

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
MESTRADO PROFISSIONALIZANTE EM ENGENHARIA**

**MÉTODOS PARA PREVISÃO DE DEMANDA DE VEÍCULOS NOVOS - ESTUDO
DE CASO EM UMA CONCESSIONÁRIA DE AUTOMÓVEIS**

Marco Aurélio Kurrle

Porto Alegre

2004

Marco Aurélio Kurrle

**MÉTODOS PARA PREVISÃO DE DEMANDA DE VEÍCULOS NOVOS - ESTUDO
DE CASO EM UMA CONCESSIONÁRIA DE AUTOMÓVEIS**

Trabalho de Conclusão do Curso de Mestrado
Profissionalizante em Engenharia como requisito parcial à
obtenção do título de Mestre em Engenharia – modalidade
Profissionalizante – Ênfase Gerência da Produção

Orientador: Professor Flávio Sanson Fogliatto, *Ph.D.*

Porto Alegre

2004

Este Trabalho de Conclusão foi analisado e julgado adequado para a obtenção do título de mestre em ENGENHARIA e aprovada em sua forma final pelo orientador e pelo coordenador do Mestrado Profissionalizante em Engenharia, Escola de Engenharia, Universidade Federal do Rio Grande do Sul.

Prof. Flávio Sanson Fogliatto, *Ph.D.*
Orientador Escola de Engenharia/UFRGS

Prof^a. Helena Beatriz Bettella Cybis, *Ph.D.*
Coordenadora MP/Escola de Engenharia/UFRGS

BANCA EXAMINADORA

Prof. Dr. Álvaro Gehlen de Leão
PPGEP/UFRGS

Prof. Dr. José Luís Duarte Ribeiro
PPGEP/UFRGS

Prof. Dr. Guilherme Luís Roehe Vaccaro
FAMAT/PUC-RS

AGRADECIMENTOS

Ao meu orientador, Professor Flávio Sanson Fogliatto, pela compreensão, orientação segura e ensinamentos indispensáveis à elaboração desta dissertação.

À direção e aos funcionários da concessionária escolhida para a realização deste trabalho, pela confiança e apoio irrestritos.

Feliz aquele que transfere o que sabe e aprende o que ensina.

Cora Coralina

RESUMO

A identificação antecipada do comportamento da demanda de veículos novos na extremidade da rede de distribuição é imprescindível para implementação de um sistema de produção puxada pela demanda. Previsões confiáveis, obtidas nas concessionárias, conferem aos fabricantes maior sensibilidade diante das peculiaridades locais da demanda e reduzem as incertezas da produção em larga escala. A obtenção de previsões consistentes requer, porém, o emprego de métodos formais. Os profissionais responsáveis pela elaboração de previsões nas concessionárias desconhecem, em grande parte, os métodos de *forecasting* abordados na literatura. Essa dissertação visa o desenvolvimento de um sistema formal para elaboração de previsões de demanda de veículos novos em concessionárias. Em estudo de caso, conduzido em uma concessionária da marca *Volkswagen*, modelos estatísticos de Box-Jenkins e de suavização exponencial são aplicados para gerar previsões quantitativas das vendas de veículos novos. Previsões qualitativas, correspondentes ao julgamento de especialistas no segmento, são formalizadas através do método Delphi. Finalmente, as previsões quantitativas e qualitativas são combinadas matematicamente e comparadas. Tal comparação demonstra que as vantagens inerentes a cada método podem ser absorvidas para proporcionar previsões mais acuradas.

Palavras-chave: previsão de demanda, veículos novos, concessionárias de automóveis.

ABSTRACT

The advanced identification of the new vehicles demand patterns, at the extremity of the distribution network, is essential to establish a demand pull production system. Reliable forecasts from dealers offer the manufacturers a greater perception of the peculiarities of the local demand and reduce the uncertainties regarding the mass production. However, formal forecasting methods are required to obtain accurate forecasts. The professionals which are responsible for forecasting at dealers usually overlook the forecasting methods discussed in the literature. This thesis aims at the development of a formal system to produce new vehicles demand forecasts at dealers. During a case study, conducted at a dealer of the *Volkswagen* brand, statistical Box-Jenkins and exponential smoothing models are applied to generate quantitative forecasts of the new vehicles demand. Qualitative forecasts, related to the judgement of the experts in the area, are formalized through the Delphi method. Finally, quantitative and qualitative forecasts are mathematically combined and compared. Such comparison demonstrates that the inherent advantages of both methods can be absorbed to provide more accurate forecasts.

Key-words: demand forecasting, new vehicles, auto-dealers.

LISTA DE FIGURAS

Figura 1: Padrões de demanda.....	p 29
Figura 2: Aspecto de um processo estocástico, interpretado como uma família de trajetórias ...	p 32
Figura 3: Uma série temporal, definida como uma das trajetórias do processo estocástico	p 32
Figura 4: Aspecto de uma série temporal estacionária em nível e inclinação	p 33
Figura 5: Aspecto de uma série temporal não estacionária em nível	p 34
Figura 6: Aspecto de uma série temporal não estacionária em nível e inclinação	p 34
Figura 7: Fluxograma do método proposto	p 70
Figura 8: Gráfico da evolução temporal da classe Gol GIII.....	p 81
Figura 9: Gráfico de controle dos resíduos gerados para a classe Gol GIII pelo modelo provisório ARIMA (4,0,3).....	p 82
Figura 10: Modelagem da série Gol GIII, antes da substituição dos pontos espúrios, por um modelo ARIMA (4,0,3)	p 84
Figura 11: Autocorrelações dos resíduos gerados pelo modelo ARIMA (4,0,3) para a série Gol GIII	p 85
Figura 12: Autocorrelações estimadas para a série Gol GIII.....	p 86
Figura 13: Autocorrelações parciais estimadas para a série Gol GIII	p 86
Figura 14: Modelagem da série Gol GIII por um modelo ARIMA (4,0,3) x (4,0,3) ₄ após a substituição dos pontos espúrios	p 88
Figura 15: Autocorrelações dos resíduos gerados pelo modelo ARIMA (4,0,3) x (4,0,3) ₄ ajustado à série Gol GIII.....	p 89
Figura 16: Gráfico da série de demanda da classe Gol GII após a substituição de um ponto espúrio	p 90

Figura 17: Modelagem da série Gol GII, após a substituição de um ponto espúrio, por um modelo de suavização exponencial simples	p 91
Figura 18: Autocorrelações dos resíduos gerados pelo modelo de suavização exponencial simples, com $\alpha = 0,1488$, ajustado à série Gol GII	p 92
Figura 19: Representação gráfica do comportamento da demanda do Fox.....	p 93
Figura 20: Modelagem da série Fox por suavização exponencial de Holt.....	p 94
Figura 21: Modelo de suavização exponencial de Holt ajustado à série Fox com 14 períodos .	p 95
Figura 22: Autocorrelações dos resíduos gerados pelo modelo de suavização exponencial de Holt, com $\alpha = 0,1810$ e $\beta = 0,2218$, ajustado à série Fox	p 96

LISTA DE QUADROS

Quadro 1: Comportamento da FAC e FACP teóricas para um processo ARMA (p,q)p 50

LISTA DE TABELAS

Tabela 1: Série temporal e respectivo desenvolvimento para cálculo dos coeficientes de autocorrelação de <i>lag</i> 1 e 2.....	p 35
Tabela 2: Códigos comerciais, classes e modelos de automóveis <i>Volkswagen</i> novos comercializados pela concessionária.....	p 78
Tabela 3: Venda média semanal por classe de veículo	p 79
Tabela 4: Venda média semanal após a agragação das classes de veículos.....	p 80
Tabela 5: Informações referentes ao modelo ARIMA (4,0,3) ajustado à série Gol GIII.....	p 85
Tabela 6: Informações referentes ao modelo ARIMA (4,0,3) x (4,0,3) ₄ ajustado à série Gol GIII.....	p 88
Tabela 7: Previsões, limites de confiança e vendas realizadas para a série Gol GIII.....	p 89
Tabela 8: Informações referentes ao modelo de suavização exponencial simples ajustado à série Gol GII.....	p 91
Tabela 9: Previsões, limites de confiança e vendas realizadas para a série Gol GII.....	p 92
Tabela 10: Informações referentes ao modelo de suavização exponencial de Holt ajustado à série Fox	p 94
Tabela 11: Informações referentes ao modelo de suavização exponencial de Holt ajustado à série Fox com 14 períodos.....	p 95
Tabela 12: Previsões, limites de confiança e vendas realizadas para a série Fox	p 96
Tabela 13: Resultados da modelagem das demais classes de veículos	p 97
Tabela 14: Previsões quantitativas por classe de veículo.....	p 97
Tabela 15: Média, mediana, variância, quartis superiores e inferiores e MSE das previsões de cada especialista na primeira rodada para a classe Gol GIII.....	p 99
Tabela 16: Média, mediana, variância, quartis superiores e inferiores e MSE das previsões de cada especialista na segunda rodada para a classe Gol GIII.....	p 100

Tabela 17: Previsões qualitativas do grupo de especialistas na segunda rodada por classe de veículo	p 102
Tabela 18: Previsões quantitativas e qualitativas combinadas por classe de veículo.....	p 103
Tabela 19: Comparação entre as previsões e as vendas realizadas para a classe Gol GIII	p 103
Tabela 20: MSE por classe e método de previsão	p 104

SUMÁRIO

1 INTRODUÇÃO	p 15
1.1 TEMA DO TRABALHO	p 18
1.2 JUSTIFICATIVAS DO TRABALHO	p 21
1.3 OBJETIVOS DO TRABALHO	p 24
1.3.1 Objetivo Geral.....	p 24
1.3.2 Objetivos Específicos	p 25
1.4 DELIMITAÇÕES DO TRABALHO.....	p 25
1.5 ESTRUTURA DA DISSERTAÇÃO	p 26
2 REVISÃO BIBLIOGRÁFICA	p 27
2.1 ANÁLISE DE SÉRIES TEMPORAIS	p 30
2.1.1 Modelos de Box & Jenkins	p 30
2.1.1.1 Conceitos Iniciais	p 31
2.1.1.2 Modelos Auto-regressivos.....	p 37
2.1.1.3 Modelos de Médias Móveis.....	p 42
2.1.1.4 Modelos Mistos Auto-regressivos e de Médias Móveis.....	p 44
2.1.1.5 Modelos para Séries Temporais Não Estacionárias	p 45
2.1.1.6 Modelos Sazonais	p 47
2.1.1.7 Fases do Método Box-Jenkins.....	p 49
2.1.1.8 Previsões com Modelos ARIMA.....	p 53
2.2 MÉTODOS DE SUAUIZAÇÃO EXPONENCIAL	p 54
2.2.1 Suavização Exponencial Simples	p 54
2.2.2 Suavização Exponencial Dupla: Método Biparamétrico de Holt	p 55
2.2.3 Suavização Exponencial Tripla: Método de Holt-Winters	p 56
2.3 MEDIDAS DE PRECISÃO E DESEMPENHO DOS MODELOS DE PREVISÃO	p 57
2.4 MÉTODOS DE <i>FORECASTING</i> QUALITATIVOS	p 58

2.5 INTEGRAÇÃO DE MÉTODOS QUANTITATIVOS E QUALITATIVOS.....	p 62
2.6 APLICAÇÕES DE <i>FORECASTING</i> NA INDÚSTRIA AUTOMOBILÍSTICA	p 66
3 MÉTODO PROPOSTO	p 70
3.1 PREVISÕES QUANTITATIVAS	p 71
3.1.1 Consulta ao Banco de Dados Históricos de Vendas	p 71
3.1.2 Definição dos Níveis de Agregação dos Dados Históricos de Vendas.....	p 71
3.1.3 Análise Preliminar dos Dados e Composição das Séries Temporais.....	p 72
3.1.4 Ajuste e Validação dos Modelos de Previsão	p 72
3.1.5 Elaboração das Previsões Quantitativas.....	p 73
3.1.6 Atualização e Monitoramento do Sistema de Previsão Quantitativo.....	p 73
3.2 PREVISÕES QUALITATIVAS	p 74
3.2.1 Seleção dos Especialistas.....	p 74
3.2.2 Preparação e Distribuição de Tabelas de Previsão	p 74
3.2.3 Análise Estatística e Apresentação das Informações aos Especialistas	p 75
3.2.4 Definição da Previsão Final do Grupo de Especialistas	p 75
3.2.5 Atualização e Monitoramento do Processo de Previsão Qualitativo	p 75
3.3 COMBINAÇÃO DAS PREVISÕES QUANTITATIVAS E QUALITATIVAS.....	p 76
3.4 INSERÇÃO DA PREVISÃO MAIS ACURADA NO SISTEMA DA MONTADORA .	p 76
4 ESTUDO DE CASO	p 77
4.1 PREVISÕES QUANTITATIVAS	p 78
4.1.1 Consulta ao Banco de Dados Históricos de Vendas	p 78
4.1.2 Definição dos Níveis de Agregação dos Dados Históricos de Vendas.....	p 79
4.1.3 Análise Preliminar dos Dados e Composição das Séries Temporais.....	p 80
4.1.4 Ajuste e Validação dos Modelos de Previsão	p 83
4.1.5 Elaboração das Previsões Quantitativas.....	p 97
4.1.6 Atualização e Monitoramento do Sistema de Previsão Quantitativo.....	p 98
4.2 PREVISÕES QUALITATIVAS	p 98
4.2.1 Seleção dos Especialistas.....	p 98
4.2.2 Preparação e Distribuição de Tabelas de Previsão	p 99
4.2.3 Análise Estatística e Apresentação das Informações aos Especialistas	p 99
4.2.4 Definição da Previsão Final do Conselho de Especialistas	p 101

4.2.5 Atualização e Monitoramento do Processo de Previsão Qualitativo	p 102
4.3 COMBINAÇÃO DAS PREVISÕES QUANTITATIVAS E QUALITATIVAS.....	p 102
4.4 COMPARAÇÃO ENTRE AS PREVISÕES QUALITATIVAS, QUANTITATIVAS E COMBINADAS	p 103
4.5 ANÁLISE DOS RESULTADOS.....	p 104
5 CONCLUSÃO.....	p 107
5.1 COMENTÁRIOS FINAIS	p 107
5.2 SUGESTÕES PARA TRABALHOS FUTUROS	p 108
REFERÊNCIAS	p 110

1 INTRODUÇÃO

A rápida evolução observada nos processos de produção, nas últimas décadas do século XX, foi acompanhada por profundas transformações no perfil dos consumidores de veículos. Até o final da década de 70, predominava no segmento automotivo um forte apelo por aumento de produtividade, como um reflexo do tradicional modelo “fordista” de fabricação em massa, com reduzido mix de produtos.

A conjuntura da época permitia que a indústria prescindisse de previsões formais de demanda, uma vez que a produção se concentrava em alguns poucos modelos, com escassa oferta de opcionais. O ritmo da produção automotiva era ditado apenas pela expectativa de que, em algum nicho de mercado, haveria consumidores sujeitos a aceitar, mesmo relutantemente, os produtos que a indústria de veículos julgasse conveniente lhes ofertar.

Todavia, em virtude do acelerado avanço tecnológico, notavelmente materializado por ferramentas como o “projeto auxiliado por computador” (*CAD*) e a “manufatura auxiliada por computador” (*CAM*) nos anos 80, a produção industrial finalmente excedeu a demanda (LINES, 1996). Nesse novo contexto, de alta produtividade, porém de demanda insuficiente, os clientes se habituaram a exigir satisfação integral de suas necessidades de consumo, demonstrando crescente interesse por tecnologias inéditas, que lhe proporcionassem mais conforto e segurança, por um preço acessível.

Como estratégia para aumentar a demanda, os fabricantes ampliaram seus portfólios de produtos. O número de combinações disponíveis para encomenda, em cada modelo de veículo manufaturado, rapidamente atingiu a casa dos milhares (DURAND *et al.*, 2002). Entretanto, o crescimento da demanda raramente é proporcional ao aumento da variedade nos produtos. Poucas indústrias são suficientemente ágeis para reprogramar sua capacidade produtiva de acordo com as encomendas diárias e adotar um sistema de produção contra pedido (*build-to-order - BTO*), adequado para absorver a multiplicidade de opções oferecidas aos clientes no momento da compra (HOLMSTRÖM, 1998).

A extensa possibilidade de combinações compeliu as montadoras a criarem novas funções organizacionais e a adquirir ou desenvolver robustos sistemas de informação, nem sempre devidamente customizados para lidar, em tempo real, com tal multiplicidade, o

que resultou em um processo moroso de coleta e administração de pedidos. Além da complexidade no processamento de pedidos, esses sistemas fornecem previsões de vendas somente em escala nacional, desconsiderando as peculiaridades locais e regionais da demanda. Tais limitações impedem que os fabricantes de automóveis incorporem, de maneira oportuna e exata, informações de vendas diretas aos consumidores finais em seus planejamentos da produção, ampliando a distância entre a produção e as intenções de compra.

Por conseguinte, muitas empresas automotivas continuam aplicando técnicas de previsão deficientes, apoiadas em sistemas antiquados de gerenciamento de ordens, para prever a demanda que será utilizada no planejamento da produção. Uma vez que a organização fundamenta suas decisões em uma espiral de imprecisões, suas operações se tornam confusas e a conduzem, freqüentemente, à perda de foco no mercado, ou seja, no aspecto comercial do negócio.

Constitui prática usual na indústria automobilística a implementação de ofertas (possíveis combinações para um determinado veículo) que sejam representativas do que as montadoras são ocasionalmente capazes de produzir, em detrimento do objetivo de suprir a demanda real, proporcionando veículos equipados conforme desejam os clientes (DURAND *et al.*, 2002).

Com o intuito de elevar o nível de serviço e permitir algum grau de escolha aos consumidores, as montadoras costumam manter, em toda a rede de distribuição, amplos estoques de veículos prontos, os quais correspondem a aproximadamente 100 dias de vendas no varejo. Estoques de 60 dias são considerados ideais (HOLWEG; MIEMCZYK, 2002). Atualmente, os maiores fabricantes automotivos lançam no mercado, em volumes agregados pelas respectivas marcas, 2.5 veículos para cada unidade efetivamente demandada (DURAND *et al.*, 2002).

A mentalidade de “empurrar” o estoque (*stock-push*) para a rede, contrária ao modelo de produção puxada pela demanda (*demand-pull*), indica que os executivos das montadoras ainda preferem garantir elevadas taxas de produtividade, com nivelamento da produção, a observar o cumprimento exato de quantidades, de configurações de opcionais e de prazos requeridos pelos clientes (O’BRIEN, 2001).

No Reino Unido, por exemplo, apenas 33% de todos os veículos novos vendidos em 1999 foram realmente produzidos contra pedido (*BTO*). Os demais 67% das

vendas foram constituídos por veículos que já se encontravam, em média, há dois meses em estoque. Até mesmo nos Estados Unidos, a demanda é suprida tradicionalmente pelos estoques mantidos pelas revendas. Apesar disso, 74% dos consumidores norte-americanos estariam dispostos a encomendar e a esperar pelo produto preferido, em vez de adquirir um veículo do estoque da concessionária, não equipado a contento (HOLWEG; MIEMCZYK, 2002).

A produção de veículos a partir de encomendas (pedidos firmes), em oposição às previsões de demanda agregadas nacionalmente, parece provida de lógica irrefutável. A idéia, porém, não é nova: o Sistema Toyota de Produção, concebido há cerca de 50 anos, tinha por principal meta produzir veículos unicamente contra pedido e, portanto, evitar os desperdícios inerentes à superprodução. Contudo, muito embora as técnicas de produção enxuta tenham fomentado inegáveis avanços nos processos de manufatura, mediante redução de estoques de componentes e incremento de eficiência, na perspectiva dos clientes, revelam-se insuficientes para dotar a indústria da velocidade e precisão exigidas pelo mercado, especialmente no que tange aos prazos de entrega.

O resultado da manutenção de grandes estoques de produtos com alto valor agregado e complexidade, como automóveis acabados, é a inevitável adoção de uma política permanente de descontos incidentes sobre os veículos estocados, a fim de incrementar as vendas. Evidentemente, essa estratégia provoca imediato acréscimo de custos na rede distribuidora e deterioração do desempenho financeiro dos fabricantes no longo prazo (HOLWEG; MIEMCZYK, 2002).

Como demonstração de reconhecimento dessas falhas, as montadoras, que anteriormente priorizavam a produção, iniciaram, mesmo antes da virada do século, um intrincado processo de aproximação e percepção da realidade do mercado. Muitos fabricantes anunciaram a intenção de implementar estratégias capazes de elevar o percentual de produção contra pedido e de reduzir o suprimento por meio de estoques.

Poucas montadoras, no entanto, estão atualmente preparadas para a produção contra pedido e apenas uma produz exclusivamente a partir das encomendas formuladas pelos consumidores finais (HOLWEG; MIEMCZYK, 2002). Tal constatação corrobora a inépcia estrutural do setor para suprimir a lacuna existente entre as atuais exigências do mercado e a realidade do chão de fábrica (DURAND *et al.*, 2002).

Diante do cenário acima descrito, a substituição do sistema de “empurrar” o estoque (*stock-push*) por um sistema de produção puxada pela demanda (*demand-pull*) somente será levada a termo, se os padrões históricos das vendas diretas ao consumidor final, identificados na extremidade da rede de distribuição, puderem ser coligidos e prontamente incorporados ao processo de planejamento da produção. O aprimoramento do processo de previsão de demanda torna-se, portanto, imprescindível, a fim de que as reais necessidades dos clientes possam ser antecipadas e muitas das operações de manufatura e distribuição concluídas antes que seus pedidos efetivos sejam recebidos (LINES, 1996).

Com efeito, para assegurar que as atividades produtivas possam transcorrer de maneira uniforme e, ao mesmo tempo, atender às expectativas dos clientes, a indústria necessita estimar a demanda eficientemente. O saldo positivo de uma previsão eficiente corresponde precisamente à habilidade de se antecipar a demanda com o menor grau de erro possível. Sem tal antecipação, a organização é compelida a operar de forma reativa (TANWARI; BETTS, 1999).

Previsões de demanda acuradas, ao indicarem as tendências de declínio ou ascensão dos produtos, fornecem a base para o cumprimento adequado de características e prazos de pedidos e permitem a programação de promoções ou de adição de recursos (mão-de-obra, estoques, etc.) para atender aos vales e picos de demanda, respectivamente (LOUDIN, 2000). Consequentemente, a força motriz das operações da indústria é dada pela previsão da demanda que deverá ser satisfeita. Sem um processo confiável de previsão, não existe um fundamento para determinação dos itens e das quantidades a produzir, estocar e expedir (LINES, 1996).

1.1 TEMA DO TRABALHO

A reestruturação do mercado automobilístico global, iniciada no fim dos anos 70, não afetou de imediato o cenário interno. Desde seus primórdios, a indústria automobilística brasileira se manteve distante da concorrência e das tendências do mercado externo, o que propiciou uma convivência relativamente harmoniosa entre as empresas dominantes do setor durante mais de três décadas, precisamente durante o ciclo de substituição

das importações. Até o início dos anos 90, a *Volkswagen* do Brasil, juntamente com três outros grandes grupos multinacionais, dominavam praticamente 100% do mercado automobilístico nacional e formavam um oligopólio, segundo a definição estrita do termo.

Com o advento da abertura de mercado, promovida durante o governo Collor, diversas facilidades foram criadas para a importação de veículos de passeio, tanto dos produzidos por outras unidades das montadoras aqui instaladas, quanto por outras empresas do setor sem fábricas no Brasil. A continuidade do processo de abertura econômica também proporcionou condições favoráveis para a instalação de diversas fábricas de outras marcas no Brasil. Em decorrência dessas políticas, os quatro grupos dominantes foram compelidos a operar em um ambiente progressivamente mais competitivo.

Como reação ao aumento da oferta de veículos importados e às montadoras recentemente instaladas no país, os quatro grandes fabricantes nacionais partiram para a reformulação de suas linhas de produção, de modo a acompanhar as inovações tecnológicas e os padrões de qualidade e segurança impostos pela concorrência externa e pelos novos entrantes.

Com a intenção de dirimir esse vácuo tecnológico e agilizar o lançamento de produtos mais competitivos, a *Volkswagen* do Brasil focalizou, durante a década de 90, a engenharia e a produção em detrimento das vendas e do marketing. Esse processo de adaptação à nova economia culminou na construção da moderna fábrica de São José dos Pinhais - PR, em 1998 e na reestruturação da fábrica de São Bernardo do Campo, no ABC paulista, em 2001, ambas preparadas para a produção de veículos de classe mundial: Golf, Audi A3, Fox e Polo.

Muito embora seu complexo industrial, composto por cinco fábricas, disponha hoje da mais avançada tecnologia para produção de veículos com qualidade internacional, a *Volkswagen* do Brasil não necessariamente produz o que os consumidores querem. O cultivo dessa cultura endógena, voltada para o aprimoramento dos processos produtivos, ofuscou a visão da empresa em relação à realidade externa e a afastou de seus fiéis clientes. Um sintoma desse distanciamento surgiu no final de 2000, quando a *Volkswagen*, líder no mercado brasileiro por mais de quatro décadas, fechou o ano em segundo lugar em vendas.

Para reconquistar o cliente, a *Volkswagen* necessitou passar por uma mudança cultural, não apenas internamente. A mudança se iniciou pela aproximação entre fabricante e

concessionárias. Entre as principais montadoras instaladas no país, a *Volkswagen* era a que mantinha a relação mais conflituosa com sua rede. O sistema de “empurrar” o estoque (*stock-push*), já descrito anteriormente, configurava o principal ponto de atrito entre as partes, pois concedia vantagens para a montadora em prejuízo das necessidades do varejo.

O envio mensal de cinco Kombi para cada revenda, sem considerar o perfil de seus clientes, sua localização e outras características específicas, pode ser citado como exemplo das distorções provocadas pelo sistema. Concessionárias localizadas em bairros nobres enfrentavam dificuldades para vender esse tipo de veículo. Em contrapartida, os modelos mais equipados e sofisticados permaneciam parados nos estoques das revendas situadas em regiões populares.

Embora o sistema estivesse ultrapassado dentro do próprio grupo, a *Volkswagen* era a única grande montadora a determinar às concessionárias quanto e o que deveriam comprar.

A partir de janeiro de 2003 o sistema de “empurrar” o estoque (*stock-push*) foi sendo gradativamente substituído pelo de varejo, ou puxado pela demanda (*demand-pull*). Com a inversão do sistema, passou a ser esperado que as concessionárias informem suas previsões de vendas para a montadora com oito semanas de antecedência.

Contudo, devido à subordinação ao sistema de atribuição de cotas durante décadas, as concessionárias *Volkswagen* não desenvolveram processos formais para elaborar suas próprias previsões de vendas de veículos. Apesar de possuírem bancos de dados relativos às suas vendas passadas, essas informações não são sistematicamente consultadas para compor modelos de previsão nas concessionárias.

Os responsáveis pelas previsões nas revendas *Volkswagen* habitualmente não analisam os dados históricos de demanda, porque não dispõem de treinamento adequado e de experiência no manejo das técnicas de previsão. Sem a aplicação de métodos explícitos, seja qualitativa ou quantitativamente, é praticamente impossível descrever o comportamento das séries históricas de vendas, identificar seu mecanismo gerador e fazer previsões confiáveis de valores futuros. Os previsores de vendas encontram, portanto, dificuldades para prever, satisfatoriamente, as quantidades e os modelos que serão vendidos oito semanas à frente e informá-los à *Volkswagen*.

O tema dessa dissertação compreende a análise do processo atualmente adotado por uma concessionária da marca Volkswagen para fornecimento de informações relativas às vendas futuras de veículos novos, bem como envolve a eliminação das deficiências percebidas nesse processo e sua reformulação mediante pesquisa e aplicação de modelos de previsão de Box-Jenkins e de suavização exponencial (quantitativos) e do método Delphi (qualitativo). Através da apresentação e aplicação desses métodos, a pesquisa pretende servir como referência e suporte para os responsáveis pela formulação de previsões de vendas em concessionárias de veículos.

1.2 JUSTIFICATIVAS DO TRABALHO

A habilidade para antever eventos futuros constitui uma das mais antigas virtudes gerenciais. Em nossos dias, a experiência e a capacidade de discernimento são freqüentemente associadas ao executivo de sucesso. Ambas as qualidades ampliam sua visão sobre o futuro do negócio e o habilitam para tomar a decisão mais apropriada, visando preparar a empresa para esse futuro. Ainda que essas virtudes não devam ser menosprezadas, são insuficientes para abranger a complexidade e acompanhar a velocidade das oscilações do mercado moderno (LINES, 1996).

