

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

ROBERTO BRAGA FERNANDES FILHO

**INTEGRAÇÃO DE MODELOS DE PREVISÃO DE DEMANDA
QUALITATIVOS E QUANTITATIVOS E COMPARAÇÃO COM SEUS
DESEMPENHOS INDIVIDUAIS**

**PORTO ALEGRE
2015**

ROBERTO BRAGA FERNANDES FILHO

**INTEGRAÇÃO DE MODELOS DE PREVISÃO DE DEMANDA
QUALITATIVOS E QUANTITATIVOS E COMPARAÇÃO COM
SEUS DESEMPENHOS INDIVIDUAIS**

**Trabalho de Conclusão do Curso
de Mestrado Profissional em
Engenharia como requisito
parcial à obtenção do título de
Mestre em Engenharia,
modalidade Profissional.**

Orientador: Prof. Dr. Ricardo Augusto Cassel

Porto Alegre

2015

ROBERTO BRAGA FERNANDES FILHO

**INTEGRAÇÃO DE MODELOS DE PREVISÃO DE DEMANDA
QUALITATIVOS E QUANTITATIVOS E COMPARAÇÃO COM
SEUS DESEMPENHOS INDIVIDUAIS**

**Trabalho de Conclusão do Curso
de Mestrado Profissional em
Engenharia como requisito
parcial à obtenção do título de
Mestre em Engenharia,
modalidade Profissional**

Prof. Dr. Ricardo Augusto Cassel

Prof. Dr. José Luis Duarte Ribeiro

Aprovado em: __/__/__

BANCA EXAMINADORA

Prof. Dr. Cláudio José Müller – UFRGS

Prof. Dra. Liane Werner – UFRGS

Prof. Dr. Luis Felipe R. Camargo – Unisinos

À minha noiva, meus
pais e meu irmão, pelo
apoio e compreensão
incondicionais.

RESUMO

Um bom sistema de previsão de demanda é um dos passos para o sucesso de uma empresa. Previsões com baixos erros permitem a manutenção de um estoque reduzido, uma ocupação de fábrica e uma gestão financeira mais eficiente, em conjunto com outros benefícios trazidos por um sistema confiável. Há diversas formas de realizar uma previsão, mas há anos a que vem sendo considerada mais promissora é a que integra métodos quantitativos e qualitativos. Ambos os métodos possuem vantagens exclusivas, o que torna a integração particularmente interessante. Este trabalho visa o desenvolvimento e teste de um sistema de previsão em uma empresa de grande porte, a fim de disponibilizar uma forma confiável de integração de métodos. Busca ainda validar o auxílio de especialistas nos ajustes de previsão de forma que os problemas provenientes do julgamento humano possam ser evitados. Uma comparação entre as várias previsões realizadas é apresentada, de forma que o leitor possa interpretá-las e julgar quais possam ser as mais adequadas à situação em que se encontra.

Palavras Chave: Demanda, Previsão de Demanda, Previsão integrada

ABSTRACT

A good forecasting system is one of the steps to the success of a company. Forecasts with small errors enable the maintenance of a reduced inventory, a more efficient factory occupation and financial management, together with other benefits provided by a reliable system. There are several ways to make a forecast, but for years the quantitative and qualitative methods integrated has been considered more promising. Both methods have unique advantages which makes it particularly interesting integration. This paper aims to develop and test a forecasting system in a large company in order to provide a reliable form of integration methods. It also seeks to validate the aid of experts in the predictive adjustments so that problems derived from the human judgment can be avoided. A comparison of the various forecasts made is provided in a way that the reader can interpret them and judge which may be the most appropriate to the situation you are in.

Key-Words: Demand, Forecasting, Integrated Forecasting

LISTA DE FIGURAS

Figura 1: Metodologia utilizada para desenvolvimento do trabalho.....	15
Figura 2: Demanda histórica com linha de tendência	28
Figura 3: Comparativo entre demanda histórica e modelo de Winters	29
Figura 4: Comparativo entre demanda histórica e modelo de Decomposição.....	30
Figura 5: FAC e FACP da série temporal.....	31
Figura 6: FAC e FACP da série temporal após diferenciação.....	31
Figura 7: Comparativo entre demanda histórica e modelo de ARIMA	32
Figura 8: FAC de resíduos do modelo ARIMA aplicado	33
Figura 9: Esquemático de ajuste de previsão baseado em opinião de especialista.....	47
Figura 10: Ciclo de Vida de Produtos.....	50
Figura 11: Padrões comuns de ciclo de vida de produtos	50
Figura 12: Demanda histórica com linha de tendência	51

LISTA DE TABELAS

Tabela 1: Demanda histórica do produto	27
Tabela 2: Resultado da aplicação do modelo Winters multiplicativo	29
Tabela 3: Resultado da Aplicação do Modelo de Decomposição Clássica	30
Tabela 4: Resultado da Aplicação do Modelo de ARIMA	32
Tabela 5: Comparativo de MAPE entre os modelos aplicados	34
Tabela 6: Demanda histórica do produto	51
Tabela 7: Integração entre previsões quantitativas.....	52
Tabela 8: Integração entre previsões qualitativa e quantitativa	53
Tabela 9: Integração entre previsão qualitativa e três quantitativas	53
Tabela 10: Integração via média ponderada entre Winters e ARIMA.....	54
Tabela 11: Integração via média ponderada entre Winters e Qualitativo	54
Tabela 12: Integração via média ponderada entre qualitativo e três modelos quantitativos	55
Tabela 13: Ajuste de especialistas baseados na previsão gerada pelo modelo de Winters....	55
Tabela 14: Ajuste de especialistas baseados na previsão gerada pelo modelo integrado via média aritmética.....	56
Tabela 15: Ajuste de especialistas baseados na previsão gerada pelo modelo integrado via média ponderada.....	56
Tabela 16: resultado da integração aritmética entre modelos Winters e ARIMA	57
Tabela 17: Resultado da integração aritmética entre modelos Winters e qualitativo	57
Tabela 18: Resultado da integração aritmética entre quatro modelos	58
Tabela 19: Resultados da integração ponderada entre modelos Winters e ARIMA.....	58
Tabela 20: Resultado da integração ponderada da previsão qualitativa e do modelo de Winters	59
Tabela 21: Resultados da integração ponderada entre quatro previsões individuais	59
Tabela 22: Resultados dos ajustes de previsão baseados na opinião de especialistas	60
Tabela 23: Consolidado de Resultados das integrações	60
Tabela 24: Consolidado de Resultados de MAPE das previsões integradas	61
Tabela 25: Comparação da integração de métodos	61

INDICE

1. Introdução	11
1.1 Considerações Iniciais	11
1.2 Problema de Pesquisa	12
1.3 Objetivos	13
1.3.1 Objetivo Geral	13
1.3.2 Objetivo Específico	13
1.4 Justificativa do trabalho	13
1.5 Metodologia	14
1.5.1 Método de Pesquisa	14
1.5.2 Método de trabalho	14
1.7 Estrutura	17
1.8 Referências	17
2. Artigo Um: Previsão de Demanda em uma Indústria Cordoeira	18
Resumo	18
2.1 Introdução	18
2.2 Referencial Teórico	21
2.2.1 Modelo de Winters	22
2.2.2 Modelos de Decomposição Clássica	24
2.2.3 Modelos de Box-Jenkins	24
2.2.4 Validação do Método	25
2.3 Procedimentos Metodológicos	26
2.3.1 Modelo de Winters	28
2.3.2 Modelo de Decomposição Clássica	29
2.3.3. Modelo ARIMA	30
2.4 Resultados e Discussões	33
2.5 Conclusão	34
2.6 Referências	36
3. Artigo dois: Análise de Ganho de Acuracidade na Integração de Modelos de Previsão de Demanda	38
Resumo	38
3.1 Introdução	38

3.2 Referencial Teórico	41
3.2.1 Integração de Modelos Via Média Aritmética	45
3.2.2 Integração de Previsão Via Média Ponderada	45
3.2.3 Ajuste de Previsão Quantitativa Baseado em Opinião de Especialista	46
3.2.4 Acurácia - MAPE	48
3.3 Procedimentos Metodológicos	49
3.3.1 Integração de Previsões Via Média Aritmética	52
3.3.2 Integração de Previsão Via Média Ponderada	53
3.3.3 Ajuste de Previsão Quantitativa Baseado em Opinião de Especialista	55
3.4 Resultados e Discussões	57
3.4.1 Integração via Média Aritmética	57
3.4.2 Integração via Média Ponderada	58
3.4.3 Ajuste de Previsão por Opinião de Especialistas	59
3.4.4 Avaliação dos resultados obtidos	60
3.4.5 Integrações de previsões	61
3.4.6 Ajuste de especialista	62
3.5 Conclusão	63
3.6 Referências	64
4. Conclusão	67
4.1 A Escolha do Método Quantitativo	67
4.2 Desempenho dos Modelos Mistos	67
4.3 Desempenho do Ajuste de Especialistas	68
4.4 Considerações Finais	68
4.5 Sugestões para pesquisas futuras	69

1. Introdução

1.1 Considerações Iniciais

A manutenção da sobrevivência das organizações empresariais no cenário global atual não depende mais apenas do grande espírito empreendedor dos seus sócios ou do tamanho do potencial de injeção de capital de grandes investidores. Traçar estratégias, estar sempre atento às mudanças de exigências do mercado consumidor, entrada de novos concorrentes, inovações tecnológicas, mudanças políticas, econômicas, financeiras, climáticas, enfim, o mundo incerto dos negócios está cada vez mais abrangente, mais indefinido e mais difícil para aqueles que buscam perseverar e manter suas instituições lucrativas.

Segundo Werner e Ribeiro (2003), as empresas que têm o desejo de manterem-se no mercado local ou mundial devem estar atentas aos rumos que a situação está tomando no âmbito global. De acordo com Mileski Jr. (2007), mesmo empresas localizadas em países ainda em processo de industrialização já enfrentam os desafios de um mercado globalizado.

Um passo importante rumo ao sucesso das instituições é realizar um bom dimensionamento da produção, que somente pode ser realizado via uma boa previsão de demanda. Não basta uma boa imagem, baixos custos ou alta qualidade para uma empresa obter sucesso. É necessário também que se tenha um bom dimensionamento de bens e serviços produzidos para atender à demanda do mercado consumidor (Werner e Ribeiro, 2006).

A dificuldade principal desta atividade recai sobre a grande quantidade de variáveis de influência da demanda de produtos e serviços. Conforme Casagrande e Hoss (2010), as múltiplas combinações destas variáveis contribuem para o aumento da dificuldade de composição de uma boa previsão. Não há formas de garantir que se conheçam todas as variáveis envolvidas nas alterações de mercado e monitorá-las a fim de se ter um controle de quais impactos poderão ter no cenário comercial. Um modelo de previsão de demanda que não contenha a variável de erro ainda não pode existir, mas o que se pode fazer e é feito em grande parte das corporações atuais é trabalhar duro para reduzir ao máximo essa variável, trazendo maior confiabilidade ao sistema e aos investimentos.

Mas existem muitos casos ainda em que o uso de um método em específico não consegue ser suficientemente abrangente para aumentar a acurácia em níveis satisfatórios. Nestes casos, é muito comum a utilização de mais de um método para a realização das previsões. E a forma de unir estes métodos de previsão também varia muito dependendo da

sua aplicação. De acordo com Werner e Ribeiro (2006), combinar as previsões é uma forma de utilizar toda informação disponível para gerar uma previsão mais confiável.

Segundo Clemen (1989), a integração de métodos de previsão teve seu início na década de 70, mas ainda hoje é bastante utilizada como fonte de melhoria e aumento da capacidade de abrangência de métodos distintos. A análise de dados passados é necessária para a maioria dos métodos, porém, somente ela, sem avaliação de outros fatores influentes na demanda, é insatisfatória em quase todos os cenários atuais. Existem diversos eventos inéditos ou com impactos diferentes do que os anteriores que não podem ser mensurados apenas com a avaliação de dados históricos.

A forma de inserir informações adicionais a uma previsão realizada varia tanto quanto a quantidade de informações disponíveis. Porém, esses fatores não são diretamente inseridos na previsão, em valores numéricos. Esta inserção deve ser feita de forma metodológica e confiável, sob pena de comprometer os resultados de toda a previsão e gerar desastrosos prejuízos à instituição.

Este é um dos desafios de muitas corporações. Empresas com anos de atuação no mercado, gestores muito experientes e muitas vezes com grandes bancos de dados, na maior parte das vezes, não conseguem extrair todo o potencial que esta disponibilidade de informações é capaz de propiciar. A busca por melhores integrações, para que os modelos de previsão possam ser mais abrangentes, continua existindo e não parece perto de terminar.

1.2 Problema de Pesquisa

A busca por uma previsão de demanda de boa qualidade é grande e, geralmente, traz bons resultados às empresas que investem tempo e dinheiro nesta atividade. Pesquisadores no mundo todo procuram métodos para propiciar aos gestores tomadas de decisões mais seguras, colocando menores riscos sobre os investimentos realizados e garantido a margem de lucro mínima desejada.

Os benefícios em se obter maior acuracidade na previsão da demanda são percebidos por muitas instituições nos dias atuais. Segundo levantamento apresentado pelo *Institute of Business Forecasting & Planning (IBF)*, de 2005, a média da redução de perdas entre dez indústrias do setor de produtos de consumo foi de 3,52 milhões de dólares para uma redução média de 1% do erro de previsão de demanda para previsões com vieses negativos e 1,43 milhões para 1% de redução de vieses positivos. Estes valores chamam atenção não apenas

pela sua magnitude, mas também porque os investimentos para obter a redução destes percentuais de erro são milhares de vezes menores que o retorno.

Desta forma, as questões de pesquisa deste trabalho podem ser definidas como: é possível obter um modelo com baixo erro e com uma metodologia confiável de conciliação entre os conhecimentos quantitativos e qualitativos para gerar uma previsão? E é viável obter um ajuste de especialista diretamente na previsão gerada com uma confiabilidade razoável?

1.3 Objetivos

1.3.1 Objetivo Geral

O objetivo geral do trabalho é avaliar o desempenho dos modelos tradicionais de previsão de demanda com os modelos de integração propostos.

1.3.2 Objetivo Específico

Os objetivos específicos deste trabalho são:

- Escolher métodos quantitativos para utilização na demanda proposta
- Avaliar o desempenho dos métodos de integração de previsões e se os mesmos trazem benefícios justificáveis aos sistemas de previsão
- Elencar quais os riscos e benefícios de realizar ajustes diretamente na previsão obtida

1.4 Justificativa do trabalho

Para uma maior abrangência de informações dos métodos de previsão de demanda é necessário que sejam considerados fatores não recorrentes na demanda histórica. Para isso é importante a utilização de modelos mistos de forma que os conhecimentos de gestores experientes possam ser considerados no momento de gerar a previsão. A forma de introduzir estes conhecimentos, entretanto, é muitas vezes incluída de forma pouco confiável, podendo acarretar em erros maiores do que as previsões puramente quantitativas. Nesta circunstância se faz necessário o uso de procedimentos metodológicos para a inclusão de fatores de influencia na demanda sem incorrer em riscos de prejudicar muito a previsão.

1.5 Metodologia

1.5.1 Método de Pesquisa

Trabalhos científicos são classificados, de acordo com sua estrutura, em três critérios básicos: objetivo, finalidade e natureza (Andrade (1997)). Dentro do critério de objetivo, a pesquisa pode ser definida em três categorias: exploratória, descritiva ou explicativa. As pesquisas exploratórias buscam aprofundar o conhecimento sobre uma determinada matéria, servindo de fonte de pesquisa para estudos futuros. As pesquisas descritivas são caracterizadas pelo acompanhamento de fatos, mas em que o autor não interage com o mesmo, apenas o descreve. Já nas pesquisas explicativas, ainda segundo Andrade (1997), o objetivo é aprofundar o conhecimento da realidade.

Quanto à finalidade, as pesquisas são divididas em duas classificações: fundamental ou aplicada. Para pesquisas classificadas como fundamentais, a pesquisa é voltada à busca por novos conhecimentos sem que haja necessidade da aplicação. Já na pesquisa aplicada o foco é a busca de solução para problemas do cotidiano, aplicando os conhecimentos existentes e para resolução dos mesmos.

Ainda quanto à natureza do trabalho científico, o mesmo pode ser classificado como bibliográfico, documental ou pesquisa de campo. No caso de pesquisa bibliográfica, trata-se de estudo baseado em informações de livros e fontes antigas. Para trabalhos documentais, o mesmo é baseado em dados estatísticos e fontes históricas primárias e para pesquisa de campo é utilizada a observação de fatos do cotidiano para base do trabalho.

Com base nestes critérios, este trabalho pode ser classificado como pesquisa aplicada, quanto à finalidade, explicativa quanto ao objetivo e documental quanto à natureza.

1.5.2 Método de trabalho

Na figura 1 é possível visualizar as etapas realizadas ao longo do trabalho e a forma que o mesmo foi conduzido. Na primeira etapa foi definido o problema de pesquisa, baseado em uma necessidade real da empresa em que o trabalho foi realizado.

Na segunda etapa foi realizada uma revisão aprofundada da bibliografia existente sobre o assunto de previsão de demanda, com a finalidade de utilizar os métodos mais difundidos e reconhecidos para validá-los em uma situação específica e, frente a seus resultados, realizar as devidas avaliações pertinentes à sua aplicação.

Na terceira etapa as metodologias de sistemas de previsão de demanda foram divididas entre quantitativas, qualitativas e modelos mistos, a fim de avaliar a primeira de forma separada para, posteriormente, comparar seu desempenho com os métodos qualitativos e com as integrações.

Na quarta etapa foram aplicados os modelos quantitativos considerados os mais indicados para a demanda proposta. Já na quinta etapa foram avaliados os desempenhos individuais dos modelos quantitativos na previsão da demanda proposta.

