

COMBINAÇÃO DE PREVISÕES EM SÉRIES TEMPORAIS: APLICAÇÃO EM
DEMANDA DE COMBUSTÍVEIS

Victor Santos Raposo

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS
PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE
FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS
PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA DE
PRODUÇÃO.

Aprovada por:

Prof. Basílio de Bragança Pereira, Ph.D.

Prof. Carlos Patrício Samanez, D.Sc.

Prof. Virgilio José Martins Ferreira Filho, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

AGOSTO DE 2006

RAPOSO, VICTOR SANTOS

Combinação de Previsões em Séries
Temporais: Aplicação em Demanda de
Combustíveis [Rio de Janeiro] 2006

X, 62 p. 29,7 cm (COPPE/UFRJ,
M.Sc., Engenharia de Produção, 2006)

Dissertação - Universidade Federal do
Rio de Janeiro, COPPE

1. Análise de Séries Temporais

I. COPPE/UFRJ II. Título (série)

A meus pais, namorada, irmãos, amigos, colegas de profissão e colaboradores.

Meus agradecimentos

- Ao Professor Basílio de Bragança Pereira, orientador da dissertação de mestrado, pelo apoio e confiança depositados.
- Ao doutor e irmão Gustavo Raposo, pelo apoio, orientação e estímulo.
- Ao amigo Paulo Ferri, gerente de instalações da Shell Brasil Ltda, pelo suporte concedido no desenvolvimento da pesquisa.
- Aos meus pais, pelo incentivo.
- À Mariana Goulart, por todo o carinho e compreensão.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

COMBINAÇÃO DE PREVISÕES EM SÉRIES TEMPORAIS: APLICAÇÃO EM
DEMANDA DE COMBUSTÍVEIS

Victor Santos Raposo

Agosto/2006

Orientador: Basílio de Bragança Pereira

Programa: Engenharia de Produção

O presente trabalho visa estabelecer um arcabouço analítico para previsão de demanda de combustíveis baseada no emprego de modelos de séries temporais. Para tal, utilizou-se um estudo de caso real de uma distribuidora de combustíveis no Brasil, em busca de otimizar a performance de suas previsões de vendas de combustíveis.

Baseado na literatura técnica sobre a questão, diferentes abordagens em análises de séries temporais são apresentadas e discutidas em detalhes. O trabalho busca dar foco a três metodologias básicas, que são os modelos de: Box e Jenkins, Holt Winters e Combinação de Previsões.

Como principais objetivos do trabalho, podemos destacar: (i) o suporte na tomada de decisão sobre qual modelo melhor se ajusta ao caso estudado e (ii) a comparação dos resultados encontrados empregando os modelos propostos com aqueles obtidos pela distribuidora.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

COMBINED FORECASTING OF TIME SERIES: APPLICATION ON OIL
DEMAND

Victor Santos Raposo

August/2006

Advisor: Basílio de Bragança Pereira

Department: Industrial Engineering

This work presents an analytical approach for Oil Demand forecasting based on time series models. For this task, a real case of Oil Company in Brazil is analyzed, in order to enhance its forecasting performance.

Based on technical literature over the subject, different approaches on time series analysis are presented and discussed in further details. This work focuses on three basic methodologies, as follows: Box and Jenkins, Holt Winters and Combined Forecasting models.

It is possible to highlight as the main objectives of this work: (i) the support on decision making process concerning which model best fits the real case study, and (ii) the evaluation regarding the results obtained using the proposed models and the current results of the Oil Company as a base line.

ÍNDICE DO TEXTO

| | |
|--|----|
| 1 Introdução | 01 |
| 1.1 Relevância do Tema | 01 |
| 1.2 Estrutura do Trabalho | 03 |
| 2 O Mercado de Distribuição de Combustíveis no Brasil | 05 |
| 2.1 Introdução | 05 |
| 2.2 Análise do Mercado | 09 |
| 2.2.1 Presença de Concorrentes | 09 |
| 2.2.2 Localização Geográfica | 12 |
| 2.2.3 Cadeia de Suprimentos e Distribuidoras | 13 |
| 3 Métodos de Previsão | 15 |
| 3.1 Modelos Box e Jenkins | 15 |
| 3.1.1 Processo Estocástico e Série Temporal | 15 |
| 3.1.2 Estacionariedade e Ergodicidade | 16 |
| 3.1.3 Modelos de Box e Jenkins | 17 |
| 3.1.4 Modelos Box e Jenkins: Formulação Geral | 18 |
| 3.1.5 Casos Particulares | 19 |
| 3.2 Amortecimento Exponencial (Modelos Holt Winters) | 21 |
| 3.2.1 Modelos para Nível Constante (Amortecimento Simples) | 23 |
| 3.2.2 Modelos Holt Winters para Tendência Linear | 23 |
| 3.2.3 Modelos para Tendência Não-Linear | 24 |
| 3.3 Método de Combinação de Previsões | 26 |
| 3.3.1 Formas de Combinação | 28 |

| | | |
|-------|--|----|
| 4 | Estudo de Caso: Modelo de Previsão Distribuidora | 31 |
| 4.1 | Introdução | 31 |
| 4.2 | Modelo de Previsão Distribuidora | 32 |
| 5 | Estudo de Caso: Modelos Propostos | 36 |
| 5.1 | Base: Duque de Caxias/RJ | 37 |
| 5.1.1 | Modelo Box e Jenkins | 37 |
| 5.1.2 | Holt Winters | 41 |
| 5.1.3 | Combinação de Previsões | 42 |
| 5.1.4 | Resultados Encontrados | 43 |
| 5.2 | Base: Suape/PE | 49 |
| 5.2.1 | Resultados Encontrados | 50 |
| 5.3 | Base: Brasília/DF | 53 |
| 5.3.1 | Resultados Encontrados | 53 |
| 6 | Conclusão e Considerações Finais | 56 |
| 6.1 | Conclusão | 56 |
| 6.2 | Ganhos Potencias | 59 |
| 6.3 | Sugestões de Desenvolvimentos Futuros | 60 |
| 7 | Referências Bibliográficas | 61 |

ÍNDICE DE FIGURAS

| | |
|---|----|
| Figura 1: Malha Logística do Brasil | 08 |
| Figura 2: Análise do Mercado de Distribuição | 10 |
| Figura 3: Mapa das Refinarias do Brasil | 11 |
| Figura 4: Cadeia de Suprimento das Distribuidoras | 13 |
| Figura 5: Modelo de Previsão Distribuidora | 33 |
| Figura 6: Análises Série Original e Série Diferenciada | 38 |
| Figura 7: Análises Série Vendas por Dia e Série Vendas por Dia Diferenciada | 39 |
| Figura 8: Análises Série Ajuste Calendário e Série Ajuste Calendário Diferenciada | 40 |
| Figura 9: Análise dos Resíduos (Box e Jenkins) | 41 |
| Figura 10: Análise dos Resíduos (Holt Winters) | 42 |
| Figura 11: Método de Combinação de Previsões | 43 |

ÍNDICE DE TABELAS

| | |
|--|----|
| Tabela 1: Notação Amortecimento Exponencial | 22 |
| Tabela 2: Modelos de Nível Constante | 23 |
| Tabela 3: Modelos de Tendência Linear | 24 |
| Tabela 4: Modelos de Tendência exponencial | 25 |
| Tabela 5: Modelos de Tendência Amortecida | 26 |
| Tabela 6: MAPE - Base de Duque de Caxias/RJ | 45 |
| Tabela 7: MSE - Base de Duque de Caxias/RJ | 45 |
| Tabela 8: Vendas Reais x Modelos | 46 |
| Tabela 9: Análise Comparativa Modelos - Erro Absoluto | 47 |
| Tabela 10: Análise Comparativa de Modelos - MAPE | 48 |
| Tabela 11: MAPE II - Base de Duque de Caxias/RJ | 49 |
| Tabela 12: MSE II - Base de Duque de Caxias/RJ | 49 |
| Tabela 13: MAPE - Base de Suape/PE | 51 |
| Tabela 14: MSE - Base de Suape/PE | 51 |
| Tabela 15: MAPE II - Base de Suape/PE | 52 |
| Tabela 16: MSE II - Base de Suape/PE | 52 |
| Tabela 17: MAPE - Base de Brasília/DF | 53 |
| Tabela 18: MSE - Base de Brasília/DF | 54 |
| Tabela 19: MAPE II - Base de Brasília/DF | 55 |
| Tabela 20: MSE II - Base de Brasília/DF | 55 |
| Tabela 21: Desempenho dos Modelos Teóricos de Previsão de Séries Temporais | 57 |
| Tabela 22: Combinação de Previsões (Holt Winters, Box e Jenkins e Distribuidora) | 58 |

1 Introdução

1.1 - Relevância do Tema

O mercado de distribuição de combustíveis e derivados de petróleo no Brasil sofreu, na última década, a reestruturação de seu modelo regulatório, em especial após 1997, com a implementação da Lei do Petróleo e criação da ANP, o que acarretou profundas mudanças na conjuntura do mesmo.

Com a entrada de novos concorrentes e abertura do mercado, verificou-se a necessidade de ganho logístico cada vez maior e otimização do capital empregado, visto que a competitividade se tornou muito mais acirrada.

Dentro desse contexto, as companhias que já participavam do mercado de distribuição viram suas margens de lucro diminuir significativamente, o que as fez buscar alternativas imediatas para rentabilizar seus ativos como antes.

O montante de capital empregado em estoque de produtos, principalmente considerando a extensão e particularidades geográficas do Brasil, é, sem dúvida, o aspecto de maior relevância em termos de alavancagem financeira das distribuidoras de combustíveis atuantes no mercado brasileiro. Os estoques físicos de produtos representam, para uma distribuidora de atuação nacional, a maior parcela de todo o capital empregado no negócio.

Além das distribuidoras, os fornecedores também passaram a otimizar suas operações na área de suprimento e abastecimento. Neste contexto, cabe lembrar que no Brasil a

Petrobras¹ detém 87,4% de participação no mercado nacional de gasolinas automotivas e 98,8% no de óleo diesel².

A Petrobras, ao longo dos últimos anos, vem buscando otimizar suas operações de suprimento e abastecimento, através de um planejamento estruturado que passa, acima de tudo, pela necessidade de aumentar a acurácia na previsão e atendimento de sua demanda. Assim, através de regras pré-estabelecidas nos contratos de fornecimento, busca premiar a acurácia dos pedidos de seus clientes (distribuidoras), penalizando-os no caso de não cumprimento destes. A precisão na demanda garante a estratégia integrada da empresa, desde a produção, importação e exportação, passando pelo planejamento do parque de refino e chegando à logística de transporte e disponibilização dos produtos para comercialização.

Neste quadro, as distribuidoras se vêem obrigadas a controlar a dinâmica de compra de produtos junto à Petrobras, diante das regras particulares dos contratos desta natureza, nos quais a precisão e acurácia dos pedidos podem representar diferencial competitivo fundamental para as mesmas.

O presente trabalho se propõe a modelar a previsão de demanda de um caso real de uma distribuidora, através do emprego de análises de séries temporais, em particular os modelos de Box e Jenkins, amortecimento exponencial e combinação de previsões, visando estabelecer um arcabouço analítico para previsão da demanda futura, bem como análise de características, tais como tendência e sazonalidade.

Assim sendo, procurar-se-á responder algumas perguntas. São elas:

¹ Petrobras: Petróleo Brasileiro S.A.

² Segundo Balanço Social de 2004, divulgado no site oficial da empresa (www.petrobras.com.br)

- O modelo proposto para análise das previsões de vendas das distribuidoras se mostra robusto?
- Quais as características destas séries históricas de vendas?
- A modelagem proposta no presente trabalho pode aumentar a precisão e acurácia na previsão futura de demanda? Qual seria o ganho financeiro com o uso deste modelo?

Para tal, foi realizado um levantamento bibliográfico que trata dos principais trabalhos existentes, tanto no que diz respeito à análise de séries temporais, quanto no que tange à dinâmica de comercialização de produtos derivados no Brasil e seu processo de otimização.

Dentre as principais metas do trabalho, destacam-se:

- Entender a dinâmica do processo de previsão de demanda para um estudo de caso real de uma distribuidora de combustíveis e derivados de petróleo;
- Propor abordagem teórica para análise das séries históricas de vendas para a empresa objeto do estudo;
- Analisar e comparar resultados obtidos;
- Otimizar, através da combinação dos métodos apresentados, os resultados da previsão de demanda futura da empresa analisada.

1.2 - Estrutura do Trabalho

O presente trabalho está dividido em seis partes. A primeira apresenta uma breve introdução ao tema, onde são estabelecidos as principais metas e objetivos do estudo. Em seguida, no segundo capítulo, são apresentadas de maneira sucinta as principais

características do mercado de distribuição de derivados de petróleo no Brasil, seu atual cenário e a cronologia das modificações de maior importância ocorridas, que impactarão na pertinência e relevância do tema abordado.

No terceiro capítulo, são apresentadas as principais características dos métodos de previsão com uso de séries temporais que serão empregados no trabalho, respectivamente, os modelos de Box e Jenkins, Holt Winters, além de método de combinação de previsões; ilustrando aspectos inerentes às fases de identificação e estimação dos parâmetros e considerando fatores de tendência e sazonalidade.

No capítulo seguinte, é apresentado estudo de caso real, considerando uma distribuidora de combustíveis e derivados. Nele será detalhado o modelo de previsão atualmente empregado pela distribuidora em questão.

No quinto capítulo, os modelos de previsão aqui propostos são implementados para o caso em estudo. Neste é realizada uma análise comparativa dos resultados encontrados com utilização dos modelos teóricos propostos, buscando-se otimizar o processo de previsão de demanda da distribuidora.

A última parte é dedicada aos comentários finais e conclusões do estudo, onde são apontadas as linhas de pesquisa a serem seguidas para continuidade do tema.

2 O Mercado de Distribuição de Combustíveis no Brasil

2.1 - Introdução

Como já foi comentado, o segmento de distribuição de derivados de petróleo tem apresentado uma competitividade cada vez maior, advinda da abertura do mercado promovida principalmente durante o governo do presidente Fernando Henrique Cardoso (1994-2002), com o objetivo de instaurar a livre concorrência e proteger os interesses do consumidor quanto a preço, qualidade e oferta dos produtos. Abaixo, está apresentado cronologicamente o histórico do mercado brasileiro de distribuição na última década, englobando as principais mudanças ocorridas no setor.

- 1990:
 - ✓ Facilidades para abertura de postos;
 - ✓ Preços nos postos passam a ser máximos (instauração de tetos por produto).
- 1991:
 - ✓ Preços nos postos diferenciados no país.
- 1993:
 - ✓ Facilidades para novas distribuidoras (mais de 400 se registram);
 - ✓ Autorizado posto de bandeira branca.
- 1994:
 - ✓ Combustíveis aditivados com preços diferenciados.
- 1996:
 - ✓ Liberação dos preços da gasolina e do álcool nos postos.

- 1997:
 - ✓ Lei do Petróleo;
 - ✓ Criação da ANP;
 - ✓ Fim do vínculo à bandeira.
- 1998:
 - ✓ Preço da refinaria vinculado ao mercado internacional.
- 2000:
 - ✓ Prorrogada para 2002 a liberação do mercado;
 - ✓ Autorizada a produção de gasolina das Centrais Petroquímicas;
 - ✓ Volta do vínculo à bandeira.
- 2001:
 - ✓ Liberação do preço do diesel nos postos;
 - ✓ Reforma tributária dos combustíveis.
- 2002:
 - ✓ Liberação do mercado (preço livre nas refinarias);
 - ✓ Importação de gasolina e diesel liberada.

