

AJUSTE DE PREVISÃO DE DEMANDA QUANTITATIVA COM BASE EM FATORES QUALITATIVOS: ESTUDO DE CASO EM UM RESTAURANTE FAST FOOD

Mateus Meneghini (UFRGS)

mateusmeneghini91@gmail.com

Michel José Anzanello (UFRGS)

anzanello@producao.ufrgs.br

RESUMO

Este artigo propõe um método de previsão de demanda que integra modelos quantitativos com fatores contextuais qualitativos. O método proposto inicialmente seleciona o modelo matemático (quantitativo) que melhor se adapta aos dados históricos, com base no coeficiente de determinação R^2 e MAPE. Na sequência, as previsões geradas pelo modelo selecionado são ajustadas com base na opinião de especialistas sobre fatores contextuais (realização de eventos e reformas, por exemplo) não incluídos nos dados históricos. O método proposto foi aplicado em um restaurante fast food, realizando a previsão de demanda de carnes. O método ajustado gerou um erro percentual médio na pior das hipóteses de 10% quando comparado com a demanda real do período, enquanto que o modelo quantitativo, sem a intervenção dos especialistas, gerou um erro percentual médio de até 38%.

Palavras-chave: previsão de demanda, ajuste qualitativo, *fast food*.

ABSTRACT

This article proposes a method that integrates quantitative models and qualitative forecasting contextual factors. The method initially selects the mathematical model that better fits the historical data based on the coefficient of determination R^2 and MAPE. Next, forecasts generated by the selected model are adjusted based on the opinions of specialists regarding contextual factors (judgemental adjustment), e.g. events held and rebuilding, not included in the historical data. The method proposed was applied to a fast food restaurant to forecast meat demand. The adjusted method yielded an average error of 10% in the worst scenario when compared to the actual demand, while the quantitative model with no judgemental adjustment led to an average error of 38%.

Keywords: demand forecasting, judgemental adjustment, *fast food*.

1. Introdução

Diante de um cenário com frequentes mudanças e uma exigência de nível de serviço cada vez mais personalizado pelo consumidor, as empresas do setor terciário têm buscado diferenciais competitivos para destacarem-se em seus segmentos. Para Machado *et al.* (2006), oferecer serviços com qualidade elevada é um fator essencial no desempenho da empresa. Dentro deste contexto, Cranage (2003) reforça que estratégias de gestão na indústria hoteleira devem se tornar diferenciadas devido à alta competição deste mercado. O setor de restaurantes, incluído neste tipo de indústria, sofre com as profundas mudanças nas exigências dos clientes, necessitando de alternativas para enfrentar a concorrência.

Liu *et al.* (2001) afirmam que existem três habilidades essenciais demandadas a um gerente e que impactam na lucratividade de um restaurante: prever necessidades de pessoal, prever níveis de estoque e prever os pedidos para programar a preparação dos pratos no tempo certo. Além disso, prever as refeições que serão vendidas fornece informações valiosas para reduzir custos, utilizar os recursos com maior eficiência e melhorar a habilidade para competir em um meio de constante mudança (CRANAGE, 2003). Segundo Ansel e Dyer (1999), previsão de demanda em um restaurante é o primeiro passo para resolver problemas críticos de planejamento, tais como disponibilidade de mesas, força de trabalho e quantidade de estoque de matéria-prima.

Choi (1999) conclui que gestores de restaurantes *fast food* precisam prever a demanda para seus serviços e também controlar seu estoque efetivamente para que o desperdício seja reduzido. Em um restaurante *fast food*, existe um ponto crucial que confronta o desperdício de insumos com o atendimento ao cliente. Uma vez que diversos processos na cozinha de um restaurante são “empurrados”, há uma importância fundamental em apoiar-se em uma previsão de demanda precisa que evite o início do preparo depois do pedido do cliente e, ao mesmo tempo, reduza a violação do “tempo de prateleira” dos produtos. Excesso de produção por antecipação gera desperdício, enquanto que falta de produção gera insatisfação no cliente (serviço lento). Ambos incorrem em perda de receita e de imagem da empresa.