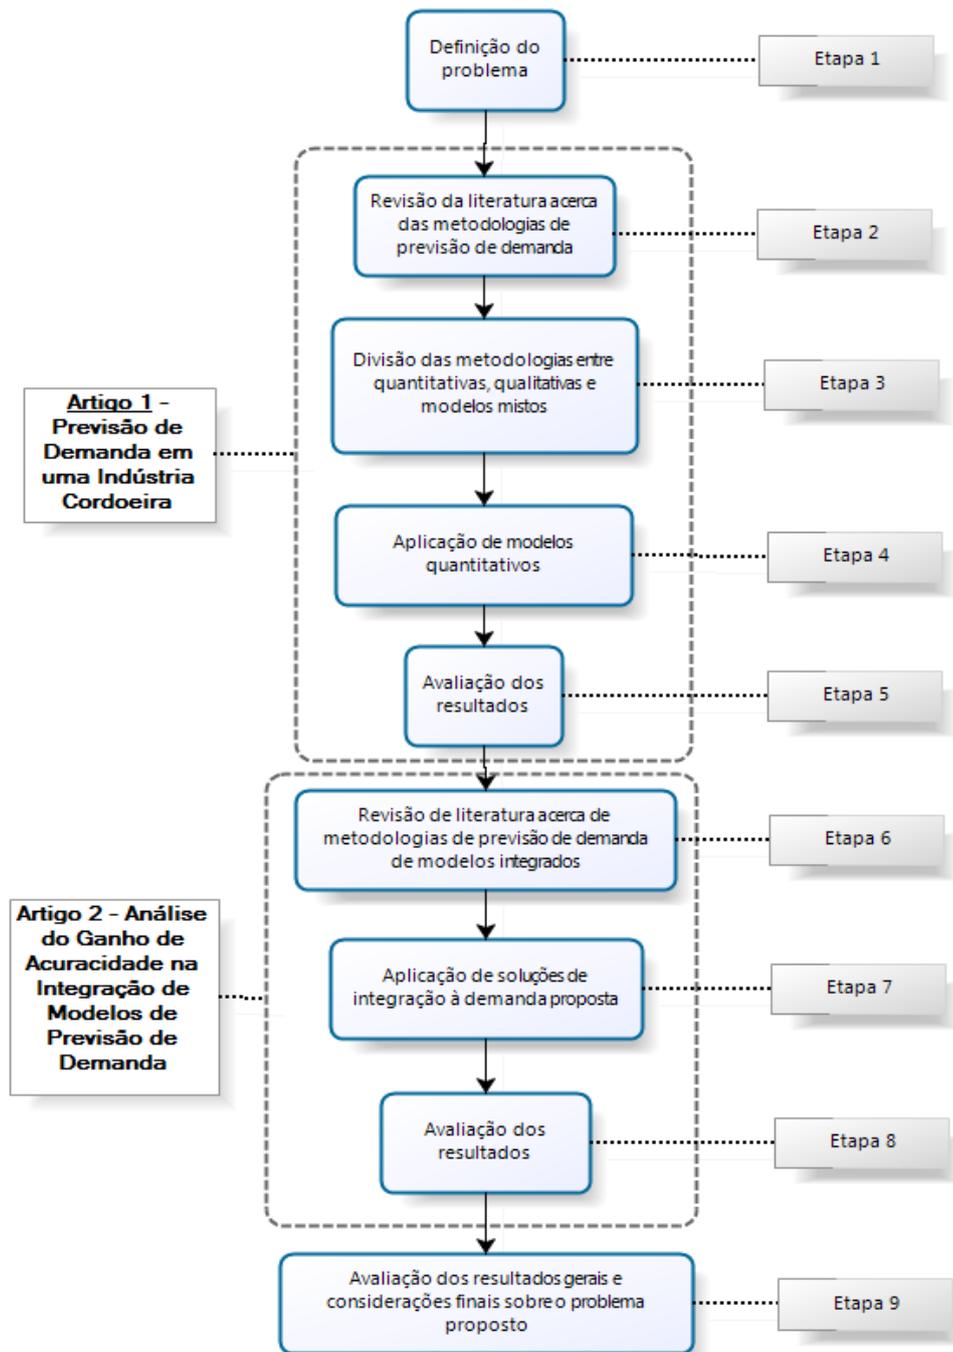


Figura 1: Metodologia utilizada para desenvolvimento do trabalho

Na sexta etapa foi realizada uma nova revisão da bibliografia existente, desta vez com enfoque nos modelos de integração de previsões quantitativas, qualitativas e mistas (quantitativas e qualitativas), a fim de verificar quais os mais indicados para a situação real descrita.

Na sétima etapa foram então desenvolvidas e aplicadas as hipóteses de melhores formas de integração dos métodos encontrados e utilizados na demanda disponibilizada. Posteriormente, na oitava etapa, foi realizada a avaliação das integrações realizadas e a comparação dos desempenhos individuais. Na nona etapa são apresentadas algumas considerações finais acerca dos métodos de integração, sugerindo posteriores estudos dentro da mesma linha de pesquisa utilizada.

1.6 Delimitação

O método apresentado neste trabalho é um método de aplicação geral, porém, foi aplicado e validado em apenas uma situação. Sendo assim, o trabalho possui algumas delimitações. A primeira delas, espacial, refere-se ao local no qual o trabalho foi realizado; as demais relacionadas à abrangência do trabalho no que diz respeito ao assunto abordado.

O trabalho foi realizado sobre a demanda fornecida por uma indústria cordoeira situada no Rio Grande do Sul. Desta forma, as avaliações servem para esta indústria em específico, podendo não ser representativa para outros segmentos de indústrias ou outras regiões geográficas.

Os métodos quantitativos utilizados foram encontrados na bibliografia citada e as respectivas alterações realizadas para o melhor desempenho na demanda trabalhada. Não se objetivou desenvolver métodos genéricos de aplicação para qualquer segmento do mercado.

O trabalho não objetivou realizar análises de custo de implantação dos métodos utilizados, bem como não realiza avaliações de mercado, econômico-financeiras ou de concorrências. As informações que foram utilizadas foram incluídas implicitamente nas previsões qualitativas dos especialistas.

1.7 Estrutura

Este trabalho está dividido da seguinte forma. No Capítulo 1 é apresentado o tema abordado, as justificativas para escolha do mesmo, os objetivos gerais e específicos, as delimitações do trabalho e a estrutura do mesmo.

No capítulo 2 é apresentado o Artigo 1, no qual é realizado o estudo de avaliação dos métodos quantitativos e qual seu desempenho sobre a demanda em questão.

No Capítulo 3 é apresentado o Artigo 2, no qual é realizada a integração entre os métodos de previsão e apresentado o comparativo de desempenho entre os mesmos. É ainda realizado um ajuste de especialista diretamente nos valores obtidos nas previsões e apresentado o desempenho e dificuldades enfrentadas nos mesmos.

No Capítulo 4 é apresentada a conclusão do trabalho, com a avaliação dos objetivos alcançados e sugestão de possíveis estudos futuros.

1.8 Referências

Institute of Business Forecasting & Planning (IBF). **Why Forecasting?**, 2005, disponível em <https://ibf.org/index.cfm?fuseaction=showObjects&objectTypeID=87>

ARMSTRONG, J.S. **Principles of Forecasting: A handbook for researchers and practitioners**. Kluwer Academic Publishers. Philadelphia, 2001

CASAGRANDE, L. F; HOSS O. **Métodos de Forecasting Conjugado com um Método Qualitativo e um Método com a Média das Previsões Quantitativas e Qualitativas**. Revista CAP, Ano 4 (2010)

CLEMEN, R.T. **Combining Forecasts: A Review and Annotated Bibliography**. International Journal of Forecasting 5 (1989) Pag. 559-583

MILESKI JR, A. **Análise de Métodos de Previsão de Demanda Baseados em Séries Temporais em uma Empresa do Setor de Perfumes e Cosméticos**. Dissertação de mestrado em Engenharia de Produção e Sistemas. Curitiba, 2007.

WERNER, L.; RIBEIRO, J. L. D. **Previsão de Demanda: Uma Aplicação dos Modelos Box-Jenkins na Área de Assistência Técnica de Computadores Pessoais**. Revista Gestão e Produção, v.10, n1, 2003. Pag. 47-67

WERNER, L.; RIBEIRO, J. L. D. **Modelo Composto para Prever Demanda Através da Integração de Previsões**. Produção, V.16, n.3, 2006. Pag. 493-509

2. Artigo Um: Previsão de Demanda em uma Indústria Cordoeira

Roberto B. Fernandes Filho

Universidade Federal do Rio Grande do Sul

Dr. Ricardo Augusto Cassel

Universidade Federal do Rio Grande do Sul

Resumo

Este artigo apresenta uma situação em que é objetivada a escolha de um modelo de previsão de demanda para um produto de uma indústria cordoeira, com a intenção de proporcionar recursos de programação da produção. A demanda escolhida contempla características de tendência e sazonalidade a fim de testar modelos variados de previsão de demanda e avaliar seus desempenhos. Com os resultados obtidos é possível afirmar que a utilização de previsão de demanda pode reduzir custos de produção e propiciar melhor aproveitamento de recursos da empresa.

Palavras-Chave: Previsão de demanda, análise de séries temporais, ARIMA, modelo de Holt-Winters.

2.1 Introdução

As recentes descobertas do setor petrolífero no Brasil tornou o país foco de muitas empresas multinacionais de grande porte. Esta abertura de novos horizontes obrigou as empresas locais a se modernizarem e buscarem alternativas para melhorarem seus processos e produtos. De acordo com Farias et al. (2006), esta adaptação deve ser bastante rápida, com estruturas operacionais flexíveis, a fim de proporcionar uma vantagem frente à grande concorrência.

Grande parte das empresas nacionais já tem seu foco mais voltado à melhoria de seus processos e gestão do que aumento da capacidade produtiva. Segundo informativo divulgado pela Confederação Nacional da Indústria (2014), houve um crescimento significativo no investimento em melhorias do processo e uma redução dos investimentos para aumento da capacidade produtiva, o que indica que as empresas entendem que há capacidade produtiva disponível, apenas necessitando melhor gestão da mesma.

Planejar os recursos humanos que deverão estar disponíveis, a matéria prima, os equipamentos, o capital, entre outros, faz parte de um bom gerenciamento. Ballou (2006) afirma que os efeitos da demanda no momento em que a mesma ocorre tem influência direta sobre índices de capacidade, necessidades financeiras e estrutura geral das empresas.

Conforme Favaretto (2012), indicadores como prazos de entrega e custos de produção dependerão diretamente do bom ou mau planejamento de produção, o qual deve estar embasado em uma previsão de demanda.

Mas prever a demanda não é uma atividade fácil. Os grandes gestores no passado faziam isso apenas com base na sua experiência, mas com o passar do tempo e os avanços tecnológicos, uma quantidade imensa de dados puderam ser armazenados e disponibilizados, e análises estatísticas aprofundadas puderam ser realizadas sobre os mesmos. Com o crescimento das pesquisas na área, tornou-se cada vez mais evidente a vantagem competitiva obtida por quem utiliza um sistema de previsão de demanda.

Segundo Pellegrini e Fogliatto (2001), a natureza deste sistema utilizado pode ser dividida em três categorias: quantitativo, qualitativo, ou um modelo conjugado, que contemple ambos os tipos de método. Ainda de acordo com os autores, as técnicas possuem graus de precisão e custos de utilização distintos, e estes são fatores determinantes na escolha do método a se adotar.

O modelo conjugado de métodos quantitativos e qualitativos, dentre os três citados, é um modelo de grande aceitação. De acordo com Fildes et al. (1994), este tipo de modelo permite que efeitos como a baixa de preços, promoções e campanhas de marketing, que não são facilmente modeláveis estatisticamente e geram alterações na amplitude da demanda, possam ser incluídos, mesmo que posteriormente, como ajuste, mas que tornam a previsão mais representativa e fiel à demanda que virá a acontecer. Entretanto, assim como o modelo puramente quantitativo, o modelo misto necessita uma modelagem probabilística baseada em dados históricos e a posterior manutenção deste banco de dados, o que acaba tornando-o um modelo com custo de implantação e manutenção mais elevado que o puramente qualitativo.

Talvez por conta disto, a grande maioria das empresas ainda siga optando por um modelo puramente qualitativo de previsão de demanda.

O objetivo geral deste trabalho é a escolha de um modelo estatístico de bom desempenho para previsão da demanda proposta. Para tanto, é possível citar os seguintes objetivos específicos: (i) análise de demanda e aplicação dos modelos apresentados; (ii) estudo comparativo da aplicação dos modelos e seleção do melhor modelo segundo o critério da menor Média Absoluta Percentual dos Erros (MAPE).

De acordo com Sanders e Graman (2009), erros de previsão de demanda podem aumentar os custos de 10% a 30%, dependendo das características da empresa. Baseado nesta evidência fica claro que são válidos os esforços para implantação de um sistema de previsão de demanda em um mercado que trabalha com margens que são, muitas vezes, menores que isto.

Os testes de validação dos modelos gerados se restringem à demanda fornecida historicamente. Apesar de possível, não será realizado um teste de validação da previsão para datas futuras. Os modelos testados neste artigo não levarão em conta aspectos econômico-financeiros ou alterações mercadológicas, e sim, serão baseados apenas na demanda histórica fornecida e suposição da repetição parcial dos fatores que a geraram. Sua avaliação de ajuste para a melhor precisão será segundo o método supracitado. O trabalho também não levará em consideração as capacidades produtivas disponíveis ou alterações das mesmas.

Este trabalho está dividido em cinco seções, sendo que nesta primeira é feita uma contextualização do assunto do trabalho no cenário atual, abordando a importância do tema apresentado. Também são apresentados os objetivos gerais e específicos, bem como a justificativa do trabalho. Apresentam-se ainda nesta seção o método utilizado, as etapas, as delimitações e a estrutura do artigo. Na segunda seção será apresentado o referencial teórico, com a revisão bibliográfica que fornecerá o embasamento teórico necessário para realização do trabalho. Nela serão abordados os modelos mais utilizados e para quais tipos de demanda a literatura indica seu uso. Na terceira seção serão apresentados os procedimentos metodológicos, com aplicações dos modelos propostos sobre a demanda apresentada. Será utilizada a medida MAPE, citada anteriormente para validação dos modelos sob o aspecto de precisão dos mesmos. Na quarta seção serão analisados os resultados obtidos realizando a comparação entre os modelos e, na quinta seção, avaliados os objetivos e realizados alguns comentários finais.

2.2 Referencial Teórico

De acordo com Armstrong (2001), previsões de demanda são necessárias somente quando podem afetar decisões. Como o mundo dos negócios está colocado em um universo de incertezas em que decisões devem ser tomadas de forma a guiar a empresa em meio a estas incertezas, a previsão de demanda é muito necessária. E a função de prever busca sempre a melhor maneira possível de fazer isso, ou seja, com suposições do que irá ocorrer, embasadas de motivos pelos quais ela deverá ocorrer.

A verdade é que hoje a atividade de previsão de demanda possui muito mais prestígio e é muito mais respeitada do que foi há alguns anos. Em seu estudo, Fildes (1994) afirmou que o motivo pelo qual os sistemas de previsão de demanda ainda não possuem todo o reconhecimento necessário é devido ao fato de que as organizações não acompanharam os avanços tecnológicos do poder de processamento de dados. Segundo ele, os gerentes recebem análises superficiais não por indisponibilidade de dados ou recursos de processamento, mas sim pela sua própria falta de conhecimento e experiência em gestão. Não há motivação para, por exemplo, a busca de análises de complexidade multivariada, pois os profissionais responsáveis pelas tomadas de decisão não estão devidamente preparados para recebê-las e analisá-las conforme deveriam.

Ainda assim a atividade de prever demanda atrai pesquisadores e instiga o desenvolvimento de novos métodos, mais confiáveis e precisos, devido à sua importância dentro das instituições. Como as empresas atuam em mercados diferentes, com produtos diferentes, cada uma se enquadra em um tipo de cenário e uma característica de demanda. Este fato acaba gerando uma gama bastante grande de modelos e métodos para a previsão.

De acordo com Kerkanen et al. (2009), existem mais de 70 técnicas quantitativas diferentes para previsão, aplicáveis para os mais diversos tipos de demanda. Mesmo assim, modelos qualitativos ainda são amplamente utilizados na indústria. Isto se deve ao fato de serem modelos de baixo custo de implantação e operacionalização, e ao grande retorno que proporcionam frente a não utilização de modelos de previsão.

Mas muitos dos modelos quantitativos têm sido utilizados por empresas cujas margens acabam se tornando mais apertadas. Segundo Pellegrini e Fogliatto (2001), o emprego do modelo de previsão a ser utilizado depende basicamente do comportamento da série temporal que se deseja analisar. Como os modelos são baseados em dados, estes possuem parâmetros e características de curvas que podem ou não abranger as características da demanda a ser modelada.

A escolha de um método para a modelagem de demanda não é direta, pois as curvas a serem modeladas podem contemplar características que nem sempre são visíveis. Makridakis et al. (1998) destacam que as séries temporais possuem quatro componentes importantes: média, ciclo, tendência e sazonalidade. Segundo Pellegrini (2000), média é a constante em torno da qual os valores oscilam. Ciclo é a variação ascendente e descendente em intervalos não regulares de tempo. Tendência é a característica ascendente ou descendente em um período longo de tempo e, finalmente, sazonalidade é a variação cíclica com padrões regulares de tempo.

Porém, Veiga et al. (2010) classificam estes quatro componentes característicos das séries temporais como componentes sistemáticos e cita ainda um componente que é classificado como aleatório. Segundo os autores, este componente aleatório pode ser considerado como o erro de uma previsão ou parte da previsão desviada da parte sistemática. Este componente, no universo dos sistemas de vendas, muito provavelmente se trata de uma variável cuja modelagem não abrangeu, não foi fornecida, ou simplesmente não tenha se repetido o suficiente para ser compreendida pelo modelo.

Pellegrini e Fogliatto (2001) dividem os modelos quantitativos mais utilizados para previsão de demanda em duas famílias: os modelos de suavização exponencial e os modelos ARIMA. Embora não citado pelos autores, existem ainda outros métodos quantitativos que também executam previsões apenas com base em dados passados, porém estes não serão utilizados no presente trabalho.

Dentre esta divisão realizada pelos autores, serão abordados os modelos de suavização exponencial conhecidos como Modelo de Holt-Winters e Modelos de Decomposição, por serem modelos que possuem análise de dados com presença de tendências e sazonalidades. Será abordado também um modelo ARIMA que melhor se enquadre na modelagem da demanda.