Diante das inúmeras mudanças ocorridas na última década, o mercado passou a se comportar de maneira diferente, onde a posição de uma empresa na cadeia, agora muito mais complexa, é fator fundamental para sua sobrevivência. Dois belos exemplos disto são a liberação de produção da gasolina nas CPQs (Centrais Petroquímicas) e a liberação de postos de bandeira branca. Com as CPQs produzindo gasolina, aumentou a concorrência de oferta deste produto no mercado, fazendo com que as distribuidoras

tenham mais opções nesta negociação e ganhem competitividade. Já na outra ponta da cadeia, com a liberação de postos de bandeira branca, empresários presentes neste setor aumentaram significativamente seu poder de barganha junto às grandes distribuidoras, pois estas se viram obrigadas a reconsiderar algumas condições em seus contratos de CVM³ para não reduzir sua participação (*market-share*). Isto é, postos que utilizam a imagem de uma grande distribuidora e que estavam obrigados a adquirir produtos apenas desta, passam a ter uma condição de negociação diferenciada, já que têm opção de se desvincular desta distribuidora e comprar da que mais lhe convier.

Por ser um país continental e dotado de condições geográficas específicas em diferentes regiões, o Brasil detém uma particular malha logística e infra-estrutura instalada, que visam garantir o atendimento à demanda energética do país e sua expansão. Apesar de estar distante dos grandes centros consumidores, a região norte, por exemplo, é fundamental no processo de distribuição, pois possui a bacia do Amazonas, que produz uma quantidade relevante de petróleo, e uma refinaria da Petrobras (REMAN). Estes fatores são fundamentais para a implantação de um ponto de fornecimento, pois a indústria da região cresce devido a ganhos logísticos e, conseqüentemente, atraem os interesses das distribuidoras.

A seguir, será ilustrado mapa da cadeia logística de distribuição de combustíveis e derivados de petróleo no Brasil:

³ CVM: Contrato de Venda de Mercadoria. Neste tipo de contrato, as grandes distribuidoras financiam os investimentos de novos postos e cedem sua imagem, em troca da monopolização de fornecimento de seus produtos por um prazo estipulado e condições particulares.

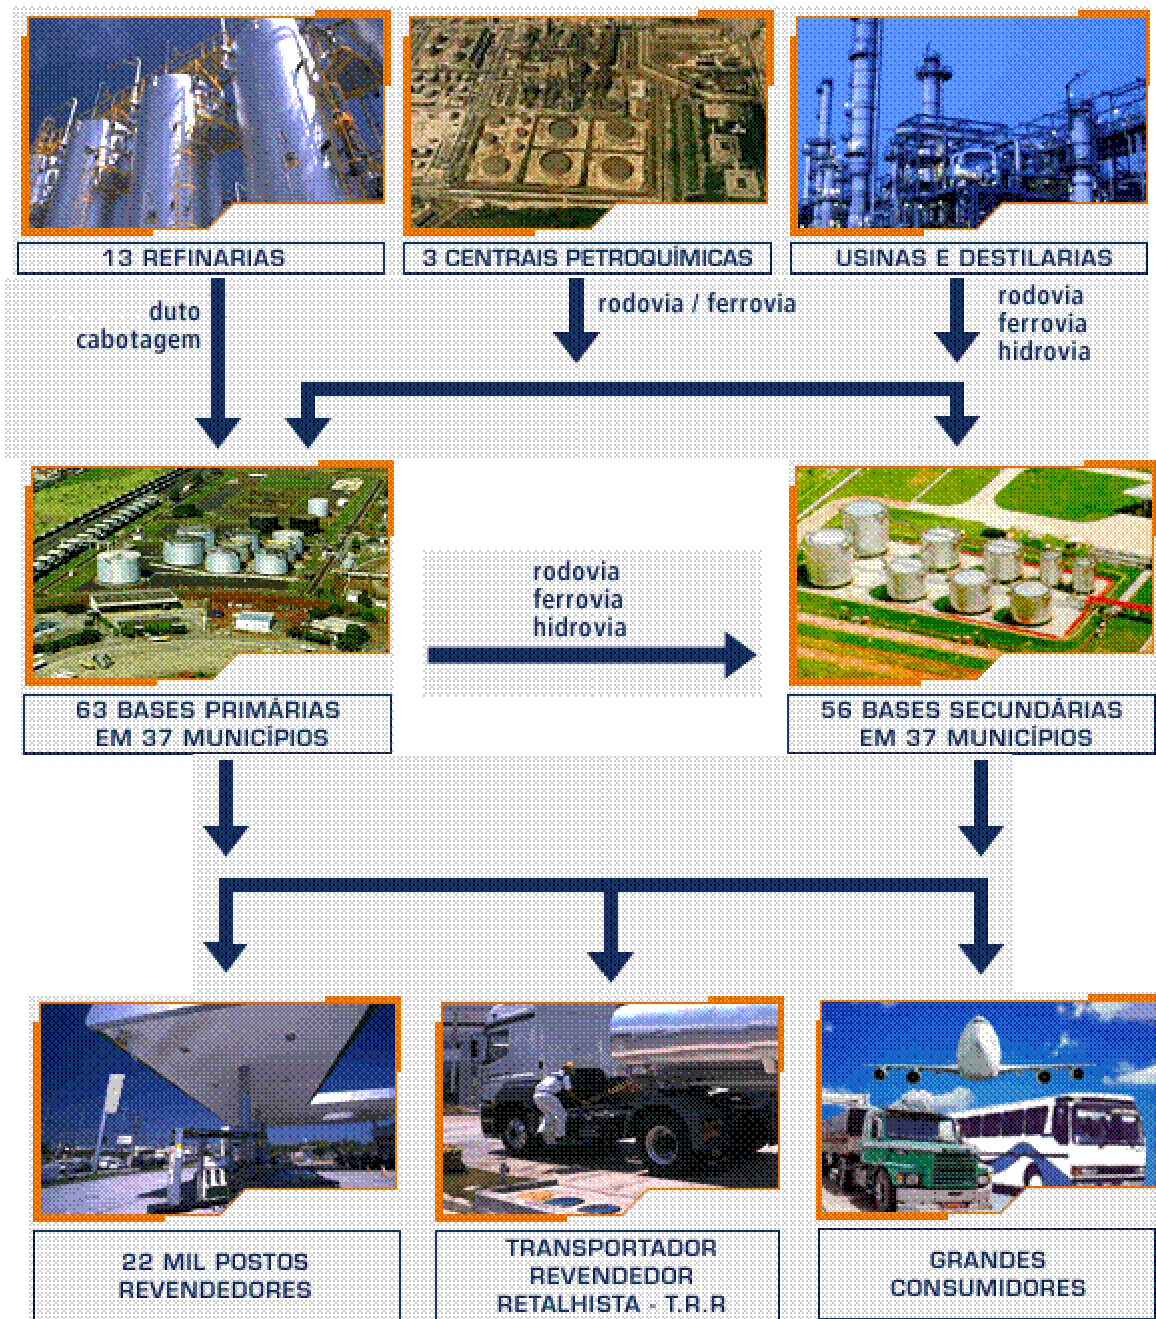


Figura 1: Malha Logística do Brasil - Fonte: Sindicom

Analisando o mapa, é possível perceber a diversidade de modais utilizados no Brasil e o elevado número de bases de distribuição existentes. As bases são divididas em primárias (que recebem produtos diretamente da refinaria) e secundárias (que recebem

produtos transferidos de outras bases de distribuição). Outro ponto interessante é a diversidade de nichos de clientes, desde os tradicionais postos revendedores até grandes clientes consumidores, como companhias aéreas e grandes indústrias.

2.2 - Análise do Mercado

Face à maior competitividade existente no mercado nacional de distribuição, principalmente após a abertura do mercado promovida pela ANP, as empresas distribuidoras passaram a utilizar ferramentas de mercado para resguardar seus interesses e maximizar sua participação no mercado.

Analisando este cenário, os gestores devem levar em consideração importantes aspectos que afetam a posição de sua empresa perante o mercado, como a presença de concorrentes, a importância logística da região, entre outros. A seguir, será apresentada análise de mercado, do ponto de vista dos gestores de negócio das empresas distribuidoras.

2.2.1 - Presença de Concorrentes

Analisando a concorrência sob a ótica das 5 forças citadas por PORTER (1986), podemos ilustrar o mercado de distribuição e identificar seus participantes:

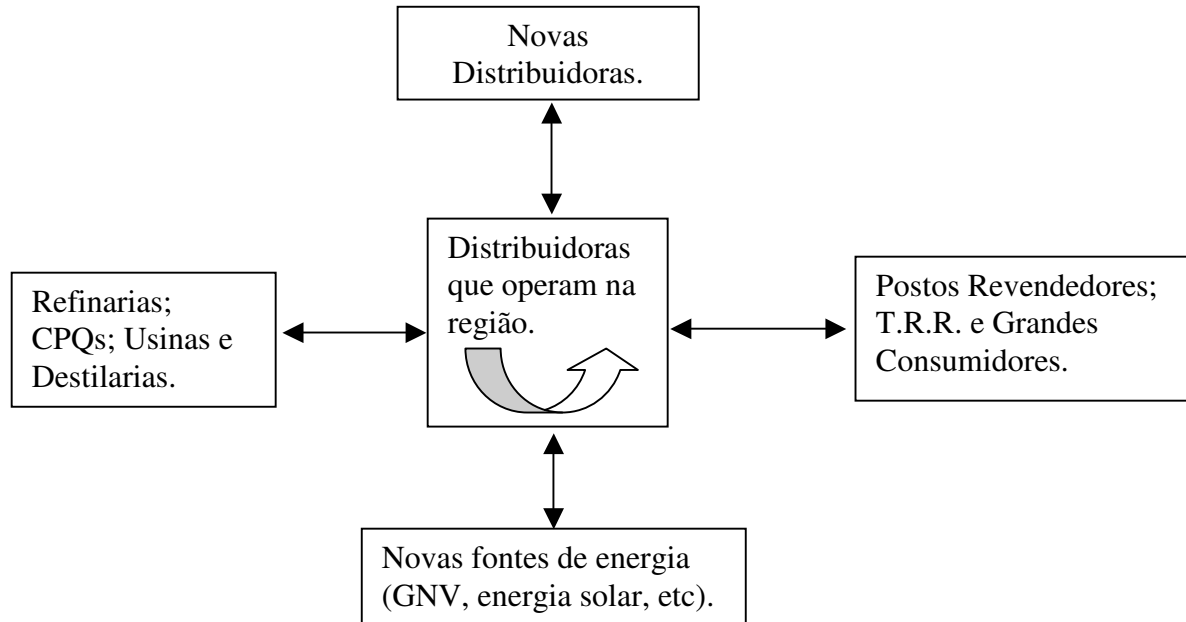


Figura 2: Análise do Mercado de Distribuição

- Relação com os fornecedores - Cabe à distribuidora negociar condições de compra com a Petrobrás (refinarias) e com as usinas de álcool, de forma a estabelecer condições mais atrativas para seu negócio nos diferentes aspectos, como prazo, preço, pontos de fornecimento, quantidades demandadas, entre outras condições particulares, tais como, benefícios fiscais em compras interestaduais⁴ e diluição de acúmulo de créditos fiscais.

O parque de refino hoje, no Brasil, conta com 13 plantas, sendo 11 pertencentes à Petrobrás, o que representa mais de 95% da capacidade instalada total. Isto significa que a Petrobrás, na prática, ainda determina os preços utilizados na cadeia. Há planos de

⁴ Algumas operações de comercialização contam com alíquotas diferenciadas de impostos para incentivo à mesma.

expansão do parque de refino brasileiro, tendo em vista a projeção da produção do óleo nacional, porém esta expansão requer elevados investimentos, o que dificulta o processo.

A Petrobrás utiliza a chamada política de *import parity* em sua prática de preços, atuando de forma protecionista, no sentido de fixar valores um pouco abaixo do custo de se importar o produto.

Segue abaixo mapa ilustrando a estrutura do parque de refino brasileiro:



Figura 3: Mapa das Refinarias do Brasil - Fonte: Sindicom

- Relação com os compradores - A distribuidora atua junto aos postos e demais clientes, sendo a prática de preços determinada pela eficiência de toda a cadeia (preço = custo do produto + custo operacional + impostos + margem).

- Ameaça de substitutos - Novas fontes de energia tendem a impactar o mercado de distribuição de combustíveis no longo prazo, porém ações e reposicionamento estratégico já são pontos importantes a serem considerados.

Um bom exemplo de produto substituto é o GNV (Gás Natural Veicular), que apesar de atualmente não impactar significativamente na cadeia, vem crescendo exponencialmente e seu uso, como combustível, apresenta inúmeras vantagens frente aos combustíveis convencionais (não poluente, mais barato e com um processamento muito menos complexo).

- Entrantes potenciais - A ameaça da entrada de novas distribuidoras, que possam ganhar mercado e impactar significativamente o equilíbrio da indústria já presente, torna-se cada vez mais real no contexto atual. A própria natureza do negócio de distribuição pode representar uma barreira natural à entrada de novos participantes, já que exige altos investimentos, principalmente no que tange à infra-estrutura operacional (bases operacionais, transporte dos produtos, elevado capital de giro, entre outros).

- Concorrentes na indústria - As distribuidoras que operam em determinada região sofrem os efeitos diretos da competitividade e da disputa de mercado. O mercado abrange inúmeras distribuidoras, principalmente nas regiões Sul e Sudeste, nas quais a demanda é maior e as alternativas logísticas são mais abrangentes.

2.2.2 - Localização Geográfica

O estudo da localização é fundamental para empresas que procuram as maiores vantagens em termos de custos e receitas, além de desequilíbrios regionais que porventura aconteçam. A localização de uma base operacional deve ser estudada em

escala regional, tendo em vista a abrangência da utilidade da mesma e seu porte. Aspectos como custos de transporte, diferenciais de custos de suprimentos e de mão-de-obra e acessos aos mercados são fundamentais para uma tomada de decisão desta ordem, como observado por CLEMENTE *et al.* (1998). A área logística de uma distribuidora tem que estar muito atenta a essas diversas variáveis, de forma a entender e prever o comportamento da demanda da região em estudo e confrontar com os custos inerentes à operação.

2.2.3 - Cadeia de Suprimentos e Distribuidoras

As distribuidoras são elos fundamentais da cadeia de fornecimento, na medida em que as mesmas são responsáveis por garantir a entrega do produto ao cliente da melhor maneira possível, do ponto de vista logístico. Os grandes grupos de clientes das mesmas são: postos revendedores (varejo), T.R.R. (retalhistas), grandes consumidores (companhias aéreas, transportadoras, indústrias, etc).

A seguir ilustraremos a cadeia de suprimentos na qual a distribuidora está inserida.

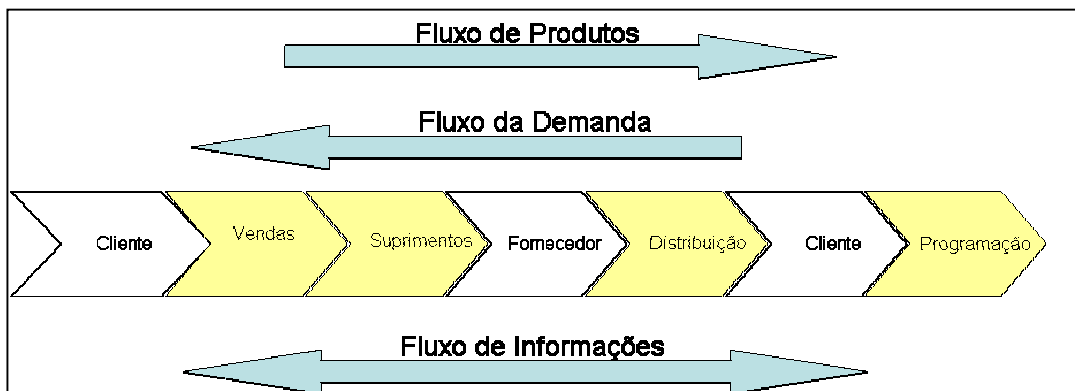


Figura 4: Cadeia de Suprimento das Distribuidoras

Área de Vendas – Responsável pela previsão da demanda (estimativa de vendas).

Área de Suprimentos – Responsável pela compra de produtos junto aos fornecedores.

Área de Distribuição – Responsável por armazenar e distribuir aos clientes.

Área de Programação – Responsável por receber os pedidos dos clientes e programar as entregas.

3 Métodos de Previsão

3.1 - Modelos Box e Jenkins

A teoria de análise de séries temporais, em particular os modelos ARIMA Box-Jenkins, permite a modelagem de variáveis de interesse, a partir da formulação explícita da dependência linear apresentada pelas mesmas.

