

DEFINIÇÃO DE UM MODELO DE PREVISÃO DAS VENDAS DA REDE VAREJISTA
ALPHABETO

André Furtado Silva

MONOGRAFIA SUBMETIDA À COORDENAÇÃO DE CURSO DE ENGENHARIA
DE PRODUÇÃO DA UNIVERSIDADE FEDERAL DE JUIZ DE FORA
COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A
GRADUAÇÃO EM ENGENHARIA PRODUÇÃO.

Aprovada por:

Prof. Fernando Marques de Almeida Nogueira, D.Sc.

Prof. Marcos Martins Borges, D.Sc.

Filipe Rocha Furtado.

JUIZ DE FORA, MG - BRASIL
NOVEMBRO DE 2008

SILVA, ANDRÉ FURTADO

Definição de um Modelo de Previsão das
Vendas da Rede Varejista Alfabeta

[Juiz de Fora] 2008

vii, 42 p. 29,7 cm (EPD/UFJF, Engenharia
de Produção, 2008)

Tese - Universidade Federal de Juiz de
Fora, EPD

1. Métodos de Previsão

I. EPD/UFJF II. Título (série)

Resumo da monografia apresentada à Coordenação de Curso de Engenharia de Produção como parte dos requisitos necessários para a graduação em Engenharia Produção.

DEFINIÇÃO DE UM MODELO DE PREVISÃO DAS VENDAS DA REDE VAREJISTA
ALPHABETO

André Furtado Silva

Novembro/2008

Orientador: Fernando Marques de Almeida Nogueira

Curso: Engenharia de Produção

O aquecimento e conseqüente acirramento do mercado nacional têm levado diversas empresas a se interessarem cada vez mais pelo processo de previsão de vendas. Neste contexto, este trabalho foi realizado na rede varejista de vestuário Alphabeto e objetivou determinar o melhor modelo quantitativo que aperfeiçoe a previsão das vendas agregada de todas as lojas que compõe a rede Alphabeto, além de apoiar a gestão dos estoques, evitando investimentos desnecessários e melhorando o nível de atendimento aos clientes. Para isto, foi feito um estudo comparativo entre três métodos quantitativos de previsão, que após análise das componentes da série temporal, foram julgados mais adequados. Posteriormente à comparação dos erros obtidos com tais métodos, concluiu-se que o modelo SARIMA $(0,1,1) * (0,1,0)_{12}$ é o mais adequado para realizar as previsões, uma vês que obteve os melhores desempenhos nas análises *within-sample* e *out-of-sample*.

Palavras-chaves: Previsão de Vendas, Mercado Varejista, Modelos Quantitativo, SARIMA

Abstract of Thesis presented to EPD/UFJF as a partial fulfillment of the requirements for the undergraduate degree of Production Engineering

FINDING THE MOST ACCURATE SALES FORECASTING MODEL FOR
ALPHABETO RETAIL CHAIN

André Furtado Silva

November/2008

Advisor: Fernando Marques de Almeida Nogueira.

Department: Production Engineering

Since the Brazilian retail market is getting, not only hotter, but also more competitive day by day, the companies are paying more attention in their sales forecasting process. In this context, this thesis has been done on the retail chain Alphabeto and it intended to conclude the quantitative forecast model that best improve the aggregated sales forecasting result of all stores within Alphabeto's chain. Furthermore, it will support the management and stock control, avoiding unnecessary investments and improving the quality of service offered to final customers. In order to obtain an acceptable result, a comparative study among three quantitative forecasting methods, judged more adequate after analyze the components of the time series, have been done. Finding out that the model that more accurate describe how the demand of Alphabeto's products performs is the SARIMA $(0,1,1) * (0,1,0)_{12}$, once it has outperformed the others models in both winthin-sample and out-of-sample analysis

Key-Words: Sales Forecasting, Retail Market, Quantitative Forecast Model, SARIMA.

:

SUMÁRIO

I. INTRODUÇÃO	1
1.1 CONSIDERAÇÕES INICIAIS	1
1.2 OBJETIVOS	2
1.3 JUSTIFICATIVAS	2
1.4 CONDIÇÕES DE CONTORNO	2
1.5 METODOLOGIA	3
II. REVISÃO BIBLIOGRÁFICA	4
2.1 INTRODUÇÃO	4
2.2 MÉTODOS DE PREVISÃO	5
2.2.1 MÉTODOS QUALITATIVOS	6
2.2.2 MÉTODOS QUANTITATIVOS	8
2.2.3 SELEÇÃO DO MELHOR MÉTODO DE PREVISÃO	22
III. CONJUNTURA E DESCRIÇÃO DO TRABALHO	25
3.1 O VAREJO BRASILEIRO	25
3.2 A EMPRESA	26
3.3 O ESTUDO	27
IV. DESENVOLVIMENTO DO TRABALHO	29
4.1 COLETA DE DADOS	29
4.2 ANÁLISE DA SÉRIE TEMPORAL	30
4.3 APLICAÇÃO DOS MÉTODOS SELECIONADOS	31
4.3.1 SAZONAL ADITIVO DE WINTERS	31
4.3.2 SAZONAL MULTIPLICATIVO DE WINTERS	34
4.3.3 BOX-JENKINS	36
4.3.4 COMPARAÇÃO E ANÁLISE DOS MODELOS	38
V. CONCLUSÃO	40
BIBLIOGRAFIA	41

LISTA DE FIGURAS

Figura 2 - Custo da previsão versus custo da imprecisão.....	5
Figura 3 - Tendências comuns em métodos qualitativos	7
Figura 4 - Características de uma série temporal	10
Figura 5 - Séries temporais.	12
Figura 6 - Série histórica do número de roupas vendidas.....	30
Figura 7 - Previsão com método sazonal aditivo de Winters.....	32
Figura 8 - Previsão com método sazonal multiplicativo de Winters.....	34
Figura 9 - Previsão com método Box-Jenkins.....	36

LISTA DE TABELAS

Tabela 1 - Estatísticas <i>within-sample</i> método sazonal aditivo de Winters.....	32
Tabela 2 - Estatísticas <i>out-of-sample</i> método sazonal aditivo de Winters.....	33
Tabela 3 - Estatísticas <i>within-sample</i> método sazonal multiplicativo de Winters	34
Tabela 4 - Estatísticas <i>out-of-sample</i> método sazonal multiplicativo de Winters	35
Tabela 5 - Estatísticas <i>within-sample</i> método Box-Jenkins.....	36
Tabela 6 - Estatísticas <i>out-of-sample</i> método Box-Jenkins.....	37
Tabela 7 - Comparação dos resultados dos modelos	38

I. INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

As mudanças econômicas ocorridas nos últimos tempos têm forçado as organizações a adaptarem-se continuamente para enfrentar os desafios de manterem-se no mercado de forma competitiva. Para tal, é notória a maior atenção dada ao planejamento, requisito básico para a gestão eficiente de qualquer corporação, seja ela privada ou pública, industrial ou varejista. Para um planejamento efetivo é necessário que se tenha uma expectativa precisa das condições futuras em que a corporação irá operar, e de como se relacionam os elementos condicionantes desta expectativa (PASSARI, 2003).

Como parte de um planejamento, uma empresa varejista, por exemplo, deve antecipar qual a demanda para seus produtos para agendar a compra dos mesmos junto a seus fornecedores, evitando estoques desnecessários ou a falta de artigos nas prateleiras. Devendo também saber os principais fatores que afetam esta demanda, para tomar as decisões corretas quando preciso.

Para apoiar decisões corporativas como a citada acima, as empresas procuram criar sistemas e procedimentos a fim de explorar cenários, com base em informações quantitativas e/ou qualitativa (PASSARI, 2003). Devido ao rápido desenvolvimento de computadores e outras tecnologias de coleta, manipulação e disponibilização de dados, diversas técnicas quantitativas de previsão têm sido pesquisadas e mais amplamente utilizada pelas empresas.

Enquanto os métodos qualitativos baseiam-se em opiniões de especialistas, sendo vulneráveis a tendências que podem comprometer a confiabilidade de seus resultados (PELLEGRINI, 2000), os métodos quantitativos utilizam-se basicamente de dados históricos para detectar padrões de comportamento e estimá-los no futuro. Tais modelos empregam ferramental matemático-estatístico para representar a realidade para a qual foram criados.

1.2 OBJETIVOS

Este trabalho apresenta um estudo para determinar o melhor modelo quantitativo que aperfeiçoe a previsão de vendas agregada de todas as lojas que compõe a rede de vestuário varejista Alfabeto. O mesmo foi demandado visando melhorar a gestão dos recursos da rede, reduzindo o investimento em estoques desnecessários e garantindo o pronto atendimento aos clientes.

1.3 JUSTIFICATIVAS

Através das técnicas de previsão quantitativas foi possível extrair dos dados passados disponíveis sobre o processo de demanda, informações que permitiram a modelagem matemática de seu comportamento. A suposição de uma continuidade nesse comportamento permitiu a realização de previsões, cuja qualidade e precisão foram muito superiores àquelas das previsões anteriormente feitas na empresa, uma vez que esta projeção era estritamente baseada em conceitos qualitativos e não atingiam uma acurácia aceitável, comprometendo todo o planejamento das lojas componentes da rede Alfabeto.

1.4 CONDIÇÕES DE CONTORNO

O trabalho foi desenvolvido junto ao setor responsável pelo planejamento das lojas Alfabeto. Uma das principais atividades desenvolvidas por este setor é justamente a previsão das vendas futuras de toda a rede. Esta previsão é primeiramente realizada de forma agregada, ou seja, é feita a projeção da demanda para todos os produtos de todas as unidades Alfabeto.

Os valores obtidos desta projeção são então repassados ao setor de planejamento e controle da produção (PCP) da Confecções Children, empresa dona da marca Alfabeto e responsável pela produção de todos os produtos comercializados com esta marca. De posse destes dados a fábrica dá início à programação de sua produção, visando atender da melhor forma possível a demanda prevista.

É justamente em cima desta previsão agregada que o trabalho foi concebido, objetivando melhorar sua qualidade. É fácil perceber que uma previsão mal feita influencia não só o resultado das lojas, mas também o desempenho de toda a fábrica,

que, ao fabricar aproximadamente cem mil roupas por mês, pode representar um prejuízo considerável para seus controladores.

1.5 METODOLOGIA

Para a confecção do trabalho, primeiramente foi realizada uma pesquisa bibliográfica sobre os principais métodos de previsão de demanda utilizada atualmente, bem como as limitações e aplicações de cada um deles.

Em seguida foi feita a coleta dos dados, referentes às vendas das lojas Alfabeto, no sistema de gerenciamento da empresa. Possibilitando assim, após estes dados serem analisados, ser criada a série temporal, na qual os modelos propostos foram baseados.

Com a série histórica definida, foi feita a montagem de um gráfico de linha, com os valores das vendas mensais (em unidades) *versus* o tempo (em meses), objetivando obter indícios sobre quais métodos quantitativos de previsão testar.