2.2.1 Modelo de Holt-Winters

Segundo Gamberini et al. (2010), o modelo de Holt-Winters é uma técnica que isola os componentes de nível, tendência e sazonalidade de uma série de dados, independente da sua natureza. De acordo com Pellegrini (2000), o modelo aplica-se a séries que possuam a amplitude da variação sazonal aumentando ou diminuindo como função do tempo.

O modelo é composto pelas equações de 1 a 4:

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

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (2)$$

$$S_t = \gamma \frac{z_t}{L_t} + (1 - \gamma)S_{t-s} \quad (3)$$

$$\hat{z}_{t+k} = (L_t + kT_t)S_{t-s+k} \quad (4)$$

Nestas, Makridakis et al. (1998) descrevem cada termo como:

L_t é a componente de nível;

T_t é a componente de tendência;

S_t é a componente de sazonalidade;

s é o período sazonal;

k é o horizonte de previsão;

\hat{z}_{t+k} é a previsão para k períodos;

γ é a constante de suavização do peso relativo à sazonalidade;

β é a constante de suavização do peso relativo à tendência;

α é a constante de suavização do peso relativo ao nível.

Para os cálculos, Pellegrini (2000) cita que é necessário atribuir valores iniciais aos componentes de nível, tendência e sazonalidade. A estimativa destes valores é realizada segundo equações 5 a 7.

$$L_s = \frac{1}{s}(z_1 + z_2 + \dots + z_s) \quad (5)$$

$$T_s = \frac{1}{s} \left(\frac{z_{s+1} - z_1}{s} + \frac{z_{s+2} - z_2}{s} + \dots + \frac{z_{s+s} - z_s}{s} \right) \quad (6)$$

$$S_1 = \frac{z_1}{L_s}, S_2 = \frac{z_2}{L_s}, \dots, S_s = \frac{z_s}{L_s} \quad (7)$$

Gamberini et al. (2010) referem-se ao modelo de Holt-Winters como um modelo de fácil aplicação, inclusive para softwares comerciais, sendo portanto, recomendável para análises de demandas que não exigem detalhes aprofundados. Holt (2004) ressalta a flexibilidade do método, que pode ainda servir de degrau para aproximações mais elaboradas e complexas, baseadas em equações diferenciais de segunda ordem ou maior.

2.2.2 Modelos de Decomposição Clássica

Os modelos de decomposição clássica, como cita Pellegrini (2000), são modelos que tratam a série temporal como uma composição dos cinco componentes básicos: sazonalidade, tendência, média, ciclo e ruído aleatório (erro). O método sugere uma análise individual dos componentes, de forma que os quatro primeiros apresentam comportamentos modeláveis estatisticamente, enquanto que o ruído aleatório é a parte da análise que não segue um comportamento estatístico modelável e é considerado como a diferença entre o valor previsto e o valor real.

A decomposição clássica se divide em dois modelos, o aditivo e o multiplicativo. O modelo aditivo é composto da soma dos cinco componentes previamente citados, conforme demonstrado na equação 12.

$$z_t = S_t + T_t + L_t + C_t + a_t \quad (12)$$

Onde:

z_t é a previsão gerada para o período t ;

S_t é a componente de sazonalidade;

T_t é a componente de tendência;

L_t é a componente de nível;

C_t é a componente de ciclo;

a_t é a componente de ruído aleatório;

Como se pode deduzir, o modelo multiplicativo é composto pelo produto de seus componentes, conforme equação 13.

$$z_t = S_t \times T_t \times L_t \times C_t \times a_t \quad (13)$$

2.2.3 Modelos ARIMA

Os modelos ARIMA são também conhecidos por modelos Autoregressivos Integrados a Média Móvel, ou simplesmente ARIMA. Segundo Makridakis e Hibon (1997), este modelo foi popularizado na década de 70, quando foi introduzido o “I”, de integrados, nos já existentes modelos ARMA, com o objetivo de diferenciá-los dos modelos de séries estacionárias. Modelos ARMA são representativos para séries temporais estacionárias, mas estas não representam a maior parte das séries encontradas na indústria. Comumente encontram-se séries não estacionárias e que necessitam de modelagem.

Conforme definição, séries estacionárias são séries nas quais seus valores flutuam em torno de um valor médio central. As séries estacionárias não são constantes, podendo apresentar variações aleatórias (independentes estatisticamente) ou correlacionadas (diferenças são influenciadas pela magnitude dos demais valores da série), mas tem a característica de ter média e variância constantes ao longo do tempo.

Segundo Fischer (1982), os modelos ARMA foram utilizados porque Box e Jenkins perceberam que grande parte dos processos estocásticos não permitem uma descrição satisfatória somente com um modelo média móvel ou somente auto-regressivo. Isso implicaria em utilizar de forma parcimoniosa os dois processos para gerar o modelo.

Mas a maior contribuição do método desenvolvido por Box e Jenkins foi a flexibilização do método para utilização em séries não estacionárias através do modelo ARIMA. Ainda de acordo com Fischer (1982), processos não estacionários exigem o operador somatório para a transformação em série temporal. Como para variáveis contínuas o operador somatório é o operador integral, foi incluído o termo “*integrated*”.

Pellegrini (2000) divide o método em 3 etapas, sendo elas: identificação do modelo ARIMA através da análise dos dados históricos, estimativa dos parâmetros do modelo e verificação do modelo quanto à adequação aos dados.

Na etapa de identificação do modelo, é necessário observar nos dados históricos a existência de características determinantes como estacionariedade e sazonalidade e a adequação dos dados às características exigidas pelo método. Depois de identificado o tipo de modelo, faz-se a identificação dos parâmetros do mesmo e, por último, é realizada a verificação do modelo que, frequentemente, é feita através da análise residual, verificando a existência de autocorrelação entre os resíduos, ou através dos testes de Portmanteau, que testa a hipótese de os resíduos serem significativos.

2.2.4 Validação do Método

Conforme Pellegrini (2000), existem vários critérios que devem ser utilizados no momento de validar um método de previsão de demanda. O autor cita que, além da acurácia, deve-se ter atenção à necessidade de conhecimento dos aspectos que influenciam a demanda, como promoções ou entrada de concorrentes, conhecimentos das características da série temporal, da agregação temporal dos dados (extremamente vinculado ao tamanho do período no qual os dados estão dispostos) e o intervalo cujo o qual as previsões deverão ser refeitas.

A observação destas características direcionará a seleção de um modelo estatístico apropriado ao tipo de demanda analisada, levando então a uma maior acurácia. Esta acurácia, neste caso, será medida através da medida MAPE (Mean Absolute Percentage Error), ou EAMP (Erro Absoluto Médio Percentual).

O MAPE é uma medida bastante útil quando se tem valores de previsão muito grandes ou então quando se deseja uma comparação válida e direta entre acurácias de análises de séries completamente distintas. Segundo Mileski Jr. (2007), o MAPE fornece um indicativo mais intuitivo de quão grandes os erros da previsão estão na comparação com os valores reais, tornando-os assim melhores interpretáveis para administradores que não estejam muito aprofundados na série em questão e facilitando decisões gerenciais.

O MAPE é o erro absoluto médio como porcentagem, e pode ser expresso de acordo com a expressão da equação 14.

$$MAPE_n = \frac{\sum_{t=1}^n \left| \frac{D_t - Z_t}{D_t} \right| 100}{n} \quad (14)$$

Onde:

D_t é a demanda real no período t ;

Z_t é a previsão obtida para o período t ;

N é o número de períodos.

2.3 Procedimentos Metodológicos

A demanda a ser modelada no presente trabalho foi retirada de uma indústria cordoeira cujas principais características são: carteira de pedidos de carácter emergencial (abastece o setor naval e petroleiro com produtos essenciais para operações de altíssimo custo) e pela alta sazonalidade presente na demanda de alguns dos produtos comercializados.

O estudo foi realizado para analisar a demanda de uma linha de produtos com presença de sazonalidade. Busca-se modelar a demanda desta linha de forma que se possa prever o comportamento da mesma e assim programar uma produção mesmo sem a confirmação prévia dos pedidos em carteira, obtendo vantagens que geralmente são proporcionadas por boas previsões (redução de custos, melhor alocação de recursos de produção, correto dimensionamento de estoques, etc).

Os cálculos envolvidos na modelagem da demanda em questão foram realizados no software estatístico *NCSS 2007 – Versão 7.1.18*.

A demanda a ser modelada é a demanda apresentada na tabela 1. Trata-se de uma demanda mensal, em quilos, do produto em questão. Até o presente trabalho, o histórico confiável de demanda disponível era de 38 meses de venda. É apresentado na figura 2 o gráfico da demanda no qual se pode perceber imediatamente a presença de fatores como sazonalidade e tendência. Com o auxílio da linha de tendência, pode-se perceber que há tendência de crescimento. Também é evidente o crescimento se analisados os valores totais anuais de venda do produto apresentado na tabela 1. A sazonalidade é perceptível pelo aumento notório de vendas na metade dos períodos (em torno dos meses seis e sete). Há picos aparentemente aleatórios em alguns meses que deverão ficar melhores caracterizados após a modelagem.

Tabela 1: Demanda histórica do produto

2011		2012		2013		2014	
Mês	Peso (kg)	Mês	Peso (kg)	Mês	Peso (kg)	Mês	Peso (kg)
1	633	1	478	1	1924	1	2165
2	957	2	498	2	1768	2	2750
3	326	3	1391	3	2219		
4	1509	4	1252	4	3502		
5	1180	5	1440	5	3005		
6	786	6	1508	6	2516		
7	637	7	2388	7	3450		
8	788	8	1997	8	3232		
9	1327	9	1158	9	3328		
10	1308	10	1820	10	4656		
11	1700	11	1943	11	2035		
12	1200	12	2360	12	3194		
Total	12.348	Total	18.230	Total	34.827	Total	4.915

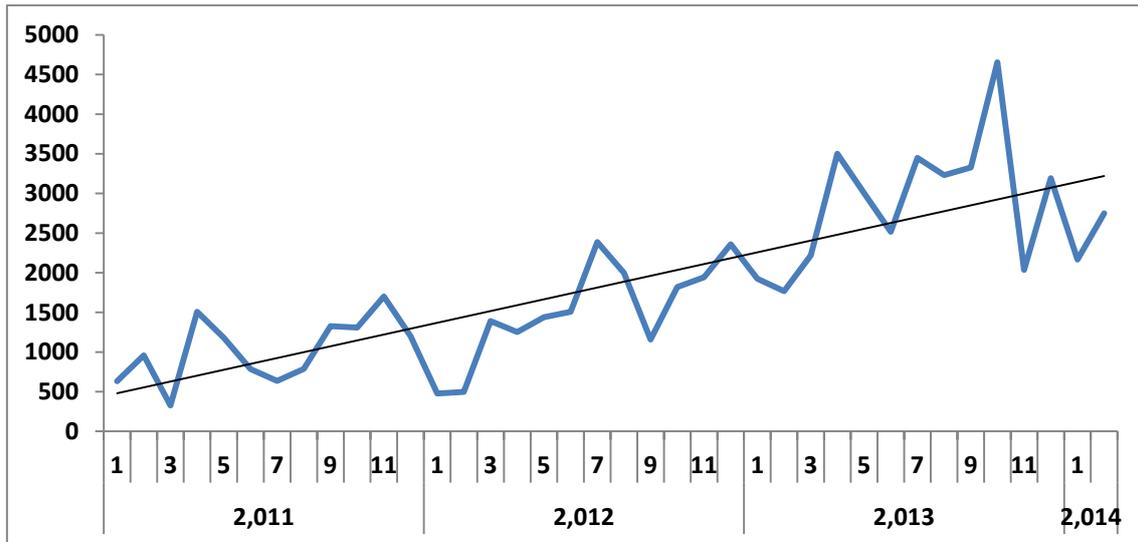


Figura 2: Demanda histórica com linha de tendência

A demanda foi dividida em duas partes para modelagem. Os primeiros 30 meses foram utilizados para a análise e calibração do modelo. Os 8 meses subsequentes foram utilizados para os testes de validação do mesmo. Não é recomendável para uma modelagem de boa acurácia um período inferior a 48 meses e 18 meses para validação (em demandas sazonais cuja sazonalidade é de 12 meses). Porém, a demanda histórica disponível é de somente 38 meses, pois o produto é novo no portfólio da empresa e não há dados anteriores de vendas do mesmo.

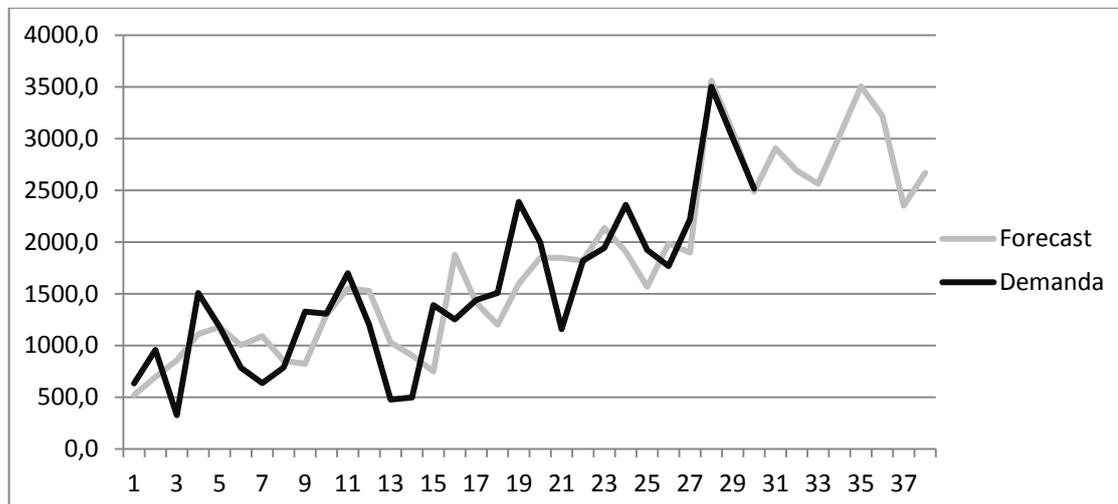
2.3.1 Modelo de Holt-Winters

O modelo de Holt-Winters utilizado na demanda foi o modelo multiplicativo devido ao fato de que, conforme citado, é o modelo recomendado para a variação da amplitude sazonal presente na demanda a ser modelada.

O método utilizado para a busca da constante de suavização do peso relativo à sazonalidade foi também o MAPE. O resultado da modelagem pelo modelo de Holt-Winters é apresentado na tabela 2. No gráfico apresentado na figura 3 é possível observar a boa aderência dos dados à demanda apresentada e a flexibilidade do modelo matemático para captar variações sazonais.

Tabela 2: Resultado da aplicação do modelo Holt-Winters multiplicativo

2011		2012		2013		2014	
Mês	Peso (kg)						
1	633	1	478	1	1924	1	2350,9
2	957	2	498	2	1768	2	2668,3
3	326	3	1391	3	2219		
4	1509	4	1252	4	3502		
5	1180	5	1440	5	3005		
6	786	6	1508	6	2516		
7	637	7	2388	7	2906,3		
8	788	8	1997	8	2690,6		
9	1327	9	1158	9	2563,7		
10	1308	10	1820	10	3028,4		
11	1700	11	1943	11	3504,8		
12	1200	12	2360	12	3221,7		

**Figura 3: Comparativo entre demanda histórica e modelo de Holt-Winters**

2.3.2 Modelo de Decomposição Clássica

O modelo de decomposição clássica utilizado foi o modelo multiplicativo, pois é utilizado para séries em que há variação da amplitude sazonal. Os modelos de decomposição clássica, conforme já comentado, são modelos extremamente fáceis de aplicar em softwares comerciais. Por não possuir parâmetros configuráveis, é também um modelo bastante limitado para customização e melhoria de acurácia. Qualquer alteração na previsão obtida pela decomposição clássica deve ser realizada após os dados serem extraídos. Ou seja, não farão parte da sistemática do modelo.

Na tabela 3 estão expostos os valores modelados pelo método da decomposição e na figura 4 o gráfico comparativo com a demanda fornecida. Pode-se perceber inicialmente que a

aderência dos dados modelados à demanda histórica é muito menor do que a obtida na modelagem pelo método de Holt-Winters. Porém, esta avaliação visual não é uma análise conclusiva acerca da acurácia do modelo.

Tabela 3: Resultado da Aplicação do Modelo de Decomposição Clássica

2011		2012		2013		2014	
Mês	Peso (kg)						
1	633	1	478	1	1924	1	2032,5
2	957	2	498	2	1768	2	2204,7
3	326	3	1391	3	2219		
4	1509	4	1252	4	3502		
5	1180	5	1440	5	3005		
6	786	6	1508	6	2516		
7	637	7	2388	7	2629,4		
8	788	8	1997	8	2492,7		
9	1327	9	1158	9	2530,9		
10	1308	10	1820	10	2919,9		
11	1700	11	1943	11	3480,9		
12	1200	12	2360	12	3047,1		

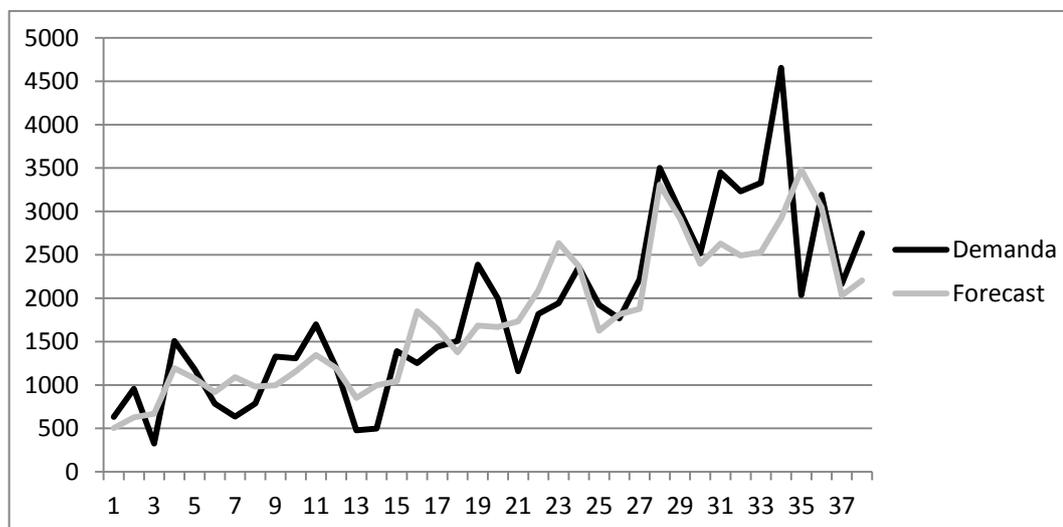


Figura 4: Comparativo entre demanda histórica e modelo de Decomposição

2.3.3. Modelo ARIMA

Conforme recomendação de aplicação do método ARIMA, é necessária, antes da geração do modelo, uma análise mais aprofundada do tipo de demanda que será modelada e qual o melhor tipo de modelo para adequá-la.

