

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

Luciana Cristina Calsing

PREVISÃO DE DEMANDA COMBINADA A PARTIR DE
MÉTODOS QUANTITATIVOS E OPINIÃO DE
ESPECIALISTAS

Porto Alegre

2015

Luciana Cristina Calsing

**PREVISÃO DE DEMANDA COMBINADA A PARTIR DE MÉTODOS QUANTITATIVOS E OPINIÃO DE
ESPECIALISTAS**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul como requisito parcial à obtenção do título de Mestre em Engenharia de Produção, modalidade Profissional, na área de concentração em Sistemas de Produção.

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

Porto Alegre

2015

Luciana Cristina Calsing

**PREVISÃO DE DEMANDA COMBINADA A PARTIR DE MÉTODOS QUANTITATIVOS E OPINIÃO DE
ESPECIALISTAS**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Produção na modalidade Profissional e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul.

Prof. Flávio Sanson Fogliatto, *Ph.D.*

Orientador PPGEP / UFRGS

Prof. José Luis Duarte Ribeiro, Dr.

Coordenador PPGEP/UFRGS

Banca Examinadora:

Prof. Gilberto Tavares dos Santos, Dr. (EA/UFRGS)

Profa. Liane Werner, Dra. (PPGEP/UFRGS)

Prof. Michel José Anzanello, *Ph.D.* (PPGEP/UFRGS)

AGRADECIMENTOS

Agradeço a Deus pela saúde e sabedoria.

Sou grata aos meus pais, Judit e Plínio, à minha irmã Larissa e à minha sobrinha Lívia pelo incentivo e afeto. A todos os familiares e amigos que souberam compreender o tempo que dediquei para execução desta dissertação, em especial ao Gustavo pelo companheirismo e paciência.

Agradeço ao meu orientador Flávio Sanson Fogliatto pela sua nobre contribuição, confiança e disponibilidade. Aos membros da banca que disponibilizaram tempo para avaliar o trabalho.

Agradeço a Fernando Lemos pelos ensinamentos marcantes durante a graduação que contribuíram para a elaboração desta dissertação.

Aos amigos Viviane, David, Vagner e Erica por cederem suas casas durante o período das disciplinas.

Aos colegas do mestrado pelos momentos agradáveis, em especial ao Lúcio Cantarelli Noal pela parceria e troca de informações ao longo destes dois anos.

À Sheila Lauffer Glaser pelo apoio e encorajamento.

E à empresa que viabilizou o estudo de caso apresentado.

CALSING, Luciana Cristina. **Previsão de demanda combinada a partir de métodos quantitativos e opinião de especialistas**, 2015. Dissertação (Mestrado em Engenharia) - Universidade Federal do Rio Grande do Sul, Brasil.

RESUMO

A previsão de demanda que combina métodos quantitativos e a opinião de especialistas é uma técnica amplamente utilizada na tentativa de aproximar a previsão da demanda real. A presente dissertação apresenta uma revisão bibliográfica sobre combinação de previsões e propõe um método combinado a partir de métodos quantitativos e opinião de especialistas. A revisão sistemática da literatura foi realizada em trabalhos atuais e de relevância para o tema em estudo, com o auxílio de cinco bases de dados. O referencial teórico, que totaliza 38 publicações, apresenta conceitos teóricos sobre combinação de previsões, bem como exemplifica, através de aplicações práticas, como esta técnica está sendo utilizada pelas empresas. Com base nesta revisão foi possível estruturar um método combinado de previsão de demanda. O método proposto não só combina matematicamente as previsões quantitativas e qualitativas, como também pondera, através da matriz de comparações do método AHP (*Analytic Hierarchy Process*), a opinião de cada especialista responsável por gerar as previsões qualitativas. Esta dissertação, além de descrever detalhadamente o método proposto, ilustra a aplicação deste através de um estudo de caso realizado em uma empresa metal-mecânica. Tal estudo foi realizado para diferentes modelos de produtos, considerando um horizonte de previsão de doze meses. Ao final, o método AHP mostrou-se uma forma eficiente de ponderação da opinião dos especialistas. O resultado mostra que a previsão combinada proposta apresentou os menores erros entre as previsões analisadas, não só melhorando a acurácia total da previsão em mais de 23%, como também aumentando a acurácia para a maioria dos meses analisados e dos modelos testados. A partir da revisão bibliográfica e do método proposto, oportunidades para estudos futuros foram identificadas.

Palavras-chave: previsão de demanda, combinação de previsões, opinião de especialistas, AHP

CALSING, Luciana Cristina. **Combination of demand forecast using quantitative methods and expert opinion**, 2015. Dissertation (Master in Engineering) - Federal University of Rio Grande do Sul, Brazil.

ABSTRACT

Demand forecasting that combines quantitative methods and judgmental adjustments is a technique widely used in the attempt to approximate forecast to actual demand. This thesis presents a literature review on combination of forecasts, and proposes a combined method using quantitative methods and expert opinion. A systematic literature review has been carried out analyzing works that were considered relevant to the topic under study, gathered from five databases. The review, which is comprised of 38 references, introduces theoretical concepts about combination of forecast, and exemplifies through practical applications how companies are using this technique. Based on this review it was possible to structure a combination model. The model presented not only combines mathematically the quantitative and qualitative forecast, but also assigns importance weights to experts using the comparison matrices of AHP (Analytic Hierarchy Process). We describe in details the model proposed and illustrate it through a practical application in a manufacturing industry. The case study considers several products in a 12-month forecast horizon. AHP has proven to be efficient for assigning weights to experts. Using the combination model proposed in this thesis we obtained improvements in the overall forecast accuracy of more than 23%; accuracy was also improved for the majority of periods and products analyzed. The literature review and proposed model led to the proposition of several opportunities for future research.

Keywords: demand forecasting, combination of forecast, expert opinion, AHP

LISTA DE FIGURAS

Figura 2.1 - Esquema de pesquisa.....	20
Figura 2.2 - Combinação de métodos quantitativos e qualitativos.....	24
Figura 2.3 - MAE versus ajustes normalizados.....	30
Figura 3.1 - Sequência de execução do método proposto.....	43
Figura 3.2 - Organização dos dados coletados.....	51
Figura 3.3 - Demanda do produto e sua tendência.....	52
Figura 3.4 - Modelagem para a série temporal do produto.....	53
Figura 3.5 - Matriz de comparação e vetor de pesos.....	55

LISTA DE TABELAS

Tabela 2.1 - Pesquisa nas bases de dados.....	19
Tabela 3.1 - Índice randômico.....	47
Tabela 3.2 - Previsão qualitativa para $i = 1$	52
Tabela 3.3 - Modelo matemático por família de produto.....	54
Tabela 3.4 - Previsão quantitativa para $i = 1$	54
Tabela 3.5 - Valores de α_j	55
Tabela 3.6: Valores ótimos de β_i	56
Tabela 3.7 - Previsão combinada para $i=1$ em $t-4$	56
Tabela 3.8 - Acurácia das previsões (MAPE) por família.....	58
Tabela 3.9 - Acurácia das previsões (MAPE) por período.....	58
Tabela 3.10 - Acurácia total (MAPE) das previsões.....	58

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Considerações Iniciais	11
1.2	Tema e Objetivos	12
1.3	Justificativa do Tema e dos Objetivos	12
1.4	Procedimentos Metodológicos	13
1.5	Estrutura da Dissertação	13
1.6	Delimitações do Estudo	14
1.7	Referências	14
2	PRIMEIRO ARTIGO: PREVISÃO DE DEMANDA COMBINADA A PARTIR DE MÉTODOS QUANTITATIVOS E OPINIÃO DE ESPECIALISTAS: ANÁLISE DE ESTUDOS EMPÍRICOS	16
2.1	Introdução	16
2.2	Metodologia.....	18
2.3	Previsão de demanda e combinação de previsões.....	21
2.3.1	Aplicações práticas de combinação de previsões.....	25
2.4	Conclusões e sugestões para trabalhos futuros.....	33
2.5	Referências	35
3	SEGUNDO ARTIGO: Previsão de demanda combinada a partir de métodos quantitativos e opinião de especialistas: proposta metodológica e estudo de caso	40
3.1	Introdução	40
3.2	Método	43
3.2.1	Passo 1: Coleta e tratamento de dados	43
3.2.2	Passo 2: Obtenção das previsões individuais	44
3.2.2.1	Obtenção da previsão qualitativa.....	44
3.2.2.2	Obtenção da previsão quantitativa.....	45
3.2.3	Passo 3: Determinação dos pesos de importância dos especialistas	46
3.2.4	Passo 4: Obtenção da previsão combinada	47
3.2.5	Passo 5: Validação dos resultados.....	48
3.3	Estudo de caso	49
3.3.1	Passo 1: Coleta e tratamento de dados	50
3.3.2	Passo 2: Obtenção das previsões individuais	51
3.3.2.1	Obtenção da previsão qualitativa.....	51
3.3.2.2	Obtenção da previsão quantitativa.....	52

3.3.3	Passo 3: Determinação dos pesos de importância dos especialistas	54
3.3.4	Passo 4: Obtenção da previsão combinada	56
3.3.5	Passo 5: Validação dos resultados.....	57
3.4	Discussão dos resultados	58
3.5	Conclusões e sugestões para trabalhos futuros.....	59
3.6	Referências	60
4	CONSIDERAÇÕES FINAIS	63
4.1	Conclusões	63
4.2	Sugestões para trabalhos futuros	64
4.3	Referências	65
APÊNDICE	66

1 INTRODUÇÃO

1.1 Considerações Iniciais

Previsões de demanda desempenham um papel fundamental para o futuro das organizações. Por apresentarem uma visão mais clara de futuro, previsões podem auxiliar na tomada de decisões, tanto em nível operacional como estratégico (ARMSTRONG, 2001). As previsões são utilizadas nos mais diversos setores e propiciam não só o gerenciamento da produção e controle eficiente de recursos, como também a projeção de novos investimentos, elevados níveis de serviço e satisfação dos clientes (KOTLER, 1991).

Os diversos métodos de previsão de demanda podem ser classificados em duas categorias: qualitativos e quantitativos (MONTGOMERY; JOHNSON; GARDINER, 1990). Enquanto os métodos qualitativos consideram a opinião de especialistas para gerar previsões, os métodos quantitativos utilizam técnicas estatísticas e modelos matemáticos para prever a demanda futura (MAKRIDAKIS; WHEELWRIGHT; HUYNDMAN, 1998). Atualmente, a maioria dos pesquisadores concorda que tanto os métodos quantitativos quanto qualitativos têm pontos fortes e fracos (SANDERS; RITZMAN, 2004).

Devido à quantidade de fatores que influenciam no desempenho das empresas (e.g., curto ciclo de vida de produtos, elevada concorrência e agressivas ações de marketing), as previsões de demanda estão se tornando mais complexas (TRAPERO *et al.*, 2013). Prever a demanda utilizando apenas uma técnica pode não ser suficiente para obter um resultado satisfatório. O mercado competitivo exige previsões assertivas que utilizem mais de um método e incorporem a maior quantidade de informações relevantes (WERNER, 2004).

Elaborar previsões de demanda que contenham o menor erro possível é um desafio constante para as organizações (CHASE, 2013). Uma forma de aprimorar a acurácia e diminuir o efeito de variáveis externas é a integração de métodos qualitativos e quantitativos (BOPP, 1985). Webby e O'Connor (1996) propõem quatro formas de integração de previsão: (i) construção de modelos; (ii) decomposição baseada em opinião; (iii) ajuste baseado na opinião; e (iv) combinação de previsão.

Diversas pesquisas sugerem melhorias na acurácia utilizando previsões combinadas (LEMOS, 2006). Após um amplo estudo sobre combinação de previsões, Clemen (1989) afirma que métodos combinados apresentam melhores resultados do que qualquer método individual, independente da combinação utilizada. Armstrong (2006) apresenta uma revisão sobre as

técnicas mais utilizadas nos últimos anos para diminuição de erros de previsões e conclui que a combinação de previsão é a de maior potencial para melhora na acurácia.

A combinação ocorre quando diferentes fontes de previsão (e.g., métodos qualitativos e quantitativos) são integradas para construção de uma previsão final. Para tanto, deve-se, primeiramente, construir as previsões individuais. Assim que essas estiverem finalizadas, pode-se obter a previsão final (WEBBY; O'CONNOR, 1996). Esta combinação pode ser realizada subjetivamente, através do julgamento humano, ou quantitativamente, com o auxílio de modelos matemáticos.

1.2 Tema e Objetivos

O tema desta dissertação é a integração de métodos quantitativos e da opinião de especialistas através da combinação de previsão. Os objetivos desta pesquisa são: (i) efetuar uma revisão bibliográfica sobre técnicas de previsão de demanda e combinação de previsões, em trabalhos atuais e de relevância para o tema em estudo; e (ii) estruturar um método que combine matematicamente as previsões quantitativas e qualitativas, aplicável a múltiplos modelos de produto, em diferentes períodos de previsão e considerando a opinião de diferentes especialistas.

1.3 Justificativa do Tema e dos Objetivos

A justificativa para o tema proposto é a necessidade do aumento de acurácia das previsões. Erros de previsões podem ocasionar baixos níveis de serviços ou elevados níveis de estoque (FILDES; BEARD, 1992). Por outro lado, previsões mais acuradas podem trazer economias significativas para as empresas, resultando em maior retorno monetário, maior competitividade, melhor relacionamento com clientes e aumento de sua satisfação (MOON; MENTZER; SMITH, 2003).

Diversas pesquisas sugerem melhorias na acurácia utilizando previsões combinadas (LEMOS, 2006). Apesar da importância da opinião de especialistas para o processo de previsão, autores sugerem que trabalhos que estudam este tema ainda são escassos (TRAPERO *et al.*, 2013). Além disso, a literatura atual considera poucos produtos, horizontes curtos de previsão ou um número limitado de especialistas (FRANSES; LEGERSTEE, 2011). Considerando a vasta quantidade de produtos ofertados atualmente estudos mais aprofundados nesta área são necessários, para maior confiabilidade e generalização dos resultados.

Este trabalho traz uma contribuição importante para o estado da arte de estudo sobre combinação de previsões. Neste trabalho, propõem-se a utilização do AHP (*Analytic Hierarchy Process*), um método de decisão multicriterial, para definir a atribuição de pesos de importância a especialistas responsáveis por gerar previsões qualitativas.

1.4 Procedimentos Metodológicos

No presente trabalho, o método de pesquisa é classificado sob o ponto de vista de sua natureza, abordagem do problema, objetivos e procedimentos técnicos. Esta pesquisa é classificada como aplicada já que é direcionada para uma aplicação prática que busca solucionar um problema específico (BOAVENTURA, 2004). A forma de abordagem é qualitativa e quantitativa, pois visa quantificar os resultados obtidos e interpretar os cenários estudados considerando situações reais de trabalho. Quanto aos objetivos, trata-se de uma pesquisa explicativa, que pretende identificar as variáveis que contribuem para a ocorrência de eventos. Os procedimentos são caracterizados como experimentais, uma vez que determina-se um objeto de estudo e realizam-se intervenções para avaliar o seu resultado (GIL, 1991).

1.5 Estrutura da Dissertação

A dissertação está organizada em quatro capítulos. O primeiro capítulo introduz o trabalho, apresentando o tema, os objetivos, justificativas e os procedimentos metodológicos adotados. Também são apresentadas as delimitações do estudo e a estrutura do trabalho.

O segundo capítulo traz o primeiro artigo, que apresenta uma revisão da literatura sobre técnicas de previsão de demanda e combinação de previsões, em trabalhos atuais e de relevância para o tema em estudo. Além de apresentar conceitos teóricos sobre combinação de previsões, este capítulo exemplifica, através de aplicações práticas, como esta técnica está sendo utilizada pelas empresas.

O terceiro capítulo apresenta o segundo artigo, onde é proposto um método que combina matematicamente as previsões quantitativas e qualitativas, aplicável a múltiplos modelos de produto, em diferentes períodos de previsão e considerando a opinião de diferentes especialistas. O capítulo, além de descrever detalhadamente o método proposto, ilustra a aplicação do método através de um estudo de caso.

O quarto capítulo apresenta a conclusão do trabalho, onde os resultados obtidos são analisados em acordo com os objetivos desejados e as delimitações do estudo. Esse capítulo também apresenta sugestões para desenvolvimentos futuros.

1.6 Delimitações do Estudo

Este trabalho limita-se a desenvolver um modelo de previsão através da combinação de métodos qualitativos e quantitativos. O detalhamento das abordagens individuais (quantitativas e qualitativas) não são escopo desta pesquisa.

Cofatores externos, tais como preço de venda, promoções e fatores climáticos, não serão abordados neste estudo. Além disso, apenas um especialista de cada região geográfica será entrevistado no estudo de caso para fins de obtenção das previsões qualitativas. Da mesma forma, não será mensurado o impacto financeiro nem será realizada uma análise financeira do investimento necessário para a implantação das técnicas propostas.

1.7 Referências

ARMSTRONG, J. S. **Principles of Forecasting: A handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.

ARMSTRONG, J. S. Findings from evidence-based forecasting: Methods for reducing forecast error. **International Journal of Forecasting**, v. 22, 583-598, 2006.

BOAVENTURA E. M. **Metodologia de Pesquisa**. São Paulo: Editora Atlas, 2004.

BOPP, A. E. On Combining Forecasts: Some Extensions and Results. **Management Science**, v. 31, 1492-1498, 1985.

CHASE, C. W. **Demand-Driven Forecasting: A Structured Approach to Forecasting**. 2ª ed. Cary: Wiley, 2013.