Muitas organizações ainda contam com previsões formuladas a partir da opinião de um gerente ou equipe de vendas, sobre bases informais, sem a aplicação de um método explícito e consistente (RAMOS *et al.*, 2001). Nas previsões obtidas dessa forma, é comum a incorporação de um viés que represente, convenientemente, objetivos pessoais ou corporativos.

Esse viés pode ser motivado pelo próprio sistema de gratificações da empresa. Recursos financeiros são geralmente alocados segundo as previsões de vendas, o que cria um incentivo para superestimá-las. Em outros casos, critérios de avaliação do desempenho baseados na superação das previsões estimulam a minimização das estimativas. Apesar disso, o viés associado às previsões pode não ser intencional e provir do excesso de otimismo da equipe de vendas ou da restrita compreensão das metas organizacionais. O otimismo e a

tendência para superestimar as vendas são os desvios mais citados na literatura (SANDERS, 1995).

As concessionárias de veículos também se enquadram no perfil acima descrito. Respalçadas pela política de “empurrar” o estoque para a rede, as montadoras determinam os modelos e as quantidades de veículos que cada revenda deve receber mensalmente. Tais modelos e quantidades recebidos compõem as cotas mensais das concessionárias e são denominadas pelos vendedores de “metas de vendas”.

Nas regras tradicionalmente utilizadas pelas montadoras para distribuição de veículos entre suas revendas, se encontra embutido um sistema de recompensa pela venda de determinada quantidade de carros, através da alocação automática de um percentual maior de veículos, no próximo ciclo de vendas, para as concessionárias que cumpriram a cota estipulada para o período corrente (DURAND *et al.*, 2002).

Essa forma de gratificação induz os gerentes a se concentrarem no preenchimento das cotas mensais que lhe são atribuídas pelas respectivas montadoras, mediante definição de metas de vendas para os vendedores e exercício de pressão sobre a equipe, a fim de que os resultados sejam alcançados. Posto que a gestão da demanda permanece centralizada nas montadoras, os gerentes de concessionárias não analisam o comportamento histórico das vendas de forma sistemática e, portanto, não encontram justificativas plausíveis para investir na obtenção de previsões mais precisas.

Somente as opiniões dos vendedores são informalmente reunidas, para compor uma análise superficial e intuitiva do mercado, a qual fornece previsões para um horizonte curto e com pouca confiabilidade, em razão do viés provocado pelo sistema de atribuição de cotas e gratificações (PINTO FILHO, 2000).

Contudo, a sujeição ao sistema de “empurrar” o estoque (*stock-push*), embora force as concessionárias a venderem de acordo com as cotas estipuladas pelas montadoras, não elimina a necessidade de manutenção de reserva financeira e inventário de veículos compatíveis com a demanda. O excesso de inventário provoca elevação de custos. A escassez de produtos acabados, por sua vez, resulta em queda do nível de serviço e perda de vendas, pois se um veículo, com as características e faixa de preço desejados, não se encontrar em estoque ou não puder ser disponibilizado em curto prazo, o consumidor possivelmente optará por procurá-lo na marca concorrente.

A antecipação das necessidades de recursos financeiros é igualmente essencial para o desenvolvimento de planos de contingência, que possam sustentar a eficiência das operações das concessionárias em períodos de baixa nas vendas e garantir investimentos em situações de mercado favoráveis (AHADIAT, 1992). Tanto a gestão financeira quanto a otimização de estoques dependem diretamente da habilidade das revendas para prever localmente suas próprias vendas, independentemente do fabricante.

Além disso, ao ocuparem um espaço intermediário entre as montadoras e os clientes, as revendas detêm o privilégio de proporcionar o primeiro contato dos consumidores com o produto. As operações anteriores, desde o projeto até a produção do veículo, podem ser interpretadas apenas como uma preparação para esse derradeiro encontro. Na divisão de responsabilidades ao longo da cadeia automotiva, sempre coube às concessionárias, na condição de organismos especializados, distintos dos fabricantes, além da função de fiadores da qualidade e da manutenção do produto final, a tarefa de buscar esse contato com os consumidores.

É natural que a inserção das revendas no contexto cultural torne possível a construção de relações locais e regionais com o público. Logo, o ato que culmina na compra de um veículo novo é, via de regra, de cunho pessoal e localmente circunscrito. A destreza para estabelecer esse contato com os clientes sempre foi atributo das revendas. As montadoras, ao contrário, se mostraram incapazes de alcançar semelhante sintonia e de encontrar as vias de acesso aos consumidores (ARBIX; VEIGA, 2001).

Em decorrência dessa inerente proximidade dos consumidores, a capacidade das concessionárias para interpretar o comportamento local da demanda e elaborar previsões de vendas adquire relevância também para as montadoras. Previsões confiáveis, obtidas na extremidade final da rede de distribuição, conferem aos fabricantes, desde que adequadamente consolidadas e integradas aos seus processos de administração de pedidos e de planejamento de produção, maior sensibilidade diante das peculiaridades locais da demanda e encurtam a distância que os separam de seus clientes.

A identificação antecipada do perfil dos consumidores e do comportamento da demanda nas concessionárias podem reduzir as incertezas da produção em larga escala e impulsionar a substituição do tradicional sistema de “empurrar” o estoque (*stock-push*) por

um sistema de produção puxada pela demanda (*demand-pull*) ou de produção contra pedido (*BTO*).

A obtenção de previsões consistentes requer, porém, o emprego de um processo formal para elaborá-las (ELIKAI *et al.*, 1999). De fato, a qualidade das previsões de demanda tende a aumentar significativamente, quando um processo sistemático é colocado em prática (JAIN, 2001).

Os processos para geração de previsões são constituídos por técnicas qualitativas, quantitativas (denominadas técnicas de *forecasting*) ou pela combinação de ambas. As técnicas quantitativas se valem de uma seqüência de observações e de um padrão histórico de demanda, capturado por intermédio de modelos matemáticos, para extrapolar (estimar) valores futuros. As técnicas qualitativas têm por fundamento a opinião de especialistas, que recorrem a um método de análise de situações similares para prever a demanda futura (ELSAYED; BOUCHER, 1994).

Os gerentes de vendas e os vendedores das concessionárias, no entanto, desconhecem os métodos para elaboração de previsões abordados na literatura, tanto os quantitativos quanto os qualitativos. Mesmo os métodos mais simples, como médias móveis ou a técnica denominada previsão ingênua (*naive forecasting*), que consiste apenas em projetar para o período seguinte o valor das vendas do período anterior, são desconhecidas pelos gerentes das concessionárias pesquisadas em Pinto Filho (2000).

Perante a evidente contradição entre a importância das previsões de demanda, abordada acima, e a ausência de familiaridade com as técnicas de *forecasting*, observada nas concessionárias, o desenvolvimento dessa dissertação se encontra justificado.

1.3 OBJETIVOS DO TRABALHO

1.3.1 Objetivo Geral

O presente trabalho visa o desenvolvimento de um sistema formal para elaboração de previsões de demanda de veículos novos em uma concessionária da marca *Volkswagen* localizada em Curitiba – PR.

1.3.2 Objetivos Específicos

- Descrever o comportamento da demanda de veículos novos na concessionária *Volkswagen* abordada, a partir do reconhecimento de média, tendências, variações sazonais, pontos espúrios e ruído aleatório nas séries temporais de vendas;
- Determinar os modelos matemáticos de previsão que melhor se ajustam ao perfil da demanda de veículos novos na revenda estudada;
- Elaborar, por meio da aplicação dos modelos mais adequados, as previsões das vendas de veículos novos que serão previamente transmitidas para a *Volkswagen*;
- Formalizar a incorporação do julgamento de especialistas e gerentes às previsões obtidas pelos modelos estatísticos.

1.4 DELIMITAÇÕES DO TRABALHO

As técnicas de *forecasting* apresentadas e aplicadas nesse estudo compreendem os modelos de Box & Jenkins e de Suavização Exponencial (qualitativos) e o método Delphi (qualitativo). Outras técnicas de previsão não são abordadas em detalhes.

Essa dissertação não contempla as seguintes questões organizacionais:

- Melhoria do relacionamento entre a *Volkswagen* e sua rede de concessionárias;
- Otimização dos sistemas de informação desenvolvidos e utilizados pela *Volkswagen* para a programação e administração de pedidos;
- Reestruturação do processo de gestão de demanda na montadora e
- Análise de investimento para a implantação de técnicas de *forecasting* na revenda em estudo.

1.4 ESTRUTURA DA DISSERTAÇÃO

O CAPÍTULO 1 traz o contexto geral do problema, a justificativa e o tema da dissertação. São também descritos os objetivos gerais e específicos, a contribuição, as limitações e a estrutura da pesquisa.

O CAPÍTULO 2, de revisão bibliográfica, apresenta uma compilação de fontes bibliográficas que suportem a consecução dos objetivos almejados pela pesquisa.

O CAPÍTULO 3 apresenta uma descrição pormenorizada do método empregado para execução e consolidação dos resultados da pesquisa.

O CAPÍTULO 4 traz o estudo de caso, no qual se efetua uma exposição detalhada do processo gestão da demanda na concessionária abordada e se desenvolve um processo formal para gerar previsões de vendas de veículos novos. Também são apresentados o detalhamento da aplicação do sistema desenvolvido e dos resultados obtidos.

No CAPÍTULO 5 são apresentadas as conclusões do estudo e sugestões para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Para abranger a diversidade das possíveis aplicações, diversas técnicas de previsão de vendas foram desenvolvidas. Essas técnicas foram classificadas em duas categorias principais: quantitativas e qualitativas.

Os métodos de *forecasting* quantitativo englobam a análise de séries temporais, os modelos de suavização exponencial e os modelos causais (econométricos); os métodos de *forecasting* qualitativo se dividem em métodos exploratórios e normativos (MAKRIDAKIS *et al.*, 1998).

A abordagem quantitativa é a mais eficiente na geração de previsões, quando existe uma demanda histórica pelo produto, disponível em uma infra-estrutura sistêmica confiável, capaz de propiciar informações históricas, e quando a demanda se comporta de um modo que possa ser capturado pelos métodos estatísticos. Padrões simples, suaves e repetitivos constituem a situação ideal da abordagem estatística e serão previstos com relativa facilidade e precisão (GILLILAND; PRINCE, 2001). O *forecasting* quantitativo, portanto, é aplicado quando (MAKRIDAKIS *et al.*, 1998):

- a) existem dados históricos das vendas;
- b) esses dados podem ser quantificados para fornecer informações numéricas úteis e
- c) se presume que o padrão histórico das vendas se repetirá no futuro.

Todos os métodos de *forecasting* quantitativo e muitos métodos qualitativos têm por fundamento a condição (c), conhecida por “suposição de continuidade”. Quase todas as previsões de vendas de curto prazo provêm da extrapolação de dados, ou seja, são baseadas na suposição de que o futuro próximo representará a continuidade do padrão registrado no passado imediato (MAKRIDAKIS *et al.*, 1998).

Os modelos de análise de séries temporais compreendem o método de Box-Jenkins, cujo objetivo consiste justamente em identificar um modelo matemático que seja capaz de extrapolar o padrão histórico das séries de vendas, a partir de seus valores e/ou erros passados.

Os modelos de suavização exponencial atribuem pesos que decaem exponencialmente em direção ao passado, a partir das observações mais recentes de uma série

temporal, e incluem as abordagens de Brown, para séries com tendência e de Holt-Winters, utilizada para séries que também apresentam comportamento sazonal.

A aplicação da suavização exponencial requer menor esforço, em comparação com o método de Box-Jenkins e com os modelos causais, pois não exige conhecimentos aprofundados em Estatística. Os modelos de suavização apresentam, porém, a desvantagem de confundirem mudanças estruturais nos dados originais com variações sazonais. Nos modelos de Box-Jenkins é possível incorporar mudanças estruturais mediante a utilização de uma variável fictícia (*dummy variable*) para um evento específico nos dados históricos, mantendo intocadas as estimativas sazonais (ZHOU, 1999).

Uma vez que a demanda por bens de consumo está intrinsecamente relacionada aos valores pessoais e que os indivíduos tendem a modificar seus hábitos lentamente, tanto os métodos de Box-Jenkins quanto os de suavização exponencial costumam fornecer previsões confiáveis (LINES, 1996).

Os modelos causais, por sua vez, assumem que os valores a serem previstos guardam relação de causa e efeito com uma ou mais variáveis independentes (por exemplo, volume de vendas como função do preço do produto, impostos, taxa de inflação, investimentos em publicidade, etc.). O conhecimento das características dessa relação viabiliza a previsão de valores futuros da variável dependente (MAKRIDAKIS *et al.*, 1998).

Os valores futuros das variáveis independentes devem ser conhecidos, a fim de que modelos causais possam ser utilizados como método de *forecasting*. Do mesmo modo que as vendas, essas variáveis independentes configuram funções econômicas, que também devem ser previstas (ELSAYED; BOUCHER, 1994). A necessidade de se prever outras variáveis, além da própria demanda, pode provocar acréscimo dos erros de previsão (TIDESWELL *et al.*, 2001).

Por conseguinte, modelos causais oferecem melhores resultados quando empregados na elaboração de planos de ação e para tomadas de decisão, ao passo que modelos de séries temporais e de suavização exponencial são mais adequados para a geração de previsões (MAKRIDAKIS *et al.*, 1998).

A utilização de métodos quantitativos de *forecasting* depende dos padrões de comportamento da demanda que será prevista. Cinco padrões podem ser exibidos por uma

série histórica: horizontal (ou estacionário na média), sazonal, cíclico e tendente. A mesma série pode incluir quaisquer combinações desses padrões (KRAJEWSKI; RITZMAN, 1999).

A Figura 1 ilustra graficamente os quatro primeiros padrões de comportamento mencionados. As letras de (a) a (d) relacionam cada gráfico da Figura 1 com as suas respectivas descrições. O item (e) apresenta o padrão de comportamento aleatório.

- a) A estacionariedade na média consiste na flutuação dos valores em torno de uma média constante;
- b) O padrão sazonal ocorre quando a série sofre variações influenciadas por fatores que se repetem em intervalos constantes de tempo, como o incremento das vendas de aparelhos de ar condicionado nos meses de verão ou de champanhe em dezembro;
- c) A série é cíclica caso apresente variações ascendentes ou descendentes que se prolongam por períodos relativamente longos e não regulares de tempo;
- d) A série contém tendência quando o comportamento ascendente ou descendente se mantém por um longo período de tempo;
- e) Variação aleatória, ou imprevisível, na demanda.

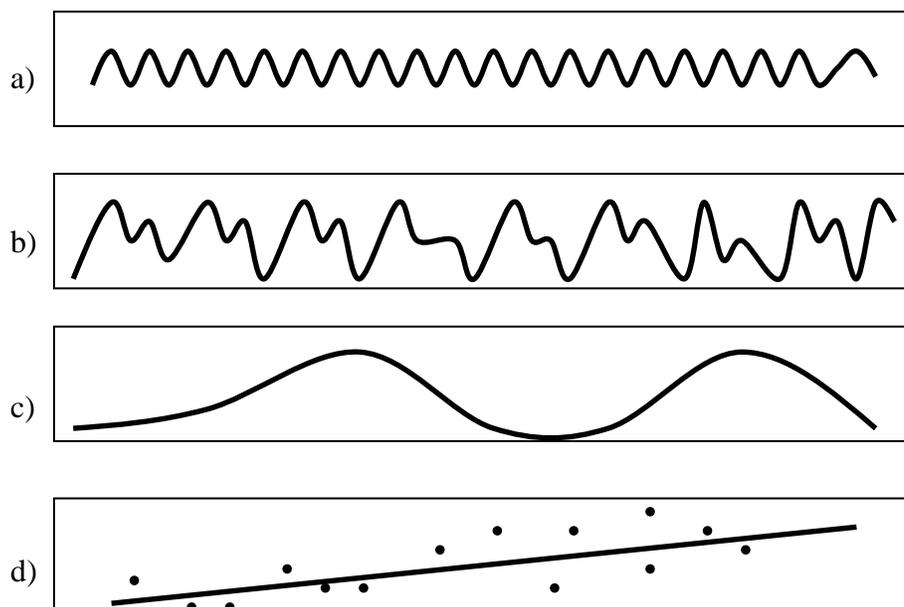


Figura 1: Padrões de demanda (adaptado de KRAJEWSKI; RITZMAN, 1999)

O quinto padrão (e) é resultante de variações aleatórias na demanda. O ruído aleatório não pode ser previsto, visto que não se sujeita à modelagem matemática.

Ao contrário dos métodos quantitativos, o *forecasting* qualitativo não requer a existência de dados históricos. Os dados de entrada da abordagem qualitativa são formados a partir do conhecimento acumulado e do julgamento de profissionais especializados. Os métodos qualitativos exploratórios, entre os quais o Delphi, partem do passado e do presente, a fim de promover um movimento heurístico em direção ao futuro, que contemple as possibilidades disponíveis para a composição de diferentes cenários. Os métodos normativos, como as matrizes de decisão, procuram determinar os objetivos futuros, para então se moverem retroativamente até o presente e avaliar se aquelas metas podem ser atingidas, considerando as restrições, os recursos e a tecnologia atualmente disponíveis (MAKRIDAKIS *et al.*, 1998).

Nas seções seguintes serão apresentados os métodos de *forecasting* quantitativo de Box-Jenkins e de Suavização Exponencial, o método qualitativo Delphi e algumas formas de integrá-los para geração de previsões mais acuradas.

2.1 ANÁLISE DE SÉRIES TEMPORAIS

2.1.1 Modelos de Box & Jenkins

O método desenvolvido pelos pesquisadores George Box e Gwilym Jenkins no início da década de 70, através do qual foi proposta uma classe geral de modelos lineares conhecidos por ARIMA (*auto-regressive integrated moving average* ou auto-regressivos, integrados, de médias móveis), pode ser considerado o mais importante trabalho publicado no âmbito da previsão de séries temporais, posto que propiciou a formalização da área de estudo denominada *Análise de Séries Temporais* (OLIVEIRA, 2002).

O trabalho de Box e Jenkins fundamentou-se na demonstração de Wold (1938) de que qualquer série temporal estacionária poderia ser modelada por uma combinação de observações e erros passados, ou seja, pela soma de processos auto-regressivos (AR) e de médias móveis (MA), desde que as respectivas ordens p (número de termos AR) e q (número

de termos MA) fossem apropriadamente especificadas (modelos ARMA) (MAKRIDAKIS; HIBON, 1997).

Todavia, o trabalho de Box e Jenkins adquiriu influência no meio científico, principalmente porque transferiu a atenção dos pesquisadores, da modelagem de processos estacionários, para uma classe de processos não estacionários e respectivas idéias relacionadas à obtenção de séries estacionárias, mediante determinada ordem de diferenciação (d) (modelos ARIMA).

O método Box-Jenkins se tornou popular graças à possibilidade de generalização, tanto para o tratamento de séries estacionárias ou não-estacionárias, como para séries com ou sem componentes sazonais. O uso freqüente do método em trabalhos empíricos e a inclusão de recursos de cálculo compatíveis, em pacotes computacionais bem documentados, contribuíram ainda mais para sua difusão (LIM; McALEER, 2001).

A adequada aplicação dos modelos Box-Jenkins depende da compreensão dos conceitos iniciais apresentados na próxima seção desse capítulo.

2.1.1.1 Conceitos Iniciais

- *Processos Estocásticos e Séries Temporais*

Uma seqüência de valores que descrevem algum fenômeno físico ao longo do tempo pode ser representada por modelagem matemática. O modelo matemático pode ser utilizado, por exemplo, para a elaboração de previsões de valores da série em momentos futuros.

Quando a obtenção de previsões exatas for possível, os modelos são denominados determinísticos. Contudo, a maioria dos fenômenos encontrados na prática estão sujeitos à ocorrência de eventos aleatórios, que tornam impossível o cálculo de valores exatos (PELLEGRINI, 2000). Nesse caso, a previsão deve ser considerada como a probabilidade de um valor futuro permanecer entre dois limites específicos (LAPA, 1998).

Os modelos matemáticos empregados para analisar fenômenos dependentes de leis probabilísticas são ditos estocásticos. Desta forma, um processo estocástico consiste de

uma família de variáveis aleatórias, definidas num espaço de probabilidades, que descrevem a evolução temporal de um fenômeno de interesse.

Nos processos com parâmetro contínuo, as variáveis representam uma medida que varia continuamente, como temperatura, nível das marés, etc. Quando, porém, o parâmetro é discreto, a família de variáveis pode ser uma contagem, como a venda semanal de veículos por uma concessionária.

Nesse contexto, uma série temporal pode ser definida como uma realização de um processo estocástico, denotada simplesmente por Z_t e constituída por um conjunto de observações que guardam dependência serial entre si, tomadas em instantes discretos e equiespaçados no tempo: Z_1, Z_2, \dots, Z_n (MORETTIN; TOLOI, 1985). As Figuras 2 e 3 apresentam um processo estocástico e uma série temporal respectivamente.

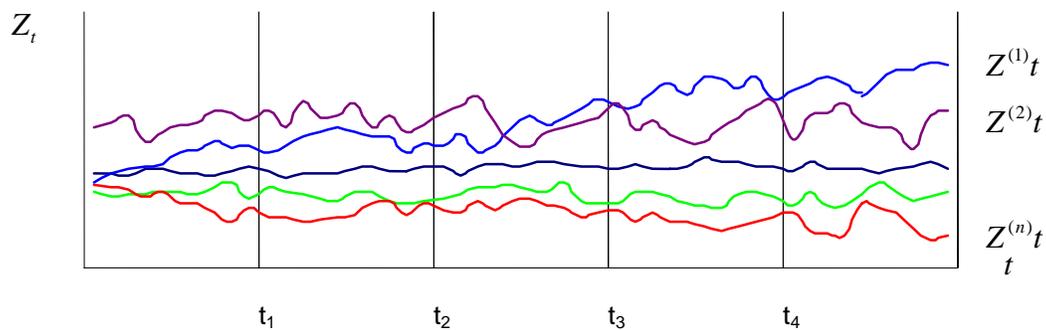


Figura 2: Aspecto de um processo estocástico, interpretado como uma família de trajetórias (adaptado de MORETTIN; TOLOI, 1985)

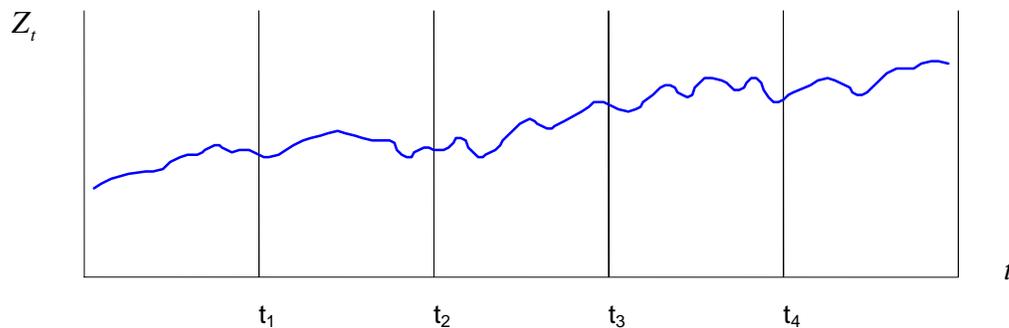


Figura 3: Uma série temporal, definida como uma das trajetórias do processo estocástico (adaptado de TRENTIN, 2002)

▪ *Processos Estocásticos Estacionários e Não-Estacionários*

Em sentido amplo, um processo estocástico é considerado estacionário se a família de variáveis se mantém em torno de uma média constante, possui variância finita e se a covariância entre duas observações do processo depende somente de sua defasagem no tempo. Considera-se, ainda, estritamente estacionário, um processo estocástico cuja função de distribuição de probabilidade permaneça a mesma para qualquer grupo de observações, de modo que as características de Z_{t-k} sejam idênticas as de Z_t , para todo k (LAPA, 1998).

A média do processo estacionário é representada por $\mu = E[Z_t]$ e variância, do mesmo modo, é dada por $\sigma_t^2 = E[Z_t - \mu]^2 = \gamma_0$. Tanto a média quanto a variância do processo estacionário podem ser estimadas a partir das respectivas médias e variâncias das observações da série temporal $\{Z_t, t = 1, 2, 3, \dots, n\}$:

$$\bar{Z} = \frac{1}{n} \sum_{t=1}^n Z_t \quad (1)$$

$$s_z^2 = \frac{1}{n} \sum_{t=1}^n (Z_t - \bar{Z})^2 = \hat{\gamma}_0 \quad (2)$$

A Figura 4 exhibe graficamente uma série temporal estacionária, cujas observações oscilam em torno de um nível médio constante. Contudo, a maioria das séries encontradas na prática, como as vendas semanais de um determinado produto, não flutuam em torno de uma média fixa e, portanto, são não estacionárias em nível e/ou inclinação. As Figuras 5 e 6 exemplificam o comportamento de séries não estacionárias.

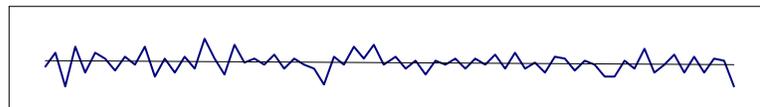


Figura 4: Aspecto de uma série temporal estacionária em nível e inclinação (adaptado de BOX; JENKINS, 1976)



Figura 5: Aspecto de uma série temporal não estacionária em nível
(adaptado de BOX; JENKINS, 1976)

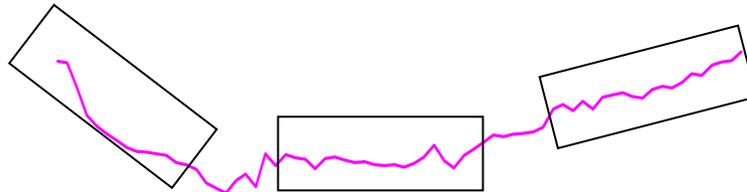


Figura 6: Aspecto de uma série temporal não estacionária em nível e inclinação
(adaptado de BOX; JENKINS, 1976)

- *Função de Autocorrelação (FAC)*

Uma série temporal estacionária pode ser apropriadamente descrita através de suas funções de média e variância. Entretanto, se a série analisada é não estacionária, a média e variância, isoladamente, não terão muita utilidade. Nesse caso, a estatística fundamental na análise de séries temporais é a função de autocorrelação, a qual descreve a correlação entre duas observações da mesma série temporal para uma defasagem de 1 ou mais intervalos de tempo (MAKRIDAKIS *et al.*, 1998). A correlação entre duas observações Z_t e Z_{t+j} , da mesma série temporal, distantes j intervalos de tempo entre si, é denominada autocorrelação de *lag* j (ou defasagem j) e definida pela razão:

$$\frac{\gamma_j}{\gamma_0} = \rho_j = \frac{E[(Z_t - \mu)(Z_{t+j} - \mu)]}{\sigma_Z^2}$$

onde γ_j é a covariância entre as observações Z_t e Z_{t+j} e γ_0 é a variância da série temporal. O coeficiente de autocorrelação ρ_j pode ser estimado a partir da série observada $\{Z_t, t = 1, 2, \dots, n\}$:

$$\mathcal{H}_j = \frac{\sum_{t=1}^{n-j} (Z_t - \bar{Z})(Z_{t+j} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (3)$$

Para ilustrar o cálculo do coeficiente de autocorrelação, será utilizada a série temporal apresentada na Tabela 1.

Tabela 1: Série temporal e respectivo desenvolvimento para o cálculo dos coeficientes de autocorrelação de lag 1 e 2 (adaptado de MAKRIDAKIS *et al*, 1998)

t	Z_t	Z_{t+1}	Z_{t+2}	$(Z_t - \bar{Z})$	$(Z_{t+1} - \bar{Z})$	$(Z_{t+2} - \bar{Z})$	$(Z_t - \bar{Z})^2$	$(Z_t - \bar{Z})(Z_{t+1} - \bar{Z})$	$(Z_t - \bar{Z})(Z_{t+2} - \bar{Z})$
1	14	-	-	2,4	-	-	5,8	0	0
2	8	14	-	-3,6	2,4	-	13,0	-8,64	0
3	17	8	14	5,4	-3,6	2,4	29,2	-19,44	12,96
4	7	17	8	-4,6	5,4	-3,6	21,2	-24,84	16,56
5	13	7	17	1,4	-4,6	5,4	2,0	-6,44	7,56
6	12	13	7	0,4	1,4	-4,6	0,2	0,56	-1,84
7	11	12	13	-0,6	0,4	1,4	0,4	-0,24	-0,84
8	10	11	12	-1,6	-0,6	0,4	2,6	0,96	-0,64
9	14	10	11	2,4	-1,6	-0,6	5,8	-3,84	-1,44
10	10	14	10	-1,6	2,4	-1,6	2,6	-3,84	2,56
$\bar{Z} = 11,6$				Σ			82,4	-65,76	34,88

Utilizando a equação (3) e os somatórios da Tabela 1, obtêm-se:

$$\mathcal{H}_1 = \frac{-65,76}{82,4} = -0,798$$

e

$$\mathcal{H}_2 = \frac{34,88}{82,4} = 0,423$$

Prosseguindo com o mesmo desenvolvimento para $j=3$ e $j=4$, chega-se a $\mathcal{H}_3 = -0,139$ e $\mathcal{H}_4 = 0,106$ respectivamente, o que revela uma série com associações significativas entre seus valores, para defasagens de 1 e 2 intervalos de tempo, e associações decrescentes a partir de uma defasagem maior ou igual a 3.

