procedimento matemático, também proposto neste trabalho. O modelo baseia-se na análise de séries temporais, ou seja, utilizando dados históricos de vendas de um produto ou família de produtos, analisa os componentes da série: tendência, sazonalidade e erro, e gera a previsão. O modelo pode ser aplicado de uma maneira fácil e rápida, usando planilhas de cálculo como o Excel. O modelo matemático proposto é validado teoricamente com dados da bibliografia e fazendo-se uma comparação com os procedimentos matemáticos dos métodos clássicos de previsão de dados sazonais como o de Winters e de Decomposição Clássica. Os resultados desta primeira fase apresentaram-se melhores ou semelhantes aos obtidos com os procedimentos clássicos, o que estimulou a aplicação prática do método proposto como um todo. Desta forma, foi realizada uma aplicação do método proposto a situações reais, utilizando-se dados de vendas de produtos de três empresas de alimentos. Analisou-se dados de vários produtos e aplicou-se o método proposto para gerar a previsão àqueles que apresentaram sazonalidade significativa. As previsões obtidas com o método proposto foram comparadas com as dos métodos de Winters e de Decomposição Clássica, e mostraram que, com flexibilidade quanto ao período de previsão e grande simplicidade, se tem um método com previsibilidade igual ou melhor do que os métodos clássicos de previsão de demanda que incluem a sazonalidade.

Palavras-chave: *previsão de demanda, sazonalidade, planejamento da produção.*

ABSTRACT

Since last decade, the Brazilian economy has experienced a period of low inflation and relative stability that led to a more predictable demand of sales and production. For several decades, the economic changes and the difficulties of forecasting impeded the development and application of planning techniques. In economic scenery relatively stable and, still with the globalization of the economy, the enterprises are more attentive with the operation planning getting to use better the forecasting practices now and to become world-wide competitive. The Food Industry compose one of the more important sector of the national economy and, like the others industries, need to plan its production, with products sensitives to offer and demand seasonality, perishable and in a big diversity. The present work proposes a method to determine the forecast of demand to apply to planning production. The method consists of three steps: analyse the historical data of demand, verify the seasonality and apply the mathematical model. In the first step is done a qualitative analyse on the data; in the second step verify the significance of seasonality with the analyse of the variance and F test; the last step is the application of the model, proposed in this work too. The model underlies on the time series analysis doing the decomposition of the demand in their components of trend, seasonality and error, and providing the forecasting. The model can be applied in a quick and easy way using spreadsheets as Excel. The model validation, in the theory, is taken place with data from bibliography and comparing its results with the results of the mathematical procedures of classical methods like Winters and Decomposition. The results of this first fase was better or similar to the results got with model of classical methods and this estimulate the application of the proposed method in real situations. This was done using sales data from three Food Industry. To the products that had significance in seasonality was calculated the forecasting with the proposed and classical methods. The forecasting results from proposed method shown that with flexibility in the forecasting period and big simplicity it have a method with accuracy similar or better comparing with classical method who analised seasonality too.

Keywords: *Forecasting, Seasonality, Planning Production.*

CAPÍTULO 1

1 INTRODUÇÃO

As mudanças econômicas ocorridas nos últimos tempos, como o processo de globalização, têm forçado as organizações empresarias a adaptarem-se continuamente para enfrentar os desafios de manterem-se no mercado de forma competitiva. Esta situação requer especial atenção das empresas ao planejamento adequado das atividades envolvidas no processo de produção, a fim de melhorar o fluxo e alocação de informações, materiais e pessoas, e atender satisfatoriamente à demanda pelos seus produtos.

O planejamento da produção tem a previsão de demanda como um dos seus principais subsídios. A previsão tem a função de fornecer informações sobre a demanda futura dos produtos para que a produção possa ser planejada com antecedência, permitindo que os recursos produtivos estejam disponíveis na quantidade, momento e qualidade adequada. Uma boa previsão proporcionará menor estoque, custo financeiro e tempo de entrega, maior previsibilidade e satisfação do cliente.

A indústria de alimentos constitui um dos setores mais importantes da economia nacional e, assim como as indústrias de outros setores, está exposta às adversidades de um mercado competitivo, que exige flexibilidade e rapidez na tomada de decisões. Além disso, os produtos alimentícios têm características especiais, como a perecibilidade, a sazonalidade de oferta e demanda e a grande diversidade, por exemplo, que exigem de cada empresa um esforço extra ao planejar a produção. Desta forma, a utilização de ferramentas capazes de gerar informações que contribuam para o planejamento eficaz da produção é indispensável.

A sazonalidade é uma característica freqüente na demanda por alimentos, sendo causada por variações climáticas, datas comemorativas, entre outros fatores. Com isso, é conveniente utilizar métodos de previsão que considerem o efeito das flutuações sazonais sobre a demanda, pois quanto mais informação se tiver sobre o comportamento da demanda de um produto, mais acurada será a previsão e, conseqüentemente, as decisões baseadas nesta previsão.

A previsão de demanda pode ser obtida por métodos qualitativos, quantitativos ou ambos. Os métodos qualitativos são baseados em opiniões, intuições e na experiência acumulada; enquanto que os métodos quantitativos são baseados na análise de séries temporais e modelos causais. A análise de séries temporais usa os valores passados de uma variável para prever seus

valores futuros. Os modelos causais fazem previsões com base em uma relação causa-efeito entre variáveis.

Neste trabalho, propõe-se um método para gerar dados de previsão da demanda, os quais serão aplicados no planejamento da produção de médio a curto prazo. Uma etapa importante do método é a verificação da significância da sazonalidade presente nos dados de vendas, sendo que a principal etapa do método consiste na aplicação do modelo matemático de previsão, também proposto neste trabalho. O modelo baseia-se na análise de séries temporais, ou seja, utilizando dados históricos de vendas de um produto ou família de produtos, analisa os componentes da série e faz a previsão. O modelo proposto é validado teoricamente com dados da bibliografia e fazendo-se uma comparação com métodos clássicos de previsão de dados sazonais como o método de Winters e o método de decomposição. Este trabalho também inclui a aplicação do método proposto a situações reais, utilizando-se dados de vendas de produtos de empresas de alimentos.

1.1 Objetivos

1.1.1 Objetivo principal

Propor um método de previsão de demanda, que sirva como ferramenta para o desenvolvimento do planejamento da produção da indústria de alimentos.

1.1.2 Objetivos específicos

- Estudar previsão de demanda e sua relação com o planejamento da produção;
- Estudar os métodos clássicos de previsão de demanda baseados na análise de séries temporais;
- Desenvolver um método para previsão de séries temporais com características sazonais;
- Estudar e avaliar a sazonalidade presente nos dados de demanda;
- Validar o modelo, inserido no método proposto, com dados bibliográficos, comparando-o com modelos ou procedimentos matemáticos clássicos da literatura;
- Aplicar o método proposto a situações reais, utilizando dados de vendas de produtos alimentícios.

1.2 Justificativa

A principal justificativa para este trabalho está baseada na importância da previsão de demanda para o planejamento da produção.

As atividades do planejamento da produção conciliam o fornecimento dos produtos com sua demanda. Assim, faz-se necessário determinar o que, quanto e quando produzir de forma a satisfazer continuamente os consumidores.

Para a produção qualquer informação confiável da demanda futura é de grande utilidade, já que decisões equivocadas que não reflitam o desejo de consumo dos clientes podem acarretar grandes prejuízos ou perdas de oportunidades de negócios.

A previsão de demanda baseada em métodos que reflitam melhor a realidade possibilita informações mais precisas sobre o comportamento da demanda de um produto e, conseqüentemente, as decisões baseadas nesta previsão.

1.3 Estrutura do trabalho

A presente dissertação está estruturada da seguinte forma:

- No capítulo 1 tem-se uma breve introdução sobre o trabalho desenvolvido, os objetivos, a justificativa e a estrutura deste trabalho;
- No capítulo 2 tem-se a revisão bibliográfica, que apresenta tópicos sobre Indústria de Alimentos, Administração da Produção, Planejamento da Produção, Previsão de Demanda, Séries Temporais, Sazonalidade, Métodos de Previsão, entre outros;
- No capítulo 3 apresenta-se o método de previsão de demanda proposto neste trabalho;
- No capítulo 4 apresenta-se a validação teórica do modelo, o qual integra o método proposto, comparando-o com modelos clássicos de previsão de dados sazonais;
- No capítulo 5 apresenta-se a aplicação do método proposto a dados reais de vendas de alimentos;
- No capítulo 6 têm-se as conclusões sobre o trabalho realizado e também sugestões para estudos futuros.

CAPÍTULO 2

2 REVISÃO BIBLIOGRÁFICA

A área de Administração da Produção tem, entre outras atividades, no desenvolvimento do Planejamento da Produção uma das suas principais responsabilidades. Para que o planejamento da produção seja realizado de forma a corresponder às expectativas da empresa e do mercado deve amparar-se em previsões. A Previsão de Demanda constitui-se num importante subsídio para o planejamento da produção, principalmente para aquelas empresas que produzem para manter estoques. A previsão de demanda pode ser gerada por vários métodos, sendo um dos mais utilizados a Análise de Séries Temporais.

Neste capítulo, apresentam-se alguns assuntos importantes ao contexto no qual insere-se este trabalho, como Administração da Produção, Planejamento da Produção, Gestão da Demanda, Previsão da Demanda, Séries Temporais, entre outros. Também faz-se uma abordagem sobre a Indústria de Alimentos, para a qual está voltada a aplicação deste trabalho, e sobre Sazonalidade, característica comum da demanda por alimentos.

2.1 Indústria de alimentos

No ambiente agroalimentar a indústria de alimentos compreende a agroindústria e a indústria de alimentos. Esta divisão visa separar as empresas que estão mais próximas dos consumidores finais, com produtos prontos para o consumo, chamadas indústrias de alimentos, das agroindústrias, produtoras de *commodities* e como tal processadoras primárias de produtos, fornecendo-os ao mercado industrial e que, de forma geral, não atingem diretamente o consumidor final. Exemplos de agroindústria são usinas de açúcar, moinhos e abatedouros. E como exemplos da indústria de alimentos têm-se a indústria de chocolates, leite e derivados, massas, entre outras. (Neves *et al*, 2000)

Sato (1997) desenvolveu um estudo sobre o perfil econômico da indústria de alimentos no Brasil entre 1990-1995, onde apresenta uma breve retrospectiva deste setor desde após a Segunda Guerra Mundial até a década de 90. Segundo a autora, no ano de 1949, época que o Brasil era um País determinantemente agrícola, a indústria de alimentos participava com 20,5% em termos do valor agregado; no início dos anos 70, quando a industrialização já dava seus primeiros passos, esse número diminuiu para 12,4%. A participação relativa cai, mas em

números absolutos, cresce significativamente. O número de estabelecimentos aumentou de 14.905 para 46.815, e de 173.535 empregados para 372.401, ou seja, nesse período as taxas de crescimento foram positivas. Nos anos 80, o país atravessava um período de desordem econômica e política devido a problemas provenientes da dívida externa e interna e da inflação endêmica. Sem uma política industrial clara, o setor não incrementou investimentos entre 1980 e 1992, implicando uma redução na produção de 7,4%, e os setores mais afetados foram os de bens de capital e duráveis. Diferentemente, os setores de bens de consumo não duráveis (alimentos e têxtil) cresceram 8% no período, revertendo à tendência da década anterior. Nos anos 90, as empresas brasileiras já estavam em processo de reestruturação, preparando-se para a abertura dos mercados brasileiros à internacionalização dos padrões de qualidade e produtividade.

A partir desta época, o setor de alimentos expandiu, experimentando intensa concorrência, aumento progressivo da demanda e da variedade de seus produtos, e maior exigência dos consumidores por alimentos mais elaborados e de qualidade, levando as empresas a implantarem novos conceitos, práticas e ferramentas de gerenciamento e qualidade.

De acordo com dados da Associação Brasileira das Indústrias de Alimentos (ABIA), em 1997 a indústria de alimentos atingiu um faturamento líquido (líquido de impostos indiretos) de R\$ 67,4 bilhões e, juntamente com a indústria de bebidas, contribuiu com 9,0% do Produto Interno Bruto (PIB). Já em 2001, o faturamento foi de R\$ 96,8 bilhões e o PIB 9,6%. A participação da indústria de alimentos e bebidas na indústria de transformação em 2001 foi 18,5%. O número de empregados e o número de estabelecimentos industriais formais, em 2001, foram 896 mil e 39,8 mil, respectivamente. Estes dados confirmam a expansão da indústria de alimentos nesses últimos anos.

Donk (2001) apresenta algumas características da indústria de alimentos:

- **Características da planta:** capacidade cara e de uso específico; com uma variedade de produtos pequena e alto volume; tempo de *set up* longo entre diferentes produtos.
- **Características do produto:** a origem da matéria prima freqüentemente implica em oferta, qualidade e preço variável, devido à produção instável; em contraste com a manufatura discreta, volume ou peso são usados; matérias-primas, semi-manufaturadas e produtos acabados são perecíveis.
- **Características do processo de produção:** os processos têm produtividade variável; a taxa de produção é principalmente determinada pela capacidade; devido a incertezas em preço, qualidade e fornecimento de matéria-prima, várias fórmulas estão disponíveis para o mesmo produto.

Na maioria dos casos, um número limitado destas características está presente. Cada um destes fatores apresentados devem ser levados em conta para os propósitos de planejamento e programação da produção.

Com relação às características do mercado da indústria de alimentos, os tempos de entrega são geralmente curtos e os consumidores, tais como as cadeias varejistas, necessitam de uma alta confiabilidade. Do ponto de vista do produtor, estes curtos tempos de entrega parecem ir de mão em mão com uma imprevisibilidade relativa da demanda. Em vários casos, os varejistas tentam passar todas as incertezas da demanda para os produtores, solicitando entregas instantâneas, sem apoio adequado em previsão de demanda. Hoje em dia, melhores oportunidades de previsão têm surgido, por exemplo, pela análise do ponto de venda e rastreamento de dados, que disponibilizam informações necessárias ao processo de previsão de demanda. Embora a demanda atual dos consumidores ainda seja irregular, tais esforços em previsão podem melhorar o desempenho global da cadeia de suprimentos. (Donk, 2001)

2.2 Administração da produção

A administração da produção trata da maneira pela qual as organizações produzem bens e serviços (Slack *et al* 1997).

De acordo com Davis *et al* (1997), a partir de uma perspectiva operacional, a administração da produção pode ser vista como um conjunto de componentes, cuja função está concentrada na conversão de um número de insumos em algum resultado desejado. Esta conversão é denominada processo de transformação.

O processo de transformação compreende três áreas de atividades que selecionam, localizam e organizam a transformação de recursos, que determinam a natureza e o *timing* do fluxo dos recursos transformados: projeto, planejamento e controle e melhoria (Slack *et al* 1997).

Dentre estas atividades, destaca-se o planejamento e controle, que é a atividade de se decidir sobre o melhor emprego dos recursos de produção, assegurando assim, a execução daquilo que foi previsto.

Desta forma, para fazer um bom planejamento deve-se ter uma boa previsão. A previsão da demanda é um *input* fundamental para o planejamento, sendo a base para se desenvolver o planejamento mestre da produção, o planejamento da capacidade e o planejamento de estoques.

A Figura 1 representa o modelo geral de administração da produção proposto por Slack *et al* (1997).

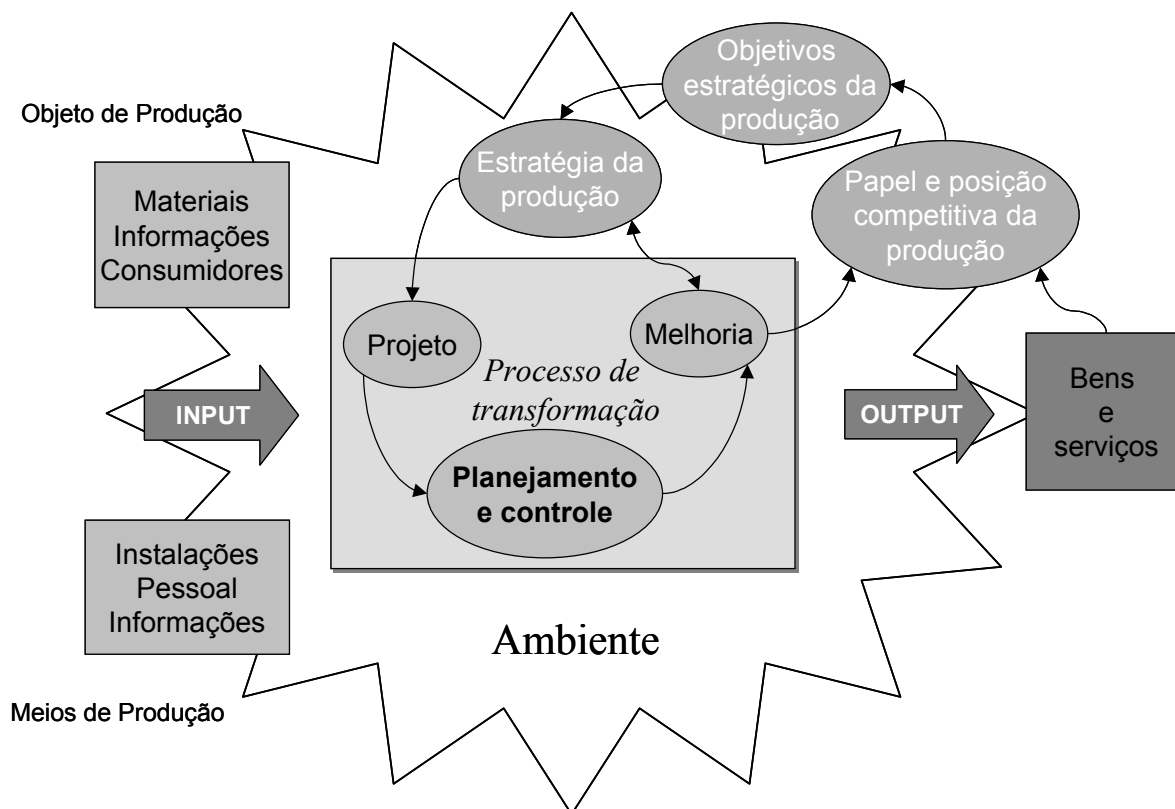


Figura 1. Modelo geral da administração da produção. Slack et al (1997).

O presente modelo é definido em termos de ambiente, *inputs*, processo de transformação e *outputs*. O ambiente inclui o que está fora do sistema de produção – consumidores, concorrentes, fornecedores, regulamentações governamentais, tecnologia e economia – mas que o influencia de alguma maneira, e dá forma à estratégia de produção da organização. Os *inputs* compreendem os recursos transformados (materiais, informações, consumidores) e os recursos de transformação (instalações, pessoal, informações). O processo de transformação é a parte do sistema que adiciona valor aos *inputs*, e onde se encontra a atividade de planejamento e controle de produção. E os *outputs* constituem-se nos bens e/ou serviços (Shafer & Meredith, 1998).

2.3 Planejamento e controle da produção

Conforme Slack *et al* (1997), o planejamento e controle da produção (PCP) compreende as atividades que conciliam o fornecimento dos produtos de um sistema com sua demanda.

Para Vollmann *et al* (1997), basicamente o sistema de PCP provê informações para eficientemente gerenciar o fluxo de materiais, efetivamente utilizar pessoas e equipamentos, coordenar atividades internas com aquelas dos fornecedores, e comunicar-se com os consumidores sobre as necessidades do mercado.

Atividades típicas de gerenciamento suportadas pelo sistema de PCP incluem (adaptado de Córrea *et al* (1997) e Vollmann *et al* (1997)):

- Planejar as necessidades de capacidade;
- Planejar os materiais;
- Planejar estoques adequados de matérias-primas, semi-acabados e produtos finais, nos pontos certos;
- Programar as atividades de produção para que pessoas e equipamentos estejam trabalhando no momento e tarefa certos;
- Informar sobre materiais, pessoas, ordens, equipamentos e outros recursos na fábrica;
- Comunicar-se com consumidores e fornecedores;
- Ser capaz de reagir eficazmente a situações adversas.

De acordo com Tubino (2000), as atividades do planejamento da produção são exercidas em três níveis hierárquicos. No nível estratégico, onde são definidas as políticas estratégicas de longo prazo da empresa, tem-se o *planejamento estratégico da produção*. No nível tático, onde são estabelecidos os planos de médio prazo para a produção, gera-se o *programa mestre de produção*. E no nível operacional, onde são preparados os planos de curto prazo de produção, e realizado o acompanhamento dos mesmos, desenvolve-se a *programação da produção*.

Uma visão global das atividades do planejamento da produção pode ser vista na Figura 2, adaptada de Davis *et al* (1997).

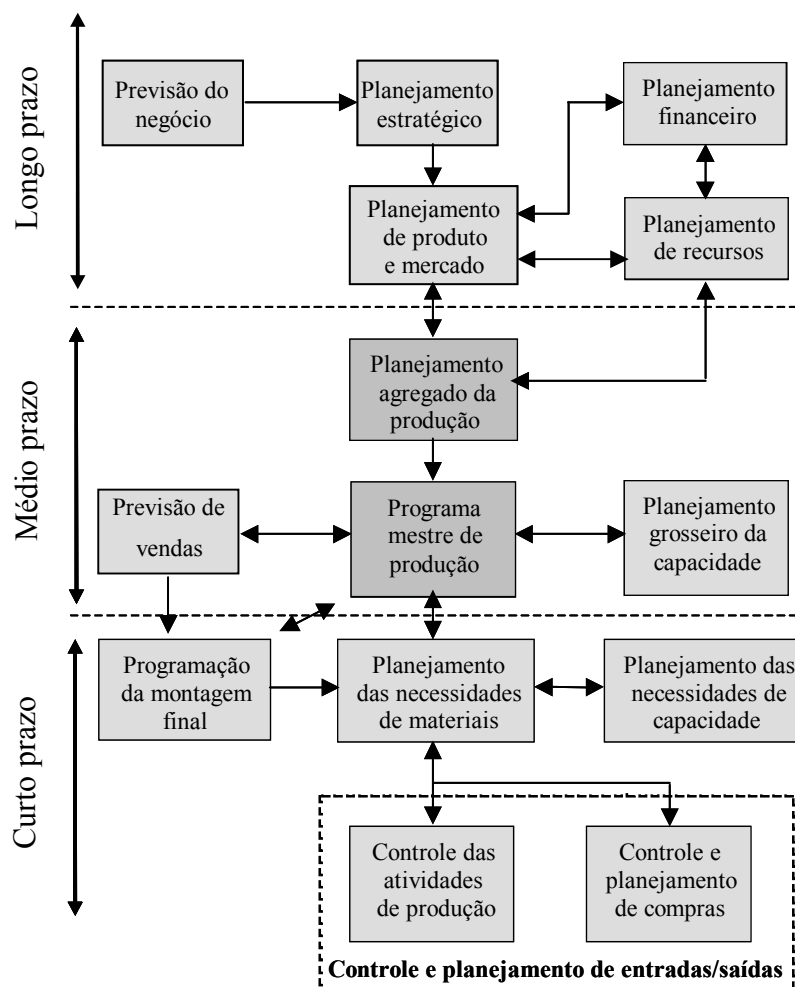


Figura 2. Visão global das atividades de planejamento e controle da produção. Davis *et al* (1997)

O planejamento de longo prazo inicia com a declaração dos objetivos e metas da organização para os próximos 2 a 10 anos (o horizonte de planejamento depende de cada empresa). O *planejamento estratégico* articula como estes objetivos e metas serão atingidos, levando em conta a capacitação da empresa e seu ambiente econômico e político, projetado pela *previsão do negócio*. Os elementos do plano estratégico incluem a delimitação da linha de produtos, dos níveis de qualidade e preços e das metas de penetração no mercado. O *planejamento do produto e do mercado* transfere estes elementos para os objetivos dos mercados individuais e das linhas de produtos, e inclui um plano de produção a longo prazo (basicamente, uma previsão dos itens a serem fabricados para os próximos dois anos ou mais). O *planejamento financeiro* analisa a viabilidade financeira destes objetivos e o *planejamento de recursos*

identifica as instalações, os equipamentos e o pessoal necessário para viabilizar o plano de produção a longo prazo.

No planejamento de médio prazo o *planejamento agregado* da produção especifica a produção mensal ou trimestral necessária para os grupos principais de produtos para até 18 meses adiante, buscando encontrar qual combinação dos níveis de mão-de-obra e de estoques que minimiza os custos totais relativos de produção, procurando simultaneamente atender à demanda prevista para o produto.

A *previsão de vendas* fornece uma estimativa da demanda dos produtos individuais, a qual, quando integrada ao plano agregado de produção, corresponde à produção necessária para o *programa mestre de produção*, e este gera para o fabricante a quantidade e os dados dos produtos finais individuais. O processo de monitorar e de integrar estas informações é denominado *gestão da demanda*.

O *planejamento grosseiro da capacidade* revisa o programa mestre de produção para certificar-se de que restrições óbvias de capacidade não irão exigir mudanças na programação.

No planejamento de curto prazo tem-se o *planejamento das necessidades de materiais (MRP)* que considera as necessidades do produto final a partir do programa mestre de produção e o explode em suas submontagens e componentes. O *planejamento das necessidades de capacidade (CRP)* fornece uma programação detalhada de quando cada operação deve ser executada em cada centro de trabalho, e quanto tempo levará para ser processada. A informação utilizada é proveniente dos pedidos planejados (previstos) e abertos (existentes) que são gerados pelo plano de materiais.

A *programação da montagem final* identifica as diversas operações necessárias para colocar o produto em sua forma final. O *planejamento e controle de entrada/saída* compreende o *controle das atividades de produção* que envolve a programação e o controle das atividades do dia-a-dia no chão-de-fábrica, e o *planejamento e controle de compras* que consiste na aquisição e controle dos itens de compra, como especificado pelo plano de materiais.

Na descrição anterior das etapas do processo de planejamento da produção, verifica-se que a previsão da demanda tem uma função relevante para o PCP, pois é ela que juntamente com o plano agregado de produção compõem o plano mestre de produção que determinará o que, quanto e quando produzir.