Logo após, foram aplicados os modelos julgados importantes, para então ser feita uma análise comparativa de seus parâmetros, erros e resultados, definindo assim qual traduz de maneira mais eficaz a demanda e apresenta previsões mais adequadas.

II. REVISÃO BIBLIOGRÁFICA

2.1 INTRODUÇÃO

A previsão de vendas é um importante insumo para o planejamento não só de empresas de diversos setores da economia, mas também de praticamente todos os seus departamentos. A questão que deve ser colocada em pauta não é “as empresas devem prever vendas?”, mas “como as empresas podem prever vendas ao menor custo possível”

Na Figura 2, são ilustrados dois importantes pontos que devem ser enfatizados no que diz respeito aos componentes de custos da equação a seguir:

$$\text{CUSTO TOTAL DE PREVER VENDAS} = \\ \text{CUSTO DE EXECUTAR O PROCEDIMENTO} + \text{CUSTO DOS ERROS DE PREVISÃO}$$

Percebe-se que muitas vezes os custos de utilizar a sensibilidade do tomador de decisão como previsão de vendas é baixíssimo; entretanto, o custo incorrido com erros de previsão mais do que supera esta economia. Por outro lado, o uso de modelos sofisticadíssimos, cuja compreensão é restrita a especialistas, é pouco aconselhável: seus custos de operação são elevados, não sendo compensados mesmo que a precisão das previsões seja aceitável. As empresas, portanto, devem adotar procedimentos de previsão de acordo com suas necessidades de previsão:

- Ao horizonte de previsão (curto, médio ou longo prazo);
- Tipo de produto (classe A, B, C; novo ou já existente; valor agregado alto ou baixo);
- Tipo de decisão a ser tomada.

Uma vez compreendidas as reais necessidades de previsão, a empresa deve escolher o método que se situe mais próximo da região de operação ideal da Figura 2, isto é, aquele que apresentar a melhor relação no *trade-off* custo/precisão (WANKE et al., 2006).

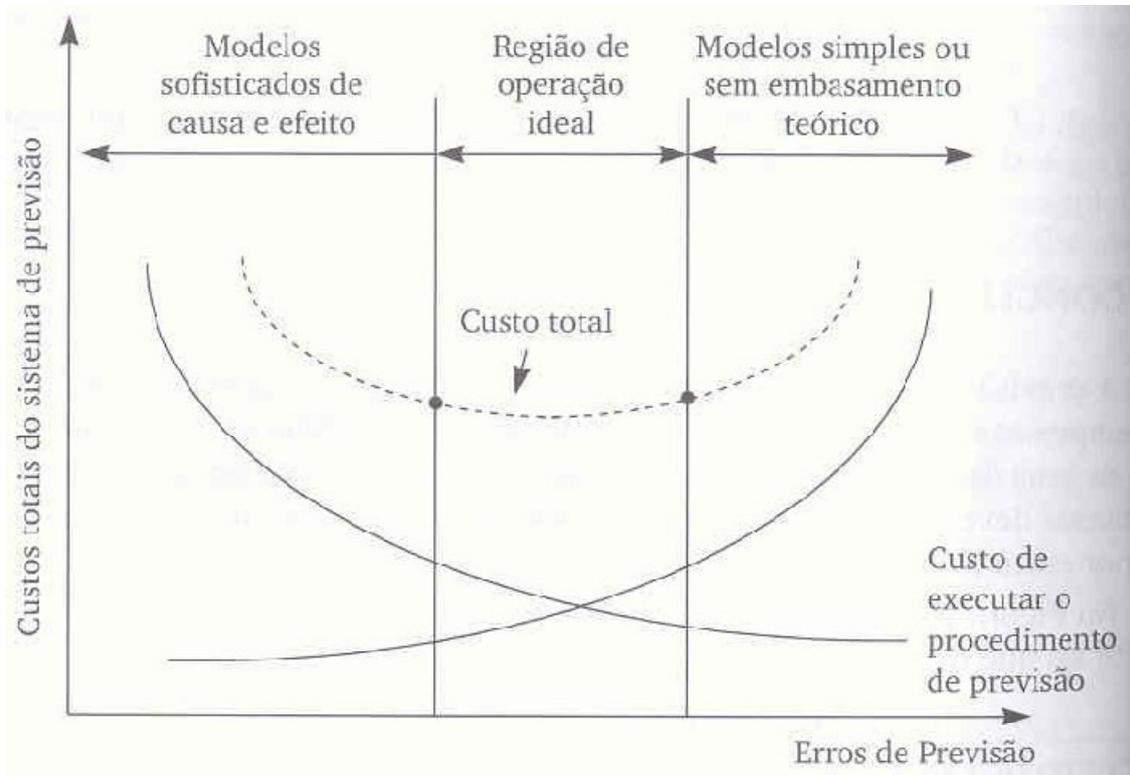


Figura 1 - Custo da previsão versus custo da imprecisão (WANKE et al., 2006, p. 50)

2.2 MÉTODOS DE PREVISÃO

Vários são os métodos padronizados de previsão disponíveis. Tais métodos são divididos em duas categorias: qualitativos e quantitativos. Cada grupo tem diferentes graus em termos de exatidão relativa em previsões de longo prazo e de curto prazo, o nível de sofisticação utilizado e a base lógica (dados históricos, opiniões de especialistas, ou estudos) da qual a previsão é derivado (BALLOU, 2006).

2.2.1 MÉTODOS QUALITATIVOS

Mesmo quando uma empresa utiliza técnicas quantitativas de previsão de demanda, o julgamento e o conhecimento dos analistas, que não são considerados nos modelos, representam um importante papel no processo de previsão. Até mesmo durante a utilização de técnicas quantitativas, o julgamento do decisor está presente, seja quando decide entre quais métodos utilizar, seja quando seleciona os dados que serão utilizados e realiza os tratamentos que julgam necessários (por exemplo, expurgo de *outliers*) (WANKE et al., 2006).

O uso de modelos qualitativos é muito observado quando da necessidade do desenvolvimento de estratégias de longo e médio prazo e de novos produtos onde a taxa de aceitação do mesmo no mercado é ainda incerta, possuindo dados limitados e nenhum precedente histórico (MAKRIDAKIS et al., 1998).

Métodos qualitativos são aqueles que recorrem a julgamento, intuição, pesquisas ou técnicas comparativas a fim de produzir estimativas quantitativas sobre o futuro. As informações relativas aos fatores que afetam a previsão são tipicamente não quantitativas, flexíveis e subjetivas (BALLOU, 2006).

Devido à análise subjetiva apresentam tendências no processo preditivo. A Figura 3 apresenta um quadro com tendências que afetam os métodos qualitativos e esboça resumidamente maneiras de reduzir suas conseqüências. Apesar de dúvidas serem freqüentemente levantadas sobre o valor e precisão de previsões qualitativas, elas oferecem informações úteis às empresas (MAKRIDAKIS et al., 1998).

TIPO DE TENDÊNCIA	DESCRIÇÃO DA TENDÊNCIA	MANEIRAS DE REDUZIR O IMPACTO NEGATIVO DA TENDÊNCIA
Otimismo	Previsão reflete os resultados desejados pelos tomadores de decisão.	Ter mais de uma pessoa para fazer a previsão.
Inconsistência	Incapacidade de aplicar o mesmo critério de decisão em situações similares.	Formalizar o processo de tomada de decisão e criar regras de tomada de decisão.
Novidades	Os eventos mais recentes são considerados mais importantes que eventos mais antigos, que são minimizados ou ignorados.	Considerar os fatores fundamentais que afetam o evento de interesse. Perceber que ciclos e sazonalidades existem.
Disponibilidade	Facilidade com a qual informações específicas podem ser reutilizadas quando necessário.	Apresentar informações completas que apontem todos os aspectos da situação a ser considerada.
Correlações Ilusórias	Acreditar na existência de padrões e/ou que variáveis são relacionadas quando isto não é verdade.	Verificar significância estatística dos padrões. Modelar relações, se possível, em termos de mudanças.
Conservadorismo	Não mudar ou mudar lentamente o ponto de vista quando novas informações / evidências estão disponíveis.	Monitorar as mudanças e elaborar procedimentos para atuar quando mudanças sistemáticas são identificadas.
Percepção seletiva	Tendência de ver problemas baseado na própria experiência.	Fazer com que pessoas com diferentes experiências façam previsões independentes.

Figura 2 - Tendências comuns em métodos qualitativos (Adaptado de MAKRIDAKIS, 1988)

Citado por Lemos (2006), estudos de Kahn (2002) sugerem que tomadores de decisão preferem contar com métodos qualitativos ao invés de métodos quantitativos de previsões de demanda. Os responsáveis pelas tomadas de decisão não estão familiarizados com métodos quantitativos e a utilização de métodos qualitativos cria um sentimento de controle e posse sobre o processo de previsão (SANDERS; MANRODT, 1994; GOODWIN, 2002).

Abaixo estão brevemente descritos alguns métodos qualitativos de previsão de acordo com Gaither e Frazier (2002):

- **Consenso do comitê executivo:** Executivos com capacidade de discernimento, de vários departamentos da organização, formam um comitê que tem a responsabilidade de desenvolver uma previsão de vendas. O comitê pode usar muitas informações (*inputs*) de todas as partes da organização e fazer com que os analistas do staff forneçam análises quando necessário. Essas previsões tendem a ser previsões de compromisso, não refletindo as tendências que poderia estar presentes caso tivessem sido preparadas por um único indivíduo. Esse método de previsão é o mais comum.
- **Método Delphi:** Esse método é usado para se obter o consenso dentro de um comitê. Por esse método, os executivos respondem

anonimamente a uma série de perguntas em turnos sucessivos. Cada resposta é repassada a todos os participantes em cada turno, e o processo é então repetido. Até seus turnos podem ser necessários antes que se atinja o consenso sobre a previsão. Esse método pode resultar em previsões com as quais a maioria dos participantes concordou apesar de ter ocorrido uma discordância inicial.

- **Pesquisas de mercado:** Nesse método, questionários por correspondência, entrevistas telefônicas ou entrevistas de campo formam a base para testar hipóteses sobre mercados reais. Em testes de mercado, produtos comercializados em regiões ou centros de compras *outlets* são estatisticamente extrapolados para mercados totais. Esses métodos comumente são preferidos para novos produtos ou para produtos existentes a serem introduzidos em novos segmentos de mercado.

2.2.2 MÉTODOS QUANTITATIVOS

2.2.2.1 Técnicas de Séries Temporais

Para Wanke e Julianelli (2006) uma série temporal consiste em dados coletados, armazenados ou observados em sucessivos incrementos de tempo. Assim, no estudo de técnicas de previsão de vendas, pode-se definir temporal o histórico das vendas de um determinado item ao longo do tempo.