Os principais objetivos da análise de séries temporais são:

- a) **Descrição:** inicia-se a análise de séries temporais com a construção de um gráfico mostrando como o fenômeno evolui no tempo. Obtém-se também medidas descritivas simples de suas principais características.
- b) **Explicação:** tendo-se um conjunto de observações de duas ou mais variáveis, pode ser possível explicar o comportamento de uma em função das demais.
- c) **Previsão:** a previsão do comportamento futuro da variável constitui um dos principais objetivos da análise de séries temporais.
- d) **Controle:** controlar o processo gerador da série temporal.

3.1.1 - Processo Estocástico e Série Temporal

Um modelo que descreva a estrutura de probabilidade de uma seqüência de observações é chamado de processo estocástico. Processos estocásticos são sistemas que evoluem no tempo e/ou no espaço de acordo com leis probabilísticas.

Um processo estocástico é uma família $Z = \{Z(t), t \in \mathbb{N}\}$ tal que para cada $t \in \mathbb{N}$, $Z(t)$ é uma variável aleatória. Se $N \equiv Z = \{1, \dots, t\}$, diz-se que o processo é de

parâmetro discreto, denotando-se por Z_t . Se $N \in \mathfrak{R}$, diz-se que o processo é de parâmetro contínuo, denotando-se por $Z(t)$.

Suponha que $Z(t)$ se origina de um experimento que pode ser repetido sob condições idênticas; a cada experimento obtém-se um registro dos valores de $Z(t)$ no tempo. A coleção de todos os registros possíveis denomina-se conjunto. Assim, uma série temporal pode ser observada como uma realização parcial do processo estocástico, ou seja, uma amostra finita de observações no tempo.

3.1.2 - Estacionariedade e Ergodicidade

Um processo estocástico está estatisticamente determinado quando se conhece suas funções de distribuição até a N -ésima ordem. Na prática, ocorrem duas situações problemáticas: não se conhece todas as funções de distribuição até a N -ésima ordem e, comumente, tem-se apenas uma realização do processo estocástico em questão, a partir da qual se deseja inferir todas as características do mecanismo gerador da série. Para superar essas dificuldades assumem-se duas restrições: estacionariedade e ergodicidade⁵.

Se o processo estocástico que gerou a série de observações é invariante com respeito ao tempo, diz-se que o mecanismo é estacionário. A importância do conhecimento da série ser ou não estacionária reside no fato de que, quando se trabalha com uma série estacionária, se está em presença de uma função amostral do processo que tem a mesma forma em todos os instantes do tempo $t \in N$, o que acarreta possibilidades de obtenção de estimativa das características do processo de forma bastante simples, o que, em caso contrário, não seria possível.

⁵ Para maiores detalhes, ver PAPOULIS (1965).

Um processo estocástico é dito ergódico se apenas uma realização deste é o suficiente para se obter todas as estatísticas do mesmo; também conhecido como *memoryless process*, ou processo “sem memória”.

Assim, algumas das principais propriedades que se aplicam aos processos estacionários, que também se aplicam aos processos ergódicos são: (i) média e variância constantes e (ii) funções de autocovariância e autocorrelação independentes da origem dos tempos.

3.1.3 - Modelos de Box e Jenkins

Uma das características fundamentais da metodologia Box e Jenkins⁶ é interpretar uma dada série temporal como sendo uma realização de um vetor aleatório multivariado, cuja dimensão é a da série temporal disponível. A partir de uma única realização do processo, com os argumentos de estacionariedade e ergodicidade do processo subjacente, procura-se detectar o sistema gerador da série, através das informações contidas nesta.

A filosofia da modelagem Box e Jenkins se utiliza de duas idéias: o princípio da parcimônia e a construção de modelos através de um ciclo iterativo.

O princípio da parcimônia estabelece que devemos escolher um modelo com o menor número de parâmetros possíveis, para uma adequada representação matemática. O ciclo iterativo é uma estratégia de seleção de modelos a ser empreendida até que tenhamos um modelo satisfatório.

⁶ Para maiores detalhes, ver BOX e JENKINS (1976).

3.1.4 - Modelos Box e Jenkins: Formulação Geral

Trataremos, de agora em diante, de maneira indistinta um processo estocástico e uma série temporal (realização do mesmo), pois assumimos se tratar de um processo estacionário (mais especificamente, ergódico), conforme apresentado na seção 3.1.2.

Uma classe muito importante de processos estocásticos w_t é aquela obtida pela passagem de um processo ruído branco (processo cujas variáveis aleatórias têm médias nulas e são mutuamente independentes) através de um filtro linear, isto é:

$$w_t = \sum_{k=0}^{\infty} \psi_k a_{t-k} \quad (3.1.4.1)$$

A modelagem proposta por Box e Jenkins é da forma da equação abaixo, onde o filtro linear:

$$\psi_k = \frac{\theta_q(B)}{\phi_p(B)} \quad (3.1.4.2)$$

Desta forma os modelos Box e Jenkins são dados por:

$$\phi_p(B)w_t = \theta_q(B)a_t \quad (3.1.4.3)$$

Onde:

1) $\phi(\cdot); \theta(\cdot)$ são polinômios do tipo:

$P(X) = 1 - C_1X - C_2X^2 - \dots - C_kX^k$ de graus p, q, respectivamente.

2) B é o operador de atraso e seu efeito sobre uma variável discreta é:

$$B^k Z_t = Z_{t-k} \quad (3.1.4.4)$$

3) Os graus dos polinômios ϕ , θ (todos tendo “B” como variável) são, respectivamente, p e q.

De acordo com Box e Jenkins, o modelo (3.1.4.3) é denominado: ARMA (p, q). De (3.1.4.3) pode se escrever:

$$w_t = \theta(B) \cdot \phi^{-1}(B)a_t \quad (3.1.4.5)$$

A expressão para w_t em função dos ruídos a_t , pode ser escrita como:

$$w_t = \sum_{k=0}^{\infty} \psi_k a_{t-k} \quad (3.1.4.6)$$

Onde ψ_k são coeficientes do polinômio obtido pelo produto:

$$\phi^{-1}(B) \theta(B) \text{ ou } w_t = \psi(B) a_t;$$

$$\text{Onde, } \psi(B) = \phi^{-1}(B)\theta(B). \quad (3.1.4.7)$$

3.1.5 - Casos Particulares

- Modelos Médias Móveis – MA(q):

O modelo que tem $\phi(B) \equiv 1$ é chamado Modelo Médias Móveis, cuja notação é MA(q).

A nomenclatura do modelo vem do fato de que w_t é uma função soma algébrica ponderada dos a_t que se movem no tempo.

- Modelos Auto-Regressivos – AR(p)

O modelo $\theta(B) \equiv 1$ é chamado Modelo Auto-Regressivo, cuja notação é AR(p).

O nome Auto-Regressivo se deve ao fato de que w_t no instante t é função dos w 's nos instantes anteriores à t .

- Modelos Auto-Regressivos – Médias Móveis – ARMA (p,q)

É o modelo que tem componentes AR ($\phi(\cdot) \neq 1$) como uma MA ($\theta(\cdot) \neq 1$), cuja notação é ARMA (p, q).

Usualmente denotam-se todos os modelos como ARMA (p, q) colocando-se os valores p, q iguais a zero quando $\phi(\cdot)$ e $\theta(\cdot)$ forem idênticos a 1, respectivamente.

Assim:

$$\text{MA (q)} \longrightarrow \text{ARMA (0, q)}$$

$$\text{AR(p)} \longrightarrow \text{ARMA (p, 0)}$$

É importante ressaltar também que, dentro de certas restrições, um modelo ARMA (p, q) é equivalente a um modelo AR com um conjunto infinito de parâmetros. Desta forma, a formulação ARMA para um modelo inclui os tradicionais modelos AR e MA com a grande vantagem da economia de parâmetros (Princípio de Parcimônia Box e Jenkins).

- Modelos Não Estacionários – ARIMA (p,d,q)

Como os processos encontrados na vida prática raramente são estacionários, deve-se procurar algum tipo de operador que produza, a partir de w_t um processo não estacionário.

Nesta modelagem consideram-se apenas os processos chamados não estacionários homogêneos, isto é, aquela classe de processos não estacionários para os quais diferenças sucessivas produzem um processo estacionário.

Em termos analíticos, estamos falando da criação de um novo processo (do tipo não estacionário e homogêneo) Z_t relacionado com w_t da forma:

$$S.w_t = .Z_t \text{ ou } w_t = \nabla.Z_t \quad (3.1.5.1)$$

Onde S ou ∇ são, respectivamente, o operador soma e diferença, e representam um filtro não estacionário.

3.2 - Amortecimento Exponencial (Modelos Holt Winters)

Os métodos de amortecimento exponencial são amplamente utilizados na indústria. Sua popularidade se dá devido a uma série de considerações práticas para previsões de horizonte curto. A formulação dos modelos é relativamente simples. Seus componentes e parâmetros têm significado intuitivo para o usuário. Somente limitada armazenagem de informação e esforço computacional são requeridos. Testes de sinal de rastreamento para controle de previsão são de fácil aplicação.

Talvez a razão mais importante para a popularidade do amortecimento exponencial é a surpreendente acurácia que pode ser obtida com esforço mínimo na identificação do modelo. Dois estudos empíricos de larga escala encontraram pequena diferença na acurácia de previsão entre amortecimento exponencial e modelos ARIMA identificados pela metodologia Box e Jenkins – ver MAKRIDAKIS e HIBON (1979) e MAKRIDAKIS *et al.* (1982).

Apresentaremos nas seções 3.2.1 a 3.2.4 diferentes classes de modelos, desde o amortecimento simples à classe de modelos não-lineares.

Como não há consenso na literatura em termos de notação, o quadro abaixo é proposto como padrão e referência para os modelos descritos nas seções seguintes.

| Símbolo | Definição |
|----------------|--|
| α | Parâmetro para o nível das séries |
| γ | Parâmetro para a tendência |
| δ | Parâmetro para fatores sazonais |
| ϕ | Parâmetro de modificação de tendência |
| β | Fator de desconto, $0 \leq \beta \leq 1$ |
| S_t | Nível amortecido das séries, computado depois que X_t é observado. Também o valor esperado dos dados no final do período t em alguns modelos. |
| T_t | Tendência amortecida no final do período t. Pode ser aditiva (linear) ou multiplicativa. |
| I_t | Índice sazonal amortecido ou fator no final do período t. Pode se aditivo ou multiplicativo. |
| S_t'' | Média duplamente amortecida (da aplicação do amortecimento exponencial simples à S_t). |
| X^t | Valor observado na série temporal no período t. |
| m | Número de período no <i>lead-time</i> da previsão. |
| p | Número de períodos no ciclo sazonal. |
| $\hat{X}_t(m)$ | Previsão para m períodos à frente da origem t. |
| e_t | Erro de previsão para um período à frente. $e_t = X_t - \hat{X}_{t-1}$. Nota-se que $e_t(m)$ deve ser usado para outras origens de previsões. |

Tabela 1: Notação Amortecimento Exponencial

3.2.1 - Modelos para Nível Constante (Amortecimento Simples)

No amortecimento simples representam-se as séries temporais por $X_t = b + \varepsilon_t$, onde ε_t é um componente aleatório com média zero e variância σ^2 . O nível b é assumido como constante em qualquer segmento local das séries, mas pode mudar vagarosamente com o tempo.

| Modelos de nível constante | Fórmulas (correção de erro) |
|----------------------------|---|
| Não-sazonal | $S_t = S_{t-1} + \alpha e_t$ $\hat{X}_t(m) = S_t$ |
| Sazonal aditivo | $S_t = S_{t-1} + \alpha e_t$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t$ $\hat{X}_t(m) = S_t + I_{t-p+m}$ |
| Sazonal multiplicativo | $S_t = S_{t-1} + \alpha e_t / I_{t-p}$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t / S_t$ $\hat{X}_t(m) = S_t I_{t-p+m}$ |

Tabela 2: Modelos de Nível Constante

3.2.2 - Modelos Holt Winters para Tendência Linear

Um processo de tendência linear é representado por $X_t = b_0 + b_1 t + \varepsilon_t$, Os modelos Holt Winters utilizam parâmetros separados para amortecer o nível, tendência e, quando for o caso, sazonalidade das séries.

Estudos empíricos indicam que os modelos de Holt Winters mostraram-se robustos para horizontes curtos, como indicado por MAKRIDAKIS *et al.* (1982). Para horizontes longos (mais de três ou quatro períodos à frente) os modelos apresentam uma tendência

de superestimar os dados. Como veremos a seguir, pode ser recomendável amortecer a tendência para horizontes longos (*damped trend models*).

| Modelos de tendência linear Holt Winters | Fórmulas (correção de erro) |
|--|---|
| Não-sazonal | $S_t = S_{t-1} + T_{t-1} + \alpha e_t$ $T_t = T_{t-1} + \alpha \gamma e_t$ $\hat{X}_t(m) = S_t + mT_t$ |
| Sazonal aditivo | $S_t = S_{t-1} + T_{t-1} + \alpha e_t$ $T_t = T_{t-1} + \alpha \gamma e_t$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t$ $\hat{X}_t(m) = S_t + mT_t + I_{t-p+m}$ |
| Sazonal multiplicativo | $S_t = S_{t-1} + T_{t-1} + \alpha e_t / I_{t-p}$ $T_t = T_{t-1} + \alpha \gamma e_t / I_{t-p}$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t / S_t$ $\hat{X}_t(m) = (S_t + mT_t)I_{t-p+m}$ |

Tabela 3: Modelos de Tendência Linear

3.2.3 - Modelos para Tendência Não-Linear

Os modelos lineares podem ser adaptados em diversos caminhos diferentes para acomodar tendências não-lineares. Apresentaremos a seguir tendências exponenciais e exponenciais amortecidas.

As tendências exponenciais podem ser perigosas para longos horizontes de previsão, porém úteis para previsões de horizonte curto, no início do ciclo de vida do produto. Já a

tendência exponencial amortecida foi a forma de tendência mais acurada para horizontes longos nos estudos de MAKRIDAKIS *et al.* (1982).

○ Tendência Exponencial:

Uma tendência exponencial é gerada por $X_t = b_0 b_1^t$, com $b_1 > 0$. Diversos modelos de amortecimento foram sugeridos para o processo - ver PEGELS (1969) e ROBERTS (1982). A abordagem mais simples foi feita por Pegels e descrita no quadro abaixo:

| Modelos de tendência exponencial | Fórmulas (correção de erro) |
|----------------------------------|--|
| Não-sazonal | $S_t = S_{t-1}T_{t-1} + \alpha e_t$ $T_t = T_{t-1} + \alpha \gamma e_t / S_{t-1}$ $\hat{X}_t(m) = S_t T_t^m$ |
| Sazonal aditivo | $S_t = S_{t-1}T_{t-1} + \alpha e_t$ $T_t = T_{t-1} + \alpha \gamma e_t / S_{t-1}$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t$ $\hat{X}_t(m) = S_t T_t^m + I_{t-p+m}$ |
| Sazonal multiplicativo | $S_t = S_{t-1}T_{t-1} + \alpha e_t / I_{t-p}$ $T_t = T_{t-1} + (\alpha \gamma e_t / S_{t-1}) / I_{t-p}$ $I_t = I_{t-p} + \delta(1 - \alpha)e_t / S_t$ $\hat{X}_t(m) = (S_t T_t^m) I_{t-p+m}$ |

Tabela 4: Modelos de Tendência exponencial

○ Tendência Exponencial Amortecida (*Damped Trend*):

Para exemplificar o modelo de tendência exponencial amortecida, tomemos o caso não-sazonal, onde se adiciona um parâmetro autoregressivo ϕ ao modelo de tendência linear de Holt Winters. Se $\phi = 1$, os modelos são idênticos. Se $\phi > 1$, o crescimento nas previsões é exponencial (entretanto, o modelo requer um parâmetro a mais que o modelo

de Pegels). Se $\phi < 1$, o crescimento nas previsões tem a forma de uma exponencial amortecida, decrescendo em termos relativos e absolutos a cada período.