O coeficiente de autocorrelação de lag 1 negativo indica que as diferenças entre a média \bar{Z} e as observações adjacentes Z_t e Z_{t+1} tendem a possuir sinais opostos, ou seja, quando a diferença $(Z_t - \bar{Z})$ é positiva, $(Z_{t+1} - \bar{Z})$ tende a ser negativa. A autocorrelação de lag

1 positiva ocorre quando diferenças positivas tendem a seguir diferenças positivas e vice-versa (ELSAYED; BOUCHER, 1994).

Para fins didáticos, é possível estimar o coeficiente de autocorrelação para a uma série temporal com apenas 10 observações, como no exemplo acima. Na prática, porém, uma boa estimativa do coeficiente de autocorrelação requer pelo menos 50 observações da série $\{Z_t, t=1,2,3,\dots,n\}$, sendo n a quantidade total de observações da série, e pode ser calculada para um número de *lags* $j=1,2,3,\dots,J$, onde $J = \frac{n}{4}$ (BOX; JENKINS, 1976).

▪ *Modelo de Filtro Linear*

Uma série temporal $\{Z_t, t=1,2,3,\dots,n\}$, cujos sucessivos valores são intrinsicamente dependentes, pode ser gerada por uma série de choques aleatórios estatisticamente independentes $\{a_t, a_{t-1}, a_{t-2}, \dots\}$, tomados de uma distribuição fixa, geralmente a Normal com média zero e variância σ_a^2 . A seqüência de variáveis aleatórias $\{a_t, a_{t-1}, a_{t-2}, \dots\}$ é conhecida por ruído aleatório.

O ruído aleatório a_t é transformado no processo Z_t , isto é, em uma série temporal, mediante a *função de transferência do filtro* $\psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \dots$, que consiste em uma soma ponderada dos ruídos aleatórios precedentes, tal que (BOX; JENKINS, 1976):

$$Z_t = \mu + a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots,$$

onde $\psi_0 = 1$ ou

$$Z_t = \mu + \psi(B)a_t, \tag{4}$$

sendo B um operador de translação ao passado, definido por $B^m a_t = a_{t-m}$; quando $m=1$, $Ba_t = a_{t-1}$.

Se a seqüência de pesos $\{\psi_1, \psi_2, \dots, \psi_j, j \geq 1\}$ for finita, ou infinita, porém convergente, o filtro é estável (somável), o processo Z_t é estacionário e o parâmetro μ representa a média em torno da qual o processo oscila. Quando a seqüência $\{\psi_1, \psi_2, \dots, \psi_j\}$ não

converge, ou seja, quando a soma dos pesos não possui um valor definido, o processo não é estacionário e o parâmetro μ não tem significado específico e indica apenas um ponto de referência para o nível do processo (MORETTIN; TOLOI, 1985).

2.1.1.2 Modelos Auto-regressivos

Um modelo estocástico que explora a estrutura de autocorrelações existente entre os valores de uma série temporal, para elaborar, a partir das suas próprias observações anteriores, previsões de valores futuros, é dito auto-regressivo (ELSAYED; BOUCHER, 1994).

Definem-se as observações anteriores de uma série temporal, tomadas em instantes discretos e equiespaçados no tempo $t, t-1, t-2$, por $Z_t, Z_{t-1}, Z_{t-2}, \dots$ e seus respectivos desvios da média μ por $\bar{Z}_t = Z_t - \mu$, $\bar{Z}_{t-1} = Z_{t-1} - \mu$, $\bar{Z}_{t-2} = Z_{t-2} - \mu, \dots$.

No processo auto-regressivo de *lag* 1, ou de primeira ordem, designado por AR(1), a expressão do valor corrente da série depende unicamente de sua observação precedente, mais um ruído aleatório a_t , ou seja,

$$\bar{Z}_t = \phi_1 \bar{Z}_{t-1} + a_t, \quad t \quad (5)$$

onde ϕ_1 é um coeficiente (ou peso) que descreve como o valor corrente \bar{Z}_t se relaciona com a observação precedente \bar{Z}_{t-1} .

Assim, um processo auto-regressivo de ordem p , AR(p) tem a forma geral:

$$\bar{Z}_t = \phi_1 \bar{Z}_{t-1} + \phi_2 \bar{Z}_{t-2} + \dots + \phi_p \bar{Z}_{t-p} + a_t, \quad (6)$$

ou simplesmente

$$\phi(B)\bar{Z}_t = a_t, \quad (7)$$

com o operador auto-regressivo de ordem p definido por

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p.$$

▪ *Condições de Invertibilidade e Estacionariedade de um processo AR(p)*

O processo auto-regressivo constitui um caso especial do modelo de filtro linear. Para demonstrar tal proposição, basta substituir \hat{Z}_{t-1} , no lado direito da equação (6), pela expressão

$$\hat{Z}_{t-1} = \phi_1 \hat{Z}_{t-2} + \phi_2 \hat{Z}_{t-3} + \dots + \phi_p \hat{Z}_{t-p-1} + a_t$$

e assim, sucessivamente, para \hat{Z}_{t-2} , \hat{Z}_{t-3} , até que se obtenha uma série infinita de a 's, de forma que se $\phi(B)\hat{Z}_t = a_t$ e $\hat{Z}_t = \psi(B)a_t$, chega-se a

$$\phi(B)\psi(B)a_t = a_t$$

$$\phi(B)\psi(B) = 1$$

$$\psi(B) = \phi^{-1}(B) \text{ ou } \phi(B) = \psi^{-1}(B).$$

Essa propriedade é conhecida por invertibilidade, pois permite que os pesos dos valores passados ϕ_j possam ser obtidos a partir dos pesos dos ruídos passados ψ_j e vice-versa. Para que um processo seja invertível, o operador $\phi(B)$ deve convergir para $|B| \leq 1$.

Visto que $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ é finito, $\phi(B)$ converge para $|B| \leq 1$ e, portanto, não existem restrições relativas aos parâmetros para assegurar a invertibilidade de um processo AR(p) (MORETTIN; TOLOI, 1985).

O caso mais simples de processo auto-regressivo, AR(1), $\hat{Z}_t = \phi \hat{Z}_{t-1} + a_t$, pode ser escrito ainda como

$$\hat{Z}_t = \frac{1}{1 - \phi_1 B} a_t.$$

Se $\hat{Z}_t = \psi(B)a_t$, então

$$\psi(B) = \frac{1}{1 - \phi_1 B}$$

Da seção 2.1.1.1 sabe-se que um processo é estacionário se a série $\psi(B)$ convergir para $|B| \leq 1$. Para $\psi(B) = \frac{1}{1 - \phi_1 B}$ e $|B| \leq 1$, existe convergência somente se

$|\phi| < 1$, o que resulta em raiz da equação $\phi(B) = 1 - \phi B$, expressa por $B = \frac{1}{\phi}$, obrigatoriamente

maior do que 1 em módulo, isto é, situada fora do círculo unitário (BOX; JENKINS, 1976).

As condições acima, válidas para modelos AR(1), podem ser estendidas para quaisquer modelos AR(p), de modo que o operador auto-regressivo $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$, considerado um polinômio em B de grau p , deve possuir todas as suas raízes $\phi(B) = 0$ fora do círculo unitário, para que esteja garantida a estacionariedade do processo (PELLEGRINI, 2000).

▪ *Função de Autocorrelação (FAC) de um processo AR(p)*

A função de autocorrelação de um processo AR(1) é expressa por $\rho_j = \phi_1 \rho_{j-1}$, se $j > 0$, ou $\rho_j = \phi_1^j$, se $j \geq 0$, visto que $\rho_0 = 1$. Nesse caso, a FAC sempre decai exponencialmente até zero, sem alternância de sinal, se $\phi_1 > 0$, e com alternância de sinal, a começar pelo lado negativo, se $\phi_1 < 0$.

De modo geral, para um processo AR(p), a FAC tem a forma

$$\rho_j = \phi_1 \rho_{j-1} + \phi_2 \rho_{j-2} + \dots + \phi_p \rho_{j-p}, \quad (8)$$

que também pode ser escrita $\phi(B)\rho_j = 0$, onde $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$, com B operando em j e não em t , de forma que $B\rho_j = \rho_{j-1}$.

▪ *Estimativa dos Parâmetros Auto-regressivos em Função das Autocorrelações*

O modelo AR(p) contém $p+2$ parâmetros desconhecidos, que devem ser estimados. A estimativa da média e da variância do processo pode ser obtida diretamente das observações da série temporal, como demonstrado na seção 2.1.1.1. Os coeficientes $\phi_1, \phi_2, \dots, \phi_p$ podem ser estimados a partir das autocorrelações (MORETTIN; TOLOI, 1985).

Caso se substitua $j = 1, 2, \dots, p$ em $\rho_j = \phi_1 \rho_{j-1} + \phi_2 \rho_{j-2} + \dots + \phi_p \rho_{j-p}$ (8), obtêm-se as equações

$$Z_t = \phi_{k1}Z_{t-1} + \phi_{k2}Z_{t-2} + \dots + \phi_{kk}Z_{t-k} + a_t$$

e da equação (8)

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{k(k-1)}\rho_{j-k+1} + \phi_{kk}\rho_{j-k}, \quad (9)$$

com $j = 1, 2, \dots, k$. Para um modelo AR(1), especificamente, tem-se

$$Z_t = \phi_{11}Z_{t-1} + a_t,$$

de forma que ϕ_{11} mede o relacionamento entre Z_t e Z_{t-1} . Posto que não existem outras variáveis no modelo, ϕ_{11} mede tanto a autocorrelação, quanto a autocorrelação parcial, ou seja, $\phi_{11} = \rho_1$.

Para ordens maiores, por exemplo, um AR(2),

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + a_t,$$

onde ϕ_{22} indica o grau de relacionamento, isto é, mede a autocorrelação parcial entre Z_t e Z_{t-2} , mantendo fixo o efeito de Z_{t-1} .

Conforme o procedimento de estimativa dos parâmetros auto-regressivos $\phi_1, \phi_2, \dots, \phi_p$ visto anteriormente, os coeficientes de autocorrelação parcial $\phi_{11}, \phi_{22}, \dots, \phi_{kk}$ também podem ser estimados mediante ajuste sucessivo de $k = 1, 2, 3, \dots$ na equação (9), o que resulta em equações de *Yule-Walker*. Da mesma forma, deve-se substituir as autocorrelações teóricas $\rho_1, \rho_2, \dots, \rho_j$ pelas estimativas das autocorrelações amostrais $\hat{\rho}_1, \hat{\rho}_2, \dots, \hat{\rho}_j$ nas equações de *Yule-Walker*, para que se obtenha os coeficientes $\hat{\phi}_{11}, \hat{\phi}_{22}, \dots, \hat{\phi}_{kk}$ estimados (MAKRIDAKIS *et al.*, 1998).

Em um modelo AR(2) chega-se a

$$\phi_{22} = \frac{\begin{bmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{bmatrix}}{\begin{bmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{bmatrix}} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}$$

2.1.1.3 Modelos de Médias Móveis

Um processo de médias móveis tira proveito da estrutura de autocorrelações existente entre os erros (ou resíduos) das previsões anteriores de uma série temporal, para formular um modelo de previsão de seus valores futuros (ELSAYED; BOUCHER, 1994). Assim, representando ainda os desvios da média das observações Z_t por \hat{Z}_t , um modelo de médias móveis de ordem q , MA(q), depende linearmente de um número finito q de erros precedentes correlacionados ($\theta_q a_{t-q}$), mais um ruído aleatório a_t , de forma que

$$\hat{Z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}, \quad (10)$$

com o operador de médias móveis de ordem q definido por $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$, pode-se escrever

$$\hat{Z}_t = \theta(B) a_t, \quad (11)$$

sendo que $\theta_1, \theta_2, \dots, \theta_q$ constituem pesos atribuídos aos erros prévios correlacionados.

- *Condições de Estacionariedade e Invertibilidade de um processo MA(q)*

Uma vez que $\psi(B) = \theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ é finito, $\theta(B)$ converge para $|B| \leq 1$ e, portanto, não existem restrições relativas aos parâmetros para assegurar a estacionariedade de um processo MA(q) (MORETTIN; TOLOI, 1985).

No caso de um modelo de médias móveis de primeira ordem, MA(1), tem-se

$$\hat{Z}_t = a_t - \theta_1 a_{t-1} \quad (12)$$

ou

$$\phi(B) = \frac{1}{1 - \theta_1 B}$$

Da seção 2.1.1.2 sabe-se que um processo é invertível, se o operador $\phi(B)$ convergir para $|B| \leq 1$. Para $\phi(B) = \frac{1}{1 - \theta_1 B}$ e $|B| \leq 1$, existe convergência somente se

$|\theta| < 1$, o que resulta em raiz da equação $\theta(B) = 1 - \theta B$, expressa por $B = \frac{1}{\theta}$, obrigatoriamente maior do que 1 em módulo, isto é, situada fora do círculo unitário (BOX; JENKINS, 1976).

Do mesmo modo que se pode generalizar as condições de estacionariedade dos modelos AR(1) para quaisquer modelos AR(p), as condições de invertibilidade dos modelos MA(1) são aplicáveis aos modelos MA(q), desde que o operador de médias móveis $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_p B^p$ também possua todas as suas raízes $\theta(B) = 0$ fora do círculo unitário.

- *Função de Autocorrelação (FAC) de um processo MA(q)*

A FAC de um processo MA(q) possui seguinte expressão

$$\rho_k = \frac{-\theta_k + \theta_1 \theta_{k+1} + \dots + \theta_{q-k} \theta_q}{1 + \theta_1^2 + \dots + \theta_q^2}, \text{ quando } k = 1, 2, \dots, q, \text{ e} \quad (13)$$

$$\rho_k = 0, \text{ quando } k > q.$$

Cabe notar a FAC de um processo MA(q) é nula para uma ordem superior a q . Isso significa, em outras palavras, que a FAC sofre um corte brusco após o *lag* q (BOX; JENKINS, 1976).

- *Estimativa dos Parâmetros de Médias Móveis em Função das Autocorrelações*

A média e a variância de um processo MA(q) podem ser estimadas a partir das observações da série temporal.

Se os coeficientes $\rho_1, \rho_2, \dots, \rho_p$ forem conhecidos, é possível solucionar q equações (13) e, assim, estimar os coeficientes de médias móveis $\theta_1, \theta_2, \dots, \theta_q$. Entretanto, ao contrário das equações lineares de *Yule-Walker*, apresentadas para a estimativa dos parâmetros auto-regressivos, as equações (13) não são lineares.

Consequentemente, substituindo sucessivamente as autocorrelações teóricas ρ_k pelas estimativas das autocorrelações amostrais $\hat{\rho}_k$ e resolvendo as equações (13) resultantes,

somente estimativas iniciais dos coeficientes $\theta_1, \theta_2, \dots, \theta_q$ podem ser obtidas, sem grande eficiência estatística. Embora imprecisas, essas estimativas iniciais são úteis na fase de identificação do modelo que melhor representa uma série temporal qualquer. Além disso, proporcionam valores de partida para o método iterativo da máxima verossimilhança, que será visto na seção 2.1.1.7 (BOX; JENKINS, 1976).

2.1.1.4 Modelos Mistos Auto-regressivos e de Médias Móveis

Os modelos auto-regressivos $AR(p)$ e os modelos de médias móveis $MA(q)$ podem ser combinados e, com isso, produzir um novo modelo designado por auto-regressivo e de médias móveis $ARMA(p, q)$ (MAKRIDAKIS *et al.*, 1998).

Apesar de os modelos puros $AR(p)$ e $MA(q)$ serem capazes de representar uma grande variedade de séries temporais, a combinação de ambos os termos conduz a um modelo mais parcimonioso (com menor número de parâmetros a serem estimados) do que se poderia obter com as formas puras. A parcimônia amplia as possibilidades de ajuste adequado de um modelo a muitas séries encontradas na prática (MORETTIN; TOLOI, 1985).

Os modelos $ARMA(p, q)$ são expressos genericamente por

$$\hat{Z}_t = \phi_1 \hat{Z}_{t-1} + \dots + \phi_p \hat{Z}_{t-p} - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} + a_t \quad (14)$$

ou

$$\phi(B)\hat{Z}_t = \theta(B)a_t, \quad (15)$$

onde $\phi(B)$ e $\theta(B)$ são os operadores auto-regressivo e de médias móveis, respectivamente, introduzidos anteriormente.

As condições de estacionariedade e invertibilidade estabelecidas para modelos $AR(p)$ e $MA(q)$ são inteiramente aplicáveis aos modelos $ARMA(p, q)$, de forma que o processo é estacionário se todas as raízes de $\phi(B)=0$ caírem fora do círculo unitário e invertível se todas as raízes de $\theta(B)=0$ estiverem fora do círculo unitário.

O modelo $ARMA(1,1)$, no qual $p = q = 1$, encontra aplicação frequentemente em situações reais, sendo descrito por

$$\hat{Z}_t = \phi_1 \hat{Z}_{t-1} - \theta_1 a_{t-1} + a_t. \quad (16)$$

Sua função de autocorrelação possui as formas

$$\rho_1 = \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 - 2\phi_1 \theta_1}$$

e

$$\rho_j = \phi_1 \rho_{j-1}, \text{ para } j > 1. \quad (17)$$

Nota-se que um termo de médias móveis aparece somente na determinação de ρ_1 ; as demais autocorrelações são afetadas unicamente pela parte auto-regressiva do modelo, conforme a equação (17).

2.1.1.5 Modelos para Séries Temporais Não Estacionárias

Os processos $AR(p)$, $MA(q)$ e $ARMA(p, q)$ são apropriados para a descrição de séries estacionárias, as quais são raramente encontradas em aplicações práticas na indústria ou na economia, como mencionado na seção 2.1.1.1.

Em função de seu caráter probabilístico, no entanto, as séries temporais necessitam ser estacionárias para que possam ser descritas por um modelo matemático capaz de gerar previsões satisfatórias (LAPA, 1998).

As séries industriais ou econômicas costumam exibir, independentemente das médias ou inclinações locais, alguma homogeneidade em seus comportamentos não estacionários, devido a fatores que se repetem.

Uma série temporal não estacionária homogênea pode se tornar estacionária, se reproduzida por um número finito de diferenças (d) entre suas próprias observações. Tal diferenciação é efetuada por meio do operador de translação ao passado B , tal que (TRENTIN, 2002)

$$BZ_t = Z_{t-1},$$

e, então,

$$\omega_t = Z_t - Z_{t-1} = (1 - B)Z_t = \nabla Z_t. \quad (18)$$

Quando a ordem de diferenciação é $d = 2$, tem-se

$$\omega_t = (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}) = Z_t - 2Z_{t-1} + Z_{t-2} = (1 - B)^2 Z_t = \nabla^2 Z_t$$

e, genericamente, tem-se

$$\omega_t = (1 - B)^d Z_t = \nabla^d Z_t, \quad (19)$$

que é estacionária e, por conseguinte, pode ser representada por um modelo ARMA(p, q), cuja forma é

$$\phi(B)\omega_t = \theta(B)a_t. \quad (20)$$

Se ω_t é uma diferença de Z_t , então Z_t constitui uma integração (ou soma) de ω_t . Dessa relação resulta que Z_t segue um modelo auto regressivo, integrado, de médias móveis, (ARIMA), dado por

$$\phi(B)(1 - B)^d Z_t = \theta(B)a_t, \quad (21)$$

ou

$$\phi(B)\nabla^d Z_t = \theta(B)a_t, \quad (22)$$

de ordem (p, d, q) , sendo que p e q são as ordens dos polinômios $\phi(B)$ e $\theta(B)$, respectivamente, e d é a ordem de diferenciação (MORETTIN; TOLOI, 1985).

Geralmente, uma série Z_t não estacionária somente em nível (Figura 5) adquire estacionariedade na média após uma diferenciação ($d = 1$). Uma série que apresente não estacionariedade em nível e inclinação (Figura 6) necessita de duas diferenciações para se tornar estacionária ($d = 2$). A nova série diferenciada d vezes pode, então, ser descrita por um modelo ARMA(p, q), estacionário e invertível.

Apesar disso, a estacionariedade nem sempre é alcançada somente por intermédio de diferenciações. Principalmente em séries econômicas, que se estendem por longos períodos e, normalmente, possuem forte tendência, se faz necessário efetuar uma transformação da série, a fim de estabilizar também a variância.

Uma transformação, nesse contexto, nada mais é do que a representação das variáveis de uma série em uma unidade diferente da original e pode ser obtida através da potência adequada λ (JOHNSON; WICHERN, 1982).

O parâmetro λ é proveniente da família de transformações de Box-Cox

$$Z_t^{(\lambda)} = \begin{cases} \frac{Z_t^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \log Z_t, & \lambda = 0 \end{cases}$$

onde λ é um parâmetro de transformação, tal que $\lambda = 1$ representa a série original, $\lambda = 0,5$ indica a raiz quadrada da série, $\lambda = 0$ indica o logaritmo natural da série, $\lambda = -0,5$ indica o inverso da raiz quadrada da série, $\lambda = -1$ representa o inverso da série, etc.

É possível realizar uma transformação apenas através da variação de λ entre -1 e 1 e posterior comparação entre a série original e as respectivas séries transformadas. Para determinação do valor ótimo de λ , porém, é mais conveniente aplicar o teste de Box-Cox, o qual estima o valor de λ que produz a menor soma dos quadrados dos resíduos da série analisada (LAPA, 1998).

2.1.1.6 Modelos Sazonais

Assim como as observações consecutivas de uma série temporal podem exibir propriedades relativas aos modelos AR, MA, ARMA ou ARIMA, observações equidistantes s intervalos de tempo podem apresentar as mesmas propriedades (MAKRIDAKIS *et al.*, 1998).

Considere, por exemplo, uma série temporal cujas características dos dados se repetem trimestralmente ao longo do ano. As diferenças sazonais, entre os quatro trimestres do ano, poderiam ser computadas por

$$Z'_t = Z_t - Z_{t-4} = (1 - B^4)Z_t.$$

A nova série Z'_t representaria as características comuns entre um trimestre e os trimestres precedentes, ou seja, descreveria como o primeiro trimestre de 2004 se relaciona com o primeiro trimestre de 2003, por exemplo.

Se os dados fossem coletados mensalmente, uma variação sazonal anual seria

$$Z'_t = Z_t - Z_{t-12} = (1 - B^{12})Z_t.$$

Chega-se, então, à expressão geral do operador de diferença sazonal

$$\nabla_s Z_t = Z_t - Z_{t-s} = (1 - B^s)Z_t \quad (23)$$

que corresponde à primeira diferenciação sazonal. Quando mais de uma diferenciação se faz necessária para tornar estacionária uma série, o operador de diferenciação sazonal assume uma ordem de diferenciação D , tal que

$$\nabla_s^D = (1 - B^s)^D, \quad (24)$$

o que conduz à formulação do modelo sazonal ARIMA (P, D, Q) , que estabelece a correlação entre os períodos sazonais

$$\Phi(B^s)\nabla_s^D Z_t = \Theta(B^s)\varepsilon_t, \quad (25)$$

no qual

$$\Phi(B^s) = 1 - \Phi_1 B^s - \dots - \Phi_p B^{ps}$$

e

$$\Theta(B^s) = 1 - \Theta_1 B^s - \dots - \Theta_q B^{qs}$$

são polinômios em B^s de ordens P e Q , respectivamente, que satisfazem as condições de estacionariedade e invertibilidade (BOX; JENKINS, 1976).

Um segundo modelo torna-se necessário para descrever a correlação dentro dos períodos sazonais. Esse novo modelo surge da constatação de que os erros ε não são estatisticamente independentes, ou seja, não formam uma série de ruído aleatório, pois $\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}$ são autocorrelacionados. Como o termo ε_t de ruído de entrada do modelo puramente sazonal não é aleatório, deve ser modelado por um ARIMA (p, d, q) simples, do que resulta

$$\phi(B)\nabla^d \varepsilon_t = \theta(B)a_t, \quad (26)$$

onde

$$\phi(B) = 1 - \phi_1(B) - \dots - \phi_p B^p$$

e

$$\theta(B) = 1 - \theta_1(B) - \dots - \theta_q B^q$$

são polinômios em B de ordens p e q , respectivamente, que satisfazem as condições de estacionariedade e invertibilidade.

Das equações (25) e (26) se obtém, portanto, a seguinte formulação geral do modelo ARIMA multiplicativo, para séries temporais que contêm correlação serial entre e dentro dos períodos sazonais

$$\Phi(B^s)\phi(B)\nabla_s^D \nabla^d Z_t = \Theta(B^s)\theta(B)a_t, \quad (27)$$

cuja notação é

$$\text{ARIMA}(p, d, q) \times (P, D, Q)_s.$$

2.1.1.7 Fases do Método Box-Jenkins

A construção dos modelos de Box-Jenkins depende da aplicação de um ciclo interativo constituído de três fases: (a) identificação do modelo ARIMA que melhor se ajusta aos dados históricos; (b) estimativa dos parâmetros do modelo identificado; e (c) verificação da adequação do modelo para fins de previsão. Essas fases são detalhadas na sequência.

a) Identificação do Modelo

O estágio de identificação tem por finalidade o reconhecimento da estrutura – AR(1), MA(2), ARMA(2,1), etc. – do processo estocástico que gerou uma determinada série temporal. A identificação do processo gerador é efetuada principalmente a partir da análise das autocorrelações (FAC) e autocorrelações parciais (FACP). Os gráficos amostrais da FAC e da FACP, denominados correlogramas, são comparados com os gráficos teóricos de cada estrutura, a fim de se descobrir qual modelo representa melhor a série.

A estacionariedade da série constitui pré-requisito para a identificação do modelo através dos correlogramas da FAC e FACP. Se a série é não estacionária, deve ser devidamente diferenciada e, se necessário, transformada, conforme seção 2.1.1.5, a fim de que o processo $\nabla^d Z_t$ seja reduzido a um processo ARMA(p, q) estacionário. Observações oscilando em torno de uma média constante e correlogramas da FAC e FACP decrescendo rapidamente para zero são indicadores de estacionariedade da série, conforme apresentado no Quadro 1.

Quadro 1: Comportamento da FAC e FACP teóricas para um processo ARMA (p, q) (adaptado de MORETTIN; TOLOI, 1985)

Ordens (p, q)	Comportamento da FAC (ρ_k)	Comportamento da FACP (ϕ_{kk})
ARMA(1,0) ou AR(1)	decaimento exponencial	somente $\phi_{11} \neq 0$
ARMA(0,1) ou MA(1)	somente $\rho_1 \neq 0$	decaimento exponencial predominante
ARMA(2,0) ou AR(2)	mistura de exponenciais ou ondas senoidais decrescentes	somente $\phi_{11} \neq 0$ e $\phi_{22} \neq 0$
ARMA(0,2) ou MA(2)	somente $\rho_1 \neq 0$ e $\rho_2 \neq 0$	predominância de exponenciais ou senóides decrescentes
ARMA(1,1)	decaimento exponencial após lag 1	predominância de decaimento exponencial após lag 1

A fase de identificação representa um dos maiores obstáculos à utilização do método Box-Jenkins, devido à grande variedade de modelos ARIMA passíveis de ajuste à determinada série temporal. Por conseguinte, outras propostas de identificação têm sido apresentadas na literatura.

Entre as formas alternativas de identificação mais utilizadas encontra-se o critério de informação de Akaike (*Akaike Information Criterion* – AIC), desenvolvido por Akaike (1973) para seleção do modelo cujas ordens p e q minimizam o critério

$$AIC(p, d, q) = n \log(\sigma_a^2) + \frac{2n(p+q+1+\delta_{d0})}{n-d} + n \log(2\pi) + n, \quad (28)$$

onde

$$\delta_{d0} = \begin{cases} 1, & d = 0 \\ 0, & d \neq 0 \end{cases}$$

e n é o número de observações da série.