Segundo Pellegrini (2000), deve-se inicialmente identificar e comprovar a estacionariedade ou não da série. Tal análise é possível através dos gráficos de FAC (Função

de Auto Correlação) e FACP (Função de Auto Correlação Parcial). De acordo com o autor, para uma boa análise de auto correlação é indicada a análise de, no mínimo, 50 observações, mas conforme já citado, não há disponibilidade tão grande de dados da demanda em questão. A figura 5 demonstra os gráficos FAC e FACP da demanda em questão. Pode-se perceber que o gráfico FAC não decresce à zero rapidamente, o que indica a não estacionariedade da série. Para séries não estacionárias através do FAC, faz-se necessário o procedimento de diferenciação.

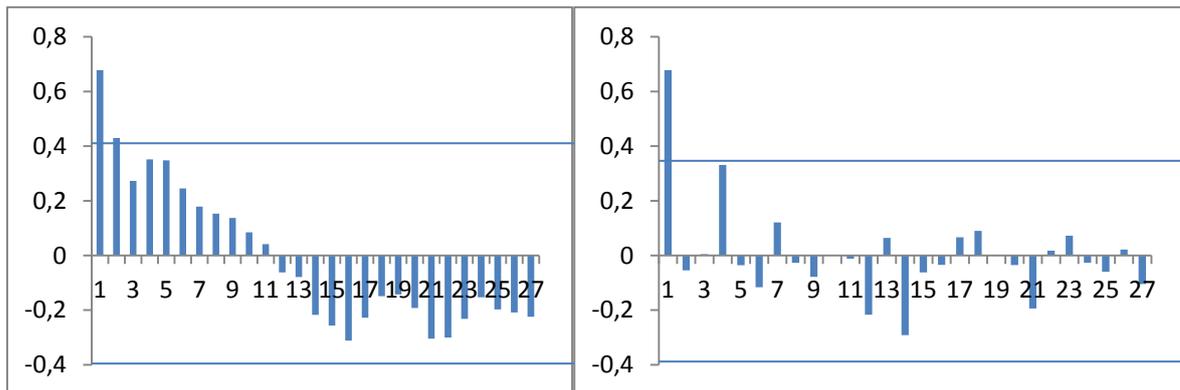


Figura 5: FAC e FACP da série temporal

Após a primeira diferenciação o gráfico FAC e FACP obtidos estão demonstrados na figura 6. Nota-se que agora se tem o gráfico FAC decrescendo rapidamente à zero. Segundo Pellegrini (2000), quando o gráfico FAC decresce rapidamente e o gráfico FACP apresenta apenas um *lag* significativo, tem-se um modelo ARIMA (1,1,0), sendo o primeiro valor o valor de p (valor do componente Autoregressivo), o valor do meio sendo o valor referente à diferenciação e o último o valor de q (valor do componente Média Móvel).

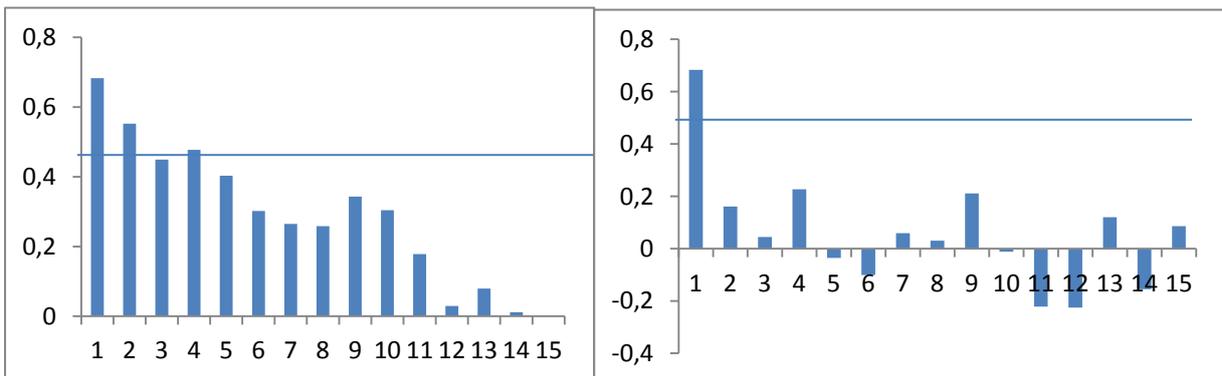


Figura 6: FAC e FACP da série temporal após diferenciação

Com esta configuração, gera-se então o modelo para previsão. Na tabela 4 estão expostos os valores modelados pelo método e na figura 7 o gráfico comparativo com a demanda fornecida.

Tabela 4: Resultado da Aplicação do Modelo de ARIMA

2011		2012		2013		2014	
Mês	Peso (kg)						
1	689,2	1	561,0	1	372,3	1	2905,0
2	1125,2	2	745,2	2	185,5	2	2630,2
3	164,4	3	816,7	3	2114,4		
4	1602,6	4	1390,0	4	1077,0		
5	1085,4	5	1299,8	5	1615,5		
6	521,1	6	1118,6	6	1998,5		
7	104,3	7	1443,7	7	3576,3		
8	345,2	8	1345,2	8	2818,0		
9	1388,8	9	1249,2	9	1043,7		
10	1120,8	10	1543,8	10	2166,8		
11	1611,1	11	1812,0	11	2108,0		
12	774,8	12	1734,5	12	3147,9		

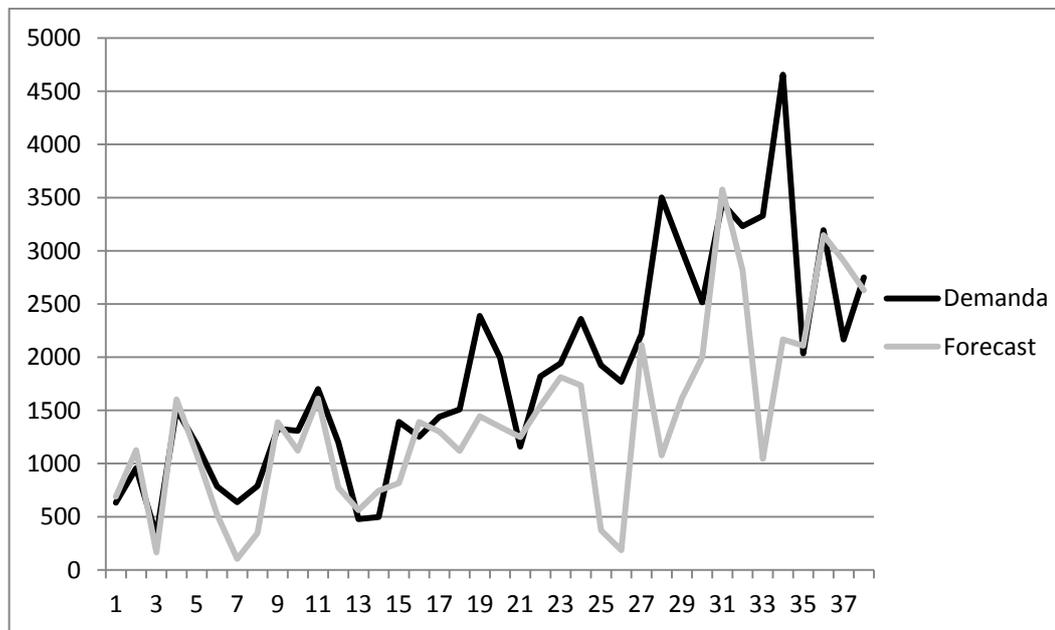


Figura 7: Comparativo entre demanda histórica e modelo de ARIMA

A figura 8 apresenta a FAC de resíduos do modelo ARIMA. Como a FAC de resíduos não apresenta nenhum *lag* significativo, sugere-se que o modelo obtido para a série temporal seja adequado.

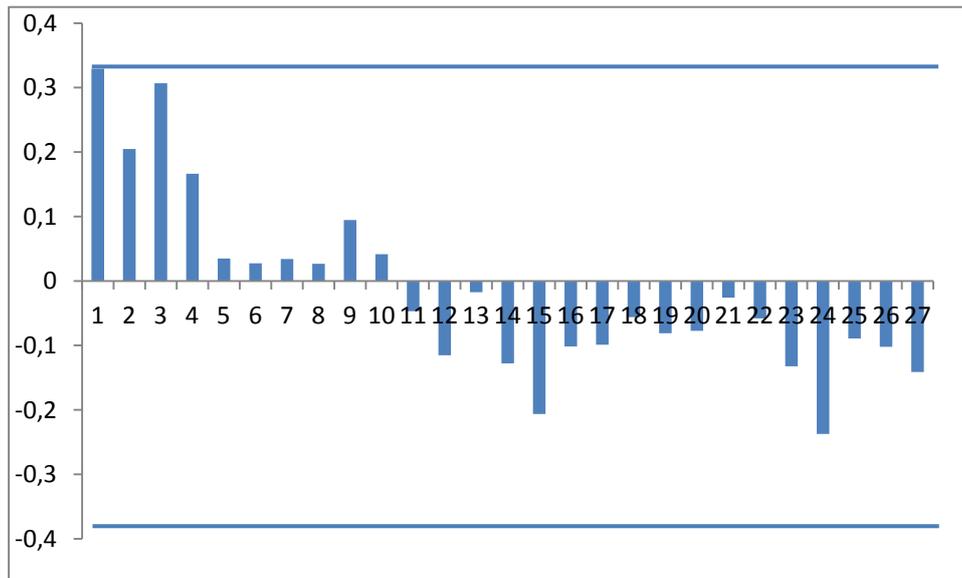


Figura 8: FAC de resíduos do modelo ARIMA aplicado

2.4 Resultados e Discussões

Aplicados os modelos na seção anterior e de posse dos resultados destas aplicações, pode-se então realizar agora um estudo comparativo da acurácia de cada um deles e, com base no método MAPE de comparação, definir qual é o modelo que melhor prevê o comportamento da demanda em questão.

O primeiro modelo apresentado, o modelo de Holt-Winters, foi um modelo escolhido para comparação por possuir características que abrangem a sazonalidade presente na demanda analisada. O estudo revelou uma medida MAPE de 30,39% para os 30 meses de calibração do modelo e 21,88% para os 8 meses de previsão.

Já para o modelo de decomposição clássica, obteve-se o MAPE de 27,62% no período de calibração e 26,19% no período de previsão.

No modelo ARIMA, foi obtido o ajuste do modelo com MAPE de 30,59%. Para o período de previsão, porém, obteve-se o MAPE de 22,77%.

Na tabela 5 é possível verificar o consolidado dos resultados e avaliar seus desempenhos em ambos os períodos, calibração e previsão.

Tabela 5: Comparativo de MAPE entre os modelos aplicados

Método	Período de Calibração	Período de Previsão
Holt-Winters	30,39%	21,88%
Decomposição Clássica	27,62%	26,19%
ARIMA	30,59%	22,77%

Realizando uma análise comparativa dos modelos aplicados, segundo critério MAPE, percebe-se que os métodos em questão possuem um erro relativamente alto. Boa parte deste erro pode ser explicada por se tratar de uma base de dados pequena. Conforme afirmam Makridakis e Hibon (1997), é necessária uma base de dados relativamente grande para a estimação correta dos parâmetros do modelo.

Um comparativo entre o modelo ARIMA e o modelo de Holt-Winters gera uma dúvida acerca de suas acuracidades. Ambos possuem valores muito próximos se analisado o critério do erro MAPE, tanto para o período de calibração quanto para o período de previsão. Um fator favorável ao ARIMA é que a variância do erro deste modelo é menor que a variância do erro do modelo de Holt-Winters. Entretanto, o modelo de Holt-Winters é de fácil aplicação e customização. Portanto cabe a cada instituição realizar um levantamento acerca dos prós e dos contras de cada modelo e avaliar qual se enquadra melhor nos seus padrões. Há ainda a afirmação de Pellegrini (2000), de que o modelo ARIMA não é muito aconselhado para demandas com forte componente aleatório, sendo para estes casos aconselhado um modelo mais simples.

O modelo de decomposição clássica teve um desempenho mais baixo que os demais modelos utilizados. Por se tratar de um modelo extremamente simples, possivelmente não conseguiu captar as complexidades das variáveis da demanda, cuja qual não pôde ser representada com mais eficácia pelo modelo multiplicativo.

O importante em uma análise como esta é levar em consideração não somente o período de validação previsto e seu erro pontual. Deve-se lembrar que há componentes aleatórios em uma demanda e que estes componentes, conforme uma distribuição de probabilidade, podem ter se alocados de maneira que um modelo tivesse melhor desempenho que outro.

2.5 Conclusão

Com realização de previsão se faz possível um dimensionamento aprimorado de máquinas, pessoas e recursos das mais variadas formas. Claro que uma decisão de

implantação ou não de uma nova sistemática de gerenciamento de produção abrange muito mais que a simples avaliação do erro percentual de uma previsão. Faz-se necessária a avaliação dos custos de implantação de um sistema de previsão comparado aos benefícios que este proporciona e também, para muitas empresas que decidem implantar, qual será o nível de credibilidade que estas previsões terão no aspecto gerencial. Dentre os benefícios pode-se incluir redução no custo por falta de produtos, ganhos em negociação e programação de entregas de matéria-prima, custos de estocagem, entre outros.

Quanto à escolha do modelo a utilizar, seria imprudente realizar uma escolha definitiva para o método de previsão a ser adotado pela empresa. Ao longo do tempo esta série será maior, mais robusta e permitirá a execução de modelos mais completos.

Dentre os princípios de Forecasting, elaborados por Armstrong (2001), há uma orientação de estabelecer um processo formal de revisão para os métodos de previsão. Portanto, no cenário em questão, o modelo mais adequado no momento atual pode não ser necessariamente o modelo recomendado daqui a alguns meses. Ao passo que uma quantidade maior de dados confiáveis esteja disponível, melhor poderá ser a modelagem e modelos mais complexos e completos podem ser exigidos. O importante é que seja estabelecida uma revisão periódica dos modelos e métodos de previsão e que os mesmos tenham seu desempenho avaliado ao longo do tempo.

Para a modelagem executada, o melhor desempenho obtido foi no modelo de Holt-Winters, que apresentou um erro em torno de 21%. Pode-se realizar um acompanhamento de desempenho ao longo dos próximos períodos e verificar se realmente o modelo seguirá sendo o de melhor desempenho. Para tanto se faz necessária a aplicação de todos os modelos utilizados para comparação.

A aplicação destes modelos torna a previsão de demanda um processo viável e necessário, principalmente em situações como a apresentada, em que nenhum método é utilizado para prever. A introdução destes processos na mentalidade de alguns empresários é algo fundamental para que metodologias mais confiáveis de gestão dos negócios sejam utilizadas.

2.6 Referências

- ARMSTRONG, J.S. **Principles of Forecasting: A handbook for researchers and practitioners**. Kluwer Academic Publishers. Philadelphia, 2001
- BALLOU, R.H. **Gerenciamento da cadeia de suprimentos/logística empresarial**. 5ª ed. Porto Alegre. Bookman, 2006.
- CLEMEN, R.T. **Combining Forecasts: A Review and Annotated Bibliography**. International Journal of Forecasting 5 (1989) Pag. 559-583
- DAWES, R.; FILDES, R; LAWRENCE, M.; ORD, K. **The past and the future of forecasting research**. International Journal of Forecasting 10 (1994) Pag 151-159
- FARIAS, O.O.; NETO, M.S.N.; NOGUEIRA, C.C.S. **Estudo comparativo da aplicação de modelos clássicos de previsão de demanda no agronegócio**. Organizações em contexto. Ano 2, nº 3. 2006
- FAVARETTO, F. **Impacto das incertezas da previsão de demanda no planejamento detalhado da produção**. P&D Engenharia de Produção (2012). Vol. 10, pag 101-108
- FILDES, R; HIBON, M.; MAKRIDAKIS,S.; MEADE,N. **Generalising about univariate forecasting methods: further empirical evidence**. International Journal of Forecasting 14 (1998) Pag. 339-358
- FISCHER, S. **Séries univariantes de tempo – metodologia de Box-Jenkins**. Fundação de economia e estatística. Porto Alegre, 1982.
- GAMBERINI, R.;LOLLI, F.; RIMINI, B.; SGARBOSSA, F. **Forecasting of sporadic demand patterns with seasonality and trend components: An empirical comparison between Holt-Winters and (S)ARIMA methods**. Mathematical Problems in Engineering, Vol. 2010.
- HANKE, J.E.; REITSCH, A.G. **Business Forecasting**. Eastern Washington University. (1981)
- HOLT, C.C. **Forecasting seasonals and trends by exponentially weighted moving averages**. International Journal of forecasting 20 (2004). Pag 5-10.
- KALCHSCHMIDT, M. **Best practices in demand forecasting: Tests of universalistic, contingency and configurational theories**. Int. J. Production Economics 140 (2012) Pag 782-793
- Confederação Nacional da Indústria. **Investimentos na Indústria**. Ano 5. Nº 1. 2014

- KERKKANEN, A.; KORPELA, J.; HUISKONEN, J. **Demand forecasting errors in industrial context: Measurement and impacts.** Int. J. Production Economics 118 (2009) Pag. 43-48
- MAKRIDAKIS, S.; HIBON, M. **ARMA models and the Box-Jenkins methodology.** Journal of Forecasting, Vol. 16 (1997). Pag. 147-163.
- MAKRIDAKIS, S.; WHEELWRIGHT, S.C.; HYNDMAN, R.J. **Forecasting – methods and applications**, 3a. edição, John Wiley, Nova York, 1998.
- MILESKI JR, A. **Análise de Métodos de Previsão de Demanda Baseados em Séries Temporais em uma Empresa do Setor de Perfumes e Cosméticos.** Dissertação de mestrado em Engenharia de Produção e Sistemas. Curitiba, 2007.
- PELLEGRINI, F. R. **Metodologia para implementação de sistemas de previsão de demanda.** Dissertação de mestrado em Engenharia de Produção. Porto Alegre, 2000.
- PELLEGRINI, F. R.; FOGLIATTO, F. S. **Passos para Implantação de Sistemas de Previsão de Demanda – Técnicas e Estudo de Caso.** Revista Produção, V. 11 n. 1 Novembro de 2001
- SANDERS, N.R.; GRAMAN, G.A. **Quantifying costs of forecast errors; A case study of the warehouse environment.** Omega 37 (2009) Pag. 116-125
- SANDERS, N.R.; MANRODT, K.B. **Forecasting practices in US corporations: survey results.** Interfaces, (1994) Vol. 24, Pag. 91-100.
- VEIGA, C.R.P.; VEIGA, C.P; DUCLÓS, L.C.; **A acuracidade dos modelos de previsão de demanda como fator crítico para o desempenho financeiro na indústria de alimentos.** Future studies research journal. V.2 (2010), N.2, Pag 83-107

3. Artigo dois: Análise de Ganho de Acuracidade na Integração de Modelos de Previsão de Demanda

Roberto B. Fernandes Filho

Universidade Federal do Rio Grande do Sul

Dr. Ricardo Augusto Cassel

Universidade Federal do Rio Grande do Sul

Resumo

Tendo em vista a necessidade de integrar métodos de previsão de naturezas diferentes buscando a maior abrangência possível de informações, este artigo apresenta a aplicação de métodos de integração de modelos de previsões em uma demanda de um produto da indústria cordoeira. Realizou-se uma revisão da literatura disponível sobre o assunto e a validação de alguns conceitos e afirmações publicados. Apesar da baixa disponibilidade de informações de demanda demonstrou-se ser possível obter ganhos de acuracidade na previsão da demanda. Fez-se ainda uma avaliação acerca dos riscos de incluir ajustes de especialistas sem uma metodologia apropriada para tal e como pode ser difícil a escolha de um método em específico de integração.