CLEMEM, R. T. Combining forecasts: A review and annotated Bibliography. **International Journal of Forecasting**, v. 5, 559-583, 1989.

FILDES, R.; BEARD, C. Forecasting systems for production and inventory control. **International Journal of Production and Operations Management**, v. 12, 4-27, 1992.

FRANSES, P. H.; LEGERSTEE, R. Combining SKU-level sales forecasts from models and experts. **Expert Systems with Applications**, v. 28, 2365-2370, 2011.

GIL, A. C. **Como Elaborar Projetos de Pesquisa**. São Paulo: Editora Atlas, 1991.

KOTLER, P. **Marketing Management: Analysis, Planning, Implementation, and Control**. New Jersey: Prentice-Hall, 1991.

LEMOS, F. O. **Metodologia para Seleção de Método de Previsão de Demanda**. Porto Alegre: UFRGS, 2006. 183 f. Dissertação (Mestrado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia de Produção, Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

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

MONTGOMERY, D. C.; JOHNSON, L. A.; GARDINER, J. S. **Forecasting And Time Series Analysis**. New York: McGraw-Hill, 1990.

MOON, M. A.; MENTZER, J. T.; SMITH, C. D. Conducting a sales forecasting audit. **International Journal of Forecasting**, v. 19, 5–25, 2003.

SANDERS, N. R.; RITZMAN, L. P. Integrating judgmental and quantitative forecasts: methodologies for pooling marketing and operations information. **International Journal of Operations & Production Management**, v. 24, 514-529, 2004.

TRAPERO, J. R.; PEDREGAL, D. J.; FILDES, R.; KOURENTZES, N. Analysis of judgmental adjustments in the presence of promotions. **International Journal of Forecasting**, v. 29, 234–243, 2013.

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

WERNER, L. **Um Modelo Composto Para Realizar Previsão De Demanda Através Da Integração Da Combinação De Previsões e Do Ajuste Baseado Na Opinião**. Porto Alegre: UFRGS, 2004. 166 f. Tese (Doutorado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia de Produção, Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

2 PRIMEIRO ARTIGO: PREVISÃO DE DEMANDA COMBINADA A PARTIR DE MÉTODOS QUANTITATIVOS E OPINIÃO DE ESPECIALISTAS: ANÁLISE DE ESTUDOS EMPÍRICOS

Resumo

A previsão de demanda que combina métodos quantitativos e a opinião de especialistas é uma técnica amplamente utilizada na tentativa de aproximar a previsão da demanda real. A proposta deste trabalho é fazer uma revisão bibliográfica sobre combinação de previsões, em trabalhos atuais e de relevância para o tema em estudo. Este artigo, além de apresentar conceitos teóricos sobre combinação de previsões, exemplifica através de aplicações práticas como esta técnica é utilizada pelas empresas. O resultado indica que as previsões podem ser combinadas de diversas maneiras e que estudos atuais estão focando não só na melhoria da acurácia, como também na análise do perfil do especialista e em fatores internos e externos que afetam a demanda futura. Apesar de ser um tema vastamente investigado, várias oportunidades para pesquisas futuras foram identificadas a partir desta revisão.

Palavras-chave: previsão de demanda, combinação de previsões, opinião de especialistas

Abstract

Demand forecasting that combines quantitative methods and judgmental adjustments is a technique widely used in the attempt to approximate forecast to actual demand. The purpose of this paper is to present a literature review on combination of forecasts. We start by introducing theoretical concepts about combination of forecast, to then exemplify how this technique is being used by companies through practical applications. Results indicate that forecasts may be combined in different ways, and that current studies are focusing not only in improving accuracy, but also in analyzing the profile of experts producing judgments, as well as internal and external factors affecting future demand. Despite being vastly investigated in the literature, several opportunities for future research on the subject were identified from this review.

Keywords: demand forecasting, combination of forecast, expert opinion

2.1 Introdução

Previsões de demanda desempenham um papel fundamental para o futuro das organizações. Por apresentarem uma visão mais clara de futuro, previsões podem auxiliar na tomada de decisões, tanto em nível operacional como estratégico (ARMSTRONG, 2001). As previsões são utilizadas nos mais diversos setores e propiciam não só o gerenciamento da

produção e controle eficiente de recursos, como também a projeção de novos investimentos, elevados níveis de serviço e satisfação dos clientes (KOTLER, 1991).

Os diversos métodos de previsão de demanda podem ser classificados em duas categorias: qualitativos e quantitativos (MONTGOMERY; JOHNSON; GARDINER, 1990). Os métodos qualitativos consideram a opinião de especialistas para gerar previsões quando dados são inexistentes ou escassos, podendo ser utilizados isoladamente ou combinados com métodos quantitativos (MAKRIDAKIS; WHEELWRIGHT; HUYNDMAN, 1998; KRAJEWSKI; RITZMAN, 2002).

Através de dados históricos, os métodos quantitativos baseiam-se em modelos matemáticos para prever a demanda futura. Usualmente, a previsão quantitativa é construída através de pacotes computacionais que desenvolvem modelos matemáticos a partir do histórico de demanda. O grupo de dados que descrevem a variação da demanda ao longo do tempo é denominado série temporal (PELLEGRINI, 2000). Dependendo do modelo utilizado, o método quantitativo também pode incorporar variáveis causais à previsão.

Devido à quantidade de fatores que influenciam no desempenho das empresas (e.g., curto ciclo de vida de produtos, elevada concorrência e agressivas ações de marketing), as previsões de demanda estão se tornando mais complexas (TRAPERO *et al.*, 2013). Prever a demanda utilizando apenas uma técnica pode não ser suficiente para obter um resultado satisfatório. O mercado competitivo exige previsões assertivas que utilizem mais de um método e incorporem a maior quantidade de informações relevantes (WERNER, 2004).

Elaborar previsões de demanda que contenham o menor erro possível é um desafio constante para as organizações (CHASE, 2013). Uma forma de aprimorar a acurácia e diminuir o efeito de variáveis externas é a integração de métodos qualitativos e quantitativos (BOPP, 1985). Webby e O'Connor (1996) propõem quatro formas de integração de previsão: (i) construção de modelos; (ii) decomposição baseada em opinião; (iii) ajuste baseado na opinião; e (iv) combinação de previsão.

O tema deste artigo é a integração de métodos quantitativos e da opinião de especialistas através da combinação de previsão. Esta pesquisa tem como objetivo geral efetuar uma revisão bibliográfica sobre técnicas de previsão de demanda e combinação de previsões, em trabalhos atuais e de relevância para o tema em estudo.

A justificativa para o tema proposto é a necessidade do aumento de acurácia das previsões. Erros de previsões podem ocasionar baixos níveis de serviços ou elevados níveis de estoque (FILDES; BEARD, 1992). Por outro lado, previsões mais acuradas podem trazer economias significativas para as empresas, resultando em maior retorno monetário, maior competitividade, melhor relacionamento com clientes e aumento de sua satisfação (MOON; MENTZER; SMITH, 2003).

Diversas pesquisas sugerem melhorias na acurácia utilizando previsões combinadas (LEMONS, 2006). Após um amplo estudo sobre combinação de previsões, Clemen (1989) afirma que métodos combinados apresentam melhores resultados do que qualquer método individual, independente da combinação utilizada. Armstrong (2006) apresenta uma revisão sobre as técnicas mais utilizadas nos últimos anos para diminuição de erros de previsões e conclui que a combinação de previsão é a de maior potencial para melhora na acurácia. Apesar da importância da opinião de especialistas para o processo de previsão, autores sugerem que trabalhos que estudam este tema ainda são escassos (TRAPERO *et al.*, 2013).

Este artigo está estruturado em quatro seções. A primeira apresenta o tema abordado, bem como sua relevância para a área de estudo. Também são apresentados os objetivos a serem alcançados, a justificativa da pesquisa e a estrutura. A segunda seção apresenta a metodologia utilizada para alcançar os resultados esperados. A terceira seção traz os resultados da pesquisa. Além de apresentar uma revisão bibliográfica sobre combinação de previsões qualitativas e quantitativas, a seção exemplifica técnicas que utilizam a integração destes dois métodos. A última seção apresenta as conclusões do estudo e sugestões para trabalhos futuros.

2.2 Metodologia

A fim de se atingir o objetivo proposto por esta pesquisa, procurou-se, em periódicos selecionados, palavras e expressões relacionadas ao tema. As etapas que compõe a metodologia para obtenção das referências utilizadas nesta revisão foram as seguintes: (i) definição das bases de dados a serem utilizadas, (ii) escolha das palavras e expressões a serem pesquisadas, (iii) busca dos trabalhos nas referidas bases, (iv) exclusão de estudos duplicados e (v) análise dos artigos. Após a execução dessas etapas, artigos relevantes foram revisados e artigos não significativos foram excluídos. Por fim, alguns artigos que estavam referenciados nos trabalhos analisados e que eram pertinentes para este estudo foram adicionados à revisão.

As bases de dados utilizadas neste artigo foram identificadas considerando outras pesquisas dessa natureza (e.g., Fogliatto *et al.*, 2012). Para dar início à revisão sistemática da

literatura buscou-se, na base de dados de dissertações e teses da UFRGS e na SCIELO, por publicações nacionais com a palavra-chave “previsão de demanda”. Para obtenção das referências internacionais, selecionaram-se as bases que apresentavam periódicos recorrentes sobre combinação de métodos de previsão de demanda; são elas: *Scopus*, *ScienceDirect* e *Wiley Online Library*. A pesquisa limitou-se a publicações posteriores ao ano 2000. As palavras pesquisadas nesta busca (referências internacionais) e seus respectivos resultados estão apresentados na Tabela 2.1.

Tabela 2.1: Pesquisa nas bases de dados

Base	Palavras pesquisadas	Filtro	Áreas	Resultados
Scopus	<i>Forecasting OU Forecast, E</i>	Título	<i>Business, Management and Accounting; Decision Sciences; Economics, Econometrics and Finance; Engineering; Mathematics</i>	112
	<i>Combining OU Combination OU Integrate, E</i>	Título, resumo, palavras-chave		
	<i>Judgmental OU Judgment</i>	Todos		
	<i>E NÃO Election</i>	Todos		
Science Direct	<i>Forecasting OU Forecast, E</i>	Título	<i>Business, Management and Accounting; Decision Sciences; Economics, Econometrics and Finance; Engineering; Mathematics</i>	72
	<i>Combining OU Combination E</i>	Título, resumo, palavras-chave		
	<i>Judgment E NÃO Election</i>	Todos		
Wiley Online Library	<i>Forecasting OU Forecast, E</i>	Título	Todos	31
	<i>Combining OU Combination E</i>	Resumo		
	<i>Judgmental OU Judgment</i>	Todos		
	<i>E NÃO Election</i>			

A pesquisa inicial resultou em um total de 215 trabalhos internacionais e 23 trabalhos nacionais, sendo que 30 estavam duplicados. Após a remoção dos trabalhos duplicados, iniciou-se a análise dos artigos. Primeiro, verificou-se os títulos das publicações e somente aqueles que estavam aderentes ao objetivo deste estudo foram mantidos. Leu-se, então, o resumo dos 120 artigos restantes, resultando em 45 trabalhos para análise geral. Esta etapa consistiu na verificação dos objetivos, metodologia utilizada e resultados alcançados pelos autores analisados. Finalmente, vinte artigos foram considerados diretamente relacionados ao tema da presente pesquisa, além de 18 citações neles contidas que também foram adicionadas ao referencial teórico, totalizando 38 publicações.

Para facilitar a compreensão da metodologia utilizada nesta pesquisa, a Figura 2.1 traz um esquema das etapas e número de publicações anteriormente citados.

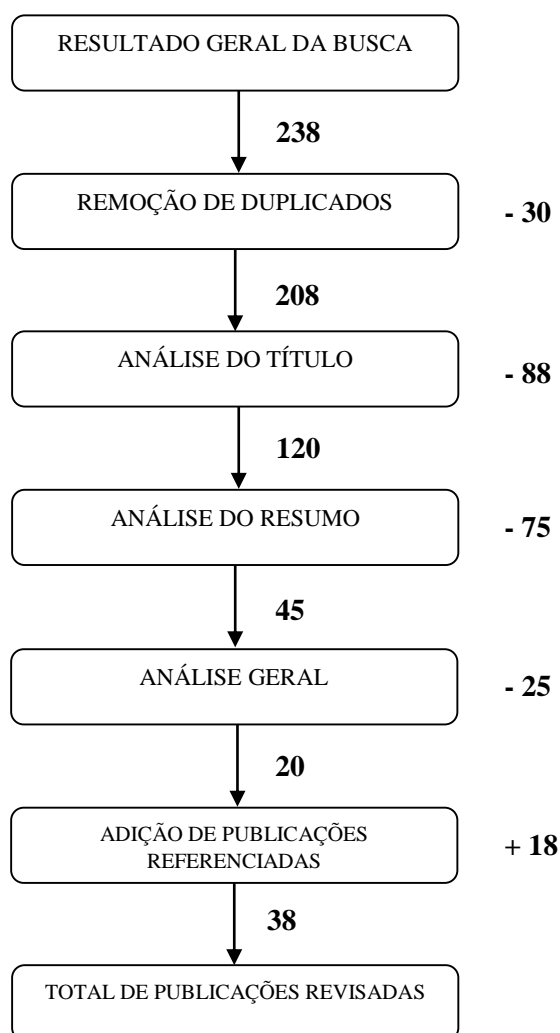


Figura 2.1: Esquema de pesquisa

Das 38 publicações incluídas na revisão, 31 (81%) eram provenientes de periódicos científicos, 3 (8%) eram trabalhos acadêmicos e 4 (11%) eram livros. Os periódicos com maior incidência de artigos foram: *International Journal of Forecasting* (7 artigos) e *Management Science* (4 artigos).

Nesta pesquisa os artigos foram divididos em 2 grupos, para a apresentação de seus conteúdos. O primeiro grupo reuniu trabalhos sobre previsão de demanda e combinação de previsões, abordando aspectos teóricos do assunto em estudo; o segundo grupo reuniu trabalhos reportando aplicações de combinação de previsões, exemplificando casos práticos onde os conceitos foram utilizados.

2.3 Previsão de demanda e combinação de previsões

Previsão de demanda é um elemento crucial para gestão estratégica e operacional. As previsões buscam antever os pedidos futuros para encontrar um equilíbrio entre oferta e demanda. A partir das previsões é possível gerenciar a produção, controlar os estoques e utilizar os recursos disponíveis de maneira mais eficiente. Desta forma, é possível diminuir os custos operacionais, mitigar riscos, garantir um adequado nível de serviço e a satisfação dos clientes (MAKRIDAKIS; WHEELWRIGHT; HUYNDMAN, 1998; KLASSEN; FLORES, 2001; NIKOLOPOULOS; ASSIMAKOPOULOS, 2003).

De maneira geral, os métodos de previsão de demanda dividem-se em quantitativos e qualitativos (MONTGOMERY; JOHNSON; GARDINER, 1990). Os métodos qualitativos são usualmente utilizados quando os dados de venda forem inexistentes ou escassos. Entre os métodos qualitativos destacam-se: (i) Delphi, (ii) Pesquisa de Intenção, (iii) Analogia e (iv) Opinião de Especialistas (MAKRIDAKIS; WHEELWRIGHT; HUYNDMAN, 1998; KRAJEWSKI; RITZMAN, 2002).

O Delphi é um método sistemático e iterativo. Nele, um grupo de especialistas rigorosamente selecionado responde anonimamente a uma sequência de questionários. A previsão é obtida após o consenso das opiniões (GUPTA; CLARKE, 1996). A Pesquisa de Intenção visa identificar as preferências dos consumidores e as perspectivas de demanda de determinado produto ou serviço (ARMSTRONG, 2001).

A previsão por Analogia procura comparar o produto de interesse com outro que apresente alguma característica semelhante (e.g., utilização, preço, tecnologia). A Opinião de Especialista baseia-se no julgamento humano e na intuição dos especialistas na área de negócio

para criar cenários futuros (MAKRIDAKIS; WHEELWRIGHT; HUYNDMAN, 1998; ARMSTRONG, 2001).

Durante muitos anos os métodos qualitativos foram o principal recurso para elaboração de previsões. Embora estes métodos possam ser tendenciosos e inconsistentes, pois dependem da honestidade, sensibilidade e bom julgamento dos entrevistados, eles predominaram devido à flexibilidade que oferecem ao usuário. A ausência de pacotes computacionais ou de pessoas capacitadas para elaboração de previsões estatísticas também justifica o predomínio de métodos qualitativos na prática. O avanço da tecnologia e o desenvolvimento da capacidade de processamento computacional e de armazenamento de dados proporcionou a utilização de métodos mais complexos de previsão (SANDERS; MANRODT, 1994, GOODWIN, 2002).

Enquanto que os métodos qualitativos baseiam-se no julgamento humano, os métodos quantitativos utilizam técnicas estatísticas e modelos matemáticos para prever a demanda futura. Usualmente, a previsão quantitativa é construída através de pacotes computacionais que ajustam modelos matemáticos a séries históricas de dados (PELLEGRINI, 2000). Apesar de não serem tão flexíveis para se adaptar a mudanças quanto os métodos qualitativos, os métodos quantitativos são consistentes e possibilitam trabalhar com um grande volume de dados (LEMOS, 2006).

Os métodos quantitativos são classificados em: (i) análise de séries temporais e (ii) métodos causais. A análise de séries temporais utiliza o histórico de demanda para elaboração da previsão, assumindo que os padrões de dados passados, como tendência e sazonalidade, irão se repetir no futuro. Exemplos de métodos baseados em análise de séries temporais são: (i) Média Móvel; (ii) Suavização Exponencial; (iii) Decomposição e (iv) *Box-Jenkins* (MAKRIDAKIS; WHEELWRIGHT; HUYNDMAN, 1998).