Ainda segundo Wanke e Julianelli (2006), as técnicas de série temporais são baseadas na identificação de padrões existentes nos dados históricos para posterior utilização no cálculo do valor previsto. Assim, todas essas técnicas consideram uma ou mais das cinco principais componentes de séries temporais.:

- **Nível:** representa o comportamento das vendas caso não existisse nenhuma outra componente. Geralmente, o nível é simplesmente o ponto inicial de uma série de vendas;
- **Tendência:** componente que representa o crescimento ou declínio de uma série no médio ou longo prazo;
- **Sazonalidade:** componente que representa um comportamento periódico de curto ou médio prazo. Por exemplo, sabe-se que as

vendas de sorvete são mais elevadas nos meses do verão e menores no inverno, comportamento este que se repete ano a ano;\

- **Ciclo:** semelhante à sazonalidade mas reflete as flutuações ocorridas no longo prazo, sendo repetidas a cada três, quatro ou mais anos. Geralmente, esta componente é afetada pelas variações econômicas das nações;
- **Aleatoriedade:** as demais variações, não explicadas pela tendência, ciclo e sazonalidade, são denominadas variações aleatórias. Estas são causadas principalmente por eventos particulares e não recorrentes.

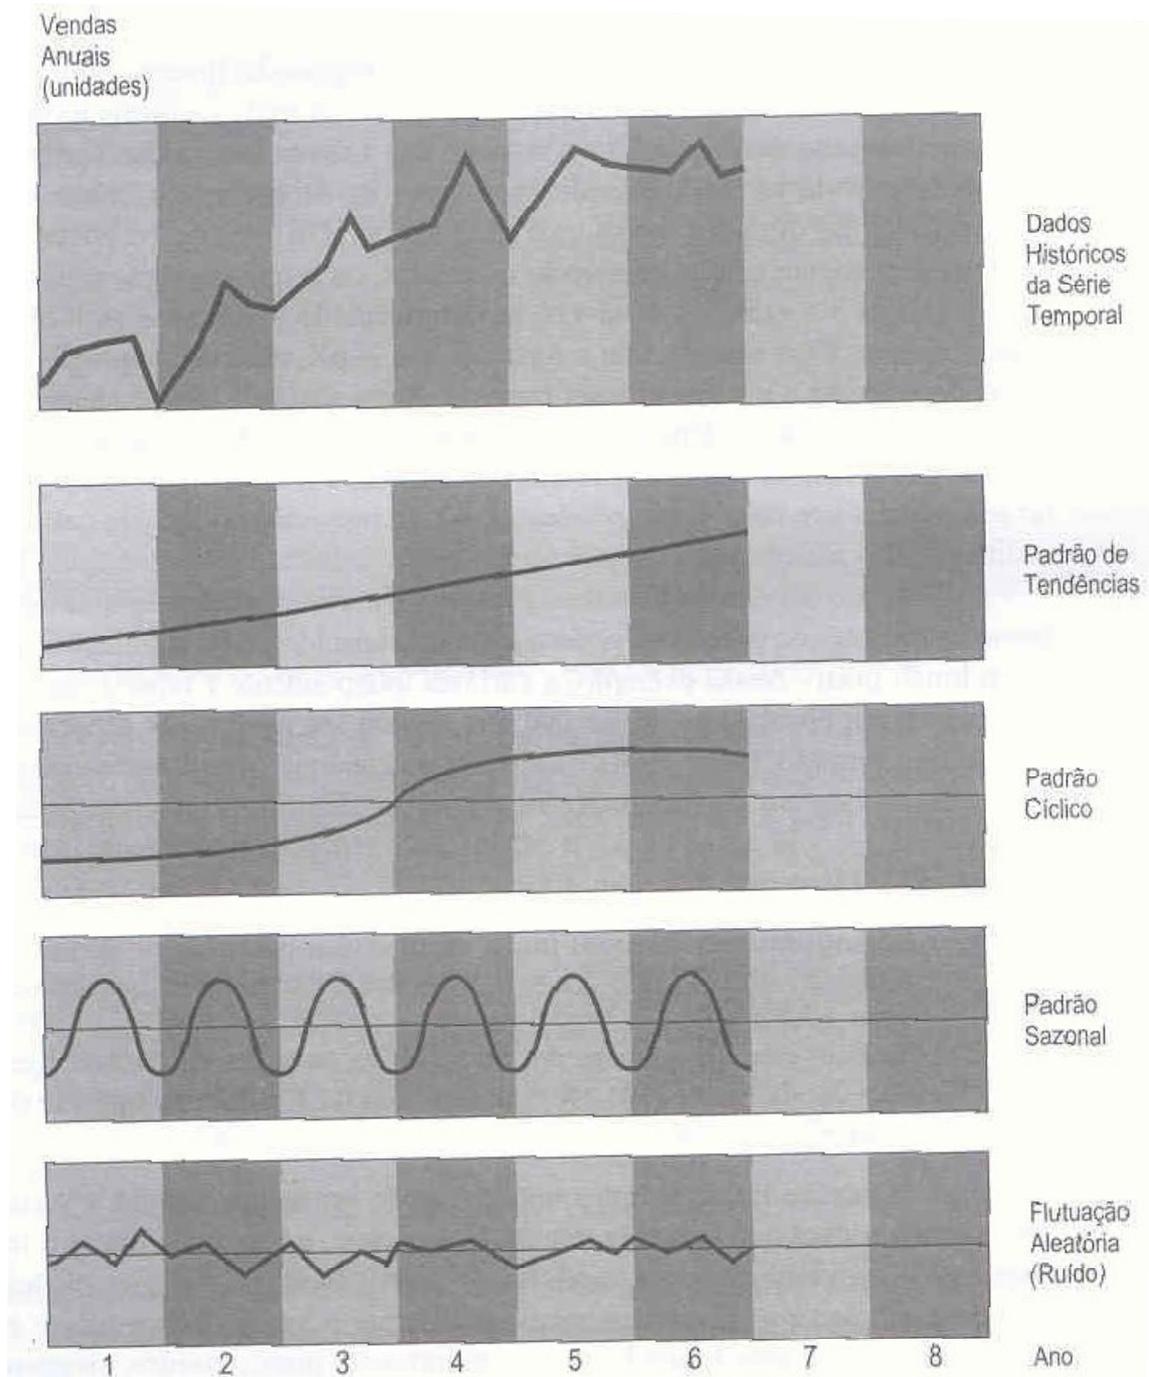


Figura 3 - Características de uma série temporal (GAITHER e FRAZIER, 2002, p. 59)

Segundo Mentzer e Gomes (1989), as técnicas de séries temporais podem ser classificadas em: (i) métodos com modelos matemáticos fixos (FMTS – *fixed-model timeseries*); e (ii) métodos com modelos matemáticos ajustáveis ou abertos (OMTS – *open-model time series*).

Os métodos FMTS, como o próprio nome diz, são compostos por equações fixas que são responsáveis por extrair da série histórica suas principais componentes (nível, tendência, sazonalidade, ciclo e erro aleatório) para projetar um futuro moldado

no padrão dos dados passados. São muito utilizados nas empresas por serem métodos extremamente baratos, simples e de fácil entendimento, proporcionando um ambiente mais flexível para previsões emergenciais de curto prazo. Os métodos de Média Móvel e de Amortecimento Exponencial são métodos FMTS (MENTZER et al., 1989).

Os modelos que se enquadram na classe OMTS só realizam a previsão depois de identificar matematicamente as componentes existentes na série histórica de demanda. Embora muita pesquisa acadêmica seja conduzida com métodos OMTS, no ambiente empresarial estes ainda são pouco utilizados devido à sua complexidade e limitado ganho de acurácia em relação aos métodos FMTS (MENTZER et al., 1984).

Há vários métodos OMTS, entre eles a análise por decomposição, a análise espectral, a análise de Fourier e os modelos de Box-Jenkins. Todas estas técnicas, além de analisarem as componentes presentes nas séries, exigem um histórico razoável de dados.

2.2.2.1.1 Modelos de Box-Jenkins

Para o entendimento dos modelos de Box-Jenkins é necessário o entendimento de alguns conceitos apresentados na sequência.

- **Modelos Determinísticos e Estocásticos:** um modelo é dito determinístico se a previsão gerada para valores futuros é exatamente determinada por alguma função matemática. No entanto, muitos fenômenos não são de natureza determinística, devido à incidência aleatória de fatores desconhecidos; nestes casos, a previsão do valor futuro está sujeita a um cálculo de probabilidade. Modelos matemáticos desenvolvidos para analisar tais sistemas são ditos estocásticos, sendo caracterizado por uma família de variáveis aleatórias que descrevem a evolução de algum fenômeno de interesse (PELLEGRINI, 2000).
- **Modelos Estocásticos Estacionários e Não-estacionários:** modelos estacionários pressupõem um processo sob equilíbrio, onde a família de variáveis se mantém a um nível constante médio (Box et al., 1994).

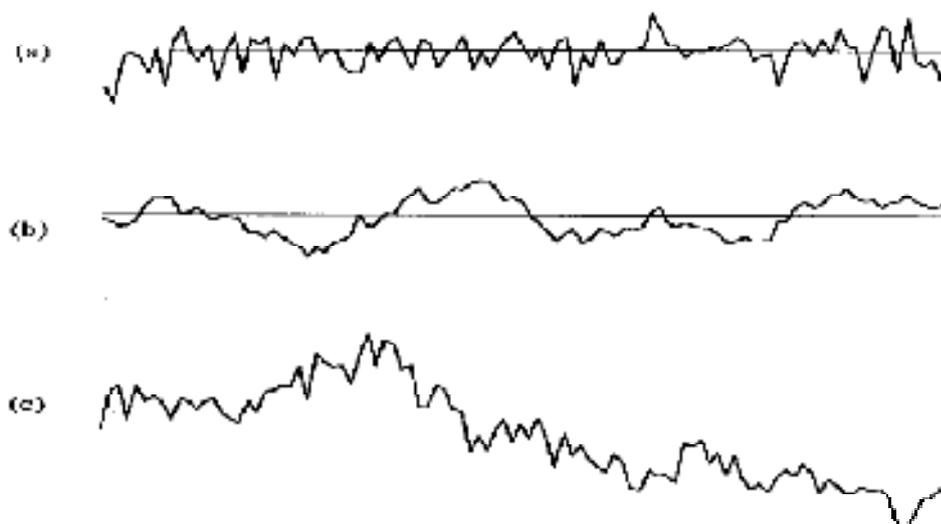


Figura 4 - Séries temporais. (PELLEGRINI, 2000).

Segundo Pellegrini (2000) Os gráficos (a) e (b) na Figura 5 mostram séries temporais exibindo variação estacionária. Tais séries variam de maneira estável no tempo, sobre um valor de média fixo. O gráfico (c) mostra uma série temporal não estacionária, a qual não se desloca no tempo sobre uma média fixa.

A série da Figura 5(a) é uma série de ruído aleatório. Em tais séries, as diferenças entre as observações e a média são estatisticamente independentes, seguindo alguma distribuição de probabilidade (geralmente normal, com média zero e desvio padrão σ_a^2). A propriedade chave em uma série de ruído aleatório é que a ordem na qual as observações ocorrem não informa nada a respeito da série. Assim, valores passados da série não podem ser utilizados na previsão de valores futuros (BOX apud PELLEGRINI, 2000).