Procedimento semelhante é aplicado aos demais modelos (sazonal aditivo e sazonal multiplicativo), conforme ilustrado no quadro abaixo:

| Modelos de tendência amortecida ($0 < \phi < 1$) | Fórmulas (correção de erro) |
|--|---|
| Não-sazonal | $S_t = S_{t-1} + \phi T_{t-1} + \alpha e_t$ $T_t = \phi T_{t-1} + \alpha \gamma e_t$ $\hat{X}_t(m) = S_t + \sum_{i=1}^m \phi^i T_t$ |
| Sazonal aditivo | $S_t = S_{t-1} + \phi T_{t-1} + \alpha(2 - \alpha)e_t$ $T_t = \phi T_{t-1} + \alpha(\alpha - \phi + 1)e_t$ $I_t = I_{t-p} + \delta[1 - \alpha(2 - \alpha)]e_t$ $\hat{X}_t(m) = S_t + \sum_{i=1}^m \phi^i T_t + I_{t-p+m}$ |
| Sazonal multiplicativo | $S_t = S_{t-1} + \phi T_{t-1} + \alpha(2 - \alpha)e_t / I_{t-p}$ $T_t = \phi T_{t-1} + \alpha(\alpha - \phi + 1)e_t / I_{t-p}$ $I_t = I_{t-p} + \delta[1 - \alpha(2 - \alpha)]e_t / S_t$ $\hat{X}_t(m) = (S_t + \sum_{i=1}^m \phi^i T_t) I_{t-p+m}$ |

Tabela 5: Modelos de Tendência Amortecida

3.3 - Método de Combinação de Previsões

O artigo de BATES e GRANGER (1969) é considerado o trabalho inspirador para a extensa produção sobre combinação de previsões, cujo princípio refere-se à possibilidade de aumentar a precisão de prognósticos beneficiando-se da complementaridade da

informação contida em cada previsão individual. Esse resultado decorre da proposição de que a variância esperada dos erros da previsão combinada é inferior à menor das variâncias das previsões individuais subjacentes⁷.

Este conceito, entretanto, não se restringe ao campo de previsões ou teve origem no artigo de Bates e Granger, como pode ser visto na extensa revisão bibliográfica feita por CLEMEN (1989). A mais antiga referência a este conceito talvez se deva a GALTON (1907), mencionada por SUROWIECKI (2004).

Neste artigo, Galton descreve um experimento realizado como base em palpites para o peso da carcaça de um boi em um concurso promovido numa feira regional. O prêmio para a melhor previsão era o incentivo para que cada participante procurasse fazer a melhor estimativa. Para surpresa de Galton, devido à elevada heterogeneidade dos participantes, das 787 previsões registrou-se como mediana 1207 libras ante o peso real de 1198 libras.

Um resultado estilizado deste efeito, e no mesmo espírito de Galton, decorre do experimento sobre a quantidade de balas de goma num jarro. MILLER (2003) fez esta experiência e observou que apenas dois por cento dos participantes registrou um desvio inferior à média. Um agravante a este resultado, como observou SUROWIECKI (2004), é que embora sempre se observe um pequeno conjunto de indivíduos que “batem” a média, talvez um conjunto ainda mais restrito consiga apresentar consistentemente melhor desempenho do que o grupo.

O valor da contribuição adicional de cada série individual tem relação inversamente proporcional ao grau de correlação entre as previsões. Dito de outra forma, quando duas

⁷ Este resultado requer que as previsões sejam não-viesadas e não apresentem elevada correlação. Outro ponto relevante a ser observado é que a interação entre a variância e a correlação dos erros das previsões individuais é determinante para a performance da combinação.

séries apresentam elevada correlação, a previsão derivada de suas combinações terá um forte componente de redundância, reduzindo o ganho esperado pela diversificação. O limite do benefício da diversificação se dá na medida em que se aumenta o número de previsões individuais, o que resulta na eliminação do desvio diversificável.

Cabe ressaltar, como observado por GRANGER (1989), que não há razões para se esperar que a melhor previsão possível seja produzida por uma combinação de previsões. Entretanto, HIBON e EVGENIOU (2004) concluíram que, quando não se sabe qual o melhor método de previsão individual, incorre-se em menor risco ao selecionar combinações, mesmo que estas não sejam, em média, superiores à melhor previsão individual.

3.3.1 - Formas de Combinação

Várias formas de combinação de previsões foram desenvolvidas desde a publicação do artigo de BATES e GRANGER (1969), se estendendo da simples média aritmética aos métodos mais sofisticados, como redes neurais para combinações não-lineares.

O valor esperado de uma determinada variável, derivado da combinação, é formado com base em diversas fontes de informação. Vários modelos podem ser utilizados para gerar um conjunto de previsões, onde o peso de cada previsão está associado ao seu grau de precisão e correlação entre os desvios das demais séries.

Um problema na combinação de previsões é a sobreposição de informações entre as previsões individuais. Como destacado por CLEMEN e WINKLER (1985), o valor incremental de cada série é uma função côncava do número de séries combinadas, ou seja, é decrescente na medida em que cresce sua quantidade. Esta sobreposição pode ser

representada por uma correlação positiva entre as previsões individuais sendo diretamente relacionada ao grau de concavidade, e, portanto, à velocidade em que a informação adicional se torna irrelevante.

Portanto, este grau de dependência entre as previsões individuais pode comprometer a precisão e a contribuição do valor contido em cada série. Os métodos aqui considerados ilustram a sensibilidade da precisão da previsão, combinada ao grau de dependência entre as previsões individuais subjacentes.

BATES e GRANGER (1969), NEWBOLD e GRANGER (1974) e WINKLER (1981) constroem modelos teóricos análogos e ótimos que admitem a dependência entre as séries de previsões individuais. Estes modelos consideram uma forte hipótese: que sejam conhecidas as verdadeiras propriedades estatísticas de cada série de previsão individual. Considera-se, portanto, que a variância dos erros e suas correlações sejam conhecidas e estacionárias nos períodos de previsões, dentro e fora da amostra.

Na prática, nem sempre o grau de dependência é conhecido, ou as séries deixam de apresentar sistematicamente algum viés. Neste caso, como destacado por WINKLER (1981), o modelo não vai à direção de uma combinação linear, mas requer um arcabouço bayesiano que, em linhas gerais, além de corrigir o viés, pondera cada previsão com base no valor esperado de sua precisão. ANANDALINGAM e CHEN (1989) mostram que o modelo bayesiano corresponde a um caso geral que engloba todos os demais modelos de combinação.

Dentre os mais influentes artigos publicados recentemente referentes à combinação de previsões, destaca-se o de GRANGER e RAMANATHAN (1984) onde se apresentou

uma abordagem por regressão como alternativa aos métodos convencionais de combinação de previsões.

GRANGER e RAMANATHAN (1984) apontam para o fato de que as técnicas convencionais eram equivalentes à estimação por método de mínimos quadrados ordinários com restrições nos parâmetros. Ao invés de restringir que os pesos combinatórios somem um e forçar a regressão através da origem, GRANGER e RAMANATHAN (1984) sugerem a utilização do método de mínimos quadrados sem restrição nos parâmetros, visando obter um melhor ajuste e, presumidamente, uma melhor performance da previsão.

No presente trabalho, será empregada a técnica de combinação de previsões baseada no modelo defendido por GRANGER e RAMANATHAN (1984), conforme detalhado acima.

4 Estudo de Caso: Modelo de Previsão Distribuidora

4.1 - Introdução

Como explicitado anteriormente no primeiro capítulo do presente trabalho, o capital empregado em estoques e o elevado capital de giro, inerentes ao processo de distribuição de combustíveis, tornam o processo decisório das distribuidoras junto aos seus fornecedores, no caso em questão a Petrobras, uma atividade de extrema relevância para o sucesso de suas respectivas atividades.

A Petrobras, principal fornecedora de derivados no Brasil, estabeleceu regras contratuais claramente definidas, buscando também otimizar suas operações e logística de fornecimento.

Diante deste contexto, o trabalho busca uma melhor solução para o problema de compra de produtos derivados de petróleo pelas distribuidoras junto à Petrobras, através da modelagem da previsão de demanda futura das mesmas.

A acurácia nas estimativas de vendas feitas pelas distribuidoras respondem, *a priori*, pelos prejuízos financeiros incorridos no processo de compra de produto junto à Petrobras. Obviamente que a estimativa de demanda depende de uma série de fatores, internos e externos, controláveis ou não, e a imperfeição de tais previsões é um aspecto inerente ao processo.

Assim, é objetivo desta dissertação propor um novo arcabouço analítico para previsão das séries de vendas, através da aplicação de modelos teóricos de séries temporais. Dentre estes, tem-se: Box e Jenkins, Holt Winters e combinação de previsões, já apresentados ao longo do terceiro capítulo.

Por fim, serão realizados testes de aderência para cada um dos modelos propostos, buscando-se comparar os resultados obtidos com as estimativas reais da distribuidora.

Para todas as análises serão utilizados dados fictícios que guardam relação com a série real. Da mesma forma, o nome da distribuidora em questão também será mantido em sigilo. A razão disto se explica pela natureza estratégica e confidencial dos mesmos.

A seguir será apresentada a modelagem empregada pela distribuidora na previsão de demanda (vendas) futura.

4.2 - Modelo de Previsão Distribuidora

O modelo de previsão utilizado atualmente pela distribuidora, objeto do presente estudo de caso, consiste em duas etapas distintas, sendo a primeira uma abordagem quantitativa e, em seguida, com o resultado desta, é aplicado método qualitativo para ajuste e validação da previsão final.

A abordagem inicial consiste na análise de uma base de dados, com as séries históricas de vendas dos diferentes pólos de suprimento de produtos (combustíveis), contendo dados mensais até o mês anterior ao mês em questão.

Utilizando uma planilha de cálculo convencional, a análise é feita da seguinte forma:

- 1) São armazenadas, mensalmente, as médias dos doze meses anteriores.
- 2) A partir das médias calculadas acima, são calculadas médias móveis entre cada mês e seu antecessor (médias móveis centradas).
- 3) Calcula-se, então, a “sazonalidade”, que é determinada pela divisão das vendas reais mensais por suas respectivas médias móveis centradas.

4) Determina-se um índice de sazonalidade mensal, que é calculado através do somatório normalizado das sazonalidades mensais, com a atribuição de pesos maiores para as sazonalidades mensais mais recentes. Para definir os índices de sazonalidade finais, calcula-se a média dos índices de sazonalidade mensais e ajustam-se os índices mensais por esta média.

5) Para se determinar a previsão final, primeiro calculam-se a média das vendas dos dois meses anteriores ao atual, divididos pelos respectivos índices de sazonalidade. Em seguida, multiplica-se esta média encontrada pelo índice de sazonalidade de cada mês (previsão para os doze meses subsequentes).

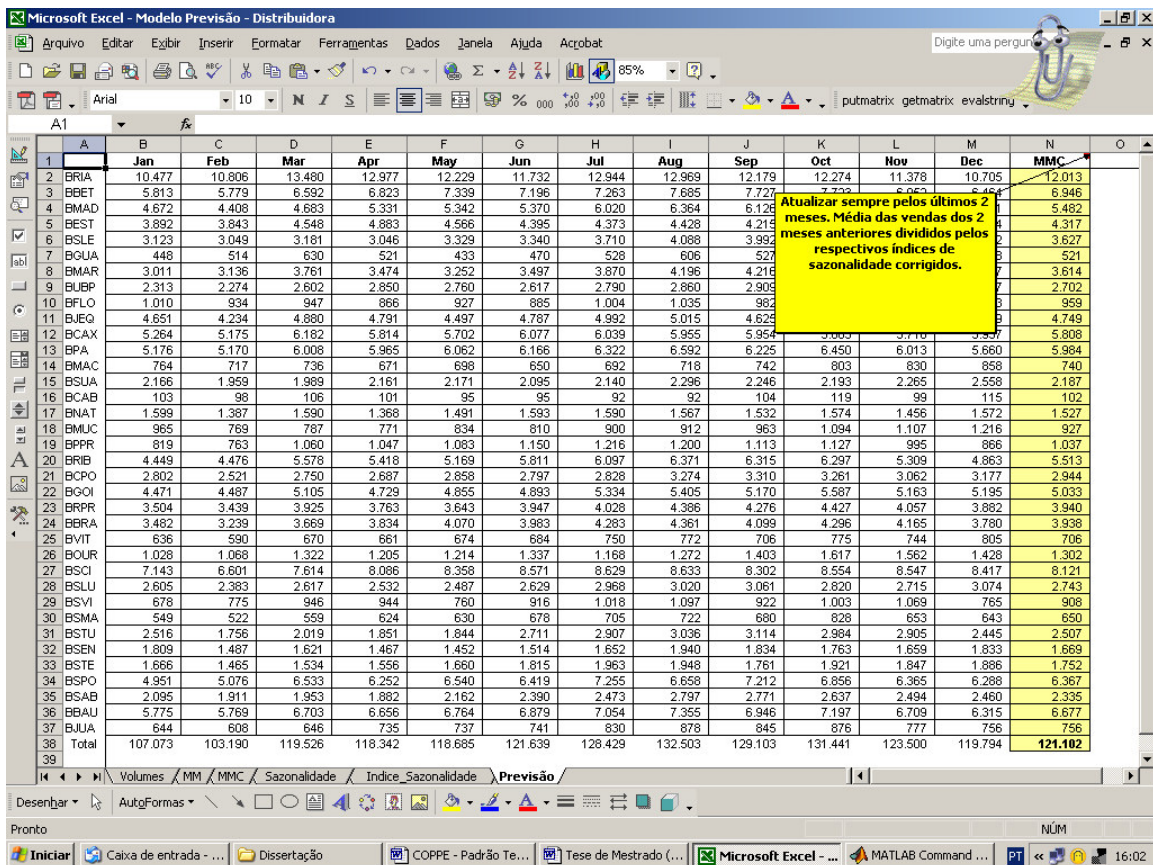


Figura 5: Modelo de Previsão Distribuidora

Vale lembrar que, apesar do método quantitativo propiciar previsão para doze meses à frente, a previsão final, que inclui a validação qualitativa, só é feita para um horizonte de tempo de um mês à frente, pois esta é a prioridade no processo de compra junto aos fornecedores, principalmente a Petrobras. Entretanto, segundo informações apresentadas, a distribuidora pretende melhorar a acurácia de suas previsões para horizontes mais longos, pois assim irá fornecer um cenário mais consistente para a estratégia de compras e políticas de estoques.

Após a análise quantitativa descrita acima, já de posse da previsão gerada, são feitos ajustes qualitativos para finalmente determinar a estimativa final de demanda. A etapa de análise qualitativa é baseada em fatores que podem impactar ou direcionar a previsão de demanda futura. Em geral, as fontes de informações primárias (força de vendas, por exemplo) são determinantes para este tipo de análise, porém fatores externos e causas conjunturais podem causar grande impacto nas previsões. Destacam-se abaixo exemplos de fatores impactantes no processo de previsão:

- Informações da força de vendas, isto é, os funcionários “da ponta da cadeia” recebem a previsão gerada e devem fazer o ajuste dos valores baseados na relação direta com clientes e mercado.
- Expectativas de aumento de preços dos fornecedores (pré-altas), que geram aumento da demanda na busca de realização do chamado lucro de inventário.
- Guerra de preços em determinada localidade. Estas podem acarretar aumento na demanda futura, em função da redução de margens e conseqüente aquecimento do consumo.

- Novos clientes. Por exemplo, o contrato de um novo posto revendedor ou atendimento de um novo cliente comercial (indústria ou grande consumidor pontual).
- Outros fatores, tais como crises externas, desabastecimento, aumento do preço internacional, também são considerados nesta etapa do processo de previsão.

Após as etapas de análise descritas, a previsão de demanda final é definida e irá servir de direcionador para os demais setores da empresa que dependem desta informação, em especial o setor de suprimentos, que é responsável pela estratégia de aquisição de produtos juntos aos fornecedores.