Os métodos causais buscam identificar variáveis internas ou externas à organização, que estejam relacionadas ao histórico de vendas. Através de análises estatísticas, o método visa encontrar relações de causa e efeito entre a variável dependente (demanda) e variáveis independentes (eventos internos e externos) (MENTZER; GOMES, 1989). Diversas variáveis podem ser analisadas, na hipótese que afetem a demanda; por exemplo, ações promocionais, preço de venda, ações de concorrentes, variação cambial e fatores climáticos, entre outras.

Atualmente, a maioria dos pesquisadores concorda que tanto os métodos quantitativos quanto qualitativos têm pontos fortes e fracos. Os métodos quantitativos têm a vantagem da objetividade, consistência, capacidade de processamento de grandes quantidades de dados e análise da correlação entre variáveis externas e internas. No entanto, não são flexíveis e

dependem da qualidade dos dados históricos utilizados para elaboração das previsões. Os métodos qualitativos permitem incorporar rapidamente mudanças de padrão de consumo ou novas estratégias na previsão, mas são altamente dependentes da sinceridade e bom julgamento dos especialistas (SANDERS; RITZMAN, 2004).

Um modelo de previsão ideal é aquele que incorpora as vantagens de cada método. Assim, a integração de métodos qualitativos e quantitativos surge como forma de melhorar a qualidade das previsões (SANDERS; RITZMAN, 2004). Webby e O'Connor (1996) propõem quatro formas de integração de previsão: (i) construção de modelos; (ii) decomposição baseada em opinião; (iii) ajuste baseado na opinião; e (iv) combinação de previsão.

A construção de modelos utiliza fatores contextuais para selecionar variáveis, especificar a estrutura do modelo e estabelecer os parâmetros. O ajuste baseado em opinião, por sua vez, elabora uma previsão baseada em dados históricos e depois ajusta-a com base no conhecimento dos especialistas, enquanto que a decomposição baseada em opinião visa incorporar experiências do passado e então recompor a série com informações orientadas para o futuro. A última forma mencionada pelos autores é a combinação de previsão, que integra modelos estatísticos com o julgamento humano, ponderando o histórico de demanda com a análise subjetiva de fatores contextuais (WEBBY; O'CONNOR, 1996; WERNER, 2004).

A combinação, segundo Goodwin (2002), é a forma mais discutida para integração de previsões. Clemen (1989) afirma que, independente da metodologia utilizada, as previsões realizadas através da combinação apresentam diminuição de variabilidade e melhoria na acurácia se comparadas a qualquer técnica individual. Batchelor e Dua (1995) constataram que o resultado das combinações pode ser ainda melhor quando aumenta-se o número de métodos combinados ou quando estes diferem entre si.

Com o objetivo de analisar as técnicas mais utilizadas nos últimos anos para diminuição de erros de previsões, Armstrong (2006), com o auxílio de 22 pesquisadores, apresentou uma ampla revisão bibliográfica. Após apontar 25 métodos de previsão, o autor enfatiza que, entre todos os métodos analisados, a combinação de previsão é a de maior potencial para melhora na acurácia das previsões.

A combinação ocorre quando diferentes fontes de previsão (e.g., métodos qualitativos e quantitativos) são integradas para construção de uma previsão final. A Figura 2.2 mostra um esquema de combinação entre métodos quantitativos e qualitativos.




Figura 2.2: Combinação de métodos quantitativos e qualitativos (Adaptado de WEBBY; O'CONNOR, 1996, LEMOS; 2006)

Para construção da previsão final deve-se, primeiramente, construir as previsões individuais. Assim que essas estiverem finalizadas, pode-se obter a previsão final (WEBBY; O'CONNOR, 1996). Esta previsão final combinada pode ser obtida subjetivamente, através do julgamento humano, ou quantitativamente, com o auxílio de modelos matemáticos.

Quando a combinação é subjetiva, os pesos de importância das previsões quantitativas e qualitativas são determinados pelos especialistas. Muitas vezes, o critério adotado para seleção dos pesos não é claro, tornando a técnica vulnerável a tendências. Previsões quantitativas podem também receber menos ênfase ou serem ignoradas na previsão final (GOODWIN; 2000, LEMOS; 2006, FRANSES; LEGERSTEE, 2011). Além disso, obter a opinião destes especialistas pode ser um processo oneroso e exigir a utilização de muitos recursos das organizações (FILDES *et al.*, 2009).

Diferente da combinação subjetiva, na qual os pesos de importância são definidos de maneira empírica, a combinação quantitativa é calculada através de modelos matemáticos que determinam o peso de importância para cada fonte de previsão. Estudos realizados sobre este tema indicam que os resultados obtidos por este tipo de combinação são superiores à combinação subjetiva (LAWRENCE; EDMUNDSON; O'CONNOR, 1986).

Durante muitos anos, o principal objetivo dos estudos sobre combinação era desenvolver métodos de combinação que melhorassem a acurácia das previsões. Nos últimos anos, a ênfase está na seleção do método de previsão e na maneira que estes serão combinados. A partir de então, um grande desafio da área está na definição dos pesos de importância de cada método de previsão a ser combinado (MACKAY; METCALFE, 2002; ZOU; YANG, 2004; WERNER, 2004).

2.3.1 Aplicações práticas de combinação de previsões

As aplicações de combinação de previsões apresentadas nesta seção abordaram três pontos centrais: (i) métodos para combinação de previsões; (ii) determinação de fatores que afetam a demanda futura; e (iii) caracterização do perfil dos especialistas.

As previsões quantitativas e qualitativas podem ser combinadas de diversas formas. A forma mais elementar de combinação quantitativa é o cálculo da média aritmética (ASHTON; ASHTON, 1985). Quando não se têm conhecimento suficiente sobre a série temporal ou quando esta é instável, recomenda-se utilizar a média aritmética para combinação (FLORES; WHITE; 1988; MAKRIDAKIS; WHEELWRIGHT; HUYNDMAN, 1998). O cálculo de média simples garante que o resultado da combinação seja melhor do que a previsão com o maior erro (THOMAS, 1996).

Conforme os estudos realizados por Ashton e Ashton (1985), a média aritmética não só permite realizar o cálculo dos pesos de maneira simplificada, como também oferece ganhos similares aos obtidos através de combinações mais complexas. A heurística proposta por Blattberg e Hoch (1990), conhecida como “50% model, 50% manager” (50% modelo, 50% gerente; também denominada critério de Blattberg e Hoch), pondera com pesos iguais os métodos quantitativos e a opinião gerencial. Os resultados desta combinação foram superiores a qualquer previsão gerada de forma isolada.

Os pioneiros no estudo de diferentes ponderações entre as previsões a serem combinadas foram Bates e Granger (1969). Nesta proposta, os pesos utilizados nas combinações totalizavam 1, onde à primeira previsão combinada atribuíam-se peso w e à segunda, peso $(1-w)$. No caso de pesos iguais, a combinação resultaria idêntica ao critério de Blattberg e Hoch (1990). Entretanto, para Bates e Granger (1969), o ideal seria dar maior peso à previsão que contém os menores erros. Essa proposta é conhecida como método da variância mínima, pois busca identificar os pesos de cada método a ser combinado através da minimização da variância dos erros da previsão final. Desta forma, o peso w será definido segundo a equação (1).

$$w = \frac{\sigma_2^2 - \rho \sigma_1 \sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho \sigma_1 \sigma_2} \quad (1)$$

onde w é o peso da primeira previsão a ser combinada, σ_1^2 e σ_2^2 são as variâncias dos erros das previsões a serem combinadas, e ρ é o coeficiente de correlação entre os erros das previsões.

Newbold e Granger (1974) aprimoraram o modelo criado por Bates e Granger (1969) aumentando o número de métodos a serem combinados de 2 para p . Para verificar a eficiência do novo modelo, os autores examinaram séries temporais através de três métodos de extrapolação: *Holt-Winters*, *Box-Jenkins* e auto-regressão *stepwise*. A conclusão foi que a previsão combinada de três métodos resulta, na maioria das vezes, em erros menores de previsão em relação aos métodos quantitativos isolados.

Estimar o peso a ser atribuído a diferentes métodos utilizados na previsão combinada também foi objeto da investigação em Winkler e Makridakis (1983). Os autores demonstraram empiricamente que as previsões combinadas apresentam uma melhora na acurácia em relação a previsões individuais. Foram combinados dez métodos de previsão aplicados a 1001 séries temporais. Para identificar os pesos que minimizassem as variâncias dos erros, os autores seguiram o método desenvolvido por Newbold e Granger (1974). Desta forma, a previsão combinada é representada pela equação (2).

$$\hat{Y}_t = \sum_{i=1}^p w_i \hat{Y}_t^{(i)} \quad (2)$$

onde $\hat{Y}_t^{(i)}$ é a previsão para o período t considerando o método i , w_i é o peso atribuído à previsão obtida através do método i , e p é o número de métodos considerados na combinação.

Nesta proposta, Winkler e Makridakis (1983) variaram o horizonte de previsão avaliado de 1 a 18 meses. A média dos erros percentuais absolutos (MAPE - *Mean Absolute Percentual Error*), que foi calculada tanto para as previsões individuais quanto para os métodos combinados, foi utilizada como única medida de acurácia para estimar a melhor estratégia para obter as previsões. Ao final do estudo ficou evidente que a combinação de previsões resultava em erros menores, se comparados àqueles obtidos a partir do uso de métodos individuais. Os resultados eram válidos para horizontes curtos de previsão e para a maioria dos horizontes longos de previsão.

A pesquisa realizada por Werner e Ribeiro (2006) também buscou combinar diferentes métodos de previsão através da minimização das variâncias dos erros de previsão. O estudo foi realizado utilizando dados de uma empresa de pequeno porte, da área de manutenção de equipamentos de informática, que apresentava alta variabilidade na demanda. A modelagem incluiu dados históricos de demanda, dados econômicos e a opinião de especialistas.

Primeiramente, os autores obtiveram as previsões individuais. Os modelos de *Box-Jenkins* foram utilizados para elaboração da previsão quantitativa, enquanto que a modelagem econométrica foi operacionalizada através de uma análise de regressão. As variáveis correlacionadas com a demanda (número de atendimentos) utilizadas na regressão foram as seguintes: (i) valor médio do dólar, (ii) variação acumulada do PIB industrial, e (iii) preço deflacionado pelo IPC-IEPE.

O último método a ser combinado foi a previsão de demanda através do julgamento humano. Especialistas previamente selecionados participaram de entrevistas individuais para prever a demanda do próximo período. Os fatores citados pelos especialistas que mais influenciam na demanda foram os seguintes: (i) avanço da tecnologia; (ii) condições facilitadas de pagamento; (iii) estabilidade econômica; (iv) inflação; (v) lançamento de um novo produto; (vi) promoção de vendas; (vii) variação cambial; e (viii) período de férias. Para facilitar a análise por julgamento, os especialistas receberam os dados históricos de atendimentos da empresa. A previsão baseada na opinião de especialistas foi obtida através do cálculo da média aritmética das opiniões dos três especialistas entrevistados.

De posse das previsões individuais e da demanda real observada no horizonte de previsão, foi possível estimar a variância dos erros de previsão através do erro quadrático médio (MSE – *Mean Square Error*). Como os autores assumiram que os erros não estavam correlacionados ($\rho=0$), o peso de cada método foi definido conforme a equação (3).

$$w_i = \frac{\frac{1}{\sigma_i^2}}{\frac{1}{\sigma_{est}^2} + \frac{1}{\sigma_{eco}^2} + \frac{1}{\sigma_{esp}^2}} \quad (3)$$

onde σ_i^2 é a variância dos erros das previsões obtidas usando o método $i = \{est, eco, esp\}$, σ_{est}^2 é a variância dos erros das previsões estatísticas, σ_{eco}^2 é a variância dos erros das previsões econométricas, e σ_{esp}^2 é a variância dos erros das previsões baseadas na opinião de especialistas.

Ao final do estudo, os autores realizaram um novo ajuste, com auxílio da opinião dos especialistas, sobre a previsão combinada. Todas as previsões geradas foram comparadas através do erro médio (ME – *Mean Error*), MSE e MAPE. Para todas as medidas de acurácia testadas, a previsão combinada e posteriormente ajustada pelos especialistas apresentou os menores erros.

Para investigar se ajustes gerenciais aumentam a acurácia das previsões e quais estratégias estão sendo utilizadas pelas organizações, alguns autores analisam os históricos de vendas e previsões de empresas em diferentes ramos de atuação. Uma abordagem frequentemente adotada por empresas consiste em definir as previsões de vendas através da combinação subjetiva em reuniões gerenciais. Neste caso, as empresas analisadas elaboram, com o auxílio de *softwares* estatísticos, a previsão quantitativa de vendas. Em seguida, analistas conduzem as reuniões gerenciais envolvendo marketing, produção e vendas, com objetivo de incorporar informações que as organizações julgam serem relevantes mas que não são contempladas pelos modelos estatísticos.

As previsões estatísticas (quantitativas) são ajustadas de forma subjetiva pelos participantes para elaboração da previsão dos especialistas. A previsão dos especialistas normalmente é classificada pelos autores em ajustes positivos e negativos. Os ajustes positivos (negativos) foram aqueles onde a previsão dos especialistas oriunda da reunião elevou (rebaixou) o valor proposto pelo sistema.

Fildes *et al.* (2009) analisaram quatro empresas que elaboram previsões de vendas a partir de reuniões gerenciais: três empresas de manufatura, que realizam previsões mensais, e um varejista, que realiza previsões semanais. Para as empresas de manufatura, todos os artigos comercializados foram analisados; para o varejista, dois grupos de produtos foram analisados. No total, foram investigados mais de 60.000 dados. Os autores então propuseram duas formas para combinação destas previsões; foram elas: (i) critério de *Blattberg-Hoch*; e (ii) modelo completo.

O critério de *Blattberg-Hoch* foi apresentado anteriormente nesta seção. O modelo completo consistiu em calcular a previsão $\hat{Y}_{ij,t}$ para o produto i da empresa j no período t , segundo a equação (4).

$$\hat{Y}_{ij,t} = \lambda_{1j}SF_{ij,t-1}(1) + \lambda_{2j}Adj_{ij,t-1} + \beta_{1j}\hat{Y}_{ij,t-1} + \gamma_{1j}e_{ij,t-1} + v_{ij,t} \quad (4)$$

onde $SF_{ij,t-1}(1)$ é a previsão quantitativa um período à frente realizada no período $t-1$; $Adj_{ij,t-1}$ é a magnitude do ajuste executado pelo especialista no período $t-1$; $\hat{Y}_{ij,t-1}$ é a previsão quantitativa um período à frente realizada no período $t-2$; $e_{ij,t-1}$ é o erro da previsão realizada no último período; $v_{ij,t}$ é um termo de erro aleatório; e λ , β e γ são parâmetros do modelo.

Para determinação dos parâmetros da eq. (4), a base de dados foi dividida em uma porção de treino, contendo 80% dos dados, e uma porção de teste. Os parâmetros foram

calculados a partir da proposta do autor para minimização dos erros de previsão, conforme equação (5).

$$e_{ij,t} = (1 + \lambda_{1j})SF_{ij,t-1}(1) + (1 + \lambda_{2j})Adj_{ij,t-1} + \beta_{1j}\hat{Y}_{ij,t-1} + \gamma_{1j}e_{ij,t-1} + v_{ij,t} \quad (5)$$

Através do cálculo do MAPE e da mediana dos erros percentuais absolutos (MdAPE - *Median Absolute Percentual Error*), os autores concluíram que os modelos de combinação propostos melhoraram a acurácia das previsões. O melhor modelo para cada empresa dependerá das características de cada organização e do tipo de ajuste. Combinações baseadas no critério de *Blattberg-Hoch*, por exemplo, só devem ser aplicadas no caso de ajustes positivos. Entre as variações analisadas, as negativas apresentaram menores erros para todas as empresas participantes da pesquisa.

O estudo também relevou que os principais indicadores utilizados pelos especialistas destas empresas foram os seguintes: (i) reposicionamento de preço; (ii) condições climáticas, (iii) estoques; e (iv) ações promocionais. Entre eles, as ações promocionais foi o indicador que mais afetou as previsões.

Outra pesquisa realizada em uma empresa que elabora as previsões de vendas em reuniões gerenciais foi efetuada por Trapero et al. (2013). Os pesquisadores analisaram a acurácia de previsões ajustadas pela opinião de especialistas em uma empresa de manufatura.

A primeira análise realizada pelos autores foi o cálculo do MAPE e do MdAPE. Os resultados mostraram que, para as duas medidas de acurácia utilizadas, as previsões quantitativas apresentaram menores erros tanto na presença, quanto na ausência de promoções. Os autores decidiram então investigar a razão pela qual os ajustes não estavam beneficiando as previsões. A conclusão foi que os ajustes subjetivos eram tendenciosos e otimistas; assim, a previsão dos especialistas era muito superior à demanda real. Por outro lado, as previsões quantitativas, por levarem em consideração apenas dados passados, também apresentaram erros significativos.

Outra análise realizada pelos autores foi o cálculo do MAE de acordo com o tipo de ajuste (positivo ou negativo). Para melhorar a visualização dos resultados, os dados calculados foram plotados em gráficos. A Figura 2.3 apresenta a comparação entre os erros gerados pela previsão quantitativa e pela previsão dos especialistas em relação aos desvios-padrão (σ) normalizados do ajuste.