A série da Figura 5(b) também é estacionária, mas apresenta ruídos autocorrelacionados. Nesse caso, diferenças entre observações e a média não são estatisticamente independentes entre si. Dependência estatística implica na probabilidade de uma diferença qualquer ser influenciada pela magnitude das demais diferenças na série. Na série da Figura 5(b), diferenças positivas tendem a seguir diferenças positivas e vice-versa.

Finalmente, a Figura 5(c) ilustra uma variação não estacionária. Essas séries são encontradas com freqüência em aplicações na indústria, bem como em estudos de economia e negócios.

Os modelos de Box-Jenkins, também conhecidos como Modelos Autoregressivos Integrados a Média Móvel, ou simplesmente ARIMA (*Autoregressive Integrated Moving Average*), foram propostos por George Box e Gwilym Jenkins no início dos anos 70 (BOX et. al., 1994).

Apesar de ser uma abordagem poderosa na solução de muitos problemas de previsão, é duvidoso que as vantagens da acuracidade obtida possam justificar o custo envolvido no processo de construção destes modelos. Os modelos ARIMA são mais eficientemente empregados em situações onde somente um pequeno número de séries temporais são envolvidas e a administração está disposta a despende os recursos necessários para obter um alto grau de precisão nas previsões. Segundo Montgomery (1990), o método é apropriado para séries de comprimento médio a longo, de, no mínimo, 50 e, preferencialmente, 100 observações.

Segundo Rinaldi (2005) uma serie temporal, denominada por z_t , é um conjunto de valores sucessivos e dependentes de alguma variável (volume de vendas, temperatura, etc) registrada no decorrer do tempo.

Uma estatística importante na análise de séries temporais é o coeficiente de auto-correlação ρ , sendo este utilizado para descrever a correlação entre dois valores da mesma série temporal, em diferentes períodos de tempo. De modo geral, o coeficiente de auto-correlação ρ_k mede a correlação entre observações distantes k períodos de tempo (ou seja, uma auto-correlação de *lag* k).

A auto-correlação de *lag* k é medida pelo coeficiente ρ_k , definido por:

$$\rho_k = \frac{E[(z_t - \mu)(z_{t-k} - \mu)]}{\sqrt{E[(z_t - \mu)^2]E[(z_{t-k} - \mu)^2]}} \quad (1)$$

Onde μ é a média da série temporal.

Os modelos de Box-Jenkins assumem que os valores de uma série temporal são altamente dependentes, isto é, cada valor atual pode ser explicado por valores anteriores da série. Os modelos ARIMA e SARIMA representam uma das classes mais gerais destes modelos.

Os modelos, mais especificamente, são AR(p) (auto-regressivo de ordem p) e MA(q) (média-móvel de ordem q), que podem ser integrados, gerando os modelos ARIMA(p,d,q), ou seja, composto de AR(p) e MA(q) com d diferenciações. Essas diferenciações são referentes a estacionaridade de z_t , ou seja, podem ser aplicadas diferenciações na série até que esta estabilize no tempo. Em geral d assume os valores de 0, 1 ou 2 no máximo, sendo que para $d = 0$ nenhuma diferenciação foi

aplicada. Existem ainda modelos com sazonalidade. Esses são utilizados para analisar séries temporais que apresentam comportamento recursivo no tempo, por exemplo, a cada s períodos de tempo. Assim, se um comportamento se repete a cada ano, ou seja, com sazonalidade anual, então $s = 12$ meses. São denominados por SARIMA $(p,d,q)(P,D,Q)_s$, onde as letras maiúsculas denotam a parte sazonal do modelo e são análogas a p,d,q sendo que s funciona como descrito acima. Trata-se, portanto de um modelo multiplicativo geral considerando conjuntamente as partes sazonal e não sazonal

De acordo com Morettin (2006) a estratégia para a construção do modelo é baseada em um ciclo iterativo, no qual a escolha da estrutura do modelo é baseada nos próprios dados. Os estágios do ciclo iterativo são:

- a) Uma classe geral de modelos é considerada para a análise (especificação);
- b) Há identificação de um modelo, com base na análise de autocorrelações, autocorrelações parciais e outros critérios;
- c) A seguir vem a fase de estimação, na qual os parâmetros do modelo identificado são estimados;
- d) Finalmente, há a verificação ou diagnóstico do modelo ajustado, através de uma análise de resíduos, para saber se este é adequado para os fins em vista (previsão, por exemplo).

Caso o modelo não seja adequado, o ciclo iterativo retorna à fase de identificação. Um procedimento utilizado é identificar não só um único modelo, mas alguns que serão então estimados e verificados. Se o propósito é previsão, será escolhido o melhor, por exemplo, no sentido de fornecer o menor erro quadrático médio de previsão.

Em geral os modelos postulados são parcimoniosos, pois contêm um número pequeno de parâmetros e as previsões obtidas são bastante precisas, comparando-se favoravelmente com os demais métodos de previsão.

2.2.2.1.2 Média Móvel

Por necessitar de poucos dados históricos e ser de fácil implementação e manutenção, o método da média móvel é bem difundido. Todavia, este método apresenta algumas limitações no seu uso. Deve apenas ser empregado para previsões de curto prazo e para dados históricos irregulares, onde os componentes tendência e sazonalidade não estão presentes (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Este método utiliza a média aritmética ou ponderada dos últimos n valores para prever o valor seguinte. Assim, a cada nova observação disponível, o valor mais antigo é descartado e o mais recente é inserido para o cálculo da nova média (WANKE et al., 2006).

As desvantagens desse modelo estão relacionadas à falta de acurácia ao lidar com séries históricas que apresentam tendência ou sazonalidade já que, nesse método, a previsão para o próximo período envolve sempre a adição de novos dados e a desconsideração dos anteriores. Uma alternativa para amenizar esse erro é a utilização da média ponderada para tentar construir um padrão mais próximo à realidade. A desvantagem na utilização da média móvel ponderada é a necessidade de conhecimento para determinar os pesos a serem utilizados (DAVIS; AQUILANO; CHASE, 2001).

2.2.2.1.3 Amortecimento Exponencial Simples (AES)

O método AES pondera os valores utilizados na previsão de acordo com o tempo. Em outras palavras, o AES permite atribuir um maior peso em valores mais recentes, assumindo que estes são mais importantes na determinação do valor previsto (WANKE et al., 2006). Sua representação matemática vem dada por

$$\hat{Z}_{t+1} = \alpha z_t + (1 - \alpha)\hat{z}_t \quad (2)$$

Onde:

- \hat{Z}_{t+1} : previsão da demanda para o tempo $t + 1$, feita no período atual t ;
- α : coeficiente de amortecimento ($0 \leq \alpha \leq 1$);
- z_t : valor real observado no período t ;
- \hat{z}_t : previsão referente ao período t .

O coeficiente de amortecimento α pode ser interpretado como um fator de ponderação, determinando o quanto os valores mais recentes são mais importantes que os mais antigos para a previsão. Assim, quanto mais próximo de 1 for α , a previsão será mais sensível ao último valor observado. Por outro lado, quanto mais próximo de 0 for α , a previsão para cada período seguinte pouco será afetada pelo último valor observado, sendo cada vez mais próxima ao valor da última previsão (WANKE et al., 2006).

É de fácil percepção que a acurácia do método está relacionada com o valor arbitrado de α . Procedimentos para a seleção do valor de α serão abordados na sessão 2.2.2.2.5.

Os modelos de AES também possuem sua precisão relacionada à estimativa inicial para \hat{z}_t . Quando dados históricos estão disponíveis, pode-se usar uma média simples das n observações mais recentes como \hat{z}_t ; caso contrário, pode-se utilizar a observação mais recente, ou fazer uma estimativa subjetiva.

O AES também não deve ser aplicado a séries temporais que apresentem tendência, uma vez que os valores das previsões apresentam um viés, de forma que ficam sistematicamente abaixo dos reais.

2.2.2.1.4 Amortecimento Exponencial Duplo (Método de Holt)

Considerando uma série histórica que apresente um componente de tendência linear de crescimento ou decrescimento, podendo desprezar características como sazonalidade e ciclo, o método de Holt pode ser empregado para obter previsões satisfatórias. Neste método são definidos dois coeficientes de amortecimento, sendo um específico para ajusta a estimativa de tendência.

Neste método são utilizadas as três equações seguintes:

$$L_t = \alpha z_t + (1 - \alpha)(L_{t+1} + T_{t-1}) \quad (3)$$

$$T_t = \beta(L - L_{t-1}) + (1 - \beta)T_{t+1} \quad (4)$$

$$\hat{z}_{t+k} = L_t + kT_t \quad (5)$$

Onde:

- L_t : componente nível;
- T_t : componente tendência;
- α : coeficiente de amortecimento ($0 \leq \alpha \leq 1$);
- β : coeficiente de amortecimento para a estimativa de tendência

$$(0 \leq \beta \leq 1);$$

- z_t : valor real observado no período t ;
- k : número de períodos a serem previstos;
- \hat{z}_{t+k} : previsão para o período $t+k$.

A equação (2) é resultado da adição do termo relativo a estimativa da tendência à formulação do AES. A segunda é utilizada para ajustar a estimativa da tendência, ponderando a estimativa anterior e a mais recente a partir do coeficiente β . Finalmente, a terceira equação retorna a previsão para k períodos à frente (WANKE et al., 2006).

Assim como no AES, o método de Holt requer valores iniciais, neste caso L_0 e T_0 . Uma alternativa para estes cálculos iniciais é igualar L_0 ao último valor observado na série temporal e calcular uma média da declividade nas últimas observações para T_0 . Outra forma de cálculo é a regressão linear simples aplicada aos dados da série temporal, onde se obtém o valor da declividade da série temporal e de L_0 em sua origem (PELLEGRINI, 2000).

Também da mesma maneira que o AES, a precisão obtida com a aplicação do método de Holt está diretamente associada à seleção dos coeficientes α e β . As abordagens para a seleção desses coeficientes estão descritas na sessão 2.2.2.2.5.

2.2.2.1.5 Amortecimento Exponencial Triplo (Modelos de Winters)

Para séries temporais que, além de uma tendência linear, apresentam a componente de sazonalidade, os modelos de Winters podem ser aplicados apropriadamente. Demandas do tipo sazonal são caracterizadas pela ocorrência de padrões cíclicos de variação que se repetem em intervalos relativamente constantes (PELLEGRINI, 2000). A sazonalidade é bastante observada em vários segmentos de mercado, como alimentício e vestuário (ramo de atuação da marca Alfabeto).