5 Estudo de Caso: Modelos Propostos

Este capítulo trata da análise empírica de dados referentes às séries históricas de vendas de combustíveis de três diferentes bases de distribuição. A escolha das bases de distribuição foi feita buscando abranger os diferentes perfis encontrados no país, considerando aspectos como natureza (primária ou secundária), modal de recebimento e localização geográfica. Além destes, somente foram consideradas bases de distribuição que não sofreram alterações conjunturais ou rupturas estruturais, tais como mudanças logísticas de grande porte e/ou restrições legais, ao longo dos últimos anos.

As séries históricas utilizadas representam o volume mensal de venda de óleo diesel B, em metros cúbicos, proveniente de cada base de distribuição estudada. O período das séries compreende desde janeiro de 1998 até janeiro de 2006.

Havia disponibilidade de dados históricos de demanda de gasolina A e óleo diesel B. Convém ressaltar que a opção pela utilização do óleo diesel B em detrimento à gasolina A se deu pelas inúmeras alterações, ocorridas ao longo dos últimos anos, na proporção de álcool anidro e gasolina A na composição final da gasolina C⁸. Tal fato poderia comprometer as análises subseqüentes.

Serão apresentados a seguir os resultados das análises realizadas, tomando por base os dados de venda de óleo diesel B, para as três bases de distribuição selecionadas – Duque de Caxias/RJ, Suape/PE e Brasília/DF.

⁸ A gasolina C é comercializada pela distribuidora aos seus revendedores e/ou consumidores finais. Ela é composta pela mistura de álcool anidro (produzido pelas destilarias) e gasolina A (fornecida pelas refinarias). Atualmente, a proporção é de 80% de gasolina A e 20% de álcool anidro.

5.1 - Base: Duque de Caxias/RJ

O primeiro caso estudado refere-se à base de distribuição de Duque de Caxias, no Estado do Rio de Janeiro. Trata-se de uma base primária, isto é, que possui recebimento de produtos diretamente do fornecedor (Petrobras - Refinaria Duque de Caxias) por meio de dutovias.

A área de influência da base compreende todo o Estado do Rio de Janeiro e ainda parte da região nas divisas com os Estados de Minas Gerais (Zona da Mata) e Espírito Santo. Além disso, são transferidos produtos, via modal ferroviário, para a base de distribuição secundária existente na cidade de Campos/RJ, que, por sua vez, abastece os clientes no interior do Estado.

Nas próximas três seções serão discutidos os modelos empregados para o presente caso. Já em 5.1.4 serão consolidados os resultados encontrados (performance dos modelos propostos versus previsão da distribuidora).

5.1.1 - Modelo Box e Jenkins

Durante a fase de identificação do modelo, percebeu-se a necessidade de estacionarizar a série, conforme ilustrado no gráfico da série e de suas funções de autocorrelação e autocorrelação parcial (figura 6).

Assim, foi realizada diferenciação de primeira ordem, atingindo com sucesso a estacionariedade do modelo, conforme ilustrado abaixo. Feito isto, o modelo que melhor se adequou para o caso foi o MA (1), isto é, um ARIMA (0,1,1).

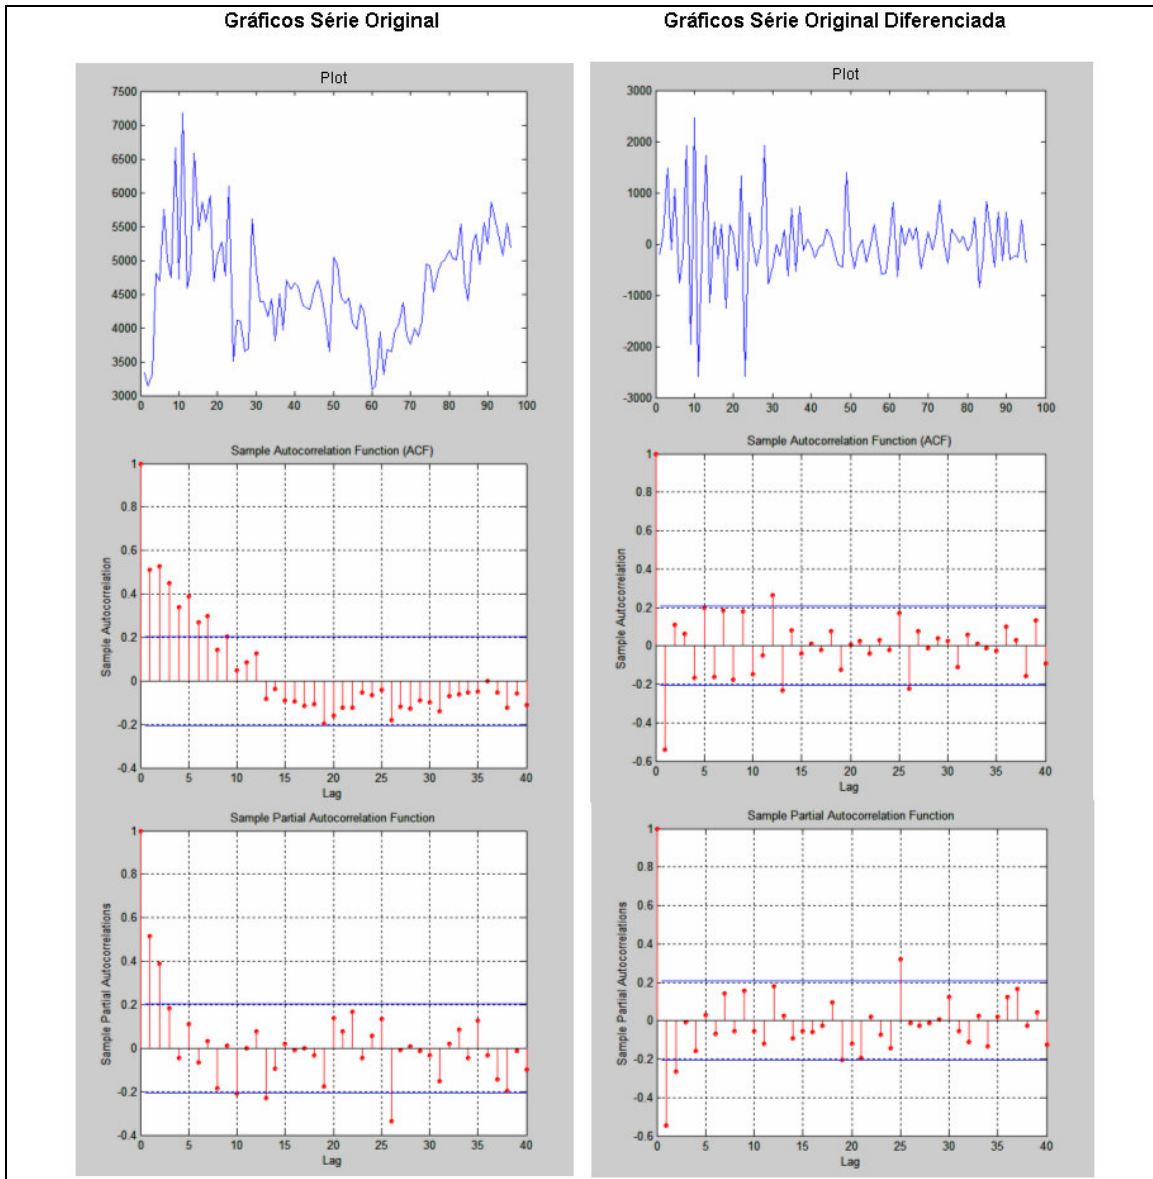


Figura 6: Análises Série Original e Série Diferenciada

Em função da série de dados ser relativa ao volume mensal de vendas, testou-se a existência de dependência ligada aos efeitos de calendário. Para tal foram propostos dois ajustes:

- 1) Venda por dia: série equivalente, calculada pelas vendas totais dos meses divididas pelo número de dias de venda dos respectivos meses.

2) Série ajustada (efeito calendário): extrair a dependência linear da série de vendas explicadas pelo número de dias de venda, através do emprego de modelos de regressão.

Em ambos os casos, conforme ilustrado pelos gráficos das figuras 7 e 8, os efeitos de calendário não se mostraram relevantes para o processo de análise da série.




Figura 7: Análises Série Vendas por Dia e Série Vendas por Dia Diferenciada




Figura 8: Análises Série Ajuste Calendário e Série Ajuste Calendário Diferenciada

Partindo do modelo identificado, pode-se obter a função de previsão da demanda de venda de combustíveis. Assim, comparando-se os resultados encontrados com os valores reais associados à série de interesse, pode-se notar que o modelo apresenta performance bastante satisfatória. Quando tomamos por base as previsões da distribuidora, podemos perceber que os erros incorridos por esta são maiores que aqueles relativos ao modelo

teórico. Além disso, a análise dos resíduos comprova que o modelo capturou a dependência linear existente. A figura 9 apresenta o histograma e a função de autocorrelação dos resíduos.

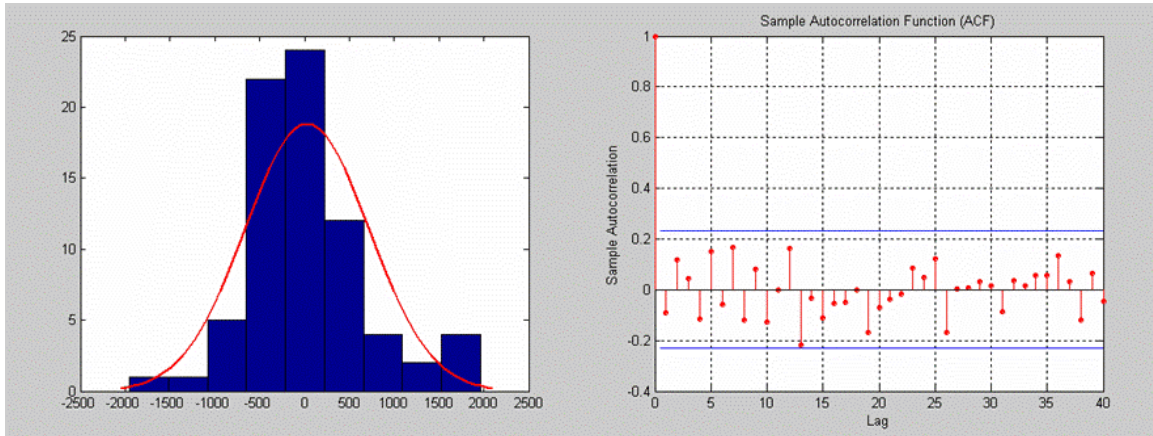


Figura 9: Análise dos Resíduos (Box e Jenkins)

5.1.2 - Holt Winters

Pelas próprias características da série e após a realização de testes, tomando-se por base diferentes formas funcionais, foi empregado modelo Holt Winters de amortecimento exponencial englobando parâmetros de tendência e sazonalidade.

Como não há evidência que justifique o contrário, foi utilizado componente sazonal aditivo. O critério de otimização se deu através da minimização do erro quadrático médio (MSE).

Outro ponto que merece destaque é o não emprego de modelo de tendência amortecida, pois o horizonte de previsão é curto (um mês à frente) e, portanto, o modelo de Holt Winters apresenta-se robusto, como ratificado nos estudos de MAKRIDAKIS *et al.* (1982).

O resultado das previsões foi o melhor em termos de precisão, pois, além de superar aquele encontrado pelo método empregado pela distribuidora, também suplantou os

resultados dos demais modelos propostos, conforme será visto em detalhes na seção 5.1.4.

A análise dos resíduos comprova o ajuste do modelo, que se mostrou capaz de capturar a dependência linear existente, conforme ilustrado nos gráficos abaixo (figura 10 – histograma e autocorrelação). Vale ressaltar que a autocorrelação dos resíduos apresenta forma de um ruído branco.

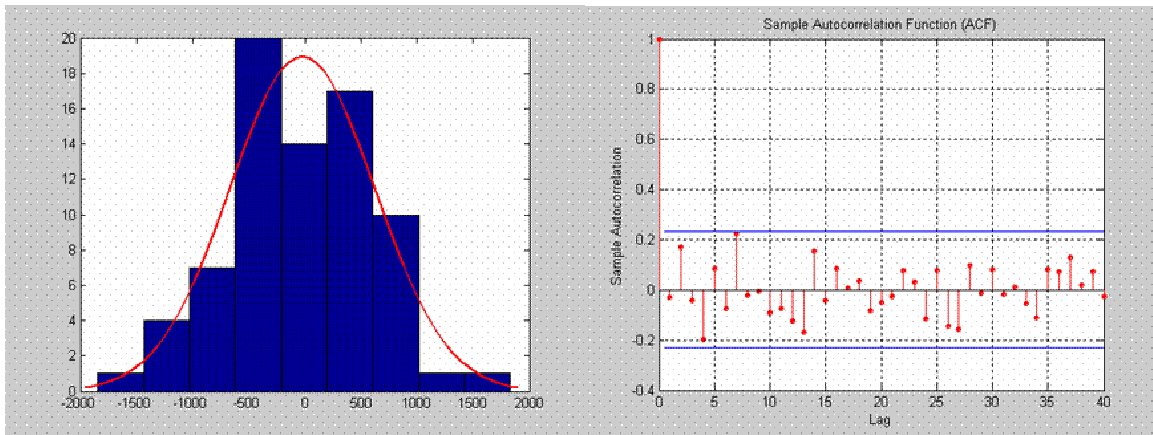


Figura 10: Análise dos Resíduos (Holt Winters)

5.1.3 - Combinação de Previsões

A próxima abordagem aplicada ao problema em questão foi o método de combinação de previsões, utilizando as previsões geradas pelos modelos de Box e Jenkins e Holt Winters, descritos anteriormente.

O critério para o modelo foi o mesmo proposto por GRANGER e RAMANATHAN (1984), que recomenda o uso da combinação de previsões sem restrições dos parâmetros, conforme citado previamente na seção 3.3.1.

A partir da série de dados, com início em fevereiro de 1998, foram calculadas e utilizadas as previsões entre maio de 2003 e abril de 2004 (doze meses) para realizar a estimativa dos parâmetros do modelo de combinação de previsões.

A exemplo dos demais modelos, o método de combinação de previsões gerou previsões para um mês à frente, desde maio de 2004 até janeiro de 2006. Os resultados encontrados foram superiores (maior precisão) aos obtidos pela distribuidora e serão apresentados na seção 5.1.4.

| | | Box & Jenkins | Holt Winters | Combined Forecast: HW+ BJ | Vetor de Pesos | | |
|---------|-------------|--------------------------|-----------------------|----------------------------------|-----------------------|--------------|-------------|
| Tempo | Vendas (M3) | Prev. Box&Jenkins | Previsão Holt Winters | Previsão Combined Forecast | Intercepto | Pesos BJ | Pesos HW |
| 2004.05 | 4532,777808 | 4.559 | 5.004 | 4.748 | 2250,447433 | -0,105467758 | 0,5951204 |
| 2004.06 | 4823,19 | 4.549 | 5.145 | 4.730 | 2906,942991 | -0,311035107 | 0,629271605 |
| 2004.07 | 4966,35 | 4.654 | 5.239 | 4.790 | 2754,673498 | -0,270516093 | 0,628841317 |
| 2004.08 | 5001,4 | 4.775 | 4.868 | 4.594 | 2461,065631 | -0,179913871 | 0,614557707 |
| 2004.09 | 5149,3 | 4.863 | 4.850 | 4.789 | 1550,919184 | 0,196053794 | 0,470982754 |
| 2004.10 | 5019,4 | 4.975 | 4.847 | 4.981 | 952,0237372 | 0,451408493 | 0,367878369 |
| 2004.11 | 5009,445 | 4.993 | 4.810 | 4.990 | 901,8584313 | 0,473562874 | 0,358403263 |
| 2004.12 | 5532,65 | 4.999 | 4.995 | 5.064 | 882,8680027 | 0,482159454 | 0,35459846 |
| 2005.01 | 4674,88 | 5.208 | 4.874 | 5.244 | 547,958403 | 0,61324269 | 0,308339549 |
| 2005.02 | 4402,1 | 5.000 | 4.911 | 5.013 | 985,6896814 | 0,400423349 | 0,412462902 |
| 2005.03 | 5239,63 | 4.770 | 5.601 | 5.181 | 1271,158165 | 0,284582633 | 0,455701496 |
| 2005.04 | 5389,57 | 4.950 | 5.133 | 5.024 | 1267,38252 | 0,273699526 | 0,467932089 |
| 2005.05 | 4946,6 | 5.118 | 5.138 | 5.111 | 1148,124438 | 0,302975081 | 0,469472083 |
| 2005.06 | 5562,6 | 5.052 | 5.247 | 5.125 | 1218,056003 | 0,277617581 | 0,477331336 |
| 2005.07 | 5237 | 5.247 | 5.418 | 5.307 | 1081,325239 | 0,309545321 | 0,480132668 |
| 2005.08 | 5864,75 | 5.243 | 5.147 | 5.167 | 1108,401243 | 0,302164492 | 0,4808354 |
| 2005.09 | 5560,4 | 5.483 | 5.361 | 5.445 | 834,4802762 | 0,42391128 | 0,426438755 |
| 2005.10 | 5323,8 | 5.513 | 5.434 | 5.506 | 783,2827303 | 0,445673733 | 0,416998164 |
| 2005.11 | 5074,3 | 5.440 | 5.290 | 5.390 | 854,6979595 | 0,417257465 | 0,428266102 |
| 2005.12 | 5544,9 | 5.300 | 5.581 | 5.434 | 958,1119923 | 0,370144013 | 0,450381947 |
| 2006.01 | 5173,33 | 5.394 | 4.977 | 5.202 | 934,6055033 | 0,370886645 | 0,45546542 |

Figura 11: Método de Combinação de Previsões

Apesar das previsões da distribuidora terem apresentado desempenho inferior aos modelos propostos, foi também testado modelo combinando as previsões de Box e Jenkins, Holt Winters e da distribuidora. Como a série histórica da distribuidora é restrita, foram utilizados os dados com origem em maio de 2004 indo até abril de 2005 para estimação dos parâmetros do modelo, ficando os meses seguintes para validação do desempenho do mesmo, apresentado em maiores detalhes ao final da seção 5.1.4.