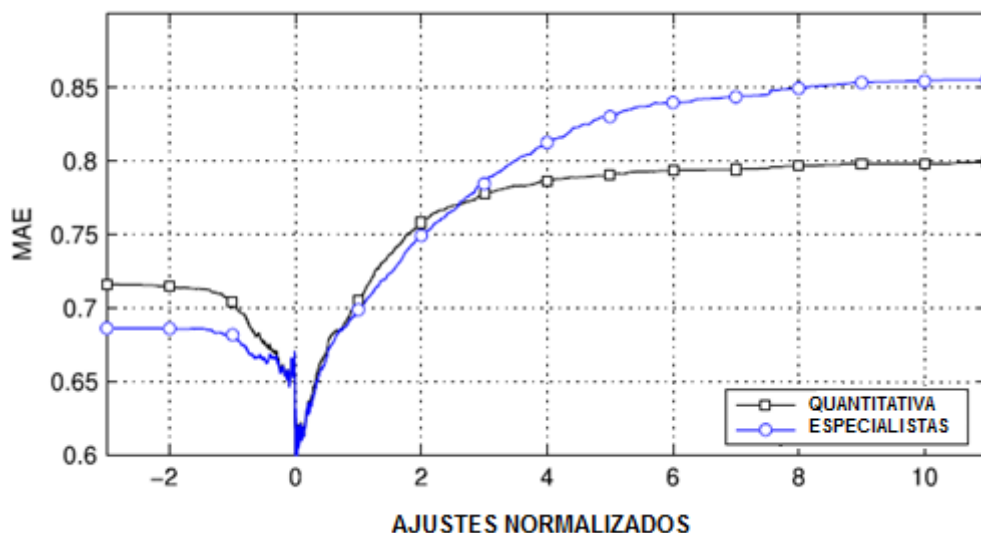


Figura 2.3: MAE versus ajustes normalizados (Adaptado de TRAPERO *et al.*, 2013)

O gráfico mostra que a previsão dos especialistas apresentou melhores resultados quando pequenos ajustes positivos eram realizados (ajustes normalizados até +2,5 desvios-padrão) e para todos os ajustes negativos. No entanto, para ajustes positivos de maior magnitude verificou-se maiores erros na previsão dos especialistas em relação à previsão quantitativa.

Os autores elaboraram então um modelo estatístico multivariado (TF), eliminando o julgamento humano e incorporando matematicamente a presença ou ausência de promoções ao modelo. Para finalizar o estudo, os autores construíram um modelo híbrido, combinando o modelo TF com a previsão dos especialistas (EF), conforme equação (6).

$$\hat{Y}_t = \alpha_0 + (\alpha_1 TF_t + \alpha_2 EF_t) + (\alpha_3 TF_t + \alpha_4 EF_t)X_1 + \epsilon_t \quad (6)$$

onde α_0 é uma constante, α_n é o peso da previsão n , X_1 é uma variável *dummy* que indica a presença ou ausência de promoções, e ϵ_t é um termo de erro.

A variável *dummy* X_1 será incorporada ou não à equação de acordo com o tamanho do ajuste normalizado realizado pelo especialista, conforme a condição a seguir:

$$X_1 = \begin{cases} 0, & \text{se } 0 \leq \text{ajuste} \leq 2,5 \sigma \\ 1, & \text{caso contrário} \end{cases}$$

Os resultados foram comparados utilizando MAE, MdAPE e a mediana dos erros percentuais (MdPE – *Median Percentual Error*). As conclusões mostraram que o modelo

híbrido, que incorporou as promoções nos modelos estatísticos e o ajuste subjetivo, apresentou os melhores resultados entre todos os modelos testados no estudo.

De acordo com Ali *et al.* (2009), ações promocionais realizadas no varejo e curtos ciclos de vida dos produtos nele comercializados dificultam a realização de previsões, exigindo modelos mais elaborados. Os autores analisaram diversos itens comercializados em supermercados na Europa. Em períodos onde a venda dos itens ocorria sem a realização de promoções, previsões elaboradas através de técnicas de suavização exponencial apresentavam resultados satisfatórios. Para melhorar a acurácia das previsões em períodos nos quais promoções eram realizadas, os autores utilizaram cálculos baseados em árvore de regressão.

Árvore de regressão consiste em dividir os dados em pequenos subconjuntos num formato de árvore de decisão. Cada folha da árvore de decisão indica o modelo de regressão a ser utilizado para elaboração da previsão de demanda (THOMASSEY; FIORDALISO, 2006; ALI *et al.*, 2009).

As previsões empregadas eram quantitativas e o julgamento humano foi adotado apenas para seleção da base de dados de vendas em períodos nos quais promoções foram realizadas. Utilizando o cálculo do erro absoluto médio (MAE – *Mean Absolute Error*) como medida de acurácia, as previsões combinadas apresentaram melhoras de 30% para as previsões globais e de 65% para períodos com promoções, em comparação as previsões baseadas somente em suavização exponencial.

Com o objetivo de analisar não só o desempenho de previsões combinadas, mas também caracterizar o perfil dos especialistas, Franses publicou três estudos utilizando uma mesma base de dados. A base é proveniente de uma empresa fabricante de produtos farmacêuticos com matriz na Holanda, que gera previsões quantitativas com auxílio de pacotes computacionais. Os 50 especialistas, localizados em 37 países, recebem os modelos estatísticos (previsões quantitativas) e elaboram as suas previsões.

No primeiro estudo, Franses e Legerstee (2009) testaram quatro hipóteses: (i) as previsões quantitativas tendem a ser frequentemente ajustadas através do julgamento humano; (ii) os especialistas tendem a realizar mais ajustes positivos do que negativos; (iii) os ajustes estão relacionados com os ajustes feitos passados e com os erros recentes observados nas previsões quantitativas; (iv) o tamanho do ajuste está correlacionado com a própria previsão quantitativa.

Os resultados demonstraram que aproximadamente 90% das previsões quantitativas eram ajustadas pelos especialistas [validando a hipótese (i)]. Observou-se uma leve tendência (54%) de ajuste positivo nas previsões [validando a hipótese (ii)]. Com relação à hipótese (iii), verificou-se que o tamanho do ajuste é fortemente dependente dos ajustes feitos anteriormente; esta dependência é até três vezes maior do que a relação de dependência com o erro das previsões quantitativas [hipótese (iv)].

Considerando que a maioria dos especialistas não utiliza os modelos estatísticos exclusivamente, Franses (2013) desenvolveu uma demonstração matemática simplificada da previsão combinada, na qual a magnitude do ajuste foi somada à previsão quantitativa, multiplicada pelo seu peso de importância.

Em outro estudo, Franses e Legerstee (2011) denominaram as previsões quantitativas de $SF_{i,j,t+h|t}$, onde t é o período de análise; $t+h$ é o horizonte de previsão (variando de 1 a 12 meses); i o país onde a venda é realizada (variando de 1 a 37, sendo que cada país possuía ao menos um especialista); e j é o produto analisado, sendo que o número de produtos analisado por país variava 10 a 85. As previsões dos especialistas foram denominadas $EF_{i,j,t+h|t}$. A previsão final foi obtida pela combinação das previsões quantitativas e qualitativas conforme equação (7).

$$\hat{Y}_{ij,t} = \alpha_i MF_{i,j,t+h|t} + (1 - \alpha_i) EF_{i,j,t+h|t} \quad (7)$$

onde α_i é o peso atribuído à previsão oriunda do modelo estatístico i . O valor de α_i foi calculado a partir da minimização da raiz do erro quadrático médio de previsão (RMSPE – *Root Mean Squared Prediction Error*).

Franses e Legerstee (2011) mencionaram que não há como afirmar quais fatores eram considerados pelos especialistas na elaboração de suas previsões, nem se eles baseavam tais previsões nos modelos estatísticos. Em um estudo posterior (Franses, 2013), os especialistas responderam a questionários sobre a utilização dos modelos estatísticos. O resultado da pesquisa mostrou que menos de 50% dos entrevistados asseguraram que as previsões quantitativas recebidas serviam de referência para suas projeções. Além disso, os entrevistados demonstraram interesse em compreender como dados passados são utilizados pelos *softwares* para prever a demanda futura.

As combinações dos 37 países e de 12 meses foram analisadas, totalizando 444 combinações. Os pesos ótimos ajustados evidenciaram que em apenas 4,73% dos casos utilizou-se somente a previsão do especialista, ao passo que em 5,86% dos casos foram utilizadas exclusivamente as previsões quantitativas; ou seja, em 89,41% dos casos a previsão combinada apresentou menores erros de previsão. A média dos pesos α_i ajustados a cada período variou entre 0,49 e 0,55, evidenciando que a utilização do critério de Blattberg e Hoch (1990) pode, de fato, ser uma boa escolha. Entretanto, devido à grande variação entre as opiniões dos especialistas, os autores decidiram investigar o perfil de cada indivíduo, levando em consideração a idade, gênero e tempo exercendo a função. Ao final do estudo concluíram que os resultados estavam diretamente relacionados com a idade dos entrevistados.

Outro estudo que mostrou a relevância da idade nas previsões dos especialistas foi o de Lamont (2002). O autor analisou previsões quantitativas macroeconômicas e o perfil de diversos especialistas em economia e concluiu que a experiência influencia nas previsões. No entanto, os especialistas mais experientes eram mais ousados e, assim, suas previsões apresentaram maiores erros. Desta forma, as melhores previsões eram realizadas pelos especialistas com média experiência.

O perfil dos especialistas também foi o objetivo da pesquisa de Barber e Oden (2001). O estudo analisou o perfil de investidores em ações e levou em consideração as características demográficas: (i) gênero; (ii) idade; (iii) estado civil; (iv) quantidade de filhos; e (v) renda. O estudo sugere que o gênero do investidor influencia na elaboração de projeções e que homens tendem a ter excesso de confiança, o que pode levar a previsões superestimadas.

2.4 Conclusões e sugestões para trabalhos futuros

A combinação de métodos quantitativos com o julgamento humano é uma técnica amplamente utilizada para aproximar a previsão da demanda real. Conforme visto neste trabalho, a opinião de especialista pode ser agregada de diversos meios, seja através de formas elementares como a média simples, ou com o auxílio de métodos complexos. Normalmente, previsões combinadas apresentam melhorias significativas na acurácia, se comparadas a previsões individuais.

A melhoria da acurácia através das previsões combinadas é tema de diversos estudos, sendo de interesse tanto para a academia quanto para as empresas. Embora a literatura apresente várias aplicações nesta área, a maioria das pesquisas até agora considera poucos produtos, horizontes curtos de previsão ou um número limitado de especialistas (FRANSES;

LEGERSTEE, 2011). Muitas vezes não são generalizáveis, sendo válidos somente para a amostra analisada. Considerando a vasta quantidade de produtos ofertados atualmente é indiscutível a necessidade de estudos mais aprofundados nesta área, para maior confiabilidade e generalização dos resultados.

Mostrou-se neste trabalho que poucos especialistas utilizam os modelos estatísticos para elaboração de suas previsões. Muitas vezes eles não compreendem as informações quantitativas e, por isso, acabam descartando-as (FRANSES, 2013). Acredita-se, porém, que o ideal seria explicar aos especialistas a relevância dos dados passados para prever a demanda futura e a eficiência dos modelos computacionais.

A qualidade das previsões dos especialistas é igualmente questionável. Frequentemente, eles apontam suas projeções em reuniões onde podem se sentir pressionados pelos outros participantes, realizando previsões que não condizem com sua real crença. Este trabalho também apresentou pesquisas onde o perfil dos especialistas foi analisado (BARBER; ODEN, 2001; LAMONT, 2002; FRANSES, 2013). Os resultados mostraram que algumas características são relevantes para elaboração das previsões como, por exemplo, a idade (experiência). Outros estudos poderiam ser realizados neste sentido para entender o comportamento dos entrevistados ou, até mesmo, melhorar a seleção dos especialistas.

Além do perfil dos especialistas, alguns fatores externos e internos à organização influenciam na demanda. Este trabalho mostrou que autores (WERNER; RIBEIRO, 2006; FILDES *et al.*, 2009) costumam indicar quais os elementos são analisados pelos especialistas, entre eles: reposicionamento de preço, condições climáticas, estoques e ações promocionais. Alguns autores (ALI *et al.*, 2009; TRAPERO *et al.*, 2013) deram ênfase às ações promocionais para elaboração de seus modelos de previsão.

Através dos exemplos apresentados neste trabalho, ficou evidente que uma abordagem comum para elaboração de previsão de demanda dentro das organizações estudadas envolve a utilização de um sistema informatizado para produzir previsões iniciais e o posterior ajuste baseado no julgamento humano (FILDES *et al.*, 2009; FRANSES; LEGERSTEE, 2009; TRAPERO *et al.*, 2013). Entre as áreas mais envolvidas na tomada de decisão destacam-se marketing, produção e vendas (FILDES *et al.*, 2009; TRAPERO *et al.*, 2013).

Conclui-se também que os *softwares* próprios para previsões de demanda são amplamente utilizados pelas empresas e possibilitam a seleção dos parâmetros desejados. Entretanto, devido aos grandes benefícios dos modelos combinados, é fundamental que o

desenvolvimento destes *softwares* incorpore o julgamento humano diretamente nos modelos computacionais. Fildes, Goodwin e Lawrence (2006) mencionam a necessidade deste aperfeiçoamento, já que os pacotes computacionais ainda não possuem esta função.

É importante ressaltar que todas as previsões envolvem o ajuste de especialistas. Mesmo as previsões consideradas puramente quantitativas necessitam da opinião subjetiva. A escolha dos modelos estatísticos, a coleta dos dados passados e apuração do histórico a ser utilizado são atividades geralmente realizadas pelos planejadores de demanda das empresas. Estes profissionais são responsáveis também pelo descarte de dados discrepantes e pela seleção dos dados, externos ou internos a organização, relacionados com a demanda futura. Como tais ajustes são altamente dependentes dos planejadores, seria também interessante agregar estas informações de maneira automática e padronizada a fim de evitar a subjetividade.

2.5 Referências

ALI O. G.; SAYIN, S.; WOENSEL, T. V.; FRANSOO, J. SKU demand forecasting in the presence of promotions. **Expert Systems with Applications**, v. 36, 12340–12348, 2009.

ARMSTRONG, J. S. **Principles of Forecasting: A handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.

ARMSTRONG, J. S. Findings from evidence-based forecasting: Methods for reducing forecast error. **International Journal of Forecasting**, v. 22, 583-598, 2006.

ASHTON, A. H.; ASHTON, R. H. Aggregating Subjective Forecasts: Some Empirical Results. **Management Science**, v. 31, 1499-1508, 1985.

BARBER, B. M.; ODEAN T. Boys will be boys: Gender, overconfidence, and common stock investment. **The Quarterly Journal of Economics**, v. 116, 261-292, 2001.

BATCHELOR, R. DUA, P. Forecaster Diversity and the Benefits of Combining Forecast. **Management Science**, v. 41, 68-75, 1995

BATES, J. M.; GRANGER, C. W. J. The Combination of Forecast. **Operational Research Quarterly**, v. 20, 451-468, 1969.

BLATTBERG, R. C.; HOCH, S. J. Database models and managerial intuition: 50% model + 50% manager. **Management Science**, v. 36, 887–899, 1990.

BOPP, A. E. On Combining Forecasts: Some Extensions and Results. **Management Science**, v. 31, 1492-1498, 1985.

CHASE, C. W. **Demand-Driven Forecasting: A Structured Approach to Forecasting**. 2^a ed. Cary: Wiley, 2013.

CLEMEM, R. T. Combining forecasts: A review and annotated Bibliography. **International Journal of Forecasting**, v. 5, 559-583, 1989.

FILDES, R.; BEARD, C. Forecasting systems for production and inventory control. **International Journal of Production and Operations Management**, v. 12, 4–27, 1992.

FILDES, R.; GOODWIN, P.; LAWRENCE, M. The design features of forecasting support systems and their effectiveness. **Decision Support Systems**, v. 42, 351–361, 2006.

FILDES, R.; GOODWIN, P.; LAWRENCE, M.; NIKOLOPOULOS, K. Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning. **International Journal of Forecasting**, v. 25, 3–23, 2009.

FLORES, B. E.; WHITE, E. M. A. Framework for the Combination of Forecasts. **Journal of the Academy of Marketing Science**, v. 16, 95-103, 1988.

FOGLIATTO, F. S.; DA SILVEIRA, G. J.C.; BORENSTEIN, Denis. The mass customization decade: An updated review of the literature. **International Journal of Production Economics**, v. 138, 14-25, 2012.

FRANSES, P. H.; LEGERSTEE, R. Properties of expert adjustments on model-based SKU-level forecasts. **International Journal of Forecasting**, v. 25, 35–47, 2009.

FRANSES, P. H.; LEGERSTEE, R. Combining SKU-level sales forecasts from models and experts. **Expert Systems with Applications**, v. 28, 2365-2370, 2011.

FRANSES, P. H. Improving judgmental adjustment of model-based forecasts. **Mathematics and Computers in Simulation**, v. 93, 1–8, 2013.

GOODWIN, P. Improving the voluntary integration of statistical forecasts and judgement. **International Journal of Forecasting**, v. 16, 85–99, 2000.

GOODWIN, P. Integrating management judgement with statistical methods to improve short-term forecasts. **Omega**, v. 30, 127–135, 2002.

GUPTA, U.; CLARKE, R.E. Theory and applications of the Delphi technique: A bibliography (1975-1994). **Technological Forecasting and Social Change**, v. 53, 185-211, 1996.