2.4 Gestão da demanda

Esta atividade gerencia a integração entre o consumidor e a empresa, sendo responsável pelo planejamento apropriado de todas as demandas geradas, externas ou internas, a fim de que se tenha um equilíbrio entre o que a produção pode fornecer e o que o mercado requer. (Favaretto, 2001)

Os principais elementos da gestão da demanda são *previsão da demanda*, comunicação com o mercado, influência sobre o mercado, promessa de prazos e priorização e alocação. Contudo, o processo de previsão de vendas é possivelmente o mais importante dentro da gestão da demanda. (Corrêa *et al*, 1997)

A Figura 3 apresenta a gestão da demanda como um módulo de entrada para o sistema de PCP, fazendo a conexão do mesmo ao mercado. Uma implicação desta conexão é a necessidade de prever a demanda como um pré-requisito a outras atividades do PCP. Um aspecto importante é fornecer previsões num nível apropriado de detalhes. Também pode implicar em restrições à previsão para adequar-se a certos requerimentos globais da empresa. (Vollmann *et al*, 1997)

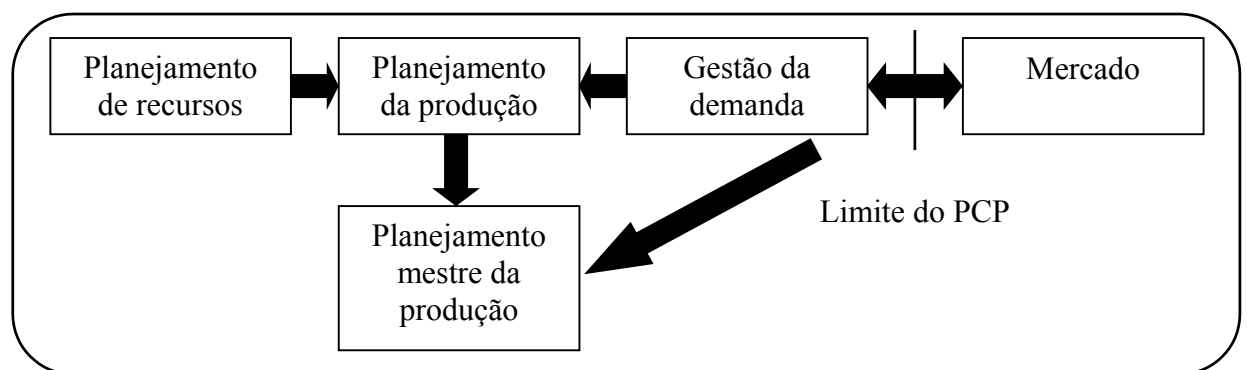


Figura 3. Gerenciamento da demanda no sistema de planejamento e controle da produção.

Vollmann *et al* (1997)

Em adição à função de sincronização e comunicação entre as atividades do mercado e o plano de produção, uma atividade chave no módulo de gerenciamento da demanda é assegurar a integridade da informação da demanda. Todas as fontes da demanda para os recursos de produção devem ser identificadas e incorporadas no processo de planejamento da produção.

As interações do gerenciamento da demanda e o planejamento mestre da produção (PMP) são freqüentes e detalhadas. Os detalhes variam significativamente entre as diferentes formas de responder à demanda: fazer-para-estoque, montar-sob-pedido e fazer-contra-pedido. Em todos os

exemplos, o conceito base é que as previsões são consumidas durante os períodos futuros de tempo pelos atuais pedidos dos clientes.

Nas empresas que produzem para manter estoques há poucos pedidos atuais e a demanda é geralmente satisfeita pelo estoque. Desta forma, a tarefa do PMP é prover estoque para satisfazer os pedidos previstos. Para aquelas que produzem da forma montar-contrapedido, a tarefa chave do PMP é prover datas prometidas viáveis. O PMP usa o conceito disponível-para-promessa (*available-to-promise*) para cada modulo ou opção do cliente para gerenciar a conversão das previsões em pedidos registrados. Quando se produz da forma fazer-contrapedido há um grande número de pedidos em carteira, não dependendo de previsões.

A resposta à demanda do tipo fazer-para-estoque é a que requer previsões mais detalhadas – as previsões devem ser feitas para itens, por localização e período de tempo – pois a empresa precisa manter um estoque adequado através do sistema de distribuição e manter os níveis de serviço para satisfazer os desejos dos clientes. Quando se trata de produtos de primeira necessidade, como alimentos, os níveis de serviço referem-se, principalmente, à disponibilidade do produto final aos consumidores.

2.5 Previsão da demanda

Martins & Laugeni (1998) definem previsão da seguinte maneira: “Previsão é um processo metodológico para a determinação de dados futuros baseado em modelos estatísticos, matemáticos ou econométricos ou ainda em modelos subjetivos apoiados em uma metodologia de trabalho clara e previamente definida”.

Muitas empresas reconhecem a importância da previsão de demanda em todos os níveis de uma organização. Para a produção, ela é fundamental para a tomada de *decisões periódicas* envolvendo seleção de processo, planejamento de capacidade, melhorias de layout, e de *decisões contínuas* sobre planejamento da produção, da programação e do estoque. (Davis *et al*, 1997)

Segundo Buffa & Sarin (1987) *apud* Moura Júnior (1996), as previsões de demanda podem ser classificadas em:

- Curto prazo: estão relacionadas com a programação da produção e decisões relativas ao controle de estoque.
- Médio prazo: o horizonte de planejamento varia aproximadamente de seis meses a dois anos. Planos tais como plano agregado de produção e plano mestre de produção se baseiam nestas previsões.

- Longo prazo: o horizonte de planejamento se estende aproximadamente a cinco anos ou mais. Auxilia decisões de natureza estratégica, como ampliações de capacidade, alterações na linha de produtos, desenvolvimento de novos produtos, etc...

A previsão é uma ferramenta de auxílio as decisões do planejamento da produção e de nenhuma forma é a palavra final, principalmente porque existem alguns acontecimentos políticos, econômicos e até materiais que podem mudar substancialmente o comportamento dos consumidores. Contudo, para a produção qualquer informação confiável da demanda futura é de grande utilidade, já que decisões equivocadas de antecipação de compras, contratação ou produção que não reflitam o desejo de consumo dos clientes podem acarretar grandes prejuízos ou perdas de oportunidades de negócios.

É muito importante que a empresa saiba utilizar todas as ferramentas disponíveis para conseguir antecipar a demanda futura com alguma precisão. Isso pode envolver formar e manter uma base de dados históricos de vendas, assim como informações que expliquem suas variações e comportamento no passado, utilizar modelos matemáticos adequados que ajudem a explicar o comportamento da demanda, compreender como fatores ou variáveis internas (promoções, por exemplo) e externas (clima, condições econômicas) influenciam o comportamento da demanda, coletar informações relevantes do mercado e ser capaz de derivar daí uma estimativa da demanda futura. (Corrêa *et al*, 1997)

2.5.1 Sistemas de previsão de vendas

De acordo com Corrêa *et al* (1997), sistema de previsão de vendas é o conjunto de procedimentos de coleta, tratamento e análise de informações que visa gerar uma estimativa das vendas futuras, medidas em unidades de produtos (ou famílias de produtos) em cada unidade de tempo (semanas, meses, etc.). As principais informações que devem ser consideradas pelo sistema de previsão são:

- Dados históricos de vendas, período a período;
- Informações relevantes que expliquem comportamentos atípicos das vendas passadas;
- Dados das variáveis correlacionadas as vendas que ajudem a explicar o comportamento das vendas passadas;
- Situação atual de variáveis que podem afetar o comportamento das vendas no futuro ou estejam a ele correlacionadas;

- Previsão da situação futura de variáveis que podem afetar o comportamento das vendas no futuro ou estejam a ele correlacionadas.
- Conhecimento sobre a conjuntura econômica atual e previsão da conjuntura econômica;
- Informações de clientes que possam indicar seu comportamento de compra;
- Informações relevantes sobre a atuação de concorrentes que influenciam o comportamento da vendas;
- Informações sobre decisões da área comercial que podem influenciar o comportamento das vendas.

A aplicabilidade de um sistema de previsão quantitativo depende de três condições (Makridakis *et al*, 1998):

- Disponibilidade de informações históricas;
- Possibilidade da transformação das informações históricas em dados numéricos; e
- Suposição da repetição de padrões observados em dados passados no tempo futuro.

2.5.2 Avaliação da previsão

Um dos problemas da previsão é que nunca se consegue uma previsão 100% correta, ao contrário, na maioria dos casos, não se consegue chegar perto disso. Sendo a previsão uma das informações mais importantes para o planejamento, conclui-se que qualquer processo de planejamento sofre em virtude dos erros de previsão. As incertezas das previsões e os erros correspondentes provêm de duas fontes distintas: a primeira delas corresponde ao próprio mercado, que, dada sua natureza, pode ser bastante instável e de baixa previsibilidade; a segunda corresponde ao sistema de previsão, que, com base em várias informações coletadas junto ao mercado e dados históricos, gera uma informação que pretende antecipar a demanda futura, informação esta que pode conter incertezas em virtude da própria eficácia (ou falta de eficácia) do sistema de previsão (Corrêa *et al*, 1997).

A qualidade de qualquer previsão é refletida na decisão baseada nesta previsão. Isto sugere que a comparação ideal dos procedimentos de previsão seja baseada nos custos de se produzir a previsão e no valor da previsão para a decisão. Infelizmente, nenhum custo é facilmente medido, e, além disso, diferentes procedimentos de previsão podem ser necessários para cada decisão, uma possibilidade complexa indesejável. Como resultado dessas

complicações, para avaliar a qualidade das previsões depende-se de alguma medida direta. (Vollmann *et al*, 1997)

O critério predominante para avaliar a previsão é a acurácia. Em muitos exemplos, a palavra acurácia refere-se ao “melhor ajuste”, o qual representa o quanto bem o modelo de previsão é capaz de reproduzir os dados que já são conhecidos. Em modelos de séries temporais é possível usar um conjunto de dados conhecidos para prever o restante dos dados desconhecidos, permitindo estudar a acurácia da previsão futura mais diretamente. (Wheelwright & Makridakis, 1985)

Ao dedicar mais recursos para a previsão, ou seja, utilizar métodos mais complexos e caros, deve-se melhorar a acurácia da previsão e através disso eliminar algumas das perdas resultantes da incerteza no processo de tomada de decisão. Este conceito é ilustrado na Figura 4, onde à medida que o custo de previsão é aumentado, as perdas associadas ao risco diminuem. Em certo nível de tentativa de previsão a soma destes custos é um mínimo. (Montgomery & Johnson, 1976)

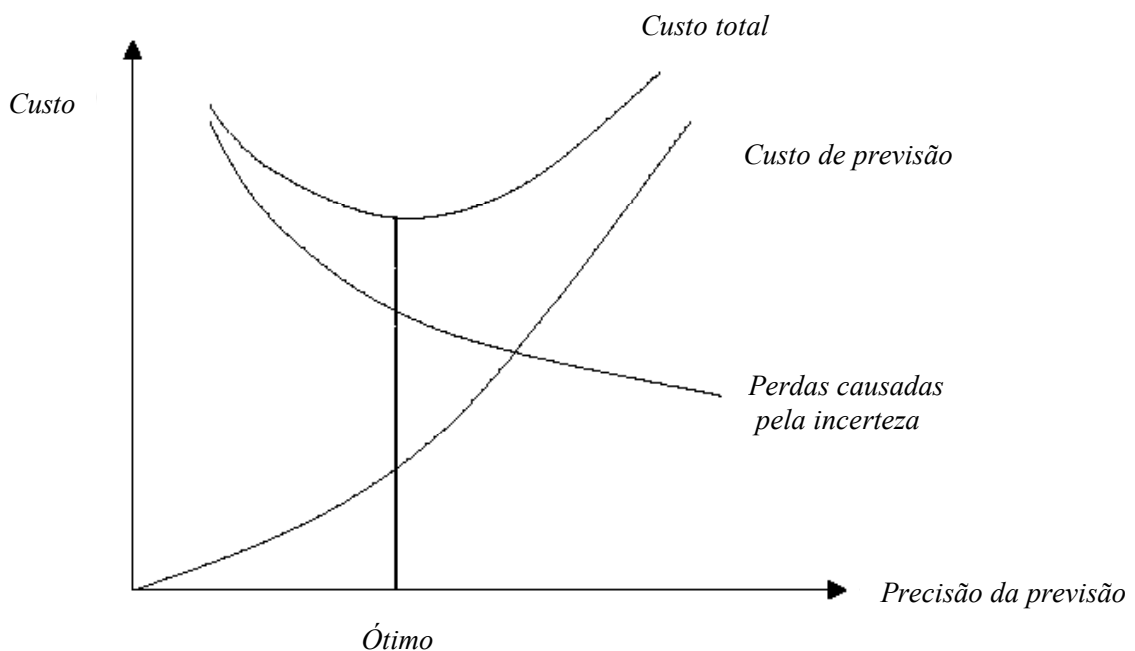


Figura 4. Relação entre acurácia e custo da previsão. (Montgomery & Johnson, 1976).

O modelo conceitual da Figura 4 é baseado na suposição do decréscimo do valor marginal da previsão. Isto é, cada unidade monetária gasta em previsão resulta em uma pequena redução nas perdas associadas ao risco do que no custo anterior. Além de certo ponto, os

recursos adicionais dedicados à previsão podem não trazer nenhum melhoramento ao todo. Isto porque será impossível reduzir o erro de previsão médio abaixo de um dado nível, não importando quão complexo seja o processo de previsão empregado. (Montgomery & Johnson, 1976)

A maioria das empresas tolera uma certa quantidade de erro, e isto depende de duas coisas: a capacidade de ajuste da empresa e o custo de um erro. A capacidade de ajuste refere-se a quão rapidamente a empresa pode ajustar-se ao erro, o que depende do *lead time*. Menor o *lead time*, mais rapidamente a empresa deve ser capaz de ajustar-se ao erro, e maior o erro que ela pode tolerar. O custo de um erro também faz a diferença. Mais alto o custo, mais baixo o erro que a empresa pode tolerar. Para produtos perecíveis ou de moda o custo de um erro pode ser alto.

O erro de previsão, e , consiste na diferença entre o valor previsto, F , e o valor observado ou demanda atual, X . Matematicamente, o erro no período de tempo i pode ser expresso como:

$$e_i = X_i - F_i, i = 1...n \quad (2.1)$$

Se há n períodos de tempo para os quais tanto a previsão quanto a demanda atual são conhecidas, então tem-se várias maneiras de calcular o erro total, ou seja, a acurácia da previsão. (Sule, 1988)

Uma medida de acurácia que pode ser calculada é o erro médio (*mean error* – ME) de previsão, na qual adicionam-se os valores dos erros e calcula-se a média. O resultado obtido é próximo de zero, visto que os erros positivos cancelam os erros negativos. Para evitar este problema pode-se calcular o erro absoluto, comumente chamado de desvio absoluto médio (*mean absolut deviation* – MAD), o qual é simplesmente a média do erro absoluto. Esta segunda medida é freqüentemente preferida ao erro médio. Outra medida de acurácia é o erro percentual absoluto médio (*mean absolute percentage error* – MAPE). Como uma percentagem, esta medida é próxima a um, e desta forma é algumas vezes preferida ao ME e MAD. Ainda outra medida de acurácia é o erro quadrado médio (*mean squared error* – MSE). Uma das diferenças entre o MAD ou o MAPE e o MSE é que este penaliza a previsão muito mais para os desvios extremos do que para pequenos desvios. Desta forma, adotar o critério de minimizar o MSE implica em ter-se vários pequenos desvios do valor de previsão ao invés de um grande desvio. Outra medida também utilizada é o desvio padrão do erro (*standard deviation of errors* – SDE). (Wheelwright & Makridakis, 1985)

As medidas de acurácia da previsão descritas anteriormente podem ser representadas pelas equações a seguir:

Erro médio:

$$ME = \frac{\sum_{i=1}^n e_i}{n} \quad (2.2)$$

Desvio absoluto médio:

$$MAD = \frac{\sum_{i=1}^n |e_i|}{n} \quad (2.3)$$

Erro quadrado médio:

$$MSE = \frac{\sum_{i=1}^n e_i^2}{n} \quad (2.4)$$

Desvio padrão do erro:

$$SDE = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n-1}} \quad (2.5)$$

Erro percentual:

$$PE_t = \frac{X_t - F_t}{X_t} (100) \quad (2.6)$$

Erro percentual médio:

$$MPE = \frac{\sum_{i=1}^n PE_i}{n} \quad (2.7)$$

Erro percentual absoluto médio:

$$MAPE = \frac{\sum_{i=1}^n |PE_i|}{n} \quad (2.8)$$

Sendo que:

e_i = erro de previsão para o período de tempo $i = X_i - F_i$

X_i = valor observado para o período de tempo i

F_i = valor previsto para o período de tempo i

i = período, $i = 1 \dots n$

n = número de períodos de tempo

t = tempo

2.5.3 Previsões agregadas e desagregadas

Muitas empresas possuem uma grande diversidade de produtos, o que poderia ser uma preocupação ao fazer previsões, porém nem sempre é necessário prever a demanda para cada item individualmente. Desta forma, os produtos podem ser agregados em marcas, linhas ou qualquer outro critério adotado pela empresa, e analisados sob uma série de dados única.

Algumas vezes, para se captar alguma característica no comportamento de uma série temporal, faz-se necessário uma agregação de seus elementos temporais. Por exemplo, quando se está analisando uma série contendo dados diários pode não ser possível visualizar com facilidade um padrão no comportamento da série que se manifeste numa base mensal, o que poderia implicar em uma deficiência na modelagem. Neste caso, se poderia agregar os dados em períodos semanais e mensais, até que algum padrão possa ser identificado na série de maneira distinta. (Pellegrini, 2000).

As agregações temporais são definidas, basicamente, pelos dados de demanda disponíveis. Já as agregações dos produtos, são definidas por preferências gerenciais, custos da análise, acurácia requerida e a disponibilidade dos dados de demanda (Montgomery *et al*, 1990).

A metodologia mais aplicada para a agregação de produtos é a classificação ABC, a qual determina a importância do produto, relacionando demanda e seu faturamento (Nahmias, 1993) *apud* (Pellegrini, 2000).

As decisões de maior inércia, que envolvem maiores recursos, necessitam de maior antecedência; também requerem visão do futuro com maiores horizontes e, portanto estão sujeitas a incertezas. Por outro lado, essas mesmas decisões tendem a não requerer previsões de futuro desagregadas. Com a agregação, os erros de previsão ficam reduzidos, compensando a necessidade de antecedência mais longa com a possibilidade do tratamento agregado de informações. A previsão desagregada pode ser feita com uma antecedência bem menor. Se, por um lado, a incerteza com que trabalha neste momento é maior devido ao grau de desagregação, por outro, a incerteza devido à antecedência é muito menor pelo fato de a própria antecedência ser muito menor. Isso significa que ao trabalhar-se adequadamente os níveis de antecedência e agregação dos dados, pode-se trabalhar com um nível de incerteza mais uniforme ao longo de todo o horizonte de previsão. (Corrêa *et al*, 1997)

As decisões de longo prazo, geralmente, requerem previsões de níveis agregados da demanda, utilizando medidas como volume anual de vendas. Em uma lógica, isto é positivo, visto que níveis agregados de uma atividade podem ser previstos mais acuradamente do que atividades individuais. (Vollmann *et al*, 1997)

Para planejar a produção de uma linha de produtos, pode ser necessário ter a previsão das vendas unitárias para cada item, por período de entrega, para um número de meses no futuro. Esta previsão para produtos acabados pode então ser convertida em requerimentos para produtos semi-acabados, componentes, materiais, força de trabalho, e etc., para que o sistema de manufatura inteiro possa ser programado. Também se pode prever em algum nível agregado, dito famílias de produtos similares, e então decompor a previsão agregada para o nível de item. (Montgomery & Johnson, 1976)

2.6 Métodos de previsão

A escolha do método a ser adotado para a previsão de demanda depende de vários fatores, tais como disponibilidade de dados históricos, horizonte de previsão (longo, médio ou curto), precisão necessária, orçamento disponível e padrão dos dados existentes (horizontal, sazonal, cíclico ou tendência). (Davis *et al*, 1997)

Existem vários métodos para previsão de demanda, os quais podem ser agrupados em duas categorias principais: quantitativos e qualitativos.

Os métodos qualitativos envolvem estimação subjetiva através de opiniões de especialistas. Há geralmente procedimentos formais para obtenção de predições desta forma, variando da consolidação de estimativas de vendas pessoais ao uso de métodos tipo Delphi para obter um consenso de opinião de um painel de responsáveis pela previsão. Estes procedimentos podem depender em parte de testes de marketing, pesquisa com consumidores, estimativas da força de vendas e dados históricos, mas o processo pelo qual a informação é usada para obter a previsão é subjetivo. (Montgomery & Johnson, 1976)

Os métodos quantitativos ou de previsão estatística definem explicitamente como a previsão é determinada. A lógica é claramente determinada e as operações são matemáticas. Os métodos envolvem análise de dados históricos para determinar o processo base gerando a variável e, assumindo que o mesmo é estável, usa deste conhecimento para extrapolar o processo para o futuro. Dois tipos básicos de modelos são usados: modelos de séries temporais e modelos causais. (Montgomery & Johnson, 1976)

Uma *série temporal* é uma seqüência ordenada no tempo de observações de uma variável. A análise de séries temporais usa somente a história da série temporal da variável a ser prevista para desenvolver um modelo para prever valores futuros. *Modelos causais* exploram a relação entre a série de tempo de interesse e uma ou mais outras series temporais. Se estas outras variáveis são correlacionadas com a variável de interesse e se mostra ser alguma causa para esta correlação, um modelo estatístico descrevendo esta relação pode ser construído. Então, conhecendo os valores das variáveis correlacionadas, pode-se usar o modelo para obter a previsão da variável dependente.

Neste trabalho serão apresentados os principais métodos quantitativos que usam modelos de séries temporais, pois estes proporcionam melhores resultados para previsões de médio e curto prazo, empregadas no planejamento da produção.

2.6.1 Análise de Séries Temporais

Uma série de tempo é uma seqüência de observações sobre uma variável de interesse. A variável é observada em pontos discretos de tempo, geralmente espaçados igualmente. (Montgomery & Johnson, 1976)

A análise de séries temporais examina o padrão do comportamento passado de um fenômeno no tempo e usa a análise para prever o seu comportamento futuro. (Slack *et al*, 1997).

Tal abordagem trabalha bem em ambientes estáveis, mas não reage a mudanças nos fatores industriais ou economia nacional. (Shafer & Meredith, 1998). É o método mais simples e usual de previsão, e quando bem elaborado oferece bons resultados (Tubino, 2000).

A análise de séries temporais assume que os dados históricos da demanda têm quatro componentes (Shafer & Meredith, 1998):

- **Tendência:** é a direção a longa distância da série, incluindo qualquer quantidade constante de demanda nos dados.

Na análise de séries temporais tem-se como finalidades de se isolar a tendência identificá-la e usá-la em previsões; e removê-la de modo a estudar as outras componentes. Quando a tendência está presente ela pode obscurecer as variações sazonais e cíclicas.

A direção de longo prazo é muito importante para a empresa, pois se a tendência é de aumento pode indicar uma necessidade de expansão; e se a tendência é de queda pode indicar a necessidade de esquemas promocionais, pesquisa de novos produtos, redução de orçamento, etc.

Estratégias de curto prazo, em geral dependem mais de fatores sazonais do que de uma tendência a longo prazo. (Albernaz, 2002)

- **Variação sazonal:** são flutuações regulares que se repetem em períodos quase sempre coincidindo com o calendário anual, mensal ou semanal. Resultam primariamente por naturalidade, mas também podem ser causadas pelo comportamento humano.

- **Variação cíclica:** o ciclo ou componente cíclico é óbvio somente em séries que transpõem vários anos. Um ciclo pode ser definido como uma oscilação de longo-prazo, ou um impulso de dados sobre a linha de tendência durante um período de pelo menos três estações completas. Para a maioria das atividades operacionais, a previsão para o componente cíclico não é considerada, desde que os dados estejam tipicamente indisponíveis para determinar o ciclo. Em adição, os ciclos não são provavelmente repetidos em amplitude e duração similar.

- **Variação aleatória:** as variações deste tipo são sem uma causa específica e sem um padrão. São as flutuações deixadas na série temporal depois da tendência, sazonalidade e variação cíclica terem sido consideradas.

O objetivo da análise de séries temporais é determinar a magnitude de um ou mais componentes e usar este conhecimento para o propósito de previsão.

A Figura 5 apresenta os componentes da série temporal descritos anteriormente.

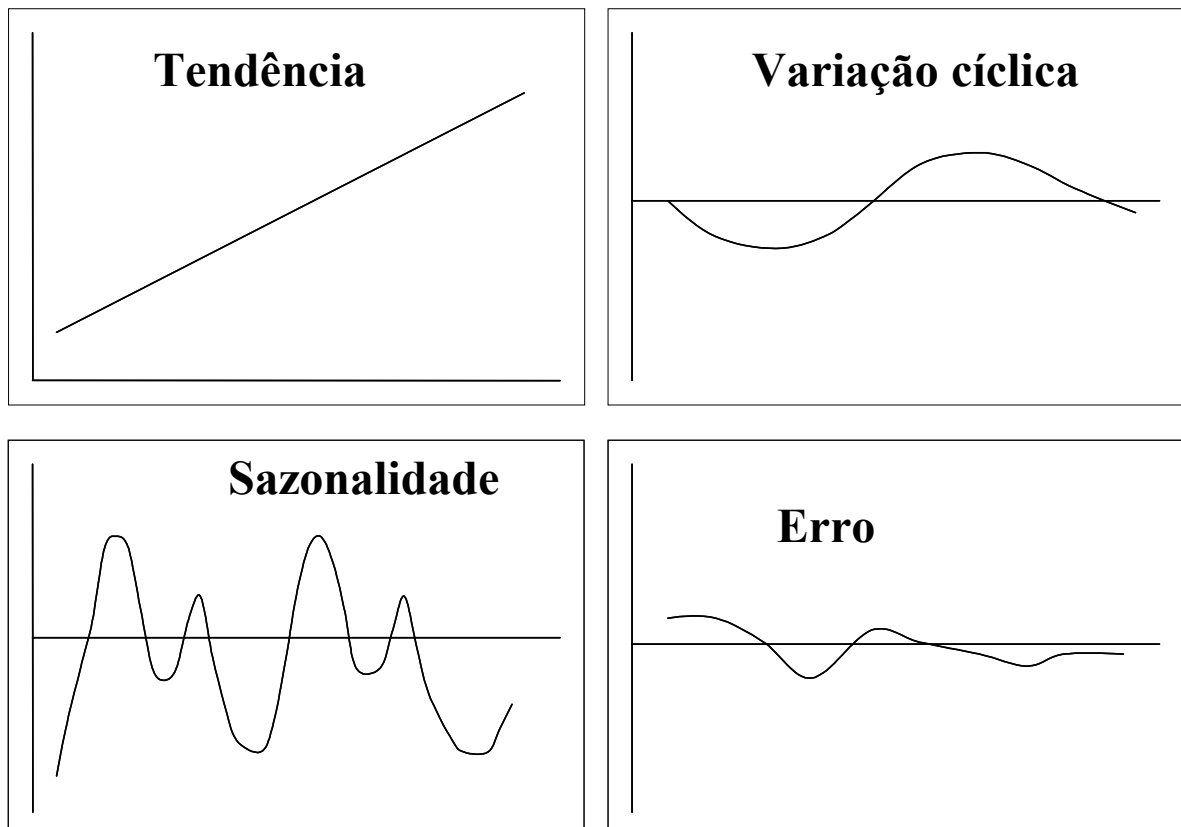


Figura 5. Componentes da série temporal.