Considerando que geralmente se identifica a série já adequadamente diferenciada e que n pode ser fixado, quando se compara vários modelos candidatos para a mesma série, obtém-se

$$AIC(p, d, q) = n \log(\sigma_a^2) + 2(p+q+2). \quad (29)$$

A lógica da minimização do critério de Akaike consiste em favorecer a parcimônia durante a seleção dos modelos candidatos, ou seja, em conferir primazia aos modelos capazes de se ajustarem à série contendo o menor número de parâmetros possível. Quando o modelo ajustado tem ordens pequenas para p e q e a série possui um número grande de observações, o AIC pode ser entendido como um estimador aproximadamente não viciado (CAVANAUGH, 1997).

b) Estimativa dos Parâmetros

Esta é a fase mais objetiva do método Box-Jenkins. Os parâmetros p e/ou q (e seus equivalentes sazonais P e/ou Q) são estimados por intermédio do procedimento de otimização não linear, baseado no método de descida desenvolvido por Marquardt (1963). Esse método de estimação não oferece dificuldades especiais, exceto pela sua incapacidade de garantir um ótimo global (um problema comum a todos os algoritmos não lineares) e pela ocorrência de problemas ocasionais, quando não existe convergência. A estimação é totalmente automática e não requer qualquer intervenção subjetiva, visto que todos os pacotes computacionais utilizam o mesmo algoritmo para aplicação do procedimento de otimização de Marquardt (MAKRIDAKIS; HIBON, 1997).

Uma vez que se tenha identificado um modelo ARIMA (p, d, d) provisório, na forma

$\phi(B)\omega_t = \theta(B)a_t$, com $\omega_t = \nabla^d Z_t$, admitindo que $d > 0$ e $\mu = 0$, ou seja, a estacionariedade da série, seus $p + q + 1$ parâmetros são incluídos no vetor

$$\underline{\xi} = [\underline{\phi}, \underline{\theta}, \sigma_a^2] = [\phi_1, \phi_2, \dots, \phi_p, \theta_1, \theta_2, \dots, \theta_p, \sigma_a^2],$$

o qual é estimado através do método da máxima verossimilhança, a partir da função de verossimilhança

$$L(\underline{\xi} | Z_1, Z_2, \dots, Z_N), \quad (30)$$

compreendida como um função de $\underline{\xi}$ para as observações Z_1, Z_2, \dots, Z_N . O estimador de máxima verossimilhança (EMV) de $\underline{\xi}$ será o valor que maximiza a função de verossimilhança na equação (30) ou seu logaritmo natural. Uma alternativa para estimação dos parâmetros nos

modelos Box-Jenkins utiliza a função soma dos quadrados não condicional, sendo detalhada em Box; Jenkins (1976, p. 504 – 505).

c) Verificação (Análise dos Resíduos)

A fase de verificação visa estabelecer o grau de adequação de um determinado modelo, previamente identificado e estimado, para fins de previsão. Somente um modelo que represente apropriadamente os dados pode ser empregado para a elaboração de previsões de valores futuros da série. Quando o ajuste é insuficiente, o ciclo iterativo do método deve ser repetido, de modo que um modelo alternativo possa ser identificado, estimado e verificado.

A principal forma de verificação consiste na análise dos resíduos (ou erros) do modelo em questão, definidos como a diferença entre os valores reais e aqueles estimados pelo modelo

$$e_t = Z_t - \hat{Z}_t. \quad (31)$$

Se os resíduos tendem para um processo de ruído aleatório, ou seja, formam uma série de choques aleatórios, o modelo é considerado apropriado (MAKRIDAKIS; HIBON, 1997). Nesse caso, a FAC amostral dos resíduos $r_k(\hat{\mathcal{E}}_t)$ deve possuir média aproximadamente igual a zero e variância inferior a n^{-1} em todos os *lags* do respectivo correlograma (n indica o número de observações da série).

Todavia, a variância de $r_k(\hat{\mathcal{E}}_t)$ pode ser muito inferior a n^{-1} nos primeiros *lags*, de modo que se torna arriscado afirmar que as autocorrelações dos resíduos são significativamente diferentes de zero nos *lags* iniciais. Assim, em vez de se proceder uma análise individualizada das autocorrelações residuais, é aconselhável testar a significância, por exemplo, das 20 primeiras autocorrelações em conjunto (MONTGOMERY *et al.*, 1990). Se o modelo possui ajuste satisfatório, a seguinte estatística (LJUNG; BOX, 1978), aplicada às k primeiras autocorrelações $r_k(\hat{\mathcal{E}}_t)$

$$Q = n(n+2) \sum_{k=1}^k (n-k)^{-1} r_k^2(e_t) \quad (32)$$

se aproxima de uma distribuição qui-quadrado (χ^2) com $k - p - q$ graus de liberdade, onde k representa a quantidade de autocorrelações residuais analisadas, p e q correspondem às ordens AR e MA do modelo a ser verificado.

Por outro lado, a hipótese de adequação do modelo deve ser rejeitada, quando Q exceder determinado valor de referência na tabela de pontos percentuais da distribuição qui-quadrado com $k - p - q$ graus de liberdade (BOX; JENKINS, 1976).

2.1.1.8 Previsões com Modelos ARIMA

O cumprimento das fases de identificação, estimação e verificação do método Box-Jenkins possibilita a construção de um modelo ARIMA apropriado para prever valores futuros da série temporal. A partir do período corrente t (origem da previsão) se pode prever um valor Z_{t+h} da série, onde $t+h$, com $h \geq 1$, representa um período futuro (horizonte da previsão).

A melhor previsão de Z_{t+h} é resultante da função de previsão denotada por $\hat{Z}_t(h)$, $h = 1, 2, \dots$, cujo objetivo é minimizar, para cada horizonte h , o erro quadrático médio esperado entre os valores reais e suas respectivas previsões, expresso por (BOX; JENKINS, 1976)

$$E \left[Z_{t+h} - \hat{Z}_t(h) \right]^2. \quad (33)$$

Admitindo-se que a série Z_t seja estacionária e μ seja a média do processo, a função de previsão assume a forma

$$\hat{Z}_t(h) = \delta + \phi_1 Z_{t+h-1} + \dots + \phi_p Z_{t+h-p} - \theta_1 a_{t+h-1} \dots - \theta_q a_{t+h-q} + a_t \quad (34)$$

onde δ é o termo constante da série, dado por

$$\delta = \mu(1 - \phi_1 - \phi_2 - \dots - \phi_p) \quad (35)$$

A previsão para o período $t+h$ depende de sucessivas previsões para os períodos $t+1, t+2, \dots, t+h-1$ (MONTGOMERY *et al.*, 1990), as quais são obtidas através de substituições dos termos da equação de previsão, conforme as seguintes regras:

- os termos Z_{t-h} ($h = 0, 1, 2, \dots$), ocorridos antes da origem t , permanecem inalterados;

- os termos Z_{t+h} ($h = 1, 2, \dots$) que ainda não ocorreram são substituídos por suas respectivas previsões $\hat{Z}_t(h)$, efetuadas na origem t ;
- os ruídos a_{t+h} , para instantes à frente da origem t , são considerados nulos;
- os ruídos passados a_{t-h} são obtidos de $Z_{t-h} - \hat{Z}_{t-h}$.

2.2 MÉTODOS DE SUAUIZAÇÃO EXPONENCIAL

Os métodos de suavização exponencial compreendem uma classe de modelos de previsão cuja principal suposição é que observações mais recentes da série oferecem informações mais confiáveis a respeito do que irá ocorrer no futuro. Desta forma, as observações mais recentes recebem pesos relativamente maiores, os quais decrescem exponencialmente à medida em que as observações se distanciam no passado.

Conforme o padrão de comportamento apresentado pela série (horizontal, com tendência ou sazonal), uma, duas ou três constantes de suavização devem ser respectivamente calculadas. Tais constantes servem como parâmetros para a determinação da proporção entre os pesos, de acordo com a relevância que se deseja atribuir às observações mais recentes em relação às mais antigas (MAKRIDAKIS *et al.*, 1998).

2.2.1 Suavização Exponencial Simples

Quando os dados da série são localmente constantes, ou seja, apresentam tendência insignificante, pode-se aplicar a suavização exponencial simples para gerar previsões. A ênfase colocada sobre as observações é controlada pela constante de suavização α , cujos valores variam entre 0 e 1 (ELSAYED; BOUCHER, 1994). Valores de α mais próximos de 1 indicam que maior relevância será dada às observações imediatamente anteriores e, portanto, que o modelo reagirá rapidamente frente a mudanças recentes no comportamento da série. Inversamente, se os valores de α são pequenos, o modelo demora a incorporar alterações no padrão dos dados, uma vez que as observações mais recentes são relativamente pouco relevantes (MONTGOMERY *et al.*, 1990).

Os pacotes computacionais empregam um procedimento iterativo para determinar o valor ótimo da constante de suavização. O valor ótimo de α é aquele que minimiza a média da soma do quadrado dos desvios entre as previsões e os valores reais. Em aplicações práticas, o valor de α permanece entre 0,01 e 0,3. Valores acima de 0,3 podem indicar que o modelo não está devidamente ajustado (ELSAYED; BOUCHER, 1994).

A representação matemática do modelo é dada pela equação

$$\hat{Z}_t = \alpha Z_t + (1 - \alpha) \hat{Z}_{t-1}, \quad (36)$$

que pode ser interpretada da seguinte forma: a previsão suavizada \hat{Z}_t é igual a uma fração α da última demanda observada Z_t , acrescida de uma fração $(1 - \alpha)$ da previsão da demanda gerada para o período anterior \hat{Z}_{t-1} . A média das últimas n observações, a observação anterior ou mesmo uma avaliação subjetiva podem fornecer o valor inicial de \hat{Z}_{t-1} .

2.2.2 Suavização Exponencial Dupla: Método Biparamétrico de Holt

A suavização exponencial dupla encontra aplicação satisfatória na previsão de valores futuros de processos que variam linearmente no tempo, ou seja, que apresentam tendência linear. O método de Holt permite a suavização direta dos valores da tendência, propiciando a flexibilidade de se usar constantes de suavização distintas para o nível e a tendência, que no instante t são estimadas através das equações (MAKRIDAKIS *et al.*, 1998)

$$\hat{Z}_t = \alpha Z_t + (1 - \alpha)(\hat{Z}_{t-1} + \mathbf{P}_{t-1}), \quad (37)$$

$$\mathbf{P}_t = \beta(\hat{Z}_t - \hat{Z}_{t-1}) + (1 - \beta)\mathbf{P}_{t-1}, \quad (38)$$

onde \hat{Z}_t e \mathbf{P}_t representam estimativas do nível e da declividade da série no instante t respectivamente, \mathbf{P}_{t-1} é a estimativa da declividade no instante $t-1$, Z_t é a observação mais recente, α indica a constante de suavização do nível e β a constante de suavização da tendência da série, ambas variando entre 0 e 1. A determinação dos valores α e β ótimos é feita mediante escolha do par que produza a menor soma do quadrado dos erros de previsão.

A previsão do valor Z_{t+h} , na origem t , para um horizonte h , é dada por

$$\hat{\mathbf{F}}_{t+h} = \hat{Z}_t + h\hat{\mathbf{F}}_t, \quad (39)$$

ou seja, a previsão é obtida pela adição do valor suavizado do nível da série a uma tendência suavizada, multiplicada pelo número de passos serem previstos (h).

Para iniciar o processo de suavização de Holt são necessárias estimativas do primeiro valor suavizado \hat{Z}_1 e da tendência $\hat{\mathbf{F}}_1$. A observação mais recente da série pode servir como nível inicial, de forma que $\hat{Z}_1 = Z_1$ e a tendência pode ser obtida pela diferença entre as duas últimas observações, ou seja, $\hat{\mathbf{F}}_1 = Z_2 - Z_1$.

2.2.3 Suavização Exponencial Tripla: Método de Holt-Winters

O método de Holt-Winters possui a propriedade de se adaptar às variações sazonais presentes em um conjunto de dados, cujo processo gerador assume a forma

$$Z_t = (\mu_t + T_t)S_t + a_t, \quad (40)$$

onde μ_t representa o nível da série, T_t é uma componente de tendência, S_t indica um fator sazonal multiplicativo e a_t é a parte estocástica do modelo. Os parâmetros μ_t , T_t e S_t são continuamente atualizados através das respectivas constantes de suavização α , β e γ , com valores entre 0 e 1, aplicadas à observação mais recente e à última previsão (ELSAYED; BOUCHER, 1994). No fim do período t , já tendo sido registrada a observação Z_t , a estimativa atualizada do nível da série é dada pela equação

$$\hat{Z}_t = \alpha \left(\frac{Z_t}{\hat{S}_{t-s}} \right) + (1-\alpha)(\hat{Z}_{t-1} + \hat{\mathbf{F}}_{t-1}), \quad (41)$$

na qual a observação mais recente Z_t é dividida pela previsão do fator sazonal para o instante t , gerada s períodos sazonais atrás, \hat{S}_{t-s} . Essa divisão é efetuada para que as flutuações sazonais da série possam ser eliminadas, preservando apenas os componentes do nível e da tendência (MAKRIDAKIS *et al.*, 1998). A equação de suavização da tendência é idêntica a equação (42) utilizada no modelo biparamétrico de Holt

$$\hat{\mathbf{F}}_t = \beta(\hat{Z}_t - \hat{Z}_{t-1}) + (1-\beta)\hat{\mathbf{F}}_{t-1} \quad (42)$$

e a equação para atualização do fator sazonal, que pondera a observação mais recente Z_t com γ e a previsão do fator sazonal S_{t-s} com $(1-\gamma)$, tem a forma

$$S_t = \gamma \left(\frac{Z_t}{\hat{Z}_t} \right) + (1-\gamma) S_{t-s}. \quad (43)$$

A previsão do valor Z_{t+h} , na origem t , para um horizonte h , é dada pelos últimos parâmetros atualizados

$$\hat{Z}_{t+h} = (\hat{Z}_t + hT_t) S_{t+h-s}. \quad (44)$$

A estimativa inicial da componente da tendência é obtida da média da demanda realizada nos dois últimos períodos completos (dois anos, por exemplo) (ELSAYED; BOUCHER, 1994)

$$T_1 = \frac{\bar{X}_2 - \bar{X}_1}{N}, \quad (45)$$

sendo que $\bar{X}_1 = \frac{\sum_{t=1}^N Z_t}{N}$ e $\bar{X}_2 = \frac{\sum_{t=N+1}^{2N} Z_t}{N}$.

A estimativa inicial do nível da série é obtida do nível calculado no final do período \bar{X}_2 e da tendência estimada T_1

$$\mu_{t,2N} = \bar{X}_2 + T_1 \frac{N-1}{2} \quad (46)$$

e os fatores sazonais são estimados pela razão entre as observações e a respectiva média no primeiro período

$$S_1 = \frac{Z_1}{\bar{X}_1}, \quad S_2 = \frac{Z_2}{\bar{X}_1}, \quad \dots, \quad S_N = \frac{Z_N}{\bar{X}_1} \quad (47)$$

2.3 MEDIDAS DE PRECISÃO E DESEMPENHO DOS MODELOS DE PREVISÃO

O desempenho de um modelo de *forecasting* pode ser mensurado pela diferença entre o valor observado da série em um instante t e a previsão para o mesmo instante, conforme equação (31). Quando são geradas previsões para n períodos adiante, haverá n

desvios (ou erros) entre os valores realizados e os previstos, os quais podem ser calculados em termos independentes ou relativos. As medidas independentes usuais são (MAKRIDAKIS *et al.*, 1998):

- Erro absoluto médio (MAE – *mean absolute error*) = $\sum_{t=1}^n \frac{|e_t|}{n}$, (48)

- Erro médio quadrático (MSE – *mean squared error*) = $\sum_{t=1}^n \frac{e_t^2}{n}$, e (49)

- Raiz do erro médio quadrático (RMSE – *root mean squared error*) = $\sqrt{\sum_{t=1}^n \frac{e_t^2}{n}}$. (50)

O MSE evidencia erros maiores. O RMSE expressa o erro de previsão na mesma unidade dos dados da série, o que torna mais fácil sua interpretação. Se os erros apresentam distribuição normal, o MAE corresponde a 80% da raiz quadrada do MSE, ou seja, $RMSE = 0,8 MAE$. Essa relação permite rápida migração de um indicador para outro (SANDERS, 1997).

CrITÉrios relativos possibilitam o estabelecimento de comparações coerentes entre diferentes séries ou intervalos temporais, uma vez que apresentam os erros em forma percentual e, portanto, estão livres das unidades de medida específicas de cada conjunto de dados. O critério relativo mais utilizado é o

- Erro percentual absoluto médio (MAPE – *mean absolute percentage error*) = $\sum_{t=1}^n \frac{|pe_t|}{n}$,

(51)

onde $pe_t = \left| \frac{(Z_t - \hat{Z}_t)}{Z_t} \right| \times 100$.

2.4 MÉTODOS DE *FORECASTING* QUALITATIVOS

São denominados qualitativos os métodos que propiciam a incorporação do julgamento humano ao processo de *forecasting*, mediante a interpretação sistemática de

informações não capturáveis pelos modelos estatísticos, como intenções de compradores e opiniões de especialistas. As técnicas qualitativas aplicadas com mais sucesso atualmente são a pesquisa de mercado, o consenso de executivos, a composição da força de vendas e o método Delphi (KRAJEWSKI; RITZMAN, 1999).

A *pesquisa de mercado* visa identificar o nível de interesse por um produto, com base na análise de intenções de compra obtidas diretamente dos prováveis compradores através de entrevistas estruturadas. Fundamenta-se na hipótese de que os consumidores são capazes de presumir seus próprios comportamentos futuros em relação à aquisição de determinados bens.

Quando aplicada para prever a demanda de bens duráveis, por exemplo, a técnica oferece bons resultados, uma vez que os consumidores tendem a planejar com certa antecedência a compra de produtos como eletrodomésticos, veículos ou imóveis (ARMSTRONG *et al.*, 2000). Contudo, a acurácia das previsões é fortemente afetada pela volubilidade da opinião dos consumidores, pois uma intenção manifesta pode não resultar em uma compra efetiva, ao passo que consumidores sem interesse prévio pelo produto podem mudar de opinião e eventualmente comprá-lo (LEE *et al.*, 1997).

O *consenso de executivos* constitui um método de *forecasting* no qual a opinião, o conhecimento técnico e a experiência de profissionais com poder decisório são sintetizados com o objetivo de gerar uma única previsão. O consenso de executivos é freqüentemente empregado para estimar o impacto provocado nas vendas por eventos promocionais ou outras circunstâncias especiais. As deficiências do método residem na dificuldade para obtenção de um consenso autêntico, quando conflitos de interesse emergem no grupo (KRAJEWSKI; RITZMAN, 1999).

Desvios ainda mais significativos podem surgir se a presença de indivíduos dominantes no grupo e a pressão pelo consenso conduzirem à formação de julgamentos sem uma suficiente troca de informações e pontos de vista. Problemas dessa natureza motivaram o desenvolvimento de técnicas de grupo estruturadas, como o método Delphi (GOODWIN, 2002).

A *composição da força de vendas* aproveita, para a elaboração de previsões de demanda, a perspicácia desenvolvida pelos profissionais de vendas, em função de sua inerente proximidade com os clientes finais. A principal desvantagem do método refere-se ao viés

incorporado às previsões pelo sistema de atribuição de cotas de vendas, que induz os vendedores a estimarem valores compatíveis com o cumprimento das metas individuais (LOPES, 2002).

O *método Delphi* é um método estruturado para correlacionar opiniões de especialistas e informações pertinentes a uma determinada área da estratégia empresarial, visando a prospecção de tendências futuras (McCOY, 2001). A abordagem Delphi fundamenta-se na suposição de que a conciliação do conhecimento, da experiência e da criatividade de um grupo de especialistas configura um julgamento coletivo, que proporciona previsões melhores do que as produzidas por um só indivíduo (WRIGHT; GIOVINAZZO, 2000).

O método Delphi, desenvolvido na década de 50 no âmbito da estratégia norte-americana de defesa militar, envolve um grupo de profissionais com reconhecida perícia na área de interesse para o processo de *forecasting*, os quais são convidados a responder uma série de questionários relacionados a uma classe similar de problemas. O objetivo final do exercício consiste em conduzir o grupo em direção a um consenso ou a uma clara polarização das opiniões, de forma que cenários alternativos possam ser identificados (TIDESWELL *et al.*, 2001).

Quatro características são consideradas essenciais para definir um processo de *forecasting* como “Delphi”: anonimato dos respondentes, iteração dos questionários, reavaliação das respostas do grupo e representação estatística da distribuição dos resultados.

O anonimato é alcançado mediante a aplicação de questionários, que conferem aos envolvidos a oportunidade de expressar suas opiniões e julgamentos confidencialmente, isentos de influências pessoais ou pressões exercidas pela maioria ou por indivíduos dominantes no grupo. A confidencialidade também elimina a resistência natural dos participantes em modificar pontos de vista já manifestados, pois evita o reconhecimento público de opiniões originalmente equivocadas. Isso possibilita a livre reavaliação das previsões anteriores, a qual é conduzida através da repetição dos questionários ao longo de diversas rodadas.

No intervalo entre as aplicações dos questionários, os membros do grupo são informados sobre a opinião de seus colegas anônimos. As respostas são analisadas e apresentadas sob a forma de um sumário estatístico, geralmente contendo os extremos, a

média, a mediana e os quartis superiores e inferiores das previsões individuais. Com base nessa análise estatística, os participantes devem supostamente ajustar suas próprias previsões ou fornecer argumentos para aquelas que permanecerem fora de limites previamente estabelecidos (ROWE; WRIGHT, 1999).

Após duas ou três rodadas, as previsões normalmente tendem para um ponto de equilíbrio, a partir do qual não apresentam mudanças significativas. Esse grau de convergência pode ser identificado através da análise dos quartis superiores e inferiores. A média ou mediana das respostas dessa última rodada representam o consenso do grupo em torno de uma única previsão (WRIGHT; GIOVINAZZO, 2000).

A concepção original do método exigia a convergência das previsões ou justificativas para as posições divergentes no final do processo. Com a evolução do Delphi, a obrigatoriedade do consenso foi questionada, contribuindo para o surgimento de variações, como o *Policy Delphi* (Delphi de Políticas), cujo foco principal são os pontos extremos e não as medidas de tendência central, o que permite considerar todas as opções possíveis e avaliar o impacto e a aceitabilidade de qualquer opinião em particular (KAYO; SECURATO, 1997).

Não obstante a ampla aplicação do Delphi há mais de três décadas, diversas questões conceituais e metodológicas permanecem obscuras, como a falta de critérios para avaliar o nível de especialização, a utilização de técnicas inadequadas de análise de resultados, a geração de consenso artificial, etc.

Ironicamente, algumas das vantagens do Delphi podem se converter em desvantagens. O anonimato, por exemplo, considerado o atributo mais importante do Delphi, uma vez que o diferencia dos demais métodos qualitativos, pode induzir a priorização de interesses pessoais em detrimento de um esforço espontâneo no sentido do consenso (GUPTA; CLARKE, 1994). Por conseguinte, o sucesso do método depende não apenas da competência técnica da equipe coordenadora, mas também da sua habilidade para granjear a cooperação irrestrita e imparcial de todos os participantes (ISMAIL; AHAMAD, 2003).

2.5 INTEGRAÇÃO DE MÉTODOS QUANTITATIVOS E QUALITATIVOS

Métodos quantitativos e qualitativos possuem vantagens e desvantagens específicas, se comparados entre si, pois agregam diferentes informações ao processo de *forecasting*.

Os métodos quantitativos são objetivos, podem processar uma vasta quantidade de dados simultaneamente, produzem as mesmas previsões para um mesmo conjunto de dados (SANDERS; RITZMAN, 2001) e, em muitas situações, são menos dispendiosos e proporcionam previsões mais acuradas do que aquelas obtidas através de métodos qualitativos (SANDERS; MANRODT, 1994).

Não obstante as virtudes atribuídas aos métodos quantitativos, os profissionais que elaboram previsões geralmente possuem informações antecipadas acerca de eventos que possam ocasionar mudanças no nível de uma determinada série temporal. Quando modelos estatísticos são empregados, essas discontinuidades estruturais confundem o processo de *forecasting*. Como esses modelos são baseados em um padrão histórico, são incapazes de incorporar e antecipar alterações para as quais não existe precedente histórico (WILLIAMS; MILLER, 1999).

Nesse contexto, a abordagem qualitativa é mais adequada, pois compreende técnicas de previsão de demanda por novos produtos ou em ambientes notoriamente instáveis, nos quais mudanças econômicas, políticas ou tecnológicas são freqüentes.

Visto que a probabilidade de ocorrência de oscilações conjunturais aumenta significativamente em função do horizonte de previsão, os métodos qualitativos são aplicados prioritariamente para prever alterações de cenário que possam interferir no padrão da demanda no longo prazo (LOPES, 2002).

Contudo, caso existam dados históricos de demanda e se deseje somente prevê-la para um horizonte de algumas semanas ou meses, no qual os indicadores econômicos, políticos ou tecnológicos tendam a permanecer relativamente estáveis, os resultados dos métodos qualitativos revelam maior utilidade se associados às previsões originadas por modelos de séries temporais (O'CONNOR *et al.*, 1993).

Haja vista os pontos fortes e fracos presentes nos métodos quantitativos e qualitativos, uma das mais importantes contribuições para o aperfeiçoamento dos processos de

forecasting ocorreu há aproximadamente trinta anos, quando os pesquisadores comprovaram que a integração de diferentes técnicas de *forecasting* aumenta a qualidade das previsões (GEURTS; WHITLARK, 2000). Existem duas formas de integração de técnicas de *forecasting*: o *ajuste* qualitativo e a *combinação* matemática (GOODWIN, 2002).

A primeira forma de integração de técnicas de *forecasting* consiste em utilizar o julgamento qualitativo, representado por opiniões de especialistas ou pesquisas de mercado, como parâmetro de ajuste das previsões resultantes de um modelo estatístico (GOODWIN; WRIGHT, 1993). O propósito dos ajustes é compensar influências de eventos específicos sobre o comportamento da demanda, provocadas, por exemplo, por uma greve de operários ou campanhas publicitárias. Todavia, a aplicação de ajustes proporciona maior acurácia às previsões somente se conduzida por profissionais experientes, com profundo conhecimento do contexto empresarial, e através de um método estruturado, que contenha procedimentos formais de análise qualitativa e ferramentas de suporte à decisão (SANDERS; RITZMAN, 2001).

Williams & Miller (1999) propuseram uma técnica de aplicação de ajustes sobre previsões quantitativas, que permite incorporar ao modelo de previsão estimativas de mudanças no nível da série, decorrentes de eventos especiais planejados. No modelo proposto, a previsão do valor Z_{t+h} , na origem t , para um horizonte h , assume a forma

$$\hat{Z}_{t+h} = \hat{Z}_t + h\hat{P}_t + (P_{t+h} - P_t). \quad (52)$$

Esse modelo difere do modelo de suavização exponencial de Holt apenas pela inclusão, na equação de previsão para um horizonte h , do termo $(P_{t+h} - P_t)$, que representa um fator de ajuste A_{t+h} , definido pela diferença entre a estimativa de mudança no nível da série no instante $t+h$, P_{t+h} , e o efeito cumulativo da política de ajustes até o instante t , P_t .

Simulações demonstraram que a técnica proposta fornece previsões mais acuradas do as abordagens alternativas, além de não requerer, no que se refere às mudanças no nível da série, a existência de precedente histórico. Uma vez que a estimativa de mudança já está incluída no modelo estatístico, nenhuma manutenção manual da série de eventos especiais se faz necessária. Outras vantagens referem-se à capacidade de se detectar quando uma

mudança de nível não ocorreu como planejada e à facilidade para correção das políticas de ajustes.

O emprego de um modelo formal de decomposição de temas gerais em uma série de tópicos menores, a fim de que o analista possa se concentrar em aspectos particulares do problema separadamente e apontar justificativas específicas para cada ajuste efetuado, também pode contribuir para estruturar o julgamento e oferecer maior credibilidade ao processo de ajuste (GOODWIN, 2002).

Na prática, porém, os previsores costumam confiar apenas na própria intuição para ajustar previsões quantitativas, sem se valerem de bases formais, de documentação adequada ou de argumentos que justifiquem suas intervenções subjetivas no modelo estatístico. Essa abordagem *ad hoc* dificulta a revisão e a manutenção do processo de *forecasting* e conduz à redução da acurácia das previsões (WILLIAMS; MILLER, 1999).

Em pesquisa realizada com 96 companhias norte-americanas, 45% dos entrevistados afirmaram que sempre ajustam, com base em seus julgamentos informais, as previsões provenientes do *forecasting* quantitativo e somente 9% admitiram que jamais procedem tais ajustes (SANDERS; RITZMAN, 2001).