Palavras-Chave: Previsão de demanda, forecasting, análise de séries temporais, acurácia.

3.1 Introdução

Previsão de demanda não é uma atividade recente na história dos negócios. Porém, após o surgimento dos recursos computacionais e das grandes capacidades de processamento e armazenamento de dados, a tarefa de prever demandas recebeu novos desafios. Há alguns anos o mercado vem se expandindo, a globalização está abrindo horizontes antigamente inimagináveis e, com isso, as variáveis de influência da demanda também estão aumentando consideravelmente.

Demandas podem ser influenciadas por muitas variáveis diferentes. Um bom exemplo é a condição climática de uma dada região, determinante para a sazonalidade de alguns produtos. Esta nova possibilidade, de as empresas negociarem com clientes de qualquer parte do mundo, gera uma alteração significativa nesta característica de venda de produtos e/ou

serviços. Algo que vende bem no verão, por exemplo, pode ser vendido bem o ano todo, em regiões diferentes, para clientes diferentes.

Modelos de previsão de demanda quantitativos, segundo Pellegrini e Fogliatto (2001), tradicionalmente não possuem meios de incluir certas variabilidades do mercado ou mudanças de estratégias das corporações. São modelos estatísticos, baseados em padrões de repetição. Neste ponto, a interferência humana ainda permanece sendo a forma mais adequada de “indicar” ao modelo o caminho para incluir algo que não aconteceu ou não se repetiu vezes suficientes para ser modelado matematicamente. O fator humano tem sido utilizado para diminuir o erro de previsão causado por eventos inéditos ou aleatoriamente recorrentes, adaptando a previsão gerada pelo modelo estatístico.

Mas se a capacidade humana para prever eventos é tão boa, porque não utilizar modelos puramente qualitativos para realizar previsões? O ponto negativo de fazer isto é que a capacidade humana para prever interpretando situações semelhantes é conflitante com a limitação da capacidade de análise de dados complexos ou muito grandes. Segundo Armstrong (2001), o cérebro humano não é preparado para analisar e interpretar dados complexos, fazer análises de correlação ou ainda distinguir determinada aleatoriedade de variabilidade. Foi pensando em resolver este conflito que surgiram as integrações dos métodos qualitativos e quantitativos.

A discussão principal recai sobre a forma de realizar esta integração de conhecimentos. De um lado têm-se uma previsão modelada matematicamente que pode ser a mais precisa possível baseando-se no passado. De outro, há um conhecimento empírico de caso de gestores experientes que podem ser peças-chave neste processo preditivo. Como conciliá-los? Como fazer com que o otimismo ou pessimismo dos gestores frente a uma determinada condição não se sobreponha a uma predição realizada pelo modelo quantitativo?

Armstrong (2001) demonstrou este tipo de preocupação ao alertar que a integração de previsões deve acontecer quando as técnicas de previsão obtidas levaram em consideração no seu processo preditivo fontes de informação não correlacionadas, ou seja, que levam em consideração fatores completamente distintos, sob risco de comprometer o ganho de acuracidade com a integração em caso de estarem baseadas na mesma fonte de informação.

Um pouco antes, Goodwin e Fildes (1999) já haviam demonstrado, através de experimentos, que ajustes de previsões estatísticas realizados diretamente por especialistas, apesar de algumas vezes apresentarem erros menores que os da previsão individual, acabam sendo influenciados por fatores humanos que não devem ser aceitos em um modelo confiável. Eles acabaram modificando predições altamente confiáveis e ignoraram linhas de ajustes

ideais após já tê-las formado. Ou seja, um modelo de previsão não deve ser considerado confiável se depender apenas da influência de seus gestores quando os mesmos não conseguirem criar regras e procedimentos para determinar quando deve ou não ser realizado o ajuste, baseado em análise de confiabilidade da fonte de informação.

Não existe ainda uma unanimidade quanto ao melhor método de integrar previsões, pois cada caso é um caso. Assim como é dito para os modelos estatísticos de previsão, cada empresa e cada produto têm suas peculiaridades, suas necessidades, características de mercado, suscetibilidade a variações, etc, e cabe à empresa avaliar se é vantajoso investir tempo e recursos para encontrar o melhor método de prever a sua demanda e, se julgar necessário, o melhor método para integração destas previsões.

O presente trabalho tem como objetivo geral uma avaliação dos métodos de integração de previsão de demanda utilizados e seus resultados. Serão abordados objetivos específicos como avaliação do desempenho das integrações de previsões estatísticas aplicadas e a integração de previsões qualitativas e quantitativas. Será avaliada também a influência que a previsão base pode ter no ajuste de especialista e o impacto de realizar ajustes qualitativos sobre previsões que já receberam sua parcela de influência qualitativa.

Este trabalho não busca criar uma nova forma de integrar previsões, aprofundar-se em sistemáticas de modelos de previsão ou suas fundamentações matemáticas. Apenas se restringe a avaliar o desempenho de integrações realizadas e avaliar sua real eficácia e confiabilidade.

O trabalho está dividido em cinco seções, sendo que nesta primeira é feita uma contextualização do assunto do trabalho no cenário atual, abordando a importância do tema apresentado. Também são apresentados os objetivos gerais e específicos, bem como a justificativa do trabalho. Na segunda seção será apresentado o referencial teórico, com a revisão bibliográfica que fornecerá o embasamento teórico necessário para realização do trabalho. Nela serão abordados os modelos mais utilizados e para quais tipos de demanda a literatura indica seu uso, as formas de integração utilizadas ao longo do trabalho e formas de medida de erro. Na terceira seção serão apresentados os procedimentos metodológicos, com aplicações dos modelos propostos sobre a demanda apresentada, as integrações propostas e como foram realizadas. Na quarta seção serão analisados os resultados obtidos realizando a comparação entre as integrações e na quinta seção serão avaliados os objetivos e realizados alguns comentários finais.

3.2 Referencial Teórico

De acordo com Hanke e Reitsch (1981), previsões sempre foram vistas como um esforço muito grande para um retorno muito pequeno, devido a sua grande imprecisão. Porém, segundo os autores, o mundo dos negócios está colocado em um universo de incertezas e que, em vista disto, decisões devem ser tomadas de forma a guiar a empresa em meio a estas incertezas. A função de prever busca sempre a melhor maneira possível de fazer isso, ou seja, com suposições do que irá ocorrer, embasadas de motivos pelos quais ela deverá ocorrer.

Existem muitas formas e tipos de previsões de demanda. Dividem-se, na literatura, basicamente entre métodos qualitativos e quantitativos. Previsões puramente qualitativas são previsões que não requerem nenhum tipo de manipulação de dados. São previsões em que somente a opinião de pessoas com conhecimento de causa é considerada. Conforme Hanke e Reitsch (1981), os métodos puramente qualitativos são “um resultado da manipulação mental de dados históricos”.

Hoje, para métodos qualitativos, existe uma série de procedimentos criados com a finalidade de captar os conhecimentos empíricos dos administradores e especialistas o máximo de informações possíveis que possam contribuir na previsão. O mais difundido deles é o método Delphi. Segundo Anderson et al. (1983), o método Delphi é baseado na realização de uma série de rodadas de questionários a um grupo de especialistas, separados fisicamente e anônimos. Estes especialistas, a cada rodada, recebem um consolidado das respostas do restante e então têm a oportunidade de reformular suas respostas, até que se alcance um consenso ou o ponto em que as alterações de respostas já não estejam mais acontecendo. Este método permite a convergência das opiniões buscando evitar erros muito grandes e unindo fontes de conhecimentos de diferentes áreas sem que ocorram interferências de problemas interpessoais.

O outro tipo de previsão, de métodos puramente quantitativos, de acordo com Hanke e Reitsch (1981), são métodos que não necessitam de nenhum dado “subjetivo”. São procedimentos mecânicos que utilizam dados históricos para análise e produzem resultados numéricos acerca do futuro. Como é de se esperar, existem métodos que exigem maior manipulação de dados que outros, dependendo da complexidade dos dados ou do resultado desejado. Segundo Kerkkanen et al. (2009), existem mais de 70 técnicas quantitativas diferentes para previsão, aplicáveis para os mais diversos tipos de demanda, algumas mais simples outras mais complexas. Cabe ao usuário definir qual delas é mais aplicável e necessária à sua previsão.

Conforme Pellegrini e Fogliatto (2001), os modelos quantitativos mais utilizados para previsão de demanda são divididos em duas famílias: os modelos de suavização exponencial e os modelos de Box-Jenkins (ARIMA).

Dentre esta divisão realizada pelos autores, serão abordados no presente trabalho os modelos de suavização exponencial conhecidos como Modelo de Holt-Winters e Modelos de Decomposição, por serem modelos que possuam análise de dados com presença de tendências e sazonalidades. Será abordado também um modelo ARIMA que melhor se enquadre na modelagem da demanda.

Gamberini et al. (2010) descrevem o modelo de Holt-Winters como uma técnica que isola os componentes de nível, tendência e sazonalidade de uma série de dados, independente da sua natureza. De acordo com Pellegrini (2000), o modelo aplica-se a séries que possuam a amplitude da variação sazonal aumentando ou diminuindo como função do tempo.

O modelo, utilizado neste trabalho, é composto pelas equações de 2.1 a 2.4:

$$L_t = \alpha \frac{z_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (2.1)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (2.2)$$

$$S_t = \gamma \frac{z_t}{L_t} + (1 - \gamma)S_{t-s} \quad (2.3)$$

$$\hat{z}_{t+k} = (L_t + kT_t)S_{t-s+k} \quad (2.4)$$

Nestas equações, Makridakis et al. (1998) descrevem L_t , T_t e S_t como variáveis representativas de nível, tendência e sazonalidade, respectivamente. A variável s representa um ciclo completo de sazonalidade (por exemplo, 12 para sazonalidade anual), \hat{z}_{t+k} é a previsão para k períodos e γ é a constante de suavização do peso relativo à sazonalidade.

Já os modelos de decomposição clássica, como cita Pellegrini (2000), são modelos que tratam a série temporal como uma composição dos cinco componentes básicos: sazonalidade, tendência, média, ciclo e ruído aleatório (erro). O método sugere uma análise individual dos componentes, de forma que os quatro primeiros apresentam comportamentos modeláveis estatisticamente, enquanto que o ruído aleatório é a parte da análise que não segue um comportamento estatístico modelável e é considerado como a diferença entre o valor previsto e o valor real.

A decomposição clássica se divide em dois modelos, o aditivo e o multiplicativo. O modelo aditivo é composto da soma dos cinco componentes previamente citados, conforme demonstrado na equação 2.5.

$$z_t = S_t + T_t + L_t + C_t + a_t \quad (2.5)$$

Como se pode deduzir, o modelo multiplicativo é composto pelo produto de seus componentes, conforme equação 6.

$$z_t = S_t \times T_t \times L_t \times C_t \times a_t \quad (2.6)$$

Em ambos os modelos, a variável S_t é referente ao componente de sazonalidade, T_t é o de tendência, L_t referente à média, C_t o ciclo e a_t o componente de aleatoriedade.

Serão utilizados ainda neste trabalho os modelos ARIMA que, de acordo com Fischer (1982), foram criados porque os autores George E. P. Box e Gwilym M. Jenkins perceberam que grande parte dos processos estocásticos não permite uma descrição satisfatória somente com um modelo média móvel ou somente auto-regressivo. Isso implicaria em utilizar de forma parcimoniosa os dois processos para gerar o modelo. Como a maior parte das séries incorpora os dois tipos de processos, o modelo Box-Jenkins acabou ficando bastante difundido como modelo estatístico de grande acurácia.

Foi da divisão entre modelos qualitativos e quantitativos que surgiu um problema. As duas formas diferentes de previsões possuem vantagens e desvantagens que se complementam. Segundo Goodwin e Fildes (1999), as previsões quantitativas possuem um potencial imenso de extrapolar padrões em séries, enquanto previsões qualitativas têm uma capacidade única de incluir na previsão o efeito de influências externas, muitas vezes inexistentes ao longo da série.

Com o intuito de unir estes pontos positivos e negativos de cada modelo individual, surgiram as propostas e tentativas de integração de sistemas de previsão. Mas há uma dificuldade em integrar previsões de forma que esta integração proporcione um erro menor, e esta dificuldade está intimamente ligada ao fator humano.

Segundo Clemen (1989), os trabalhos de Reid (1968,1969) e Bates e Granger (1969) são considerados o marco inicial de estudos de combinação de previsões. De acordo com o autor, nos respectivos trabalhos foram apresentados os primeiros modelos analíticos gerais desenvolvidos especificamente para integrar previsões em situações reais. E desde então, centenas de trabalhos já foram realizados em busca de melhores métodos.

É possível realizar a integração de previsões com qualquer tipo de previsão individual. Pode-se realizar a integração de métodos quantitativos, qualitativos, ou ambos. De acordo com Granger e Newbold (1974), sempre vale a pena tentar a combinação de previsões, pois requer muito pouco esforço e quase sempre traz melhorias. No entanto, a integração de uma previsão quantitativa com uma qualitativa é particularmente interessante, pois, conforme citado anteriormente, possuem características complementares e importantes para o sucesso da previsão.

Segundo Makridakis e Winkler (1983), a acurácia da previsão é pouco influenciada ao integrar algum método em específico. Ela aumenta com o acréscimo de métodos que são integrados, chegando à saturação depois de quatro ou cinco integrações. Foi constatado ainda que a cada acréscimo de método integrado, a variabilidade da acurácia decresce, tornando o modelo cada vez mais preciso e confiável.

A dúvida ainda reside em como integrar conhecimentos tão distintos. De acordo com grande revisão de estudos de integrações de previsão de Clemen (1989), métodos considerados simples, como a média simples entre as previsões obtidas, ou a aplicação de médias ponderadas, propiciam resultados tão bons quanto os de métodos complexos e sofisticados de integração. Ainda segundo o autor, a combinação de diferentes métodos de previsão trás uma redução no erro, se comparado aos erros das previsões individuais.

Há um consenso entre os pesquisadores quanto ao fato de que para obter uma boa integração de previsões se faz necessário algumas avaliações prévias. De acordo com Sanders e Ritzman (2004) e Armstrong (2001), é importante que as previsões sejam geradas de forma independente, tenham um baixo coeficiente de correlação entre seus erros, sem vieses ou com vieses que se anulem e que os envolvidos com as previsões qualitativas tenham profundo domínio do conhecimento ou detenham de informações específicas não contempladas pelos modelos quantitativos.

Nesta mesma linha de avaliação, segundo Dawes et al. (1994), a integração de modelos de previsão deve ter pelo menos uma das quatro características a seguir: Identidade, em que ambos os geradores, humano e o modelo estatístico, devem ter exatamente a mesma fonte de informação; Inclusão, em que algumas das informações utilizadas pelo modelo estatístico são disponibilizadas pelo humano e vice-versa; Disjunção, em que somente algumas, mas não todas, as informações usadas pelo modelo estatístico devem estar disponíveis ao humano e vice-versa; e Exclusão, em que as informações do modelo estatístico e humano são totalmente distintas.

Na revisão de bibliografia acerca de modelos integrados de previsões de demanda há alguns que são mais comuns de encontrar. Aplicam-se muito as previsões integradas por média aritmética simples, médias ponderadas, ajuste de previsões quantitativas baseado na opinião de especialistas, ingresso de dados qualitativos como variável para geração de modelo quantitativo, entre outros menos citados.

Neste artigo serão tratados os seguintes métodos de integração de previsões: i) integração via média aritmética; ii) integração via média ponderada; iii) ajuste de previsões quantitativas baseado em opinião de especialistas;

3.2.1 Integração de Previsões Via Média Aritmética

Fazer a média aritmética entre duas previsões distintas pode ser considerado o método mais simples de integração de previsões. Baseia-se em coletar a previsão pontual de cada um dos períodos previstos e calcular o valor médio para cada um deles, conforme a equação 2.7.

$$F_t = \frac{F_1^t + F_2^t \dots + F_n^t}{n} \quad (2.7)$$

Na equação 2.7, F^t trata-se da previsão final obtida para o período t , n é o número de previsões que se deseja integrar e F_n é a previsão pontual para o período t , de cada modelo individual.