Apesar da extrema importância da previsão de demanda no contexto de um restaurante *fast food*, percebe-se uma ampla utilização de métodos qualitativos informais, baseados apenas na experiência do gestor. Para Pellegrini (2000), métodos qualitativos, por serem fundamentados na opinião de especialistas com preferências distintas, são vulneráveis a tendências que podem comprometer a previsão. Por outro lado, previsões quantitativas são confiáveis desde que os eventos verificados durante a geração do banco de dados históricos permaneçam

inalterados (SANDERS e RITZMAN, 2004). Mathews e Diamantopoulos (1986) afirmam que ajustes baseados na opinião de especialistas em previsões quantitativas aumentam a precisão dos resultados. Todavia, este ajuste, conforme Goodwin *et al.* (2007), deve ser feito com a adição de conhecimentos que não estejam incluídos no método quantitativo. Em restaurantes *fast food*, existem diversos fatores novos que afetam a demanda e que não podem ser incluídos na previsão quantitativa por conta da inexistência de dados históricos, tais como promoções, propagandas, relação corporação-franquia, entre outros. Esses fatores devem ser mensurados por meio da opinião de especialistas e então incluídos no método quantitativo (ajuste subjetivo).

O objetivo deste artigo é propor um modelo de previsão de demanda apoiado no ajuste qualitativo das previsões geradas pelo método quantitativo e testá-lo no processo de compra de um restaurante *fast food*. Para tanto, primeiramente escolhe-se o modelo quantitativo de previsão de demanda que melhor se adapta aos dados históricos com base em métricas de ajuste, como o coeficiente de determinação R^2 e o MAPE. Na sequência, identificam-se fatores qualitativos que poderiam influenciar a demanda. Por fim, ajusta-se a previsão de demanda quantitativa com base na influência dos fatores, e compara-se os resultados da previsão com a demanda real. Dessa forma, o trabalho procura auxiliar no aumento da confiabilidade da previsão de demanda do restaurante e no processo de compra de insumos.

Este artigo está organizado da seguinte maneira: após esta introdução, apresenta-se um referencial teórico na seção 2, onde são revisados conteúdos sobre métodos de previsão de demanda e ajuste subjetivo. A seção 3 trata dos procedimentos metodológicos utilizados no trabalho. Na seção 4 são apresentados os resultados de um estudo de caso em um restaurante *fast food*, onde foi aplicado o método de previsão de demanda proposto. Por fim, na seção 5 são relatadas as considerações finais sobre o presente estudo e discutidas oportunidades para trabalhos futuros.

2. Fundamentação da previsão de demanda

A previsão de demanda é uma atividade essencial para planejamento, estratégia ou qualquer outro meio que necessite tomar decisões futuras (MAKRIDAKIS, 1988). No contexto empresarial, tal previsão é de suma importância em diversos setores, como vendas, financeiro, logística e produção (MOON *et al.*, 1998). Neste último setor, a previsão de demanda normalmente é o primeiro passo para planejar sua operação, pois é com base nela que são

desenvolvidos os planos de capacidade, mão de obra, estoques e produção (ELSAYED e BOUCHER, 1985; TUBINO, 2000).

Existem duas abordagens principais para previsão de demanda: métodos qualitativos e métodos quantitativos. A abordagem qualitativa baseia-se em opiniões, julgamentos e em desempenhos passados de especialistas (SLACK *et al.*, 2009). A abordagem quantitativa leva em conta dados históricos e realiza uma projeção por meio de algum modelo matemático (CORRÊA e CORRÊA, 2005).

No setor de restaurantes predominam os métodos qualitativos. Todavia, existem diversos estudos que utilizaram previsões de demanda quantitativas neste ramo de atividade: Reynolds *et al.* (2013) aplicaram um modelo de regressão (causal) em restaurantes de diferentes segmentos, como *fast food*, *à la carte*, restaurantes não comerciais (próprios de estabelecimentos, como hospitais e fábricas) e restaurantes terceirizados (contratados de estabelecimentos como os anteriores), obtendo previsões confiáveis. Cranage (2003) realizou previsões de vendas por meio de uma vasta carta de métodos (entre eles, suavização exponencial, média móvel e decomposição) em um restaurante e comparou com demandas reais do período previsto, tendo sucesso com algumas das técnicas. Cranage e Andrew (1992) concluíram, em uma pesquisa feita em um restaurante médio de uma cidade universitária, que modelos de séries temporais (como suavização exponencial e o método de *Box-Jenkins*) se comportavam melhor do que modelos causais na predição de vendas.