Modelo Sazonal Multiplicativo de Winters

No Modelo Multiplicativo, a amplitude de variação sazonal aumenta ou diminui como função do tempo, ou seja, a diferença entre o maior e o menor valor de demanda dentro das estações aumenta ou diminui com o acréscimo no nível médio da serie temporal (KOEHLER apud TEIXEIRA, 2004). Sua representação matemática vem dada por (MAKRIDAKIS apud PELLEGRINI, 2000).

$$L_t = \alpha \frac{z_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (6)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (7)$$

$$S_t = \gamma \frac{z_t}{L_t} + (1 - \gamma)S_{t-s}, \quad (8)$$

$$\hat{z}_{t+k} = (L_t + kT_t)S_{t-s+k} \quad (9)$$

Onde:

- L_t : componente nível;
- S_t : componente sazonalidade;
- T_t : componente tendência;
- α : coeficiente de amortecimento ($0 \leq \alpha \leq 1$);
- β : coeficiente de amortecimento para a estimativa de tendência ($0 \leq \beta \leq 1$);
- γ : coeficiente de amortecimento para a estimativa sazonalidade ($0 \leq \gamma \leq 1$);
- z_t : valor real observado no período t ;
- k : números de períodos futuros a serem previstos;
- \hat{z}_{t+k} : previsão para k períodos a frente;
- s : estação completa da sazonalidade.

A equação (5) difere da equação que trata do nível da série no modelo de Holt, já que o primeiro termo é dividido por um componente sazonal, eliminando assim a flutuação sazonal de z_t . A equação (6) é exatamente igual à equação da tendência no método de Holt. Já a equação (7), faz um ajuste sazonal nas observações z_t (PELLEGRINI, 2000).

Como todos os métodos de suavização exponencial, os modelos de Winters necessitam valores iniciais de componentes (neste caso, nível, tendência e sazonalidade) para dar início aos cálculos. Para a estimativa do componente sazonal, necessita-se no mínimo uma estação completa de observações, ou seja, s períodos (MAKRIADAKIS apud PELLEGRINI, 2000). As estimativas iniciais do nível e da tendência são feitas, então, no período s definido para o componente sazonal.

O estimador inicial para o nível da série é dado pela média da primeira estação:

$$L_s = \frac{1}{s}(z_1 + z_2 + \dots + z_s). \quad (10)$$

Para se inicializar a tendência, é recomendado o uso de duas estações completas, ou seja, 2s períodos:

$$T_s = \frac{1}{s} \left(\frac{z_{s+1} - z_1}{s} + \frac{z_{s+2} - z_2}{s} + \dots + \frac{z_{s+s} - z_s}{s} \right) \quad (11)$$

Para o componente sazonal, utilizam-se s estimativas iniciais:

$$S_1 = \frac{z_1}{L_s}, S_2 = \frac{z_2}{L_s}, \dots, S_s = \frac{z_s}{L_s}. \quad (12)$$

Modelo Sazonal Aditivo de Winters

O modelo aditivo de Winters ajusta-se mais apropriadamente a series com tendência e sazonalidade aditiva, isto é, aquelas em que o efeito sazonal não é função do nível corrente da série temporal e pode ser simplesmente adicionado ou subtraído de uma previsão que dependa apenas de nível e tendência (KOEHLER apud TEIXEIRA, 2004). Suas equações matemáticas são (MAKRIADAKIS apud PELLEGRINI, 2000):

$$L_t = \alpha(z_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (13)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (14)$$

$$S_t = \gamma(z_t - L_t) + (1 - \gamma)S_{t-s} \quad (15)$$

$$\hat{z}_{t+k} = L_t + kT_1 + S_{t-s+k} \quad (16)$$

A equação da tendência permanece a mesma utilizada para o modelo multiplicativo. Nas demais equações, a única diferença é que o componente sazonal está efetuando operações de soma e subtração, ao invés de multiplicar e dividir.

Os valores iniciais de L_s e T_s são calculados de forma idêntica ao modelo multiplicativo. Já os componentes sazonais são calculados da seguinte forma:

$$S_1 = z_1 - L_s \quad S_2 = z_2 - L_s, \dots, S_s = z_s - L_s \quad (17)$$

Analogamente aos outros modelos de amortecimento exponencial, a precisão dos modelos de Winters está relacionada com a definição dos valores dos coeficientes de amortecimento α , β e γ . Assunto que será abordado na próxima sessão.

2.2.2.1.6 Seleção dos Coeficientes de Amortecimento

Como dito anteriormente, o nível de precisão obtido com a aplicação dos métodos de amortecimento está intimamente ligada aos valores escolhidos para seus coeficientes.

Wanke, 2006 sugere uma abordagem que pode ser utilizada em qualquer método de amortecimento. Consiste em utilizar o método em questão para calcular previsão para períodos passados, e assim determinar o erro médio resultante. Em

seguida, definem-se os valores dos coeficientes como sendo aqueles que minimizam o erro médio resultante.

O autor também diz que esta abordagem apresenta inúmeras variações, uma vez que é possível utilizar técnicas exaustivas, algoritmos realmente otimizadores, ou heurísticas, que apesar de não garantirem resultados ótimos, geralmente exigem menos esforço computacional.

Pode-se concluir que a complexidade destes procedimentos cresce à medida que o número de coeficientes a serem determinados aumenta.

Ilustrando esta questão, para o conjunto de possíveis valores de α , β e γ relacionados abaixo e considerando um procedimento exaustivo, que visa testar todas as combinações possíveis entre estes conjuntos, é fácil perceber que para descobrir o valor do coeficiente α para o AES, deve-se testar 101 diferentes possibilidades, para achar a melhor combinação de α e β para o método de Holt testa-se $101 \times 101 = 10.201$ combinações, e para a combinação de α , β e γ para os modelos de Winter $101 \times 101 \times 101 = 1.030.301$ combinações.

$$\alpha \in \{0; 0,01; 0,02; 0,03; 0,04; \dots; 0,98; 0,99; 1\}$$

$$\beta \in \{0; 0,01; 0,02; 0,03; 0,04; \dots; 0,98; 0,99; 1\}$$

$$\gamma \in \{0; 0,01; 0,02; 0,03; 0,04; \dots; 0,98; 0,99; 1\}$$

Algoritmos também podem ser utilizados na definição dos valores dos coeficientes de amortecimento. Apesar de, geralmente, serem mais eficientes que os métodos exaustivos, apresentam maior complexidade de implementação.

Ainda de acordo com Wanke, 2006, diversas heurísticas foram desenvolvidas com o objetivo de se determinarem bons valores para os coeficientes de amortecimento. Uma das mais conhecidas é a SAFT (do inglês *Self-Adaptive Forecasting Technique*). Esta técnica pode ser aplicada em qualquer método de amortecimento; no entanto, ela será descrita considerando a determinação dos três coeficientes dos modelos de Winter, por ser o mais complexo (da maneira descrita em WANKE, 2006). A SAFT é composta por duas etapas; na primeira, avaliam-se todas as combinações possíveis, considerando os seguintes valores possíveis para cada coeficiente:

$$\alpha \in \{0,05; 0,10; 0,15; 0,20; \dots; 0,90; 0,95\}$$

$$\beta \in \{0,05; 0,10; 0,15; 0,20; \dots; 0,90; 0,95\}$$

$$\gamma \in \{0,05; 0,10; 0,15; 0,20; \dots; 0,90; 0,95\}$$

Após avaliar as 6.859 combinações, seleciona-se aquela que resultou em um menor erro médio.

Definidos os valores de α , β e γ , inicia-se a segunda etapa do processo, que consiste na busca local por um valor ainda menor do erro, testando outros valores acima e abaixo de cada coeficiente em incrementos de 0,01.

Por exemplo, caso, após a primeira etapa, a combinação que resultou no menor erro tenha sido $\alpha = 0,10$, $\beta = 0,35$ e $\gamma = 0,70$, então são testadas todas as combinações provenientes de:

$$\alpha \in \{0,06; 0,07; 0,08; 0,09; 0,11; 0,12; 0,13; 0,14\}$$

$$\beta \in \{0,31; 0,32; 0,33; 0,34; 0,36; 0,37; 0,38; 0,39\}$$

$$\gamma \in \{0,66; 0,67; 0,68; 0,69; 0,71; 0,72; 0,73; 0,74\}$$

Os resultados provenientes desses 512 combinações adicionais são comparados com os da combinação anterior, para assim se selecionar aquela que apresenta o menor erro médio.

Ao comparar a heurística SAFT com o método exaustivo descrito acima, pode-se notar uma redução considerável no número de combinações a serem testadas.

2.2.3 SELEÇÃO DO MELHOR MÉTODO DE PREVISÃO

Dependendo do comportamento da série temporal que se deseja analisar, vários modelos podem ser empregados na previsão de seus valores futuros. A escolha do modelo mais apropriado é feita, geralmente, a partir do somatório dos erros gerados por cada modelo ($e_t = z_t - \hat{z}_t$) (PELLEGRINI, 2000).

Dentre os tipos de erros mais utilizados para avaliar a precisão de um método quantitativo de previsão de vendas é possível listar: Média absoluta dos erros (*Mean Absolute Deviation* - MAD), Média percentual dos erros (*Mean Percentual Error* - MPE), Média percentual absoluta dos erros (*Mean Absolute Percentual Error* - MAPE) e Média dos quadrados dos erros (*Mean Square Error* - MSE).

2.2.3.1 MAD

Este cálculo é empregado para avaliar o nível de erro na mesma unidade que a série de vendas.

$$MAD = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (18)$$

2.2.3.2 MPE

Este cálculo é utilizado para avaliar se o método possui algum viés, ou seja, se os valores previstos estão sistematicamente acima ou abaixo das vendas reais.

Para previsões não enviesadas, espera-se um valor do MPE próximo de ZERO.

$$MPE = \frac{1}{n} \sum_{t=1}^n \frac{e_t}{z_t} \quad (19)$$

2.2.3.3 MAPE

Com o objetivo de avaliar a magnitude do erro com relação à série histórica calculam-se o MAPE

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{z_t} \right| \times 100 \quad (20)$$

2.2.3.4 MSE

Com este cálculo, os grandes erros se destacam, quando comparados aos erros de menor magnitude.

$$MSE = \frac{1}{n} \sum_{t=1}^n (e_t)^2 \quad (21)$$

2.2.3.5 Máximo R^2

Não consiste em uma medida de erro e sim em uma medida de ajuste de uma modelo a uma série temporal.

Um valor de R^2 próximo de ZERO indica um modelo de ajuste pobre, enquanto um valor próximo da unidade indica um bom ajuste (TEIXEIRA, 2004).

$$R^2 = 1 - \frac{\sum_{t=1}^n (z_t - \hat{z}_t)^2}{\sum_{t=1}^n (z_t - \bar{z}_t)^2} \quad (22)$$

III. CONJUNTURA E DESCRIÇÃO DO TRABALHO

3.1 O VAREJO BRASILEIRO

De acordo com a pesquisa “O Mercado da Moda no Brasil”, divulgada em 2005 pela ABIT, o varejo brasileiro, diferentemente do que é observado nos outros pólos mundiais de confecção, é muito fragmentado – haja visto os mais de 100 mil pontos de venda espalhados por todo o País (onde apenas 4% são organizados em redes que compram maiores volumes de peças).

Outra característica marcante do setor que chama a atenção é que a grande maioria dessas empresas é predominantemente de origem familiar e constituída por capital nacional – fator registrado em todo território nacional.

Dentre os principais pólos existentes, sobressai a Região Sudeste: responde por mais da metade da produção nacional. No entanto, vale ressaltar também o Pólo Nordeste pelos bons resultados que vem apresentando nos últimos 5 anos (em 2006 já era responsável por 11% da produção brasileira). Especialistas creditam esse resultado, em grande parte, ao baixo custo da mão-de-obra local.