Muitos pesquisadores defendem a integração via média simples. Porém, modelos integrados desta forma tendem a amenizar pontos que podem ser picos de demanda, positivos ou negativos, captados por apenas um dos métodos, prejudicando assim a acuracidade do sistema para aquele período.

Armstrong e Collopy (1998) argumentaram que o uso de médias simples é particularmente interessante quando a série apresenta auto grau de incerteza e instabilidade porque, sob tais condições, haverá uma considerável incerteza sobre qual dos métodos será mais preciso.

3.2.2 Integração de Previsão Via Média Ponderada

Grande parte dos pesquisadores são adeptos também ao critério de obtenção de pesos para realização de integração via média ponderada. Conforme Winkler e Makridakis (1983) e Werner e Ribeiro (2006), dentre tantos outros, os pesos podem ser atribuídos segundo a

variância do erro das previsões individuais, de acordo com a equação 2.8. O propósito deste método é priorizar aquela previsão que obteve menor variância no erro. Contudo, em nem todos os casos isto é possível. Quando se trata de integração de métodos quantitativos é possível obter a variância da previsão para períodos passados. Porém, quando se trata de métodos qualitativos novos, sem registros anteriores, não há como obter a variância de erros de previsões anteriores. Neste caso, acaba-se optando pela média aritmética, que atribui pesos de forma igual entre as previsões, ou seja, peso $1/n$, onde n é o número de previsões que se deseja integrar.

$$w_i = \frac{\frac{1}{\sigma_i^2}}{\frac{1}{\sigma_1^2} + \frac{1}{\sigma_2^2} + \dots + \frac{1}{\sigma_n^2}} \quad (2.8)$$

Na equação 2.8, w_i representa o peso a ser atribuído para a previsão i e σ^2 representa a variância de cada uma das previsões a serem integradas.

O método de integração via média ponderada é, na verdade, uma forma mecanizada de favorecer aquela previsão na qual sua variância (ou algum outro parâmetro escolhido para definição dos pesos) foi menor. Assim como em outros métodos de integração, busca-se reduzir erros provenientes de variáveis intrínsecas do modelo que possam ser responsáveis pela aleatoriedade das séries.

Uma variação de ponderação seria adotar pesos diferentes para cada período da série. Esta pode ser uma alternativa para demandas com presença muito acentuada de sazonalidades, ou em integrações entre previsões quantitativas e qualitativas, cujas previsões qualitativas abrangem promoções ou eventos inéditos. Neste caso, pode-se utilizar o mesmo critério da equação 2.8, porém, ao invés de calcular os pesos para a série inteira com base na variância de cada uma, deve-se calcular o peso para cada série período a período, levando em consideração a variância do erro de cada período individualmente.

3.2.3 Ajuste de Previsão Quantitativa Baseado em Opinião de Especialista

O ajuste de previsões quantitativas baseado em opinião de especialistas é um tipo de integração que gera certo conflito de opiniões entre os pesquisadores. Conforme Webby e O'Connor (1996) é possível encontrar bons resultados com ajustes baseados em opinião de especialistas. Já, segundo Goodwin e Fildes (1999), há vários riscos em realizar um ajuste deste formato. Um deles é que os especialistas precisam ter pleno conhecimento de impacto e

repetição dos padrões dos eventos que gerarão os ajustes, uma vez que se não forem eventos inéditos na série os mesmos já podem ter modificado a previsão do período, causando acúmulo de impacto. Armstrong (2001), alerta ainda para o entusiasmo excessivo ou descrença dos responsáveis pelo ajuste, podendo gerar vieses inexistentes ou prejudicando uma boa previsão quantitativa.

O problema maior na realização de ajustes baseados em opinião é que não há um método padrão para a realização do mesmo. Boa forma de minimizar impactos negativos nos ajustes é a validação da opinião através de acompanhamento do desempenho dos ajustes ao longo do tempo, da mesma forma que é calculado o erro de previsão. Porém, muitas empresas não o fazem devido a seu longo tempo para aplicação. É necessário obter uma boa quantidade de dados históricos para torná-lo um método confiável e, na grande maioria dos casos, os colaboradores acabam deixando as corporações e suas avaliações se tornam uma perda de tempo.

Um método alternativo para tal é a coleta de opinião de vários especialistas e a consolidação destas opiniões. Após algumas rodadas de coleta de dados entre especialistas, é possível chegar a um ajuste comum entre eles, evitando vieses causados pelas razões citadas anteriormente, como excesso de entusiasmo ou de pessimismo frente a uma determinada situação.

Independentemente da forma em que se deseja realizar o ajuste baseado em opinião, sua estrutura básica segue o esquemático da Figura 9.

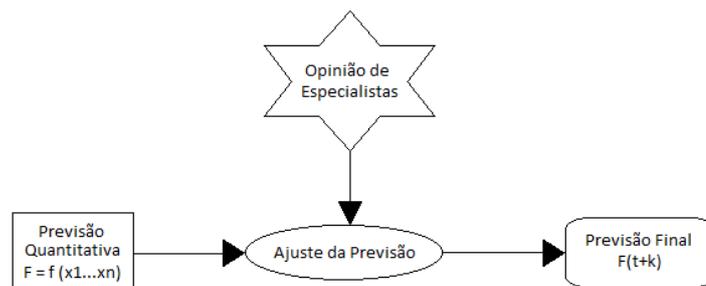


Figura 9: Esquemático de ajuste de previsão baseado em opinião de especialista
Fonte: Adaptado de Sanders e Ritzman (2004)

Muitos autores sugerem o uso de ajuste baseado em opinião, embora todos façam ressalvas quanto à sua utilização. É um método com grande potencial de melhora, porém necessita cuidados especiais no uso, pois como altera diretamente o valor predito, muitas vezes pode ser desastroso dependendo da forma que é realizado. Clemen (1996) alerta ao fato de que o especialista tende a começar nossa avaliação por uma “âncora”, um ponto de referência. Este ponto pode ser a média, mediana, previsão pontual, entre outros, e faz suas avaliações comparativamente a esta âncora. Por conta das características humanas de receio, a

maioria dos casos acaba subestimando a probabilidade de resultados extremos, substituindo previsões mais elevadas por quantidades mais modestas. Este é um tipo de variabilidade humana em avaliações que se deve ter cuidado.

Mas existem, segundo Clemen (1996), alguns fatores pelos quais os humanos, apesar das desconfianças quanto à suas decisões em previsões, merecem chances na previsão ajustada. Previsões meteorológicas, após receberem ajustes qualitativos, têm melhoras significativas na sua acuracidade. Claro que o fato de os meteorologistas realizarem muitas previsões e receberem o *feedback* das mesmas rapidamente auxilia no processo de melhora dos métodos e dos seus conhecimentos de causa, de acordo com o autor.

3.2.4 Acurácia - MAPE

Segundo Moreno et al. (2013), a medida de acurácia MAPE (Mean Absolute Percentage error) é, provavelmente, uma das medidas de acurácia mais utilizadas. É comumente utilizado devido ao fato de realizar comparações percentuais, sem unidade. Isso permite a comparação entre séries completamente diferentes em grandezas e unidades de medida, com quantidades de dados distintos. Permite avaliar sua acuracidade independentemente da natureza dos dados.

Segundo Mileski Jr. (2007), o MAPE fornece um melhor indicativo de quão grandes ou não os erros de previsão podem estar em relação ao valor real. Desta forma, segundo o autor, os erros são mais bem interpretados por administradores e gestores que não estejam totalmente integrados à série em questão, facilitando a tomada de decisão.

$$MAPE_n = \frac{\sum_{t=1}^n \left| \frac{D_t - Z_t}{D_t} \right| \times 100}{n} \quad (2.9)$$

Na equação 2.9, D_t trata-se do valor real da demanda no período t , Z_t é o valor previsto para o período t , e n é o número total de períodos da série.

De acordo com Armstrong (2001), não é recomendado utilizar o R-Quadrado como critério de seleção de um modelo de previsão. O valor de R-Quadrado explica o quanto o modelo pode representar os valores observados, mas não necessariamente indica que se trata de um bom modelo de previsão. Os valores para futuro não são necessariamente dependentes das variáveis que fizeram o modelo se adequarem à série nos dados passados.

3.3 Procedimentos Metodológicos

A demanda a ser modelada no presente trabalho foi retirada de uma indústria cujas principais características são: carteira de pedidos de carácter emergencial (abastece o setor naval e petroleiro com produtos essenciais para operações de altíssimo custo) e pela alta sazonalidade presente na demanda de alguns dos produtos comercializados (produtos para prática esportiva, comumente utilizados nos períodos quentes do ano, ou produtos para pesca, também sazonais).

A variável a ser estudada foi retirada de uma linha de produtos que tem também presença de tendência de crescimento. Trata-se de uma demanda de cordas específicas para trabalhos em altura e prática de esportes de aventura. Busca-se modelar a demanda desta linha de forma que se possa prever o comportamento da mesma e assim programar uma produção mesmo sem a confirmação prévia dos pedidos em carteira, obtendo vantagens que geralmente são proporcionadas por boas previsões (redução de custos, melhor alocação de recursos de produção, correto dimensionamento de estoques, etc).

A demanda base para o estudo é a demanda apresentada na tabela 6. Trata-se de uma demanda mensal de cordas, expressa em quilos vendidos. Até o presente trabalho, o histórico de demanda disponível era de 38 meses de venda. O produto em questão trata-se de um produto recente, inovador para a empresa no seu segmento de utilização. Avaliando seu estágio no ciclo de vida de um produto, conforme demonstrado na figura 10, o produto ainda se encontra na fase de crescimento, não tendo atingido a fase de maturidade. Porém, segundo Kotler e Keller (2006), há ainda a possibilidade de o produto se enquadrar em outros tipos de ciclos de vida, como os apresentados na figura 11. A indefinição quanto a qual característica de ciclo de vida o produto pertence é mais um agravante no momento de prever a demanda do mesmo.

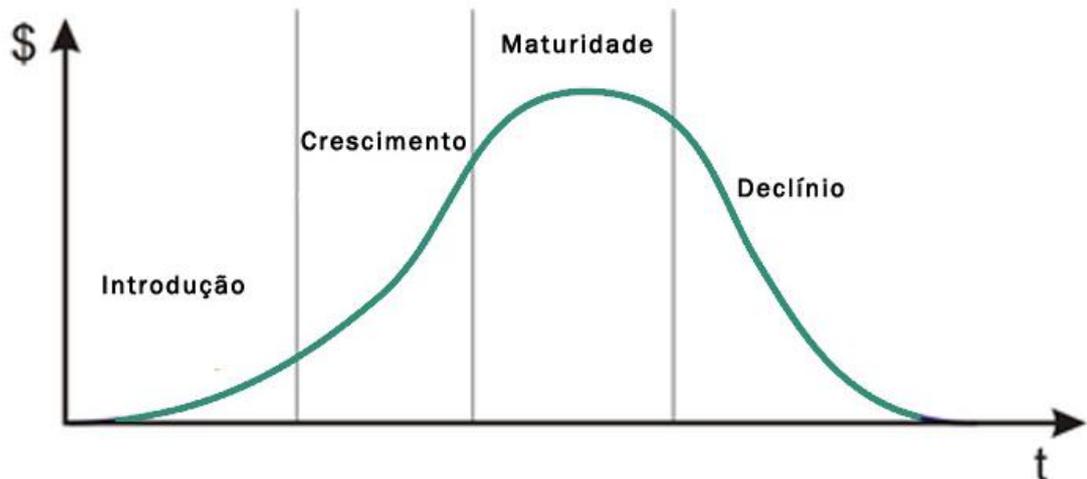


Figura 10: Ciclo de Vida de Produtos
 Fonte: adaptado de Kotler e Keller (2006)

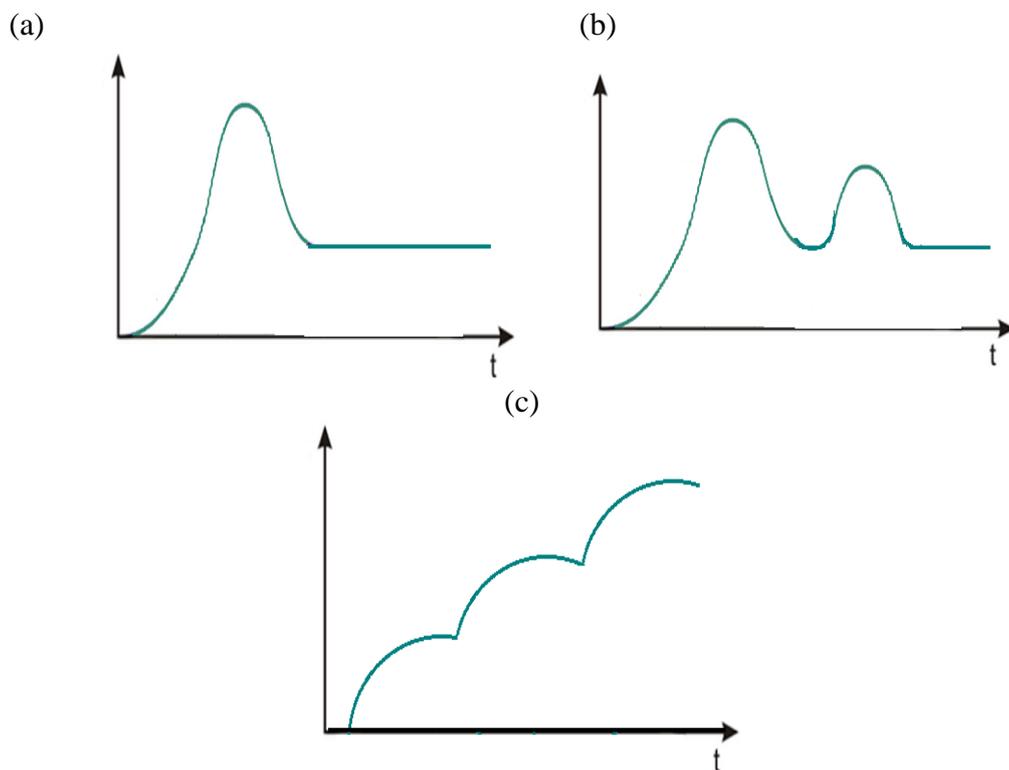


Figura 11: Padrões comuns de ciclo de vida de produtos
 (a) Padrão de crescimento-queda-maturidade (b) Padrão de ciclo-novo ciclo (c) Padrão escalonado

O ciclo de vida de um produto é também um fator complicador na atividade de prever demanda. Sabe-se que, em casos como da demanda em questão, é natural o crescimento da venda até que se atinja o patamar de maturidade. Porém, não é fácil estimar quando o produto atinge este estágio do ciclo, pois este tempo pode variar muito dependendo da estratégia de mercado da empresa, da engenharia de desenvolvimento e aprimoramento do produto e das ações de concorrentes. Quando se tratam de demandas com esta característica (produtos em

fase de crescimento) têm-se maiores as dúvidas quanto à manutenção das características da série histórica e se faz mais necessária ainda a intervenção humana, a fim de evitar erros de previsão.

Tabela 6: Demanda histórica do produto

2011		2012		2013		2014	
Mês	Peso (kg)	Mês	Peso (kg)	Mês	Peso (kg)	Mês	Peso (kg)
1	633	1	478	1	1924	1	2165
2	957	2	498	2	1768	2	2750
3	326	3	1391	3	2219		
4	1509	4	1252	4	3502		
5	1180	5	1440	5	3005		
6	786	6	1508	6	2516		
7	637	7	2388	7	3450		
8	788	8	1997	8	3232		
9	1327	9	1158	9	3328		
10	1308	10	1820	10	4656		
11	1700	11	1943	11	2035		
12	1200	12	2360	12	3194		
Total	12.348	Total	18.230	Total	34.827	Total	4.915

O gráfico da demanda, para melhor visualização da mesma, é demonstrado na figura 12. Na mesma é possível verificar o acompanhamento da linha de tendência, demonstrando a tendência de crescimento.

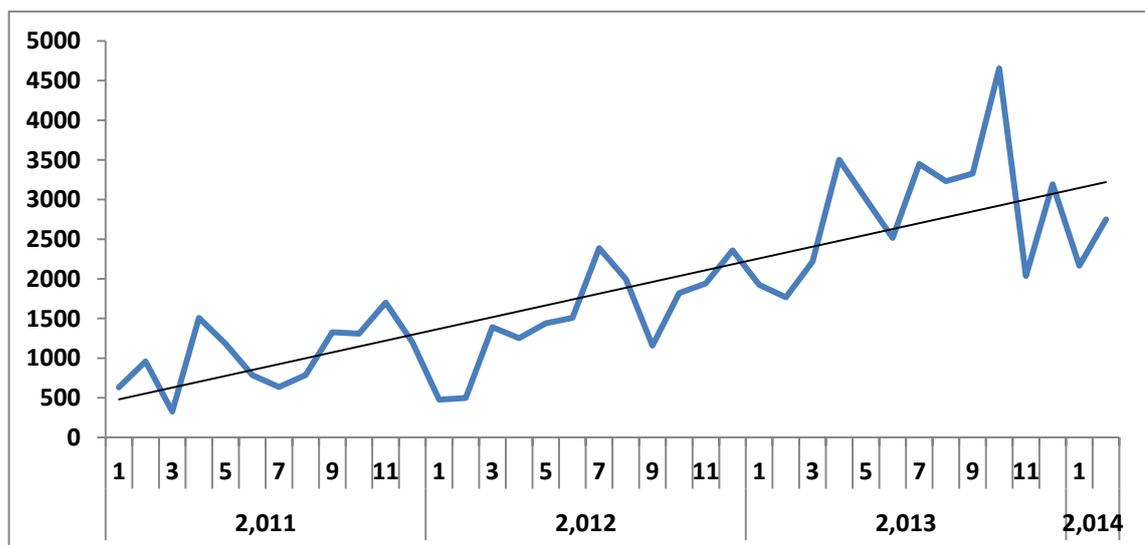


Figura 12: Demanda histórica com linha de tendência

A demanda foi dividida em duas partes para modelagem. Os primeiros 30 meses foram utilizados para a análise e calibração dos modelos quantitativos. Os 8 meses subsequentes foram utilizados para os testes de validação dos mesmos. Não é recomendável para uma

modelagem de boa acurácia um período inferior a 48 meses e 18 meses para validação (em demandas sazonais cuja sazonalidade é de 12 meses). Porém, por se tratar de um produto ainda no início do ciclo de vida, são os dados disponíveis para a previsão. As previsões qualitativas foram obtidas para os 8 meses a partir do mês 30 e utilizadas no estudo atual.