2.6.2 Métodos de análise de séries temporais

A seguir são descritos alguns métodos tradicionais de análise de series temporais comumente encontrados na bibliografia, como métodos de amaciamento e decomposição de série temporais.

a) Métodos de amaciamento

A base dos métodos de amaciamento é a ponderação simples ou amaciamento das observações passadas de uma série temporal com objetivo de se obter a previsão. As maiores vantagens dos métodos de amaciamento são seu baixo custo, a facilidade de aplicação e a rapidez na qual podem ser adotados. Estas características os fazem particularmente atrativos quando um grande número de itens deve ser previsto e quando o horizonte de tempo é relativamente curto (menor que um ano). Incluem métodos baseados em médias e métodos de amaciamento exponencial. (Wheelwright & Makridakis, 1985)

Média móvel simples

A média móvel usa dados de um número pré-determinado de períodos, normalmente os mais recentes, por exemplo, os últimos quatro meses, para gerar a previsão. A cada novo período de previsão se substitui o dado mais antigo pelo mais recente. É obtida pela seguinte equação (Tubino, 2000):

$$Mm_n = \frac{\sum_{i=1}^n D_i}{n} \quad (2.9)$$

onde:

Mn_n = média móvel de n períodos

D_i = demanda ocorrida no período i

n = número de períodos (varia de 4 a 7, de acordo com Slack *et al*, 1997)

i = índice do período ($i = 1, 2, 3, \dots$)

A grande vantagem do uso da média móvel para previsões consiste em sua simplicidade operacional e facilidade de entendimento.

Se a demanda de um produto não cresce nem decresce rapidamente, e se também não apresenta nenhuma característica sazonal, uma média móvel pode ser útil na identificação de uma tendência dentro da flutuação dos dados (Davis *et al*, 1997).

Média móvel ponderada

Considerando que a média móvel simples atribui peso igual para cada componente da série de dados, uma média móvel ponderada permite a cada componente ser ponderado por um fator, no qual a soma de todos os pesos é igual a um.

A fórmula para a previsão por média móvel ponderada é (Davis *et al*, 1997):

$$M_t = \frac{w_{t-1}D_{t-1} + w_{t-2}D_{t-2} + \dots + w_{t-n}D_{t-n}}{n} \quad (2.10)$$

onde:

M_t = previsão para o período t

D_{t-1} = demanda do período t-1

w_{t-1} = peso atribuído ao período t-1

n = número de períodos relacionados na média

A média móvel ponderada tem uma grande vantagem sobre a média móvel simples em ser capaz de variar os efeitos entre os dados antigos e os mais recentes. A desvantagem da média móvel ponderada é a de que se precisa determinar os pesos a serem utilizados.

Média móvel exponencial ou amaciamento exponencial

Na média móvel exponencial, cada nova previsão é obtida com base na previsão anterior, acrescida do erro cometido na previsão anterior, corrigido pelo coeficiente de amaciamento. A equação a seguir apresenta esta situação (Tubino, 2000):

$$M_t = M_{t-1} + \alpha(D_{t-1} - M_{t-1}) \quad (2.11)$$

onde:

M_t = previsão para o período t

M_{t-1} = previsão para o período t-1

D_{t-1} = demanda do período t-1

α = coeficiente de amaciamento

Conforme Slack *et al* (1997), o valor de α determina o equilíbrio entre a sensibilidade das previsões às mudanças na demanda e a estabilidade das previsões. Quanto mais próximo de zero,

tanto mais as previsões serão amortecidas pelas previsões anteriores (não muito sensíveis, mas mais estáveis).

Método de Holt

O Método de Holt é baseado no amaciamento exponencial. Pode ser utilizado, de maneira satisfatória, em séries temporais com tendência linear. Este modelo emprega duas constantes de suavização, α e β (com valores entre 0 e 1), sendo representado por três equações (Pellegrini, 2000):

$$L_t = \alpha z_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (2.12)$$

$$T_t = \beta (L_t - L_{t-1}) + (\beta - 1)T_{t-1} \quad (2.13)$$

$$\hat{z}_{t+k} = L_t + kT_t \quad (2.14)$$

As equações (2.12) e (2.13) fazem uma estimativa do nível e da inclinação da série temporal, respectivamente. Já a equação (2.14), calcula a previsão da demanda para os próximos k períodos.

Método de Winters

Os modelos de Winters, freqüentemente chamados de Método de Winters, descrevem apropriadamente dados de demanda onde se verifica a ocorrência de tendência linear, além de um componente de sazonalidade.

O método de Winters será apresentado detalhadamente na seção 2.7.3, a qual apresenta métodos especiais para series temporais com características sazonais.

Análise de regressão linear

É utilizada para definir um relacionamento funcional entre duas ou mais variáveis correlacionadas. O relacionamento é desenvolvido a partir de um dado observado no qual um parâmetro (a variável independente) é usado para predizer outro (a variável dependente). A equação para a regressão linear simples inclui somente uma variável independente (Davis *et al*, 1997):

$$Y = a + bX \quad (2.15)$$

onde:

Y = variável dependente
 a = intersecção no eixo Y
 b = inclinação
 X = variável independente

A principal restrição em se utilizar este método é considerar que os dados do passado e as projeções futuras devem se situar próximos a uma linha reta.

Análise de regressão polinomial

A regressão polinomial é representada pela seguinte equação (Gil, 2002):

$$Y = \alpha_0 + \alpha_1 X + \alpha_2 X^2 + \dots + \alpha_k X^k \quad (2.16)$$

onde:

Y = variável dependente
 X = variável independente
 α = parâmetros (coeficientes do polinômio)
 k = ordem do polinômio

Consiste em determinar os parâmetros de uma função que se ajuste a um conjunto de pontos, utilizando um método de otimização, como o método dos mínimos quadrados. O método dos mínimos quadrados baseia-se na minimização da função constituída pelo somatório dos quadrados dos desvios:

$$S = \sum_{i=1}^n (y_i - \hat{Y}_i)^2 \quad (2.17)$$

onde:

y_i - valor de y correspondente ao valor x_i . É o valor observado.

\hat{Y}_i - valor obtido por substituição de cada x na equação da função. É a estimativa do valor.

b) Métodos de decomposição

Os métodos de amaciamento são baseados no conceito de que quando existe um padrão na série de dados, este padrão pode ser distinguido do erro pelo amaciamento dos valores passados. O efeito deste amaciamento é eliminar o erro para que o padrão possa ser projetado no futuro e usado como previsão. Estes métodos não fazem nenhum esforço para identificar componentes individuais do padrão. Em muitos casos, o padrão pode ser decomposto em

subpadrões que identificam cada componente da série de tempo separadamente. Tal decomposição pode frequentemente facilitar a melhoria da acurácia da previsão e ajudar no melhor entendimento do comportamento da série. (Wheelwright & Makridakis, 1985)

Os métodos de decomposição decompõem a série de tempo em seus componentes. Desta forma, além de tentar prever um padrão comum, um esforço a parte é feito para prever o padrão sazonal, de tendência e cíclico, e suavizar o erro. Fazer previsão usando estes métodos envolve extrapolar cada componente separadamente e recombina-los em uma previsão final. Os métodos de decomposição são frequentemente úteis não somente em prover previsões, mas também informações a respeito dos componentes da série de tempo e o impacto de vários fatores, como sazonalidade e ciclicidade, sobre os resultados observados. (Makridakis *et al*, 1983)

Entre os métodos de decomposição estão o método clássico e suas variantes como o Census II. No item 2.7.3 será descrito o método clássico de decomposição, bastante útil para tratar séries de dados sazonais.

Há vários outros métodos disponíveis em literatura, como os métodos de Box-Jenkins, redes neurais, entre outros. Estes métodos são mais complexos e não serão abordados em detalhes neste trabalho.

O *Método de Box-Jenkins* constitui-se em importante ferramenta para solução de problemas de previsão. A metodologia Box-Jenkins gera previsões acuradas da série temporal e oferece uma abordagem bem estruturada para a construção e análise do modelo. (Pellegrini, 2000)

Porém, estes modelos possuem algumas limitações (Montgomery *et al*, 1990):

- De maneira geral, são necessárias pelo menos 50 observações para o desenvolvimento de um modelo aceitável de Box-Jenkins. Este fato pode impossibilitar a obtenção dos modelos em situações onde não existem muitas observações disponíveis;
- Não existe uma maneira fácil de modificar (ou melhorar) as estimativas dos parâmetros do modelo quando novas observações são acrescentadas à série de dados;
- O tempo despendido na construção de um modelo satisfatório costuma ser grande. Existem situações em que centenas, ou talvez milhares de séries temporais estão em estudo, o que pode inviabilizar economicamente a realização de melhorias na acurácia das previsões.

As *Redes Neurais* representam uma área relativamente nova e crescente de previsão. Diferentemente das técnicas de previsões estatísticas comuns, como análise de séries temporais, as redes neurais simulam o aprendizado humano. Desta forma, com o passar do tempo e com o uso repetido, as redes neurais podem desenvolver um entendimento dos relacionamentos complexos que existem entre as entradas e saídas de um modelo de previsão (Davis *et al*, 1997).

A propriedade mais importante das redes neurais é a sua capacidade de “aprender”, ou seja, reconhecer padrões e regularidades nos dados. Uma vez feito o aprendizado, a rede está apta a melhorar seu desempenho, e então extrapolar quanto a um comportamento futuro. (Pellegrini, 2000).

Em muitos casos, as redes neurais conseguem modelar irregularidades em séries temporais de forma superior a modelos tradicionais. Porém, este método necessita um número maior de dados observados na série temporal e nem sempre se consegue entender o que se passa na modelagem, pois não existe um modelo explícito (Makridakis *et al*, 1998).

2.7 Sazonalidade

Pino *et al* (1994) fizeram um levantamento do estado da arte sobre sazonalidade, onde cita sobre a definição de sazonalidade o seguinte:

“Embora nem sempre esteja claro o que significa realmente a sazonalidade, quer conceitual quer estatisticamente (Pierce, 1980b), pode-se tentar defini-la como o conjunto dos movimentos ou flutuações com período igual ou inferior a um ano, ‘sistemáticos, mas não necessariamente regulares’ (Wallis & Thomas, 1971), que ocorrem numa série temporal. Alguns autores referem-se a sazonalidade como flutuações periódicas regulares que se repetem todo ano, mais ou menos ao mesmo tempo e com a mesma intensidade (Kallek, 1978; Hillmer & Tiao, 1982).”

Conforme Slack *et al* (1997), quase todos os produtos e serviços possuem alguma sazonalidade na demanda. Em alguns casos, esta sazonalidade se estende aos insumos, principalmente quando estes são oriundos da agricultura sazonal. Estas flutuações na demanda podem ser razoavelmente previsíveis, entretanto algumas são afetadas por variações inesperadas no clima e por evolução das condições econômicas.

Slack *et al* (1997) citam algumas causas da sazonalidade: climáticas, datas comemorativas, comportamentais, políticas, financeiras e sociais; e alguns exemplos de produtos

sazonais: bebidas (cervejas, refrigerantes), alimentos (sorvetes, ovos de Páscoa, bolos de Natal) e vestuário (maiôs, sapatos).

Em resumo, a variação sazonal numa variável econômica é o resultado de causas naturais, econômicas, sociais e institucionais (Pierce, 1980b; Granger, 1978; Grether & Nerlove, 1970) *apud* (Pino *et al*, 1994).

Os processos de ajustamento sazonal são largamente empregados na análise de dados econômicos (Sutradhar *et al*, 1995). Existem dois interesses principais no ajustamento sazonal: o *estudo da sazonalidade* propriamente dita e a *remoção da sazonalidade da série* para depois estudá-la em seus demais aspectos. Este último é o que está presente na maioria dos trabalhos, nos quais está implícita a idéia de que a existência de movimentos sazonais afeta o reconhecimento e a interpretação de importantes movimentos não-sazonais numa série, tais como: mudanças de tendência e outros eventos cíclicos, padrões emergentes ou ocorrências inesperadas para os quais possíveis causas são procuradas (Pierce, 1980b) *apud* (Pino *et al*, 1994). Ainda, os componentes sazonais podem representar o efeito de fatores não-econômicos que são exógenos ao sistema econômico e, portanto são incontroláveis. (Sutradhar *et al*, 1995)

Kallek (1978) *apud* (Pino *et al*, 1994) propõe remover tanto quanto possível a sazonalidade da série, a fim de se poder estudar a componente ciclo-tendência. Entretanto, de acordo com Pino *et al* (1994), alguns autores argumentam que o estudo da sazonalidade pode ter importância própria, como para comparar valores de uma variável em diferentes épocas do ano (Gait, 1975), para estudar conjuntamente os movimentos sazonais e os movimentos econômicos cíclicos (Barsky & Miron, 1989), ou para prever séries mensais (Kallek, 1978).

Há vários métodos disponíveis para desazonalizar séries de tempo. Contudo, há situações onde a sazonalidade em séries temporais pode não ser significativa. Em tais casos o ajustamento para sazonalidade é desnecessário. Isto sugere testes para a presença de sazonalidade significativa na série de tempo antes de fazer o ajuste sazonal.

2.7.1 Teste para sazonalidade

Morettin & Tolo (1981) apresentam alguns testes no domínio de tempo para a existência de sazonalidade, nos quais são testadas as hipóteses: H_0 : não existe sazonalidade e H_1 : existe sazonalidade nos dados.

A existência de sazonalidade pode ser testada antes ou depois da estimação da componente sazonal. Entre os testes, os autores apresentam o teste de Kruskal-Wallis e o teste de

Friedman (testes não paramétricos) e um teste F rotineiro como em uma análise de variância (teste paramétrico). Antes da aplicação dos testes, os autores recomendam a eliminação da tendência caso ela esteja presente na série.

No caso do modelo aditivo, por exemplo, o teste F pode ser aplicado aos resíduos de

$$Y_t = Z_t - \hat{T}_t \quad (2.18)$$

onde,

Y_t = série de dados sem tendência

Z_t = série de dados original

\hat{T}_t = tendência estimada

Dado o modelo: $Y_{ij} = S_j - e_{ij}$, $i=1, \dots, n_j$; $j=1, \dots, s$

Supondo $e_{ij} \approx N(0, \sigma^2)$, ou seja, os erros normalmente distribuídos, independentes, com média zero e variância constante, pode-se testar:

$$H_0: S_1 = S_2 = \dots = S_s \text{ (isto é, não existe sazonalidade)}$$

$$H_1: S_i \neq S_j, \text{ para algum } i \text{ e } j \text{ (isto é, existe sazonalidade)}$$

A estatística do teste é dada por:

$$T = \frac{N-s}{s-1} \cdot \frac{\sum_{j=1}^s n_j (\bar{Y}_j - \bar{Y})^2}{\sum_{j=1}^s \sum_{i=1}^{n_j} (Y_{ij} - \bar{Y}_j)^2} \quad (2.19)$$

que tem, sob H_0 , distribuição F com $s-1$ e $N-1$ graus de liberdade.

Freitas & Amaral (2002) analisaram o comportamento dos preços de amendoim através do ajustamento sazonal pelo Método X-11. Para avaliar a hipótese de existir sazonalidade na série de preços o teste F foi aplicado sobre os índices de sazonalidade, obtidos a partir dos resultados do Método X-11. Inicialmente foi testada a hipótese de existir sazonalidade na série, isto é, H_0 : não existe sazonalidade na série de preços e H_a : existe sazonalidade na série de preços. Para o cálculo do teste F considerou-se nível de significância mínimo de 1%.

Para identificar a sazonalidade em uma série de tempo, o Método X-11-ARIMA, uma versão atualizada do Método X-11, usa os resultados do teste F usual em uma análise de variância de fator único de variação entre-estação dos termos sazonal mais irregular obtidos da decomposição da série de dados pelo referido método. (Sutradhar *et al*, 1995)

2.7.2 Amplitude da sazonalidade

Quando a sazonalidade faz-se presente na série de dados deve-se observar a seguinte característica: se ela é aditiva ou multiplicativa. No caso aditivo, a série mostra uma flutuação sazonal estável, sem levar em consideração o nível médio da série; no caso multiplicativo, o tamanho da flutuação sazonal varia, dependendo do nível médio da série. Sendo assim, tem-se o modelo sazonal aditivo e o modelo sazonal multiplicativo (Montgomery & Johnson, 1976):

$$\text{Modelo sazonal aditivo: } X_t = T_t + S_t + e$$

$$\text{Modelo sazonal multiplicativo: } X_t = T_t \cdot S_t + e$$

onde,

X_t = dados da demanda ou observações da série temporal

T_t = componente de tendência

S_t = componente sazonal

e_t = erro aleatório

A Figura 6 apresenta o comportamento da sazonalidade aditiva e da sazonalidade multiplicativa.




Figura 6. Sazonalidade aditiva e sazonalidade multiplicativa.

2.7.3 Métodos para previsão de séries temporais sazonais

Há várias abordagens para análise de dados com características sazonais. Os modelos de amaciamento de dados sazonais, como o Método de Winters, são provavelmente os mais amplamente usados na prática (Montgomery & Johnson, 1976).

O método de decomposição clássica e suas variantes (a variante do Método Census II – X-11 dos US Bureau of the Census desenvolvido por Shiskin *et al.* (1967) e a versão X-11-ARIMA desenvolvida por Dagum (1975,1980) *apud* (Sutradhar *et al.*, 1995)) são amplamente

usados por agências governamentais e *bureau's* de estatística. Estes métodos de ajustamento sazonal são baseados principalmente em técnicas de média móvel.

a) Modelo de amaciamento para dados sazonais

Entre os modelos de previsão para séries temporais sazonais, os mais extensamente conhecidos e usados são os modelos propostos por Winters, freqüentemente chamados de método de Winters, um para sazonalidade aditiva e outro para sazonalidade multiplicativa. Este último tem sido implementado com freqüência em *softwares* de previsão. (Koehler *et al*, 2001)

O método de Winters para sazonalidade multiplicativa, de interesse para este trabalho, será descrito a seguir. Para informações sobre o método aditivo ver (Montgomery & Johnson, 1976).

Modelo sazonal multiplicativo

Assume-se que a série de tempo é adequadamente representada pelo modelo

$$x_t = (b_1 + b_2 t)c_t + \varepsilon_t \quad (2.20)$$

onde:

b_1 = componente permanente

b_2 = componente de tendência linear

c_t = fator sazonal multiplicativo

ε_t = componente do erro aleatório

O comprimento da estação é L períodos, e os fatores sazonais são definidos de forma que eles somem o comprimento da estação, isto é,

$$\sum_{t=1}^L c_t = L \quad (2.21)$$

Este modelo incorpora a tendência linear e o efeito sazonal. O modelo sazonal multiplicativo é apropriado para as séries de tempo nas quais a amplitude (ou altura) do padrão sazonal é proporcional ao nível da média da série.

Denota-se a estimativa da inclinação e do componente sazonal no final de qualquer período de tempo, dito T , como $\hat{b}_2(T)$ e $\hat{c}_T(T)$, respectivamente. O componente permanente será estabelecido sobre uma base de origem corrente, e sua estimativa no final do período T , $\hat{a}_1(T)$. O procedimento para atualização periódica da estimativa dos parâmetros do modelo e

com o intuito de previsão é relativamente simples. No final do período corrente T , depois de observar a realização para aquele período, x_T , poder-se-á realizar os seguintes cálculos:

1. Atualizar a estimativa do componente permanente:

$$\hat{a}_1(T) = \alpha \frac{x_T}{\hat{c}_T(T-L)} + (1-\alpha) [\hat{a}_1(T-1) \hat{b}_2(T-1)] \quad (2.22)$$

onde $0 < \alpha < 1$ é a constante de amaciamento. Dividindo x_T por $\hat{c}_T(T-L)$, o qual é a estimativa do fator sazonal para o período T computado uma estação (L períodos) atrás, desazonaliza-se os dados para que somente o componente de tendência e o valor anterior do componente permanente entrem no processo de atualização para $\hat{a}_1(T)$. Isto muda a origem de tempo para o final do período corrente.

2. Atualizar a estimativa do componente de tendência:

$$\hat{b}_2(T) = \beta [\hat{a}_1(T) - \hat{a}_1(T-1)] + (1-\beta) \hat{b}_2(T-1) \quad (2.23)$$

onde $0 < \beta < 1$ é segunda constante de amaciamento. A estimativa do componente de tendência é simplesmente a diferença amaciada entre duas estimativas sucessivas do componente permanente.

3. Atualizar a estimativa do fator sazonal para o período T :

$$\hat{c}_T(T) = \gamma \frac{x_T}{\hat{a}_1(T)} + (1-\gamma) \hat{c}_T(T-L) \quad (2.24)$$

onde $0 < \gamma < 1$ é a terceira constante de amaciamento. A variação sazonal corrente observada, isto é, $\frac{x_T}{\hat{a}_1(T)}$, é amaciada com a estimativa do fator sazonal para o período T computado L períodos atrás, o qual era a última oportunidade para observar esta porção do padrão sazonal, para obter uma nova estimativa do efeito sazonal no período T . Como revisa-se as estimativas do fator sazonal, elas podem não adicionar-se ao comprimento da estação. Uma possível modificação do método de Winters é “normalizar” os fatores sazonais no final de cada estação.

4. Para prever a observação em qualquer período futuro $T + \tau$, calcular:

$$x_{T+\tau}(T) = [\hat{a}_1(T) + \hat{b}_2(T)] \hat{c}_{T+\tau}(T+\tau-L) \quad (2.25)$$

Novamente, deve-se lembrar que a quantidade em parênteses para $\hat{a}_1(\cdot)$, $\hat{b}_2(\cdot)$ e $\hat{c}_i(\cdot)$ indica o tempo de cálculo da estimativa. Desta forma, para prever o período $T + \tau$, precisa-se do

fator sazonal para o período $T + \tau$, o qual foi calculado no período $T + \tau - L$. Previsões para períodos de tempo mais distantes do que L podem ser feitos usando novamente $\hat{c}_t(\cdot)$ apropriado.

O desenvolvimento de um sistema de previsão usando o método de Winters requer valores iniciais dos parâmetros $\hat{a}_1(0)$, $\hat{b}_2(0)$ e $\hat{c}_t(0)$ para $t = 1, 2, \dots, L$. Informação histórica, se disponível, pode ser usada para fornecer alguma ou todas as estimativas iniciais. Supondo-se que os dados para as últimas m estações estão disponíveis, e permitindo que \bar{x}_j , $j = 1, 2, \dots, m$, denote a média das observações durante a estação j -ésima, estima-se o componente de tendência por

$$\hat{b}_2(0) = \frac{\bar{x}_m - \bar{x}_1}{(m-1)L} \quad (2.26)$$

O componente permanente no início do primeiro período poderá ser estimado por

$$\hat{a}_1(0) = \bar{x}_1 - \frac{L}{2} \hat{b}_2(0) \quad (2.27)$$

Os fatores sazonais são computados para cada período de tempo $t = 1, 2, \dots, mL$, como a razão entre a observação atual e o valor da média sazonalmente ajustada para aquela estação, além de ajustada pela tendência; isto é,

$$\hat{c}_t = \frac{x_t}{\bar{x}_i - [(L+1)/2 - j] \hat{b}_2(0)}, \quad t = 1, 2, \dots, mL \quad (2.28)$$

onde \bar{x}_i é a média para a estação correspondente ao índice t , e j é a posição do período t dentro da estação. A equação acima produzirá m estimativas do fator sazonal para cada período. Destas deverá ser calculada a média para produzir uma estimativa simples do fator sazonal para cada período dentro da estação. Isto é efetuado por

$$\bar{c}_t = \frac{1}{m} \sum_{k=0}^{m-1} \hat{c}_{t+kL}, \quad t = 1, 2, \dots, L \quad (2.29)$$

Finalmente, os fatores sazonais deverão ser normalizados para que eles somem iguais a L . Isto produz uma estimativa inicial dos fatores sazonais como:

$$c_t(0) = \bar{c}_t \frac{L}{\sum_{t=1}^L \bar{c}_t}, \quad t = 1, 2, \dots, L \quad (2.30)$$

b) Método de decomposição clássica

De acordo com Wheelwright & Makridakis (1985), os métodos de decomposição geralmente tentam identificar separadamente três componentes do padrão base que tendem a caracterizar séries econômicas e de negócios. Estes são tendência, ciclo e os fatores sazonais. A tendência representa o comportamento a longo prazo dos dados e pode ser crescente, decrescente ou imutável. Frequentemente, pode ser aproximada por uma linha reta, mas uma exponencial, curva S, ou algum outro padrão de longo prazo pode existir em certas situações. O fator cíclico representa os altos e baixos da economia ou de uma indústria específica. O ciclo frequentemente segue um padrão de uma onda, passando de um grande para um pequeno valor e volta novamente para um valor grande. O fator sazonal relaciona-se a flutuações periódicas de comprimento constante que são causadas por temperatura, chuvas, mês do ano, feriados e políticas corporativas. A distinção entre sazonalidade e ciclo é que a sazonalidade repete-se em intervalos fixos tais como um ano, um mês ou uma semana, enquanto os fatores cíclicos têm uma duração longa que varia de ciclo para ciclo.

A decomposição assume que os dados consistem de:

$$\text{dados} = \text{padrão} + \text{erro} = f(\text{tendência, ciclo, sazonalidade}) + \text{erro}$$

Desta forma, em adição aos componentes do padrão, um elemento de erro ou aleatoriedade é também assumido estar presente. Este erro é suposto ser a diferença entre o efeito combinado do três subpadrões da série e os dados atuais.

Há várias abordagens para decompor series de tempo, todas com o objetivo de isolar cada componente da série tão acuradamente quanto possível. O conceito básico em tal separação é empírico e consiste da remoção primeiro da sazonalidade, então a tendência, e finalmente o ciclo. Qualquer resíduo é suposto ser aleatório, o qual, enquanto não pode ser predito, pode ser identificado. Há um número de pontos fracos teóricos na abordagem de decomposição que são problemas de um ponto de vista estatístico. Contudo, os usuários têm ignorado estes pontos falhos e têm aplicado a abordagem com considerável sucesso.

A representação matemática geral da abordagem da decomposição é

$$X_t = f(S_t, T_t, C_t, E_t)$$

onde,

X_t é o valor da série de tempo (dado atual) no período t,

S_t é o componente sazonal (ou índice) no período t,

T_t é o componente de tendência no período t

C_t é o componente cíclico no período t,

E_t é o componente aleatório (ou erro) no período t.