5.1.4 - Resultados Encontrados

Os modelos propostos foram analisados de acordo com dois critérios: erro percentual absoluto médio (MAPE) e erro médio quadrático (MSE). Ambos referem-se aos erros das

previsões geradas, comparadas às vendas reais observadas no período de maio de 2004 até janeiro de 2006.

Em linhas gerais, o MSE fornece informações a respeito de qual dos modelos apresenta os maiores erros. O MAPE permite avaliar, em média, o comportamento de cada um dos modelos. O formulário abaixo ilustra a diferença entre os dois critérios citados:

$$\text{MSE (Erro Médio Quadrático): } \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (5.1.4.1)$$

$$\text{MAPE (Erro Percentual Absoluto Médio): } \frac{1}{n} \sum_{t=1}^n \left| \left(\frac{e_t}{y_t} \right) \cdot 100\% \right| \quad (5.1.4.2)$$

Onde:

e_t : erro no tempo t ; y_t : observação no tempo t ; n : número de observações.

O período delimitado de comparação foi escolhido pela disponibilidade do histórico de previsões feitas pela própria distribuidora. Assim, foi possível medir a acurácia, não só dos modelos propostos entre si, como também destes com as previsões realizadas pela própria distribuidora.

A seguir, temos o quadro com o MAPE dos modelos para o caso da base de distribuição de Duque de Caxias/RJ:

| MAPE - Erro Percentual Absoluto Médio | | | | |
|---------------------------------------|---------------|--------------|-----------------------------|------------------------|
| Período | Box e Jenkins | Holt Winters | Combined Forecast (HW + BJ) | Previsão Distribuidora |
| 2004.05 | 0,57% | 10,39% | 4,74% | 8,35% |
| 2004.06 | 5,69% | 6,68% | 1,93% | 5,04% |
| 2004.07 | 6,29% | 5,49% | 3,55% | 1,45% |
| 2004.08 | 4,53% | 2,67% | 8,15% | 8,09% |
| 2004.09 | 5,56% | 5,81% | 7,00% | 5,26% |
| 2004.10 | 0,88% | 3,44% | 0,77% | 0,15% |
| 2004.11 | 0,34% | 3,99% | 0,39% | 3,83% |
| 2004.12 | 9,64% | 9,73% | 8,47% | 11,80% |
| 2005.01 | 11,40% | 4,25% | 12,18% | 4,73% |
| 2005.02 | 13,59% | 11,55% | 13,89% | 9,52% |
| 2005.03 | 8,97% | 6,90% | 1,12% | 7,54% |
| 2005.04 | 8,15% | 4,77% | 6,78% | 4,61% |
| 2005.05 | 3,46% | 3,88% | 3,32% | 9,61% |
| 2005.06 | 9,17% | 5,68% | 7,87% | 6,41% |
| 2005.07 | 0,19% | 3,46% | 1,34% | 1,10% |
| 2005.08 | 10,60% | 12,25% | 11,89% | 12,25% |
| 2005.09 | 1,40% | 3,58% | 2,08% | 10,08% |
| 2005.10 | 3,55% | 2,06% | 3,42% | 8,67% |
| 2005.11 | 7,20% | 4,25% | 6,22% | 4,22% |
| 2005.12 | 4,42% | 0,65% | 2,01% | 4,60% |
| 2006.01 | 4,26% | 3,80% | 0,55% | 6,79% |
| Média | 5,71% | 5,49% | 5,13% | 6,39% |

Tabela 6: MAPE - Base de Duque de Caxias/RJ

A seguir, temos o quadro com o MSE dos modelos para o caso da base de distribuição de Duque de Caxias/RJ:

| MSE - Erro Quadrático Médio | | | | |
|-----------------------------|-------------------|-------------------|-----------------------------|------------------------|
| Período | Box e Jenkins | Holt Winters | Combined Forecast (HW + BJ) | Previsão Distribuidora |
| 2004.05 | 666,61 | 221.847,71 | 46.112,91 | 143.338,11 |
| 2004.06 | 75.444,35 | 103.881,50 | 8.664,10 | 59.141,38 |
| 2004.07 | 97.651,27 | 74.228,32 | 31.062,96 | 5.186,59 |
| 2004.08 | 51.349,70 | 17.852,28 | 166.341,53 | 163.707,63 |
| 2004.09 | 81.925,83 | 89.532,14 | 130.070,21 | 73.289,86 |
| 2004.10 | 1.952,25 | 29.819,27 | 1.483,72 | 54,29 |
| 2004.11 | 285,22 | 39.868,81 | 378,64 | 36.723,21 |
| 2004.12 | 284.628,66 | 289.604,13 | 219.356,43 | 426.240,54 |
| 2005.01 | 284.153,69 | 39.551,56 | 324.423,20 | 48.894,05 |
| 2005.02 | 357.858,24 | 258.586,94 | 373.660,62 | 175.477,21 |
| 2005.03 | 220.703,76 | 130.664,42 | 3.437,06 | 156.016,31 |
| 2005.04 | 192.785,45 | 65.967,71 | 133.568,82 | 61.809,92 |
| 2005.05 | 29.328,26 | 36.749,92 | 27.026,25 | 225.855,91 |
| 2005.06 | 260.273,42 | 99.860,59 | 191.439,04 | 127.163,56 |
| 2005.07 | 96,97 | 32.880,84 | 4.897,19 | 3.346,16 |
| 2005.08 | 386.491,35 | 515.882,46 | 486.451,69 | 516.457,82 |
| 2005.09 | 6.054,98 | 39.602,23 | 13.336,13 | 314.326,18 |
| 2005.10 | 35.810,72 | 12.076,53 | 33.247,41 | 213.266,63 |
| 2005.11 | 133.644,51 | 46.464,60 | 99.661,63 | 45.869,65 |
| 2005.12 | 59.989,52 | 1.318,22 | 12.401,04 | 64.996,44 |
| 2006.01 | 48.497,33 | 38.720,86 | 802,01 | 123.485,47 |
| Média | 124.266,29 | 104.045,76 | 109.896,31 | 142.126,04 |

Tabela 7: MSE - Base de Duque de Caxias/RJ

Pode-se concluir que, para o critério MAPE, o modelo de combinação de previsões apresenta o melhor resultado, seguido dos modelos de Holt Winters e Box e Jenkins. Ao analisarmos o critério MSE, o modelo Holt Winters supera ligeiramente o método de combinação de previsões, que vem seguido do modelo de Box e Jenkins.

Para ambos os critérios, a previsão feita pela distribuidora apresentou o pior resultado dentre aquelas em análise.

O gráfico abaixo ilustra a série de vendas reais e as previsões dos modelos:

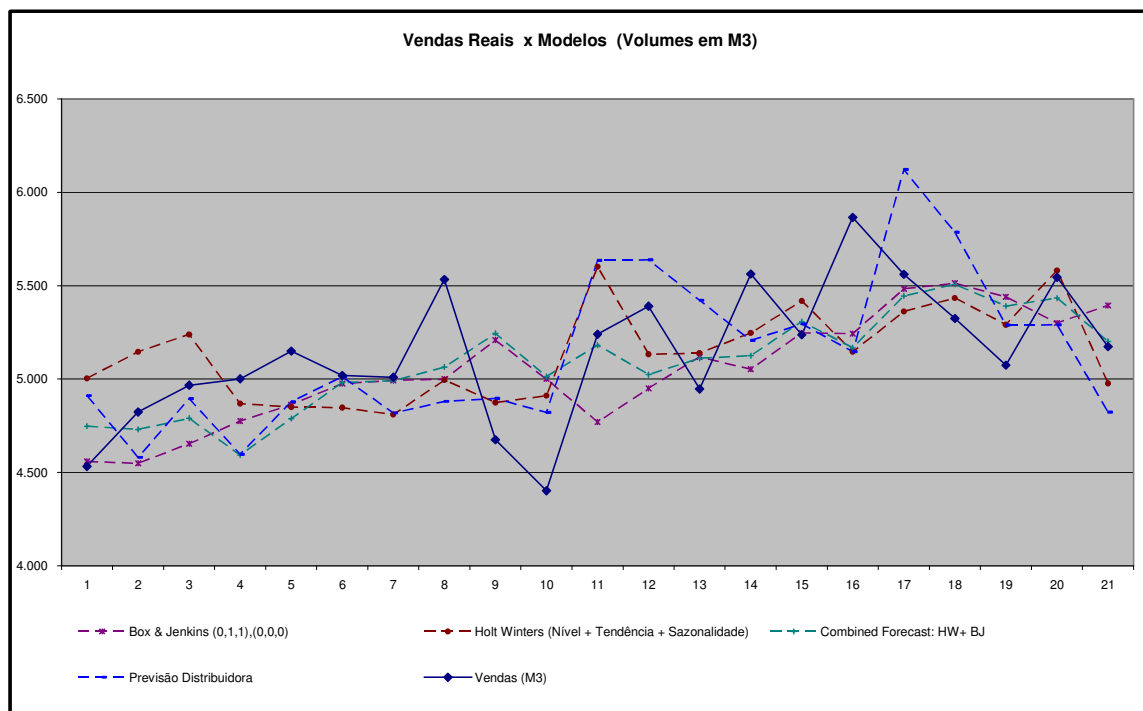


Tabela 8: Vendas Reais x Modelos

Para ilustrar a comparação entre os erros absolutos dos modelos, é apresentado o gráfico abaixo:

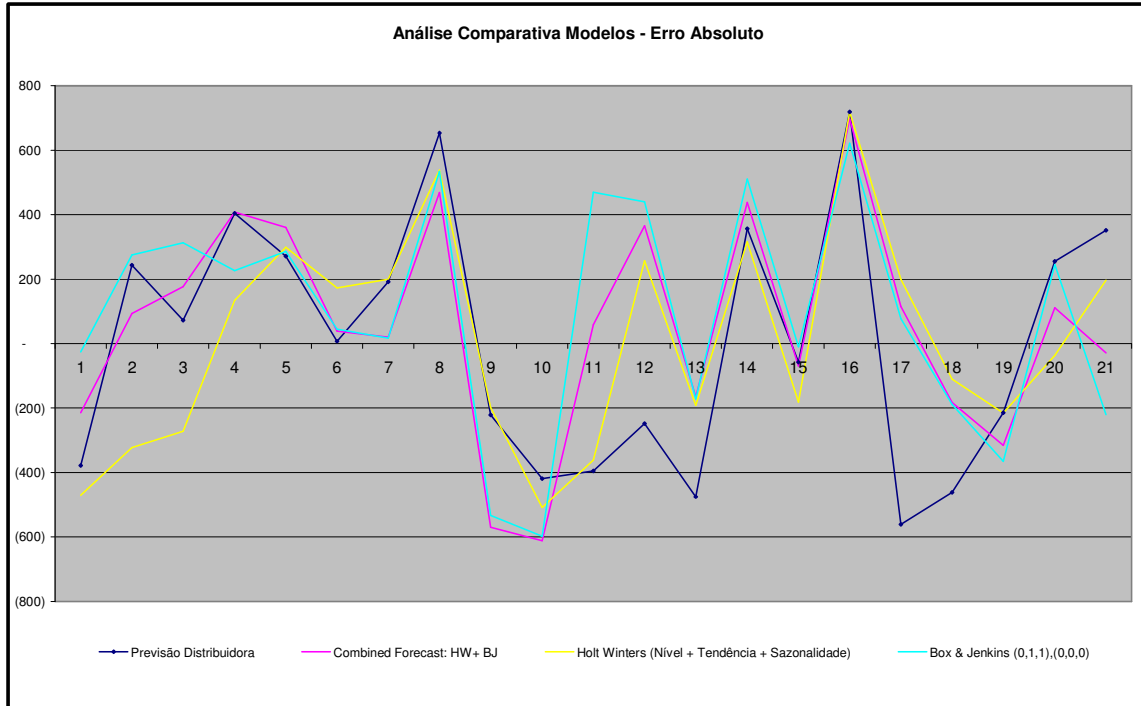


Tabela 9: Análise Comparativa Modelos - Erro Absoluto

Por fim é apresentado acompanhamento mensal do MAPE dos modelos propostos. Vale ressaltar o desempenho dos modelos Holt Winters e combinação de previsões ao longo do período delimitado.