Com efeito, o ajuste qualitativo de previsões estatísticas é o caminho menos efetivo para integrar técnicas de *forecasting*. Para muitos profissionais, a segunda forma de integração, a combinação matemática das previsões quantitativas e qualitativas, é uma opção realística que proporciona melhores resultados, pois permite aproveitar as vantagens e atenuar os desvios inerentes a cada método (SANDERS; RITZMAN, 2001).

A combinação matemática geralmente implica tomar a média aritmética simples entre as previsões qualitativas e quantitativas individuais. A alternativa de atribuir pesos inversamente proporcionais aos erros de previsão, ou seja, de conferir pesos maiores às previsões que produziram o menor erro e calcular uma média ponderada pode ser inapropriada, em função da dependência dessa abordagem da medida de erro empregada. Visto que a literatura não trata nenhuma medida como ideal para todas as situações, a definição dos pesos deve levar em conta o desempenho acumulado dos erros gerados por medidas distintas, como MSE e MAPE, por exemplo, a fim de se evitar conclusões equivocadas (ARMSTRONG, 2001). Além disso, uma adequada otimização matemática dos pesos requer previsões originalmente constituídas sem vieses, com comportamento

estacionário dos erros de previsão e suficiente quantidade de dados históricos, condições geralmente não encontradas em situações reais (GOODWIN, 2002).

Um fator que influencia significativamente o valor da previsão gerada por combinação é a correlação entre os erros das previsões originais. Se a média simples for aplicada, pode-se demonstrar que o erro médio quadrático (MSE) da previsão combinada será menor do que os erros apresentados pelas previsões originais individualmente somente se (GOODWIN, 2002)

$$\frac{\sigma_j}{\sigma_s} > \frac{r + (r^2 + 3)^{1/2}}{3} = \Phi, \quad (53)$$

onde σ_j^2 e σ_s^2 são, respectivamente, as variâncias dos erros das previsões qualitativas e quantitativas e r representa a correlação entre esses erros. A equação acima indica que a combinação é mais eficaz quando a correlação entre os erros de previsão é fraca. De fato, a situação ideal é que existam apenas correlações negativas entre os erros, de forma que possam se anular mutuamente. Muito embora isso raramente aconteça na prática, em 30 comparações empíricas, a redução dos erros das previsões obtidas por combinação alcançou 12% em média, com limites entre 3% e 24% (ARMSTRONG, 2001).

A combinação matemática produz previsões melhores do que as obtidas por seus mais acurados componentes individualmente quando (ARMSTRONG, 2001):

- as previsões originais derivam de métodos e fontes de informação substancialmente diferentes;
- análises quantitativas são aplicadas sobre as previsões originais somente através de um procedimento formal que possa ser replicado;
- as previsões originais recebem pesos iguais no processo de combinação e pesos diferentes são atribuídos somente se existir forte evidência de que um método em particular se mostrou mais acurado em testes empíricos ou foi afetado por causas especiais.

2.6 APLICAÇÕES DE *FORECASTING* NA INDÚSTRIA AUTOMOBILÍSTICA

Herz *et al.* (2001) descreveram como um projeto de reestruturação da cadeia de distribuição, conduzido pela *Volvo Car Company* na Suécia, resultou no envolvimento de suas concessionárias, localizadas em diversos pontos da Europa, na previsão da demanda de veículos novos para os respectivos mercados locais.

Muito embora a produção, a princípio, não pudesse ser iniciada sem um pedido firme, a empresa percebeu que a redução do tempo de entrega dependia da antecipação das necessidades dos clientes na extremidade da cadeia, a fim de preparar a manufatura de acordo com as exigências do mercado.

O conhecimento dos mercados locais e o suporte das concessionárias tornou-se crucial no novo processo de *forecasting* implementado, visto que as previsões das concessionárias passaram a suprir diretamente o planejamento de produção, o cálculo de necessidade de materiais e os processos de compras da montadora.

A extrapolação da série histórica das vendas em cada concessionária, por meio de métodos quantitativos de *forecasting*, formou a base do processo de previsão nos mercados locais. Semanalmente, informações relativas ao mix de ordens firmadas localmente eram comparadas às previsões, de modo que um sinal de advertência (*tracking signal*) indicativo da qualidade do processo de *forecasting* pudesse ser desenvolvido. A substituição das previsões pelos pedidos firmados na semana mais recente dava início a um novo período de revisão do processo de *forecasting*.

Através da aplicação da técnica de modelagem dinâmica, Lapa (1998) desenvolveu modelos econométricos para a previsão da demanda de veículos novos no mercado brasileiro no curto prazo, utilizando séries temporais das vendas mensais compreendidas entre janeiro de 1985 e junho de 1995. Como ponto de partida, Lapa considerou a hipótese geral de que os melhores modelos para a previsão da demanda brasileira de automóveis poderiam ser determinados pelo método proposto no trabalho.

As variáveis incluídas nos modelos foram: vendas internas e produção nacional de automóveis, exportações de automóveis fabricados no Brasil, preço de venda dos automóveis no mercado interno, renda mensal dos consumidores, taxas de juros de

financiamentos, taxa de câmbio, greves de metalúrgicos e variáveis *dummy* representativas da sazonalidade e relacionadas aos planos econômicos deflagrados durante o período da pesquisa.

A formulação dos modelos ocorreu do amplo para o restrito, ou seja, partiu-se das equações mais completas, com todas as variáveis selecionadas, até os modelos mais parcimoniosos, obtidos através da retirada dos coeficientes com menor significância. Dentre os modelos desenvolvidos, as estatísticas apontaram os que incluíam as vendas, a produção e o preço dos automóveis como os melhores para previsões de demanda no curto prazo.

Lopes (2002) estudou o comportamento da demanda de 151 autopeças, agregadas em 10 categorias, em uma concessionária de veículos da marca *Volkswagen*, com o intuito de determinar o modelo quantitativo mais adequado para gerar previsões. No estudo de caso, modelos de médias móveis com 3, 6, 9 e 12 elementos e de suavização exponencial simples, dupla e de Holt-Winters foram utilizados para extrapolar as séries de vendas mensais das 10 categorias de autopeças entre janeiro de 1996 e dezembro de 2001.

O critério de seleção do modelo com maior grau de acurácia foi o erro percentual absoluto médio (MAPE). Os modelos de suavização exponencial mostraram-se mais precisos em 7 categorias. Os valores do MAPE variaram entre 11,83% e 55,78%, sendo que em 4 categorias os modelos produziram previsões potencialmente boas.

Pinto Filho (2000) desenvolveu pesquisa relacionada à previsão de demanda de veículos novos em um segmento constituído por onze concessionárias de veículos nacionais e dez concessionárias de veículos importados, distribuídas nos cinco municípios que formam a Grande Vitória, no Espírito Santo. O trabalho foi dividido em uma fase inicial de pesquisa exploratória descritiva e uma segunda fase de coleta de dados históricos para simulações de métodos quantitativos de previsão. O estudo pretendeu investigar os processos de previsão de vendas de veículos novos adotados nas revendedoras da Grande Vitória e identificar métodos quantitativos adequados para o segmento.

Para orientar a pesquisa, o autor formulou hipóteses a respeito do comportamento gerencial nas empresas do segmento. Antes de qualquer investigação científica, o autor tentou imaginar como estariam configurados os procedimentos de previsão de vendas nas concessionárias. Para tanto, quatro suposições orientadoras da pesquisa foram definidas:

S1 – Os responsáveis pelo processo decisório desconhecem os métodos de previsão de vendas abordados na literatura especializada;

S2 – Existem métodos estruturados que são adotados pelas revendedoras de veículos e que diferem significativamente entre as empresas do mesmo segmento;

S3 – Existe adequação entre os métodos teóricos abordados e as práticas gerenciais adotadas;

S4 – Na literatura especializada, há um método quantitativo de previsão de vendas com melhor acuidade para o segmento e que não é utilizado pelos previsores.

A fase de pesquisa exploratória teve por objetivo compreender como se processa a elaboração de previsões de vendas de veículos novos nas concessionárias de veículos da Grande Vitória e, por conseguinte, obter respostas para as suposições S1, S2 e S3. O procedimento empregado nessa primeira fase consistiu de entrevistas com os gerentes de vendas, com o intuito de se obter dados referentes ao processo de previsão de vendas em uso nas concessionárias.

A análise dos dados obtidos nas entrevistas apontou os seguintes resultados:

- 100% dos gerentes de vendas e vendedores entrevistados jamais haviam participado de treinamentos sobre técnicas de previsão de vendas e desconheciam os métodos de previsão quantitativos e qualitativos descritos na literatura, o que confirmou a suposição S1;
- em relação à suposição S2, 80% das concessionárias elaboravam previsões de vendas de forma sistemática; os métodos adotados, porém, não diferiam entre si. Com exceção de uma concessionária, na qual havia um departamento dedicado exclusivamente à área de *marketing* e que, portanto, utilizava “pesquisas de mercado”, todas as demais empregavam unicamente do método da “composição da força de vendas” para elaborar previsões;
- método da composição da força de vendas foi adaptado ao modelo de gestão de demanda praticado, conforme suposição S3. Em 80% dos casos, o processo de previsão de vendas estava sob a responsabilidade direta dos gerentes de vendas, os quais transformavam as cotas negociadas com as respectivas montadoras em metas individuais de vendas para os vendedores. Os vendedores elaboravam previsões de vendas relacionadas à probabilidade de cumprimento daquelas metas previamente estipuladas.

Na segunda fase, testes empíricos foram conduzidos, a fim de se identificar um método qualitativo de previsão que pudesse comprovar a suposição S4. Para a realização dos testes, quatro revendedoras foram selecionadas, dentre aquelas com dados históricos de vendas

disponíveis, representativas das quatro grandes montadoras de veículos do país: *Fiat*, *Ford*, *General Motors* e *Volkswagen*.

Primeiramente, os dados obtidos nas quatro revendedoras foram organizados em uma planilha contendo 42 meses de vendas passadas, compreendidas entre janeiro de 1997 e junho de 2000. No segundo passo, os dados foram dispostos em gráficos de linha. O eixo vertical representou o comportamento histórico das vendas e o horizontal, os períodos. O período básico definido foi o ano; o mês foi considerado um sub-período. Esses gráficos sofreram análise visual, com o objetivo de identificar pontos espúrios e verificar a existência de tendência e sazonalidade.

A seguir, os métodos que seriam utilizados para gerar previsões foram definidos: previsão ingênua, decomposição clássica, média simples, média móvel com 3, 6, 9 e 12 elementos, suavização exponencial simples e dupla, regressão linear simples, quadrática e cúbica, regressão múltipla e combinações de modelos ARIMA com até 2 parâmetros e/ou 2 diferenciações.

Após a elaboração das previsões, os métodos foram classificados conforme o desempenho individual em cada concessionária, avaliado pelo erro percentual absoluto médio (MAPE). Na concessionária da *Fiat*, o método de regressão linear múltipla apresentou o menor erro de previsão. Os modelos ARIMA (1,0,1) e (1,1,1) produziram as previsões mais acuradas nas vendas da *Ford* e da *Volkswagen*, respectivamente. A média móvel com 3 elementos resultou em menor erro na venda da *General Motors*.

Em relação a suposição S4, o autor concluiu que o método de regressão linear múltipla apresentou o melhor desempenho, quando considerado o segmento, ou seja, o somatório das vendas realizadas pelas quatro concessionárias pesquisadas. O erro percentual absoluto médio registrado para o segmento foi de 6%. As variáveis independentes utilizadas foram o CUB (custo médio da construção civil) e o preço médio mensal da saca de café. Pinto Filho (2000) considerou que o CUB refletiu os índices inflacionários da região de Vitória e a cotação do café representou adequadamente a flutuação cambial durante o período do estudo. O autor, porém, sugeriu que outras variáveis fossem incluídas no modelo em trabalhos futuros, como fidelidade do cliente à marca, verbas destinadas a propaganda, renda per capita na região, etc.

3 MÉTODO PROPOSTO

O fluxograma da Figura 7 ilustra o método proposto para elaboração de previsões de demanda de veículos novos em concessionárias.

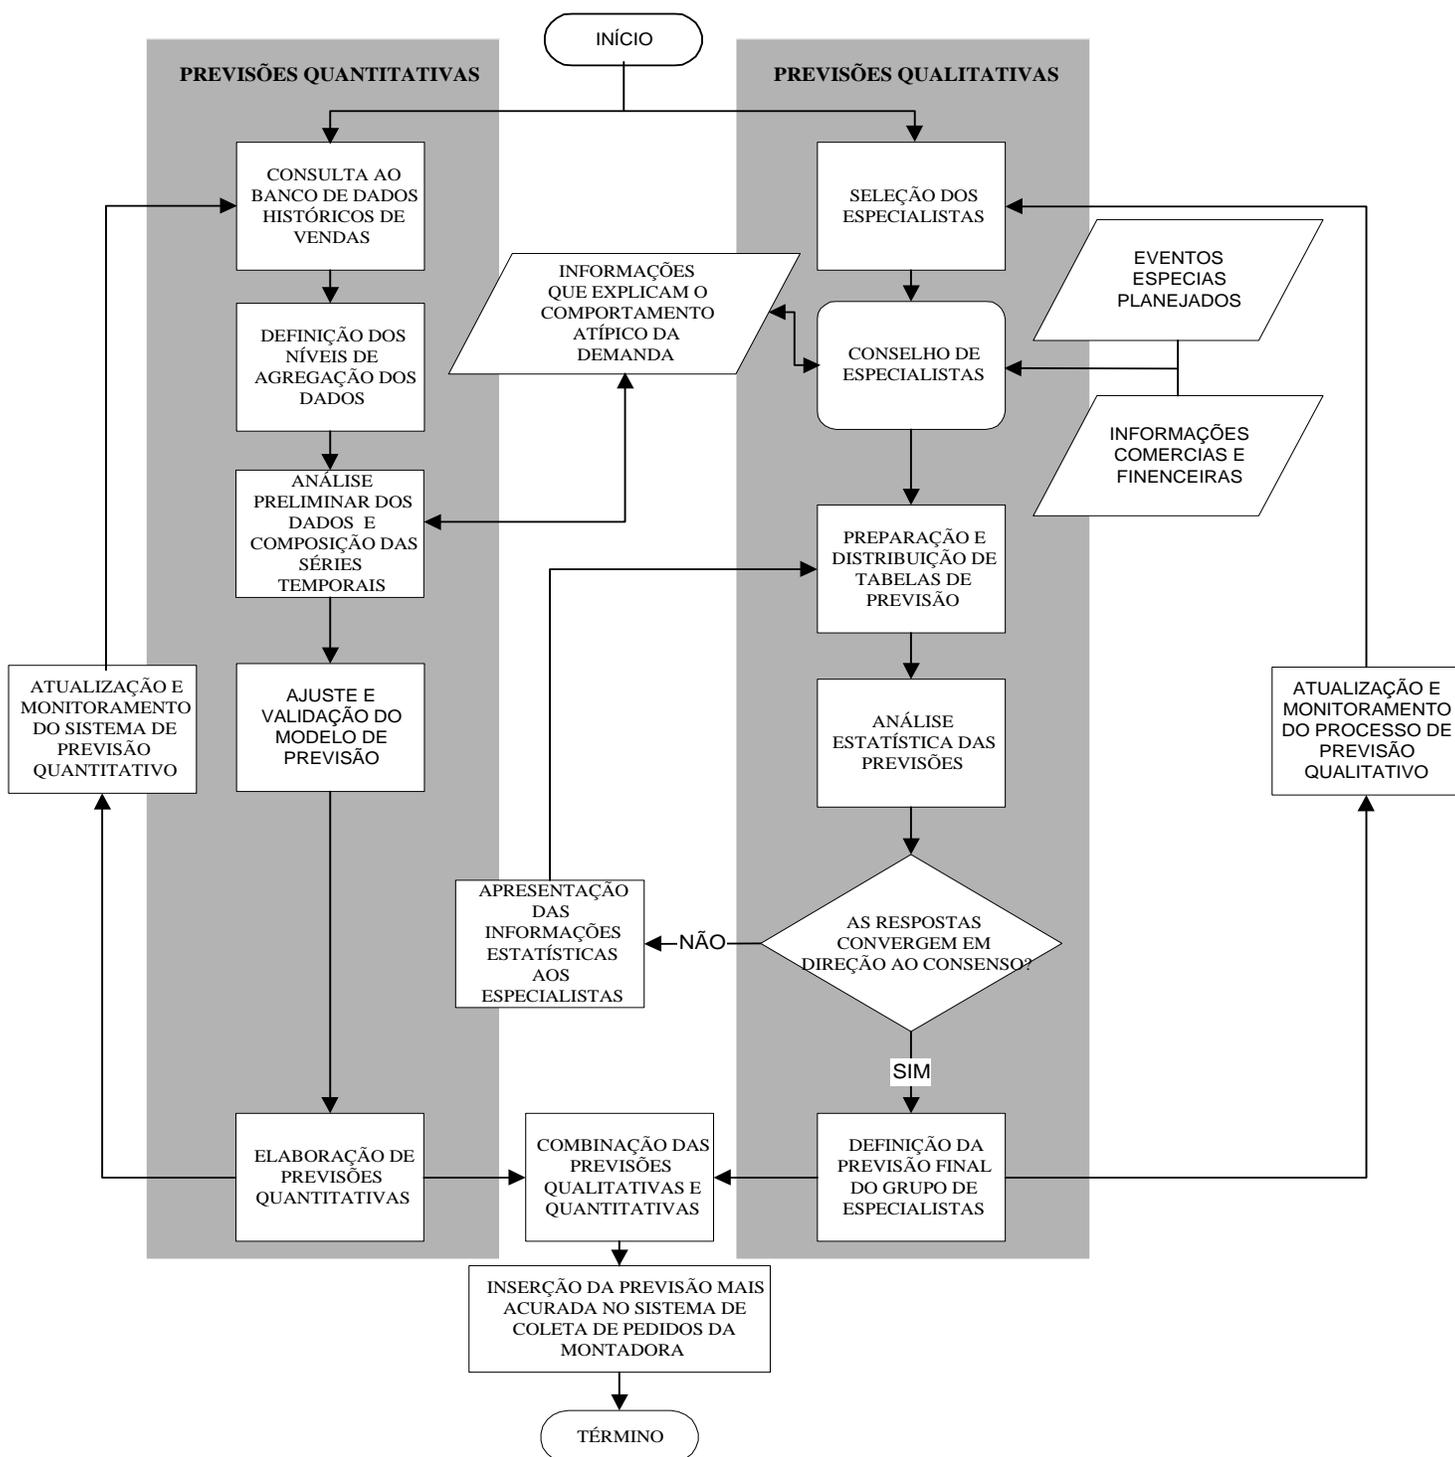


Figura 7: Fluxograma do método proposto

3.1 PREVISÕES QUANTITATIVAS

3.1.1 Consulta ao Banco de Dados Históricos de Vendas

Os dados históricos de vendas devem estar consolidados em um banco de dados relacional, disponível para acesso a qualquer tempo e atualizado a cada período semanal mediante incorporação das informações das vendas mais recentes. As consultas ao banco de dados servem de base para a formação das séries temporais utilizadas na previsão de vendas e devem conter os seguintes campos: data da venda ao consumidor final, classe, modelo e ano modelo do veículo novo vendido.

Para efeito de composição das séries históricas de vendas, a data de consecução da venda ao consumidor final corresponde à data de emissão da respectiva nota fiscal. A classe e o modelo referem-se aos atributos que distinguem os veículos entre si. Uma classe pode conter diversos modelos. A informação do ano modelo assinala os pontos de mudança nos modelos ou classes.

3.1.2 Definição dos Níveis de Agregação dos Dados Históricos de Vendas

A agregação temporal dos dados históricos de vendas das concessionárias é orientada pelo sistema de administração de pedidos da respectiva montadora. Sugere-se que dados de vendas registrados diariamente sejam agregados em períodos semanais.

Quando o volume de vendas semanais de um determinado modelo é pequeno ou irregular, o conjunto de dados apresenta um número elevado de lacunas, ou seja, de valores iguais a zero. Isso dificulta o ajuste de modelos matemáticos aos dados e compromete a acurácia das previsões. Se isso ocorrer, os modelos pertencentes à mesma classe devem ser agregados e as previsões de demanda elaboradas somente para a classe.

Mesmo após a agregação dos modelos nas respectivas classes, os volumes ainda podem ser insuficientes para que comportamento da demanda seja adequadamente capturado por um modelo de previsão. Seguindo o mesmo critério, as classes com menor volume podem se agregadas para a geração de uma previsão agregada.

3.1.3 Análise Preliminar dos Dados e Composição das Séries Temporais

Os dados históricos de vendas, agregados em classes de veículos e em períodos semanais, são representados graficamente, a fim de que valores ainda faltantes ou espúrios possam ser visualizados.

Os valores faltantes em cada conjunto de dados, ou seja, os valores de vendas iguais a zero são substituídos pelas previsões para os mesmos instantes, fornecidas por um modelo temporariamente ajustado aos dados em questão.

Os mesmos modelos provisórios informam os resíduos entre as previsões e os dados históricos. A presença de valores espúrios nos conjuntos de dados é indicada pelos resíduos localizados fora dos limites de três desvios padrão acima ou abaixo da média.

Uma vez identificado um valor espúrio, procede-se uma análise subjetiva do próprio valor espúrio e dos valores adjacentes, com o intuito de determinar as causas especiais que motivaram seu aparecimento. Essa análise pode ser realizada pelos profissionais mais experientes no ramo e com acesso a informações conjunturais que possam explicar o comportamento atípico da demanda. Com base nessas informações, os valores espúrios podem ser removidos ou substituídos pelos valores preditos pelos modelos provisórios.

Os dados históricos assim analisados permitem a composição de séries temporais das vendas semanais de cada classe de veículo comercializada pela concessionária.

3.1.4 Ajuste e Validação dos Modelos de Previsão

Às séries de vendas semanais de cada classe de veículo ajustam-se modelos de previsão por meio de pacote computacional estatístico que contenha ferramentas para análise de séries temporais e geração de previsões.

O modelo de previsão apropriado para cada série é identificado pela precisão do modelo, calculada, por exemplo, pelo do erro médio quadrático (MSE) ou erro percentual absoluto médio (MAPE) das previsões. A identificação de modelos de Box-Jenkins (ARIMA) também pode ser efetuada através da análise dos gráficos das autocorrelações (FAC) e autocorrelações parciais (FACP), e pelo nível de complexidade dos respectivos parâmetros, aferido pelo critério de informação de Akaike (AIC).

A adequação do modelo ainda pode ser validada pela análise das autocorrelações (FAC) dos erros das previsões. Erros não correlacionados, formando uma série de choques aleatórios, indicam que o modelo é apropriado para gerar previsões.

3.1.5 Elaboração das Previsões Quantitativas

Quando a unidade básica de tempo utilizada pelas montadoras de veículos para a programação da produção e o cálculo de necessidades de materiais é a semana, os pedidos das concessionárias também são coletados semanalmente. A disponibilização dos recursos de manufatura necessários para atender às oscilações na demanda deve ser providenciada com antecedência. Em função disso, as montadoras normalmente determinam que as concessionárias lhe informem suas próprias previsões de vendas várias semanas antes da produção do veículo.

Portanto, uma vez ajustado e validado um modelo para cada série temporal, a concessionária deve utilizá-lo para elaborar previsões de vendas para o horizonte definido pela respectiva montadora.

3.1.6 Atualização e Monitoramento do Sistema de Previsão Quantitativo

O intervalo de previsão, ou seja, a frequência com que novas previsões são preparadas deve coincidir com o período da previsão. Após a cada período, as vendas realizadas são incorporadas ao banco de dados históricos e, conseqüentemente, incluídas na séries originais.

O desempenho do sistema de previsão quantitativo é monitorado pela análise do comportamento cumulativo dos erros de previsão. O modelo de previsão adequadamente ajustado produz erros aleatórios, com valores positivos e negativos, cuja soma deve tender a zero. Caso os erros permaneçam sistematicamente acima ou abaixo de zero, é provável que as previsões estejam enviesadas e o modelo deve ser revisto.

3.2 PREVISÕES QUALITATIVAS

Previsões qualitativas da demanda de veículos novos podem ser elaboradas através do método Delphi, cujo procedimento de aplicação é composto pelos passos apresentados a seguir.

3.2.1 Seleção dos Especialistas

Aplicação do método Delphi deve ser conduzida por um coordenador. O coordenador deve, primeiramente, convidar profissionais experientes no ramo de concessionárias de veículos para participarem do processo Delphi. Os profissionais selecionados formam o grupo de especialistas responsável pela elaboração das previsões de vendas.

O grupo de especialistas de uma concessionária de veículos pode ser constituído pelos seguintes profissionais: diretor de vendas, gerente de vendas, vendedores mais experientes ou que possuam a maior carteira de clientes, analista de vendas responsável pela inserção das previsões no sistema de coleta de pedidos da montadora.

É desejável que o grupo de especialistas conheça ou disponha de livre acesso a informações sobre variáveis que influenciaram ou possam influenciar o comportamento da demanda, tais como: eventos especiais, como campanhas publicitárias ou promocionais, estoque de veículos novos, cotas de vendas e situação financeira da concessionária, conjuntura econômica, situação do mercado automobilístico e dos concorrentes, opiniões dos clientes.

Tais informações devem ser transmitidas pelos especialistas aos profissionais que elaboram as previsões quantitativas e que se encontram na fase de análise dos dados e composição das séries temporais de vendas, uma vez que podem representar a origem dos valores espúrios eventualmente encontrados nos dados históricos.

3.2.2 Preparação e Distribuição de Tabelas de Previsão

O coordenador envia a cada especialista uma tabela na qual as colunas indicam as classes de veículos e as linhas, o horizonte desejado de previsão. Em virtude do

conhecimento das informações relativas às variáveis de influência sobre a demanda e da experiência pessoal, os especialistas são convidados a completar a tabela com suas previsões de vendas de cada classe de veículo para os próximos períodos. Quando julgarem necessário, os especialistas ainda podem inserir, em espaços reservados para esse fim, comentários que fundamentem suas previsões. Essa é a primeira rodada do processo Delphi.

3.2.3 Análise Estatística e Apresentação das Informações aos Especialistas

Na etapa de análise estatística, o coordenador procede o cálculo da média, mediana e medidas de dispersão, como valores extremos, quartis superiores e inferiores e desvio padrão das previsões, assim como estabelece pontos de convergência ou conflito entre os comentários fornecidos pelos especialistas na primeira rodada.

Se a análise indicar que as previsões ainda não atingiram um grau satisfatório de convergência, as medidas estatísticas referentes à primeira rodada são apresentadas a cada especialista, juntamente com um resumo dos comentários dos demais participantes. Solicita-se, então, que cada especialista revise suas previsões à luz das novas informações ou aponte justificativas para posições destoantes. Essa é a segunda rodada do processo Delphi.

3.2.4 Definição da Previsão Final do Grupo de Especialistas

Esse processo de revisão é considerado concluído na rodada em que as previsões apresentarem certo grau convergência e estabilidade, o qual pode ser identificado pela redução na variância e análise dos quartis superiores e inferiores das previsões.

Para evitar distorções provocadas pelos valores extremos, é preferível utilizar o valor central das previsões (a mediana) dessa última rodada como previsão final, representativa do consenso entre especialistas.

3.2.5 Atualização e Monitoramento do Processo de Previsão Qualitativo

As previsões qualitativas são igualmente elaboradas semanalmente. Informações novas e relevantes para o processo de previsão, assim como as previsões

qualitativas para o período precedente, devem ser registradas para posterior apresentação ao grupo de especialistas, que pode ser constituído pelos mesmos membros ou agregar outros profissionais, a critério do coordenador do processo.

Assim como no sistema de previsão quantitativo, o desempenho do processo de previsão qualitativo é dado pelos erros de previsão. Erros sistemáticos em determinado sentido, positivo ou negativo, são indícios de que algum viés foi incorporado às previsões. Deve-se investigar a causa do problema e corrigir o processo.

3.3 COMBINAÇÃO DAS PREVISÕES QUANTITATIVAS E QUALITATIVAS

Se nenhum método de previsão em particular esteve sujeito a causas especiais que tenham afetado significativamente sua acurácia, as previsões originais recebem pesos iguais. Nesse caso, o processo de combinação matemática de previsões obtidas pelos modelos quantitativos e pela abordagem qualitativa consiste no cálculo da média aritmética simples entre as previsões individuais.

Quando mudanças no comportamento da série temporal, provocadas por causas especiais, ou o impacto de eventos programados sobre a demanda futura puderem ser mensurados, é possível combinar as previsões através de média aritmética ponderada, atribuindo um peso proporcionalmente maior às previsões qualitativas.