A relação funcional específica usada para relatar estes quatro subpadrões podem tomar uma variedade de formas. As mais diretas são a aditiva (simplesmente soma os quatro elementos) e a multiplicativa (faz o produto dos quatro elementos). A forma multiplicativa é a mais comumente usada.

$$\text{Modelo aditivo: } X_t = S_t + T_t + C_t + E_t$$

$$\text{Modelo multiplicativo: } X_t = S_t \cdot T_t \cdot C_t \cdot E_t$$

Uma vez realizada a decomposição da série temporal, sua previsão para períodos futuros é feita a partir do reagrupamento das previsões individuais dos componentes. Uma vez que o componente de ruído aleatório não é modelável, seu valor é igualado a zero no modelo aditivo, e um no modelo multiplicativo. (Pelligrini, 2000)

A decomposição pode frequentemente melhorar a acurácia da previsão e auxiliar em melhor entendimento do comportamento da série. A aplicabilidade destes modelos se deve ao fato que padrões na série podem ser melhor visualizados após a decomposição da mesma.

Os passos que devem ser seguidos na aplicação do método de decomposição clássico de previsão são resumidos a seguir. Para mais detalhes ver bibliografias de Wheelwright & Makridakis (1985) e Makridakis *et al* (1983).

Os primeiros três passos envolvem a identificação da sazonalidade, da tendência e do fator cíclico. No passo final estes três fatores são aplicados na previsão.

1. Para a série atual, X_t , calcular a média móvel cujo comprimento, N , é igual ao comprimento da sazonalidade. O propósito desta média móvel é eliminar a sazonalidade e a aleatoriedade;
2. Separar o resultado da média móvel do passo 1 dos dados da serie original para obter a tendência e o ciclo;
3. Isolar os fatores sazonais calculando a média deles para cada período que compõem o comprimento da sazonalidade;
4. Identificar a forma apropriada da tendência (linear, exponencial, etc.) e calcular seu valor para cada período, T_t ;
5. Separar o resultado do passo 4 daquele do passo 2 (o valor combinado de tendência e ciclo) para obter o fator cíclico;
6. Separar a sazonalidade, a tendência e o ciclo dos dados originais para isolar a aleatoriedade remanescente, E_t ;
7. Preparar a previsão, estimando cada componente para o período futuro e reagrupando-os.

2.8 Softwares de previsão de demanda

Embora haja uma tendência recente de integração de módulos de previsão em sistemas logísticos e de ERP, existem diversos produtos no mercado voltados para o problema das previsões. Estes produtos são classificados em três categorias: automáticos, semi-automáticos e manuais. Os softwares automáticos, como o nome diz, fazem praticamente sozinhos a tarefa de analisar séries e recomendar o método de previsão mais adequado à situação em estudo com base em critérios estatísticos. Embora representem uma boa opção, eles tendem a ser utilizados como caixas pretas em que o usuário tem pouca ou nenhuma possibilidade de intervenção no processo, aceitando ou não os seus resultados. Um dos produtos mais conhecidos desta categoria é o software *Forecast Pro* cuja versão mais completa custa cerca de US\$1000,00. Os softwares semi-automáticos de previsão são, em princípio, softwares estatísticos como o *SPSS*, *SAS* ou econométricos como o *EViews*. Neste caso, o usuário faz uma seleção prévia dos métodos a serem testados em seu problema, deixando ao computador a escolha dos parâmetros ótimos que minimizam o erro de previsão. A escolha do método mais adequado é feita pelo usuário com base nos resultados dos vários testes. Finalmente, os softwares manuais são aqueles em que o usuário define o método de previsão a ser testado e os respectivos parâmetros; o software é utilizado unicamente para avaliar o desempenho do método proposto. Neste caso, há necessidade de um maior conhecimento técnico por parte do usuário, mas em compensação tem-se um maior controle do processo de previsão (Saliby, 2002).

Pellegrini (2000) distingue os softwares em pacotes computacionais estatísticos de uso genérico e pacotes computacionais específicos.

2.8.1 Pacotes computacionais estatísticos de uso genérico

A maioria dos pacotes estatísticos genéricos apresentam uma opção de análise de previsão. Tais pacotes são recomendados a usuários que demandam uma análise estatística e gráfica detalhada dos dados. Entre os pacotes estatísticos genéricos mais difundidos, três são abordados na seqüência: *NCSS*, *Statgraphics* e *SPSS*. A análise destes pacotes limita-se aos seus módulos de previsão.

O *NCSS* (*Number Cruncher Statistical System*) possui, em seu módulo de previsão, a possibilidade de uso dos modelos ARIMA, suavização exponencial e decomposição. O relatório

de resultados da análise traz um grande número de informações, não disponíveis nos demais pacotes aqui abordados.

O *Statgraphics* também possui as opções dos modelos de decomposição, ARIMA e suavização exponencial no seu módulo de previsão, apresentando uma melhor interface de utilização, se comparado ao NCSS.

O *SPSS (Statistical Package for Social Science)* é o melhor dentre os três pacotes genéricos aqui abordados. O programa oferece, no seu módulo de previsão, as opções dos modelos de decomposição, ARIMA, suavização exponencial, regressão com erros dos modelos ARIMA e X-11 ARIMA.

2.8.2 Pacotes Computacionais Específicos

Os pacotes computacionais específicos para análise de previsão contêm apenas as ferramentas estatísticas necessárias para a análise das séries temporais e geração das previsões. Sua vantagem se dá em relação as técnicas de previsão não encontradas em pacotes de uso genérico. Entre os pacotes específicos para análise de previsão, destacam-se o *Forecast Pro* e o *Autobox*.

O *Forecast Pro* oferece a opção de escolha automática do modelo que melhor se adequar a uma série temporal. Para tanto, faz uma comparação entre os modelos ARIMA, suavização exponencial e X-11 ARIMA. O pacote também permite ao usuário a seleção do critério utilizado para comparação dos modelos obtidos em cada série. Uma outra característica importante do pacote é a possibilidade de fazer, simultaneamente, a previsão de um grande número de séries temporais em poucos segundos.

O *Autobox* é um software especializado nas técnicas de previsão de modelos tipo Box-Jenkins. É um software automático de previsão.

Oliveira (2002) cita ainda como programas tradicionais de estatística que apresentam, além da estatística em geral, um módulo para análise, ajustamento e previsão de séries temporais o *Statistica* e o *Minitab*. Exemplos de pacotes computacionais específicos para previsão citados pelo mesmo autor incluem o *PP-autocast* e o *SmartForecasts*.

O *Statistica* apresenta uma larga escolha de ferramentas de modelação e previsão (por ex. modelos lineares, modelos lineares/não lineares generalizados, séries cronológicas e previsão), incluindo seleção automática de modelos e ferramentas de visualização interativas.

O *Minitab* apresenta um módulo específico para previsão de séries temporais, incluindo diversos métodos.

O *PP-autocast* utiliza alisamento exponencial e amortecimento da tendência.

O *SmartForecasts* utiliza modelos de amaciamento. Permite a intervenção do usuário para ajuste das previsões estatísticas afim de que reflitam o conhecimento do negócio e as informações recentes do mercado. Cria previsões para grupos contendo centenas ou milhares de itens.

Além dos softwares citados anteriormente estão disponíveis no mercado inúmeros outros, como:

ForecastX: usa mais de 30 técnicas de previsão incluindo previsão de séries temporais e ARIMA, além de previsão para novos produtos e modelagem de eventos.

Fourcast: analisa séries temporais.

Muitas empresas optam por desenvolver seus próprios pacotes computacionais de previsão, como foi o caso da Sadia. A empresa Unisoma desenvolveu para a Sadia, em 1994, um Sistema de Previsão de Demanda (SPD). Este sistema foi concebido como sendo uma ferramenta de apoio para a equipe comercial do grupo Sadia, permitindo analisar e estimar o comportamento do volume de venda de seus produtos baseado nos dados históricos de vendas. Os dados históricos que estão armazenados no computador central da corporação são exportados para uma rede de microcomputadores onde podem ser acessados pelos usuários através do SPD; este, utilizando técnicas de séries temporais aliadas a uma interface homem/máquina amigável, permite inúmeras análises e estudos de cenários.

Empresas do setor de alimentos como Perdigão e Bunge Alimentos também tem implantado seu próprio sistema de previsão de demanda.

CAPÍTULO 3

3 MÉTODO PROPOSTO

O presente capítulo descreve o método de previsão de demanda proposto neste trabalho. Este método tem como objetivo prover dados da demanda futura de produtos, a partir de dados de demandas passadas, para serem utilizados no desenvolvimento do planejamento da produção.

A implicação da previsão de demanda para o planejamento da produção foi abordada no capítulo anterior, porém vale ressaltar que é de grande importância que as empresas façam uso de métodos apropriados para obtenção de dados de vendas futuras, pois uma boa previsão e conseqüentemente um melhor planejamento, possibilitam melhor utilização dos recursos de produção e controle de estoques. A análise dos dados de vendas permite ainda conhecer o comportamento das vendas de determinado produto ou famílias de produtos em diferentes períodos de tempo e locais.

O método proposto compreende três etapas principais: a análise dos dados de entrada, a verificação da significância da sazonalidade presente nos dados e a aplicação do modelo matemático.

A primeira etapa analisa os dados de entrada, onde são feitas as considerações necessárias para que a modelagem matemática represente da melhor forma possível o comportamento dos dados da demanda e, conseqüentemente, gere uma melhor previsão.

A segunda etapa consiste na aplicação da análise de variância de fator único e do teste F aos dados de sazonalidade para verificar a significância desta frente ao erro. Caso a sazonalidade seja significativa deve ser considerada no processo de previsão da demanda.

A terceira etapa envolve a modelagem matemática do comportamento da demanda. O modelo, também proposto nesse trabalho, determina padrões para o comportamento da demanda, e como todos os modelos baseados na análise de séries temporais, admite que estes padrões se repetem, e extrapola-os para os períodos futuros.

O horizonte das previsões obtidas pelo método proposto pode alcançar um período de até um ano, variando de acordo com o *lead time* das decisões do planejamento da produção a serem tomadas ao longo da cadeia. Porém, quanto mais à frente do período atual, menos acuradas serão as previsões.

A Figura 7 apresenta o fluxograma do método de previsão de demanda proposto.

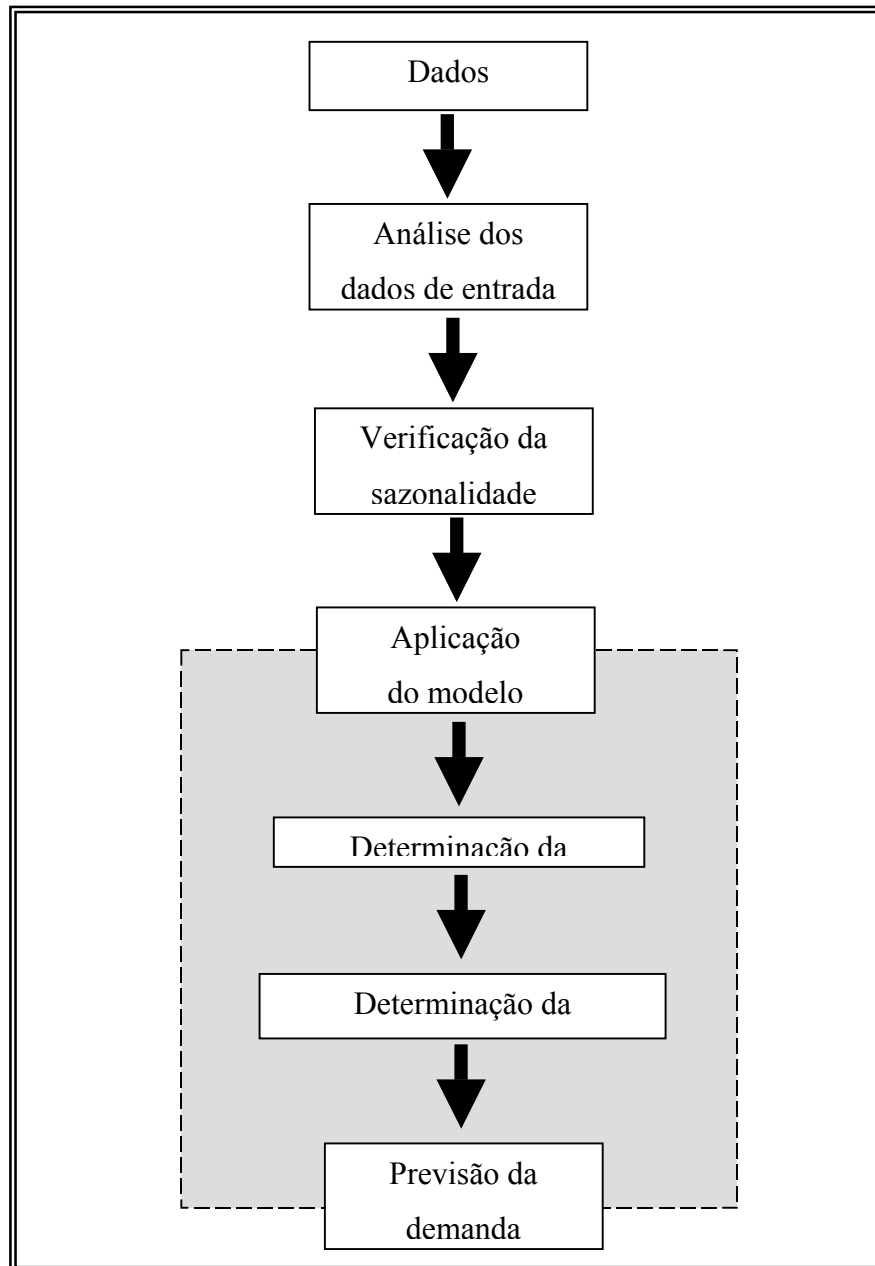


Figura 7. Fluxograma do método de previsão de demanda proposto.

Legenda: Delimitação do método



Delimitação do modelo



3.1 Análise dos dados de entrada

Os resultados das vendas devem suprir montantes suficientes para que a empresa continue operando de forma saudável. Contudo, há um retardo temporal entre os investimentos para cobrir as despesas e o surgimento dos resultados correspondentes as vendas. Do lado do suprimento ocorre quase o mesmo. As compras de matérias primas e materiais auxiliares da produção precisam ser providenciados com antecedência para que na hora de montar os produtos finais já se tenha tudo pronto. Ainda, na produção de alimentos quase 100% é feita para se manter estoques, já que o consumidor final exige abastecimento completo dos seus produtos de consumo. Mais grave para estes produtos é a vida de prateleira muito reduzida. Por esses motivos uma boa previsão de demanda é fundamental.

Os dados econômicos de uma empresa são um complexo de informações que incluem desde os dados de investimentos em infra-estrutura, passando por gastos de capital de giro, despesas operacionais, até aqueles das operações de vendas, inclusive os impostos. Quando os dados econômicos representam as vendas é interessante entender as mudanças que ocorrem nestas vendas. Esta análise pode ser por produto, por grupos de clientes, por regiões geográficas, entre outros. O entendimento do comportamento da demanda por produto pode explicar variações regulares ou outros efeitos. Por outro lado, a análise demasiadamente desagregada pode exigir um grande esforço no processo de previsão de demanda, e ainda pode ocultar efeitos comuns a vários produtos. Na análise de produtos compostos, no entanto, a agregação é útil para se calcular a demanda dependente de matérias-primas, que na maioria das vezes são comuns a diversos produtos.

Também se deve considerar os efeitos de promoções, de lançamento de produtos e de alterações na demanda devido à lei de oferta e demanda, que podem influenciar o comportamento dos dados.

Desta forma, além dos dados históricos de vendas, período a período, informações relevantes que expliquem comportamentos atípicos das vendas passadas são importantes no momento de analisar os dados para previsão. O conhecimento sobre a conjuntura econômica atual e previsão da conjuntura econômica, informações sobre decisões da área comercial que podem influenciar o comportamento das vendas, entre outras mencionadas por Corrêa *et al* (1997) devem ser consideradas no processo de previsão.

Os dados de entrada do método, utilizados para prever a demanda, são aqueles de vendas passadas de um determinado produto ou família de produtos, coletados em períodos de tempo regulares. Inicialmente estes dados são organizados em registros de vendas por períodos.

Na análise de séries temporais a quantidade em que os dados devem estar disponíveis para análise deve ser suficiente para que seja possível identificar padrões do comportamento da demanda. Desta forma, é necessário que os dados representem no mínimo dois períodos (ex. anos) de vendas por estação (ex. mês).

Os dados de vendas devem ser arranjados num gráfico de vendas por tempo, o que auxilia na identificação qualitativa do padrão da demanda. Através desta análise é possível definir qualitativamente o comportamento da demanda, por exemplo, se existe uma tendência linear crescente ou decrescente, se a tendência muda de direção do decorrer dos períodos, se há sazonalidade, se a sazonalidade é multiplicativa, entre outras variações.

A análise qualitativa dos dados da demanda contribui ainda para o processo de previsão da demanda, quando é possível incorporar alterações recentes no comportamento da demanda, refletindo melhor a atualidade. Para tanto, pode apoiar-se no conhecimento do mercado, experiências e opiniões de especialistas e em métodos formais como o Delphi.

No método proposto não existe um mecanismo para detecção ou tratamento de dados atípicos na demanda (*outliers*), sendo necessária a observação destas situações por parte do responsável pela previsão da demanda.

Se após a organização e análise prévia dos dados, estes apresentarem indícios de sazonalidade deve-se fazer a verificação da sazonalidade, seguindo com a modelagem do comportamento da demanda e finalmente, a previsão da demanda.

3.2 Verificação da significância da sazonalidade

A sazonalidade presente na série de dados nem sempre está bem definida, não acontecendo em períodos regulares e com uma forma padrão. Algumas vezes, flutuações que parecem ser sazonalidade são variações aleatórias daquele período, que não se repetirão posteriormente. Assim, há a necessidade de verificar se a sazonalidade supostamente presente na série de dados é significativa ou não.

Esta etapa do método compreende a verificação da significância da sazonalidade frente ao erro. Para tanto, propõe-se a realização da análise de variância de um fator único (*one way analysis of variance*) e do teste F sobre os dados de sazonalidade. Um exemplo da verificação da significância da sazonalidade pode ser visto no item 3.2.1.

Os dados de sazonalidade são obtidos a partir dos dados de demanda destendenciados. Para os dados históricos da demanda estima-se a tendência global para o período que está sendo analisado através de uma regressão linear ou polinomial. Dos dados históricos da demanda subtrai-se os valores de tendência estimados e o resíduo representa os dados de sazonalidade.

A análise de variância consiste numa técnica matemática que decompõe origens que justificam a variação total. No caso da *análise de variância com fator único*, que considera o efeito de um parâmetro sobre o processo, a variação total é decomposta em seus componentes apropriados (Ross, 1991):

- Variação da média de todos os dados sazonais em relação a zero.
- Variação da média dos dados sazonais conforme a estação em torno da média de todos os dados sazonais.
- Variação dos dados sazonais individuais em torno da média dos dados sazonais de acordo com a estação.

De acordo com Montgomery (1997), descreve-se a seguir a análise de variância de um único fator e o teste F.

No presente trabalho o fator é a sazonalidade; as observações compreendem os dados de sazonalidade e os tratamentos ou níveis referem-se as estações sazonais, por exemplo, meses do ano. Os dados para análise de variância podem ser representados como na Tabela 1. Sendo “*a*” estações de sazonalidade que se deseja avaliar, uma entrada na Tabela 1, s_{ij} , representa o *j*-ésimo dado de sazonalidade tomado sob a estação *i*. Há em geral *n* dados sazonais sob a estação *i*. A repetibilidade dos dados sazonais corresponde ao número de períodos, por exemplo, anos, utilizados na análise.

Tabela 1. Dados para análise de variância. (Adaptado de Montgomery, 1997)

Estação	Dados de sazonalidade				Total	Média
1	s_{11}	s_{12}	...	s_{1n}	$s_{1.}$	$\bar{s}_{1.}$
2	s_{21}	s_{22}	...	s_{2n}	$s_{2.}$	$\bar{s}_{2.}$
.
.
.
a	s_{a1}	s_{a2}	...	s_{an}	$s_{a.}$	$\bar{s}_{a.}$
					$s_{..}$	$\bar{s}_{..}$

Sendo que $s_{a.}$ representa o total dos dados de sazonalidade sob a i -ésima estação e $\bar{s}_{a.}$ representa a média dos dados sazonais sob a i -ésima estação e, similarmente $s_{..}$ representa o total de todos os dados sazonais e $\bar{s}_{..}$ representa a média de todos os dados sazonais, expressa-se simbolicamente,

$$s_{i.} = \sum_{j=1}^n s_{ij}, i = 1, 2, \dots, a \quad (3.1)$$

$$\bar{s}_{i.} = \frac{s_{i.}}{n}, i = 1, 2, \dots, a \quad (3.2)$$

$$s_{..} = \sum_{i=1}^a \sum_{j=1}^n s_{ij} \quad (3.3)$$

$$\bar{s}_{..} = \frac{s_{..}}{N}, N = \text{número total de dados de sazonalidade} \quad (3.4)$$

Obs.: A notação do ponto subscrito implica no somatório do subscrito que ele substitui.

É útil descrever os dados sazonais com um modelo linear estatístico:

$$s_{ij} = \mu + \tau_i + \varepsilon_{ij} \begin{cases} i = 1, 2, \dots, a \\ j = 1, 2, \dots, n \end{cases}$$

onde s_{ij} é o ij -ésimo dado de sazonalidade, μ é um parâmetro comum a todas as estações chamado de média global, τ_i é um parâmetro único à estação i chamado efeito da i -ésima estação, e ε_{ij} é o componente de erro aleatório.

O objetivo é testar hipóteses apropriadas sobre o efeito das estações e estimá-los. Para o teste de hipótese, os erros do modelo são assumidos ser variáveis aleatórias normalmente e

independentemente distribuídas com média zero e variância σ^2 . A variância σ^2 é assumida constante para todas as estações da sazonalidade.

A média da i -ésima estação é $E(s_{ij}) \equiv \mu_i = \mu + \tau_i$. Desta forma, a média da i -ésima estação consiste da média global mais o i -ésimo efeito da estação. Interessa testar a igualdade da média das estações, isto é,

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_a$$

$$H_1 : \mu_i \neq \mu_j \text{ para pelo menos um par } (i,j)$$

Se H_0 é verdadeira, todas as estações têm uma média comum μ .

Um modo diferente de escrever a hipótese acima é em termos do efeito das estações τ_i ,

$$H_0 : \tau_1 = \tau_2 = \dots = \tau_a = 0$$

$$H_1 : \tau_i \neq 0, \text{ para pelo menos um } i$$

O procedimento apropriado para testar a igualdade da estação “ a ” é a análise de variância.

O nome análise de variância é derivado da partição da variabilidade total em seus componentes. A soma dos quadrados total corrigida

$$SS_T = \sum_{i=1}^a \sum_{j=1}^n (s_{ij} - \bar{s}_{..})^2 \quad (3.5)$$

é usada como a medida da variabilidade total nos dados. Esta equação pode ser particionada no somatório do quadrado das diferenças entre a média das estações e a média de todos os dados de sazonalidade, mais o somatório do quadrado das diferenças dos dados sazonais, dentro das estações, da média das estações, conforme equação

$$SS_T = n \sum_{i=1}^a (\bar{s}_{i.} - \bar{s}_{..})^2 + \sum_{i=1}^a \sum_{j=1}^n (s_{ij} - \bar{s}_{i.})^2 \quad (3.6)$$

ou

$$SS_T = SS_{estação} + SS_{erro} \quad (3.7)$$

onde $SS_{estação}$ é a soma quadrática devido as estações e SS_{erro} é a soma quadrática devido ao erro.

Se há “ $a.n=N$ ” dados de sazonalidade totais, desta forma SS_T têm $(N-1)$ graus de liberdade; se há “ a ” estações de sazonalidade (e “ a ” médias das estações), assim $SS_{estação}$ tem $(a-1)$ graus de liberdade. Dentro de cada estação tem “ n ” replicações provendo $(n-1)$ graus de liberdade, com os quais estima-se o erro. Desde que há “ a ” estações, tem-se $a(n-1) = na - a = (N-a)$ graus de liberdade para o erro.

Com as quantidades, $SS_{estação}$ e SS_{erro} e seus respectivos graus de liberdade, calcula-se as médias quadradas:

$$MS_{estação} = \frac{SS_{estação}}{a - 1} \quad (3.8)$$

$$MS_{erro} = \frac{SS_{erro}}{N - a} \quad (3.9)$$

A partir das médias quadradas calcula-se o teste estatístico, ou seja, F_0 :

$$F_0 = \frac{MS_{estação}}{MS_{erro}} \quad (3.10)$$

Se a hipótese nula de nenhuma diferença na média das estações é verdadeira, a razão acima é distribuída como F com $a - 1$ e $N - a$ graus de liberdade. Contudo, se a hipótese nula é falsa, rejeita-se H_0 , e conclui-se que há diferença na média das estações, ou seja,

$$F_0 > F_{\alpha, a-1, N-a}$$

onde $F_{\alpha, a-1, N-a}$ é obtido a partir de tabelas; α representa o nível de significância (Montgomery, 1997).

Desta forma, para verificação da significância da sazonalidade se:

- $F_0 > F_{\alpha, a-1, N-a} \Rightarrow$ a sazonalidade é significativa na série de dados;
- $F_0 \leq F_{\alpha, a-1, N-a} \Rightarrow$ a sazonalidade não é significativa na série de dados.

Se a sazonalidade for significativa então a mesma deve ser considerada no processo de previsão da demanda.

Feita a verificação da sazonalidade, segue-se para a próxima etapa do método proposto que é a aplicação do modelo de previsão, também proposto neste trabalho.


3.2.1 Exemplo de verificação da significância da sazonalidade

A seguir, apresenta-se um exemplo da análise de variância e teste F para verificação da significância da sazonalidade nos dados de vendas. A Tabela 2 mostra a série de dados utilizada na exemplificação, obtida de Montgomery & Johnson (1976). Estes dados representam as vendas mensais de refrigerantes, em centenas de caixas, durante três anos.

Tabela 2. Vendas mensais de refrigerante B [centenas de caixas].

Meses	Ano 1	Ano 2	Ano 3	Meses	Ano 1	Ano 2	Ano 3
Janeiro	28	35	45	Julho	55	72	88
Fevereiro	31	40	49	Agosto	59	75	90
Março	36	46	57	Setembro	58	70	84
Abril	43	55	68	Outubro	55	66	80
Maiο	46	60	78	Novembro	47	58	57
Junho	52	68	80	Dezembro	40	50	60

A Figura 8 apresenta o gráfico de vendas por tempo dos dados da Tabela 2 e a tendência global para estes dados. Através da análise do gráfico verifica-se que os dados apresentam flutuações periódicas regulares que se repetem mais ou menos ao mesmo tempo, podendo caracterizar uma variação sazonal.

**Figura 8.** Vendas de refrigerante B e tendência global.

Utilizando os recursos de uma planilha de cálculo, determina-se a tendência global dos dados através da regressão linear ou polinomial e com a equação da reta ou curva estima-se a tendência global do período em análise. A seguir, extrai-se a tendência dos dados originais de vendas, sendo que o resíduo representa os dados de sazonalidade mais o erro. Com estes dados, faz-se a análise de variância e teste F. A Tabela 3 apresenta os dados da tendência estimada e a Tabela 4 apresenta os dados de sazonalidade mais o erro.