Analisando individualmente os Estados, o destaque, informa a pesquisa, fica por conta de Santa Catarina e São Paulo – dois dos principais e mais antigos pólos de produção do País. Enquanto o primeiro é considerado o maior exportador em malhas do Brasil, o segundo não só detém 11 mil empresas (dentre as quais estão as principais grifes nacionais), como também é sede do principal evento lançador de moda da América Latina: o São Paulo Fashion Week (que ocorre duas vezes por ano). No entanto, em termos de volume de produção, o destaque fica com os estados de Minas Gerais, Rio de Janeiro e Ceará.

Dentre todas as informações presentes na pesquisa da ABIT, nada chama mais a atenção do que o fato de que, atualmente, o setor de vestuário e confecção brasileiro, até mesmo pela característica de varejo pulverizado, passa por um forte processo de competitividade no mercado interno.

Seja por conta dos baixos salários pagos em outros estados, seja por conta dos incentivos fiscais concedidos, o fato é que o Sudeste, especialmente entre 1990 e 2001, perdeu considerável participação na produção de confecções para outras regiões – estabelecendo uma nova era de forte competitividade no mercado nacional.

Outro fator relevante que contribui muito para esse clima de competitividade está na utilização de novas matérias-primas. A partir da abertura comercial, foi possível a diversas empresas de diversos tamanhos ter acesso aos modernos tecidos existentes no mercado internacional, a preços competitivos.

Além disso, a inserção de ferramentas de design, administração das marcas e da distribuição agregaram valor ao produto final – seja ele de uma pequena, média ou grande confecção.

Por fim, há a questão da informalidade para contribuir ainda mais com o acirramento da competição no setor de vestuário brasileiro: devido à elevada carga tributária do País, aos juros altos e a falta de acesso ao financiamento, a cadeia produtiva da confecção nacional vem se informalizando muito nos últimos anos.

3.2 A EMPRESA

Este trabalho foi realizado na empresa Alfabeto, que consiste em uma cadeia de lojas de vestuário infantil especializada na comercialização de roupas para crianças de 0 a 14 anos.

A marca foi fundada em 1993, abrindo a primeira unidade no shopping Nova América na cidade do Rio de Janeiro. Apesar de possuir 4 lojas atacadistas o principal ramo de atuação da empresa é o de varejo. Atualmente são 21 lojas da marca Alfabeto espalhadas pelas cidades de São Paulo, Rio de Janeiro, Belo Horizonte, São João Nepomuceno, Contagem e Juiz de Fora.

A sede administrativa da companhia está instalada na cidade de São João Nepomuceno, a 78 quilômetros a nordeste de Juiz de Fora, onde também encontra-se a Confecções Children, fábrica responsável pela fabricação de todos os produtos da marca Alfabeto. Nesta sede é realizado todas as atividades relacionadas com a administração da rede, incluindo as tarefas de previsão de vendas, foco da atenção deste trabalho.

São produzidas na Confecções Children, em média, 100 mil unidades mensais, que são posteriormente distribuídas às lojas Alfabeto para serem comercializadas e vendidas. Quantidade que a torna umas das maiores indústrias do ramo no estado de Minas Gerais.

Seguindo o comportamento do setor, a demanda da empresa apresenta um componente de sazonalidade considerável, estando o maior volume de vendas concentrado nos últimos meses do ano, apresentando seu pico no mês de dezembro, devido principalmente às festas de fim de ano.

3.3 O ESTUDO

Após a revisão bibliográfica, para o melhor entendimento das técnicas envolvidas, deu-se início à etapa de coleta de dados. Essa coleta de informação sobre a demanda dos produtos pode ser feita em várias fontes, porém as mesmas serão retiradas do banco de dados do *Software* comercial que gerencia todas as lojas, através da emissão de relatórios de vendas agregadas por mês dos últimos três anos (período que os dados encontram-se disponíveis e de fácil acesso). Essas informações serão utilizadas na modelagem matemática do modelo de previsão.

De posse dos dados estatísticos a serem utilizados na previsão deverá ser feita a montagem de um banco de dados utilizando o *Software* Microsoft Excel 2007, tornando as informações mais claras. Como mencionado, os dados serão agregados de forma mensal para uma melhor visualização de um padrão de comportamento da série e para acompanhar o planejamento da empresa, que também é feito mensalmente.

O pacote computacional usado para geração da série temporal e posterior previsão das vendas será o Forecast Pro em sua versão 3.5, devido ao seu fácil acesso, à habilidade do acadêmico e por o mesmo satisfazer todas as necessidades requeridas pelo trabalho.

Com a série temporal gerada de forma gráfica parte-se para uma análise preliminar da mesma, possibilitando identificar possíveis valores espúrios. Segundo Pellegrini (2000) valores espúrios pode ser causados por erros de digitação, falta de produtos, promoções esporádicas e variações no mercado financeiro, entre outras causas. Para o tratamento destes valores, sugerem-se os seguintes procedimentos:

- **Procedimento A.** Quando o valor espúrio encontra-se no final da série temporal e existem valores suficientes para gerar um modelo de previsão, substitui-se o valor espúrio pela previsão relativa ao período correspondente ao dado excluído.
- **Procedimento B.** Quando o valor espúrio encontra-se no início da série temporal, o procedimento descrito anteriormente torna-se impossível. Uma sugestão para tal situação é fazer a substituição do valor espúrio por um valor médio das observações imediatamente adjacentes a ele, e gerar um modelo de previsão. Uma vez feita a previsão, o valor espúrio é substituído pela previsão relativa ao período correspondente.

Uma vez retirados os valores espúrios, analisam-se fatores como padrões, tendências e sazonalidades que podem estar presentes na série temporal em estudo. Devido ao comportamento do mercado de varejo, é possível prever que pelo menos a componente sazonalidade estará presente. A análise gráfica preliminar fornece assim subsídios auxiliares na escolha dos modelos quantitativos a serem utilizados.

Serão então aplicados os modelos quantitativos de previsão que forem julgados adequados. Na utilização dos métodos de amortecimento exponencial, a definição dos coeficientes de amortecimento será feita utilizando o algoritmo já embutido no *software* Forecast Pro.

Por fim, uma comparação de resultado foi feita mediante confrontamento dos valores obtidos nas medidas de precisão listadas na seção 2.2.3, chegando a uma conclusão sobre qual método é o mais apropriado para prever a demanda pelos os produtos da Alphabeto.

IV. DESENVOLVIMENTO DO TRABALHO

4.1 COLETA DE DADOS

Os dados coletados e que serviram de base para a realização deste estudo foi o número de peças vendidas por todas as unidades que compõem a rede de lojas Alfabeto. Estas informações foram retiradas do banco de dados do *software* comercial que fornece o suporte para o gerenciamento das lojas.

É importante salientar que os valores obtidos não denotam a demanda da empresa, uma vez que os mesmos são apenas as vendas efetivadas. Porém, apresentam uma aproximação razoável da demanda, considerando que os erros de previsão cometidos pelos analistas eram enviesados para cima, fazendo com que o estoque raramente ficasse nulo.

Como todo o planejamento de vendas é feita mensalmente, os valores retirados do *software* foram agrupados nesta mesma unidade de tempo. Cabe ainda destacar, que por consistirem em dados confidenciais os mesmos não serão apresentados neste estudo.

Foram extraídos dados das vendas mensais dos períodos compreendidos de janeiro de 2005 à Dezembro de 2007, totalizando 3 anos ou 36 observações.

4.2 ANÁLISE DA SÉRIE TEMPORAL

De posse do histórico de vendas das lojas Alfabeto e com o auxílio do *software* Microsoft Excel em sua versão 2007, foi possível plotar o gráfico referente à série histórica do número de roupas vendidas.

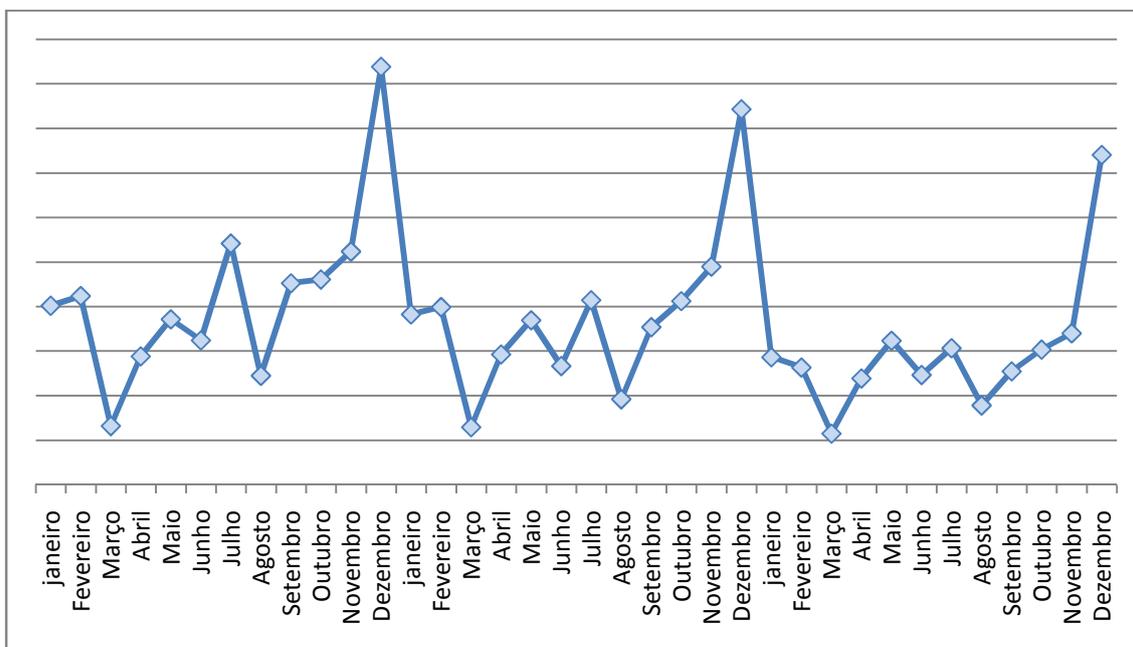


Figura 5 - Serie histórica do número de roupas vendidas

Primeiramente é aconselhável realizar uma análise quanto a existência de valores espúrios. Porém, como os valores foram extraídos do software que registra todas as saídas de mercadorias, não existindo itens não declarados, é possível afirmar que os dados não apresentam valores espúrios. Além disso, foi checado junto ao responsável pelo gerenciamento das vendas se a série histórica, representada na figura 6, condiz com as vendas realmente efetivadas e se, durante o período analisado, algum acontecimento atípico ocorreu.

Partiu-se então para uma análise a fim de identificar as componentes presentes na série histórica apresentada. Como era de se esperar as vendas da rede Alfabeto possui uma forte componente sazonal, fator bastante característico do varejo de roupas. Como mencionado anteriormente, devido às festas de fim de ano, as vendas no mês de dezembro apresentam uma alta considerável, representando aproximadamente 20% do volume de peças comercializadas ao longo de todo o ano.