3.3.1 Integração de Previsões Via Média Aritmética

A integração das previsões via média aritmética foi realizada de duas maneiras. Uma das integrações foi realizada entre duas previsões quantitativas. Na outra, foi escolhida a previsão quantitativa de menor erro percentual e uma do modelo qualitativo.

A integração entre as previsões dos modelos quantitativos foi realizada entre duas previsões. A primeira foi obtida via integração de previsão realizada através do modelo de Holt-Winters com um MAPE individual de 21,88% e a outra através de um modelo ARIMA, com MAPE de 22,67%. A tabela 7 apresenta a integração das previsões.

Tabela 7: Integração entre previsões quantitativas

Mês	t	Peso (kg)	Holt-Winters	ARIMA	INTEGRADO
Jul	31	3450	2906,3	3523,4	3214,9
Ago	32	3232	2690,6	2789,3	2740,0
Set	33	3328	2563,7	1076,4	1820,0
Out	34	4656	3028,4	2169,2	2598,8
Nov	35	2035	3504,8	2122,3	2813,5
Dez	36	3194	3221,7	3121,3	3171,5
Jan	37	2165	2350,9	2866,3	2608,6
Fev	38	2750	2668,3	2598,7	2633,5

A segunda integração via média aritmética foi obtida via integração de previsão quantitativa e previsão qualitativa. A previsão qualitativa utilizada foi obtida através de consenso de quatro especialistas de áreas distintas do ramo de cordoaria, através do método Delphi. Para aplicação do método foi necessário quatro rodadas até alcançar o consenso. Foi realizada a previsão para os 8 meses subsequentes da demanda histórica, mesmo período utilizado nas previsões quantitativas.

A previsão qualitativa obteve individualmente um MAPE de 26,67%. Ela foi integrada com a previsão quantitativa de menor erro (Holt-Winters 21,88%). Na tabela 8 é apresentada a integração realizada.

Tabela 8: Integração entre previsões qualitativa e quantitativa

Mês	t	Peso (kg)	Holt-Winters	Qualitativa	INTEGRADO
Jul	31	3450	2906,3	2420	2663,2
Ago	32	3232	2690,6	2400	2545,3
Set	33	3328	2563,7	3200	2881,8
Out	34	4656	3028,4	3370	3199,2
Nov	35	2035	3504,8	2780	3142,4
Dez	36	3194	3221,7	3900	3560,8
Jan	37	2165	2350,9	2880	2615,4
Fev	38	2750	2668,3	3700	3184,2

Foi realizada ainda uma outra previsão, também integrada através de média aritmética, porém integrando as três previsões quantitativas realizadas e a qualitativa obtida. Esta integração está demonstrada na tabela 9.

Tabela 9: Integração entre previsão qualitativa e três quantitativas

Mês	t	Peso (kg)	Holt-Winters	Qualitativa	Decomp	ARIMA	INTEGRADO
Jul	31	3450	2906,3	2420	2629,4	3523,4	2869,8
Ago	32	3232	2690,6	2400	2492,7	2789,3	2593,2
Set	33	3328	2563,7	3200	2530,9	1076,4	2342,7
Out	34	4656	3028,4	3370	2919,9	2169,2	2871,9
Nov	35	2035	3504,8	2780	3480,9	2122,3	2972,0
Dez	36	3194	3221,7	3900	3047,1	3121,3	3322,5
Jan	37	2165	2350,9	2880	2032,5	2866,3	2532,4
Fev	38	2750	2668,3	3700	2204,7	2598,7	2792,9

3.3.2 Integração de Previsão Via Média Ponderada

A integração de modelos via média ponderada, assim como na integração via média aritmética, foi realizada com quatro previsões base, em três formatos de integração. No primeiro formato é realizada a integração das previsões quantitativas, oriundas de modelos estatísticos. No segundo é realizada a integração entre um modelo qualitativo e o modelo quantitativo de menor erro e, na terceira, realizada uma integração via média ponderada de quatro modelos conjugados.

Para definição dos pesos das previsões quantitativas, utilizou-se o método citado anteriormente, baseado na variância das previsões, obtendo-se pesos muito próximos devido à semelhança das variâncias das previsões. O peso para a previsão realizada pelo modelo de Holt-Winters foi de 0,3411 e para o modelo ARIMA foi 0,6588. A integração entre estas previsões está demonstrada na tabela 10.

Tabela 10: Integração via média ponderada entre Holt-Winters e ARIMA

Mês	t	Peso (kg)	Holt-Winters	ARIMA	INTEGRADO
Jul	31	3450	2906,3	3523,4	3312,9
Ago	32	3232	2690,6	2789,3	2755,6
Set	33	3328	2563,7	1076,4	1583,8
Out	34	4656	3028,4	2169,2	2462,3
Nov	35	2035	3504,8	2122,3	2593,9
Dez	36	3194	3221,7	3121,3	3155,5
Jan	37	2165	2350,9	2866,3	2690,5
Fev	38	2750	2668,3	2598,7	2622,5

Para a integração de uma previsão do modelo qualitativo e uma do quantitativo utilizou-se o mesmo método de obtenção de pesos, baseados na variância de cada método individual. Porém, conforme citado anteriormente, para previsões qualitativas sem um histórico de previsão não se pode atribuir pesos com base na variância dos erros de previsão, então foi dividida a avaliação em duas partes. Na primeira previsão, realizada anteriormente ao período predito, foi utilizado o peso genérico, $1/n$ (média aritmética), para obtenção do resultado da situação real, sem valores anteriores. No segundo teste, foi realizada a ponderação utilizando a variância obtida com os erros da previsão após o período preditivo. Esta segunda avaliação será útil para o caso de novas previsões em que sejam interessantes novas ponderações avaliando variâncias de ambos os tipos de previsões.

Na primeira hipótese, do peso atribuído sobre formato de $1/n$, por se tratar de uma integração de apenas dois modelos, o resultado foi, na verdade, o mesmo da integração aritmética. Já para a segunda hipótese, de integração conhecendo a variância do erro, o resultado está representado na tabela 11.

Tabela 11: Integração via média ponderada entre Holt-Winters e Qualitativo

Mês	t	Peso (kg)	Holt-Winters	Qualitativa	INTEGRADO
Jul	31	3450	2906,3	2420	2456,6
Ago	32	3232	2690,6	2400	2421,9
Set	33	3328	2563,7	3200	3152,1
Out	34	4656	3028,4	3370	3344,3
Nov	35	2035	3504,8	2780	2834,5
Dez	36	3194	3221,7	3900	3849,0
Jan	37	2165	2350,9	2880	2840,2
Fev	38	2750	2668,3	3700	3622,4

Na terceira avaliação proposta, de integração de quatro modelos, a previsão resultante está representada na tabela 12.

Tabela 12: Integração via média ponderada entre qualitativo e três modelos quantitativos

Mês	t	Peso (kg)	Holt-Winters	Qualitativa	ARIMA	Decomp.	INTEGRADO
Jul	31	3450	2906,3	2420	3523,4	2629,4	2598,1
Ago	32	3232	2690,6	2400	2789,3	2492,7	2472,5
Set	33	3328	2563,7	3200	1076,4	2530,9	2829,6
Out	34	4656	3028,4	3370	2169,2	2919,9	3149,7
Nov	35	2035	3504,8	2780	2122,3	3480,9	2866,2
Dez	36	3194	3221,7	3900	3121,3	3047,1	3639,2
Jan	37	2165	2350,9	2880	2866,3	2032,5	2709,2
Fev	38	2750	2668,3	3700	2598,7	2204,7	3279,3

3.3.3 Ajuste de Previsão Quantitativa Baseado em Opinião de Especialista

Para a realização ajustes com base em opinião de especialistas foram utilizadas as previsões obtidas nas etapas anteriormente citadas.

O primeiro ajuste foi realizado a partir da previsão qualitativa de menor MAPE, que é a gerada pelo modelo de Holt-Winters. Esta previsão foi apresentada a uma dupla de especialistas e, por consenso, gerado o ajuste apresentado na tabela 13.

Tabela 13: Ajuste de especialistas baseados na previsão gerada pelo modelo de Holt-Winters

Mês	t	Peso (kg)	Holt-Winters	Ajuste Opinião
Jul	31	3450	2906,3	2600
Ago	32	3232	2690,6	2900
Set	33	3328	2563,7	2800
Out	34	4656	3028,4	3100
Nov	35	2035	3504,8	3200
Dez	36	3194	3221,7	3500
Jan	37	2165	2350,9	2750
Fev	38	2750	2668,3	2500

Foi realizado também o ajuste da previsão gerada via média aritmética das quatro previsões integradas. Para o ajuste foram utilizados os mesmos especialistas do ajuste anterior. Está apresentada na tabela 14 a previsão resultante, juntamente da previsão original.

Tabela 14: Ajuste de especialistas baseados na previsão gerada pelo modelo integrado via média aritmética

Mês	t	Peso (kg)	Integrada	Ajuste Opinião
Jul	31	3450	2869,8	2900
Ago	32	3232	2593,2	2700
Set	33	3328	2342,7	3400
Out	34	4656	2871,9	3200
Nov	35	2035	2972,0	3600
Dez	36	3194	3322,5	3800
Jan	37	2165	2532,4	3400
Fev	38	2750	2792,9	2900

E na terceira integração via ajuste de especialista foi utilizada a previsão gerada via média ponderada dos quatro modelos individuais. O resultado desta integração é apresentado na tabela 15.

Tabela 15: Ajuste de especialistas baseados na previsão gerada pelo modelo integrado via média ponderada

Mês	t	Peso (kg)	Integrada	Ajuste Opinião
Jul	31	3450	2603,7	2400
Ago	32	3232	2475,5	2700
Set	33	3328	2826,2	3400
Out	34	4656	3149,4	3700
Nov	35	2035	2864,7	3000
Dez	36	3194	3642,0	3200
Jan	37	2165	2713,3	2800
Fev	38	2750	3282,6	2900

Para a avaliação da influência da previsão base no ajuste do especialista foi utilizado um procedimento cuja execução minimizasse a memória do especialista quanto ao ajuste anterior. Os especialistas realizaram os ajustes em sequência e isolados em uma sala, sem contato com outras pessoas durante a realização dos mesmos, de forma que não pudessem modificar suas opiniões com base em informações externas. Eles também receberam as previsões separadamente, para que não pudessem compará-las e ainda, no intervalo de cada ajuste, receberam atividades de ajuste de previsões de outros produtos, de outras características de demanda. Este procedimento fez com que seu segundo ajuste não estivesse vinculado com o primeiro e assim, sucessivamente.

3.4 Resultados e Discussões

Após a realização das integrações propostas, e com suas previsões calculadas, é possível obter a medida de acurácia de cada método, comparado com a demanda real do período previsto.

As previsões puramente quantitativas já foram citadas anteriormente junto a seus respectivos erros MAPE. Não foi realizado nenhum tipo de avaliação acerca da acuracidade dos métodos quantitativos abordados, pois o objetivo é a avaliação do desempenho dos métodos integrando-os, e não avaliá-los individualmente.

3.4.1 Integração via Média Aritmética

A primeira integração proposta, a de integrar dois métodos quantitativos via média aritmética simples, foi realizada entre as previsões geradas pelos métodos de Holt-Winters e ARIMA.

A previsão integrada apresentou um MAPE maior que o do Holt-Winters individual e menor que o ARIMA individual, conforme demonstrado na tabela 16.

Tabela 16: resultado da integração aritmética entre modelos Holt-Winters e ARIMA

Holt-Winters	ARIMA	Erro Integração
21,88%	22,77%	21,9%

Nesta integração é percebido que não há mudança significativa na acurácia da previsão, possivelmente pela semelhança dos valores preditos por ambos os métodos.

A segunda integração realizada foi uma integração via média aritmética entre um modelo qualitativo e um modelo quantitativo. Para isso foi escolhido o modelo quantitativo de menor MAPE individual, o de Holt-Winters.

O resultado desta integração é apresentado na tabela 17.

Tabela 17: Resultado da integração aritmética entre modelos Holt-Winters e qualitativo

Holt-Winters	Qualitativo (Delphi)	Erro Integração
21,88%	26,67%	23,9%

Percebe-se desta vez uma redução do MAPE comparando com o desempenho individual do modelo qualitativo, porém o desempenho do modelo de Holt-Winters ainda segue sendo melhor se analisado o resultado individualmente, com base no MAPE.

Ainda na integração via média aritmética, com o objetivo de testar a hipótese levantada por Makridakis e Winkler (1983), de saturação de integrações, foi realizada uma previsão integrando as três previsões puramente quantitativas e a qualitativa. O resultado desta integração é apresentado na tabela 18.

Tabela 18: Resultado da integração aritmética entre quatro modelos

Holt-Winters	ARIMA	Decomposição	Qualitativo (Delphi)	Erro Integração
21,88%	22,77%	26,19%	26,67%	21,64%

É possível perceber que dentre as integrações via média aritmética simples, a única que gerou um resultado com um MAPE menor que todas as previsões individuais foi a da integração saturada. Isto se deve ao fato de que quando se faz uma integração via média aritmética, se está reduzindo vieses das previsões individuais, amenizando picos acima ou abaixo da curva de demanda real. Quando isto é feito entre duas previsões, muitas vezes acaba-se criando essa redução dos vieses, mas ao mesmo tempo, não tem-se fonte de dados suficientes para aproximar a previsão da curva real e reduzir o erro. Levando em consideração a sugestão de Armstrong (2001), de utilizar técnicas de previsão que tenham considerado no processo preditivo informações não correlacionadas, a probabilidade de estas previsões terem, para um dado momento, valores acima e abaixo da curva real aumenta. Desta forma, a integração via média aritmética acabaria aproximando a previsão integrada da demanda real.

3.4.2 Integração via Média Ponderada

Nas integrações via média ponderada, a primeira integração realizada, da mesma forma que nas integrações via média aritmética, foi feita com dois modelos quantitativos. O resultado desta integração é apresentado na tabela 19.

Tabela 19: Resultados da integração ponderada entre modelos Holt-Winters e ARIMA

Holt-Winters	ARIMA	Erro Integração
21,88%	22,77%	21,97%

Nota-se que o resultado da integração via média ponderada gerou um erro semelhante ao da integração via média aritmética. Isto se deve à grande semelhança entre a variabilidade do erro das duas previsões, característica utilizada para atribuição dos pesos individuais de cada previsão. Sendo assim, ambas receberam pesos muito semelhantes e sua integração acabou muito semelhante à média aritmética.

Na integração via média ponderada entre os modelos qualitativo e de Holt-Winters, o resultado encontrado foi o apresentado na tabela 20.

Tabela 20: Integração ponderada da previsão qualitativa e do modelo de Holt-Winters

Holt-Winters	Qualitativo	Erro Integração
21,88%	26,67%	26,25%

Desta vez nota-se um resultado pior na integração via média ponderada. A explicação para este resultado se deve ao fato de que a previsão qualitativa recebeu um peso maior no momento de ponderá-las, devido a ter menor variabilidade de erro. Isto é um resultado interessante, pois a previsão de menor variabilidade de erro possui maior erro médio, transformando o resultado final da integração “pior”. Pode-se perceber, neste caso, que a variabilidade do erro talvez não tenha sido o critério ideal para a atribuição dos pesos das previsões individuais.

Na integração via média ponderada, bem como na integração via média aritmética, foram integrados os quatro modelos utilizados para previsão individual, a fim de verificar a hipótese de saturação da integração. O resultado encontrado foi o apresentado na tabela 21.

Tabela 21: Resultados da integração ponderada entre quatro previsões individuais

Holt-Winters	ARIMA	Decomposição	Qualitativo	Erro Integração
21,88%	22,77%	26,19%	26,67%	24,33%

Mais uma vez pode-se observar que a média ponderada não gerou um erro menor que a média aritmética. Isto pode ser atribuído ao fato de que a média ponderada, apesar de favorecer as séries com menor variabilidade do erro, talvez tenha amenizado o impacto de fatores subjetivos que foram considerados em alguns períodos apenas nas séries de maior variabilidade de erro.

3.4.3 Ajuste de Previsão por Opinião de Especialistas

Além das integrações anteriormente citadas foi analisado ainda o desempenho da realização de ajustes de previsão baseado em opinião de especialistas.

A avaliação foi feita sobre os três ajustes efetuados e os desempenhos encontrados estão demonstrados de forma conjunta na tabela 22.

Tabela 22: Resultados dos ajustes de previsão baseados na opinião de especialistas

Método	MAPE Individual	MAPE ajuste
Modelo de Holt-Winters	21,88%	23,39%
Integração Aritmética 4 previsões	21,64%	28,02%
Integração Ponderada 4 previsões	24,33%	18,99%

Fica evidente uma disparidade entre os desempenhos das previsões ajustadas. Assim como um dos ajustes gerou uma previsão com o menor MAPE obtido em todo o estudo, para a mesma técnica e com previsão base com erro semelhante, foi gerada uma previsão com erro imenso, mostrando o quão este método pode ser inseguro.

3.4.4 Avaliação dos resultados obtidos

O consolidado dos erros das previsões obtidas ao longo deste trabalho pode ser observado na tabela 23, organizada em formato crescente de MAPE.

Tabela 23: Consolidado de Resultados das integrações

Método	MAPE
Ajuste de Opinião Ponderada 4 previsões	18,99 %
Integração via Média Aritmética 4 previsões	21,64 %
Modelo de Holt-Winters	21,88 %
Integração Aritmética Holt-Winters e ARIMA	21,90 %
Integração Ponderada Holt-Winters e Arima	21,97 %
Modelo ARIMA	22,77 %
Ajuste de Opinião Holt-Winters	23,39 %
Integração Aritmética Holt-Winters e Qualitativo	23,90 %
Integração Ponderada 4 previsões	24,33 %
Decomposição Clássica	26,19 %
Integração Ponderada Holt-Winters e Qualitativo	26,25 %
Ajuste Opinião Aritmética	28,02 %

Apenas pelo consolidado de resultados é difícil realizar uma avaliação dos métodos, pois os resultados não seguem um padrão de modelos confiáveis, mas sim uma aparente aleatoriedade entre os desempenhos individuais dos métodos. Para melhor avaliar os resultados dos métodos de integração de previsões é apresentado na tabela 24 o consolidado de resultados sem os resultados dos ajustes de opinião dos especialistas, pois o mesmo será avaliado a parte.