Tabela 3. Estimativa da tendência $\hat{T}(t)$.

Meses	Ano 1	Ano 2	Ano 3	Meses	Ano 1	Ano 2	Ano 3
Janeiro	39	52	65	Julho	45	58	71
Fevereiro	40	53	66	Agosto	46	59	73
Março	41	54	67	Setembro	47	61	74
Abril	42	55	68	Outubro	49	62	75
Maiο	43	56	69	Novembro	50	63	76
Junho	44	57	70	Dezembro	51	64	77

Tabela 4. Valores de sazonalidade mais erro.

Meses	Ano 1	Ano 2	Ano 3	Meses	Ano 1	Ano 2	Ano 3
Janeiro	-11	-17	-20	Julho	10	14	17
Fevereiro	-9	-13	-17	Agosto	13	16	17
Março	-5	-8	-10	Setembro	11	9	10
Abril	1	0	0	Outubro	6	4	5
Maiο	3	4	9	Novembro	-3	-5	-19
Junho	8	11	10	Dezembro	-11	-14	-17

A Figura 9 apresenta o gráfico dos dados de sazonalidade mais o erro. Observa-se que as flutuações apresentam uma variação da amplitude, o que pode caracterizar uma sazonalidade multiplicativa, caso a sazonalidade seja significativa. Desta forma, deve-se calcular os fatores multiplicativos (ver item 3.5.1.b) e os dados utilizados na análise de variância serão os dados de sazonalidade pura apresentados na Tabela 5.

Tabela 5. Dados de sazonalidade utilizados na análise de variância.

Meses	Ano 1	Ano 2	Ano 3	Meses	Ano 1	Ano 2	Ano 3
Janeiro	-11	-12	-11	Julho	8	8	8
Fevereiro	-8	-9	-9	Agosto	10	9	8
Março	-5	-5	-5	Setembro	8	6	5
Abril	1	0	0	Outubro	5	3	2
Maiο	3	2	4	Novembro	-2	-3	-9
Junho	7	7	5	Dezembro	-8	-8	-8




Figura 9. Dados de sazonalidade.

Utilizando-se as equações apresentadas no item 3.2, realizam-se os cálculos necessários para análise de variância e para o teste F. A Tabela 6 apresenta um resumo dos valores calculados.

Tabela 6. Resumo da análise de variância e do teste F para os dados analisados.

	<i>SS</i>	<i>Graus de liberdade</i>	<i>MS</i>	F_0	$F_{\alpha, a-1, N-a}$ ($\alpha = 1\%$)
Estação	1672	12	139	72	3,09
Erro	46	24	2		
Total	1718	36			

De acordo com os dados da Tabela 6 o F_0 é muito maior que o F tabelado, ou seja, a sazonalidade presente nos dados analisados é significativa para o nível de significância de 1%.

3.3 Aplicação do modelo

O modelo proposto baseia-se na análise de séries temporais, ou seja, utilizando dados de demandas anteriores, estratificados em períodos de tempo regulares, determina cada componente da demanda e usa este conhecimento para gerar a previsão. Os componentes da demanda incluem tendência, sazonalidade, ciclo e erro.

As etapas principais que compõe o modelo são: análise dos componentes da demanda e previsão da demanda. Na primeira etapa, a demanda é segmentada em seus componentes, identificando-se o comportamento padrão para cada componente. Na etapa seguinte, prepara-se a previsão da demanda, estimando cada componente da demanda para o período futuro e reagrupando-os.

Inicialmente, apresentam-se as etapas do modelo. Em seguida, descreve-se os procedimentos do modelo utilizando-se uma planilha de cálculo e exemplifica-se a aplicação do mesmo a uma série de dados.

3.3.1 Análise dos componentes da demanda

A análise dos componentes da demanda assume que os dados de demanda (X) têm quatro componentes: tendência (T), variação cíclica (C), variação sazonal (S) e variação aleatória ou erro (e), os quais podem ser representados da seguinte forma:

$$X_t = T_t + C_t + S_t + e_t \quad (3.11)$$

Neste trabalho, considera-se a tendência e o ciclo como um componente único, ou seja, uma tendência cíclica representada por T . Os ciclos são movimentos de longo prazo, sendo pouco perceptíveis nas séries usadas nas previsões de médio a curto prazo. Assim, a demanda compõe-se agora de tendência, sazonalidade e erro:

$$X_t = T_t + S_t + e_t \quad (3.12)$$

O procedimento consiste em analisar estes componentes e, de acordo com o comportamento de cada um, determinar sua magnitude, utilizando este conhecimento para o propósito de previsão.

a) Tendência

Em geral, os dados de demanda apresentam uma tendência, que pode variar no decorrer dos períodos de forma crescente ou decrescente. Esta tendência pode ser linear ou representada

por um polinômio de grau maior, mas sempre bem inferior ao grau que representaria as estações. Por exemplo, se as estações são os 12 meses do ano, então a tendência pode ser representada por polinômios de segundo, terceiro ou quarto grau. Polinômios de maior graduação certamente estariam se sobrepondo aos efeitos das estações. Desta forma, utiliza-se a regressão linear ou polinomial para determinar a tendência a longo prazo da demanda.

$$\text{Tendência linear: } \hat{T}_t = a + bt \quad (3.13)$$

$$\text{Tendência polinomial: } \hat{T}_t = \alpha_0 + \alpha_1 t + \alpha_2 t^2 + \dots + \alpha_k t^k \quad (3.14)$$

onde:

\hat{T}_t = estimativa da tendência para o período de tempo t

a = coeficiente linear

b = coeficiente angular

t = tempo

α = coeficientes do polinômio

k = ordem do polinômio

b) Sazonalidade

O resíduo da melhor reta ou do melhor polinômio representa a sazonalidade mais o erro da demanda, ou seja:

$$X_t - \hat{T}_t = S_t + e_t \quad (3.15)$$

Com os valores de $S_t + e_t$, faz-se o teste para verificação da sazonalidade frente ao erro, descrito no item 3.2. Se a sazonalidade for significativa, então para o próximo período de tempo t determiná-la como sendo a média dos dados sazonais de cada período j sob a estação i .

$$\hat{S}_t = \bar{s}_i \quad (3.16)$$

$$\bar{s}_i = \frac{S_i}{n}, \quad i = 1, 2, \dots, a \quad (3.17)$$

$$s_i = \sum_{j=1}^n s_{ij}, \quad i = 1, 2, \dots, a \quad (3.18)$$

\hat{S}_t = estimativa da sazonalidade para o período de tempo t

\bar{s}_i = média dos dados sazonais sob a estação i

n = número de dados sazonais sob a estação i

s_i = somatório dos dados de sazonalidade sob a estação i

Nesta etapa, deve-se analisar se a amplitude da sazonalidade através dos períodos é constante (aditiva) ou varia (multiplicativa). Caso seja variável, deve-se determinar os fatores multiplicativos da sazonalidade, conforme descrito no item 3.4.3.

c) Erro

Conhecidos os componentes de tendência e sazonalidade, obtém-se um resíduo que representa o erro:

$$e_t = X_t - \hat{T}_t - \hat{S}_t \quad (3.19)$$

A seguir, descreve-se a segunda etapa do modelo proposto.

3.3.2 Previsão da demanda

Feita a análise dos componentes da demanda é possível então prever a demanda. A previsão da demanda consiste no reagrupamento dos componentes da demanda.

A equação da melhor reta ou curva que representa a tendência do período analisado é extrapolada para os períodos subseqüentes. Contudo, nesta etapa pode-se interferir no processo de previsão avaliando se é mais favorável usar uma tendência mais ampla (por exemplo, de três anos) ou uma tendência mais recente (por exemplo, dos últimos 6 meses).

$$T_{t+1} = \hat{T}_{t+1} \quad (3.20)$$

A sazonalidade para o período $t+1$ é igual a estimativa da sazonalidade para o período $t+1$, considerando-se que a sazonalidade é significativa e repete-se em períodos de tempo regulares.

$$S_{t+1} = \hat{S}_{t+1} \quad (3.21)$$

Caso a sazonalidade seja multiplicativa, deve-se determinar os fatores multiplicativos para os períodos a serem previstos.

$$S_{t+1} = \hat{S}_{t+1} * \hat{A}_{t+1} \quad (3.22)$$

O cálculo dos fatores multiplicativos, \hat{A}_{t+1} , será descrito no item 3.4.3.

Após determinar a tendência e a sazonalidade, estas devem ser reagrupadas para gerar a previsão da demanda para os períodos futuros, de acordo com o modelo:

$$F_{t+1} = T_{t+1} + S_{t+1} \quad (3.23)$$

onde:

F_{t+1} = previsão para o período de tempo $t+1$

T_{t+1} = tendência para o período $t+1$

S_{t+1} = sazonalidade para o período $t+1$

Diferente de outros métodos de previsão de dados sazonais, como os métodos de Winters e de Decomposição Clássica utilizados como comparação neste trabalho, o método proposto apresenta uma análise dos dados em relação à significância da sazonalidade presente nos mesmos. Com esta análise assegura-se da necessidade da aplicação de um método específico para dados sazonais e ainda permite verificar se as flutuações ocorridas na série de dados são de origem sazonal, informação bastante útil ao processo de previsão e, conseqüentemente, de planejamento.

O sequenciamento dos cálculos do modelo matemático do método proposto assemelha-se com aqueles da Decomposição Clássica, que propõe identificar, extrapolar e recombina cada componente da série de dados para gerar a previsão final, porém de forma mais simples. A decomposição pode freqüentemente facilitar a melhoria da acurácia da previsão e ajudar no melhor entendimento do comportamento da série. Já o método de Winters considera a série como um todo, não separando-a em componentes. O objetivo deste método é eliminar o erro, pelo amaciamento dos valores da série, para que o padrão possa ser projetado no futuro e usado como previsão. O método de Winters considera ainda a tendência como sendo linear, enquanto os demais admitem diferentes formas para a tendência, como por exemplo uma curva representada por um polinômio.

O método proposto auxilia na obtenção de dados de previsão de vendas com relativa acurácia, de forma simples e rápida, sendo que seus cálculos não dependem de cálculos de constantes e variáveis extras, podendo ser aplicado facilmente, como mostra, por exemplo, a operacionalização do modelo matemático, a seguir.

3.4 Operacionalização do modelo utilizando planilhas de cálculo

O modelo matemático de previsão de demanda inserido no método proposto pode ser facilmente aplicado utilizando-se uma planilha de cálculo, como o Excel, que possui inúmeras facilidades de edição e de geração de gráficos, sendo comumente encontrado nas empresas.

O procedimento de aplicação do modelo compreende as seguintes etapas:

3.4.1 Dados de entrada

Na planilha de cálculo deve-se inserir, inicialmente, um registro ou coluna com os períodos de tempo a que os dados de vendas se referem. Em seguida, cria-se outro registro com os dados de vendas de um produto ou família de produtos. Os dados de vendas necessários para previsão devem compreender um período de pelo menos dois anos. Estes dados devem ser representados num gráfico de vendas por tempo, utilizando-se os recursos gráficos disponíveis na planilha.

3.4.2 Cálculo da tendência

Para os dados distribuídos no gráfico anterior, o usuário deve utilizar os recursos da planilha para executar o cálculo da tendência, podendo selecionar um ou mais modelos de regressão linear ou polinomial de baixa ordem, que melhor se ajustem aos dados de vendas. Com a equação da melhor reta ou curva obtida, cria-se um novo registro, o qual representa a tendência dos dados para o período analisado.

3.4.3 Cálculo da sazonalidade

Inicialmente, deve-se criar um registro com os dados de demanda menos os dados de tendência, o que resulta em dados de sazonalidade mais erro. Com os dados de sazonalidade mais erro faz-se um gráfico, no qual é possível avaliar se a amplitude da sazonalidade é constante ou variável. Caso a amplitude varie deve-se determinar os fatores multiplicativos para o período analisado. Para determinar os fatores multiplicativos, calcula-se a média dos valores absolutos da sazonalidade de cada período (se a sazonalidade for anual, por exemplo, esta média será calculada com os valores de sazonalidade dos 12 meses de cada ano); multiplica-se esta

média por 2, pois a sazonalidade é simétrica. A seguir faz-se um gráfico dos pontos correspondentes as médias – no caso de três anos, por exemplo, representados por 6, 18 e 30 – *versus* as médias. Usando os recursos gráficos da planilha, faz-se a regressão linear e, da equação obtida, calcula-se os fatores multiplicativos para cada estação, que devem ser armazenados em um registro. Dividindo-se os dados de sazonalidade pelos fatores multiplicativos tem-se a *sazonalidade pura*, que deve ser armazenada em um novo registro. Se a sazonalidade for significativa, com os dados da sazonalidade pura calcula-se a média do componente sazonal para cada estação do período, criando-se um registro que representa a sazonalidade média para o próximo período.

3.4.4 Previsão

Para gerar a previsão, inicialmente, deve-se extrapolar os dados do registro de tendência para o período futuro. A seguir, multiplica-se os dados do registro de sazonalidade média pelos dados do registro dos fatores multiplicativos, projetados para o próximo período. Por fim, adiciona-se a tendência à sazonalidade, obtendo-se desta forma a previsão do próximo período. Se a sazonalidade não for significativa, pode-se fazer a previsão com base na tendência ou utilizando-se técnicas simples de séries temporais, como médias móveis.

3.5 Exemplo da aplicação do modelo

Para um melhor entendimento do modelo, apresenta-se a seguir um exemplo de sua aplicação a uma série de dados obtida da bibliografia. Esta série é a mesma utilizada no exemplo da verificação da significância da sazonalidade, no item 3.2.

A Figura 10 apresenta o gráfico de vendas por tempo dos dados da Tabela 2. Pela análise gráfica, observa-se que este exemplo apresenta uma tendência linear crescente no decorrer dos períodos, além da flutuação sazonal bastante acentuada.




Figura 10. Gráfico de vendas mensais de refrigerante B em centenas de caixas.

Aplicando as etapas do modelo descritas anteriormente tem-se:

3.5.1 Análise dos componentes da demanda

Esta etapa compreende a decomposição da demanda em seus componentes de tendência e sazonalidade, supostamente presentes na série de dados em estudo, e posterior análise dos mesmos.

a) Determinação da tendência

Para determinar a tendência, inicialmente faz-se um gráfico de vendas por tempo, como o da Figura 10. Utilizando os recursos de uma planilha de cálculo, busca-se um polinômio de baixo grau para representar a tendência. Neste exemplo, usou-se um polinômio de grau 1, ou seja, uma

reta. Assim, estima-se a tendência para os três períodos analisados pela equação da regressão linear:

$$\hat{T}(t) = 1,094 * t + 37,56 \quad (3.24)$$

A Figura 8 apresenta o gráfico de vendas por tempo e a tendência a longo prazo, representada pela linha tracejada. A Tabela 3 apresenta os valores da tendência estimada para os três períodos analisados.

b) Determinação da sazonalidade

Para determinar a sazonalidade subtraem-se os dados da tendência estimada na etapa anterior dos dados de vendas originais; o resíduo desta operação representa os valores de sazonalidade mais o erro, ou seja, as vendas destendenciadas. Estes valores encontram-se na Tabela 4.

Conforme observado na Figura 9, tem-se que a sazonalidade é multiplicativa, ou seja, a amplitude sazonal varia no decorrer dos períodos, sendo necessário determinar os fatores multiplicativos da sazonalidade.

Para determinar os fatores multiplicativos da sazonalidade calcula-se a média dos valores absolutos da Tabela 4 para cada período, ou seja, para cada ano. A seguir, faz-se um gráfico dos pontos correspondentes as médias – no caso de três anos, representados por 6, 18 e 30 – *versus* as médias. Usando os recursos gráficos da planilha de cálculo faz-se a regressão linear e com a equação obtida calcula-se os fatores multiplicativos para o período. A Figura 11 apresenta o resultado da regressão linear.

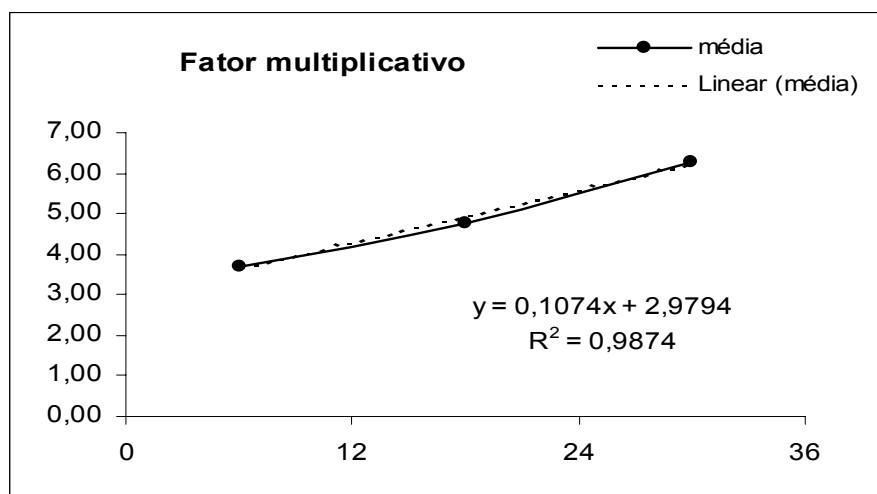


Figura 11. Regressão linear para obtenção dos fatores multiplicativos da sazonalidade.

Dividindo-se os dados de sazonalidade pelos fatores multiplicativos tem-se a *sazonalidade pura*, ou seja, a sazonalidade sem a variação de amplitude. Estes dados estão representados na Tabela 5.

Se a sazonalidade não for significativa, a mesma é tratada como erro (ruído), caso contrário, com os dados da Tabela 4, calcula-se a sazonalidade média para cada estação, ou seja, para cada mês.

3.5.2 Previsão da demanda

Considerando que a sazonalidade é constante e que a tendência e o efeito multiplicativo são extrapoláveis, para prever a demanda deve-se agrupar seus componentes seguindo o modelo proposto:

$$F_{t+1} = T_{t+1} + S_{t+1} \quad (3.25)$$

A estimativa da tendência, dada pela equação 3.24, é extrapolada para os períodos futuros e os valores utilizados para a sazonalidade são aqueles apresentados na Tabela 4, calculando-se a média para cada estação, multiplicados pelos fatores multiplicativos. Neste exemplo, a previsão é apresentada somente para até 3 períodos à frente.

A previsão da demanda para a série de dados usada nesta exemplificação do modelo apresenta-se na Tabela 7.

Tabela 7. Previsão da demanda de refrigerantes B [em centenas de caixas] para três períodos de tempo à frente.

Meses	Tendência	Sazonalidade	Previsão
Janeiro	78	-11	53
Fevereiro	79	-9	59
Março	80	-5	68

CAPÍTULO 4

4 VALIDAÇÃO TEÓRICA DO MODELO PROPOSTO

Neste capítulo, apresenta-se a validação teórica do modelo de previsão de demanda proposto neste trabalho, descrito no item 3 do Capítulo 3. Esta validação teórica é realizada aplicando-se o modelo proposto, assim como os procedimentos matemáticos de dois métodos clássicos de previsão, a um conjunto de séries temporais obtidas da bibliografia.

Os métodos clássicos utilizados na validação são o método de Winters e o método de Decomposição Clássica, comumente usados para previsão de dados que apresentam sazonalidade e já descritos no Capítulo 2.

O modelo proposto e os procedimentos matemáticos dos métodos clássicos são comparados através dos erros de previsão, expressos pelas medidas de precisão da previsão como o MAD (*mean absolut deviation*), o MSE (*mean squared error*) e o MAPE (*mean absolut percentual error*).

As séries temporais com características sazonais utilizadas na validação e obtidas da bibliografia são as seguintes:

- Vendas mensais de refrigerante A em centenas de caixas – Montgomery & Johnson (1976), página 105-106.
- Vendas mensais de refrigerante B em centenas de caixas – Montgomery & Johnson (1976), página 272.
- Vendas mensais de champanhe em milhares de garrafas – Montgomery & Johnson (1976), página 272.
- Vendas mensais de tapetes – Montgomery & Johnson (1976), página 273.
- Vendas mensais de caixas de papelão – Shafer & Meredith (1998), página 312.
- Vendas de passagens aéreas internacionais – Makridakis *et al* (1983), página 150.

Para a validação utilizam-se os primeiros períodos da série de dados para análise e previsão da demanda e o último período para comparar as previsões geradas pelo modelo proposto e pelos procedimentos matemáticos dos métodos clássicos.

A Figura 12 representa as vendas mensais de refrigerante A. A demanda para este produto apresenta uma tendência crescente e picos de máximo no mês de setembro, caracterizando uma sazonalidade para este período. A sazonalidade é multiplicativa, ou seja, sua

amplitude varia no decorrer dos períodos. A Tabela 1A do Anexo 1 apresenta os dados geradores da Figura 12.




Figura 12. Vendas mensais de refrigerante A.

A Figura 13 representa as vendas mensais de refrigerante B. A demanda para este produto também apresenta uma tendência crescente e picos de máximo no mês de agosto, caracterizando uma sazonalidade para este período. A sazonalidade é multiplicativa. A Tabela 1B do Anexo 1 apresenta os dados geradores da Figura 13.




Figura 13. Vendas mensais de refrigerante B.

A Figura 14 representa as vendas mensais de champanhe. A demanda para este produto apresenta uma tendência levemente crescente. Há pico de máximo no mês de dezembro e pico de mínimo para o mês de agosto, caracterizando uma sazonalidade para estes períodos. Neste exemplo a sazonalidade também é multiplicativa. A Tabela 1C do Anexo 1 apresenta os dados geradores da Figura 14.




Figura 14. Vendas mensais de champanhe.

A Figura 15 representa as vendas mensais de tapetes. A demanda para este produto apresenta uma tendência crescente e pico de máximo no mês de agosto, caracterizando uma sazonalidade para este período. Considerando que a amplitude da sazonalidade é constante, neste exemplo trata-se de sazonalidade aditiva. A Tabela 1D do Anexo 1 apresenta os dados geradores da Figura 15.

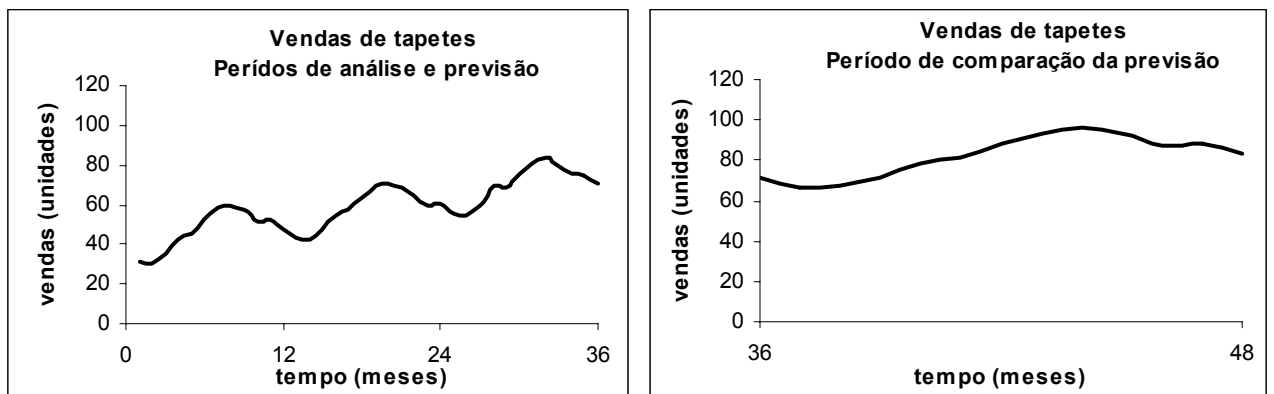


Figura 15. Vendas mensais de tapetes.

A Figura 16 representa as vendas mensais de caixas de papelão. A demanda para este produto apresenta uma tendência levemente crescente. A sazonalidade ocorre ora num mês, ora em outro, porém em meses próximos, o que ainda caracteriza a presença de sazonalidade nos dados. A Tabela 1E do Anexo 1 apresenta os dados geradores da Figura 16.




Figura 16. Vendas mensais de caixas de papelão.

A Figura 17 representa as vendas mensais de passagens aéreas. A demanda para este produto apresenta uma tendência crescente. A sazonalidade apresenta dois picos de máximo, próximos a março e julho. Neste exemplo, a sazonalidade também é multiplicativa. A Tabela 1F do Anexo 1 apresenta os dados geradores da Figura 17.




Figura 17. Vendas de passagens aéreas internacionais.

O modelo proposto foi aplicado a cada um dos exemplos de vendas expostos acima. As Figuras a seguir apresentam as previsões obtidas com a aplicação do modelo proposto e dos procedimentos matemáticos dos métodos de Winters e de Decomposição Clássica a cada série temporal. As previsões foram geradas para 12 períodos à frente, ou seja, para um período anual.

A Figura 18 apresenta a previsão para as vendas de refrigerante A. Para este exemplo os três procedimentos matemáticos produziram previsões próximas a demanda real.




Figura 18. Previsão de vendas de refrigerante A.

A Figura 19 apresenta a previsão para as vendas de refrigerante B. Para este exemplo a previsão gerada pelo método proposto esteve mais próxima da demanda real.




Figura 19. Previsão de vendas de refrigerante B.

A Figura 20 apresenta a previsão para as vendas de champanhe. Para este exemplo a linha de previsão gerada por decomposição está praticamente sobreposta a linha da demanda real.




Figura 20. Previsão de vendas de champanhe.

A Figura 21 apresenta a previsão para as vendas de tapetes. Para este exemplo a linha de previsão do modelo proposto está bem próxima da linha da demanda real.

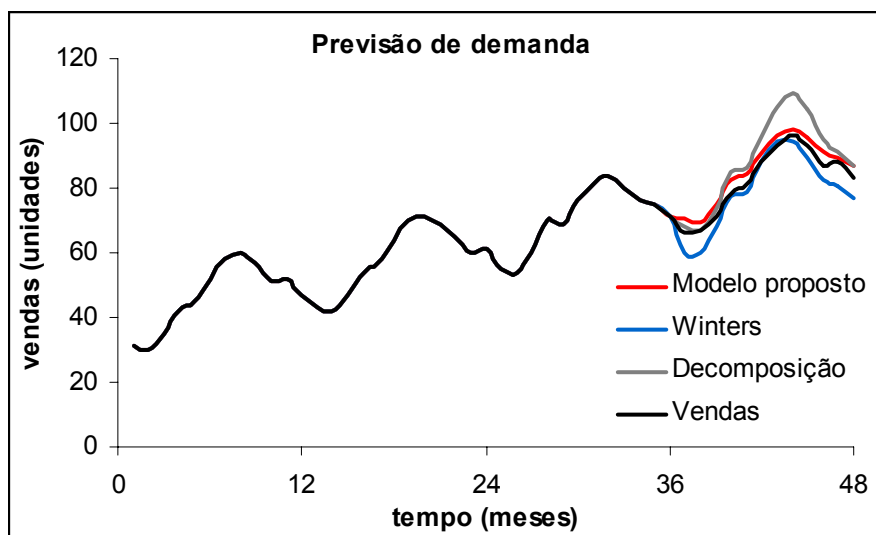


Figura 21. Previsão de vendas de tapetes.