KLASSEN, R.; FLORES, B. E. Forecasting practices of Canadian firms: survey results and comparisons. **International Journal of Production Economics**, v.70, 163-174, 2001.

KOTLER, P. **Marketing Management: Analysis, Planning, Implementation, and Control**. New Jersey: Prentice-Hall, 1991.

KRAJEWSKI, L. J.; RITZMAN, L. P. **Operations management: Strategy and Analysis**. 6^a ed. New Jersey: Prentice Hall, 2002.

LAMONT, O. A. Macroeconomic forecasts and microeconomic forecasters. **Journal of Economic Behavior & Organization**, v. 48, 265–280, 2002

LAWRENCE, M. J.; EDMUNDSON, R. H.; O'CONNOR, M. J. The Accuracy of Combining Judgemental and Statistical Forecasts. **Management Science**, v. 32,1521-1532, 1986.

LEMONS, F. O. **Metodologia para Seleção de Método de Previsão de Demanda**. Porto Alegre: UFRGS, 2006. 183 f. Dissertação (Mestrado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia de Produção, Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

MACKAY, M. M.; METCALFE M. Multiple Methods Forecast for Discontinuous Innovations. **Technological Forecasting & Social Change**, v. 69, 221-232, 2002.

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

MENTZER, J. T.; GOMES, R. Evaluating a decision support forecasting system. **Industrial Marketing Management**, v. 18, 313-323, 1989.

MONTGOMERY, D. C.; JOHNSON, L. A.; GARDINER, J. S. **Forecasting And Time Series Analysis**. New York: McGraw-Hill, 1990.

MOON, M. A.; MENTZER, J. T.; SMITH, C. D. Conducting a sales forecasting audit. **International Journal of Forecasting**, v. 19, 5–25, 2003.

NEWBOLD, P.; GRANGER, C. W. J. Experience with forecasting univariate time series and combination of forecast. **Journal Royal Statistical Society**, v. 137, 131-165, 1974.

NIKOLOPOULOS, K.; ASSIMAKOPOULOS, V. Theta intelligent forecasting information system. **Industrial Management & Data System**, v. 103, 711-726, 2003.

PELLEGRINI, F. R. **Metodologia Para Implementação De Sistemas De Previsão De Demanda**. Porto Alegre: UFRGS, 2000. 146 f. Dissertação (Mestrado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia de Produção, Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

SANDERS, N. R.; MANRODT, K. B. Forecasting practices in US corporations: survey results. **Interfaces**, v. 24, 92- 101, 1994.

SANDERS, N. R.; RITZMAN, L. P. Integrating judgmental and quantitative forecasts: methodologies for pooling marketing and operations information. **International Journal of Operations & Production Management**, v. 24, 514-529, 2004.

THOMAS, R. J. Estimating Demand for Services: Issues in Combining Sales Forecasts. **Journal of Retailing and Consumer Services**, v. 3, 241-250, 1996.

THOMASSEY, S.; FIORDALISO, A. A hybrid sales forecasting system based on clustering and decision trees. **Decision Support Systems**, v. 42, 408–421, 2006.

TRAPERO, J. R.; PEDREGAL, D. J.; FILDES, R.; KOURENTZES, N. Analysis of judgmental adjustments in the presence of promotions. **International Journal of Forecasting**, v. 29, 234–243, 2013.

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

WERNER, L. **Um Modelo Composto Para Realizar Previsão De Demanda Através Da Integração Da Combinação De Previsões E Do Ajuste Baseado Na Opinião**. Porto Alegre: UFRGS, 2004. 166 f. Tese (Doutorado em Engenharia de Produção) - Programa de Pós-

Graduação em Engenharia de Produção, Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

WERNER, L.; RIBEIRO, J. L. D. Modelo composto para prever demanda através da integração de previsões. **Produção**, v. 16, 493-509, 2006.

WINKLER, R. L.; MAKRIDAKIS, S. The Combination of Forecast. **Journal of the Royal Statistical Society**, v. 146, 150-157, 1983.

ZOU, H. YANG, Y. Combining Time Series Models for Forecasting. **International Journal of Forecasting**, v. 20, 69-84, 2004.

3 SEGUNDO ARTIGO: PREVISÃO DE DEMANDA COMBINADA A PARTIR DE MÉTODOS QUANTITATIVOS E OPINIÃO DE ESPECIALISTAS: PROPOSTA METODOLÓGICA E ESTUDO DE CASO

Resumo

A previsão de demanda que combina métodos quantitativos e a opinião de especialistas é uma técnica amplamente utilizada na tentativa de aproximar a previsão da demanda real. A proposta deste trabalho é estruturar um método combinado de previsão de demanda. O método proposto não só combina matematicamente as previsões quantitativas e qualitativas, como também pondera, através da matriz de comparação das características do método AHP, a opinião de cada especialista consultado. Este artigo, além de descrever detalhadamente o método proposto, ilustra a aplicação do método através de um estudo de caso realizado em uma empresa metal-mecânica. O estudo foi realizado para diferentes modelos de produtos, considerando um horizonte de previsão de doze meses. Os resultados indicam melhora na acurácia total, bem como para a maioria dos meses analisados e dos modelos testados.

Palavras-chave: previsão de demanda, combinação de previsões, opinião de especialistas, AHP

Abstract

Demand forecasting that combines quantitative methods and judgmental adjustments is a technique widely used in the attempt to approximate forecast to actual demand. In this paper we propose a combined forecasting model that uses quantitative methods and expert opinion. The model presented not only combines mathematically the quantitative and qualitative forecast, but also assigns importance weights to experts using the comparison matrices of AHP (Analytic Hierarchy Process). We describe in details the model proposed and illustrate it through a practical application in a manufacturing industry. The case study considers several products in a 12-month forecast horizon. Using the combination model proposed in this theses we obtained improvements in the overall forecast accuracy; accuracy was also improved for the majority of periods and products analyzed.

Keywords: demand forecasting, combination of forecast, expert opinion, AHP

3.1 Introdução

Previsões de demanda desempenham um papel fundamental para o futuro das organizações. Por apresentarem uma visão mais clara de futuro, previsões podem auxiliar na tomada de decisões, tanto em nível operacional como estratégico (ARMSTRONG, 2001). As

previsões são utilizadas nos mais diversos setores e propiciam não só o gerenciamento da produção e controle eficiente de recursos, como também a projeção de novos investimentos, elevados níveis de serviço e satisfação dos clientes (KOTLER, 1991).

Os diversos métodos de previsão de demanda podem ser classificados em duas categorias: qualitativos e quantitativos (MONTGOMERY; JOHNSON; GARDINER, 1990). Enquanto os métodos qualitativos consideram a opinião de especialistas para gerar previsões, os métodos quantitativos utilizam técnicas estatísticas e modelos matemáticos para prever a demanda futura (MAKRIDAKIS; WHEELWRIGHT; HUYNDMAN, 1998). Atualmente, a maioria dos pesquisadores concorda que tanto os métodos quantitativos quanto qualitativos têm pontos fortes e fracos (SANDERS; RITZMAN, 2004).

Um modelo de previsão ideal é aquele que incorpora as vantagens de cada método. Além disso, devido à quantidade de fatores que influenciam no desempenho das empresas (e.g., curto ciclo de vida de produtos, elevada concorrência e agressivas ações de marketing), prever a demanda utilizando apenas uma técnica pode não ser suficiente para obter um resultado satisfatório. O mercado competitivo exige previsões assertivas que utilizem mais de um método e incorporem a maior quantidade de informações relevantes (WERNER, 2004; TRAPERO *et al.*, 2013). Assim, a combinação de métodos qualitativos e quantitativos surge como forma de diminuir o efeito de variáveis externas e melhorar a qualidade das previsões (BOPP, 1985; SANDERS; RITZMAN, 2004).

A combinação ocorre quando diferentes fontes de previsão (e.g., métodos qualitativos e quantitativos) são integradas para construção de uma previsão final. Para tanto, deve-se, primeiramente, construir as previsões individuais. Assim que essas estiverem finalizadas, pode-se obter a previsão final (WEBBY; O'CONNOR, 1996). Esta combinação pode ser realizada subjetivamente, através do julgamento humano, ou quantitativamente, com o auxílio de modelos matemáticos.

Quando a combinação é subjetiva, os pesos de importância das previsões quantitativas e qualitativas são determinados pelos especialistas. Muitas vezes, o critério adotado para seleção dos pesos não é claro, tornando a técnica vulnerável a tendências. Previsões quantitativas podem também receber menos ênfase ou serem ignoradas na previsão final (GOODWIN; 2000, LEMOS; 2006, FRANSES; LEGERSTEE, 2011). Além disso, obter a opinião destes especialistas pode ser um processo oneroso e exigir a utilização de muitos recursos das organizações (FILDES *et al.*, 2009).

Diferente da combinação subjetiva, na qual os pesos de importância são definidos de maneira empírica, a combinação quantitativa é calculada através de modelos matemáticos que determinam o peso de importância para cada fonte de previsão. Estudos realizados sobre este tema indicam que os resultados obtidos por este tipo de combinação são superiores à combinação subjetiva (LAWRENCE; EDMUNDSON; O'CONNOR, 1986).

O tema deste artigo é a integração de métodos quantitativos e da opinião de especialistas através da combinação de previsão. Esta pesquisa tem como objetivo geral estruturar um método que combine matematicamente as previsões quantitativas e qualitativas, aplicável a múltiplos modelos de produto, em diferentes períodos de previsão e considerando a opinião de diferentes especialistas.

A justificativa para o tema proposto é a necessidade do aumento de acurácia das previsões. Erros de previsões podem ocasionar baixos níveis de serviços ou elevados níveis de estoque (FILDES; BEARD, 1992). Por outro lado, previsões mais acuradas podem trazer economias significativas para as empresas, resultando em maior retorno monetário, maior competitividade, melhor relacionamento com clientes e aumento de sua satisfação (MOON; MENTZER; SMITH, 2003).

Diversas pesquisas sugerem melhorias na acurácia utilizando previsões combinadas (LEMOS, 2006). Apesar da importância da opinião de especialistas para o processo de previsão, autores sugerem que trabalhos que estudam este tema ainda são escassos (TRAPERO *et al.*, 2013). Além disso, a literatura atual considera poucos produtos, horizontes curtos de previsão ou um número limitado de especialistas (FRANSES; LEGERSTEE, 2011). Considerando a vasta quantidade de produtos ofertados atualmente estudos mais aprofundados nesta área são necessários, para maior confiabilidade e generalização dos resultados.

Este trabalho traz uma contribuição importante para o estado da arte de estudo sobre combinação de previsões. Neste trabalho, propõe-se a utilização do AHP (*Analytic Hierarchy Process*), um método de decisão multicriterial, para definir a atribuição de pesos de importância a especialistas responsáveis por gerar previsões qualitativas.

Este artigo está estruturado em cinco seções. A primeira apresenta o tema abordado, bem como sua relevância para a área de estudo. Também são apresentados os objetivos a serem alcançados, a justificativa da pesquisa e a estrutura. A segunda seção apresenta o método proposto para alcançar os resultados esperados ao passo que a terceira seção traz um estudo de caso onde o método é aplicado. Os resultados obtidos a partir deste estudo são discutidos na

quarta seção. A última seção apresenta as conclusões do estudo e sugestões para trabalhos futuros.

3.2 Método

O método utilizado para elaboração da previsão combinada neste estudo está estruturado em 5 passos: (i) coleta e tratamento de dados; (ii) obtenção das previsões individuais; (iii) determinação dos pesos de importância dos especialistas; (iv) obtenção da previsão combinada; e (v) validação dos resultados. A Figura 3.1 apresenta um modelo esquemático com a sequência de passos para execução do método proposto.

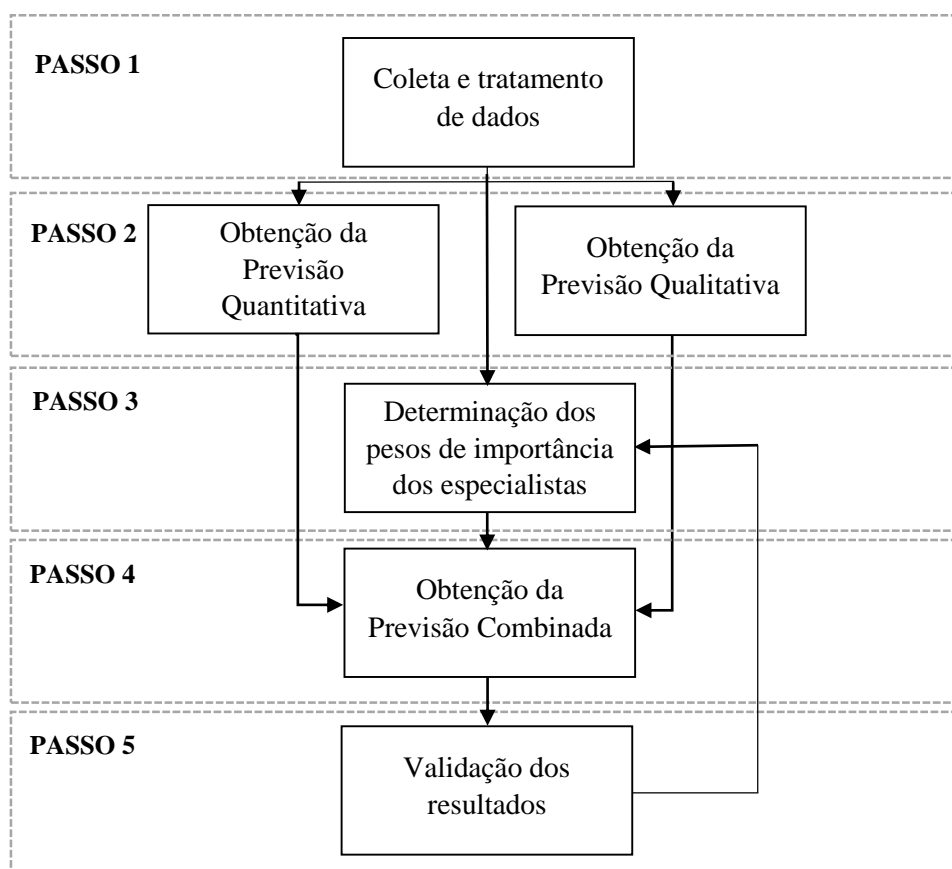


Figura 3.1: Sequência de execução do método proposto

3.2.1 Passo 1: Coleta e tratamento de dados

Segundo Makridakis, Wheelwright e Hyndman (1998), a coleta de dados é uma etapa fundamental para elaboração de previsões de demanda. Este passo consiste em verificar a disponibilidade de dados para elaboração das previsões quantitativas e qualitativas. Para construção das previsões, utilizam-se dados históricos de demanda e outras informações relevantes para o comportamento das vendas. Normalmente, as empresas armazenam os dados em banco de dados (WERNER, 2004). Os bancos de dados devem ser atualizados

periodicamente e todos os dados relevantes para a previsão devem ser coletados e disponibilizados com filtros de pesquisa (e.g., clientes, vendedores, região, promoções) (ARMSTRONG, 2001; LEMOS, 2006).

A fim de garantir a qualidade da base de dados, Lemos (2006) recomenda analisar e tratar os dados coletados. Para tanto, deve-se refinar a base de dados quantitativa através da remoção de valores espúrios ou atípicos. Da mesma forma, os especialistas devem validar se os fatores contextuais disponíveis podem ser relevantes para o processo de previsão. Dados irrelevantes não devem ser adicionados à base de dados, pois prejudicam a acurácia das previsões. A coleta de dados deve ser sistemática e não tendenciosa (ARMSTRONG, 2001).

Considerando que os recursos disponíveis nas organizações são geralmente escassos, as empresas dificilmente fazem previsões para todos os itens comercializados (LEMOS, 2006). Esta tarefa tornou-se ainda mais complexa em consequência da grande variedade de produtos ofertados, não sendo viável, muitas vezes, a elaboração de uma previsão específica para cada item (FILDES *et al.*, 2009). Por isso, é necessário priorizar os itens a serem previstos. Segundo Lemos (2006), uma prática adotada pelas empresas é realizar previsões por linha de produto, ao invés de considerar os itens individuais. Pode-se também agregar os itens por famílias de produtos, de acordo com a similaridade entre eles. Quanto mais homogêneos forem os dados coletados e maior o número de itens agregados, mais acurada será a previsão (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; ARMSTRONG, 2001; LEMOS, 2006).

3.2.2 Passo 2: Obtenção das previsões individuais

De maneira geral, os métodos de previsão de demanda dividem-se em quantitativos e qualitativos (MONTGOMERY; JOHNSON; GARDINER, 1990). A combinação de previsão ocorre quando diferentes métodos são integrados para construção de uma previsão final. Para construção da previsão final deve-se, primeiramente, obter as previsões individuais (WEBBY; O'CONNOR, 1996). Este passo aborda como obter a previsão utilizando cada método individualmente.

3.2.2.1 Obtenção da previsão qualitativa

As previsões qualitativas utilizam informações contextuais para elaboração dos cenários futuros. Entre os métodos utilizados para obtenção de previsões qualitativas destacam-se: (i) Delphi, (ii) Pesquisa de Intenção, (iii) Analogia e (iv) Opinião de Especialistas

(MAKRIDAKIS; WHEELWRIGHT; HUYNDMAN, 1998; KRAJEWSKI; RITZMAN, 2002). Nesta proposta, a previsão qualitativa será obtida através da Opinião de Especialistas.