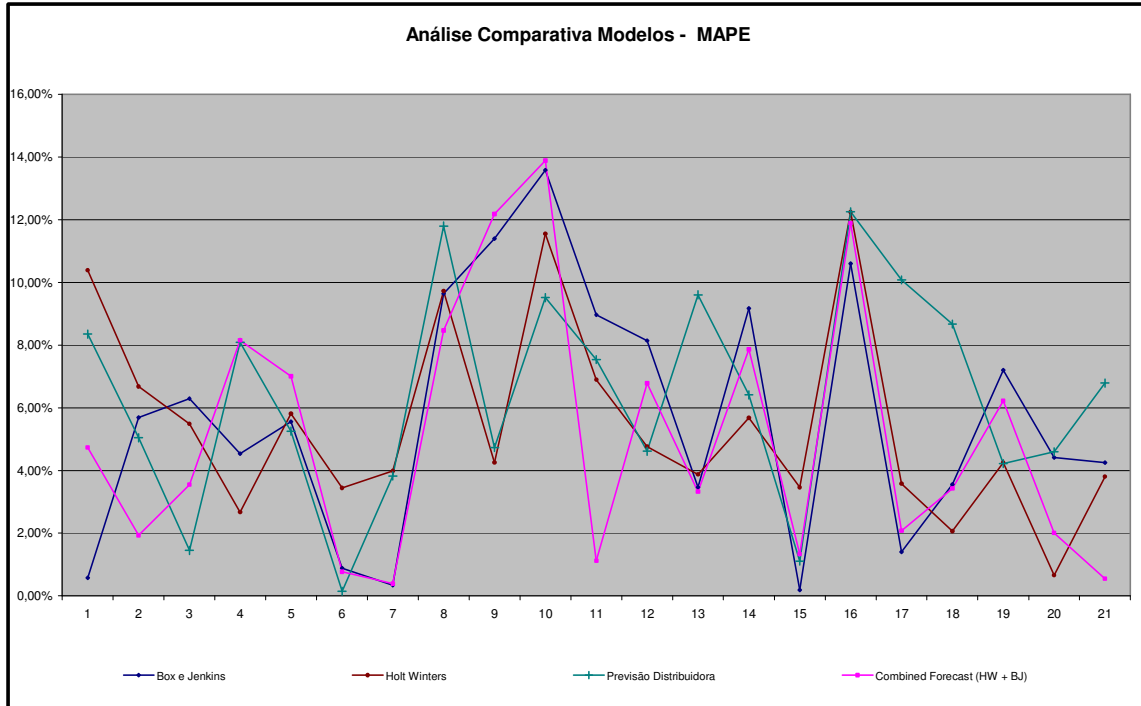


Tabela 10: Análise Comparativa de Modelos - MAPE

Cabe destacar, ainda, o resultado do método de combinação utilizando previsões dos modelos propostos (Holt Winters e Box e Jenkins) juntamente com a previsão feita pela distribuidora. Apesar do período de análise ser restrito, encontrou-se desempenho satisfatório com relação aos critérios MAPE e MSE, ficando próximo aos modelos propostos e à frente do resultado da previsão da distribuidora isoladamente, como se pode observar abaixo:

| MAPE - Erro Percentual Absoluto Médio | | | | |
|--|----------------------|---------------------|----------------------|---|
| Período | Box e Jenkins | Holt Winters | Distribuidora | Combined Forecast (HW + BJ + Dist) |
| 2005.05 | 3,46% | 3,88% | 9,61% | 5,45% |
| 2005.06 | 9,17% | 5,68% | 6,41% | 8,86% |
| 2005.07 | 0,19% | 3,46% | 1,10% | 2,87% |
| 2005.08 | 10,60% | 12,25% | 12,25% | 11,70% |
| 2005.09 | 1,40% | 3,58% | 10,08% | 2,72% |
| 2005.10 | 3,55% | 2,06% | 8,67% | 6,58% |
| 2005.11 | 7,20% | 4,25% | 4,22% | 6,84% |
| 2005.12 | 4,42% | 0,65% | 4,60% | 3,07% |
| 2006.01 | 4,26% | 3,80% | 6,79% | 0,43% |
| Média | 4,92% | 4,40% | 7,08% | 5,39% |

Tabela 11: MAPE II - Base de Duque de Caxias/RJ

| MSE - Erro Quadrático Médio | | | | |
|------------------------------------|----------------------|---------------------|----------------------|---|
| Período | Box e Jenkins | Holt Winters | Distribuidora | Combined Forecast (HW + BJ + Dist) |
| 2005.05 | 180.824 | 36.731 | 24.655 | 12.863 |
| 2005.06 | 414.853 | 903.744 | 764.383 | 593.107 |
| 2005.07 | 15.467 | 53 | 27.494 | 165.552 |
| 2005.08 | 3.830 | 24.527 | 280.175 | 79.179 |
| 2005.09 | 110.718 | 29.237 | 96.721 | 24 |
| 2005.10 | 38.970 | 26.321 | 117.909 | 305 |
| 2005.11 | 317 | 63.620 | 6.667 | 9.517 |
| 2005.12 | 244.025 | 721 | 203.401 | 49.483 |
| 2006.01 | 106.509 | 5.878 | 7.141 | 42.648 |
| Média | 123.946 | 121.204 | 169.838 | 105.853 |

Tabela 12: MSE II - Base de Duque de Caxias/RJ

5.2 - Base: Suape/PE

O próximo caso estudado refere-se à base de distribuição de Suape, no Estado de Pernambuco. Trata-se de uma base primária, cujo modal principal de recebimento de produtos é a cabotagem. A área de influência da base compreende todo o Estado de Pernambuco e regiões nas divisas com Estados vizinhos.

5.2.1 - Resultados Encontrados

Foi adotado processo analítico análogo ao caso da base de distribuição de Duque de Caxias/RJ, utilizando modelos de Box e Jenkins, Holt Winters e combinação de previsões.

Com relação aos modelos ARIMA Box e Jenkins, observamos que, da mesma forma como verificado nos dados referentes à distribuidora de Duque de Caxias/RJ, a especificação funcional que melhor se ajustou à série de interesse foi a ARIMA (0,1,1). Podemos supor, portanto, que a natureza comum das variáveis explique as similaridades observadas durante a etapa de identificação dos modelos, para os casos de Duque de Caxias e Suape.

Os modelos de Holt Winters e combinação de previsões foram empregados de forma análoga à explicitada anteriormente para a Base de Duque de Caxias/RJ.

A seguir apresentam-se, de forma consolidada (tabelas 13 e 14), os principais resultados encontrados com os modelos empíricos propostos, baseados na análise da série em questão. As medidas de desempenho utilizadas são: o erro percentual absoluto médio (MAPE) e o erro médio quadrático (MSE).

| MAPE - Erro Percentual Absoluto Médio | | | | |
|---------------------------------------|---------------|--------------|-----------------------------|------------------------|
| Período | Box e Jenkins | Holt Winters | Combined Forecast (HW + BJ) | Previsão Distribuidora |
| 2004.05 | 16,88% | 19,93% | 18,22% | 21,26% |
| 2004.06 | 8,59% | 1,81% | 9,33% | 9,21% |
| 2004.07 | 2,74% | 0,29% | 8,50% | 10,09% |
| 2004.08 | 4,98% | 2,15% | 0,91% | 2,16% |
| 2004.09 | 0,30% | 5,74% | 3,62% | 1,25% |
| 2004.10 | 5,77% | 6,21% | 7,89% | 5,32% |
| 2004.11 | 17,14% | 17,58% | 15,45% | 20,23% |
| 2004.12 | 10,39% | 3,49% | 0,67% | 5,24% |
| 2005.01 | 7,76% | 0,80% | 1,41% | 0,82% |
| 2005.02 | 18,12% | 8,01% | 19,62% | 13,48% |
| 2005.03 | 1,65% | 3,60% | 2,60% | 6,83% |
| 2005.04 | 7,72% | 2,35% | 1,21% | 6,00% |
| 2005.05 | 1,25% | 4,46% | 2,73% | 10,93% |
| 2005.06 | 4,44% | 11,25% | 8,94% | 8,03% |
| 2005.07 | 5,73% | 7,85% | 1,27% | 2,27% |
| 2005.08 | 17,01% | 14,96% | 12,94% | 13,16% |
| 2005.09 | 3,93% | 2,27% | 0,46% | 3,13% |
| 2005.10 | 2,19% | 3,15% | 4,11% | 4,01% |
| 2005.11 | 3,01% | 6,91% | 6,19% | 7,47% |
| 2005.12 | 12,51% | 0,73% | 6,93% | 8,84% |
| 2006.01 | 1,88% | 0,87% | 3,37% | 10,38% |
| Média | 7,33% | 5,92% | 6,49% | 8,10% |

Tabela 13: MAPE - Base de Suape/PE

| MSE - Erro Quadrático Médio | | | | |
|-----------------------------|------------------|------------------|-----------------------------|------------------------|
| Período | Box e Jenkins | Holt Winters | Combined Forecast (HW + BJ) | Previsão Distribuidora |
| 2004.05 | 110.100,60 | 153.594,47 | 128.313,16 | 174.714,55 |
| 2004.06 | 19.717,61 | 875,72 | 23.259,50 | 22.660,79 |
| 2004.07 | 2.095,61 | 22,72 | 20.117,86 | 28.369,00 |
| 2004.08 | 7.896,12 | 1.467,65 | 264,35 | 1.488,73 |
| 2004.09 | 26,98 | 9.823,37 | 3.918,37 | 465,35 |
| 2004.10 | 11.219,08 | 13.008,09 | 21.003,39 | 9.529,66 |
| 2004.11 | 134.509,01 | 141.593,20 | 109.318,94 | 187.489,00 |
| 2004.12 | 49.874,24 | 5.642,44 | 206,61 | 12.714,14 |
| 2005.01 | 21.309,57 | 227,37 | 708,57 | 237,56 |
| 2005.02 | 90.673,41 | 17.705,68 | 106.328,97 | 50.176,00 |
| 2005.03 | 893,72 | 4.229,47 | 2.206,05 | 15.233,48 |
| 2005.04 | 23.301,55 | 2.152,45 | 570,70 | 14.065,96 |
| 2005.05 | 547,13 | 6.926,44 | 2.590,69 | 41.589,48 |
| 2005.06 | 7.605,92 | 48.932,47 | 30.906,90 | 24.931,78 |
| 2005.07 | 13.556,21 | 25.388,91 | 668,26 | 2.116,64 |
| 2005.08 | 161.858,98 | 125.129,79 | 93.661,40 | 96.878,43 |
| 2005.09 | 7.644,06 | 2.548,08 | 105,56 | 4.855,44 |
| 2005.10 | 2.167,84 | 4.494,88 | 7.651,28 | 7.301,19 |
| 2005.11 | 3.954,37 | 20.906,14 | 16.750,89 | 24.451,58 |
| 2005.12 | 92.568,37 | 316,70 | 28.431,56 | 46.225,00 |
| 2006.01 | 1.740,94 | 371,44 | 5.567,71 | 52.917,94 |
| Média | 36.345,78 | 27.874,16 | 28.692,89 | 38.971,99 |

Tabela 14: MSE - Base de Suape/PE

Com base nos resultados ilustrados acima, podemos observar que o modelo Holt Winters apresentou o melhor desempenho para ambos os critérios. O método de combinação de previsões foi o segundo melhor classificado, superando por pouco o

modelo de Box e Jenkins. A previsão da distribuidora obteve o pior desempenho dentre os modelos avaliados.

Segue abaixo a análise complementar, comparando o resultado da combinação de previsões dos três modelos estudados (Holt Winters, Box e Jenkins e distribuidora) com aqueles obtidos pelos modelos isoladamente (tabelas 15 e 16). Vale ressaltar que o método de combinação de previsões apresenta o melhor desempenho frente aos demais modelos.

| MAPE - Erro Percentual Absoluto Médio | | | | |
|--|----------------------|---------------------|----------------------|---|
| Período | Box e Jenkins | Holt Winters | Distribuidora | Combined Forecast (HW + BJ + Dist) |
| 2005.05 | 1,25% | 4,46% | 10,93% | 4,34% |
| 2005.06 | 4,44% | 11,25% | 8,03% | 9,11% |
| 2005.07 | 5,73% | 7,85% | 2,27% | 2,34% |
| 2005.08 | 17,01% | 14,96% | 13,16% | 11,63% |
| 2005.09 | 3,93% | 2,27% | 3,13% | 5,59% |
| 2005.10 | 2,19% | 3,15% | 4,01% | 3,54% |
| 2005.11 | 3,01% | 6,91% | 7,47% | 5,53% |
| 2005.12 | 12,51% | 0,73% | 8,84% | 3,92% |
| 2006.01 | 1,88% | 0,87% | 10,38% | 1,31% |
| Média | 5,77% | 5,83% | 7,58% | 5,25% |

Tabela 15: MAPE II - Base de Suape/PE

| MSE - Erro Quadrático Médio | | | | |
|------------------------------------|----------------------|---------------------|----------------------|---|
| Período | Box e Jenkins | Holt Winters | Distribuidora | Combined Forecast (HW + BJ + Dist) |
| 2005.05 | 547 | 6.926 | 41.589 | 6.549 |
| 2005.06 | 7.606 | 48.932 | 24.932 | 32.043 |
| 2005.07 | 13.556 | 25.389 | 2.117 | 2.251 |
| 2005.08 | 161.859 | 125.130 | 96.878 | 75.607 |
| 2005.09 | 7.644 | 2.548 | 4.855 | 15.449 |
| 2005.10 | 2.168 | 4.495 | 7.301 | 5.676 |
| 2005.11 | 3.954 | 20.906 | 24.452 | 13.389 |
| 2005.12 | 92.568 | 317 | 46.225 | 9.067 |
| 2006.01 | 1.741 | 371 | 52.918 | 843 |
| Média | 32.405 | 26.113 | 33.474 | 17.875 |

Tabela 16: MSE II - Base de Suape/PE

5.3 - Base: Brasília/DF

O último caso abordado é o da base de distribuição de Brasília, no Distrito Federal. Trata-se de uma base primária, cujo modal de recebimento de produtos é o dutoviário - oleoduto OSBRA (Oleoduto São Paulo-Brasília), que liga a Refinaria de Paulínia/SP ao Terminal da Petrobras em Brasília/DF. A área de influência da base compreende o Distrito Federal e grande parte do Estado de Goiás.

5.3.1 - Resultados Encontrados

Foi adotado processo analítico idêntico aos das bases de distribuição de Duque de Caxias/RJ e Suape/PE. Observamos que a etapa de identificação dos modelos apresentou as mesmas similaridades verificadas anteriormente, o que ratifica a hipótese de que as variáveis de interesse compartilham características comuns.

Os resultados relativos à análise do erro de previsão (*out-of-sample*) são apresentados de maneira consolidada nas tabelas 17 e 18.

| MAPE - Erro Percentual Absoluto Médio | | | | |
|--|----------------------|---------------------|------------------------------------|-------------------------------|
| Período | Box e Jenkins | Holt Winters | Combined Forecast (HW + BJ) | Previsão Distribuidora |
| 2004.05 | 13,23% | 8,29% | 9,01% | 14,28% |
| 2004.06 | 8,90% | 0,25% | 6,60% | 2,48% |
| 2004.07 | 10,93% | 4,77% | 4,97% | 11,88% |
| 2004.08 | 4,63% | 1,95% | 0,30% | 3,20% |
| 2004.09 | 0,35% | 16,43% | 8,55% | 14,05% |
| 2004.10 | 4,82% | 4,34% | 1,45% | 2,89% |
| 2004.11 | 5,76% | 0,36% | 5,84% | 2,47% |
| 2004.12 | 5,12% | 8,74% | 0,30% | 6,66% |
| 2005.01 | 16,10% | 4,71% | 12,65% | 11,61% |
| 2005.02 | 11,87% | 5,22% | 11,09% | 6,18% |
| 2005.03 | 6,40% | 3,78% | 2,57% | 9,62% |
| 2005.04 | 11,62% | 5,37% | 5,70% | 8,09% |
| 2005.05 | 10,96% | 4,94% | 4,66% | 4,05% |
| 2005.06 | 14,60% | 21,55% | 16,96% | 19,82% |
| 2005.07 | 2,85% | 0,17% | 4,72% | 3,79% |
| 2005.08 | 1,45% | 3,66% | 7,15% | 12,37% |
| 2005.09 | 8,40% | 4,32% | 3,21% | 7,85% |
| 2005.10 | 4,65% | 3,82% | 2,18% | 8,09% |
| 2005.11 | 0,42% | 5,99% | 1,68% | 1,94% |
| 2005.12 | 13,31% | 0,72% | 8,23% | 12,15% |
| 2006.01 | 9,29% | 2,18% | 4,50% | 2,41% |
| Média | 7,89% | 5,31% | 5,83% | 7,90% |

Tabela 17: MAPE - Base de Brasília/DF

| MSE - Erro Quadrático Médio | | | | |
|------------------------------------|----------------------|---------------------|------------------------------------|-------------------------------|
| Período | Box e Jenkins | Holt Winters | Combined Forecast (HW + BJ) | Previsão Distribuidora |
| 2004.05 | 236.992,18 | 93.025,26 | 109.808,62 | 276.058,22 |
| 2004.06 | 83.885,78 | 64,55 | 46.162,12 | 6.517,17 |
| 2004.07 | 167.785,92 | 31.928,34 | 34.720,66 | 198.025,00 |
| 2004.08 | 31.090,94 | 5.496,87 | 128,75 | 14.884,24 |
| 2004.09 | 172,34 | 384.092,21 | 103.959,10 | 280.900,00 |
| 2004.10 | 36.352,30 | 29.530,10 | 3.300,21 | 13.129,26 |
| 2004.11 | 45.277,46 | 173,51 | 46.468,62 | 8.297,02 |
| 2004.12 | 33.420,03 | 97.395,37 | 118,10 | 56.454,24 |
| 2005.01 | 251.890,97 | 21.594,40 | 155.626,10 | 131.044,00 |
| 2005.02 | 119.378,04 | 23.133,38 | 104.285,21 | 32.409,72 |
| 2005.03 | 42.150,81 | 14.709,24 | 6.780,91 | 95.293,22 |
| 2005.04 | 172.008,94 | 36.680,72 | 41.390,47 | 83.296,31 |
| 2005.05 | 180.823,51 | 36.731,40 | 32.710,28 | 24.654,97 |
| 2005.06 | 414.853,16 | 903.744,25 | 559.825,20 | 764.383,00 |
| 2005.07 | 15.467,02 | 53,20 | 42.547,58 | 27.493,62 |
| 2005.08 | 3.829,93 | 24.527,08 | 93.456,03 | 280.175,43 |
| 2005.09 | 110.718,31 | 29.237,48 | 16.147,37 | 96.721,00 |
| 2005.10 | 38.970,36 | 26.321,17 | 8.574,33 | 117.909,14 |
| 2005.11 | 317,23 | 63.620,31 | 5.001,94 | 6.667,05 |
| 2005.12 | 244.025,48 | 721,06 | 93.310,98 | 203.401,00 |
| 2006.01 | 106.509,48 | 5.877,51 | 25.025,82 | 7.140,76 |
| Média | 111.234,29 | 87.078,92 | 72.826,12 | 129.754,97 |

Tabela 18: MSE - Base de Brasília/DF

A partir da leitura dos resultados, podemos observar que o modelo Holt Winters mais uma vez apresentou o melhor desempenho para o critério MAPE. O método de combinação de previsões foi o melhor classificado pelo critério MSE. Ambos superaram

os modelos de Box e Jenkins e as previsões da própria distribuidora. Esta última apresentou o pior resultado nos dois critérios de avaliação.