Também é de fácil verificação a presença da componente de tendência na série. Esta é representada por um declínio linear na quantidade de roupas vendidas a

cada ano. Este fato já era esperado pelos gerentes da empresa, fruto de uma política de aumento do índice de *mark-up*, que ocasiona um aumento nos preços das mercadorias.

Analisando a estacionaridade da série temporal, devido à evidente presença de uma tendência negativa, é correto afirmar que a mesma é não-estacionária.

Portanto é possível concluir que a série histórica do número de roupas vendidas pela Alphabet, apresenta sazonalidade de período igual a 12 meses e tendência linear negativa. Sendo assim, de acordo com a bibliografia apresentada no capítulo 2, julga-se mais adequado a utilização dos métodos: Sazonal Aditivo de Winters, Sazonal Multiplicativo de Winters e Box-Jenkins, para realização das previsões de vendas.

4.3 APLICAÇÃO DOS MÉTODOS SELECIONADOS

Esta seção é dedicada a analisar a eficácia de cada método selecionado acima, a fim de determinar qual possui melhor desempenho na realização das previsões.

4.3.1 SAZONAL ADITIVO DE WINTERS

Os dados do histórico de vendas foram carregados no software Forecast Pro. Os parâmetros α , β e γ , foram definidos automaticamente através do algoritmo de otimização embutido no pacote computacional. Obtendo os seguintes resultados:

$$\alpha = 0,03789$$

$$\beta = 0,32835$$

$$\gamma = 0,99999$$

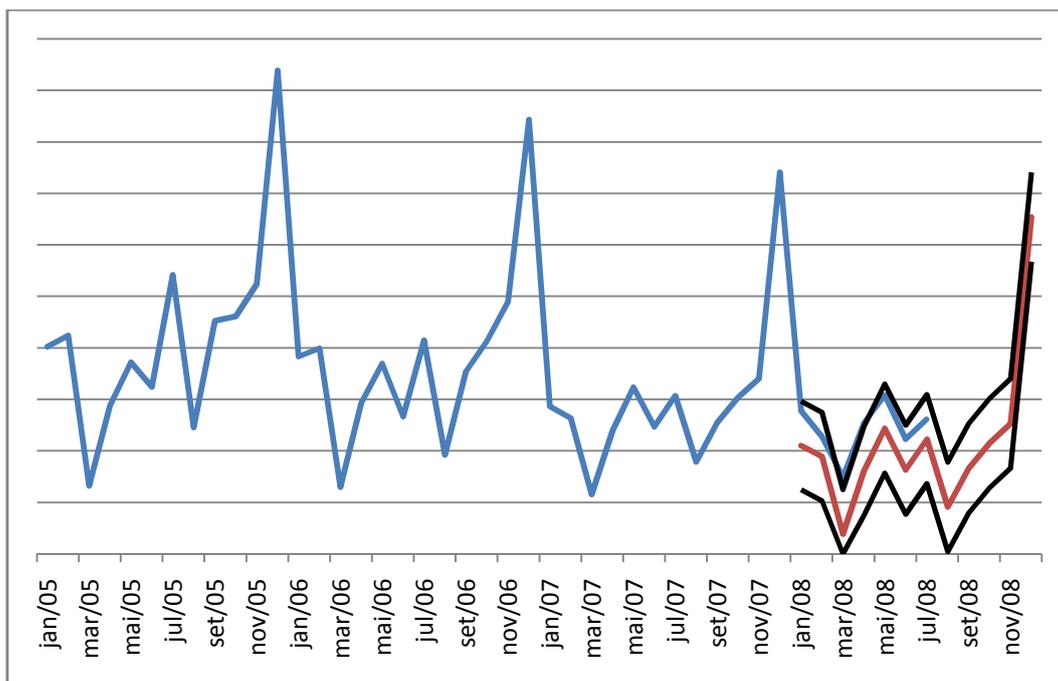


Figura 6 - Previsão com método sazonal aditivo de Winters

A série em azul corresponde às vendas ocorridas no período. A previsão obtida com este método é representada na figura 7 pela série em vermelho, enquanto as séries em preto apresentam os intervalos de confiança superior e inferior (nível de confiança = 97,5%).

Primeiramente foi realizada uma análise chamada *within-sample* (dentro da amostra), onde as estatísticas são obtidas em função dos valores utilizados para realizar a previsão, alcançando os seguintes resultados:

Estatística	Valor
MAD	5749
MPE	-0,0105
MAPE	0,1004
R²	0,9551

Tabela 1 - Estatísticas within-sample método sazonal aditivo de Winters

A partir da análise do MAD, que permite avaliar o nível de erro da previsão na mesma unidade que a série de vendas, é possível afirmar que as previsões geradas por este método apresentam um erro médio de 5749 unidades mensais, resultado considerado um pouco alto para aplicabilidade na empresa. Outra estatística que também não foi considerada satisfatória é o MAPE, que objetiva avaliar a magnitude

do erro com relação à série histórica, esta, mostrou um erro percentual médio de 10,04 % ao mês.

Por outro lado, avaliando a estatística R^2 é possível dizer que, com a utilização deste procedimento é possível explicar 95,51 % do processo, resultado bastante expressivo visto a simplicidade do método. É possível ainda afirmar com base no MPE atingido, que as previsões geradas não são enviesadas, devido à proximidade do valor obtido à ZERO.

Foi feita então uma análise *out-of-sample* (fora da amostra), ou seja, de posse das vendas reais realizadas de Janeiro de 2008 a Julho de 2008 foi possível confrontá-las com as previsões obtidas para este período. Obtendo assim o comportamento efetivo das estimativas de erros.

Mês	MAD	Média Acumulada	MAPE	Média Acumulada
Janeiro/2008	10762,857	10762,857	0,250	0,250
Fevereiro/2008	10928,334	10839,231	0,265	0,257
Março/2008	12400,326	11272,868	0,302	0,269
Abril/2008	11038,218	11230,205	0,213	0,259
Mai/2008	9671,531	11043,164	0,184	0,250
Junho/2008	9030,586	10894,084	0,193	0,246
Julho/2008	7677,344	10779,200	0,147	0,242

Tabela 2 - Estatísticas *out-of-sample* método sazonal aditivo de Winters

Conclui-se então que, apesar de ser esperado um desempenho do MAD em torno de 5749 unidades e do MAPE de 10,04%, o comportamento efetivo destas estatísticas são 10779,2 unidades e 24,2%, respectivamente. Além disso, ao analisar visualmente a figura 7, vê-se que os valores previstos tendem a ficar sempre abaixo das vendas reais, o que caracteriza um viés no modelo. Tem-se então um desempenho bem abaixo do acreditado.

4.3.2 SAZONAL MULTIPLICATIVO DE WINTERS

Utilizando o método sazonal multiplicativo de Winters, da mesma maneira descrita para o método anterior, obteve-se o seguinte resultado para os parâmetros e conseqüente previsão.

$$\alpha = 0,01644$$

$$\beta = 0,45361$$

$$\gamma = 0,98388$$

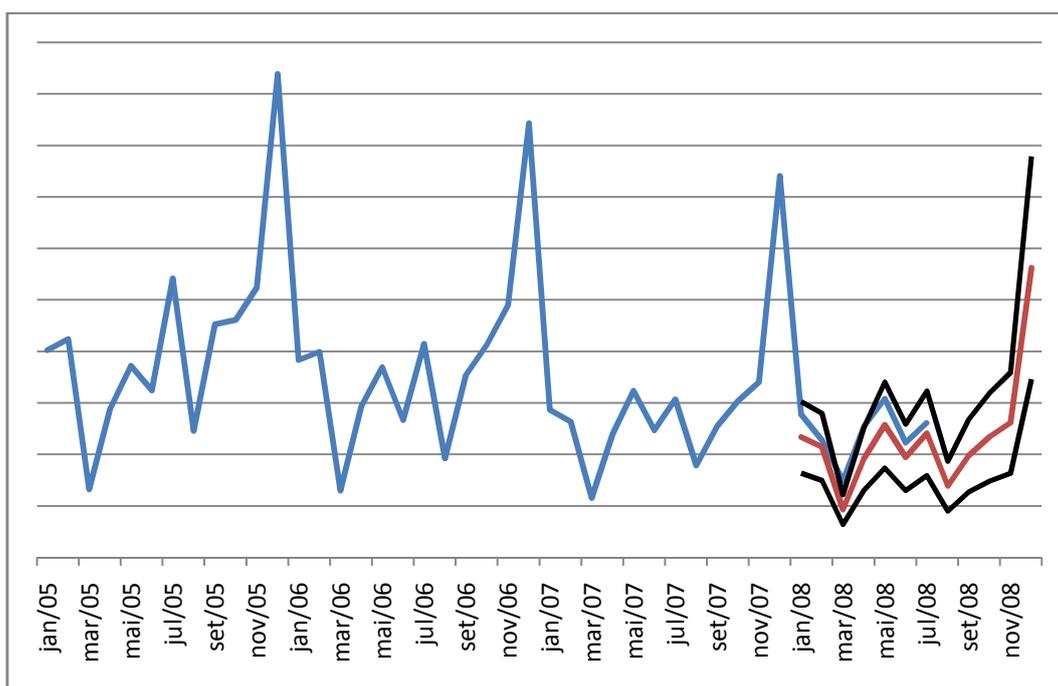


Figura 7 - Previsão com método sazonal multiplicativo de Winters

As estatísticas *within-sample* retornadas pelo Forecast Pro estão apresentadas na tabela 3.

Estatística	Valor
MAD	4728
MPE	-0,02014
MAPE	0,07456
R²	0,9674

Tabela 3 - Estatísticas *within-sample* método sazonal multiplicativo de Winters

Estudando a tabela acima se observa que, além de se ajustar melhor à realidade por explicar 96,74 % da variabilidade da série histórica e não apresentar viés, o método multiplicativo de Winters apresenta erro médio cerca de 1000 unidades menor que o método anterior, possuindo um erro percentual de apenas 7,456 %.

Examinando os dados advindos da análise *out-of-sample*, percebe-se que o modelo se comportou pior que o esperado, apresentando erros maiores e uma tendência a prever resultados abaixo das vendas efetivas. Todavia, o método atual continua sendo mais preciso que o anteriormente testado

Mês	MAD	Média Acumulada	MAPE	Média Acumulada
Janeiro/2008	6639,327	6639,327	0,149	0,149
Fevereiro/2008	6523,458	6585,849	0,152	0,150
Março/2008	7670,290	6887,083	0,178	0,158
Abril/2008	7277,381	6958,046	0,138	0,154
Mai/2008	6214,108	6868,773	0,115	0,149
Junho/2008	4513,348	6694,297	0,096	0,145
Julho/2008	4047,074	6599,754	0,078	0,143

Tabela 4 - Estatísticas *out-of-sample* método sazonal multiplicativo de Winters

4.3.3 BOX-JENKINS

Após carregar os dados no Forecast Pro, o mesmo definiu que o melhor modelo Box-Jenkins para realizar a previsão das vendas da Alphabeto foi o SARIMA $(0,1,1) * (0,1,0)_{12}$ com transformação logarítmica. Essa diferenciação, que explica o fato de $d = 1$, era esperada, uma vez que a análise da figura 6 revela a presença de tendência decrescente, indicando que a série é não-estacionária. Segue abaixo os resultados obtidos.