A Opinião de Especialista baseia-se no julgamento humano e na intuição dos especialistas na área de negócio para prever a demanda (MAKRIDAKIS; WHEELWRIGHT; HUYNDMAN, 1998; ARMSTRONG, 2001). Pode-se obter a previsão qualitativa através de entrevistas com especialistas, questionários ou em reuniões de grupo. Uma abordagem frequentemente utilizada pelas organizações para obter a previsão qualitativa consiste em realizar reuniões gerenciais onde especialistas de diversas áreas ajustam previsões quantitativas ou realizam projeções baseadas no seu julgamento (FILDES *et al.*, 2009; FRANSES; LEGERSTEE, 2009; TRAPERO *et al.*, 2013). Entre as áreas mais envolvidas na tomada de decisão destacam-se marketing, produção e vendas (FILDES *et al.*, 2009; TRAPERO *et al.*, 2013).

Nesta proposta, a previsão qualitativa baseada na opinião de especialista foi denominada de \hat{E}_{ijt} , onde i é a unidade de venda (e.g., item, produto, modelo, família), j é a área de venda (e.g., país, estado, regional) que possui um especialista correspondente, e t é o período de análise.

3.2.2.2 Obtenção da previsão quantitativa

A obtenção da previsão quantitativa consiste em modelar os dados coletados através de técnicas estatísticas e modelos matemáticos. Os métodos quantitativos podem ser classificados em (i) métodos causais e (ii) análise de séries temporais. Nesta proposta, a previsão quantitativa será obtida através da análise de séries temporais.

De acordo com Makridakis, Wheelwright e Huynzman (1998), a análise de séries temporais utiliza o histórico de demanda para elaboração da previsão, assumindo que os padrões de dados passados irão se repetir no futuro. Exemplos de métodos baseados em análise de séries temporais são Média Móvel, Suavização Exponencial, Decomposição e *Box-Jenkins*. Para facilitar a escolha do método de séries temporais a ser utilizado, os autores recomendam uma análise gráfica dos dados coletados para visualização do padrão da demanda e identificação de comportamentos como tendência, ciclo e sazonalidade.

De posse dos dados coletados e tratados de acordo com o Passo 1, utilizam-se pacotes computacionais para construção das previsões quantitativas (PELLEGRINI, 2000). Vários *softwares* aplicados a sistemas de previsões de demanda estão disponíveis no mercado (TASHMAN, 2000; ARMSTRONG, 2001). A seleção do melhor *software* dependerá das

necessidades de cada organização, dos recursos disponíveis e do nível de suporte de manutenção requerido (MENTZER; GOMES, 1989; LEMOS, 2006).

Nesta proposta, a previsão quantitativa gerada pelo *software* foi denominada de \hat{S}_{ijt} , onde i é a unidade de venda (e.g., item, produto, modelo, família), j é a área de venda (e.g., país, estado, regional) que possui um especialista correspondente, e t é o período de análise.

3.2.3 Passo 3: Determinação dos pesos de importância dos especialistas

Durante muitos anos, os métodos qualitativos foram o principal recurso para elaboração de previsões. Embora os métodos qualitativos tenham predominado devido à flexibilidade que oferecem ao usuário, estes métodos podem ser tendenciosos e inconsistentes, pois dependem da honestidade, sensibilidade e bom julgamento dos entrevistados (SANDERS; MANRODT, 1994).

A qualidade das previsões dos especialistas é igualmente questionável. Frequentemente, eles apontam suas projeções em reuniões onde podem se sentir pressionados por outros participantes, realizando previsões que não condizem com sua real crença. Estudos também apontam que algumas características pessoais são relevantes para elaboração das previsões como, por exemplo, a idade (experiência) (BARBER; ODEN, 2001; LAMONT, 2002; FRANSES, 2013).

Devido a estas variações, o terceiro passo desta proposta pretende dar um peso para cada especialista através da matriz de comparação das características do método AHP. O método AHP, criado nos anos 1970 por Thomas Saaty, utiliza uma matriz quadrada para confrontar diferentes fatores a fim de determinar a intensidade de importância que um assume frente ao outro. Os elementos das matrizes assumem valores de escala de 1 a 9, sendo 1 utilizado para fatores de igual importância e 9 para fatores de extrema importância. Além disso, o elemento mais importante na comparação é usado com valor inteiro da escala e o menos importante como o inverso dessa unidade. Segundo Saaty (1991), não existe uma técnica específica para definir o valor de escala para cada fator. O autor sugere realizar uma sessão de *brainstorming*, considerando os aspectos relevantes para o processo de decisão.

No caso desta proposta, os fatores a serem confrontados entre si são os especialistas responsáveis pelas previsões qualitativas, representados por suas áreas de venda j . Após realizar as comparações dos fatores utilizando a matriz do método AHP, obtém-se o vetor de peso. Maiores detalhes sobre o método AHP podem ser obtidos em Saaty (1991).

De acordo com Saaty (1991), após a definição do vetor de peso, deve-se analisar a consistência da matriz. Caso uma matriz de comparações seja considerada inconsistente, a

mesma deve ser revisada. O autor propõe um método para representatividade numérica da consistência, calculado através da equação (1).

$$IC = \frac{\lambda_{max} - n}{n - 1} \quad (1)$$

onde IC é o índice de consistência da matriz, λ_{max} é o autovalor máximo, e n é o número de elementos considerados na matriz.

É considerado aceitável um índice de até 0,10 para a razão da consistência da matriz (RC), calculada através da equação (2).

$$RC = \frac{IC}{IR} \quad (2)$$

onde IR é o índice randômico, correspondente a um valor tabelado que varia de acordo com o número de elementos comparados na matriz. A Tabela 3.1 apresenta valores de IR para matrizes de dimensão 1 a 15.

Tabela 3.1: Índice randômico

n	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
IR	0,00	0,00	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49	1,51	1,48	1,56	1,57	1,59

Após a verificação da consistência da matriz pode-se calcular o peso de importância para cada especialista, denominado de α_j . Nesta proposta ponderou-se os especialistas analisados em relação ao melhor especialista. Para o especialista com maior peso, definido através do vetor de pesos, considerou-se o peso de importância α igual a 1; os pesos dos demais especialistas foram obtidos proporcionalmente ao de maior peso.

3.2.4 Passo 4: Obtenção da previsão combinada

A combinação de previsão ocorre quando diferentes fontes de previsão (e.g., métodos qualitativos e quantitativos) são integradas para construção de uma previsão final. No caso desta proposta, a previsão combinada é obtida pela integração da opinião de especialista com a previsão quantitativa, a fim de melhorar a acurácia da previsão. A previsão combinada foi definida como \hat{C} e é representada pela equação (3).

$$\hat{C}_{ijt} = (\hat{E}_{ijt} \cdot \alpha_j \beta_i) + (\hat{S}_{ijt} \cdot (1 - \alpha_j \beta_i)) \quad (3)$$

Cada variável β_i corresponde a uma unidade de venda i ($i = 1, 2, \dots, I$) e é determinada através da minimização da média dos erros percentuais absolutos (MAPE - *Mean Absolute Percentual Error*), definido pela equação (4). Os valores de β_i podem variar entre 0 a 1, ou seja, se β for igual a 1, o peso da previsão qualitativa assume o valor integral de α_j . A previsão por unidade de vendas i é calculada pelo somatório das áreas de vendas j .

$$MAPE = \frac{1}{n} \sum_{t=1}^n \sum_{i=1}^I \left| \left(\frac{Y_{it} - \hat{C}_{it}}{Y_{it}} \right) \times 100 \right| \quad (4)$$

onde Y_{it} é a demanda real para a unidade de venda i no período t .

3.2.5 Passo 5: Validação dos resultados

A validação dos resultados é uma etapa necessária para garantir que o processo de previsão funcione corretamente (KLASSEN; FLORES, 2001). Esta etapa visa avaliar a eficiência do método, através da medida de acurácia das previsões, bem como identificar se este pode ser utilizado futuramente (TASHMAN, 2000; LEMOS, 2006).

Para medir a acurácia, os valores previstos são comparados aos valores reais de demanda do mesmo período. Segundo Lemos (2006), a medida de acurácia mais aplicada em estudos empíricos com comparação de métodos é o MAPE. O MAPE é pouco afetado por valores extremos e, por apresentar percentuais do erro, independe da escala utilizada (LAWRENCE; EDMUNDSON; O'CONNOR, 1986).

A validação dos resultados nesta proposta é realizada através do cálculo do MAPE. A demanda real de cada unidade de venda i deve ser comparada com as três previsões obtidas: (i) qualitativa, (ii) quantitativa, e (iii) combinada. Os resultados estarão validados se apresentarem menor valor de MAPE em relação à previsão vigente (ARMSTRONG, 2001). Caso não haja a validação dos resultados, retorna-se ao passo 3 e realiza-se os passos subsequentes até o mesmo ser validado.

3.3 Estudo de caso

Este capítulo apresenta um estudo onde a previsão combinada proposta é aplicada aos dados de demanda de uma empresa metal-mecânica líder no mercado brasileiro de ferramentas motorizadas portáteis. A matriz da empresa está localizada na cidade de Waiblingen, na Alemanha, e a unidade produtiva do Brasil está em São Leopoldo. Este estudo foi realizado apenas para o mercado brasileiro.

A empresa comercializa no Brasil 13 produtos motorizados, divididos em mais de 50 modelos, destinados aos mercados florestal, agropecuário, jardinagem, doméstico e construção civil. Esta proposta foi aplicada para o principal produto comercializado pela empresa. Este produto possui atualmente dezenove modelos disponíveis no seu portfólio, os quais encontram-se em diferentes fases do ciclo de vida do produto. Para realização deste estudo, onze modelos foram selecionados por já estarem consolidados no mercado. Os modelos selecionados representam 70% das unidades vendidas do produto e 27% do total de unidades vendidas pela empresa no Brasil. Entre os modelos selecionados, seis são produzidos no Brasil e cinco são importados de outras unidades produtivas da empresa, sendo três da China e dois dos Estados Unidos.

O período de previsão da empresa é mensal, assim como o planejamento operacional. O intervalo entre previsões também é mensal, devido às incertezas sobre o nível de demanda no futuro. A previsão de demanda é gerada em reuniões onde as áreas de marketing, vendas, produção e logística são envolvidas. A empresa conta com cinco regionais de vendas no Brasil e um gerente de vendas para cada regional, sendo cada gerente de vendas responsável pela previsão de demanda da sua regional. Os gerentes de vendas analisam, durante a reunião, dados históricos de demanda não modelados e, com base no seu julgamento e em fatores contextuais apresentados pelas outras áreas participantes geram as previsões de demanda por modelo de produto. A previsão final da empresa para o mercado brasileiro é a soma das previsões de demanda de cada regional de vendas. O horizonte de previsão é anual e a acurácia é medida por modelo de produto, independente da regional de vendas.

A acurácia da previsão é fundamental para o desempenho da empresa. As previsões são utilizadas para aquisição dos insumos produtivos (e.g., matérias-primas, equipamentos, mão-de-obra), controle dos estoques, programação e planejamento da produção, bem como para o planejamento de compra dos modelos importados. A empresa apresenta, principalmente para os modelos importados, restrições de flexibilidade para mudanças no curto prazo (0-3 meses).

Além dos processos operacionais, as previsões de demanda geram as metas de vendas e faturamento da empresa.

3.3.1 Passo 1: Coleta e tratamento de dados

A coleta de dados iniciou-se pela verificação da disponibilidade de dados para elaboração das previsões individuais. A empresa armazena os dados históricos de demanda mensais desde 1999 em uma base de dados. O banco de dados é atualizado mensalmente para cada regional de venda. Entretanto, a empresa não disponibiliza de uma base organizada de variáveis causais relacionadas à demanda.

Nesta etapa, coletaram-se os dados de demanda do produto em estudo e, através de uma análise gráfica, removeram-se valores espúrios ou atípicos. A análise gráfica permitiu também identificar um novo comportamento da demanda a partir de janeiro de 2010 e, por isso, todos os dados anteriores a esta data foram descartados. As séries temporais utilizadas no estudo foram divididas em três partes: (i) dados para obtenção das previsões quantitativas (42 períodos mensais, a partir de janeiro de 2010); (ii) dados para obtenção da previsão combinada (6 períodos mensais, a partir de julho de 2013) e; (iii) dados para validação dos resultados (12 períodos mensais, a partir de janeiro de 2014), sendo janeiro de 2014 denominado de período t .

Esta proposta foi aplicada para onze modelos do produto analisado. Os modelos estudados foram agrupados em famílias i (variando de 1 a 6) de acordo com a similaridade entre eles (potência e nicho de mercado). Além disso, os dados foram estratificados de acordo com a regional de vendas j . Para facilitar a compreensão deste passo, a Figura 3.2 apresenta um esquema da organização dos dados coletados.

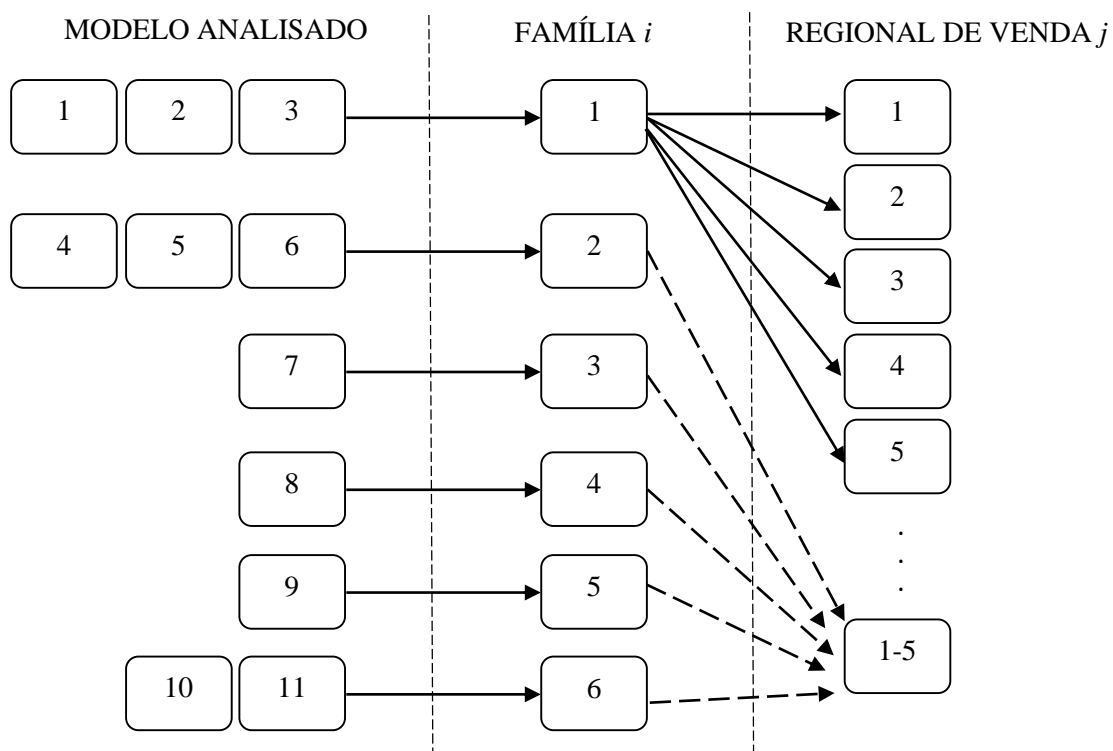


Figura 3.2: Organização dos dados coletados

3.3.2 Passo 2: Obtenção das previsões individuais

3.3.2.1 Obtenção da previsão qualitativa

A previsão qualitativa deste estudo foi obtida através da Opinião de Especialistas que, neste caso, são os gerentes de vendas. Mensalmente, a empresa realiza reuniões individuais com cada um dos cinco gerentes de vendas, envolvendo também as áreas de marketing, produção e logística. Durante a reunião, dados históricos de demanda não modelados são analisados, bem como outros fatores contextuais (e.g., preço, campanhas promocionais, lançamentos) considerados nas análises subjetivas. Ao final da reunião, cada gerente de vendas é responsável pela previsão de demanda qualitativa da sua regional por modelo de produto.

As previsões dos especialistas (\hat{E}_{ijt}) foram organizadas em tabelas, de acordo com a família de produto analisada. O período de análise nesta etapa foi de seis meses, entre julho e dezembro de 2013. Um exemplo é apresentado na Tabela 3.2 para a previsão qualitativa da família 1 ($i = 1$). A previsão de cada família é calculada pelo somatório das regionais.

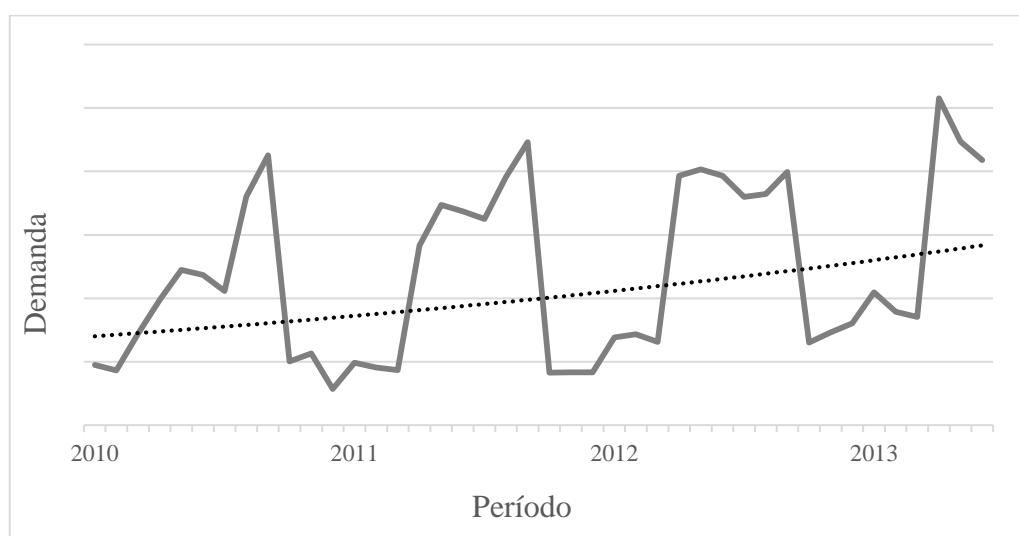
Tabela 3.2: Previsão qualitativa para $i = 1$

j	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
1	3.886	3.866	3.898	534	730	610
2	2.577	2.378	2.535	813	840	710
3	628	581	1.184	220	382	367
4	1.474	1.306	1.906	560	430	430
5	619	538	879	109	338	270
$\sum_{i=1}^j \hat{E}_t$	9.184	8.669	10.402	2.236	2.720	2.387

Este procedimento foi repetido para as seis famílias analisadas e estas previsões foram utilizadas posteriormente para obtenção da previsão combinada.