Por fim, os gráficos abaixo apresentam a análise comparativa dos resultados obtidos pelos diferentes modelos estudados, frente ao método de combinação de previsões dos três modelos (Holt Winters, Box e Jenkins e distribuidora). O modelo Holt Winters apresenta melhor desempenho para o critério MAPE, seguido do método de combinação de previsões. Já com relação ao critério MSE, o método de combinação de previsões obteve o melhor desempenho, seguido do modelo Holt Winters. As previsões de Box e Jenkins e da distribuidora foram, respectivamente, a terceira e quarta colocadas para ambos os casos.

| MAPE - Erro Percentual Absoluto Médio | | | | |
|--|----------------------|---------------------|----------------------|---|
| Período | Box e Jenkins | Holt Winters | Distribuidora | Combined Forecast (HW + BJ + Dist) |
| 2005.05 | 10,96% | 4,94% | 4,05% | 2,92% |
| 2005.06 | 14,60% | 21,55% | 19,82% | 17,46% |
| 2005.07 | 2,85% | 0,17% | 3,79% | 9,31% |
| 2005.08 | 1,45% | 3,66% | 12,37% | 6,58% |
| 2005.09 | 8,40% | 4,32% | 7,85% | 0,12% |
| 2005.10 | 4,65% | 3,82% | 8,09% | 0,41% |
| 2005.11 | 0,42% | 5,99% | 1,94% | 2,32% |
| 2005.12 | 13,31% | 0,72% | 12,15% | 5,99% |
| 2006.01 | 9,29% | 2,18% | 2,41% | 5,88% |
| Média | 7,33% | 5,26% | 8,05% | 5,67% |

Tabela 19: MAPE II - Base de Brasília/DF

| MSE - Erro Quadrático Médio | | | | |
|------------------------------------|----------------------|---------------------|----------------------|---|
| Período | Box e Jenkins | Holt Winters | Distribuidora | Combined Forecast (HW + BJ + Dist) |
| 2005.05 | 180.824 | 36.731 | 24.655 | 12.863 |
| 2005.06 | 414.853 | 903.744 | 764.383 | 593.107 |
| 2005.07 | 15.467 | 53 | 27.494 | 165.552 |
| 2005.08 | 3.830 | 24.527 | 280.175 | 79.179 |
| 2005.09 | 110.718 | 29.237 | 96.721 | 24 |
| 2005.10 | 38.970 | 26.321 | 117.909 | 305 |
| 2005.11 | 317 | 63.620 | 6.667 | 9.517 |
| 2005.12 | 244.025 | 721 | 203.401 | 49.483 |
| 2006.01 | 106.509 | 5.878 | 7.141 | 42.648 |
| Média | 123.946 | 121.204 | 169.838 | 105.853 |

Tabela 20: MSE II - Base de Brasília/DF

6 Conclusão e Considerações Finais

6.1 - Conclusão

O presente trabalho teve por objetivo principal a análise do emprego de modelos de séries temporais, na resolução do problema de otimização das previsões de vendas das distribuidoras de combustíveis.

Para tal, foi proposta a utilização de um arcabouço teórico baseado nos modelos de Box e Jenkins, Holt Winters e no método de combinação de previsões (utilizando as previsões destes últimos). Foram analisadas séries históricas de vendas de três diferentes bases de distribuição de combustíveis (análise empírica).

Com base nos resultados encontrados, pode-se notar que o modelo Holt Winters obteve o melhor desempenho no que diz respeito à previsão *out-of-sample* (MAPE e MSE), seguido de perto e, em alguns casos, superado pelo método de combinação de previsões (combinando os modelos de Holt Winters e Box e Jenkins). Já o modelo de Box e Jenkins apresentou desempenho inferior aos demais, superando apenas as previsões da distribuidora. Esta última apresentou o pior desempenho dentre os modelos analisados. A tabela 21 traz uma análise descritiva dos resultados obtidos, considerando os modelos propostos para cada uma das bases de distribuição consideradas, segundo critério de minimização do MAPE e MSE.

| Ranking (Minimização MAPE) | Duque de Caxias/RJ | Suape/PE | Brasília/DF |
|---------------------------------------|---------------------------|---------------------------|---------------------------|
| 1º | Comb. Previsões (HW + BJ) | Holt Winters | Holt Winters |
| 2º | Holt Winters | Comb. Previsões (HW + BJ) | Comb. Previsões (HW + BJ) |
| 3º | Box e Jenkins | Box e Jenkins | Box e Jenkins |
| 4º | Previsão Distribuidora | Previsão Distribuidora | Previsão Distribuidora |
| Ranking (Minimização MSE) | Duque de Caxias/RJ | Suape/PE | Brasília/DF |
| 1º | Holt Winters | Holt Winters | Comb. Previsões (HW + BJ) |
| 2º | Comb. Previsões (HW + BJ) | Comb. Previsões (HW + BJ) | Holt Winters |
| 3º | Box e Jenkins | Box e Jenkins | Box e Jenkins |
| 4º | Previsão Distribuidora | Previsão Distribuidora | Previsão Distribuidora |

Tabela 21: Desempenho dos Modelos Teóricos de Previsão de Séries Temporais

Com base nas análises realizadas, podemos considerar que os modelos teóricos propostos apresentaram resultados extremamente positivos, visto que o desempenho em todos os casos estudados foi superior à previsão atual da distribuidora. Convém ressaltar que o estudo empírico realizado tomou por base horizonte de tempo análogo àquele considerado pela distribuidora nas suas previsões, permitindo, dessa forma, a comparação dos resultados.

Por ter apresentado os melhores resultados, o modelo Holt Winters seria o mais indicado para reduzir as perdas no processo de previsão de demanda realizado pela distribuidora em estudo. Convém ressaltar que o referido modelo é de simples implementação, fato que corrobora a indicação de sua aplicação em problemas reais.

Cabe também considerar os resultados consolidados do quadro abaixo, refletindo o desempenho do método de combinação utilizando os três modelos de previsão (Holt Winters, Box e Jenkins e distribuidora) comparado à performance dos modelos isoladamente.

| Ranking (Minimização MAPE) | Duque de Caxias/RJ | Suape/PE | Brasília/DF |
|-------------------------------|-----------------------------------|-----------------------------------|-----------------------------------|
| 1º | Holt Winters | Comb. Previsões (HW + BJ + Dist.) | Holt Winters |
| 2º | Box e Jenkins | Box e Jenkins | Comb. Previsões (HW + BJ + Dist.) |
| 3º | Comb. Previsões (HW + BJ + Dist.) | Holt Winters | Box e Jenkins |
| 4º | Previsão Distribuidora | Previsão Distribuidora | Previsão Distribuidora |

| Ranking (Minimização MSE) | Duque de Caxias/RJ | Suape/PE | Brasília/DF |
|------------------------------|-----------------------------------|-----------------------------------|-----------------------------------|
| 1º | Comb. Previsões (HW + BJ + Dist.) | Comb. Previsões (HW + BJ + Dist.) | Comb. Previsões (HW + BJ + Dist.) |
| 2º | Holt Winters | Holt Winters | Holt Winters |
| 3º | Box e Jenkins | Box e Jenkins | Box e Jenkins |
| 4º | Previsão Distribuidora | Previsão Distribuidora | Previsão Distribuidora |

Tabela 22: Combinação de Previsões (Holt Winters, Box e Jenkins e Distribuidora)

Baseado nas análises apresentadas, conclui-se que o desempenho do modelo de combinação de previsões apresenta o melhor resultado frente aos demais, superando inclusive, na maior parte dos casos, o modelo Holt Winters. Entretanto, seria necessário dispormos de uma série histórica mais abrangente de previsões da distribuidora, para garantirmos a consistência dos resultados encontrados.

As conclusões do trabalho confirmam os resultados de estudos empíricos realizados. MAKRIDAKIS, WHEELWRIGHT e MCGEE (1983) constataram que o incremento da complexidade e da sofisticação estatística dos métodos de previsão de séries temporais não implica, necessariamente, em melhoria na acuidade da previsão. “Métodos simples de previsão podem apresentar desempenho extremamente satisfatório sob certas condições”. Além disso, métodos de previsão menos complexos normalmente permitem alcançar total compreensão de suas suposições e limitações, e de interpretação de seus resultados. Assim, antes de se adotar um método de previsão mais complexo, é necessário avaliar os benefícios que um método dessa natureza pode gerar em relação ao custo de sua aplicação.

Como a acuidade de uma previsão fica determinada não apenas pelo horizonte de previsão especificado, mas também pelas características das observações da série

temporal investigada, a otimização desse critério pode ser alcançada com a aplicação de mais de um método de previsão. A combinação de previsões ou a verificação da consistência desses valores permite aumentar a confiabilidade da previsão e reduzir a possibilidade de grandes desvios.

6.2 - Ganhos Potenciais

Como mencionado no primeiro capítulo, o ponto mais importante diz respeito à capacidade de geração de ganho financeiro pela otimização do processo de previsão de vendas. Embora seja difícil mensurar integralmente os impactos financeiros, podemos ter uma indicação de sua ordem de grandeza.

O benefício financeiro mais evidente refere-se ao custo do capital para níveis de estoque desnecessários. Para uma distribuidora de abrangência nacional, como é o caso da empresa estudada, considerando um capital empregado em estoques da ordem de R\$ 100 milhões e um custo de capital de 17% ao ano (valor aproximado da taxa de juros do país), se otimizarmos os níveis de estoques em 1%, teríamos um benefício da ordem de R\$ 200 mil por ano.

Outro ponto de relevância refere-se à otimização da cadeia logística, evitando custos de operações emergenciais relativos às penalidades e condições extracontratuais junto a fornecedores e transportadores. A partir de dados obtidos junto à distribuidora, estima-se que os custos ligados a estes fatores superem os R\$ 5 milhões por ano.

6.3 - Sugestões de Desenvolvimentos Futuros

Apesar dos resultados positivos encontrados com a utilização dos modelos teóricos propostos, cabe ressaltar a relevância da análise qualitativa no momento da confecção da previsão de vendas. Esta informação não deve ser ignorada, por mais preciso e confiável que seja o método quantitativo empregado.

Assim, seguindo a mesma linha de pesquisa apresentada, seria interessante avaliar como se comportariam os resultados ao combinarmos o método quantitativo de maior precisão, modelo de Holt Winters, com as informações qualitativas passíveis de serem obtidas pela distribuidora, seguindo metodologia defendida por PEREIRA, COQUEIRO, PERROTA (1989).

Outra sugestão relevante seria a de passar a utilizar um horizonte de previsão mais longo, acarretando benefícios em termos de planejamento para a distribuidora e minimizando impactos sobre as áreas operacionais que dependem da acurácia na previsão de demanda (Setor de Suprimentos, por exemplo, diretamente ligado ao processo de aquisição de produtos junto aos fornecedores). Neste ponto, vale ressaltar o comportamento dos modelos de amortecimento exponencial com tendência amortecida (*damped trends*), citados nos estudos empíricos de MAKRIDAKIS *et al.* (1982), que apresentam desempenho superior aos modelos usuais para horizontes mais longos de previsão.

7 Referências Bibliográficas

- ANANDALINGAM, G., CHEN, L., 1989, “Linear combination of forecasts: a general bayesian model”, *Journal of Forecasting*, v. 8, n. 3, pp. 199-214.
- BATES, J.M., GRANGER, C.W.J., 1969, “The Combination of Forecasts”, *Operational Research Quaterly*, n. 20, pp. 451-468.
- BOX, G., JENKINS, G., 1976, *Time Series Analysis: Forecasting and Control*, revised ed., San Francisco, Holden-Day.
- CLEMEN, R.T., 1989, “Combining forecasts: A review and annotated bibliography”, *International Journal of Forecasting*, n. 5, pp. 559-583.
- CLEMEN, R. T., WINKLER, R.L., 1985, “Limits for the precision and value of information from dependent sources”, *Operations Research*, v. 33, n. 2, pp. 427-442.
- CLEMENTE, A. et al., 1998, *Projetos empresariais e públicos*. 2 ed. São Paulo, Atlas.
- GALTON, F., 1907, “Vox Populi”, *Nature*, v.75, n. 1949, pp. 450-451.
- GRANGER, C.W. J., RAMANATHAN, R., 1984, “Improved methods of combining forecasts”, *Journal of Forecasting*, v. 3, n. 2, pp. 197-204.
- GRANGER, C.W. J., 1989, “Invited review combining forecasts - Twenty years later”, *Journal of Forecasting*, v. 8, n. 3, pp. 167-173.
- HIBON, M., EVGENIOU, T., 2004, “To combine or not combine: selecting among forecasts and their combinations”, *International Journal of Forecasting*, v.1, n. 21, pp. 15-24.
- MAKRIDAKIS, S., 1982, “The accuracy of extrapolation (time series) methods: results of a forecasting competition”, *Journal of Forecasting*, n. 1, pp. 111-153.
- MAKRIDAKIS, S., HIBON, M., 1979, “Accuracy of Forecasting: An Empirical Investigation”, *Journal of the Royal Statistical Society*, v. 142, n. 2, pp. 97-145.
- MAKRIDAKIS, S., WHEELWRIGTH, S., MCGEE, V., 1983, *Forecasting: Methods and Applications*. 2 ed. New York, Wiley.
- MILLER, B., 2003, “Outlook and closing observations”. *Legg Mason Funds Management Conference*, November 8th.

- NEWBOLD, P., GRANGER, C.W.J., 1974, "Experience with forecasting univariate time series and the combination of forecasts", *Journal of Royal Statistical Society*, v. 2, n. 137, pp. 131-165.
- PAPOULIS, A., 1965, *Probability, Random Variables, and Stochastic Processes*. 1 ed. New York, McGraw-Hill.
- PEGELS, C. C., 1969, "Exponential forecasting: some new variations", *Management Science*, v. 12, n. 5, pp. 311-315.
- PEREIRA, B. B., COQUEIRO, R. C. O., PERROTA, A. H. V., 1989, "Experience in Combining Subjective and Quantitative Forecasts of Open Market Rates", *Journal of Forecasting*, v. 8, n. 3, pp. 343-348.
- PORTER, M., 1986, *Estratégia Competitiva - Técnicas para Análise de Indústrias e da Concorrência*. 7 ed. Rio de Janeiro, Campus.
- ROBERTS, S., 1982, "A General Class of Holt-Winters Type Forecasting Models", *Management Science*, v. 28, pp. 808-820.
- SUROWIECKI, J., 2004, *The wisdom of crowds: Why the many are smarter than the few and how collective wisdom shape business, economies, societies and nations*, Doubleday.
- WINKLER, R. L., 1981, "Combining probability distributions from dependent information sources", *Management Science*, v. 27, n. 4, pp. 479-488.