3.4 INSERÇÃO DA PREVISÃO MAIS ACURADA NO SISTEMA DA MONTADORA

A acurácia das previsões quantitativas, qualitativas e das previsões geradas pela combinação de ambas é medida pelo respectivo erro médio quadrático (MSE).

A inserção das previsões mais acuradas para cada classe de veículo e para o horizonte de previsão no sistema de coleta de pedidos da montadora encerra o ciclo semanal de *forecasting* da concessionária.

4 ESTUDO DE CASO

O presente estudo de caso foi conduzido em uma concessionária de veículos da marca *Volkswagen* com sede em Curitiba – PR. As atividades comerciais da empresa englobam a venda de automóveis novos, de passeio e utilitários, da linha *Volkswagen*, a venda de acessórios e peças de reposição, bem como a prestação de serviços de assistência técnica e manutenção para veículos da marca. A empresa também comercializa automóveis usados das demais marcas existentes no mercado.

O estudo de caso se caracteriza como um estudo de caso participativo, no qual o autor não se comporta como mero observador, mas participa como agente ativo nas melhorias.

A aplicação dos métodos de *forecasting*, na concessionária abordada no estudo de caso, concentrou-se na elaboração de previsões de vendas de automóveis novos.

Em virtude da introdução do sistema de varejo (também denominado sistema puxado pela demanda) promovida pela *Volkswagen* a partir de janeiro de 2003, a montadora passou a exigir que suas concessionárias lhe informassem as próprias previsões de vendas de veículos novos com oito semanas de antecedência, a fim de preparar os recursos de manufatura necessários para responder às variações na demanda.

Para atender às exigências da montadora em relação a essas previsões, um funcionário, com a função de analista de vendas, era responsável por estimar as quantidades e classes de veículos que seriam vendidas oito semanas à frente e inseri-las, às quartas-feiras, no sistema de coleta de pedidos da *Volkswagen*. Contudo, tal estimativa não contava com o suporte de métodos formais de *forecasting*. Somente duas fontes de informação eram consultadas:

- a) uma planilha contendo as vendas realizadas por modelos nos últimos dois meses, e
- b) opiniões e avaliações subjetivas da conjuntura do mercado automobilístico e da própria empresa, colhidas informalmente entre os vendedores ou fornecidas pela equipe gerencial durante reuniões de departamento realizadas às segundas-feiras.

4.1 PREVISÕES QUANTITATIVAS

4.1.1 Consulta ao Banco de Dados Históricos de Vendas

Desde 1994 a concessionária possui registros de suas vendas diárias de veículos novos em banco de dados relacional, disponível para acesso a qualquer tempo e atualizado a cada período semanal mediante incorporação das informações das vendas mais recentes.

Para composição das séries históricas de vendas utilizadas nesse estudo os seguintes campos foram consultados no banco de dados: data da venda ao consumidor final, classe, modelo e ano-modelo do veículo novo vendido.

A data de consecução da venda ao consumidor final corresponde à data de emissão da respectiva nota fiscal. A informação do ano modelo assinala os pontos de mudança nos modelos ou classes. A classe relaciona-se ao estilo e finalidade de uso do veículo. O modelo identifica a motorização e o nível de acabamento. A atual linha de automóveis *Volkswagen* comercializados pela concessionária, relacionada na Tabela 2, engloba 10 classes e 37 modelos de automóveis de fabricação nacional, 3 classes e 6 modelos de automóveis importados.

Tabela 2: Códigos comerciais, classes e modelos de automóveis *Volkswagen* novos comercializados pela concessionária

Cód.	Classes	Modelos
3X2	Santana	1.8 e 2.0
5X1	Gol GIII	City 1.0 e 1.6, Plus 1.0 16V, Power 1.6
5X5	Parati	City 1.6, Plus 1.6 e 1.8, Track & Field 1.6 e 2.0, Crossover 2.0
5X9	Saveiro	City 1.6, Supersurf 1.6 e 1.8
5Y1	Gol GII	Special 1.0
5Z1	Fox	City 1.0, Plus 1.0 e 1.6, Sportline 1.6
7X2	Kombi	Furgão 1.6, Standard 1.6, Escolar 1.6, Lotação 1.6
9A1	Polo	1.6, Comfortline 1.6, Sportline 1.6, Série Ouro 1.6
9A2	Polo Sedan	1.6, Comfortline 1.6 e 2.0
9B1	Golf	Plus 1.6 e 2.0, Comfortline 2.0, GTI 1.8 Turbo, Generation 1.6, Sport 1.8 Turbo
9M2	Bora	2.0
3B3	Passat	1.8 Turbo, 2.8 V6, Protect 2.8 V6
3B6	Variant	1.8 Turbo, 2.8 V6

4.1.2 Definição dos Níveis de Agregação dos Dados Históricos de Vendas

A unidade básica de tempo requerida para a coleta de pedidos das concessionárias, assim como para a programação da produção e o cálculo das necessidades de materiais na *Volkswagen*, é a semana. Os dados de vendas registrados diariamente na concessionária em estudo foram, portanto, agregados em períodos semanais.

Mediante consulta ao banco de dados, as 13 classes de veículos foram classificadas em ordem decrescente segundo a respectiva venda média realizada nos 186 períodos semanais compreendidos entre 1º de janeiro de 2001 e 31 de julho de 2004. O resultado da classificação está apresentado na Tabela 3.

Tabela 3: Venda média semanal por classe de veículo

Cód.	Classe	Venda Média	% Unitário	% Acumulado	N.º Semanas
5X1	Gol GIII	27,1	38,5%	38,5%	186
5Y1	Gol GII	10,2	14,5%	53,0%	186
5Z1	Fox	7,5	10,7%	63,7%	42
9B1	Golf	7,0	10,0%	73,6%	186
5X9	Saveiro	4,4	6,2%	79,8%	186
5X5	Parati	3,9	5,5%	85,3%	186
9A1	Polo	3,5	4,9%	90,2%	116
3X2	Santana	2,6	3,7%	93,9%	186
9A2	Polo Sedan	2,0	2,8%	96,7%	86
7X2	Kombi	1,7	2,4%	99,1%	186
9M2	Bora	0,5	0,7%	99,9%	186
3B3	Passat	0,1	0,1%	99,9%	186
3B6	Variant	0,1	0,1%	100,0%	186

A venda média das classes Polo, Polo Sedan e Fox foi calculada com base em 116, 86 e 42 períodos semanais, respectivamente, contabilizados a partir da primeira venda do Polo, efetuada em 16 de maio 2002, do Polo Sedan, em 10 de dezembro 2002 e do Fox, em 17 de outubro de 2003.

Em função dos feriados e da pequena quantidade de dias úteis disponíveis, as vendas realizadas na última semana de cada ano e na primeira semana do ano subsequente foram agregadas em um único período.

A soma das vendas médias das três classes de automóveis importados: Bora, Passat e Variant, é inferior a um veículo vendido por semana. Por conseguinte, o conjunto de

dados históricos de vendas formado pelas três classes é irregular e apresenta um número elevado de valores iguais a um ou zero, o que torna incoerente o ajuste de um modelo matemático para gerar previsões.

O mesmo comportamento apresentam as vendas do Polo, Santana, Polo Sedan e Kombi. Seguindo um critério de similaridade de estilos e finalidades de uso, o Santana e os veículos importados foram agregados em uma nova classe denominada “Santana+Importados”, ao passo que a Kombi se juntou à Saveiro, para formar a classe “Utilitários”. O Polo e o Polo Sedan foram unidos para a geração de uma previsão agregada.

Após a nova classificação, as classes de veículos ficaram distribuídas como mostra a Tabela 4.

Tabela 4: Venda média semanal após agregação das classes de veículos

Classe	Venda Média	% Unitário	% Acumulado	N.º Semanas
Gol GIII	27,1	38,7%	38,7%	186
Gol GII	10,2	14,6%	53,2%	186
Fox	7,5	10,7%	63,9%	42
Golf	7,0	10,0%	73,9%	186
Utilitários	6,2	8,8%	82,8%	186
Polo	5,0	7,1%	89,9%	116
Parati	3,9	5,5%	95,4%	116
Santana+Imp.	3,2	4,6%	100,0%	186

4.1.3 Análise Preliminar dos Dados e Composição das Séries Temporais

Os dados históricos de vendas semanais da classe Gol GIII estão representados graficamente na Figura 8. A análise visual do gráfico indicou que não existem valores faltantes no interior do conjunto de dados. A presença de pontos espúrios também não pôde ser visualizada.

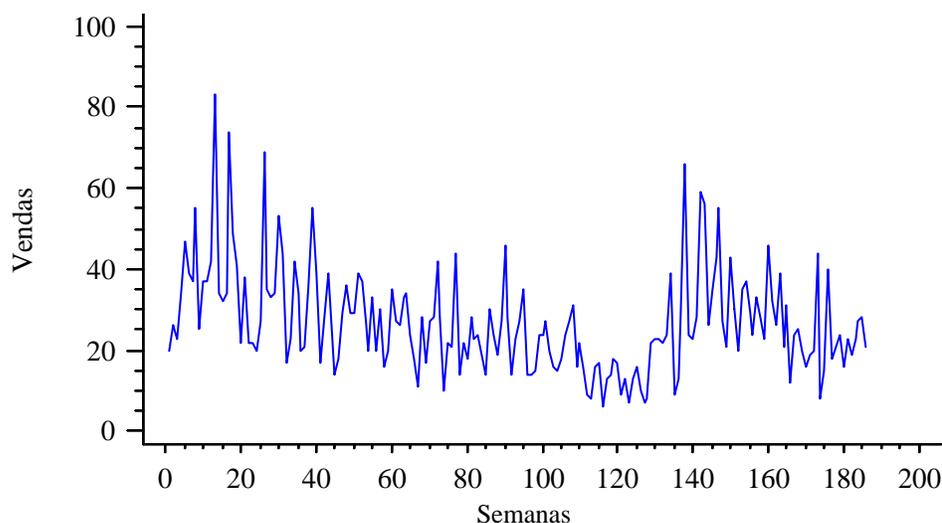


Figura 8: Gráfico da evolução temporal das vendas da classe Gol GIII

Conferiu-se a presença de valores espúrios na série de forma analítica, ajustando-se à classe Gol GIII um modelo provisório ARIMA (4,0,3), a partir do qual foram geradas previsões. Os resíduos entre os dados históricos e as previsões foram plotados em um gráfico de controle. Três pontos fora dos limites de três desvios padrão acima da média foram identificados nos períodos 13, 26 e 138, e correspondem a vendas realizadas de 83, 69 e 66 veículos, respectivamente.

Segundo informações de profissionais da empresa, é provável que os picos de demanda registrados nos períodos 13 e 26 tenham sido provocados por uma campanha especial de vendas, um “feirão de automóveis”, realizado naquelas semanas. Esses dois pontos foram substituídos pelos valores preditos pelo modelo provisório.

A Figura 9 ilustra o gráfico de controle dos resíduos utilizado para identificação de pontos espúrios na série de vendas do Gol GIII.

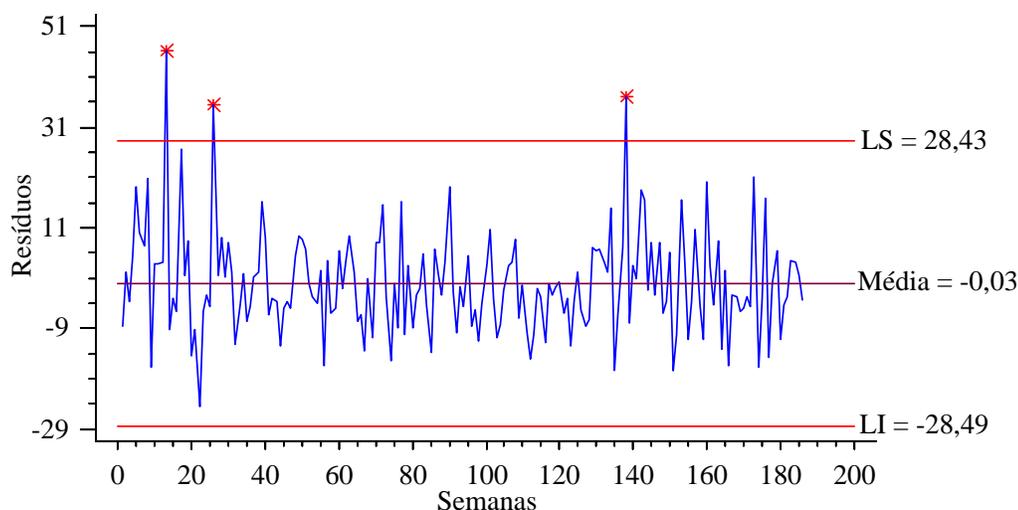


Figura 9: Gráfico de controle dos resíduos gerados para a classe Gol GIII pelo modelo provisório ARIMA (4,0,3)

Observou-se que a série de vendas do Gol GIII apresentou tendência decrescente até o período 127. A partir desse ponto, a tendência se inverteu, ou seja, houve um aumento gradativo das vendas até o período 138. Esse crescimento nas vendas foi atribuído à mudança de ano modelo, em paralelo com lançamento do Gol GIII Power 1.6. Apesar disso, nenhuma causa especial foi associada, especificamente, à venda de 66 veículos no período 138. Esse ponto foi mantido, por ter sido considerado inerente à oscilação natural da série.

Também se constatou uma nova tendência decrescente na série, a começar pelo período 138. Esse declínio nas vendas do Gol GIII foi justificado pelo lançamento do Fox no mercado, ocorrido em outubro de 2004.

O mesmo procedimento foi adotado para análise do comportamento histórico da demanda das demais classes de veículos contidas na Tabela 4.

Em nenhuma das séries analisadas foram encontrados resíduos inferiores ao limite de três desvios padrão abaixo da média. Os valores de vendas iguais a zero no interior das séries não foram relacionados a eventuais desabastecimentos de produtos, mas considerados como vendas perdidas. Substituíram-se esses valores faltantes pelas previsões geradas pelo modelo provisório.

Não foram identificados resíduos fora dos limites de controle nas séries do Fox e Polo, o que indicou que essas séries estavam livres de pontos espúrios. Nas séries Utilitários, Gol GII e Golf existiam dois resíduos além dos limites de controle. Somente o ponto referente

às vendas do período 26 da série do Gol GII pôde ser explicado, pois estava vinculado ao mesmo evento promocional que afetou a série do Gol GIII. Esse ponto foi substituído pelo valor predito pelo modelo provisório. Os demais valores fora dos limites, que não puderam ser satisfatoriamente justificados, permaneceram nas respectivas séries.

As séries restantes, Santana+Importados e Parati, apresentaram diversos resíduos fora dos limites. Nenhum ponto foi, porém, substituído, visto que não foram apontados argumentos que pudessem explicar o comportamento atípico das vendas naqueles períodos.

4.1.4 Ajuste e Validação dos Modelos de Previsão

Às séries de vendas semanais de cada classe de veículo, ajustaram-se modelos de previsão por meio do pacote computacional *Statgraphics 5.0 Plus*, que dispõe de ferramentas para análise de séries temporais e geração de previsões.

Através do recurso *time series analysis / automatic forecasting*, o *software* selecionou automaticamente, para cada série temporal, o modelo que minimizou o erro médio quadrático (MSE) das previsões e o critério de informação de Akaike – AIC.

A adequação dos modelos ARIMA selecionados pelo *Statgraphics* foi verificada pela análise visual dos gráficos da FAC e FACP das séries e da FAC dos resíduos.

Todavia, em todas as oito séries analisadas os modelos escolhidos de modo automático pelo *software* necessitaram de intervenções manuais para otimizar os respectivos ajustes e acurácia das previsões.

Em função do horizonte de previsão de oito semanas requerido pela *Volkswagen* e do último período de vendas realizadas, correspondente à 31ª semana de 2004, os modelos ajustados a cada série foram utilizados para gerar previsões para os oito períodos compreendidos entre a 32ª e 39ª semanas, ou seja, entre 02 de agosto e 25 de setembro de 2004.

▪ *Gol GIII*

A Figura 10 ilustra a modelagem da série temporal das vendas do Gol GIII pelo modelo selecionado automaticamente, ARIMA (4,0,3), antes da substituição dos pontos espúrios.

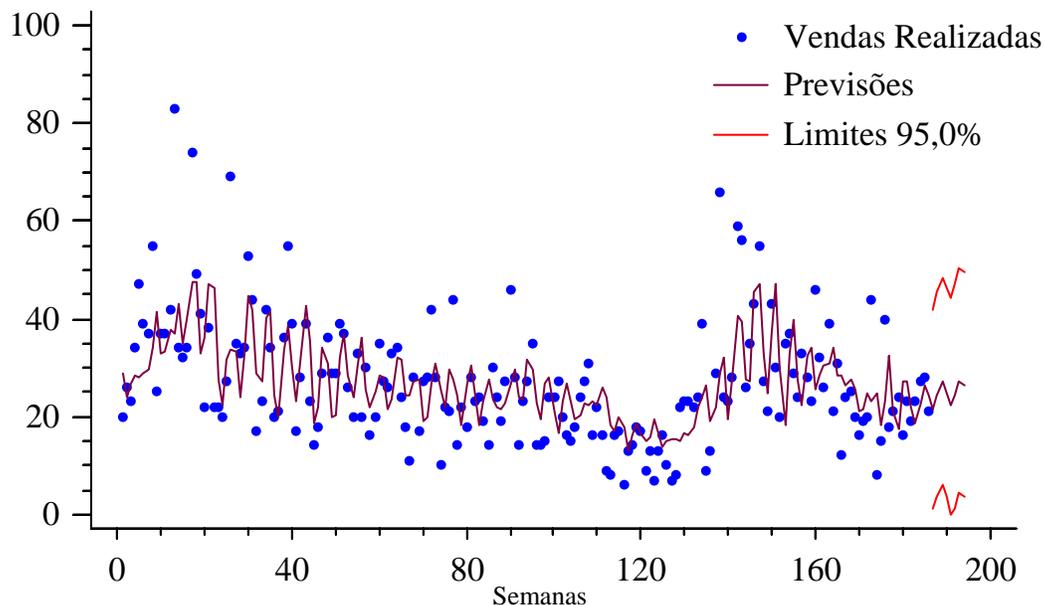


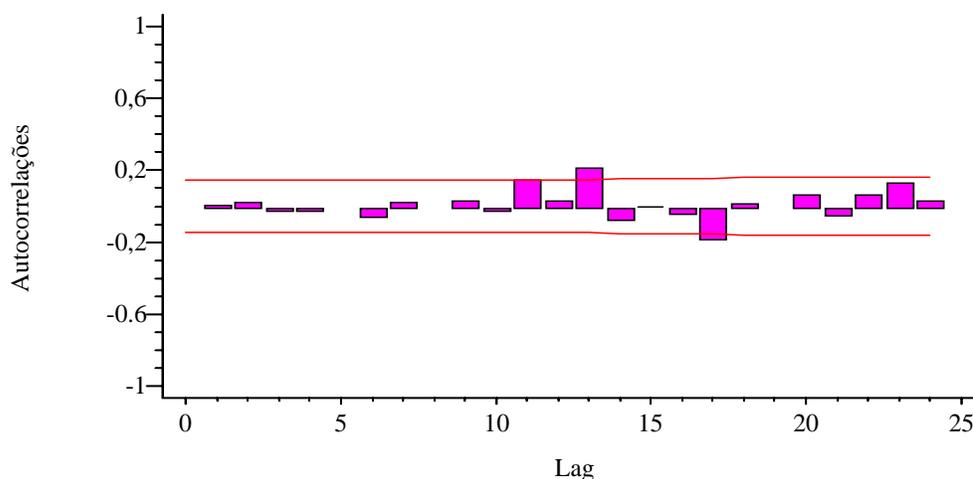
Figura 10: Modelagem da série Gol GIII, antes da substituição dos pontos espúrios, por um modelo ARIMA (4,0,3)

Na Figura 10, os pontos representam as vendas semanais realizadas e a linha, as previsões fornecidas pelo modelo para os mesmos períodos. As duas linhas no final da série assinalam o intervalo de confiança de 95% para a demanda prevista dentro do horizonte de oito semanas. A Tabela 5 apresenta informações referentes aos parâmetros estimados e à precisão do modelo ARIMA (4,0,3) selecionado para a série Gol GIII.

Tabela 5: Informações referentes ao modelo ARIMA (4,0,3) ajustado à série Gol GIII

Parâmetros	Estimativas	MSE	MAPE	AIC
AR(1)	0,977922	107,57	34,21%	4,76
AR(2)	-0,949595			
AR(3)	0,702244			
AR(4)	0,129652			
MA(1)	0,74701			
MA(2)	-0,816546			
MA(3)	0,46814			
Média	26,897			
Constante	3,75959			

A presença de duas autocorrelações residuais além dos limites de controle, como mostra a Figura 11, indica que os resíduos gerados não são totalmente aleatórios e que, portanto, o modelo ARIMA (4,0,3) não capturou tudo o que a série tinha para informar.

**Figura 11: Autocorrelações dos resíduos gerados pelo modelo ARIMA (4,0,3) para a série Gol GIII**

Após a substituição dos pontos espúrios na série Gol GIII e seguindo a mesma lógica de minimização do MSE e AIC, outros modelos foram testados quanto à adequação.

A comparação dos gráficos da FAC e FACP da série com os gráficos teóricos auxilia a identificação de modelos ARIMA. Quando, porém, os gráficos apresentam mais de duas autocorrelações ou autocorrelações parciais significativas, sem decréscimo ou corte brusco nos primeiros *lags*, a simples análise visual dos gráficos não permite identificar com clareza um modelo.

Apesar disso, os gráficos da FAC e FACP da série Gol GIII apontaram para um modelo com ordem elevada, ou seja, com mais de dois parâmetros auto-regressivos e de médias móveis, haja vista a presença de autocorrelações e autocorrelações parciais significativas até o 13º lag. Pôde-se antever, também, a existência de algum padrão sazonal na série, em função da repetição do picos em lags equidistantes. As Figuras 12 e 13 apresentam, respectivamente, os gráficos da FAC e FACP da série Gol GIII.

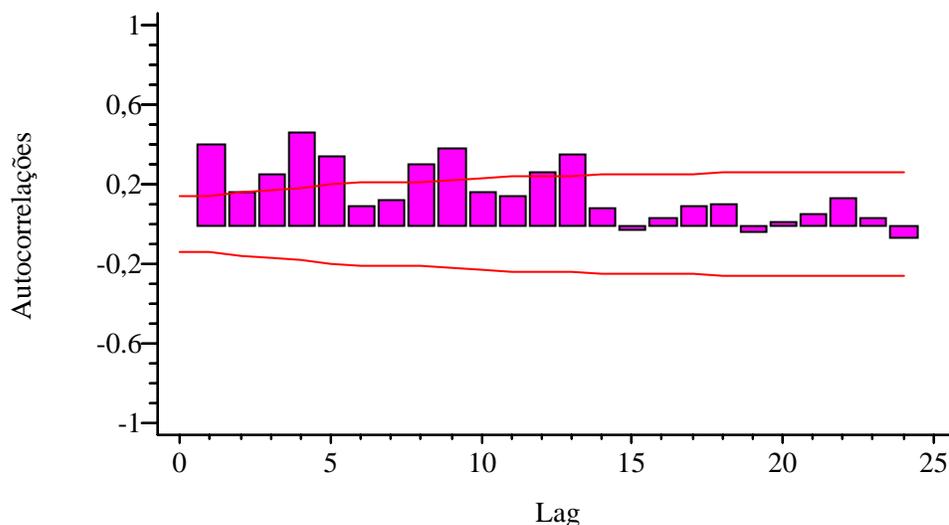


Figura 12: Autocorrelações estimadas para a série Gol GIII

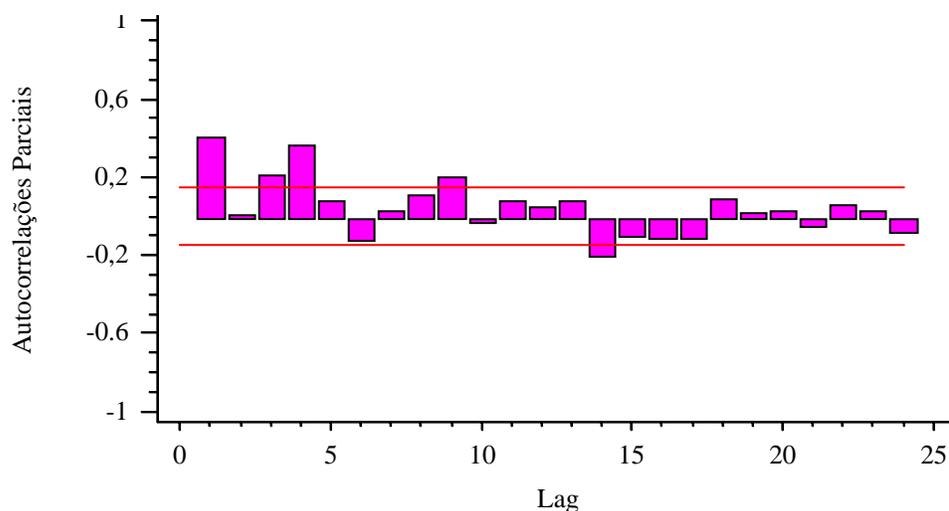


Figura 13: Autocorrelações Parciais estimadas para a série Gol GIII

O modelo que produziu os melhores resultados, $ARIMA(4,0,3) \times (4,0,3)_4$, capturou uma variação sazonal a cada 4 períodos semanais. Como o primeiro período da série corresponde à primeira semana de janeiro de 2001, esse padrão sazonal sugere que as vendas tendem a crescer no final de cada mês. Esse crescimento foi interpretado como consequência da política de concessão de descontos sobre o preço dos veículos novos em estoque ou de outras vantagens ao cliente, adotada pela concessionária na última semana de cada mês, a fim de alavancar as vendas nesses períodos e assegurar o cumprimento das metas mensais.

Apesar da ligeira tendência de declínio observada na série, os modelos verificados com ordens de diferenciação 1 ou 2, ou seja, $ARIMA(p,1,q)$ ou $(p,2,q)$, que supostamente trariam estacionariedade à série e melhoria nas previsões, apresentaram desempenhos inferiores aos obtidos com modelos sem diferenciação. Do mesmo modo, para estabilizar a variância, transformações da família Box-Cox, com λ variando entre 0 e 1, foram aplicadas à série. Nenhuma melhoria na acurácia das previsões ou no ajuste dos modelos resultou desse procedimento.

A Figura 14 apresenta a modelagem da série temporal das vendas do Gol GIII pelo modelo ajustado, $ARIMA(4,0,3) \times (4,0,3)_4$, após a substituição dos pontos espúrios. De forma análoga à Figura 10, os pontos representam as vendas semanais realizadas e a linha, as previsões fornecidas pelo modelo para os mesmos períodos. As duas linhas no final da série delimitam o intervalo de confiança de 95% para a demanda prevista dentro do horizonte de oito semanas.

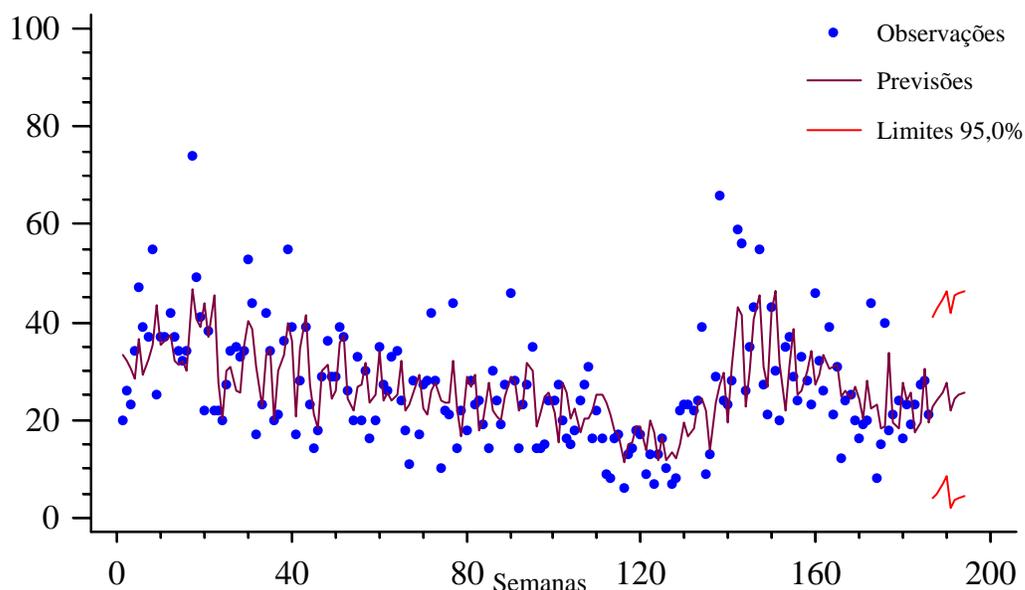


Figura 14: Modelagem da série Gol GIII por um modelo ARIMA (4,0,3) x (4,0,3)₄ após a substituição dos pontos espúrios

A Tabela 6 mostra os parâmetros estimados e os indicadores de precisão do modelo ARIMA (4,0,3) x (4,0,3)₄. Houve redução de aproximadamente 21% no MSE, de 107,57 para 84,82. O MAPE migrou de 34,21% para 30,30% e o AIC, de 4,76 para 4,60.