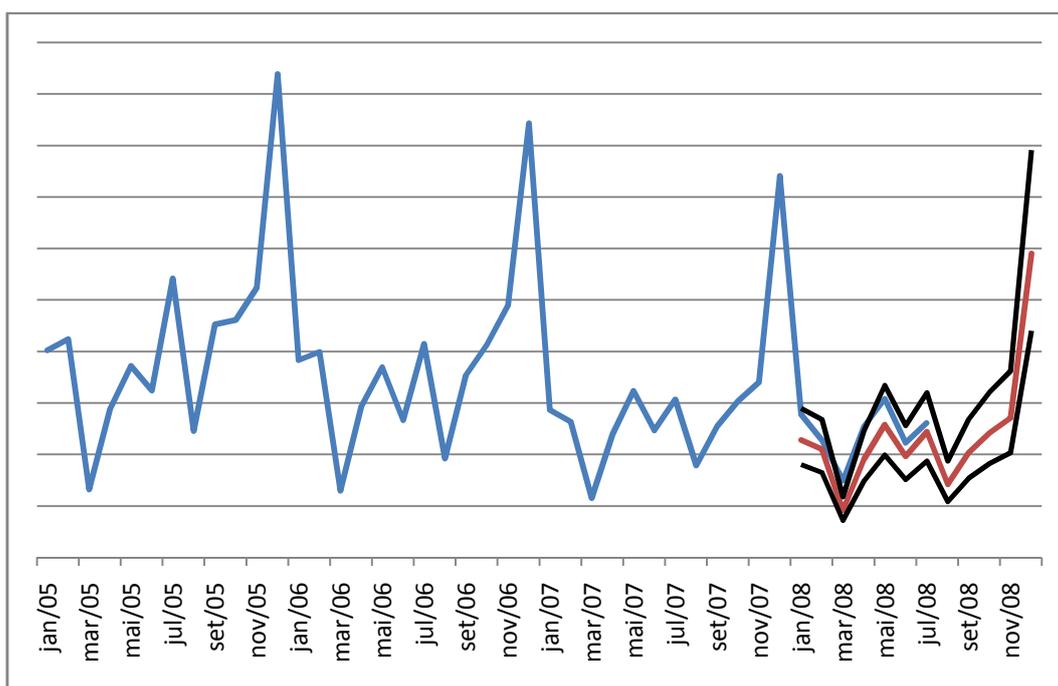


Figura 8 - Previsão com método Box-Jenkins

As estatísticas within-sample retornadas pelo Forecast Pro estão apresentadas na tabela 5.

Estatística	Valor
MAD	4446
MPE	-0,03756
MAPE	0,06996
R ²	0,9568

Tabela 5 - Estatísticas *within-sample* método Box-Jenkins

Através da análise da tabela acima é possível observar que, apesar do SARIMA apresentar um grau de explicação da série inferior ao obtido com o método

multiplicativo de Winters, os erros de previsão apresentam uma razoável melhora, com o SARIMA $(0,1,1) * (0,1,0)_{12}$ proporcionando um erro percentual médio de apenas 6,9%.

Da mesma maneira observada nos métodos de Winters, ao realizar a análise *out-of-sample*, o SARIMA comporta-se de maneira inferior ao estimado nas estatísticas presentes na tabela 5. Porém os resultados continuam sendo mais satisfatório que os obtidos com os modelos previamente estudados.

Mês	MAD	Média Acumulada	MAPE	Média Acumulada
Janeiro/2008	5258,264	5258,264	0,123	0,123
Fevereiro/2008	5937,172	5571,606	0,142	0,132
Março/2008	7452,888	6094,184	0,173	0,143
Abril/2008	7047,246	6267,468	0,133	0,142
Mai/2008	4774,941	6088,365	0,085	0,135
Junho/2008	3191,863	5873,809	0,070	0,130
Julho/2008	3341,441	5783,368	0,064	0,128

Tabela 6 - Estatísticas *out-of-sample* método Box-Jenkins

4.3.4 COMPARAÇÃO E ANÁLISE DOS MODELOS

A tabela 7 apresenta as estatísticas proporcionadas pelos três métodos julgados mais adequados para a realização das previsões.

Método	Within-Sample				Out-of-Sample	
	MAD	MPE	MAPE	R ²	MAD	MAPE
Winters (aditivo)	5749	-0,010	0,100	0,955	10779	0,242
Winters (multiplicativo)	4728	-0,020	0,075	0,967	6600	0,143
Box-Jenkins	4446	-0,038	0,069	0,957	5783	0,128

Tabela 7 - Comparação dos resultados dos modelos

Analisando o MPE nota-se um desempenho bastante semelhante para todos os métodos. Podendo considerar que nenhum modelo apresenta um viés significativo, devido aos valores obtidos estarem bem próximo a ZERO, levando-se em conta apenas a análise *within-sample*.

De acordo com Pellegrini (2000) é considerado aceitável valores para $R^2 > 0,6$. Sendo assim todos os modelos conseguem explicar de maneira satisfatória as vendas da Alphabeto. Porém os resultados conseguidos foram todos maiores que 0,95, valor considerado excepcional. Isto pode ter ocorrido devido à facilidade de se modelar matematicamente a série histórica em estudo, devido a seu padrão relativamente determinístico.

A definição de qual modelo é o mais adequado para as previsões se dará a partir das análises dos erros MAD e MAPE, encontrados tanto *within-sample* ou *out-of-sample*. Evidencia-se então que o método Box-Jenkins apresenta tais critérios de desempenho superiores, com valores até 13% menores que o método multiplicativo de Winters (segundo melhor desempenho).

Sendo assim, apesar de a bibliografia indicar que para se obter um ganho de acuracidade significativa em relação a métodos mais simples, como o amortecimento exponencial, é necessário um número de observações superiores a 50 (o presente estudo foi feito com 36 observações), o método de Box-Jenkins é o mais adequado para realizar as previsões de vendas da rede de lojas Alphabeto.

É importante portanto salientar que até mesmo as previsões advindas do Box-Jenkins apresentam uma tendência a gerar valores abaixo das vendas reais, de acordo com comparação feitas *out-of-sample*. Isto posto, se este valores tivessem

efetivamente sido usados como projeção de vendas, a empresa apresentaria um resultado inferior ao seu potencial, comprometendo seu lucro operacional.

Constata-se assim que todos os métodos, baseados no histórico de vendas, projetaram um valor de tendência para o ano de 2008 que não se efetivou. Uma possível causa para o ocorrido refere-se a uma maior aceitação dos produtos da temporada de 2008 por parte dos consumidores. Presumi-se que tal fato ocorreu devido a uma mudança de “comportamento” das estilistas responsáveis pela criação dos produtos, que, para as coleções de 2008, modificaram os padrões das roupas, deixando-as mais “ousadas”. Esta quebra de paradigmas parece ter surtido um efeito relativamente positivo: reduzindo a tendência de queda das vendas, ao mesmo tempo que a política de preço foi mantida.

A constatação acima reforça a idéia apresentada na bibliografia, da necessidade de se realizar uma análise qualitativa após a obtenção dos valores quantitativamente. A fim de identificar possíveis comportamentos do mercado, ou quaisquer outros fatores, que mudariam o padrão presente na série histórica que o modelo de previsão foi baseado.

V. CONCLUSÃO

O presente trabalho teve como objetivo principal determinar o melhor modelo quantitativo para a previsão das vendas, para os próximos 12 meses, da rede Alfabeto. Para atingir tal meta, foi necessário um levantamento bibliográfico a fim de estudar quais métodos, dentro de inúmeros existentes, se adequaria melhor à série história apresentada, gerando resultados mais precisos e satisfatórios.

Foi descrito assim alguns métodos qualitativos, e mais profundamente, os quantitativos assim como foi relacionado os critérios que permitiram a definição do modelo mais preciso de previsão.

Após a implementação e análise das três técnicas quantitativas julgadas necessárias (Sazonal Multiplicativo de Winters, Sazonal Aditivo de Winters e Box-Jenkins), considera-se que o objetivo proposto foi atingido. Chegando à conclusão que o modelo SARIMA $(0,1,1) * (0,1,0)_{12}$ além de proporcionar resultados estatisticamente aceitáveis e satisfatórios ofereceu desempenho acima dos modelos concorrentes.

Conclui-se ainda que, para uma implementação segura do modelo como padrão para projeção de vendas da empresa, é necessário, após obtenção dos valores quantitativamente, inserir avaliações qualitativas, feitas pelos especialistas da organização. Garantindo um resultado confiável e com menores índices de erros.

BIBLIOGRAFIA

BALLOU, R., 2006, *Gerenciamento da cadeia de suprimentos/logística empresarial*. 5 ed., Porto Alegre: Bookman.

DAVIS, M.; AQUILANO, N.; CHASE, R., 2001, *Fundamentos da Administração da Produção*. Porto Alegre: Bookman.

GAITHER, N., FRAZIER, G., 2006, *Administração da Produção e Operações*. 8 ed. São Paulo: Thomson Pioneira.

LEMOS, F. O., 2006, *Metodologia para seleção de métodos de previsão de demanda*. Tese de M.Sc., UFRGS, Porto Alegre, RS, Brasil.

MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R., 1998, *Forecasting: Methods and Applications*. 3. ed., New York: John Wiley & Sons.

MENTZER, J. T.; COX, Jr. J. E. *Familiarity, Application, and Performance of Sales Forecasting Techniques*. Journal of Forecasting. v. 3, n.1, p. 27-36, 1984.

MENTZER, J. T.; GOMES, R. *Evaluating a Decision Support Forecasting System*. Industrial Marketing Management. v. 18, n. 4, p. 313 -323, 1989.

MORETTIN, P. A., TOLOI, C. M. C., 2006, *Análise de séries temporais*. São Paulo: Edgard Blücher.

PASSARI, A. F. L., 2003, *Exploração de dados automatizados para a previsão de vendas no varejo utilizando redes neurais*. Tese de M.Sc., USP, São Paulo, SP, Brasil.

PELLEGRINI, F. R., 2000, *Metodologia para implementação de sistemas de previsão de demanda*. Tese de M.Sc., UFRGS, Porto Alegre, RS, Brasil.

RINALDI, J. G. S.; FARAGO, R. *Previsão de vendas de cerveja para uma indústria em Ribeirão Preto*. Revista HISPECI & LEMA, v. 8, p. 18-20, 2005.

TEIXEIRA, J. A. J., 2004, *Metodologia para implementação de um sistema de gestão de estoques baseado em previsão de demanda*. Tese de M.Sc., UFRGS, Porto Alegre, RS, Brasil.

WANKE, P.; JULIANELLI, L., 2006, *Previsão de Vendas*. 1 ed., São Paulo: Atlas.