A Figura 22 apresenta a previsão para as vendas de caixas de papelão. Para este exemplo as linhas de previsão geradas pelos três procedimentos mostraram-se desviadas da linha de demanda real. Isto se deve ao deslocamento dos picos de sazonalidade, embora entre meses próximos.

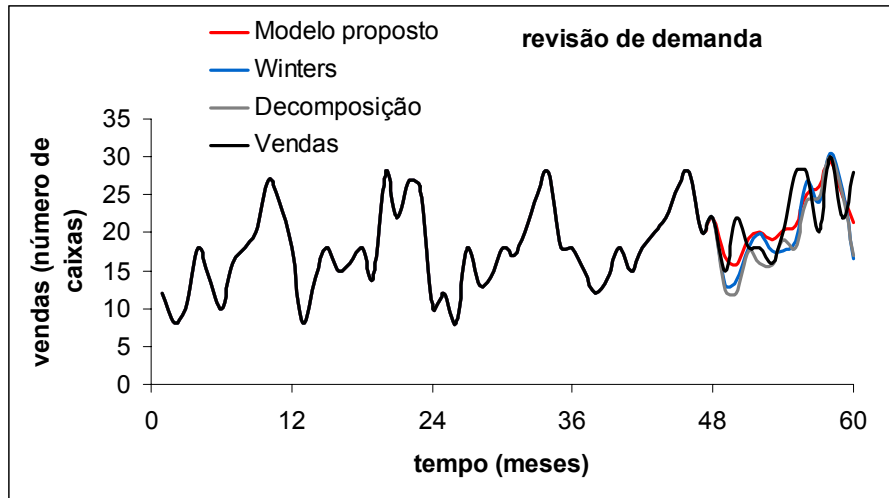


Figura 22. Previsão de vendas de caixas de papelão.

A Figura 23 apresenta a previsão para as vendas de passagens aéreas internacionais. Para este exemplo a decomposição mostra uma previsão de boa conformação com a demanda real.




Figura 23. Previsão de vendas de passagens aéreas internacionais.

Através da análise das figuras anteriores é possível perceber que, em geral, o modelo de previsão de demanda proposto neste trabalho é capaz de gerar previsões tão precisas quanto os métodos utilizados na comparação. Porém, para que se possa afirmar que o modelo proposto realmente produz previsões acuradas faz-se a comparação de diferentes medidas de precisão, baseadas no cálculo do erro de previsão.

A Tabela 8 apresenta os valores da medida de precisão da previsão MAD ou desvio absoluto médio. Para esta medida a previsão gerada pelo modelo proposto foi melhor para três

dos exemplos analisados, vendas mensais de refrigerante B, tapetes e caixas de papelão, já que os valores do MAD foram relativamente menores para estes.

Tabela 8. Comparação entre o modelo proposto e os métodos clássicos utilizando o MAD.

<i>Série</i>	<i>Winters</i>	<i>Decomposição</i>	<i>Modelo proposto</i>	<i>Melhor</i>
<i>Vendas mensais de refrigerante A</i>	106,12	87,44	101,26	<i>Decomposição</i>
<i>Vendas mensais de refrigerante B</i>	8,58	6,48	2,67	<i>Modelo proposto</i>
<i>Vendas mensais de champanhe</i>	2,09	0,38	0,95	<i>Decomposição</i>
<i>Vendas de tapetes</i>	3,56	6,45	3,24	<i>Modelo proposto</i>
<i>Vendas mensais de caixas de papelão</i>	3,85	4,06	3,44	<i>Modelo proposto</i>
<i>Vendas de passagens aéreas</i>	15,66	6,72	21,58	<i>Decomposição</i>

A Tabela 9 apresenta os valores da medida de precisão da previsão MSE ou erro quadrado médio. Esta medida penaliza a previsão muito mais pelos grandes desvios do que pelos pequenos desvios.

A Tabela 10 apresenta os valores para a medida de precisão MAPE. Esta medida representa o erro percentual médio da previsão.

Tanto os valores do MSE quanto os valores do MAPE foram relativamente menores para os mesmos exemplos do MAD, ou seja, as previsões geradas pelo modelo proposto para estes exemplos foram mais precisas.

Os valores das medidas de precisão confirmam as suposições feitas na análise das figuras anteriores, como é o caso dos exemplos de vendas mensais de refrigerante B e tapetes, em que o modelo proposto apresentou a linha de previsão da demanda bastante próxima à linha da demanda real.

Desta forma, como os resultados obtidos na validação do modelo proposto com dados bibliográficos mostraram-se satisfatórios propôs-se aplicação do mesmo a dados reais de vendas, juntamente como o método proposto neste trabalho.

Tabela 9. Comparação entre o modelo proposto e os métodos clássicos utilizando o MSE.

<i>Série</i>	<i>Winters</i>	<i>Decomposição</i>	<i>Modelo Proposto</i>	<i>Melhor</i>
<i>Vendas mensais de refrigerante A</i>	21130	13101	15146	<i>Decomposição</i>
<i>Vendas mensais de refrigerante B</i>	99,33	46,60	9,62	<i>Modelo proposto</i>
<i>Vendas mensais de champanhe</i>	6,54	0,19	2,45	<i>Decomposição</i>
<i>Vendas de tapetes</i>	18,03	57,47	11,35	<i>Modelo proposto</i>
<i>Vendas mensais de caixas de papelão</i>	27,52	31,44	17,52	<i>Modelo proposto</i>
<i>Vendas de passagens aéreas internacionais</i>	391,97	66,24	563,50	<i>Decomposição</i>

Tabela 10. Comparação entre o modelo proposto e os métodos clássicos utilizando o MAPE.

<i>Série</i>	<i>Winters</i>	<i>Decomposição</i>	<i>Modelo Proposto</i>	<i>Melhor</i>
<i>Vendas mensais de refrigerante A</i>	18,88	17,32	24,17	<i>Decomposição</i>
<i>Vendas mensais de refrigerante B</i>	9,65	7,74	3,11	<i>Modelo proposto</i>
<i>Vendas mensais de champanhe</i>	36,21	8,25	16,18	<i>Decomposição</i>
<i>Vendas de tapetes</i>	4,54	7,42	4,05	<i>Modelo proposto</i>
<i>Vendas mensais de caixas de papelão</i>	16,65	17,33	15,47	<i>Modelo proposto</i>
<i>Vendas de passagens aéreas internacionais</i>	4,45	1,97	6,36	<i>Decomposição</i>

CAPÍTULO 5

5 APLICAÇÃO DO MÉTODO DE PREVISÃO DE DEMANDA PROPOSTO

Este capítulo apresenta a aplicação do método de previsão de demanda proposto neste trabalho a dados reais de vendas de produtos alimentícios.

O método e o modelo de previsão de demanda desenvolvidos neste trabalho têm como característica fundamental a detecção, a avaliação e a determinação da sazonalidade. Para que o método, assim como o modelo, fosse completamente avaliado quanto à precisão das previsões geradas, seria desejável uma grande variedade de séries de dados, em situações de sazonalidade forte e bem definida, sazonalidade fraca e sazonalidade forte e instável, por exemplo. Infelizmente, apesar dos esforços e a premência do tempo, a resposta das empresas contatadas não foi de acordo com o esperado, portanto este conjunto desejável de séries de dados não foi obtido. A validação do modelo só foi completa porque se obteve da bibliografia bons exemplos de dados sazonais, os quais foram apresentados no Capítulo 4.

Das três empresas que disponibilizaram os dados para análise, uma caracteriza-se como indústria de pequeno porte e atua no segmento de mel de abelha e derivados. Seus produtos destinam-se ao consumidor final e também para hotéis, cafés, etc. Conforme será visto na análise a seguir, os dados de vendas desta empresa apresentam sazonalidade, porém instável.

A outra atua tanto como agroindústria quanto indústria de alimentos, sendo no primeiro caso uma forte representante de *comodities* como farinha de trigo e derivados de soja (óleo, proteínas, farinhas); e no segundo caso levando produtos embalados com suas marcas para o consumidor final, como farinhas, misturas para pães e bolos, óleos e margarinas. Estes produtos tipicamente apresentam fraca sazonalidade, pois grande parte deles é do grupo de consumo diário. A empresa também atua no segmento de misturas para sobremesas, que podem ter uma sazonalidade mais acentuada.

E a última empresa caracteriza-se como de pequeno porte, disponibilizando seus produtos para Florianópolis. Atua no segmento de sorvetes, produto com característica sazonal bastante acentuada.

Além da comparação da previsão gerada pelo método proposto com os dados reais de vendas, também faz-se uma comparação com as previsões geradas pelos métodos de Winters e de Decomposição Clássica.

5.1 Empresa A

Esta empresa caracteriza-se como uma empresa de pequeno porte, que disponibiliza ao mercado mel de abelha e produtos a base de mel. A diversidade de seus produtos é baixa, até mesmo pelas limitações mercadológicas da matéria-prima; esta é vulnerável as variações climáticas, já que a produção do mel pelas abelhas depende da floração, entre outros fatores, de modo que o suprimento não é constante ao longo do ano.

Os dados obtidos desta empresa representam as vendas mensais desde Janeiro de 2000 até Fevereiro de 2003. Os dados de 2000, 2001 e 2002 foram utilizados na aplicação do método proposto e os meses de Janeiro e Fevereiro de 2003 para avaliar a previsão gerada pelo método proposto e também pelos métodos de Winters e Decomposição Clássica.

Foram avaliadas as vendas de todos os produtos da empresa produzidos durante o período analisado, sendo um total de 18 produtos. A empresa produz aproximadamente 50 produtos, incluindo as variações de embalagens, porém muitos que eram produzidos em 2000 e 2001 deixaram de ser em 2002, e novos produtos foram lançados em 2001 e 2002, não sendo possível analisá-los devido os dados estarem incompletos.

Dos 18 produtos analisados, 9 apresentaram sazonalidade significativa. Os resultados da verificação da significância da sazonalidade encontram-se na Tabela 11.

Tabela 11. Resultados da verificação da significância da sazonalidade da empresa A.

Produto	F_0 (calculado)	$F_{\alpha, a-1, N-a}$ (tabelado)	Sazonalidade $F_0 > F$
M40	1,67	2,22	Não
M330	2,92	2,22	Sim
M800	1,71	2,22	Não
MC280	1,48	2,22	Não
M3.5	1,76	2,22	Não
M25	2,93	2,22	Sim
MP	2,66	2,22	Sim
MA	3,17	2,22	Sim
MAP	2,91	2,22	Sim
MG	3,48	2,22	Sim
MGP	2,85	2,22	Sim
SP	2,83	2,22	Sim
GR	0,59	2,22	Não
P30	1,66	2,22	Não
P20	1,69	2,72	Não
U	2,79	2,72	Sim
SPM	2,44	2,72	Não
M1	1,95	2,72	Não

As Figuras 24 a 42 apresentam os gráficos de vendas dos produtos da Empresa A analisados neste trabalho. As tabelas de dados que originaram os gráficos destas Figuras encontram-se no Anexo 2, Tabelas 2A a 2Q.

A Figura 24 apresenta as vendas mensais do produto M40 por um período de três anos. Os dados das vendas para este produto foram bastante aleatórios, não caracterizando nenhum comportamento padrão no período analisado. De acordo com os resultados da verificação da significância da sazonalidade este produto não apresentou sazonalidade significativa.




Figura 24. Vendas mensais do produto M40.

A Figura 25 apresenta as vendas mensais do produto M330. De acordo com os dados da Tabela 11, este produto apresentou uma sazonalidade significativa, porém fraca. Também, pela análise gráfica percebe-se que as flutuações sazonais são instáveis variando de um ano para outro. No primeiro ano os picos sazonais acontecem nos meses de Junho e Setembro. No segundo ano repete-se no mês de Junho e retrocede para o mês de Agosto. E para o último ano há um avanço para o mês de Julho e permanece no mês de Setembro.

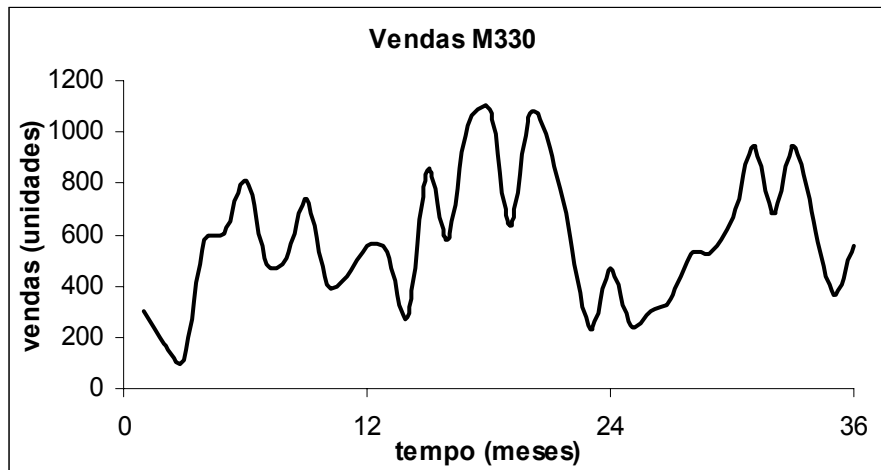


Figura 25. Vendas mensais do produto M330.

A Figura 26 mostra as vendas mensais do produto M800. Este produto apresenta varias flutuações nos dados, porém não caracterizam sazonalidade, o que é confirmado pela análise de variância e pelo teste F, ou seja, a sazonalidade não é significativa.




Figura 26. Vendas mensais do produto M800.

A Figura 27 apresenta as vendas mensais do produto MC280. Este produto tem no primeiro ano uma flutuação acentuada em abril e no segundo ano a mesma repete-se, porém no mês de março, ou seja, houve um retardo e não aparece no terceiro ano. No primeiro e terceiro ano também aparece uma variação comum nos meses de setembro, outubro e novembro. Contudo estas flutuações não são suficientes para caracterizar um comportamento sazonal, o que é confirmado pela verificação da significância da sazonalidade, a qual foi não significativa.




Figura 27. Vendas mensais do produto MC280.

A Figura 28 apresenta as vendas mensais para o produto M3.5. Este produto exibe algumas flutuações, porém bastante aleatórias, não caracterizando nenhuma sazonalidade, conforme verifica-se pelo resultado da Tabela 11.




Figura 28. Vendas mensais do produto M3.5.

A Figura 29 mostra as vendas mensais do produto M25. Este produto apresenta um leve pico de vendas em Março; outro que varia entre os meses de Junho (primeiro ano), Maio (segundo ano) e Julho (terceiro ano), caracterizando uma sazonalidade instável; e outro em Novembro, sendo que este apresenta uma variação acentuada na amplitude para o último ano. Desta forma, tem-se um produto sazonal, o que é confirmado pela verificação da significância da sazonalidade cujo resultado foi sazonalidade significativa, ainda que fraca.




Figura 29. Vendas mensais do produto M25.

A Figura 30 apresenta as vendas mensais do produto MP. Este produto tem um pico em comum no mês de Junho que é bastante característico nos dois primeiros anos; no terceiro ano este pico permanece, porém surgem dois novos picos, um entre os meses de abril e maio e outro em julho, mudando então o perfil dos dados apresentado no dois primeiros anos. Em princípio estes novos picos não podem ser ditos como flutuações sazonais, somente se repetirem no próximo período (ano de 2003). Ainda assim, a sazonalidade presente nos dados é significativa.




Figura 30. Vendas mensais do produto MP.

A Figura 31 mostra as vendas mensais do produto MA. Para este produto as vendas apresentam no primeiro ano um pico em Junho; no segundo ano um pico em Maio, ou seja, há

um deslocamento do pico para um mês atrás; e no terceiro ano repetem-se os picos em Maio e Junho e surge um novo pico em Julho. Embora haja esse movimento nos dados, a sazonalidade é considerada significativa, seguindo os resultados da Tabela 11.

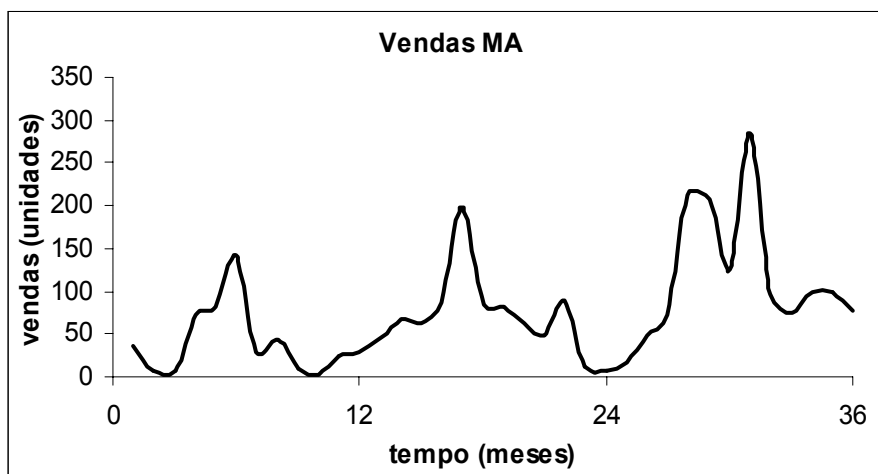


Figura 31. Vendas mensais do produto MA.

A Figura 32 apresenta as vendas mensais do produto MAP. No primeiro ano o pico de vendas acontece em Junho, deslocando-se para Maio no segundo ano e ficando entre os meses de Abril e Maio no terceiro ano. Neste último ano surge um novo pico de vendas em Julho. Ainda assim o perfil dos dados é bastante semelhante, caracterizando uma sazonalidade significativa, de acordo com os dados da Tabela 11.




Figura 32. Vendas mensais do produto MAP.

A Figura 33 apresenta as vendas mensais do produto MG. O comportamento das vendas para este produto é bastante semelhante ao do produto MAP. Há um pico em Junho no primeiro ano, que se desloca para Maio no segundo ano e no terceiro ano permanece em Maio, porém um novo pico surge em Julho. Como o perfil dos dados é semelhante para os três períodos a sazonalidade é considerada significativa, de acordo com resultados da Tabela 11, embora instável.




Figura 33. Vendas mensais do produto MG.

A Figura 34 apresenta as vendas mensais do produto MGP. O perfil das vendas é bastante semelhante para os três anos, considerando que há uma variação bastante acentuada da amplitude de um ano para o outro e que no terceiro ano ocorre um máximo das vendas no mês de Julho, diferente do que aconteceu nos períodos anteriores; no primeiro ano o pico foi em Junho e no segundo em Maio. Portanto, há um comportamento sazonal dos dados, o que está de acordo com os resultados da Tabela 11, ou seja, a sazonalidade é significativa.




Figura 34. Vendas mensais do produto MGP.

A Figura 35 apresenta as vendas mensais do produto SP. Os dois primeiros anos de vendas deste produto apresentam um perfil semelhante, sendo que o pico de vendas situa-se entre os meses de maio e junho, já para o terceiro ano as vendas sofrem uma elevada ampliação e o pico fica em torno dos meses de junho e julho. Apesar dessa alteração nos dados do ultimo ano, a análise verifica que os mesmos apresentam sazonalidade significativa, conforme resultados da Tabela 11.




Figura 35. Vendas mensais do produto SP.

A Figura 36 mostra as vendas mensais do produto GR. Apesar dos dados apresentarem diversas flutuações, as mesmas não se repetem em períodos regulares e assim não há sazonalidade significativa, o que se confirma pelos resultados da Tabela 11.




Figura 36. Vendas mensais do produto GR.

A Figura 37 apresenta as vendas mensais do produto P30. As vendas para este produto apresentam variações aleatórias não caracterizando um comportamento sazonal definido e de acordo com a Tabela 11 a sazonalidade não é significativa.




Figura 37. Vendas mensais do produto P30.

A Figura 38 apresenta as vendas mensais do produto P20. Para análise deste produto utilizaram-se somente dados de dois anos (2001 e 2002) devido a não disponibilidade dos mesmos. Há um pico de vendas em Maio, nos dois anos, porém para os demais períodos o perfil não se assemelha, não caracterizando uma sazonalidade significativa.




Figura 38. Vendas mensais do produto P20.

A Figura 39 apresenta as vendas mensais do produto U. Apesar deste produto apresentar, de acordo com a Tabela 11, sazonalidade significativa, o valor de F calculado é um pouco maior que F tabelado, caracterizando uma sazonalidade bastante fraca. Isto também pode ser verificado na análise gráfica, onde os valores não se repetem em períodos iguais.




Figura 39. Vendas mensais do produto U.

A Figura 40 apresenta as vendas mensais para o produto SPM, o qual não apresenta um perfil comum aos dois períodos e desta forma a sazonalidade não é significativa conforme os resultados da Tabela 11.




Figura 40. Vendas mensais do produto SPM.

A Figura 41 apresenta as vendas mensais para o produto M1. As flutuações apresentadas nas vendas deste produto também não caracterizam um padrão sazonal, o que se confirma na verificação da significância da sazonalidade, que foi não significativa.




Figura 41. Vendas mensais do produto M1.

Para a maioria dos produtos que apresentaram sazonalidade significativa observa-se que houve um deslocamento do pico de sazonalidade posicionado, nos dois primeiros anos analisados, em torno dos meses de Maio e Junho para, no terceiro ano, o mês de Julho; ainda no terceiro ano alguns produtos apresentam mais um pico em torno dos meses de Abril e Maio. Este fato caracteriza uma sazonalidade instável que, de acordo com informações da pessoa de contato da Empresa A, é explicado pela disponibilidade da matéria-prima, suscetível as variações climáticas. As variações no clima implicam na produção do mel pelas abelhas (por exemplo, o

excesso de chuvas que impede as abelhas de saírem em busca de pólen e também aumenta o consumo de mel pela própria colméia) e conseqüentemente, na época e na quantidade em que o mesmo é coletado pelo apicultor. Desta forma, atrasos ou antecipações na safra do mel na região onde se situa a empresa, influenciam naturalmente o atendimento da demanda, principalmente quanto aos períodos em que os produtos estão no mercado.

As variações climáticas não influenciam somente a disponibilidade de matéria-prima ou de produto final, mas também o consumo dos produtos da Empresa A, os quais são, em geral, adquiridos mais intensamente em períodos frios, como nos meses de junho e julho, devido suas características fitoterápicas.

As Figuras 42 a 50 mostram os resultados para a previsão de vendas dos produtos que apresentaram sazonalidade significativa (M330, M25, MP, MA, MAP, MG, MGP, SP e U), tanto para o método proposto quanto para os métodos de comparação, Winters e decomposição. A previsão é feita para os meses de Janeiro e Fevereiro de 2003, dando continuidade aos períodos utilizados na análise da demanda. Os valores de vendas de Janeiro e Fevereiro utilizados na comparação das previsões geradas pelos métodos situam-se no Anexo 2, Tabela 2R.

A Figura 42 apresenta a previsão para o produto M330.

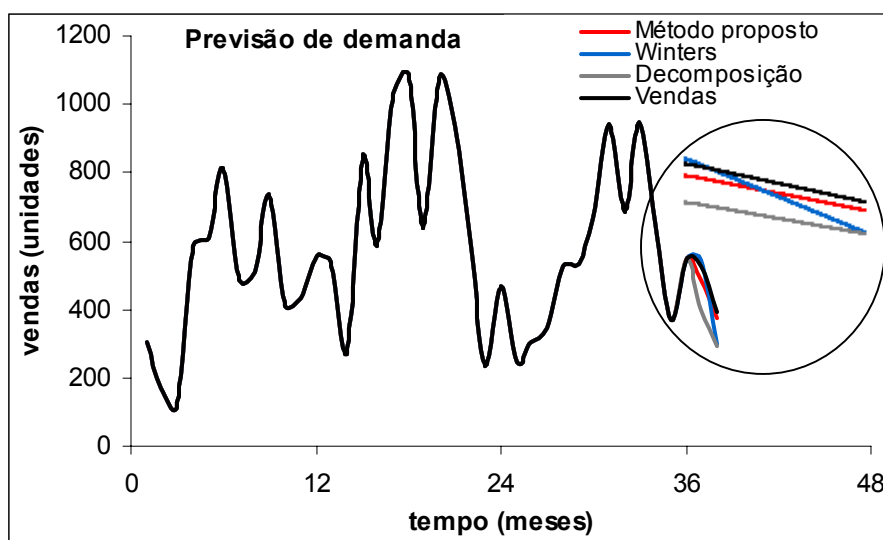


Figura 42. Previsão de vendas para o produto M330.

A Figura 43 apresenta a previsão de vendas para o produto M25.

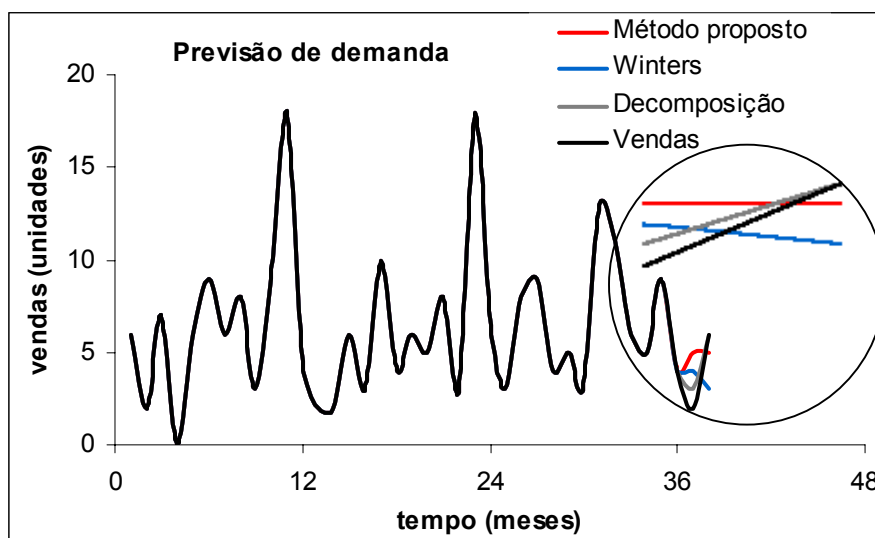


Figura 43. Previsão de vendas para o produto M25.

A Figura 44 apresenta a previsão de vendas para o produto MP.




Figura 44. Previsão de vendas para o produto MP.

A Figura 45 apresenta a previsão de vendas para o produto MA.




Figura 45. Previsão de vendas para o produto MA.

A Figura 46 apresenta a previsão de vendas para o produto MAP.




Figura 46. Previsão de vendas para o produto MAP.

A Figura 47 apresenta a previsão de vendas para o produto MG.




Figura 47. Previsão de vendas para o produto MG.

A Figura 48 apresenta a previsão de vendas para o produto MGP.