Tabela 6: Informações referentes ao modelo ARIMA (4,0,3) x (4,0,3)₄ ajustado à série Gol GIII

Parâmetros	Estimativas	MSE	MAPE	AIC
AR(1)	0,872702	84,82	30,30%	4,60
AR(2)	-0,770734			
AR(3)	0,561905			
AR(4)	0,236965			
MA(1)	0,681762			
MA(2)	-0,668404			
MA(3)	0,321636			
SAR(1)	-0,733566			
SAR(2)	0,51978			
SAR(3)	1,03699			
SAR(4)	0,188411			
SMA(1)	-0,633932			
SMA(2)	0,742792			
SMA(3)	0,999425			
Constante	-0,03929			

A Figura 15 demonstra a redução das autocorrelações dos resíduos resultantes do modelo ARIMA $(4,0,3) \times (4,0,3)_4$. Como todas as autocorrelações se encontram dentro dos limites de controle, os resíduos são aleatórios e modelo pode ser considerado adequado para descrever a série temporal Gol GIII.

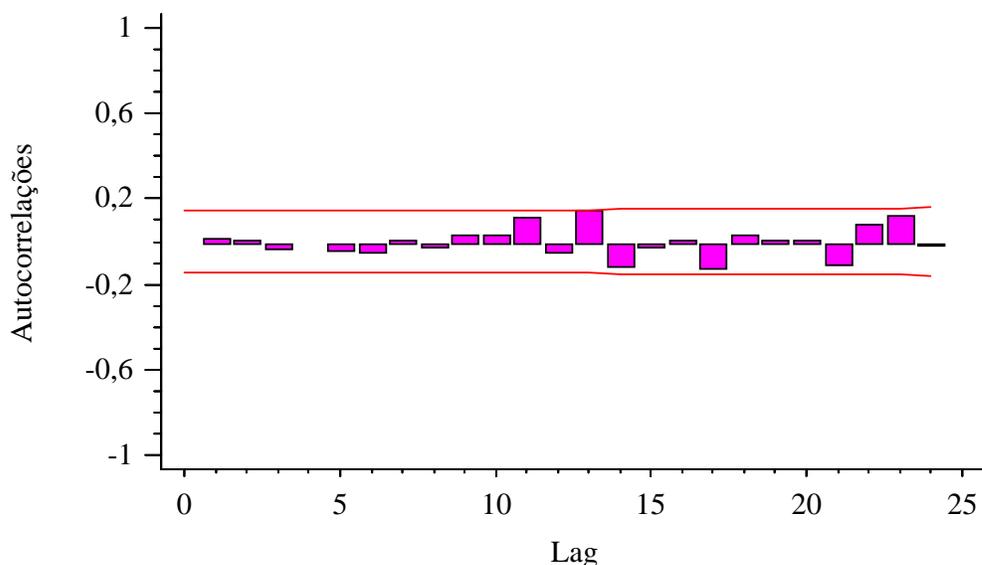


Figura 15: Autocorrelações residuais geradas pelo modelo ARIMA $(4,0,3) \times (4,0,3)_4$ ajustado à série Gol GIII

Na Tabela 7 podem ser visualizadas as previsões produzidas pelo modelo ARIMA $(4,0,3) \times (4,0,3)_4$, os limites de confiança (95%) e as vendas realizadas da série Gol GIII no horizonte de previsão de oito semanas.

Tabela 7: Previsões, limites de confiança e vendas realizadas para a série Gol GIII

Períodos de previsão	Limite Inferior	Previsões	Limite Superior	Vendas Realizadas
1º 2004/32	4,1108	22,6340	41,1573	19
2º 2004/33	4,9265	23,7844	42,6423	25
3º 2004/34	6,7382	25,6336	44,5291	33
4º 2004/35	8,3141	27,4106	46,5072	32
5º 2004/36	1,8833	21,9079	41,9325	9
6º 2004/37	3,6561	24,5299	45,4038	19
7º 2004/38	4,1214	25,0243	45,9272	34
8º 2004/39	4,5409	25,4703	46,3997	27

- *Gol GII*

Os dados históricos de vendas semanais da classe Gol GII estão representados graficamente na Figura 16. A análise visual do gráfico indicou que existem valores faltantes no interior do conjunto de dados. Essas lacunas foram completadas pelos valores preditos para os respectivos períodos. Um ponto considerado espúrio, correspondente ao 26º período da série, foi substituído pelo valor predito para o mesmo período. O gráfico na Figura 16 corresponde aos dados após essas modificações.

A demanda do Gol GII apresenta forte tendência decrescente a partir do período 121, que corresponde à 18ª semana de 2003. Esse declínio nas vendas pode estar relacionado ao desgaste do modelo frente aos lançamentos da concorrência e da própria *Volkswagen*.

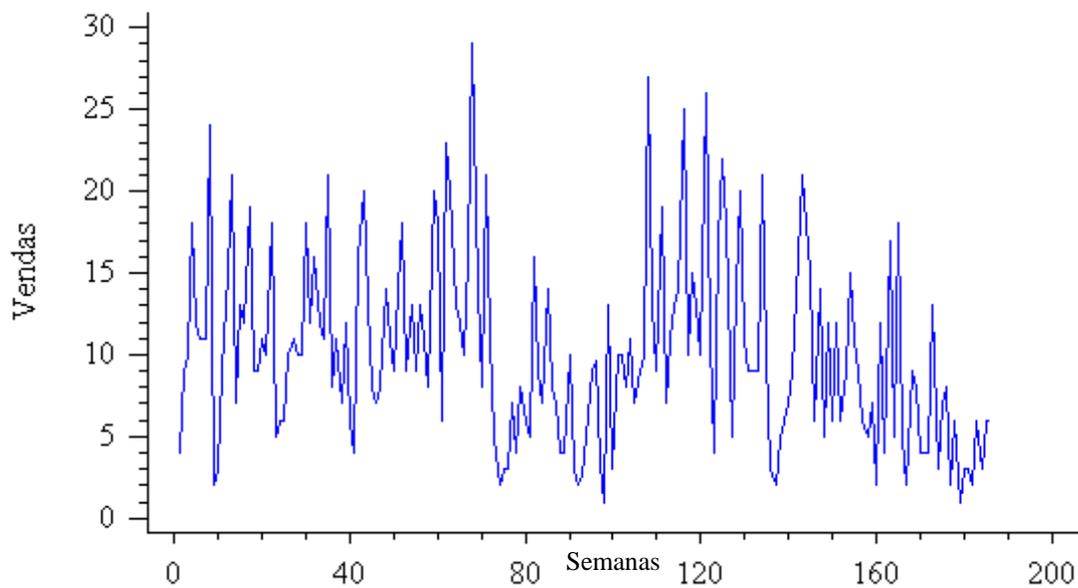


Figura 16: Gráfico da série de demanda do Gol GII, após a substituição de um ponto espúrio

As previsões mais acuradas foram obtidas por um modelo de suavização exponencial simples com $\alpha = 0,1488$. A Figura 17 ilustra o ajuste desse modelo à série do Gol GII e Tabela 8 apresenta os respectivos indicadores de precisão das previsões.

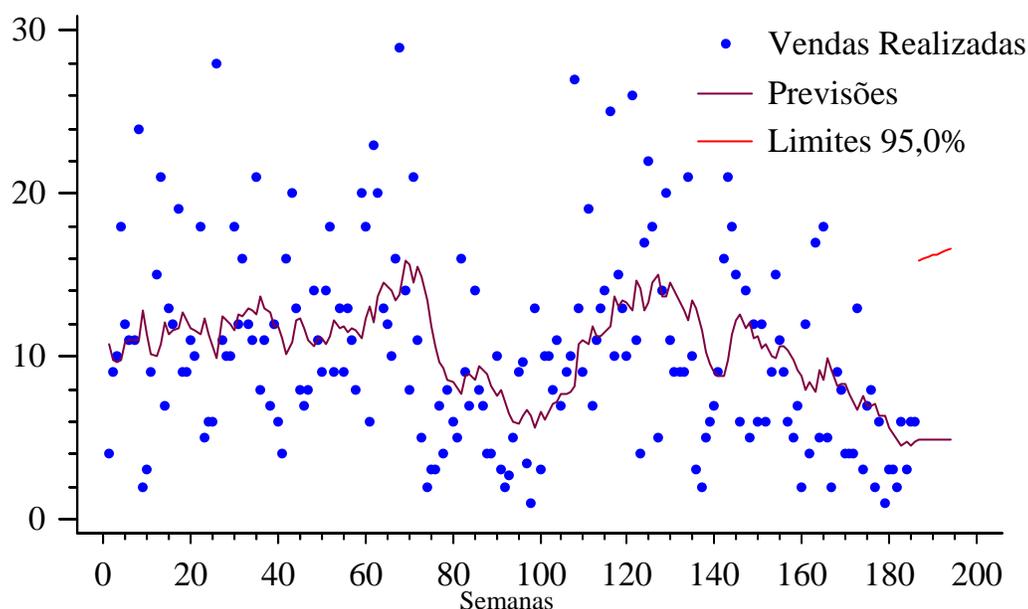


Figura 17: Modelagem da série Gol GII, após a substituição de um ponto espúrio, por um modelo de suavização exponencial simples

Tabela 8: Informações referentes ao modelo de suavização exponencial simples ajustado à série Gol GII

Parâmetros	Estimativas	MSE	MAPE	AIC
α	0,1488	30,03	70,20%	3,41

Em razão de sua formulação matemática, que utiliza as observações da série no denominador, as medidas relativas de erro, como o MAPE, sofrem distorção para cima quando os valores da série são muito baixos (SANDERS, 1997). Devido à grande quantidade de valores baixos encontrados ao longo de toda a série do Gol GII, o MAPE resultante do modelo foi considerado um indicador viciado. A Figura 18 indica que uma das autocorrelações residuais ultrapassa o limite inferior de controle, o que não invalida o modelo. Contudo, outros testes foram aplicados aos resíduos, como a estatística de Ljung-Box, confirmaram a aleatoriedade dos resíduos e validaram o modelo.

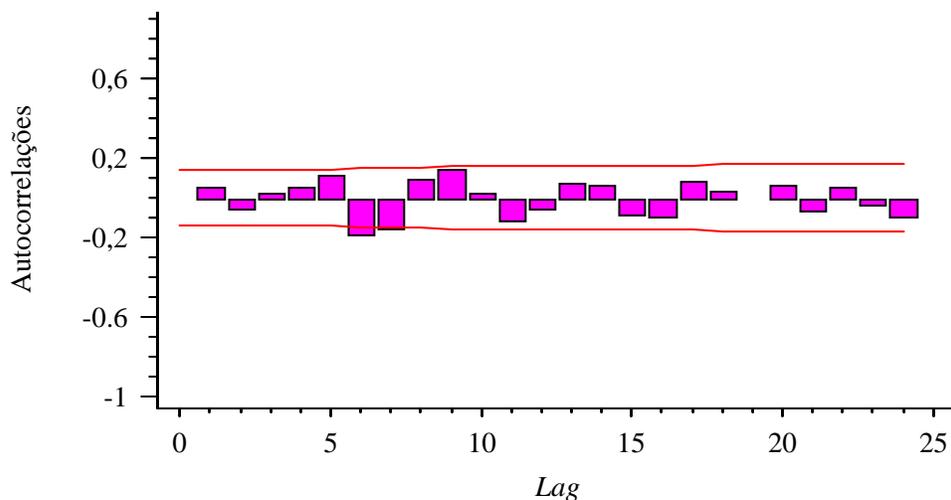


Figura 18: Autocorrelações residuais geradas pelo modelo de suavização exponencial simples, com alfa = 0,1488, ajustado à série Gol GII

A Tabela 9 apresenta as previsões elaboradas pelo modelo de suavização exponencial simples, os limites de confiança (95%) e as vendas realizadas da série Gol GII no horizonte de previsão de oito semanas.

Tabela 9: Previsões, limites de confiança e vendas realizadas para a série Gol GII

Períodos de previsão	Limite Inferior	Previsões	Limite Superior	Vendas Realizadas
1º 2004/32	-5,8844	4,8306	15,5455	3
2º 2004/33	-6,0005	4,8306	15,6616	0
3º 2004/34	-6,1153	4,8306	15,7764	4
4º 2004/35	-6,2290	4,8306	15,8901	3
5º 2004/36	-6,3415	4,8306	16,0026	0
6º 2004/37	-6,4529	4,8306	16,1140	2
7º 2004/38	-6,5632	4,8306	16,2243	0
8º 2004/39	-6,6724	4,8306	16,3335	0

- *Fox*

A concessionária vendeu as duas primeiras unidades do Fox em 17 de outubro de 2003, ou seja, na sexta-feira da 42ª semana do ano. A série semanal de demanda do Fox, ilustrada na Figura 19, foi formada, portanto, somente com 42 períodos, compreendidos entre a 42ª semana de 2003 e a 31ª semana de 2004. A série não continha lacunas ou pontos espúrios.

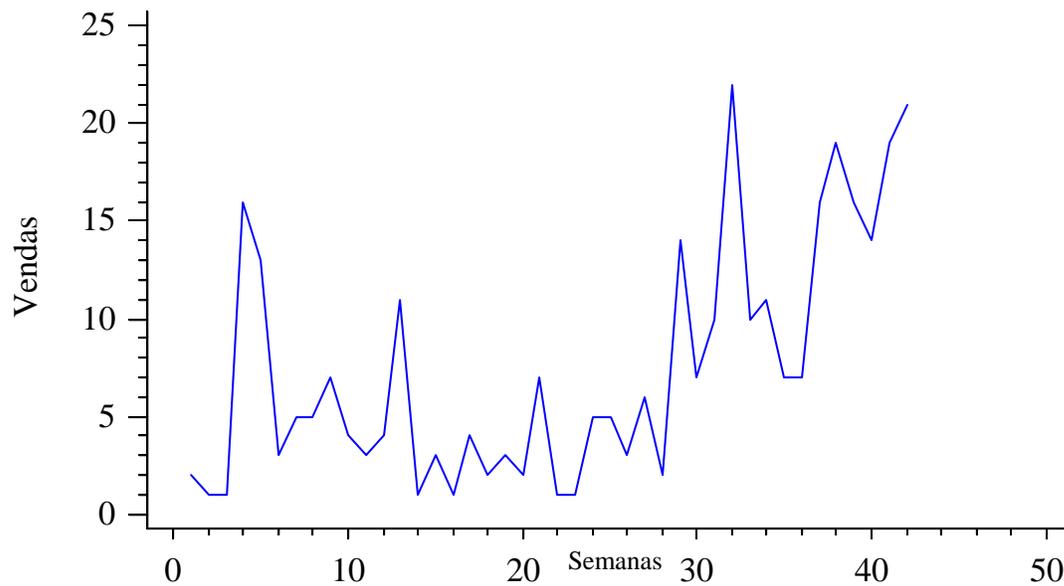


Figura 19: Representação gráfica do comportamento da demanda do Fox

O comportamento da série foi descrito por um modelo de suavização exponencial biparamétrico de Holt com $\alpha = 0,2065$ e $\beta = 0,1696$. A Figura 20 mostra modelo ajustado à série Fox e a Tabela 10, os respectivos indicadores de precisão das previsões.

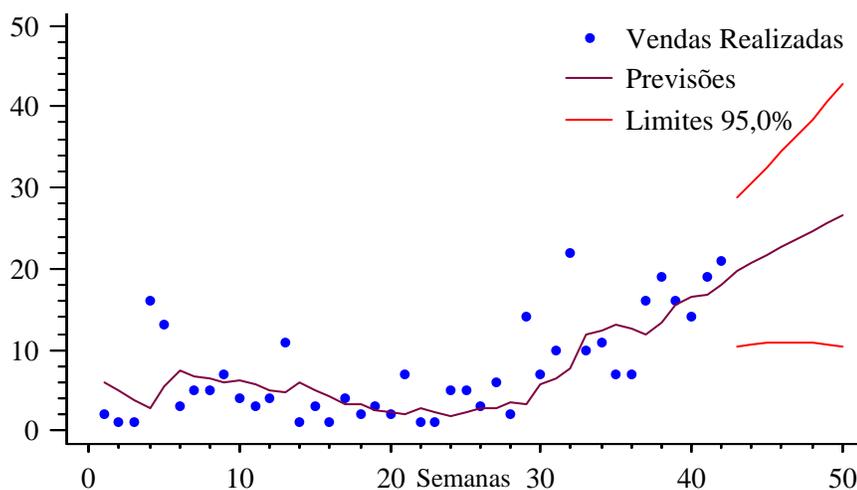


Figura 20: Modelagem da série Fox por suavização exponencial de Holt

Tabela 10: Informações referentes ao modelo de suavização exponencial biparamétrico de Holt ajustado à série Fox

Parâmetros	Estimativas	MSE	MAPE
α	0,2065	30,04	86,65%
β	0,1696		

Todavia, percebeu-se acentuada tendência de crescimento da demanda a partir do 28º período da série, correspondente à última semana de abril de 2004, supostamente motivada pelo lançamento do Fox 4 portas no mercado em março de 2004.

Constatou-se também que nas primeiras semanas após o lançamento do Fox no mercado, a concessionária não dispunha de um estoque de segurança capaz de oferecer um nível de serviço devidamente dimensionado para evitar uma eventual escassez do produto, o que pode ter afetado o comportamento inicial das vendas.

Devido aos fatores mencionados, se considerou a possibilidade de melhoria da precisão das previsões com a utilização apenas das observações posteriores ao 28º período da série.

Novamente, o modelo que melhor capturou a tendência ascendente dessa segunda série do Fox, constituída pelas 14 observações mais recentes da série original, foi o de suavização exponencial de Holt. As constantes de suavização estimadas para esse modelo

foram $\alpha = 0,1810$ e $\beta = 0,2218$. A Figura 21 apresenta o modelo ajustado à série do Fox e a Tabela 11, os respectivos indicadores de precisão das previsões.

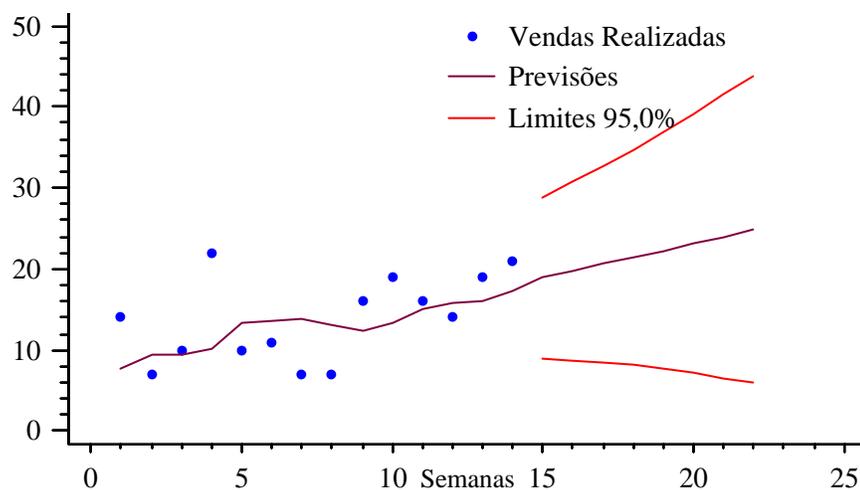


Figura 21: Modelo de suavização exponencial de Holt ajustado à série Fox com 14 períodos

Tabela 11: Informações referentes ao modelo de suavização exponencial de Holt ajustado à série Fox com 14 períodos

Parâmetros	Estimativas	MSE	MAPE
α	0,1810	23,04	34,81%
β	0,2218		

Com a modelagem das últimas 14 observações da série original houve um incremento significativo na acurácia das previsões, demonstrado especialmente pela redução do MAPE de 86,65% para 34,81%.

As autocorrelações dos resíduos, ilustradas na Figura 22, permaneceram dentro dos limites de controle, o que validou o modelo ajustado à série com 14 períodos.

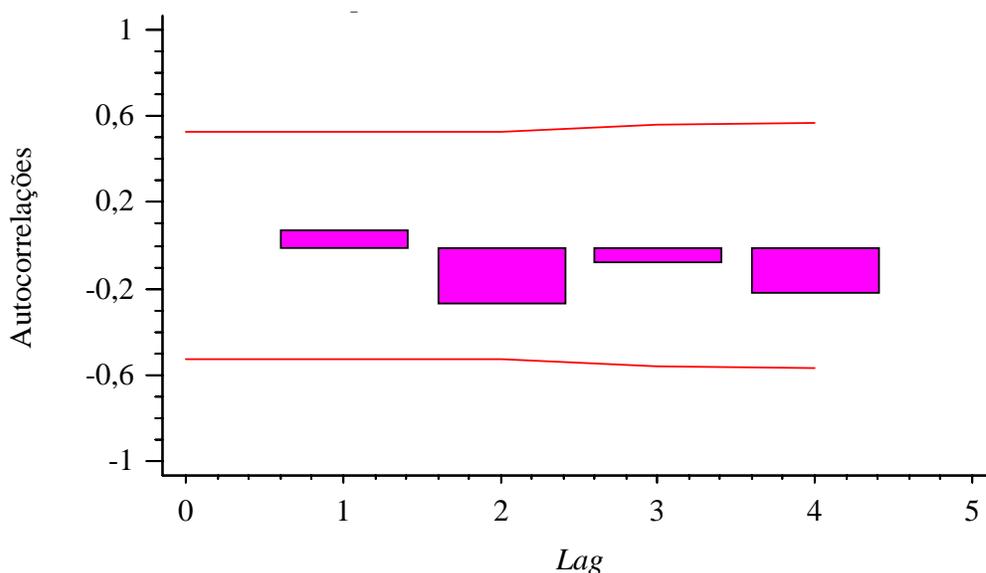


Figura 22: Autocorrelações residuais geradas pelo modelo de suavização exponencial de Holt, com alfa = 0,1810 e beta = 0,2218, ajustado à série Fox

As previsões elaboradas pelo modelo de suavização exponencial de Holt, os limites de confiança (95%) e as vendas realizadas da série Fox no horizonte de previsão de oito semanas aparecem na Tabela 12.

Tabela 12: Previsões, limites de confiança e vendas realizadas para o Fox

Períodos de previsão	Limite Inferior	Previsões	Limite Superior	Vendas Realizadas
1º 2004/32	8,91887	18,8731	28,8274	14
2º 2004/33	8,82576	19,7284	30,6311	17
3º 2004/34	8,61231	20,5837	32,5551	21
4º 2004/35	8,28908	21,4390	34,5889	14
5º 2004/36	7,86586	22,2943	36,7227	9
6º 2004/37	7,35132	23,1496	38,9479	14
7º 2004/38	6,75288	24,0049	41,2569	26
8º 2004/39	6,07690	24,8602	43,6434	38

O procedimento de análise e seleção empregado para ajustar modelos de previsão às séries de vendas semanais do Gol GIII, Gol GII e Fox foi estendido para as demais classes de veículos. A Tabela 13 resume os resultados da modelagem.

Tabela 13: Resultados da modelagem das demais classes de veículos

Classe de Veículo	Tratamento Valores Espúrios / Faltantes	Comportamento da Demanda	Modelo Selecionado	Parâmetros	MSE	MAPE
Golf	não	com tendência	ARIMA (1,0,0)	$\phi_1 = 0,4759$	13,17	69,54%
Utilitários	sim	com tendência	Suav. Exp. Simples	$\alpha = 0,0822$	9,79	55,58%
Polo	sim	com tendência	ARIMA (2,1,1)	$\phi_1 = 0,1877$ $\phi_2 = -0,2372$ $\theta_1 = 0,8716$	8,94	47,03%
Parati	sim	com tendência	ARIMA (2,1,1)	$\phi_1 = 0,2314$ $\phi_2 = -0,2054$ $\theta_1 = 0,8561$	6,35	74,11%
Santana+Imp.	sim	com tendência	Suav. Exp. Simples	$\alpha = 0,0924$	4,24	66,76%

4.1.5 Elaboração das Previsões Quantitativas

Com os modelos ajustados e validados para cada série temporal de demanda, foram elaboradas previsões para o horizonte de oito períodos semanais, conforme apresentado na Tabela 14. Por arredondamento, os valores foram expressos em números inteiros.

Tabela 14: Previsões quantitativas por classe de veículo

Períodos de previsão	Sant+Imp.	Gol GIII	Parati	Utilit.	Gol GII	Fox	Polo	Golf	
1º	2004/32	2	23	3	6	5	20	3	5
2º	2004/33	2	24	4	6	5	21	3	6
3º	2004/34	2	26	4	6	5	22	3	7
4º	2004/35	2	27	4	6	5	23	3	7
5º	2004/36	2	22	4	6	5	23	3	7
6º	2004/37	2	25	4	6	5	25	3	7
7º	2004/38	2	25	4	6	5	26	3	7
8º	2004/39	2	25	4	6	5	27	3	7

4.1.6 Atualização e Monitoramento do Sistema de Previsão Quantitativo

A existência de erros sistemáticos na elaboração das previsões quantitativas poderá ser verificada no futuro através do acompanhamento do comportamento dos erros de previsão. A cada nota fiscal emitida, o sistema lança automaticamente as informações referentes à venda realizada no banco de dados da empresa.

4.2 PREVISÕES QUALITATIVAS

As previsões qualitativas da demanda de veículos novos foram elaboradas através do método Delphi, cujo procedimento de aplicação seguiu os passos apresentados a seguir.

4.2.1 Seleção dos Especialistas

Dentre os profissionais da concessionária, procurou-se convidar para participar do processo Delphi aqueles com maior experiência no ramo de concessionárias de veículos ou que pudessem contar com informações advindas do mercado automobilístico, dos concorrentes, da conjuntura econômica e dos clientes ou relativas à própria empresa, como situação financeira, eventos especiais ocorridos ou planejados, estoque e cotas de vendas de veículos novos. Os profissionais selecionados formaram um grupo de especialistas responsável pela elaboração de previsões qualitativas de vendas de veículos novos.

O grupo de especialistas foi constituído pelos seguintes profissionais: diretor de vendas, gerente de vendas, vendedor com mais tempo de casa, vendedor com a maior carteira de clientes e analista de vendas responsável pela inserção das previsões no sistema de coleta de pedidos da *Volkswagen*. Esses mesmos profissionais forneceram as informações necessárias para o reconhecimento, remoção ou substituição dos pontos espúrios encontrados nos dados históricos de vendas.

4.2.2 Preparação e Distribuição de Tabelas de Previsão

Cada especialista recebeu uma cópia em branco de uma tabela de previsão, na qual as colunas indicavam as classes de veículos e as linhas, os oito períodos subseqüentes. A agregação das classes seguiu o mesmo critério adotado para o *forecasting* quantitativo. A primeira semana de agosto 2004, entre os dias 2 e 7, representou o primeiro período de previsão e a penúltima semana de setembro, entre os dias 20 e 25, o oitavo período.

Os especialistas completaram a tabela com suas previsões de vendas de cada classe de veículo para as próximas oito semanas. Informações adicionais, como as séries temporais de vendas ou as previsões quantitativas geradas, não foram divulgadas para os especialistas. Nessa primeira rodada do processo, optou-se por capturar o mais fielmente possível o julgamento pessoal de cada especialista, sem a influência de informações que não fossem de natureza estritamente qualitativas.

4.2.3 Análise Estatística e Apresentação das Informações aos Especialistas

As previsões fornecidas pelos especialistas na primeira rodada foram analisadas estatisticamente através do cálculo da mediana, média, variância, quartis superiores e inferiores e MSE das previsões. A Tabela 15 apresenta as previsões de cada especialista, designados por letras de A a E, na primeira rodada do processo para a classe Gol GIII e a análise estatística dos dados.