Tabela 24: Consolidado de Resultados de MAPE das previsões integradas

Método	MAPE
Integração Média Aritmética 4 previsões	21,64 %
Modelo de Holt-Winters	21,88 %
Integração Aritmética Holt-Winters e ARIMA	21,90 %
Integração Ponderada Holt-Winters e Arima	21,97 %
ARIMA	22,77 %
Integração Aritmética Holt-Winters e Qualitativo	23,90 %
Integração Ponderada 4 previsões	24,33 %
Decomposição Clássica	26,19 %
Integração Ponderada Holt-Winters e Qualitativo	26,25 %

3.4.5 Integrações de previsões

Acerca de integrações de múltiplas previsões, testando a sugestão dada por Makridakis e Winkler (1983), fica claro que estavam com razão no que diz respeito ao ganho de acuracidade ao integrar várias previsões diferentes. Quando aumentado o número de previsões integradas, o erro médio ficou menor e a variabilidade do erro também. Pôde-se perceber que ao realizar a integração via média aritmética simples das quatro previsões individuais, foi obtido um MAPE menor do que o de cada previsão individual. Isto demonstra que, com o acréscimo de previsões, mesmo elas tendo erros maiores do que outras, outros fatores são considerados, aumentando a abrangência de variáveis do método composto e tornando o modelo mais confiável do que modelos individuais simples.

Para deixar mais claro que a integração de previsões individuais não correlacionadas, mesmo que com MAPE maior, podem melhorar a previsão integrada, foi realizada a comparação entre a integração dos três métodos quantitativos separadamente da integração destes com a previsão qualitativa. O resultado é apresentado na tabela 25.

Tabela 25: Comparação da integração de métodos

MAPE Métodos Quantitativos Integrados	MAPE Método Qualitativo	MAPE Integração Quantitativos + Qualitativo
22,82%	26,67%	21,64%

Nota-se que, conforme sugerido por Armstrong (2001), a integração de métodos com fonte não-correlacionada pode sim incluir fatores não considerados nas previsões individuais, mesmo que individualmente estas previsões tenham desempenho piores.

Já o critério de integrações via média ponderada, atribuindo pesos para as previsões baseado na variância do erro é algo que deve ser avaliado para casos mais específicos. Na

integração ponderada algumas previsões receberam peso maior devido a variância do erro ser menor, porém não se tratavam de previsões boas, mas sim com menores variâncias. Talvez se possam avaliar métodos de ponderação baseados em magnitude de erro ou ainda, conforme comentado anteriormente, de acordo com sua acurácia por período. Para o critério de variância do erro, no caso específico, os resultados não revelaram boas previsões, ou mesmo, grandes vantagens frente aos outros métodos.

Pôde-se perceber ainda que a afirmação de Armstrong (2001), de que não é recomendável a integração de métodos que tenham fontes correlacionadas, serve para integrações simples, de dois métodos. Quando se trata deste tipo de integração o ganho de acuracidade é mínimo, ou ainda nulo. Porém, ao integrar vários métodos, mesmo eles sendo correlacionados, pode-se obter um ganho de acuracidade pela hipótese de redução da variabilidade.

3.4.6 Ajuste de especialista

Conforme citado anteriormente, Goodwin e Fildes (1999) já haviam demonstrado os riscos de aplicar ajustes de especialistas sem uma metodologia confiável para tal procedimento. As variabilidades humanas de avaliação podem apresentar, como no caso do ajuste de previsão integrada via média ponderada, resultados muito positivos, trazendo ao modelo um ganho de acuracidade muito grande. Porém, com a importância da atividade de previsão dentro das empresas, é impraticável adotar um método em que se tenha o risco de o desempenho da previsão variar tanto, como no caso do ajuste por opinião da previsão integrada via média aritmética.

Outro fator importante identificado é que a previsão base do ajuste por opinião de especialista não é tão relevante para avaliação do desempenho do ajuste. Levando em consideração o consolidado de resultados apresentado na tabela 23, pode-se perceber que as previsões que possuíam MAPE individual menor acabaram piorando seu desempenho. Já aquela que possuía o maior erro MAPE dentre as três acabou se tornando a de melhor desempenho de todos os métodos. Isto reforça o argumento de que ajuste baseado em opinião de especialista deve ser um recurso utilizado com algum tipo de metodologia que possa reduzir ou evitar a variabilidade humana na tomada de decisão.

Percebeu-se ainda nos ajustes realizados que não há uma opinião formada a respeito dos valores preditos. Talvez por receio ou insegurança nas próprias opiniões, o especialista realizou ajustes diferentes para períodos semelhantes. Provavelmente o fez com base no valor predito pelos modelos, alterando-os para mais ou para menos confiando naquela fonte de

informação. Isto somente comprova a afirmação de Clemem (1996), que o ajuste é realizado com base em uma “âncora”, ou um ponto de referência. O autor já alertava sobre este receio humano em expressar sua opinião diretamente, preferindo “dividir” a responsabilidade com a previsão base do modelo estatístico ou integrado.

3.5 Conclusão

Integração de modelos e resultados de previsões, conforme visto, são recursos utilizados há muitos anos. Ao longo deste tempo, pesquisadores destinaram grande parte de suas vidas buscando integrações e métodos que reduzam os erros de previsão e tragam aos seus modelos uma acurácia cada vez maior.

Pôde-se perceber que o trabalho de integrar previsões é vantajoso. Ele pode trazer resultados melhores se comparados com as previsões individuais. Porém, a integração de previsões também pode ser bastante perigosa se não for bem analisada e aplicada sem uma metodologia adequada. É preciso buscar, dentro de cada contexto, a metodologia mais apropriada de realizar a integração da maneira mais confiável possível.

Viu-se ainda que métodos estatísticos possuem desvantagens que podem estar relacionadas à uma deficiência matemática na modelagem da demanda ou a aleatoriedades do próprio mundo dos negócios. Mas levando em consideração que neste trabalho os modelos foram baseados na mesma fonte de informação, não fica difícil concordar com a afirmação de Keith Ord (Dawes et al. 1994), quando diz que combinar previsões nada mais é do que um *Band-Aid*. O autor acredita que deve-se entender porque combinar previsões funciona e trabalhar em cima disto para criar previsões mais eficientes e processos mais estáveis.

Sabe-se que um modelo matemático não é capaz de captar a variabilidade do mercado e prever fatores inéditos ao longo da série histórica. Por isso não se tem a expectativa de que seja eliminada, mas sim utilizada com formato mais metodológico e confiável, de forma que as variações fiquem a cargo do mercado, e não das fontes preditoras.

Esta mesma linha de raciocínio foi adotada por Goodwin e Fildes (1999), ao afirmarem que o grande desafio é desenvolver métodos e sistemas de suporte que ajudarão os preditores a fazer seus julgamentos mais efetivos e apropriados, incentivando-os a delegar aos modelos estatísticos as tarefas em que o julgamento pessoal poderia ser prejudicial.

Portanto é possível afirmar que, pelo menos por um grande período, as instituições não estarão livres da utilização de combinação de previsão. Porém, deve-se trabalhar em busca de

métodos mais confiáveis nas duas formas de previsão, para que depois se possa integrá-las de maneira mais vantajosa. As previsões estatísticas devem ser mais precisas, capazes de captar da demanda todo tipo de informação que possa ser útil e extrapolada, enquanto que as previsões qualitativas ou ainda ajustes realizados diretamente na previsão sejam objetivos e possam ser também utilizados sem que ocorram interferências de fatores pessoais dos especialistas ou ainda sobreposições de variáveis já captadas pelos modelos quantitativos.

3.6 Referências

- ANDERSON, D.R.; SWEENEY,D.J.; WILLIAMS, T.A.; **Quantitative Methods for Business**. West Publishing Company. (1983)
- ARMSTRONG, J.S. **Principles of Forecasting: A handbook for researchers and practitioners**. Kluwer Academic Publishers. Philadelphia, 2001
- ARMSTRONG, J.S.; COLLOPY, F. **Error Measures for Generalizing About Forecasting Methods: Empirical Comparisons**. International Journal of Forecasting 8 (1992) Pag. 69-80
- CLEMEN, R.T. **Combining Forecasts: A Review and Annotated Bibliography**. International Journal of Forecasting 5 (1989) Pag. 559-583
- CLEMEN, R.T. **Making Hard Decisions**. Second Edition. Duxbury Press. (1996)
- DAWES, R.; FILDES, R; LAWRENCE, M.; ORD, K. **The past and the future of forecasting research**. International Journal of Forecasting 10 (1994) Pag 151-159
- FILDES, R; HIBON, M.; MAKRIDAKIS,S.; MEADE,N. **Generalising about univariate forecasting methods: further empirical evidence**. International Journal of Forecasting 14 (1998) Pag. 339-358
- FISCHER, S. **Séries univariantes de tempo – metodologia de Box-Jenkins**. Fundação de economia e estatística. Porto Alegre, 1982.
- GAMBERINI, R.;LOLLI, F.; RIMINI, B.; SGARBOSSA, F. **Forecasting of sporadic demand patterns with seasonality and trend components: An empirical comparison between Holt-Winters and (S)ARIMA methods**. Mathematical Problems in Engineering, 2010.
- GRANGER, C. W. J., NEWBOLD, P. **Spurious regressions in econometrics**. Journal of Econometrics 2, 1974. Pag. 111-120.
- GOODWIN, P. **Improving the Voluntary Integration of Statistical Forecasts and Judgment**. International Journal of Forecasting 16 (2000) Pag. 85-99

- GOODWIN, P.; FILDES, R. **Judgmental Forecasts of Time Series Affected by Special Events: Does Providing a Statistical Forecast Improve Accuracy?** Journal of Behavioral Decision Making 12 (1999) Pag. 37-59
- HANKE, J.E.; REITSCH, A.G. **Business Forecasting**. Eastern Washington University. (1981)
- HOLT, C.C. **Forecasting seasonals and trends by exponentially weighted moving averages**. International Journal of forecasting 20 (2004). Pag 5-10.
- KALCHSCHMIDT, M. **Best practices in demand forecasting: Tests of universalistic, contingency and configurational theories**. Int. J. Production Economics 140 (2012) Pag 782-793
- KERKKANEN, A.; KORPELA, J.; HUISKONEN, J. **Demand forecasting erros in industrial context: Measurement and impacts**. Int. J. Production Economics 118 (2009) Pag. 43-48
- KOTLER, P.; KELLER, K.L.; **Marketing Management**. 12a. Edição. Pearson Education, Inc. New Jersey, 2006.
- MAKRIDAKIS, S.; HIBON, M. **ARMA models and the Box-Jenkins methodology**. Journal of Forecasting, Vol. 16 (1997). Pag. 147-163.
- MAKRIDAKIS, S.; WHEELWRIGHT, S.C.; HYNDMAN, R.J. **Forecasting – methods and applications**, 3a. edição, John Wiley, Nova York, 1998.
- MAKRIDAKIS, S.; WINKLER, R.L. **Averages of Forecasts: Some Empirical Results**, Management Science, 29. Pag. 987-996
- MILESKI JR., A. **Análise de métodos de previsão de demanda baseados em séries temporais em uma empresa do setor de perfumes e cosméticos**. Dissertação de mestrado. Curitiba, 2007.
- MORENO, J.J.M.; POL, A.P.; ABAD, A.S.; BLASCO, B.C.; Using the R-MAPE index as a resistant measure of forecast accuracy. Psicothema, Vol. 25. No. 4. Pag 500-506.
- PELLEGRINI, F. R. **Metodologia para implementação de sistemas de previsão de demanda**. Dissertação de mestrado. Porto Alegre, 2001.
- PELLEGRINI, F. R.; FOGLIATTO, F. S. **Passos para Implantação de Sistemas de Previsão de Demanda – Técnicas e Estudo de Caso**. Revista Produção, V. 11 n. 1 Novembro de 2001
- SANDERS, N.R.; GRAMAN, G.A. **Quantifying costs of forecast errors; A case study of the warehouse environment**. Omega 37 (2009) Pag. 116-125

SANDERS, N.R.; MANRODT, K.B. **Forecasting practices in US corporations: survey results.** Interfaces,(1994) Vol. 24, Pag. 91-100.

SANDERS, N.R.; RITZMAN, L.P. **Integrating Judgmental and Quantitative Forecasts: Methodologies for Pooling Marketing and Operations Information.** International Journal of Operations e Production Management. Vol. 24 No. 5 (2004) Pag 514-529

VEIGA, C.R.P.; VEIGA, C.P; DUCLÓS, L.C.; **A acuracidade dos modelos de previsão de demanda como fator crítico para o desempenho financeiro na indústria de alimentos.** Future studies research journal. V.2 (2010), N.2, Pag 83-107

WEBBY, R. e O'CONNOR, M.; **Judgmental and Statistical Time Series Forecasting: A Review of the Literature.** International Journal of Forecasting, 12 (1996), Pag 91-118

WERNER, L.; RIBEIRO, J.L.D.; **Modelo Composto para Prever Demanda Através da Integração de Previsões.** Produção, v. 16 (2006) Pag. 493-509

4. Conclusão

4.1 A Escolha do Método Quantitativo

A primeira etapa desenvolvida ao longo deste trabalho foi a escolha dos métodos quantitativos. Para a realização deste tipo de previsão foi necessário selecionar modelos capazes de analisar demandas com presença de tendência e sazonalidades, devido às características da demanda escolhida.

Após a seleção dos métodos e geração da previsão de cada um, não foi realizado o descarte de nenhum dos mesmos, pois suas previsões individuais serviram para auxiliar no desenvolvimento das comparações realizadas ao longo do Artigo 2 e enriquecer os resultados. Os desempenhos apresentados pelos métodos quantitativos foram bastante satisfatórios, porém não suficientemente conclusivos para determinar um modelo ideal para a demanda proposta. Seria simples definir um método adequado apontando ao menor erro MAPE apresentado, porém um sistema de previsão confiável deve possuir uma boa sistemática de revisão dele mesmo, conforme sugestão de Armstrong (2001), para garantir que o modelo escolhido segue acompanhando as mudanças ocorridas na demanda. Portanto no momento o modelo de menor erro MAPE pode ser o mais adequado, mas é importante estabelecer as diretrizes de revisão de acordo com a política de cada empresa.

4.2 Desempenho dos Modelos Mistos

Nos modelos mistos foi possível perceber uma série de fatores interessantes aos sistemas de previsão. Ficou comprovado que, conforme afirmação realizada por Makridakis e Winkler (1983), mesmo os modelos mais simples de integração podem trazer melhorias aos sistemas de previsão e compartilhando assim com a afirmação de Granger e Newbold (1974), de que sempre vale a pena tentar a integração de previsões.

Foi citada ainda ao longo do trabalho a afirmação de Goodwin e Fildes (1999) de que as previsões quantitativas possuem um potencial imenso de extrapolar padrões em séries, enquanto as qualitativas tem uma capacidade única de incluir na previsão o efeito de influências externas. Fica claro, após as integrações realizadas, que é possível extrair resultados positivos destas características, uma vez que, ao integrar as previsões, foi obtida uma previsão final com erro menor do que as previsões individuais. Houve, nesta integração,

a interação de fatores que não estavam em ambas previsões e passaram a ser considerados após a união dos conhecimentos em uma previsão única.

O principal benefício de unir previsões de naturezas diferentes é fazer com que ambas possam dar suas parcelas de contribuição para a geração da previsão final. Ambos os tipos de previsão possuem seus benefícios, portanto é sensato tentar sempre trabalhar com os dois juntos.

4.3 Desempenho do Ajuste de Especialistas

O teste da integração de métodos quantitativos e qualitativos via ajuste direto na previsão foi o único tipo de integração desaconselhado, pelo menos da forma realizada. No compilado de resultados de erro MAPE dos testes realizados, um dos ajustes de especialistas está em primeiro lugar, apresentando o menor erro. Porém, é justamente um ajuste de especialista que gerou também o pior resultado do trabalho, com cerca de nove por cento de diferença de erro entre um ajuste e outro. Isto comprova a baixa confiabilidade de um método como este em um sistema de previsão. A metodologia utilizada, de pedir aos especialistas que realizassem os ajustes de mais de uma demanda entregue levou a crer que os mesmos não o fazem com base em um valor em que acreditam, e sim em uma perspectiva de melhoria ou piora do valor apresentado. Isto demonstra que, independentemente da opinião real do especialista sobre o período apresentado, ele utilizou-se do valor informado pela previsão base para gerar seu ajuste. É uma forma que o ser humano encontra para dividir a responsabilidade de eventuais erros cometidos.

Além disto, mesmo para períodos iguais, foram obtidas previsões diferentes do mesmo especialista. Isto também demonstra que, independentemente do motivo que o especialista possa ter para tê-lo feito, discrepâncias tão grandes não podem ser aceitas em modelos que buscam a redução de erros em atividades tão importantes para os resultados das empresas.

4.4 Considerações Finais

É possível afirmar que os objetivos do trabalho foram atingidos e que foi possível determinar os riscos e benefícios que a integração de métodos de previsão pode trazer. A limitação de a demanda utilizada não ser muito antiga parece não ter impedido os modelos propostos de apresentar resultados conclusivos para a análise.

Foi possível ainda, com esta avaliação, afirmar que a empresa em questão teria vantagens na utilização dos métodos apresentados, pois com o método recomendado para utilização conseguiria transformar um erro de quase 27% (método qualitativo utilizado atualmente) para aproximadamente 21,5%. Esta redução pode ter importância significativa em valores financeiros se mantida ao longo do tempo.

4.5 Sugestões para pesquisas futuras

Como possibilidades para extensão do estudo apresentado são sugeridas as seguintes linhas de pesquisa:

- Avaliação de metodologias de análise de confiabilidade em ajustes realizados por especialistas diretamente à previsão realizada.
- Avaliação de integrações por médias ponderadas com outros parâmetros de atribuição de pesos e comparação dentre eles
- Aplicação e avaliação de integrações via médias ponderadas com pesos atribuídos período a período para os métodos individuais.
- Análise de como a curva de ciclo de vida de produtos pode auxiliar na geração de previsão de demandas mais confiáveis para produtos recém-lançados.