Figura 48. Previsão de vendas para o produto MGP.

A Figura 49 apresenta a previsão de vendas para o produto SP.




Figura 49. Previsão de vendas para o produto SP.

A Figura 50 apresenta a previsão de vendas para o produto U.




Figura 50. Previsão de vendas para o produto U.

Pela análise dos gráficos, verifica-se que para alguns exemplos, como para os produtos SP e U, nenhum dos métodos foi capaz de produzir uma boa previsão. O método proposto mostrou bom desempenho em 3 exemplos: M330, MP e MGP. Através das medidas de precisão da previsão apresentadas nas Tabelas 12, 13 e 14 é possível confirmar para quais exemplos o método proposto foi melhor.

A Tabela 12 apresenta os valores do desvio médio absoluto (MAD). Para esta medida, o método proposto gerou previsões mais acuradas para a maioria dos exemplos.

A Tabela 13 apresenta os valores do erro quadrado médio (MSE). Esta medida, que penaliza a previsão muito mais para os desvios extremos do que para pequenos desvios, os valores foram bastante elevados, isto devido às variações nos dados de vendas.

A Tabela 14 apresenta os valores do erro percentual absoluto médio (MAPE). Esta medida apresentou valores percentuais de médios a altos.

Comparativamente, é possível perceber que nenhum dos métodos utilizados foi suficientemente capaz de gerar uma boa previsão para as vendas dos produtos analisados. Este fato deve-se às mudanças ocorridas no padrão do comportamento da demanda, já comentadas anteriormente.

Tabela 12. Resultados e comparação entre os métodos utilizando MAD.

<i>Série</i>	<i>Método proposto</i>	<i>Método de Winters</i>	<i>Método de decomposição</i>	<i>Melhor</i>
<i>Produto M330</i>	31	55	116	<i>Método proposto</i>
<i>Produto M25</i>	2	3	1	<i>Método decomposição</i>
<i>Produto MP</i>	5	36	14	<i>Método proposto</i>
<i>Produto MA</i>	22	93	40	<i>Método proposto</i>
<i>Produto MAP</i>	46	70	65	<i>Método proposto</i>
<i>Produto MG</i>	57	131	61	<i>Método proposto</i>
<i>Produto MGP</i>	19	59	68	<i>Método proposto</i>
<i>Produto SP</i>	294	416	455	<i>Método proposto</i>
<i>Produto U</i>	92	33	52	<i>Método Winters</i>

Tabela 13. Resultados e comparação entre os métodos utilizando MSE.

<i>Série</i>	<i>Método proposto</i>	<i>Método de Winters</i>	<i>Método de decomposição</i>	<i>Melhor</i>
<i>Produto M330</i>	1118	4621	13646	<i>Método proposto</i>
<i>Produto M25</i>	5	7	1	<i>Método decomposição</i>
<i>Produto MP</i>	26	1386	284	<i>Método proposto</i>
<i>Produto MA</i>	679	9232	1637	<i>Método proposto</i>
<i>Produto MAP</i>	2767	4858	4400	<i>Método proposto</i>
<i>Produto MG</i>	3464	17800	5673	<i>Método proposto</i>
<i>Produto MGP</i>	641	3540	5075	<i>Método proposto</i>
<i>Produto SP</i>	91483	191118	211928	<i>Método Winters</i>
<i>Produto U</i>	9032	1125	2908	<i>Método Winters</i>

Tabela 14. Resultados e comparação entre os métodos utilizando MAPE.

<i>Série</i>	<i>Método proposto</i>	<i>Método de Winters</i>	<i>Método de decomposição</i>	<i>Melhor</i>
<i>Produto M330</i>	7	13	25	<i>Método proposto</i>
<i>Produto M25</i>	79	82	29	<i>Método decomposição</i>
<i>Produto MP</i>	4	28	11	<i>Método proposto</i>
<i>Produto MA</i>	29	106	49	<i>Método proposto</i>
<i>Produto MAP</i>	57	72	63	<i>Método proposto</i>
<i>Produto MG</i>	47	134	41	<i>Método decomposição</i>
<i>Produto MGP</i>	13	37	41	<i>Método proposto</i>
<i>Produto SP</i>	33	46	51	<i>Método Winters</i>
<i>Produto U</i>	61	22	34	<i>Método Winters</i>

5.2 Empresa B

A segunda empresa da qual se utilizaram dados para aplicação do método proposto caracteriza-se como uma empresa de grande porte, multinacional, que atua em dois grandes segmentos da agroindústria e indústria de alimentos, de derivados de trigo e de derivados de soja. Os produtos analisados neste trabalho pertencem à divisão de derivados de trigo, como farinhas e misturas para bolos e também misturas para sobremesas. Estes últimos produtos constituem um segmento secundário da empresa, porém as chances de se identificar um comportamento sazonal é maior que para farinhas e misturas para bolos, devido suas características de consumo e por isso foram analisados.

Devido à grande diversidade dos produtos, principalmente com relação as embalagens de diferentes pesos, os mesmos são agrupados em marcas e estas em linhas. Além disso, a estrutura de vendas da empresa divide os produtos por regiões, territórios e vendedores.

Seguindo então a classificação da empresa, optou-se por gerar previsões para marcas de produtos por região e para linhas de produtos por região. Como já foi mencionado anteriormente, esta empresa atua no processamento e fornecimento de *comodities* o que remete a uma demanda dependente, sendo interessante a agregação dos dados. Como a agregação de dados muitas vezes oculta efeitos como sazonalidade e mudanças de tendência, também realizou-se previsões para linhas por estados. Desta forma, aproximadamente 200 exemplos foram analisados.

O número de regiões estabelecido pela empresa é quatro: Oceânia, Ásia, Europa e África. A divisão em regiões não segue a divisão política das Regiões do Brasil e com isso as regiões estabelecidas pela empresa compõem-se de diferentes Estados do Brasil.

As linhas são um total de seis: Diamante, Esmeralda, Rubi, Quartzo, Topázio e Turmalina. As três primeiras representam as farinhas e misturas para bolos e as três últimas, as misturas para sobremesas. Cada linha inclui as seguintes marcas:

- **Linha Diamante:** arco, bocha, judô, karatê, badminton, beisebol, biribol, boxe, bumerangue, halterofilismo, handebol, pesca, basquete, bilhar;
- **Linha Esmeralda:** pólo, surfe, halterofilismo, patinação, softbol, motociclismo, pesca;
- **Linha Rubi:** mergulho, paintball, peteca;
- **Linha Quartzo:** esgrima, esqui, futebol, tênis, rugby;
- **Linha Topázio:** remo, vôlei;
- **Linha Turmalina:** ginástica, skate;

Todas as regiões incluem todas as linhas, porém as linhas de cada região incluem diferentes marcas, portanto nem todas as marcas e, conseqüentemente produtos, são vendidos por todas as regiões.

Os dados obtidos da Empresa B representam as vendas mensais dos produtos desde Janeiro de 2000 até Fevereiro de 2003. Os dados de 2000 a 2002 são utilizados na modelagem e previsão da demanda pelo método proposto, assim como pelos métodos de Winters e de Decomposição Clássica. Os dados de Janeiro e Fevereiro de 2003 são para a avaliação das previsões geradas pelos métodos.

Como o número de exemplos analisados para esta empresa foi bastante grande, somente as séries de dados que apresentaram sazonalidade significativa e que foram então utilizadas na aplicação dos métodos são apresentadas neste trabalho. Os dados utilizados na análise encontram-se no Anexo 3.

A Tabela 15 apresenta os resultados da verificação da significância da sazonalidade. De todas as séries de dados analisadas poucas apresentaram sazonalidade significativa, pois além dos produtos comumente não apresentarem características sazonais, o perfil dos dados do último ano, como pode ser observado nas figuras a seguir, muda de forma acentuada em relação aos períodos anteriores, o que pode ser explicado, de acordo como a pessoa de contato da empresa, pelo fato de que a empresa estava passando por uma fase de reestruturação organizacional, e também porque alguns produtos deixaram de ser vendidos em algumas regiões, enquanto outros passaram a ser vendidos em regiões onde não eram vendidos em anos anteriores.

Tabela 15. Resultados da verificação da significância da sazonalidade da empresa B.

Série	F_0 (calculado)	$F_{5\%,a-1, N-a}$ (tabelado)	Sazonalidade $F_0 > F$
Oceânia Remo	3,15	2,72	Sim
Europa Surfe	2,46	2,22	Sim
África Surfe	3,28	2,22	Sim
Tocantins Turmalina	2,49	2,22	Sim
São Paulo Quartzo	4,08	2,22	Sim
Rio Grande do Sul Topázio	2,86	2,72	Sim
Ceará Topázio	2,93	2,72	Sim
Acre Quartzo	4,11	2,72	Sim

Obs.: Os nomes das regiões, linhas e marcas são fictícios e foram modificados pela própria empresa.

Para a análise de linhas por regiões, nenhuma das linhas apresentou sazonalidade significativa, o que confirma que a agregação de dados pode ofuscar a identificação de padrões característicos, como a sazonalidade. Para a análise de marcas por regiões apenas a marca Remo da região Oceânia e a marca Surfe das regiões África e Europa apresentaram sazonalidade significativa. Para análise de linhas por estados, a linha Turmalina para o estado de Tocantins, a linha Quartzo para os estados do Acre e São Paulo, a linha Topázio para os estados do Ceará e Rio Grande do Sul apresentaram sazonalidade significativa. Destes exemplos somente a marca Surfe pertence ao grupo de farinhas e misturas para bolos, confirmando a nenhuma ou fraca sazonalidade para este grupo de produtos.

Apesar dos produtos da Tabela 15 apresentarem sazonalidade significativa, os valores para a estatística F calculada são pouco diferentes da tabelada, ou seja, a sazonalidade presente nos dados é fraca.

As Figuras 51 a 58 apresentam os gráficos das vendas mensais dos produtos da Tabela 16. Alguns produtos só foram analisados por um período de dois anos e outros por três anos, devido os dados estarem incompletos.

A Figura 51 apresenta as vendas mensais da marca Remo para a região Oceânia. Os picos de venda apresentam-se nos meses de maio e entre julho e agosto, caracterizando uma variação sazonal para estes períodos.




Figura 51. Vendas mensais da marca Remo para a região Oceânia.

A Figura 52 apresenta as vendas mensais da marca Surfe para a região Europa. Os meses de dezembro e janeiro caracterizam pontos regulares e periódicos para este exemplo, ou seja, períodos de sazonalidade.




Figura 52. Vendas mensais da marca Surfe para a região Europa.

A Figura 53 apresenta as vendas mensais da marca Surfe para a região África. Os picos de venda aparecem entre os meses de julho e agosto e entre setembro e outubro.




Figura 53. Vendas mensais da marca Surfe para a região África.

A Figura 54 apresenta as vendas mensais da linha Turmalina para o estado Tocantins. Para este exemplo as vendas apresentam flutuações regulares e periódicas em torno dos meses de fevereiro, abril e outubro.




Figura 54. Vendas mensais da linha Turmalina para o estado Tocantins.

A Figura 55 apresenta as vendas mensais da linha Quartzo para o estado São Paulo. Este exemplo apresenta nos dois primeiros anos uma sazonalidade forte nos meses de março, junho e agosto, porém o perfil de vendas do último ano muda, o mês de agosto permanece e o mês de outubro aparece em comum com o penúltimo ano.




Figura 55. Vendas mensais da linha Quartzo para o estado São Paulo.

A Figura 56 apresenta as vendas mensais da linha Topázio para o estado Rio Grande do Sul. Os picos situam-se no mês de julho e entre os meses de setembro e outubro.




Figura 56. Vendas mensais da linha Topázio para o estado Rio Grande do Sul.

A Figura 57 apresenta as vendas mensais da linha Topázio para o estado Ceará. Os picos situam-se entre fevereiro e março, e nos meses de maio e julho.




Figura 57. Vendas mensais da linha Topázio para o estado Ceará.

A Figura 58 apresenta as vendas mensais da linha Quartzo para o estado Acre. Este exemplo apresenta sazonalidade no mês de fevereiro.




Figura 58. Vendas mensais da linha Quartzo para o estado Acre.

As Figuras 59 a 67 apresentam as vendas reais para os meses de janeiro e fevereiro de 2003 e as previsões obtidas pelos métodos para estes meses. Em geral, pela análise dos gráficos de previsão de demanda, os métodos não foram capazes de gerar boas previsões para estes dois períodos, como pode ser visto nas figuras a seguir.

A Figura 59 apresenta a previsão da demanda para a marca Remo para a região Oceânia. As previsões obtidas pelos três métodos foram superestimadas.

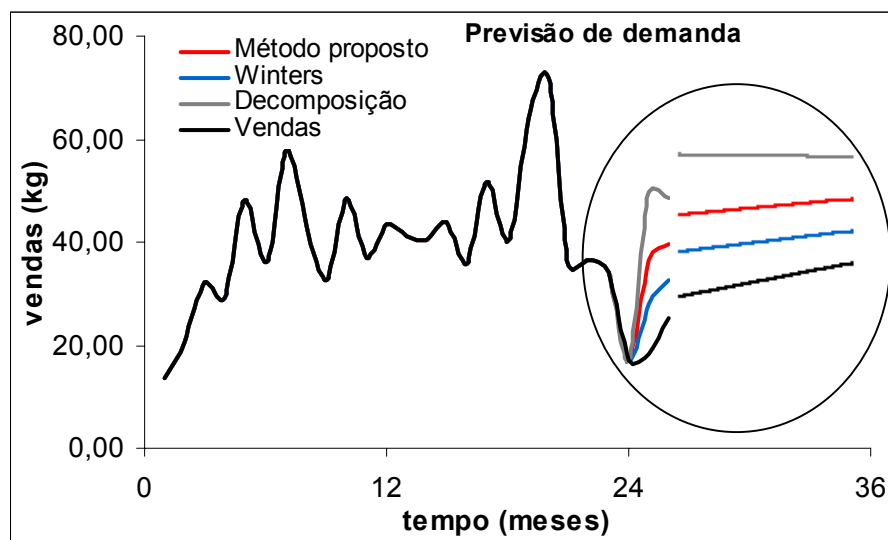


Figura 59. Previsão de vendas para Oceânia_Remo.

A Figura 60 apresenta a previsão da demanda para a marca Surfe para a região Europa. As previsões foram feitas considerando-se uma tendência decrescente, a qual não ocorreu para os períodos de janeiro e fevereiro, provavelmente o que causou a diferença acentuada entre as previsões e as vendas.




Figura 60. Previsão de vendas para Europa_Surfe.

A Figura 61 apresenta a previsão da demanda para a marca Surfe para a região África.




Figura 61. Previsão de vendas para África_Surfe.

Para este exemplo o método de Winters produziu uma boa previsão. A diferença das previsões obtidas pelos demais métodos se deve, provavelmente, ao cálculo da tendência, considerada de forma global, o que não refletiu a realidade dos últimos períodos.

A Figura 62 apresenta a previsão da demanda para a linha Turmalina para o estado Tocantins. As previsões obtidas pelos diferentes métodos foram próximas das vendas.




Figura 62. Previsão de vendas para Tocantins_Turmalina.

A Figura 63 apresenta a previsão da demanda para a linha Quartzo para o estado São Paulo. As vendas, para este exemplo, foram além das previsões geradas.




Figura 63. Previsão de vendas para São Paulo_Quartzo.

A Figura 64 apresenta a previsão da demanda para a linha Topázio para o estado Rio Grande do Sul. Para este exemplo as previsões não refletiram as vendas reais.




Figura 64. Previsão de vendas para Rio Grande do Sul_Topázio.

A Figura 65 apresenta a previsão da demanda para a linha Topázio para o estado Ceará. A tendência crescente observada nos meses de janeiro e fevereiro dos anos anteriores não se repetiu, ao contrário, as vendas decresceram para estes períodos. Desta forma as previsões não estão conforme com as vendas.




Figura 65. Previsão de vendas para Ceará_Topázio.

A Figura 66 apresenta a previsão da demanda para a linha Quartzo para o estado Acre. Graficamente as previsões foram boas.




Figura 66. Previsão de vendas para Acre_Quartzo.

As Tabelas 16, 17 e 18 apresentam os resultados das medidas de precisão da previsão obtida com o método proposto, de Winters e de decomposição.

Tabela 16. Resultados e comparação entre os métodos utilizando MAD.

<i>Série</i>	<i>Método proposto</i>	<i>Método de Winters</i>	<i>Método de decomposição</i>	<i>Melhor</i>
<i>Oceania_Remo</i>	16	8	27	<i>Método Winters</i>
<i>Europa_Surfe</i>	376	342	487	<i>Método Winters</i>
<i>África_Surfe</i>	246	29	379	<i>Método Winters</i>
<i>Tocantins_Turmalina</i>	1,07	1,18	0,55	<i>Decomposição</i>
<i>São Paulo_Quartzo</i>	84	159	85	<i>Método proposto</i>
<i>Rio G Sul_Topázio</i>	32	11	21	<i>Método Winters</i>
<i>Ceará_Topázio</i>	0,53	0,41	0,53	<i>Método Winters</i>
<i>Acre_Quartzo</i>	0,62	1,00	0,32	<i>Decomposição</i>

Tabela 17. Resultados e comparação entre os métodos utilizando MSE.

<i>Série</i>	<i>Método proposto</i>	<i>Método de Winters</i>	<i>Método de decomposição</i>	<i>Melhor</i>
<i>Oceania_Remo</i>	265	73	767	<i>Método Winters</i>
<i>Europa_Surfe</i>	157239	121158	245383	<i>Método Winters</i>
<i>África_Surfe</i>	68382	841	152628	<i>Método Winters</i>
<i>Tocantins_Turmalina</i>	1,25	2,48	0,33	<i>Decomposição</i>
<i>São Paulo_Quartzo</i>	7938	26588	7728	<i>Decomposição</i>
<i>Rio G Sul_Topázio</i>	1055	168	436	<i>Método Winters</i>
<i>Ceará_Topázio</i>	0,30	0,20	0,28	<i>Método Winters</i>
<i>Acre_Quartzo</i>	0,40	1,32	0,11	<i>Decomposição</i>

Tabela 18. Resultados e comparação entre os métodos utilizando MAPE.

<i>Série</i>	<i>Método proposto</i>	<i>Método de Winters</i>	<i>Método de decomposição</i>	<i>Melhor</i>
<i>Oceania_Remo</i>	78	41	133	<i>Método Winters</i>
<i>Europa_Surfe</i>	36	33	47	<i>Método Winters</i>
<i>África_Surfe</i>	59	7	83	<i>Método Winters</i>
<i>Tocantins_Turmalina</i>	93	44	47	<i>Método Winters</i>
<i>São Paulo_Quartzo</i>	24	46	25	<i>Método proposto</i>
<i>Rio G Sul_Topázio</i>	113	40	74	<i>Método Winters</i>
<i>Ceará_Topázio</i>	287	189	372	<i>Método Winters</i>
<i>Acre_Quartzo</i>	55	69	26	<i>Decomposição</i>

A Tabela 16 apresenta os valores do desvio médio absoluto (MAD). Para esta medida o método proposto gerou previsões mais acuradas, ou seja, MAD menor, para a linha Quartzzo no estado de São Paulo.

A Tabela 17 apresenta os valores do erro quadrado médio (MSE). Para esta medida, o método proposto não apresentou boa previsão para nenhum dos exemplos.

A Tabela 18 apresenta os valores do erro percentual absoluto médio (MAPE). Para esta medida o método proposto também apresentou resultado mais preciso ou menor MAPE para a linha Quartzzo no estado de São Paulo.

As previsões para os meses de janeiro e fevereiro de 2003 obtidas pelos métodos proposto e clássicos quando comparadas como os valores reais de vendas destes períodos são, para quase todos os exemplos, bastante diferentes. Isto se deve, principalmente, pelo fato de que o perfil das vendas no ano de 2002 apresentou-se diferente dos outros dois anos anteriores utilizados na análise. Essa mudança no comportamento das vendas ocorreu em função da reestruturação organizacional da empresa, que modificou sua rede de distribuição e vendas, além de novos produtos terem sido lançados e outros terem encerrado a produção. Como os métodos baseiam-se na análise de dados passados, então carregaram na modelagem da demanda uma mistura de um padrão definido que vinha acontecendo com um padrão aleatório do ano de 2002, e desta forma as previsões baseadas nestes dados não refletiram a realidade das vendas atuais, pelo menos para esses dois períodos analisados.

5.3 Empresa C

A empresa C dedica-se a produção de sorvetes, com uma ampla variedade de produtos (tortas geladas, copos sundae) e mais de 50 sabores de sorvete. Sua produção divide-se em quatro linhas:

- Linha leite (à base de leite, creme de leite e polpa de frutas)
- Linha frutas (à base de frutas e suco de frutas)
- Linha *light* (sem adição de açúcar e gordura)
- *Frozen* iogurte (à base de iogurte natural e polpa de frutas)
- *Soya Ice* (à base de proteína de soja, sem lactose e sem colesterol)

Caracteriza-se como uma empresa de pequeno porte e atuando apenas em Florianópolis. Possui três lojas próprias e também abastece vários pontos de venda como hotéis e restaurantes, festas comemorativas e eventos diversos.

As vendas de sorvete são fortemente influenciadas pelas estações do ano, sendo que o verão é o período de vendas mais intenso no mercado de Florianópolis. Desta forma, tem-se uma sazonalidade característica para esta época do ano, fato que motivou a aplicação do método proposto a dados de venda com sazonalidade fortemente significativa.

Os dados utilizados na análise representam o faturamento bruto mensal obtido com as vendas globais de sorvetes durante quatro anos. Os três primeiros anos foram utilizados para análise dos dados e o último ano para comparação da previsão gerada pelo método proposto e pelos demais métodos, Winters e decomposição.

A Figura 67 apresenta os dados do faturamento com as vendas de sorvetes para os anos de 1999, 2000 e 2001. Observam-se flutuações periódicas e regulares, com picos de vendas para os meses de dezembro, janeiro e fevereiro, caracterizando uma sazonalidade para estes meses.




Figura 67. Vendas mensais de sorvete (R\$).

A Tabela 19 apresenta os resultados da análise de variância e teste F para verificação da significância da sazonalidade. De acordo com os dados da Tabela 19, como o F calculado é muito maior que o F tabelado, então a sazonalidade é fortemente significativa.

Tabela 19. Resultados da verificação da significância da sazonalidade da empresa C.

Série	F_0 (calculado)	$F_{1\%,a-1, N-a}$ (tabelado)	Sazonalidade $F_0 > F$
Sorvetes	28,48	3,09	Sim

A Figura 68 apresenta as vendas mensais de sorvetes para o ano de 2002 e as previsões das vendas para o mesmo período, obtidas pelo método proposto, Winters e decomposição. Graficamente, a linha da previsão obtida pelo método proposto é a que melhor se assemelha a linha de vendas, concorrendo apenas nos últimos períodos com a linha de previsão obtida por decomposição.

Contudo, analisando os resultados das medidas de acurácia, na Tabela 20, observa-se que o método proposto apresentou valores menores para as três medidas, ou seja, a previsão gerada pelo mesmo foi mais acurada.




Figura 68. Previsão de vendas de sorvete (R\$).

Tabela 20. Resultados e comparação entre os métodos através das medidas de acurácia.

<i>Medida</i> <i>Método</i>	<i>MAD</i>	<i>MSE</i>	<i>MAPE</i>	<i>Melhor</i>
<i>Proposto</i>	9	182	18	<i>Proposto</i>
<i>Winters</i>	19	501	45	<i>Proposto</i>
<i>Decomposição</i>	12	359	22	<i>Proposto</i>

Com aplicação do método proposto utilizando dados reais de vendas de produtos alimentícios foi possível verificar diferentes comportamentos da demanda em relação à sazonalidade, já que este era um dos objetivos do trabalho, estudar a sazonalidade.

Para aqueles dados que apresentaram uma sazonalidade forte e significativa, o método proposto foi capaz de gerar previsões de boa acuracidade. Para aqueles dados cuja sazonalidade apresentou-se fraca ou instável, a previsão obtida pelo método proposto não acompanhou satisfatoriamente a demanda real, o que também se verificou com as previsões dos métodos clássicos.

CAPÍTULO 6

6 CONCLUSÕES E SUGESTÕES

Este capítulo apresenta as conclusões gerais deste trabalho e as sugestões para trabalhos futuros.

6.1 Conclusões

Neste trabalho, desenvolveu-se um método de previsão da demanda de produtos ou grupos de produtos capaz de prover dados para o planejamento da produção. Os dados gerados pelo método proposto fornecem estimativas da demanda futura, que apóiam os planos de produção (estoque, capacidade) na tarefa de informar o que, quando e quanto produzir.

Estas informações são vitais para qualquer empresa que se preocupa com o planejamento de suas operações, principalmente para aquelas cujos produtos são perecíveis e que dependem da disponibilidade de matéria-prima de origem agropecuária, como é o caso da Indústria de Alimentos.

O método proposto analisa um aspecto fundamental que é a significância da sazonalidade supostamente presente nos dados. Para produtos como alimentos, analisados neste trabalho, a sazonalidade é uma característica bastante freqüente, porém algumas flutuações que aparecem nos dados nem sempre representam sazonalidade. Desta forma, a verificação da significância da sazonalidade através da análise de variância e teste F proporciona um bom indicador da natureza dos dados quanto a sua sazonalidade.

O método inclui ainda o modelo matemático que se baseia na análise de séries temporais, decompondo os dados da demanda em seus componentes, modelando-os e reagrupando-os para gerar a previsão. O modelo é de fácil e rápida operacionalização, o que pode estimular a sua aplicação por parte do pessoal responsável pela previsão e planejamento.

A aplicação do modelo a dados bibliográficos se revelou bastante preciso, de modo que os resultados, comparados com os procedimentos matemáticos dos métodos clássicos de Winters e de Decomposição, mostraram-se iguais ou melhores.

A partir da validação teórica do modelo, seguiu-se com a aplicação do método proposto usando dados reais de vendas de produtos alimentícios. Os dados necessários para esta etapa foram obtidos de três empresas de alimentos.

A primeira empresa dispõe de produtos de natureza sazonal, principalmente porque sua produção depende não só da sazonalidade da demanda, mas igualmente da sazonalidade do fornecimento, já que sua matéria-prima, o mel de abelha, está disponível somente em determinadas estações. Contudo, a análise dos dados para os produtos desta empresa mostrou poucos produtos com sazonalidade significativa, pois os picos de sazonalidade apresentaram-se instáveis, ou seja, deslocaram-se entre determinados meses de um ano para o outro. Para aqueles produtos com sazonalidade significativa, ainda que fraca, o método proposto foi capaz de gerar previsões de boa precisão.