Tabela 15: Mediana, média, variância, quartis inferiores e superiores e MSE das previsões de cada especialista na primeira rodada para a classe Gol GIII

Períodos de previsão	A	B	C	D	E	Mediana	Média	Variância	QI	QS
1° 2004/32	17	30	25	20	25	25	23,4	25,3	20	25
2° 2004/33	12	20	10	10	25	12	15,4	45,8	10	20
3° 2004/34	20	20	10	10	30	20	18,0	70,0	10	20
4° 2004/35	15	25	10	30	28	25	21,6	75,3	15	28
5° 2004/36	35	33	50	38	47	38	40,6	56,3	35	47
6° 2004/37	28	30	35	40	40	35	34,6	30,8	30	40
7° 2004/38	12	15	20	10	35	15	18,4	100,3	12	20
8° 2004/39	28	15	10	30	31	28	22,8	92,7	15	30
						MSE	235,25	243,45	496,5	

Tomando-se a mediana como referencial para as previsões, o MSE para o horizonte de oito semanas em relação às vendas realizadas foi menor do que se considerada a média. A análise dos quartis e da variância indicou que não havia convergência satisfatória nas respostas.

O comentário mais comum registrado nessa primeira rodada referia-se à justificativa dos valores mais elevados no final do mês de agosto, ou seja, no 5º período de previsão, entre os dias 30 de agosto e 04 de setembro de 2004. O aumento das vendas no final de cada mês foi capturado pelo modelo matemático ajustado à série de demanda do Gol GIII.

Os resultados das previsões qualitativas da primeira rodada, representados na Tabela 15 foram apresentados aos especialistas para motivar uma segunda rodada do processo.

Na Tabela 16 tem-se as previsões de cada especialista na segunda rodada do processo para a classe Gol GIII e respectiva análise estatística dos dados.

Tabela 16: Mediana, média, variância, quartis inferiores e superiores e MSE das previsões de cada especialista na segunda rodada para a classe Gol GIII

Períodos de previsão	A	B	C	D	E	Mediana	Média	Variância	QI	QS
1º 2004/32	23	40	35	20	20	23	27,6	86,3	20	35
2º 2004/33	15	10	10	20	20	15	15,0	25,0	10	20
3º 2004/34	20	10	24	28	30	24	22,4	62,8	20	28
4º 2004/35	15	10	17	20	25	17	17,4	31,3	15	20
5º 2004/36	45	43	34	38	47	43	41,4	28,3	38	45
6º 2004/37	23	45	34	30	35	34	33,4	64,3	30	35
7º 2004/38	35	25	10	33	32	32	27,0	104,5	25	33
8º 2004/39	25	40	30	32	31	31	31,6	29,3	30	32
						MSE	227,88	228,35	431,8	

Apesar de não ter havido uma melhora acentuada na acurácia das previsões da segunda rodada, constatou-se que o MSE associado à utilização da mediana como previsão novamente foi menor do que o da média. A redução na variância foi de aproximadamente 13%. A análise dos quartis apontou certo grau de convergência em relação às respostas da primeira rodada, especialmente a partir do 4º período de previsão.

As previsões qualitativas elaboradas para as demais classes foram estatisticamente analisadas seguindo o mesmo procedimento. Muito embora a média tenha proporcionado previsões mais acuradas para algumas das séries, optou-se pela utilização da

mediana como padrão de referência para as previsões, uma vez que não é afetada por valores extremos como a média. As previsões para o Gol GII, Fox e Golf apresentaram boa convergência, com redução da variância na ordem de 40% entre a primeira e a segunda rodadas.

Na segunda rodada os especialistas salientaram que as quantidades inseridas no sistema de coleta de pedidos da montadora nem sempre correspondem às compras reais da concessionária nas respectivas semanas. Em função de oscilações de mercado e nível médio de estoque, alguns modelos são passíveis de bloqueio junto à fábrica da *Volkswagen* por parte da revenda. Apesar disso, como já mencionado anteriormente, a empresa não aplica métodos formais para prever seus níveis de estoque e as oscilações de mercado.

Outra questão freqüentemente mencionada diz respeito aos bônus oferecidos pela montadora e repassados pela concessionária ao cliente final por ocasião da compra de determinados modelos. Os especialistas não souberam, porém, mensurar o impacto dessa bonificação no comportamento da demanda.

4.2.4 Definição da Previsão Final do Conselho de Especialistas

O processo Delphi foi concluído na segunda rodada, uma vez que as previsões convergiram em certo grau, identificado pela redução, mesmo que parcial, na variância e na amplitude dos quartis superiores e inferiores. Entendeu-se que uma terceira rodada não proporcionaria mudanças significativas nas previsões e não traria novas informações para o processo. A mediana das previsões da segunda rodada foi considerada como representativa do consenso entre os especialistas. As previsões qualitativas, fornecidas pelos especialistas na segunda rodada, para as demais classes de veículos se encontram na Tabela 17.

Tabela 17: Previsões qualitativas do grupo de especialistas na segunda rodada por classe de veículo

Períodos de previsão	Sant+Imp.	Gol GIII	Parati	Utilit.	Gol GII	Fox	Polo	Golf
1º 2004/32	2	23	4	2	3	18	2	3
2º 2004/33	0	15	1	0	10	19	5	8
3º 2004/34	1	24	2	3	2	20	4	9
4º 2004/35	0	17	1	0	0	10	3	5
5º 2004/36	0	43	0	12	2	5	2	10
6º 2004/37	0	34	1	10	0	29	0	0
7º 2004/38	0	32	4	11	3	22	3	0
8º 2004/39	0	31	2	4	0	18	5	8

4.2.5 Atualização e Monitoramento do Processo de Previsão Qualitativo

As previsões qualitativas geradas para os oito períodos definidos nesse trabalho, assim como todos os comentários elaborados pelos especialistas durante as rodadas, foram arquivados em uma planilha eletrônica para eventuais consultas. Após algumas semanas da realização das reuniões, será possível verificar o desempenho acumulado do processo de previsão qualitativo através dos erros de previsão e corrigir possíveis desvios.

4.3 COMBINAÇÃO DAS PREVISÕES QUANTITATIVAS E QUALITATIVAS

Com exceção da retirada de alguns pontos espúrios identificados nas séries Gol GIII e Gol GII, provocados provavelmente por campanhas de vendas, nenhuma mudança relevante no comportamento da demanda foi atribuída a causas específicas. Do mesmo modo, as informações passadas pelos especialistas durante as rodadas do Delphi sugerem que não houve interferências significativas na acurácia das previsões qualitativas. As previsões quantitativas e qualitativas receberam, portanto, pesos iguais e foram combinadas através de média aritmética simples. As previsões combinadas estão representadas na Tabela 18.

Tabela 18: Previsões quantitativas e qualitativas combinadas por classe de veículo

Períodos de previsão		Sant+Imp.	Gol GIII	Parati	Utilit.	Gol GII	Fox	Polo	Golf
1º	2004/32	2	23	4	4	4	19	3	4
2º	2004/33	1	20	3	3	8	20	4	7
3º	2004/34	2	25	3	5	4	21	4	8
4º	2004/35	1	22	3	3	3	17	3	6
5º	2004/36	1	33	2	9	4	14	3	9
6º	2004/37	1	30	3	8	3	27	2	4
7º	2004/38	1	29	4	9	4	24	3	4
8º	2004/39	1	28	3	5	3	23	4	8

4.4 COMPARAÇÃO ENTRE AS PREVISÕES QUALITATIVAS, QUANTITATIVAS E COMBINADAS

As previsões qualitativas, quantitativas ou combinadas para cada classe de veículo e para o horizonte de oito semanas foram comparadas com as vendas realizadas nos mesmos períodos. Na Tabela 19, E indica os erros, SE os erros quadráticos e MSE os erros quadráticos médios resultantes da comparação entre as previsões elaboradas para a classe Gol GIII e as vendas realizadas entre a 32ª e a 39ª semanas de 2004.

Tabela 19: Comparação entre as previsões e as vendas realizadas da classe Gol GIII

Períodos de Previsão	Vendas Real.	Prev. Qual.			Prev. Quant.			Prev. Comb.		
		Qual.	E	SE	Quant.	E	SE	Comb.	E	SE
1º 2004/32	19	23	-4	16	23	-4	16	23	-4	16
2º 2004/33	25	15	10	100	24	1	1	20	6	30
3º 2004/34	33	24	9	81	26	7	49	25	8	64
4º 2004/35	32	17	15	225	27	5	25	22	10	100
5º 2004/36	9	43	-34	1156	22	-13	169	33	-24	552
6º 2004/37	19	34	-15	225	25	-6	36	30	-11	110
7º 2004/38	34	32	2	4	25	9	81	29	6	30
8º 2004/39	27	31	-4	16	25	2	4	28	-1	1
MSE		227,88			47,63			113,00		

Seguindo a mesma lógica de cálculo, a Tabela 20 mostra as medidas de MSE obtidas entre os valores previstos por cada método para as demais classes e as respectivas vendas realizadas.

Tabela 20: MSE por classe e método de previsão

Método de Previsão	Sant+Imp.	Gol GIII	Parati	Utilit.	Gol GII	Fox	Polo	Golf
Qualitativo	1,00	227,88	6,13	30,13	16,25	86,75	4,00	19,13
Quantitativo	2,88	47,63	4,00	5,63	14,75	71,50	3,00	15,63
Combinação	1,16	113,00	3,47	12,31	11,56	59,81	2,88	13,50

4.5 ANÁLISE DOS RESULTADOS

Esse estudo de caso possibilitou a aplicação, em uma situação real, do método proposto para elaboração de previsões qualitativas e quantitativas de demanda de veículos novos em concessionárias. Apesar de não existir unanimidade entre os pesquisadores quanto à forma de condução do processo Delphi, se tentou preservar a estrutura e os princípios mais recomendados pela literatura durante a aplicação do método no estudo de caso. As tabelas de previsão foram distribuídas e recolhidas de forma que a identificação dos respondentes entre si pudesse ser evitada. Presume-se que o anonimato tenha sido mantido durante todo o processo. Em cumprimento ao princípio da iteração dos questionários, duas rodadas de elaboração de previsões foram realizadas. Medidas estatísticas, julgadas necessárias para o reconhecimento de dispersão ou convergência, foram utilizadas para analisar e comparar as previsões fornecidas na primeira e segunda rodadas.

Os profissionais envolvidos concordaram que a estruturação do processo de *forecasting* qualitativo através do método Delphi propiciou redução de pressões e interesses pessoais e contribuiu para uma manifestação espontânea e equilibrada de opiniões por ocasião da elaboração das previsões. A análise estatística das respostas também foi apontada como um diferencial positivo do método Delphi em relação ao processo anteriormente adotado.

No processo de *forecasting* quantitativo, instituído por meio de ajuste de modelos estatísticos às séries temporais de vendas de cada classe de veículo, houve equilíbrio entre as técnicas de previsão selecionadas. Das oito séries analisadas, quatro foram modeladas por suavização exponencial e quatro pelo método de Box-Jenkins. O analista de vendas, responsável por informar as previsões de vendas para a montadora, admitiu que a aplicação desses modelos é fundamental para a obtenção de previsões confiáveis e que a simples análise da planilha das vendas realizadas nos últimos meses é insuficiente para a fins de *forecasting*.

A modelagem da demanda da classe Santana+Importados foi fortemente afetada pela freqüente incidência de valores iguais a um ou faltantes ao longo de toda a série. Nesse caso, o modelo de suavização exponencial simples ajustado à série ofereceu previsões menos acuradas do que as oriundas do julgamento dos especialistas. Sugeriu-se a agregação temporal da demanda dessa classe em períodos mensais quando da elaboração de novas previsões quantitativas, a fim de evitar a presença de valores muito baixos na série.

O modelo ARIMA (4,0,3) x (4,0,3)₄ logrou capturar adequadamente o comportamento histórico da demanda da classe Gol GIII e gerar previsões significativamente mais precisas do que as obtidas qualitativamente ou pela combinação dos métodos. Atribuiu-se esse resultado à impossibilidade de identificação das nuances da demanda dessa classe, como as variações sazonais a cada quatro períodos, de modo subjetivo, sem o suporte de um modelo matemático devidamente ajustado à série.

As previsões qualitativas para a classe Utilitários apresentaram grande imprecisão. Os especialistas apostaram em um aumento das vendas nos últimos quatro períodos do horizonte de *forecasting*. Essa expectativa não se concretizou; ao contrário, ocorreu retração nas vendas entre a 36^a e a 39^a semanas, precisamente no mês de setembro. Muito embora o modelo de suavização exponencial simples também não tenha capturado essa tendência de declínio nas vendas, as previsões quantitativas se mostraram mais acuradas frente às demais abordagens.

Exceto nos três casos acima justificados, nas cinco demais séries analisadas, as previsões resultantes da combinação dos métodos quantitativos e qualitativos produziram MSE menores do que os obtidos pelos métodos individualmente. Essa constatação reforça a idéia de que a utilização de diferentes métodos de previsão simultaneamente pode aumentar a acurácia das previsões.

Sugeriu-se, portanto, que a combinação dos métodos qualitativos e quantitativos fosse adotada como procedimento padrão para composição das novas previsões que seriam informadas à *Volkswagen*, salvo se a análise do desempenho dos erros de *forecasting* demonstrasse que a acurácia de um ou outro método isoladamente tivesse superado a da combinação.

Constatou-se, também, que a viabilidade de se continuar a empregar o método para elaboração de previsões de veículos novos na concessionária abordada ou de aplicá-lo em outras concessionárias depende da alocação e manutenção de recursos para:

- Aquisição de pacote computacional estatístico que disponha de ferramentas para análise de séries temporais e geração de previsões;
- Contratação de profissional especializado em *forecasting* ou treinamento em métodos de *forecasting*, orientado para os profissionais responsáveis por suprir a montadora com informações relativas às previsões de vendas da concessionária.

5 CONCLUSÃO

5.1 COMENTÁRIOS FINAIS

O desenvolvimento dessa dissertação de mestrado se justificou diante da contradição entre a inexistência de um sistema formal de *forecasting* na concessionária estudada e a responsabilidade pela elaboração de previsões acuradas da própria demanda de veículos novos, imposta pelo sistema de varejo implementado pela *Volkswagen*.

O trabalho ressaltou que a aplicação sistemática dos métodos de *forecasting* quantitativos e qualitativos abordados na literatura é imprescindível para obtenção de previsões acuradas. Tais métodos não eram, porém, conhecidos ou utilizados pelos profissionais responsáveis por elaborar previsões de demanda na concessionária e informá-las à montadora.

Na revisão bibliográfica, os fundamentos estatísticos do método de Box-Jenkins e a lógica dos modelos de suavização exponencial, bem como o procedimento básico para utilização do método Delphi foram apresentados de forma a possibilitar sua compreensão e aplicação, no contexto da concessionária, pelos profissionais interessados.

O método proposto para elaboração de previsões de demanda de veículos novos em concessionárias contribuiu para estruturar a aplicação dos métodos quantitativos e qualitativos de *forecasting* conduzida no estudo de caso. O método pode ser facilmente adaptado para aplicações diversas no ramo automobilístico ou mesmo em empresas de outros segmentos.

O estudo de caso permitiu o cumprimento do objetivo geral e dos objetivos específicos do trabalho. Primeiramente, o perfil da demanda das classes de veículos comercializadas pela empresa foi descrito mediante análise dos componentes de tendência, sazonalidade, nível, pontos espúrios e aleatoriedade presentes nas respectivas séries históricas de vendas semanais. A seguir, o modelo quantitativo mais adequado para cada série foi identificado, validado e empregado para gerar previsões para um horizonte de 8 períodos, compreendidos entre a 32ª e a 39ª semanas de 2004. Paralelamente, utilizou-se o método Delphi para formalizar o processo de *forecasting* qualitativo e produzir previsões para o mesmo horizonte.

As previsões quantitativas e qualitativas foram combinadas matematicamente. Seguindo o critério de minimização do erro médio quadrático das previsões, comparou-se o resultado das combinações com o desempenho obtido pelos métodos quantitativos e qualitativos isoladamente. A comparação indicou que em cinco das oito séries analisadas a combinação dos métodos proporcionou maior acurácia às previsões, demonstrando que as vantagens inerentes a cada método foram absorvidas. Esse procedimento encerrou o primeiro ciclo de elaboração de previsões de demanda de veículos novos na concessionária, formalizado por métodos quantitativos e qualitativos de *forecasting*.

Por fim, os métodos mais acurados para cada série foram considerados apropriados para gerar as novas previsões que serão transmitidas à *Volkswagen* via sistema de coleta de pedidos. O presente trabalho constitui uma ferramenta de suporte e referência para os responsáveis pela formulação de previsões de vendas na revenda *Volkswagen* estudada.

5.2 SUGESTÕES PARA TRABALHOS FUTUROS

Possíveis desdobramentos futuros do tema dessa dissertação incluem:

- Aplicação de análise de regressão e correlação sobre as séries temporais de demanda de veículos novos nas concessionárias, a fim de determinar o grau de influência de uma classe de veículos sobre as demais, no que tange ao comportamento local das vendas. Através de tais análises seria possível, por exemplo, mensurar o impacto provocado pelo lançamento do Fox sobre as vendas do Gol GIII. Séries de demanda de veículos de marcas concorrentes também poderiam ser analisadas sob a mesma ótica;
- Reestruturação do processo de gestão da demanda na montadora mediante otimização dos sistemas de atribuição de cotas, programação e administração de pedidos, a fim de permitir que as previsões das concessionárias e as peculiaridades locais da demanda sejam prontamente reconhecidas pela produção. Esse processo propiciará a redução do tempo real entre a colocação do pedido pelo cliente e a entrega do veículo na respectiva concessionária;
- Desenvolvimento de programa de divulgação e treinamento dos métodos de *forecasting*, direcionado aos responsáveis pela elaboração de previsões, incluindo a análise de

investimento para formação e manutenção de profissionais especializados em previsões (forecasters) nas concessionárias.

REFERÊNCIAS

- AHADIAT, N. Sales Forecasting and Cash Budgeting for Automotive Dealerships. *Journal of Business Forecasting Methods & Systems*, v. 11, n. 3, p. 17-23, Fall, 1992.
- AKAIKE, H. Information Theory and a Extension of the Maximum Likelihood Principle. *Second International Symposium on Information Theory*. Budapest: B.N. Petrov & F. Csaki Eds., Akademia Kaido, p. 267-281, 1973.
- ARBIX, G.; VEIGA, J. P. C. Distribuição de Veículos sob Fogo Cruzado. Em busca de um Novo Equilíbrio de Poder no Setor Automotivo. *On line web page*: <http://www.tela.com.br/html/montadoras.htm>. Artigo capturado em 28 de junho de 2003.
- ARMSTRONG, J. S. Extrapolation for Time Series and Cross-Sectional Data. *Principles of Forecasting: a Handbook for Researchers and Practitioners*. Philadelphia: Kluwer, 2001.
- ARMSTRONG, J. S.; MORWITZ, V. G. & KUMAR, V. Sales Forecasts for Existing Products and Services: Do Purchase Intentions Contribute to Accuracy? *International Journal of Forecasting*, v. 16, p. 383-397, 2000.
- BOX, G. E. P.; JENKINS, G. M. *Time Series Analysis – Forecasting and Control*. USA: Holden-Day, Revised Edition, 1976.
- CAVANAUGH, J. E. Unifying the Derivations for the Akaike and Corrected Akaike Information Criteria. *Statistics & Probability Letters*, v. 33, p. 201-208, 1997.
- DURAND, P.; WUJCIAK, M.; KUGLIN, F. & WILSON, C. Creating and Leading the Adaptative Automotive Enterprise. Reshuffling the Global Automotive Leadership. *Cap Gemini & Ernst Young CEO Position Paper*. *On line web page*: <http://www.cgey.com>. Artigo capturado em 22 de novembro de 2002.
- ELIKAI, F.; HALL JR., W. & ELIKAI, P. Managing and Improving the Forecasting Process. *Journal of Business Forecasting Methods & Systems*, v. 18, n. 1, p. 15-19, Spring, 1999.
- ELSAYED, E. A.; BOUCHER, T. O. *Analysis and Control of Production Systems*. New Jersey: Prentice Hall, 2nd Ed., 1994.
- PINTO FILHO, J. S. Previsão de Vendas de Veículos Novos em Concessionárias da Grande Vitória. Dissertação de Mestrado. Universidade Federal de Minas Gerais / Faculdade de Ciências Econômicas / Centro de Pós-Graduação e Pesquisa em Administração. Belo Horizonte – MG, 2000.
- GILLILAND, M.; PRINCE, D. New Approaches to “Unforecastable” Demand. *Journal of Business Forecasting Methods & Systems*, v. 20, n. 2, p. 9-12, Summer, 2001.

GOODWIN, P. Integrating Management Judgment and Statistical Methods to Improve Short-term Forecasts. *International Journal of Management Science*, v. 30, p. 127-135, 2002.

GOODWIN, P.; WRIGHT, G. Improving Judgmental Time Series Forecasting: A Review of the Guidance Provided by Research. *International Journal of Forecasting*, v. 9, p. 147-161, 1993.

GEURTS, D. M.; WHITLARK, B. D. Six Ways to Make Sales Forecasts More Accurate. *Journal of Business Forecasting Methods & Systems*, v. 18, n. 4, p. 21-24, 2000.

GUPTA, U. G.; CLARKE, R. E. Theory and Applications of the Delphi Technique: A Bibliography (1975 – 1994). *Technological Forecasting and Social Change*, v. 53, p. 185-211, 1996.

HERZT, S.; JOHANSSON, J. & JAGER, F. Customer-oriented Cost Cutting: Process Management at Volvo. *International Journal of Supply Chain Management*, v. 6, n. 3, p. 128-141, 2001.

HOLMSTRÖM, J. Handling Product Range Complexity. A Case Study on Re-engineering Demand Forecasting. *Business Process Management Journal*, v. 4, n. 3, p. 241-258, 1998.

HOLWEG, M.; MIEMCZYK, J. Logistics in the “Three-day car” Age. Assessing the Responsiveness of Vehicle Distribution Logistics in UK. *International Journal of Physical Distribution & Logistics Management*, v. 32, n. 10, p. 829-850, 2002.

ISMAIL, Z. H.; AHAMAD, M. H. Delphi Improves Sales Forecasts: Malaysia’s Electronic Companies’ Experience. *Journal of Business Forecasting Methods & Systems*, v. 22, n. 2, p. 22-25, Summer, 2003.

JAIN, C. L. Forecasting Practices in Corporate America. *Journal of Business Forecasting Methods & Systems*, v. 20, n. 2, p. 2-4, Summer, 2001.

JOHNSON, R. A.; WICHERN, D. W. *Applied Multivariate Statistical Analysis*. Englewood N.J: Prentice Hall Inc., 2nd Ed., 1982.

KAYO, E. K.; SECURATO, J. R. Método Delphi: Fundamentos, Críticas e Vieses. Universidade de São Paulo / Faculdade de Economia, Administração e Contabilidade / Cadernos de Pesquisas em Administração, v. 1, n. 4, p. 51-61, 1997.

KRAJEWSKI, L. J.; RITZMAN, L. P. *Operations Management, Strategy and Analysis*. MA: Addison-Wesley, Reading, 5th Ed., 1999.

LAPA, T. M. Modelagem Dinâmica para a Previsão da Demanda de Automóveis no Brasil. Dissertação de Mestrado. Universidade Federal de Santa Catarina / Departamento de Engenharia de Produção e Sistemas / Programa de Pós-Graduação em Engenharia de Produção. Florianópolis – SC, 1998.

LEE, M.; ELANGO, B. & SCHNAARS, S. P. The Accuracy of the Conference Board's Buying Plans Index: A Comparison of Judgmental vs. Extrapolation Forecasting Methods. *International Journal of Forecasting*, v. 13, p. 127-135, 1997.

LJUNG, G. M.; BOX, G. E. P. On a Measure of Lack of Fit in Time Series Models. *Biometrika*, v. 65, n. 2, p. 297-303, August, 1978.

LIM, C.; McALEER, M. Time Series Forecasts of International Tourism Demand for Australia. *Osaka University. The Institute of Social and Economic Research. Discussion Paper n. 533*, April, 2001.

LINES, A. H. Forecasting – Key to Good Service at Low Cost. *Logistics Information Management*, v. 9, n. 4, p. 24-27, 1996.

LOPES, R. D. Previsão de Autopeças: Estudo de Caso em Uma Concessionária de Veículos. Dissertação de Mestrado. Universidade Federal de Santa Catarina / Departamento de Engenharia de Produção e Sistemas / Programa de Pós-Graduação em Engenharia de Produção. Florianópolis – SC, 2002.

LOUDIN, A. Forecasting the Future. *Warehousing Management*, v. 7, n. 4, p. 34-36, May, 2000.

McCOY, W. R. Computer Competencies for the 21st Century Information System Educator. *Information Technology, Learning and Performance Journal*, v. 19, n. 2, p. 21-35, Fall, 2001.

MAKRIDAKIS, S.; HIBON, M. ARMA Models and the Box-Jenkins Methodology. *Journal of Forecasting*, v. 16, p. 147-163, 1997.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C. & HYNDMAN, R. J. *Forecasting – Methods and Applications*. New York: John Wiley, 3rd Ed., 1998.

MONTGOMERY, D. C.; JOHNSON, L. A. & GARDINER, J. S. *Forecasting and Time Series Analysis*. New York: McGraw-Hill, Inc, 2nd Ed., 1990.

MORETTIN, P. A.; TOLOI, C. M. C. *Previsão de Séries Temporais*. São Paulo: Atual, 1985.

O'BRIEN, L. Stepping on the Gas. *Supply Management*, p. 32-33, Jan 4, 2001.

O'CONNOR, M.; REMUS, W. & GRIGGS, K. Judgmental Forecasting in Times of Change. *International Journal of Forecasting*, v. 9, p. 163-172, 1993.

OLIVEIRA, G. A., Sistema de Controle e Otimização de Estoques Utilizando a Metodologia Box & Jenkins para Séries Temporais. Dissertação de Mestrado. Universidade Federal do Paraná / Departamento de Matemática / Programa de Pós-Graduação em Métodos Numéricos em Engenharia. Curitiba – PR, 2002.

PELLEGRINI, F. R. Uma Metodologia para Implementação de Sistemas de Previsão de Demanda. Dissertação de Mestrado. Universidade Federal do Rio Grande do Sul / Escola de Engenharia / Programa de Pós-Graduação em Engenharia de Produção. Porto Alegre – RS, 2000.

RAMOS, E. S.; KONRATH, A. C. & SAMOHYL, R. W. Previsão em MRP usando a Transformação de Box-Cox através do Aplicativo GLIM, com Aplicação. Anais ENEGEP, XXI, Salvador –BA, 2001.

ROWE, G.; WRIGHT, G. The Delphi Technique as a Forecasting Tool: Issues and Analysis. *International Journal of Forecasting*, v. 15, p. 353-375, 1999.

SANDERS, N. R.; MANRODT, K. B. Forecasting Practices in US Corporations: Survey Results. *Interfaces*, vol. 24, no. 2, pp. 92-100, 1994.

SANDERS, N. R.; RITZMAN, L. P. Judgmental Adjustment of Statistical Forecasts. In: Armstrong, J. S., editor. *Principles of Forecasting: a Handbook for Researchers and Practitioners*. Massachusetts: Kluwer, Academic Publishers, p. 405-416, 2001.

SANDERS, N. R. Managing the Forecasting Function. *Industrial Management & Data Systems*, v. 95, n. 4, p. 12-18, 1995.

SANDERS, N. R. Measuring Forecast Accuracy: Some Practical Suggestions. *Production and Inventory Management Journal*, v. 38, n. 1, p. 43-46, 1997.

TANWARI, A. U.; BETTS, J. Impact of Forecasting on Demand Planning. *Production and Inventory Management Journal*, v. 40, n. 3, p. 31-35, 1999.

TIDESWELL, C.; MULES, T. & FAULKNER, B. An Integrative Approach to Tourism Forecasting: a Glance in the Rearview Mirror. *Journal of Travel Research*, v. 40, n. 2, p. 162-171, 2001.

TRENTIN, M. G., Planejamento Estratégico de Estoques: Uma Aplicação dos Métodos Automáticos de Previsão de Séries Temporais. Dissertação de Mestrado. Universidade Federal do Paraná / Departamento de Matemática / Programa de Pós-Graduação em Métodos Numéricos em Engenharia. Curitiba – PR, 2002.

WILLIAMS, D. W.; MILLER, D. Level-Adjusted Exponential Smoothing for Modeling Planned Discontinuities. *International Journal of Forecasting*, v. 15, p. 273-289, 1999.

WOLD, H. O. *A Study in the Analysis of Stationary Time Series*. Uppsala: Almqvist and Wicksell, 1938 (2nd Ed. 1954).

WRIGHT, J. T. C.; GIOVINAZZO, R. A. Delphi – Uma Ferramenta de Apoio ao Planejamento Prospectivo. Universidade de São Paulo / Faculdade de Economia, Administração e Contabilidade / Cadernos de Pesquisas em Administração. v. 1, n. 12, p. 55-65, 2000.

ZHOU, W. Integration of Different Forecasting Models. *Journal of Business Forecasting Methods & Systems*, v. 18, n. 3, p. 26-28, Fall, 1999.