3.3.2.2 Obtenção da previsão quantitativa

Para iniciar a construção dos modelos quantitativos, plotaram-se os dados totais de demanda do produto em um gráfico. A análise da Figura 3.3 auxilia a identificar a presença de tendência e sazonalidade na série.

**Figura 3.3: Demanda do produto e sua tendência**

De posse dos dados coletados e tratados de acordo com o Passo 1, utilizou-se o pacote computacional específico *Forecast Pro* (versão 6, 2010) para construção das previsões quantitativas. Para esta etapa do estudo, 42 períodos mensais foram utilizados para obtenção dos modelos matemáticos, sendo o horizonte de previsão de seis meses, de julho a dezembro de 2013.

A previsão quantitativa foi realizada através da abordagem *top-down*, onde primeiramente é feita a previsão para a soma de todos os itens e posteriormente desagregada item a item. No caso deste estudo, a previsão de demanda foi realizada pelo total do produto e posteriormente rateada por família de produto, sendo estas, por sua vez, desagregadas por regional de vendas.

O critério de seleção do modelo matemático foi o melhor ajuste do modelo aos dados da série histórica, sendo mensurado pelo coeficiente de determinação (R^2). Um ajuste perfeito do modelo resultaria em um valor de R^2 igual a 1. Para modelos de previsão de demanda, valores com $R^2 \geq 0,6$ são considerados satisfatórios (PELLEGRINI, 2000). O *Forecast Pro* ajusta os modelos matemáticos aos dados da série temporal e calcula o MAPE dos valores ajustados em relação aos valores históricos.

A Figura 3.4 apresenta a modelagem da série temporal do produto, bem como as previsões geradas pelo *software* e o intervalo de confiança. As cores das linhas do *Forecast Pro* são: (i) verde, que representa a série temporal histórica; (ii) vermelha, que corresponde aos valores ajustados e de previsão; e (iii) azuis, que delimitam o intervalo de confiança para a previsão (nível de confiança = 80%).

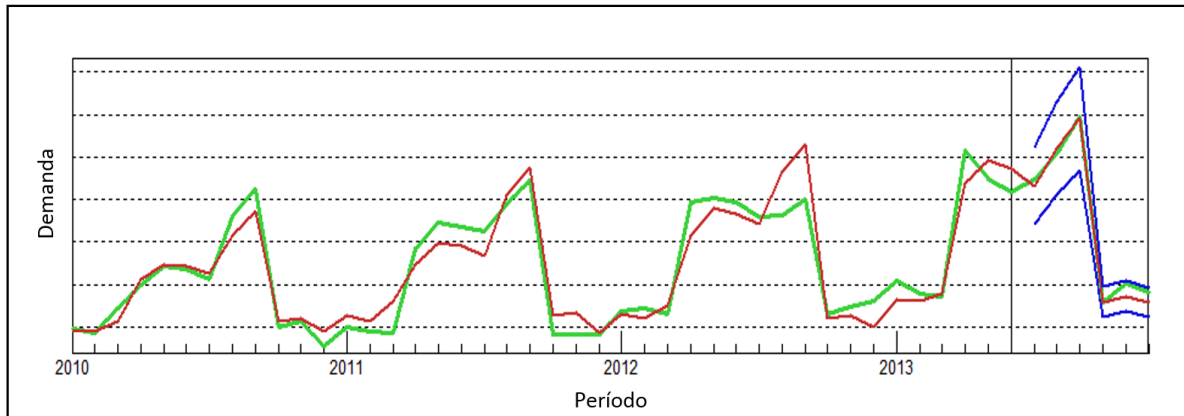


Figura 3.4: Modelagem para a série temporal do produto

Para o total do produto apresentado, o método de Suavização Exponencial com Tendência Exponencial e Sazonalidade Multiplicativa apresentou o melhor ajuste. O modelo matemático gerado pelo software apresentou um R^2 de 0,89 e MAPE de 17,59%. Os modelos matemáticos mais bem ajustados, desagregados por família de produto (i), bem como os detalhes de cada modelo, podem ser visualizados na Tabela 3.3. As informações detalhadas por regional de vendas (j) encontram-se no APÊNDICE A.

Tabela 3.3: Modelo matemático por família de produto

i	Modelo matemático	R ²	MAPE (%)
1	Box-Jenkins – ARIMA (0; 1; 0)*(0; 1; 0)	0,82	29,57
2	Box-Jenkins – ARIMA (0; 1; 0)*(1; 1; 0)	0,98	4,61
3	Suavização exponencial: Sem tendência, sazonalidade aditiva	0,66	60,42
4	Suavização exponencial: Sem tendência, sazonalidade aditiva	0,86	20,90
5	Suavização exponencial: Sem tendência, sazonalidade multiplicativa	0,86	17,33
6	Suavização exponencial: Sem tendência, sazonalidade multiplicativa	0,71	24,79

Assim como as previsões qualitativas, as previsões quantitativas (\hat{S}_{ijt}) foram organizadas em tabelas, de acordo com a família de produto analisada. Um exemplo é apresentado na Tabela 3.4 para a previsão quantitativa da família 1 ($i = 1$). A previsão de cada família é calculada pelo somatório das regionais.

Tabela 3.4: Previsão quantitativa para $i = 1$

j	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
1	4.282	4.857	5.152	1.570	1.251	1.522
2	2.259	2.256	3.923	968	951	969
3	643	1.431	1.619	560	753	483
4	1.510	1.638	1.859	383	744	618
5	448	1.227	1.512	669	325	322
$\sum_{i=1}^j \hat{S}_t$	9.142	11.409	14.065	4.150	4.024	3.914

Este procedimento foi repetido para as seis famílias analisadas e estas previsões foram utilizadas posteriormente para obtenção da previsão combinada.

3.3.3 Passo 3: Determinação dos pesos de importância dos especialistas

A determinação dos pesos de importância dos especialistas foi realizada através da matriz de comparação das características do método AHP. Para cada especialista analisado, representado pela sua regional de vendas j , foi calculado um peso que corresponde à qualidade da sua previsão.

Inicialmente, definiu-se um grau de importância a cada especialista, através de um valor de escala. Neste estudo, o critério utilizado para definir o valor de escala foi somente a acurácia das previsões. Em seguida, construiu-se a matriz para comparar os fatores das linhas com os

fatores das colunas. A Figura 3.5 apresenta a matriz de comparação com o vetor de pesos, obtido a partir do cálculo do autovetor principal da matriz.

j	1	2	3	4	5	Vetor de pesos
1	1	1/3	5	1/5	3	0,134
2	3	1	7	1/3	5	0,260
3	1/5	1/7	1	1/9	1/3	0,035
4	5	3	9	1	7	0,503
5	1/3	1/5	3	1/7	1	0,068

Figura 3.5: Matriz de comparação e vetor de pesos

Após a definição do vetor de pesos, analisou-se a consistência da matriz. O RC calculado a partir das equações (1) e (2) resultou em um índice de 0,054, evidenciando que a matriz é consistente.

A última etapa deste passo foi definir o peso de importância α_j para cada especialista. Considerou-se que o especialista mais acurado é aquele com maior valor associado no vetor de pesos, que neste caso foi o especialista da regional 4. Para este especialista atribuiu-se um α_j igual a 1. Assim, a previsão do especialista mais acurado pode receber o seu valor integral na previsão combinada. Os outros especialistas foram ponderados em relação a este especialista. A Tabela 3.5 apresenta os valores de α_j para cada especialista.

Tabela 3.5: Valores de α_j

j	α_j
1	0,27
2	0,52
3	0,07
4	1,00
5	0,14

Os valores de α_j aqui estabelecidos foram utilizados para obtenção da previsão combinada e para validação dos resultados.

3.3.4 Passo 4: Obtenção da previsão combinada

A previsão combinada deste estudo foi obtida através da equação (3). Conforme detalhado na equação, os pesos utilizados nesta proposta totalizam 1, onde à previsão qualitativa atribui-se o peso $\alpha_j\beta_i$ e à quantitativa o peso $(1-\alpha_j\beta_i)$.

Para cada família de produto analisada i atribuiu-se um valor de β_i , que foi determinado através de programação linear, onde: (i) a função objetivo era minimização do MAPE final, calculado pela diferença entre demanda real e previsão combinada para as 6 famílias analisadas e para os 6 períodos utilizados nesta etapa; (ii) as variáveis de decisão foram os seis valores de β_i ; e (iii) as restrições foram referentes aos valores de β_i , confinados no intervalo $0 \leq \beta \leq 1$.

A Tabela 3.6 apresenta os valores ótimos de β_i obtidos através da programação linear.

Tabela 3.6: Valores ótimos de β_i

i	Valor
1	0,172
2	0,813
3	0,996
4	0,501
5	0,995
6	0,968

Esses valores de β_i foram utilizados para obtenção da previsão combinada e para validação dos resultados. Com todas as informações disponíveis, foi possível calcular a previsão combinada utilizando a equação (3). A Tabela 3.7 exemplifica as previsões combinadas de todas as regionais obtidas para o mês de setembro de 2013 ($t-4$) para a família 1. A previsão por família é calculada pelo somatório das regionais.

Tabela 3.7: Previsão combinada para $i=1$ em $t-4$

Período	Setembro		
j	\hat{E}_{1jt-4}	\hat{S}_{1jt-4}	\hat{C}_{1jt-4}
1	3.898	5.152	5.094
2	2.535	3.923	3.799
3	1.184	1.619	1.614
4	1.906	1.859	1.867
5	879	1.512	1.497
$\sum_{i=1}^j \hat{C}_{t-4}$	10.402	14.065	13.871

Neste exemplo, a previsão combinada destacada na Tabela 3.7 foi obtida por:

$$\hat{C}_{11t-4} = (3898 \times (0,27 \times 0,172)) + (5152 \times (1 - 0,27 \times 0,172))$$

$$\hat{C}_{11t-4} = 5094$$

Repetiu-se este procedimento para obtenção de todas as previsões combinadas, para as famílias e períodos analisados.

3.3.5 Passo 5: Validação dos resultados

A validação dos resultados desta proposta foi realizada pela medida de acurácia das previsões, através do cálculo do MAPE. Para validar o método, utilizaram-se 12 períodos, de janeiro a dezembro de 2014. Considerando que a série histórica apresenta sazonalidade, decidiu-se analisar um horizonte anual para verificar se a proposta é eficiente para períodos com picos e vales de demanda.

A primeira etapa deste passo foi obter as previsões combinadas, conforme demonstrado na seção 3.3.4, para todas as regionais e em todos os meses utilizados na validação. A previsão por família é a soma das previsões individuais referente a cada regional de venda. Para medir a acurácia, a demanda real foi comparada não só com a previsão combinada, como também com as previsões qualitativas e quantitativas.

Primeiramente, calculou-se o erro percentual absoluto (APE – *Absolute Percentual Error*) para cada família em cada período utilizado na validação. A partir do cálculo do APE, calculou-se o MAPE consolidado por família e por período de validação. A Tabela 3.8 apresenta a acurácia das previsões por família de produto, enquanto que a Tabela 3.9 apresenta a acurácia por período. Os valores destacados nas tabelas indicam as previsões mais acuradas. O detalhamento do APE e MAPE, bem como as previsões e demanda real por família e período, encontram-se no APÊNDICE B.

Tabela 3.8: Acurácia das previsões (MAPE) por família

<i>i</i>	Previsão		
	Qualitativa	Quantitativa	Combinada
1	13,20	10,03	9,58
2	15,83	15,49	14,05
3	23,04	13,68	14,64
4	9,63	20,51	17,89
5	19,19	17,89	14,54
6	33,15	32,27	22,57

Tabela 3.9: Acurácia das previsões (MAPE) por período

Previsão/Período	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Qualitativa	29,20	19,55	15,92	12,64	9,82	8,05	5,80	2,68	12,86	10,91	28,50	28,74
Quantitativa	28,98	13,68	5,72	6,66	5,65	18,77	24,84	12,20	5,09	10,26	15,71	5,95
Combinada	27,61	14,38	6,51	6,43	4,51	15,02	22,35	10,02	2,49	9,62	17,38	5,40

Para finalizar o estudo calculou-se a acurácia total para as previsões, através da média dos erros dos doze períodos analisados. Os resultados são apresentados na Tabela 3.10.

Tabela 3.10: Acurácia total (MAPE) das previsões

	Previsão		
	Qualitativa	Quantitativa	Combinada
	15,39	12,79	11,81

3.4 Discussão dos resultados

A partir do cálculo de MAPE é possível analisar os resultados alcançados. A acurácia das previsões por família de produto, apresentada na Tabela 3.8, indica que a previsão combinada reduziu os erros para cinco das seis famílias analisadas em relação à previsão vigente (qualitativa). Além disso, a previsão combinada não apresentou o pior resultado para nenhuma família analisada.

A Tabela 3.9, que apresenta a acurácia por período, mostra que, para seis dos doze períodos analisados, a previsão combinada apresentou os menores erros. Além disso, a previsão combinada não apresentou o pior resultado para nenhum período testado. Os modelos

quantitativos se mostraram bem ajustados e melhoraram as previsões para a maioria dos períodos (9 entre 12 meses). É importante ressaltar que a empresa estudada teve sua demanda afetada nos períodos anteriores e posteriores à Copa do Mundo de Futebol (junho a agosto). Percebeu-se que, principalmente para estes períodos, a previsão qualitativa melhorou a acurácia das previsões.

A acurácia total das previsões, mostrada na Tabela 3.10, evidencia que a previsão combinada proposta apresentou o melhor resultado em relação às previsões analisadas. A previsão combinada final melhorou a acurácia da previsão qualitativa em 23,26%.

3.5 Conclusões e sugestões para trabalhos futuros

A combinação de métodos quantitativos com o julgamento humano é uma técnica amplamente utilizada na tentativa de aproximar a previsão da demanda real. Este artigo apresentou uma proposta para melhorar a acurácia de previsões a partir da combinação de modelos matemáticos e da previsão de especialistas. O resultado do estudo mostrou que a previsão combinada proposta apresentou os menores erros entre as previsões analisadas.

Diferente da maioria das pesquisas sobre previsões combinadas, que analisa poucos produtos, horizontes curtos de previsão ou um número limitado de especialistas (FRANSES; LEGERSTEE, 2011), este trabalho foi desenvolvido para onze modelos de produtos, em um horizonte de doze meses e contando com a opinião de cinco especialistas.

A previsão combinada proposta mostrou-se a mais acurada, em relação às três previsões analisadas, para a maioria das famílias de produto analisadas (4 entre 6 famílias) e não apresentou o pior resultado para nenhuma família. Entretanto, a análise do método limitou-se aos modelos comercializados pela empresa já consolidados no mercado. Estudos futuros contemplando produtos em diferentes fases do ciclo de vida poderiam ser realizados, aumentando assim a aplicabilidade do método.

O estudo contemplou um horizonte de doze meses e a previsão combinada apresentou não só os menores erros para a maioria dos períodos analisados (6 entre 12 meses), como também não apresentou o pior resultado para nenhum período testado. Assim, foi possível evidenciar a eficiência do método em períodos sazonais.

A opinião dos especialistas foi significativa principalmente em períodos considerados atípicos (e.g., Copa do Mundo de Futebol) devido à flexibilidade para se adaptar a mudanças de comportamento de demanda. Os gerentes beneficiaram as previsões através do amplo

conhecimento sobre eventos que não ocorreram anteriormente e que, conseqüentemente, não seriam considerados nos modelos matemáticos. No entanto, os gerentes apresentaram erros expressivos nos períodos pós eleições (novembro e dezembro) devido ao pessimismo frente às incertezas no cenário econômico.

Considerando que uma das premissas utilizada pela empresa para elaboração das metas de vendas é a previsão qualitativa dos gerentes, é provável que as previsões realizadas por eles não venham a condizer com sua real crença. Além disso, os gerentes podem se sentir pressionados pelos participantes das outras áreas durante a reunião. Estudos relacionados com o perfil dos especialistas poderiam ser realizados para entender o comportamento dos entrevistados ou, até mesmo, melhorar a seleção dos especialistas.

A opinião de cada especialista em relação a sua regional de vendas foi heterogênea. Enquanto uns superestimavam a demanda real, outros subestimavam-na. Neste sentido, a ponderação de cada especialista de acordo com a qualidade da sua previsão provou-se necessária. A matriz de comparação das características do método AHP mostrou-se uma forma eficiente de ponderação da opinião dos especialistas. Novos estudos com este foco seriam interessantes a fim de testar outras estratégias de atribuição de pesos e buscar otimizar os pesos atribuídos aos especialistas.