Para a segunda empresa analisou-se dois conjuntos de dados, que de acordo com informações da própria empresa um conjunto, de farinhas e derivados, não apresenta sazonalidade e outro, de pós para sobremesas, poderia apresentar. Com a verificação da sazonalidade confirmaram-se as suposições da empresa, sendo que para o primeiro grupo de produtos apenas uma marca para determinadas regiões apresentou sazonalidade significativa. Para o segundo conjunto alguns exemplos apresentaram sazonalidade significativa. A previsão obtida com o método proposto, e também com os demais métodos utilizados na comparação, não se confirmou para alguns exemplos, já que a sazonalidade mostrou-se fraca. Em outros casos o método proposto gerou uma boa previsão.

Apesar de terem sido comparados apenas dois meses de previsão para os dados destas duas empresas, o método proposto apresentou bons resultados, com erros da ordem dos métodos usados na comparação. Para alguns exemplos nenhum dos métodos foi adequado para as previsões do período analisado.

Já para a terceira empresa confirmou-se a forte sazonalidade para seus produtos e também um bom desempenho do método proposto, pois o perfil dos dados foi satisfatório à aplicação do método proposto.

A aplicação do método a dados reais de vendas de produtos alimentícios se concentrou nos produtos que apresentaram sazonalidade significante, contudo ao contrário do encontrado na validação com os dados bibliográficos, os resultados das previsões não foram tão precisos, apesar da enorme colaboração das empresas, pois o perfil dos dados não foi o mais adequado ao método proposto. Para alguns exemplos, a precisão das previsões foi da mesma ordem que para os métodos clássicos de Winters e Decomposição. Contudo, a análise dos dados permitiu exemplificar diferentes comportamentos da demanda em relação as flutuações sazonais.

Acredita-se que o método de previsão de demanda proposto neste trabalho seja de grande valia para empresas que desejam implementar, de forma fácil e rápida, métodos de previsão de

demanda. Pois para que as empresas possam manter-se competitivas devem investir no planejamento de suas operações, implementando ferramentas que melhorem seu desempenho.

6.2 Sugestões para trabalhos futuros

O método proposto apresentou-se bastante útil na geração de dados de previsão para produtos que apresentam sazonalidade, porém algumas modificações e agregações das características e procedimentos do método podem ser efetuadas e desta forma sugere-se:

- Que os procedimentos de cálculo do modelo sejam transformados num software utilitário;
- Estudar modificações para que o método seja capaz de corrigir as variações da sazonalidade no tempo;
- Pesquisar outros testes para sazonalidade e também para tendência;
- Inclusão no método de um processo de detecção de pontos extremos (*outliers*) presentes nos dados;
- Inclusão no método de formas de agregação dos dados para análise.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALBERNAZ, M. A. **Pesquisa Operacional II – Séries Temporais**. Disponível em: <<http://venus.rdc.puc-rio.br/marcoalb/PO-II/Series.PDF>> Acesso em: 12 dez. 2002.
- BARSKY, R. B.; MIRON, J. A. The seasonal cycle and business cycle. **Journal of Political Economy**, Illinois, v. 97, n. 3, p. 503-534, Jun., 1989.
- BUFFA, E. S.; SARIN, R. K. **Modern production/operations management**. New York: John Wiley & Sons, 1987.
- CORRÊA, H. L.; GIANESI, I. G. N.; CAON, M. **Planejamento, programação e controle da produção: MRP II/ERP: conceitos, uso e implantação**. São Paulo: Atlas, 1997.
- DAGUM, E. B. Seasonal factor forecasts from ARIMA models. **Bull. Inst. Internat. Statist**, v.46, n. 3, p. 203-216, 1975.
- DAGUM, E. B. The X-11-ARIMA seasonal adjustment method. Catalogue n. 12-564E, Statistics Canadá, 1980.
- DAVIS, M. M.; AQUILANO, N. J.; CHASE, R. B. **Fundamentos da Administração da Produção**. 3ª ed. Porto Alegre: Bookman, 1997.
- DONK, D. P. van. Make to stock or make to order: The decoupling point in the food processing industries. **International Journal of Production Economics**, n. 69, p. 297-306, 2001.
- FAVARETTO, F. **Uma contribuição ao processo de gestão da produção pelo uso da coleta automática de dados de chão de fábrica**. São Carlos, 2001. 235 f. Tese (Doutorado em Engenharia Mecânica) – Escola de Engenharia de São Carlos, Universidade de São Paulo.
- FREITAS, S. M.; AMARAL, A. M. P. Alterações nas variações sazonais dos preços de amendoim nos mercados primário e atacadista, 1990-2001. **Informações Econômicas**, São Paulo, v.32, n. 5, mai.2002.
- GAIT, N. **Ajustamento sazonal de séries temporais**. São Paulo, 1975. 111 f. Dissertação (Mestrado em Estatística) – Instituto de Matemática e Estatística, Universidade de São Paulo.
- GIL, M. G. B. **Análise de regressão**. <<http://dequim.ist.utl.pt/doe/ACETATOS/REGRES-ace.pdf>> Acesso em: 10 dez. 2002.
- GRANGER, C. W. J. Seasonality: causation, interpretation and implications. In ZELLNER, A. ed. **Seasonal analysis of economic time series**. Washington, U.S. Department of Commerce, Bureau of the Census, p. 33-46, 1978 (Economic Research Report, 1).
- GRETHER, D. M.; NERLOVE, M. Some properties of ‘optimal’ seasonal adjustment. **Econometrica**, Massachusetts, v.38, n.5, p. 682-703, Sep. 1970.

- HILLMER, S. C.; TIAO, G. C. An ARIMA-model-based approach to seasonal adjustment. **Journal of the American Statistical Association**, Washington, v. 77, n. 377, p. 63-70, Mar. 1982.
- KALLEK, S. An overview of the objectives and framework of seasonal adjustment. In: ZELLNER, A. ed. **Seasonal analysis of economic time series**. Washington, U.S. Department of Commerce, Bureau of the Census, p. 3-25, 1978 (Economic Research Report, 1).
- KOEHLER, A. B.; SNYDER, R. D.; ORD, J. K. Forecasting models and prediction intervals for multiplicative Holt-Winters method. **International Journal of Forecasting**, n. 17, p. 269-286, 2001.
- MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; McGEE, V. E. **Forecasting: methods and applications**. 2ª ed., New York: John Wiley & Sons, 1983.
- MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; YNDMAN, R. J. **Forecasting: methods and applications**. 3ª ed., New York: John Wiley & Sons, 1998.
- MARTINS, P. G.; LAUGENI, F. P. **Administração da produção**. São Paulo: Saraiva, 1998.
- MONTGOMERY, D. C.; JOHNSON, L. A. **Forecasting and time series analysis**. New York: McGraw-Hill, 1976.
- MONTGOMERY, D. C.; JOHNSON, L. A.; GARDINER, J. S. **Forecasting and time series analysis**. 2ª ed., New York: McGraw-Hill, 1990.
- MONTGOMERY, D. C. **Design and analysis of experiments**. 4ª ed., New York: John Wiley & Sons, 1997.
- MORETTIM, P. A.; TOLOI, C. M. de C. **Modelos para previsão de séries temporais**. Rio de Janeiro: Instituto de Matemática Pura e Aplicada, 1981.
- MOURA JÚNIOR, A. N. C. de. **Novas tecnologias e sistemas de administração da produção – análise do grau de integração e informatização nas empresas catarinenses**. Florianópolis, 1996. Dissertação (Mestrado em Engenharia de Produção) – Departamento de Engenharia de Produção, Universidade Federal de Santa Catarina.
- NAHMIA, S. **Production and operations analysis**. 2ª ed., Illinois: Irwin, 1993.
- NEVES, M. F.; CHADDAD, F. R.; LAZZARINI, S. G. **Alimentos: novos tempos e conceitos na gestão de negócios**. São Paulo: Pioneira, 2000.
- OLIVEIRA, G. A. **Sistema de controle de estoques utilizando a metodologia Box & Jenkins de séries temporais**. Curitiba, 2002. 154 f. Dissertação (Mestrado em Métodos Numéricos em Engenharia) – Programa de Pós-Graduação em Métodos Numéricos para Engenharia, Universidade Federal do Paraná.

- PELLEGRINI, F. R. **Metodologia para implementação de sistemas de previsão de demanda**. Porto Alegre, 2000. 146 f. Dissertação (Mestrado em Engenharia de Produção) – Escola de Engenharia, Universidade Federal do Rio Grande do Sul.
- PIERCE, D. A. A survey of recent developments in seasonal adjustment. **The American Statistician**, v. 34, n. 3, p. 125-134, 1980b.
- PINO, F. A.; FRANCISCO, V. L. F. dos S.; CÉZAR, S. A. G.; SUEYOSHI, M. de L. S.; Amaral, A. M. P. Sazonalidade em séries temporais econômicas: um levantamento sobre o estado da arte. **Agricultura em São Paulo**, São Paulo, v. 41, n. 3, p. 103-133, 1994.
- ROSS, P. J. **Aplicações das técnicas de Taguchi na Engenharia de Qualidade**. São Paulo: Makron Books do Brasil e McGraw-Hill, 1991.
- SALIBY, E. **Lidando com sazonalidades no processo logístico**. Disponível em: <<http://www.cel.coppead.ufrj.br/fr-sazonal.htm>> Acesso em: 29//10/2002.
- SATO, G. S. Perfil da indústria de alimentos no Brasil: 1990-95. **Revista de Administração de Empresas**, São Paulo, v. 37, n. 3, p. 56-67, jul./set. 1997.
- SHAFFER, S. M.; MEREDITH, J. R. **Operations Management**. New York: John Wiley & Sons, 1998.
- SHISKIN, J.; YOUNG, A. H.; MUSGRAVE, J. C. The X-11 variant of the census method II adjustment program. Technical paper 15, US Bureau of the Census, Washington, DC, 1967.
- SLACK, N.; CHAMBERS, S.; HARLAND, C.; HARRISON, A.; JOHNSTON, R. **Administração da Produção**. São Paulo: Atlas, 1997.
- SULE, D. R. **Manufacturing facilities: location, planning and design**. Boston: PWS-KENT Publishing Company, 1988.
- SUTRADHAR, B. C.; MACNEIL, I.B.; DAGUM, E.B. A simple test for stable seasonality. **Journal of Statistical Planning and Inference**, v. 43, p. 157-167, 1995.
- TUBINO, D. F. **Manual de planejamento e controle da produção**. 2ª ed. São Paulo: Atlas, 2000.
- VOLLMANN, T. E.; BERRY, W. L.; WHYBARK, D. C. **Manufacturing planning and control systems**. 4 ed. USA: McGraw-Hill, 1997.
- WALLIS, K. F.; THOMAS, J. J. Seasonal variation in regression analysis. **Journal of the Royal Statistical Society**, Ser. A, v. 134, n. 1, p. 57-72, 1971.
- WHEELWRIGHT, S. C.; MAKRIDAKIS, S. **Forecasting methods for management**. 4ª. ed. New York: John Wiley & Sons, 1985.

Sites pesquisados:

<http://www.abia.org.br>
<http://venus.rdc.puc-rio.br/marcoalb/PO-II/Series.PDF>
<http://www.cel.coppead.ufrj.br/fr-sazonal.htm>
<http://www.timberlake.pt/Softwares.asp>
<http://www.statsoft.com.br/produtos.html>
<http://www.smartcorp.com/vtour.stm>
<http://www.autobox.com/aboxwin.html>
<http://www.statsoft.com.br/produtos.html>
<http://www.unisoma.com>
<http://www.minitab.com/products/13/features.htm#TimeSeries> 21/02/03
<http://www.forecastpro.com>
<http://www.forecastx.com/wizard.asp>
<http://www.fourcast.net>
<http://www.aslog.com.br>
<http://www.ms.ic.uk/iif/index.htm>
<http://www.ibf.org/>
<http://www.sciencedirect.com>
<http://www.forecastingeducation.com>

ANEXO 1

As tabelas a seguir representam os dados utilizados na validação teórica do modelo proposto, no Capítulo 4.

Tabela 1A. Vendas mensais de refrigerante A.

Meses	Ano 1	Ano 2	Ano 3	Ano 4
1	143	189	359	332
2	138	326	264	244
3	195	289	315	320
4	225	293	361	437
5	175	279	414	544
6	389	552	647	830
7	454	674	836	1011
8	618	827	901	1081
9	770	1000	1104	1400
10	564	502	874	1123
11	327	512	683	713
12	235	300	352	487

Tabela 1B. Vendas mensais de refrigerante B.

Meses	Ano 1	Ano 2	Ano 3	Ano 4
1	28	35	45	52
2	31	40	49	60
3	36	46	57	66
4	43	55	68	80
5	46	60	78	85
6	52	68	80	95
7	55	72	88	100
8	59	75	90	104
9	58	70	84	101
10	55	66	80	94
11	47	58	57	81
12	40	50	60	70

Tabela 1C. Vendas mensais de champanhe.

Meses	Ano 1	Ano 2	Ano 3	Ano 4	Ano 5
1	5,375	3,633	4,016	2,639	3,934
2	3,088	4,292	3,957	2,899	3,162
3	3,718	4,154	4,510	3,370	4,286
4	4,514	4,121	4,276	3,740	4,676
5	4,520	4,647	4,968	2,927	5,010
6	4,539	4,753	4,677	3,986	4,874
7	3,663	3,965	3,523	4,217	4,633
8	1,643	1,723	1,821	1,738	1,659
9	4,739	5,048	5,222	5,221	5,951
10	5,428	6,922	6,873	6,424	6,981
11	8,314	9,858	10,803	9,842	9,851
12	10,651	11,331	13,916	13,076	12,670

Tabela 1D. Vendas mensais de tapetes.

Meses	Ano 1	Ano 2	Ano 3	Ano 4
1	31	43	55	66
2	30	42	54	67
3	35	47	60	71
4	42	54	70	78
5	45	57	69	81
6	52	64	76	88
7	58	70	81	93
8	60	71	84	96
9	57	69	80	93
10	51	65	76	87
11	52	60	75	88
12	47	61	71	83

Tabela 1E. Vendas mensais de caixas de papelão.

Meses	Ano 1	Ano 2	Ano 3	Ano 4	Ano 5
1	12	8	12	15	15
2	8	14	8	12	22
3	10	18	18	14	18
4	18	15	13	18	18
5	14	16	14	15	16
6	10	18	18	18	20
7	16	14	17	20	28
8	18	28	20	22	28
9	20	22	25	26	20
10	27	27	28	28	30
11	24	26	18	20	22
12	18	10	18	22	28

Tabela 1F. Vendas mensais de passagens aéreas internacionais.

Meses	Ano 1	Ano 2	Ano 3	Ano 4
1	196	204	242	284
2	196	188	233	277
3	236	235	267	317
4	235	227	269	313
5	229	234	270	318
6	243	264	315	374
7	264	302	364	413
8	272	293	347	405
9	237	259	312	355
10	211	229	274	306
11	180	203	237	271
12	201	229	278	306

ANEXO 2

As tabelas a seguir representam os dados obtidos da Empresa A utilizados na aplicação do método de previsão de demanda proposto nesse trabalho, no Capítulo 5.

Tabela 2A. Vendas mensais do produto M40.

Meses	Ano 1	Ano 2	Ano 3
1	512	2601	2057
2	128	1519	2173
3	807	6480	909
4	264	3329	3183
5	2030	2319	744
6	2310	4574	3510
7	2799	2681	717
8	893	3392	4018
9	525	1752	5091
10	3252	4034	2628
11	2250	3216	10376
12	9699	5197	8370

Tabela 2B. Vendas mensais do produto M330.

Meses	Ano 1	Ano 2	Ano 3
1	303	536	243
2	171	277	303
3	114	848	348
4	584	583	528
5	606	1029	532
6	811	1087	666
7	485	636	943
8	507	1076	682
9	739	936	947
10	409	587	654
11	434	233	369
12	554	466	553

Tabela 2C. Vendas mensais do produto M800.

Meses	Ano 1	Ano 2	Ano 3
1	60	115	188
2	65	161	135
3	194	383	306
4	97	304	357
5	233	275	247
6	400	195	229
7	159	256	344
8	201	193	250
9	314	559	259
10	200	244	240
11	263	224	198
12	149	253	345

Tabela 2D. Vendas mensais do produto MC280.

Meses	Ano 1	Ano 2	Ano 3
1	0	29	6
2	6	24	45
3	30	91	32
4	122	48	41
5	80	24	18
6	70	24	34
7	48	10	67
8	55	37	82
9	71	48	62
10	27	48	24
11	58	55	72
12	6	28	26

Tabela 2E. Vendas mensais do produto M3.5.

Meses	Ano 1	Ano 2	Ano 3
1	1	14	9
2	2	7	6
3	6	12	11
4	20	8	22
5	15	15	35
6	20	37	20
7	27	15	36
8	20	6	21
9	23	15	20
10	23	15	5
11	27	11	4
12	17	11	15

Tabela 2F. Vendas mensais do produto MP.

Meses	Ano 1	Ano 2	Ano 3
1	36	89	17
2	8	94	52
3	3	133	60
4	55	95	262
5	120	127	252
6	151	252	195
7	52	170	424
8	121	128	199
9	27	63	141
10	32	164	129
11	55	32	76
12	75	21	59

Tabela 2G. Vendas mensais do produto MA.

Meses	Ano 1	Ano 2	Ano 3
1	36	45	17
2	8	68	48
3	7	62	73
4	73	86	213
5	81	199	207
6	143	84	125
7	30	81	286
8	44	62	96
9	10	48	74
10	2	89	100
11	23	13	100
12	28	8	77

Tabela 2H. Vendas mensais do produto MAP.

Meses	Ano 1	Ano 2	Ano 3
1	0	40	8
2	2	68	34
3	5	65	106
4	14	89	238
5	89	204	233
6	156	120	192
7	30	102	369
8	76	74	184
9	24	53	161
10	9	96	171
11	42	35	103
12	25	17	87

Tabela 2I. Vendas mensais do produto MG.

Meses	Ano 1	Ano 2	Ano 3
1	36	69	15
2	8	32	53
3	5	64	62
4	68	79	217
5	95	239	249
6	155	128	164
7	65	86	340
8	63	80	146
9	19	82	100
10	9	130	109
11	49	26	49
12	24	7	115

Tabela 2J. Vendas mensais do produto MGP.

Meses	Ano 1	Ano 2	Ano 3
1	2	52	14
2	2	38	57
3	3	110	104
4	14	121	246
5	113	305	281
6	123	174	277
7	51	105	535
8	102	148	299
9	72	73	226
10	29	148	262
11	57	22	112
12	24	11	104

Tabela 2K. Vendas mensais do produto SP.

Meses	Ano 1	Ano 2	Ano 3
1	134	323	158
2	42	297	184
3	139	536	407
4	387	379	625
5	807	590	984
6	568	636	1484
7	461	384	1665
8	542	487	1037
9	476	471	1112
10	299	458	758
11	386	207	512
12	215	120	398

Tabela 2L. Vendas mensais do produto GR.

Meses	Ano 1	Ano 2	Ano 3
1	0	2	8
2	0	13	4
3	1	11	3
4	1	36	4
5	5	17	14
6	21	13	5
7	11	8	8
8	23	28	0
9	4	14	9
10	14	22	2
11	22	16	2
12	5	10	8

Tabela 2M. Vendas mensais do produto P30.

Meses	Ano 1	Ano 2	Ano 3
1	225	420	417
2	900	439	306
3	744	597	549
4	505	310	189
5	426	42	250
6	579	544	290
7	421	11	540
8	797	517	647
9	333	345	346
10	247	553	523
11	521	535	564
12	833	276	913

Tabela 2N. Vendas mensais do produto P20.

Meses	Ano 1	Ano 2
1	173	64
2	78	68
3	119	101
4	85	312
5	361	442
6	211	278
7	129	553
8	162	330
9	117	525
10	241	276
11	28	183
12	59	193

Tabela 2O. Vendas mensais do produto U.

Meses	Ano 1	Ano 2
1	85	51
2	90	106
3	72	114
4	114	388
5	270	344
6	408	262
7	222	529
8	121	393
9	375	576
10	392	305
11	71	250
12	117	108

Tabela 2P. Vendas mensais do produto SPM.

Meses	Ano 1	Ano 2
1	171	36
2	261	89
3	96	215
4	208	365
5	403	529
6	464	887
7	171	716
8	294	487
9	138	542
10	279	524
11	118	230
12	108	304

Tabela 2Q. Vendas mensais do produto M1.

Meses	Ano 1	Ano 2
1	15	84
2	53	50
3	73	114
4	38	106
5	143	83
6	111	244
7	119	57
8	104	76
9	92	100
10	156	138
11	181	271
12	126	111

Tabela 2R. Vendas dos meses de Janeiro e Fevereiro de 2003.

Produto	Janeiro	Fevereiro
M40	6699	6227
M330	527	394
M800	209	196
MC280	98	1
M3.5	16	10
M25	2	6
MP	127	130
MA	105	70
MAP	146	72
MG	75	179
MGP	177	148
SP	823	938
GR	3	1
P30	331	216
P20	241	436
U	162	145
SPM	381	724
M1	125	164

ANEXO 3

As tabelas a seguir apresentam os dados da Empresa B utilizados na aplicação do método proposto, descrita no Capítulo 5. As tabelas a seguir apresentam somente os dados de vendas para aqueles produtos que apresentaram sazonalidade significativa, já que foram analisados aproximadamente 200 produtos desta empresa.

Tabela 3A. Dados de vendas da Empresa B referentes ao ano 2000.

Regional	Estado	Linha	Marca	jan/00	fev/00	mar/00	abr/00	mai/00	jun/00	jul/00	ago/00	set/00	out/00	nov/00	dez/00
África	-	Esmeralda	Surfe	575,35	605,35	546,95	532,80	566,25	520,80	677,30	1015,35	878,60	1166,25	862,55	743,15
Ásia	CEARA	Topázio	-	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,11	0,14	0,00
Europa	-	Esmeralda	Surfe	1525,60	1479,35	1560,65	1678,75	1804,85	1695,65	1636,00	1732,25	1634,65	1811,45	1827,05	1398,55
Europa	ACRE	Quartzo	-	0,00	0,00	0,00	0,00	0,00	0,00	1,42	0,65	7,89	1,22	0,60	0,33
Europa	RIO GDE SUL	Topázio	-	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	27,49	27,69	14,69	36,72
Europa	TOCANTINS	Turmalina	-	0,53	0,63	0,39	2,17	0,42	0,57	2,02	1,58	1,25	3,91	0,75	1,04
Oceânia	-	Esmeralda	Remo	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	24,35	21,57	30,90	37,26
Oceânia	SAO PAULO	Quartzo	-	216,86	327,31	416,33	304,95	299,65	511,28	351,89	467,83	465,85	426,34	430,80	414,71

Tabela 3B. Dados de vendas da Empresa B referentes ao ano 2001.

Regional	Estado	Linha	Marca	jan/01	fev/01	mar/01	abr/01	mai/01	jun/01	jul/01	ago/01	set/01	out/01	nov/01	dez/01
África	-	Esmeralda	Surfe	918,50	617,75	795,80	897,50	752,75	716,90	1178,95	1003,00	1287,55	1282,65	1106,40	996,25
Ásia	CEARA	Topázio	-	0,00	0,19	0,74	0,20	0,38	0,10	1,20	0,37	0,34	0,13	0,09	0,06
Europa	-	Esmeralda	Surfe	1444,20	892,65	1286,05	1178,55	1285,60	1528,15	1306,50	1362,75	1410,85	1073,55	1097,20	1172,60
Europa	ACRE	Quartzo	-	0,29	2,50	0,00	0,00	0,70	1,01	5,26	-1,46	1,16	1,37	1,01	0,88
Europa	RIO GDE SUL	Topázio	-	18,68	40,18	51,77	62,17	71,91	77,43	94,22	57,90	68,61	72,57	48,82	45,61
Europa	TOCANTINS	Turmalina	-	0,59	1,69	1,11	2,15	2,04	0,92	1,53	2,28	3,32	3,63	1,08	1,67
Oceânia	-	Topázio	Remo	13,67	20,75	32,35	29,05	48,28	36,05	57,68	43,27	32,81	48,62	36,83	43,31
Oceânia	SAO PAULO	Quartzo	-	318,34	343,25	426,90	310,23	420,60	528,21	335,61	429,66	385,92	430,71	527,84	398,55

Tabela 3C. Dados de vendas da Empresa B referentes ao ano 2002.

Regional	Estado	Linha	Marca	jan/02	fev/02	mar/02	abr/02	mai/02	jun/02	jul/02	ago/02	set/02	out/02	nov/02	dez/02
África	-	Esmeralda	Surfe	1043,15	732,50	602,40	716,60	759,30	752,05	933,55	528,60	688,40	632,25	415,05	386,75
Ásia	CEARA	Topázio	-	0,37	1,10	0,62	0,00	0,36	0,14	0,96	0,00	0,00	0,00	0,14	0,10
Europa	-	Esmeralda	Surfe	1172,65	877,90	1027,45	804,00	1141,55	961,20	1245,50	828,00	1117,80	1048,75	883,70	943,95
Europa	ACRE	Quartzo	-	0,37	1,94	0,70	0,49	0,08	0,40	0,42	0,00	0,45	0,57	0,23	0,00
Europa	RIO GDE SUL	Topázio	-	61,16	61,50	61,01	43,75	59,28	79,17	81,51	42,15	66,24	36,11	44,77	39,47
Europa	TOCANTINS	Turmalina	-	0,70	2,67	1,77	6,62	0,92	2,93	1,42	1,99	1,53	2,30	0,00	0,48
Oceânia	-	Topázio	Remo	41,02	40,31	44,01	35,90	51,58	40,39	63,99	71,74	35,48	36,35	34,13	16,91
Oceânia	SAO PAULO	Quartzo	-	279,17	345,86	331,05	320,92	384,20	396,02	365,64	354,03	254,58	234,47	242,61	108,66

Tabela 3D. Vendas dos meses de Janeiro e Fevereiro de 2003.

Regional	Estado	Linha	Marca	jan/03	fev/03
África	-	Esmeralda	Surfe	515,10	386,65
Ásia	CEARA	Topázio	-	0,69	0,09
Europa	-	Esmeralda	Surfe	1064,90	1017,80
Europa	ACRE	Quartzo	-	0,59	2,46
Europa	RIO GDE SUL	Topázio	-	30,58	26,57
Europa	TOCANTINS	Turmalina	-	0,51	3,70
Oceânia	-	Topázio	Remo	17,93	19,26
Oceânia	SAO PAULO	Quartzo	-	349,38	345,01

ANEXO 4

A tabela a seguir apresenta os dados da Empresa C utilizados na aplicação do método proposto, descrita no Capítulo 5.

Tabela 4A. Dados de vendas da Empresa C.

Meses	1999	2000	2001	2002
Janeiro	80	103	128	99
Fevereiro	73	80	94	81
Março	50	50	53	65
Abril	21	31	34	29
Maio	14	11	13	26
Junho	11	10	15	17
Julho	20	13	26	23
Agosto	17	12	25	24
Setembro	21	18	28	26
Outubro	27	26	33	38
Novembro	28	29	41	51
Dezembro	48	63	79	103