3.6 Referências

ARMSTRONG, J. S. **Principles of Forecasting: A handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.

BARBER, B. M.; ODEAN T. Boys will be boys: Gender, overconfidence, and common stock investment. **The Quarterly Journal of Economics**, v. 116, 261-292, 2001.

FILDES, R.; GOODWIN, P.; LAWRENCE, M.; NIKOLOPOULOS, K. Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning. **International Journal of Forecasting**, v. 25, 3-23, 2009.

FRANSES, P. H.; LEGERSTEE, R. Properties of expert adjustments on model-based SKU-level forecasts. **International Journal of Forecasting**, v. 25, 35-47, 2009.

FRANSES, P. H. Improving judgmental adjustment of model-based forecasts. **Mathematics and Computers in Simulation**, v. 93, 1-8, 2013.

KLASSEN, R.; FLORES, B. E. Forecasting practices of Canadian firms: survey results and comparisons. **International Journal of Production Economics**, v.70, 163-174, 2001.

KRAJEWSKI, L. J.; RITZMAN, L. P. **Operations management: Strategy and Analysis**. 6^a ed. New Jersey: Prentice Hall, 2002.

LAMONT, O. A. Macroeconomic forecasts and microeconomic forecasters. **Journal of Economic Behavior & Organization**, v. 48, 265–280, 2002

LAWRENCE, M. J.; EDMUNDSON, R. H.; O'CONNOR, M. J. The Accuracy of Combining Judgemental and Statistical Forecasts. **Management Science**, v. 32,1521-1532, 1986.

LEMONS, F. O. **Metodologia para Seleção de Método de Previsão de Demanda**. Porto Alegre: UFRGS, 2006. 183 f. Dissertação (Mestrado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia de Produção, Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

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

MENTZER, J. T.; GOMES, R. Evaluating a decision support forecasting system. **Industrial Marketing Management**, v. 18, 313-323, 1989.

MONTGOMERY, D. C.; JOHNSON, L. A.; GARDINER, J. S. **Forecasting And Time Series Analysis**. New York: McGraw-Hill, 1990.

PELLEGRINI, F. R. **Metodologia Para Implementação De Sistemas De Previsão De Demanda**. Porto Alegre: UFRGS, 2000. 146 f. Dissertação (Mestrado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia de Produção, Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

SAATY, T. L. **Método de Análise Hierárquica**. São Paulo: McGraw-Hill, 1991.

SANDERS, N. R.; MANRODT. K. B. Forecasting practices in US corporations: survey results. **Interfaces**, v. 24, 92- 101, 1994.

TASHMAN, L. T. Out-of-sample tests of forecasting accuracy: an analysis and review. **International Journal of Forecasting**, v. 16, 437–450, 2000.

TRAPERO, J. R.; PEDREGAL, D. J.; FILDES, R.; KOURENTZES, N. Analysis of judgmental adjustments in the presence of promotions. **International Journal of Forecasting**, v. 29, 234–243, 2013.

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

WERNER, L. **Um Modelo Composto Para Realizar Previsão De Demanda Através Da Integração Da Combinação De Previsões E Do Ajuste Baseado Na Opinião**. Porto Alegre: UFRGS, 2004. 166 f. Tese (Doutorado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia de Produção, Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

4 CONSIDERAÇÕES FINAIS

4.1 Conclusões

A melhora da acurácia através das previsões combinadas é tema de diversos estudos, sendo de interesse tanto para a academia quanto para as empresas. O primeiro artigo, que teve como objetivo efetuar uma revisão bibliográfica sobre técnicas de previsão de demanda e combinação de previsões, mostrou que a opinião de especialista pode ser agregada a previsões quantitativas de diversos meios, seja através de formas elementares como a média simples, ou com o auxílio de métodos complexos. Normalmente, previsões combinadas apresentam melhorias significativas na acurácia, se comparadas a previsões individuais.

Os resultados da revisão bibliográfica mostraram que alguns autores analisam características relevantes para elaboração das previsões (e.g., idade, experiência), enquanto outros indicam quais fatores externos e internos à organização influenciam na demanda (e.g., condições climáticas, estoques, ações promocionais) (WERNER; RIBEIRO, 2006; FILDES *et al.*, 2009).

Através dos exemplos apresentados neste trabalho, ficou evidente que uma abordagem comum para elaboração de previsão de demanda dentro das organizações estudadas envolve a utilização de um sistema informatizado para produzir previsões iniciais e o posterior ajuste baseado no julgamento humano (FILDES *et al.*, 2009; FRANSES; LEGERSTEE, 2009; TRAPERO *et al.*, 2013). Conclui-se também que os *softwares* próprios para previsões de demanda são amplamente utilizados pelas empresas.

Mostrou-se neste trabalho que poucos especialistas utilizam os modelos estatísticos para elaboração de suas previsões. Muitas vezes eles não compreendem as informações quantitativas e, por isso, acabam descartando-as (FRANSES, 2013). Acredita-se, porém, que o ideal seria explicar aos especialistas a relevância dos dados passados para prever a demanda futura e a eficiência dos modelos computacionais.

O segundo artigo, cujo objetivo era estruturar um método para combinar matematicamente as previsões quantitativas e qualitativas, mostrou que a previsão combinada melhorou a acurácia da previsão vigente em mais de 23%. Diferente da maioria das pesquisas sobre previsões combinadas, que analisa poucos produtos, horizontes curtos de previsão ou um número limitado de especialistas (FRANSES; LEGERSTEE, 2011), este trabalho foi desenvolvido para onze modelos de produtos, em um horizonte de doze meses e contando com a opinião de cinco especialistas. A previsão combinada mostrou-se a mais acurada para a

maioria das famílias de produto e para a maioria dos períodos analisados. Considerando os resultados alcançados e o horizonte estudado, comprovou-se a eficiência do método em períodos sazonais.

No estudo de caso do segundo artigo, a opinião dos especialistas foi significativa principalmente em períodos considerados atípicos (e.g., Copa do Mundo de Futebol) devido à flexibilidade para se adaptar a mudanças de comportamento de demanda. Os gerentes beneficiaram as previsões através do amplo conhecimento sobre eventos que não ocorreram anteriormente e que, conseqüentemente, não seriam considerados nos modelos matemáticos. No entanto, os gerentes incorreram em erros expressivos nos períodos pós eleições (novembro e dezembro), devido ao pessimismo frente às incertezas no cenário econômico. Considerando que uma das premissas utilizada pela empresa para elaboração das metas de vendas é a previsão qualitativa dos gerentes, é provável que as previsões realizadas por eles não venham a condizer com sua real crença. Além disso, os gerentes podem se sentir pressionados pelos participantes das outras áreas durante a reunião.

A opinião de cada especialista em relação a sua regional de vendas foi heterogênea. Enquanto uns superestimavam a demanda real, outros subestimavam-na. Neste sentido, a ponderação de cada especialista de acordo com a qualidade da sua previsão provou-se necessária e a matriz de comparações do método AHP mostrou-se uma forma eficiente de obter as ponderações.

4.2 Sugestões para trabalhos futuros

A partir deste trabalho é possível sugerir pesquisas futuras para o desenvolvimento da área de combinação de previsões. São elas:

- a) Análise das características do perfil dos especialistas para melhor entendimento do comportamento dos entrevistados ou, até mesmo, melhorar a seleção dos especialistas;
- b) Aperfeiçoamento dos *softwares* de previsão para incorporação do julgamento humano diretamente nos modelos computacionais;
- c) Análise de produtos em diferentes fases do ciclo de vida a fim de aumentar a aplicabilidade do método;
- d) Análise de outras estratégias de atribuição de pesos aos especialistas; e
- e) Otimização dos pesos atribuídos aos especialistas.

4.3 Referências

FILDES, R.; GOODWIN, P.; LAWRENCE, M.; NIKOLOPOULOS, K. Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning. **International Journal of Forecasting**, v. 25, 3–23, 2009.

FRANSES, P. H.; LEGERSTEE, R. Properties of expert adjustments on model-based SKU-level forecasts. **International Journal of Forecasting**, v. 25, 35–47, 2009.

FRANSES, P. H.; LEGERSTEE, R. Combining SKU-level sales forecasts from models and experts. **Expert Systems with Applications**, v. 28, 2365-2370, 2011.

FRANSES, P. H. Improving judgmental adjustment of model-based forecasts. **Mathematics and Computers in Simulation**, v. 93, 1–8, 2013.

TRAPERO, J. R.; PEDREGAL, D. J.; FILDES, R.; KOURENTZES, N. Analysis of judgmental adjustments in the presence of promotions. **International Journal of Forecasting**, v. 29, 234–243, 2013.

WERNER, L.; RIBEIRO, J. L. D. Modelo composto para prever demanda através da integração de previsões. **Produção**, v. 16, 493-509, 2006.

APÊNDICE

APÊNDICE A - Modelo matemático por família de produto e regional de venda

<i>i</i>	<i>j</i>	Modelo matemático	R ²	MAPE
	1	Box-Jenkins – ARIMA (0; 1; 0)*(0; 1; 0)	0,80	42,70
	2	Box-Jenkins – ARIMA (0; 1; 0)*(0; 1; 0)	0,73	33,91
1	3	Suavização exponencial: Sem tendência, sazonalidade aditiva	0,78	39,33
	4	Suavização exponencial: Sem tendência, sazonalidade multiplicativa	0,82	39,13
	5	Suavização exponencial: Sem tendência, sazonalidade multiplicativa	0,78	41,50
	1	Box-Jenkins – ARIMA (0; 1; 0)*(0; 1; 0)	0,89	13,14
	2	Box-Jenkins – ARIMA (0; 1; 0)*(0; 1; 0)	0,88	14,59
2	3	Winters Aditivo: Tendência linear, sazonalidade aditiva	0,78	30,58
	4	Box-Jenkins – ARIMA (0; 1; 1)*(0; 1; 0)	0,79	26,26
	5	Box-Jenkins – ARIMA (0; 1; 1)*(0; 1; 0)	0,85	17,67
	1	Suavização exponencial: Sem tendência, sazonalidade aditiva	0,66	63,23
	2	Box-Jenkins – ARIMA (1; 0; 0)	0,42	95,60
3	3	Box-Jenkins – ARIMA (0; 0; 2)	0,49	157,68
	4	Box-Jenkins – ARIMA (1; 0; 0)	0,45	222,72
	5	Suavização exponencial: Sem tendência, sazonalidade multiplicativa	0,47	89,30
	1	Box-Jenkins – ARIMA (2; 0; 0)*(0; 1; 0)	0,90	17,01
	2	Winters Aditivo: Tendência linear, sazonalidade aditiva	0,68	26,41
4	3	Suavização exponencial: Sem tendência, sazonalidade aditiva	0,63	35,38
	4	Winters Aditivo: Tendência linear, sazonalidade aditiva	0,66	39,67
	5	Suavização exponencial: Sem tendência, sazonalidade multiplicativa	0,73	37,26
	1	Box-Jenkins – ARIMA (1; 0; 0)*(1; 0; 0)	0,79	28,25
	2	Winters Multiplicativo: Tendência linear, sazonalidade multiplicativa	0,88	23,08
5	3	Suavização exponencial: Sem tendência, sazonalidade multiplicativa	0,67	26,73
	4	Suavização exponencial: Sem tendência, sazonalidade multiplicativa	0,77	28,70
	5	Suavização exponencial: Sem tendência, sazonalidade multiplicativa	0,74	26,59
	1	Suavização exponencial: Sem tendência, sazonalidade multiplicativa	0,72	37,60
	2	Winters Multiplicativo: Tendência linear, sazonalidade multiplicativa	0,66	28,32
6	3	Média móvel simples	0,00	93,90
	4	Suavização exponencial: Sem tendência, sazonalidade multiplicativa	0,32	80,53
	5	Suavização exponencial: Sem tendência, sazonalidade aditiva	0,28	60,90

APÊNDICE B - Acurácia detalhada das previsões

<i>i</i>	Período	Demanda real	Previsão Qualitativa			Previsão Quantitativa			Previsão Combinada		
			Previsão	APE	MAPE	Previsão	APE	MAPE	Previsão	APE	MAPE
1	Janeiro	5.958	4.408	26,02		4.783	19,72		4.784	19,70	
	Fevereiro	5.201	4.540	12,71		4.659	10,42		4.670	10,21	
	Março	4.483	4.184	6,67		4.588	2,34		4.574	2,03	
	Abril	12.323	11.259	8,63		12.065	2,09		11.992	2,69	
	Maio	11.775	10.722	8,94		11.275	4,25		11.282	4,19	
	Junho	9.661	10.407	7,72	13,20	10.951	13,35	10,03	10.937	13,21	9,58
	Julho	9.628	9.940	3,24		12.260	27,34		12.110	25,78	
	Agosto	11.075	11.023	0,47		12.273	10,82		12.195	10,11	
	Setembro	13.021	11.342	12,89		13.314	2,25		13.184	1,25	
	Outubro	3.778	3.926	3,92		3.423	9,40		3.458	8,47	
	Novembro	5.409	3.568	34,04		4.682	13,44		4.593	15,09	
	Dezembro	4.342	2.903	33,14		4.559	5,00		4.438	2,21	
2	Janeiro	2.117	1.461	30,99		1.186	43,98		1.259	40,53	
	Fevereiro	1.894	1.433	24,34		1.629	13,99		1.638	13,52	
	Março	1.601	1.226	23,42		1.680	4,93		1.558	2,69	
	Abril	4.231	3.864	8,67		4.800	13,45		4.542	7,35	
	Maio	3.732	3.355	10,10		3.654	2,09		3.610	3,27	
	Junho	3.478	3.546	1,96	15,83	4.068	16,96	15,49	3.939	13,25	14,05
	Julho	3.221	3.464	7,54		4.047	25,64		3.920	21,70	
	Agosto	3.764	3.712	1,38		4.177	10,97		4.124	9,56	
	Setembro	4.428	3.870	12,60		4.464	0,81		4.437	0,20	
	Outubro	1.186	1.453	22,51		1.361	14,76		1.344	13,32	
	Novembro	1.619	1.295	20,01		1.150	28,97		1.162	28,23	
	Dezembro	1.284	944	26,48		1.164	9,35		1.092	14,95	
3	Janeiro	801	506	36,83		508	36,58		535	33,21	
	Fevereiro	759	459	39,53		692	8,83		629	17,13	
	Março	717	457	36,26		668	6,83		585	18,41	
	Abril	1.969	1.367	30,57		1.704	13,46		1.611	18,18	
	Maio	1.887	1.744	7,58		1.750	7,26		1.680	10,97	
	Junho	1.462	1.299	11,15	23,04	1.973	34,95	13,68	1.815	24,15	14,64
	Julho	1.495	1.206	19,33		1.238	17,19		1.223	18,19	
	Agosto	1.658	1.590	4,10		1.812	9,29		1.758	6,03	
	Setembro	1.819	1.566	13,91		2.052	12,81		1.905	4,73	
	Outubro	662	539	18,58		664	0,30		647	2,27	
	Novembro	738	565	23,44		678	8,13		631	14,50	
	Dezembro	644	417	35,25		699	8,54		593	7,92	
4	Janeiro	346	333	3,76		412	19,08		391	13,01	
	Fevereiro	373	320	14,21		241	35,39		253	32,17	
	Março	248	283	14,11		308	24,19		305	22,98	
	Abril	817	837	2,45		795	2,69		800	2,08	
	Maio	706	669	5,24		749	6,09		717	1,56	
	Junho	560	760	35,71	9,63	783	39,82	20,51	772	37,86	17,89
	Julho	557	610	9,52		657	17,95		649	16,52	
	Agosto	566	659	16,43		741	30,92		727	28,45	
	Setembro	705	698	0,99		741	5,11		752	6,67	
	Outubro	224	234	4,46		141	37,05		155	30,80	
	Novembro	263	266	1,14		199	24,33		207	21,29	
	Dezembro	227	244	7,49		219	3,52		230	1,32	

	Janeiro	1.150	633	44,96		612	46,78	630	45,22	
	Fevereiro	944	628	33,47		698	26,06	666	29,45	
	Março	809	560	30,78		670	17,18	646	20,15	
	Abril	2.192	1.643	25,05		2.034	7,21	1.879	14,28	
	Maiο	1.970	1.630	17,26		2.353	19,44	2.044	3,76	
5	Junho	1.733	1.577	9,00	19,19	2.209	27,47	1.934	11,60	14,54
	Julho	1.574	1.540	2,16		1.822	15,76	1.707	8,45	
	Agosto	1.877	1.692	9,86		2.245	19,61	2.041	8,74	
	Setembro	2.105	1.791	14,92		2.610	23,99	2.353	11,78	
	Outubro	636	514	19,18		633	0,47	621	2,36	
	Novembro	720	560	22,22		665	7,64	635	11,81	
	Dezembro	553	545	1,45		536	3,07	515	6,87	
	Janeiro	67	50	25,37		45	32,84	48	28,36	
	Fevereiro	64	50	21,88		53	17,19	51	20,31	
	Março	64	21	67,19		43	32,81	34	46,88	
	Abril	315	474	50,48		133	57,78	241	23,49	
	Maiο	262	216	17,56		270	3,05	253	3,44	
6	Junho	124	87	29,84	33,15	229	84,68	177	42,74	22,57
	Julho	118	86	27,12		176	49,15	148	25,42	
	Agosto	157	95	39,49		178	13,38	149	5,10	
	Setembro	153	104	32,03		182	18,95	152	0,65	
	Outubro	112	62	44,64		53	52,68	54	51,79	
	Novembro	97	77	20,62		82	15,46	81	16,49	
	Dezembro	65	51	21,54		71	9,23	69	6,15	