2.1. Métodos quantitativos

Métodos quantitativos caracterizam-se por utilizarem processos bem definidos para a análise de dados, permitindo que o método seja replicado por outros especialistas e que estes obtenham as mesmas previsões (ARMSTRONG, 1983). Nesta categoria de método, os dados históricos são a base para a previsão (ELSAYED e BOUCHER, 1985).

Os métodos quantitativos dividem-se em métodos causais e métodos de séries temporais (SLACK *et al.*, 2009). Métodos causais preveem a demanda tomando como base uma relação de causa e efeito entre as variáveis. Por outro lado, métodos de séries temporais utilizam apenas os dados históricos da demanda para prever o futuro, pressupondo que a tendência da demanda no passado permanecerá inalterada (DAVIS *et al.*, 2003). Os métodos de séries temporais mais abordados na literatura são média móvel e suavização exponencial.

As técnicas de suavização exponencial são as mais utilizadas frente a todas as outras técnicas de previsão de demanda (DAVIS *et al.*, 2003). Isso ocorre pelo fato desses métodos serem simples, fáceis de ajustar e fornecerem boa acurácia (PELLEGRINI, 2000). A seguir são apresentados os métodos mais tradicionais de suavização exponencial (RITZMAN e KRAJEWSKI, 2004; ELSAYED e BOUCHER, 1985).

(i) Suavização Exponencial Simples: Utilizada quando não há tendência ou sazonalidade na demanda. É simples e possui exigência de apenas três dados: a previsão do último período, a demanda para o período atual e um parâmetro de aproximação com valor entre 0 e 1.

(ii) Suavização Exponencial Dupla de Holt: Utilizada quando existe uma tendência, isto é, um aumento ou uma diminuição sistemática na média da série ao longo do tempo. Neste caso, há a necessidade da suavização não só da média de cada período, mas também da tendência.

(iii) Suavização Exponencial Sazonal de Holt-Winters: Método usado na presença de um aspecto sazonal, ou seja, alterações regularmente repetitivas na demanda para cima ou para baixo.

2.2. Métodos qualitativos e ajuste subjetivo

Métodos qualitativos são técnicas apoiadas em dados subjetivos (TUBINO, 2000). Em geral, são utilizados quando há escassez de dados históricos adequados, como em cenários onde existe introdução de novos produtos ou mudança na tecnologia, o que exige uma previsão com base no julgamento e nas experiências do gestor (RITZMAN e KRAJEWSKI, 2004).

Dentre os principais métodos de previsão qualitativos, destaca-se o Método Delphi (SLACK *et al.*, 2009). Outros métodos qualitativos frequentemente utilizados podem ser encontrados na literatura, como Força de Vendas e Pesquisa de Mercado.

Conforme Song *et al.* (2007), métodos quantitativos podem produzir resultados mais precisos do que métodos qualitativos uma vez que empregam critérios objetivos, menos suscetíveis a erros subjetivos. Em contrapartida, os autores argumentam que em ocasiões onde existem fatores contextuais que não podem ser inclusos no modelo estatístico, o modelo qualitativo obtém um melhor desempenho na previsão.

Wright *et al.* (1996) afirmam que a robustez gerada pela combinação de estratégias tem encorajado a integração de previsões, permitindo agregar o conhecimento contextual aos métodos estatísticos. Ritzman e Krajewski (2004), afirmam que a combinação de previsões

pode superar o melhor método de previsão isolado. Sanders (1992) complementa essa visão, afirmando que a precisão dos modelos estatísticos geralmente é aumentada com um ajuste subjetivo.

Dessa forma, Webby e O'Connor (1996) propõem quatro métodos de integração de previsões: (i) construção de modelos, (ii) combinação de previsões, (iii) decomposição subjetiva e (iv) ajuste subjetivo. Este último, foco do trabalho, será aprofundado.

Segundo Webby e O'Connor (1996), o ajuste subjetivo consiste em realizar uma previsão por meio de um método quantitativo e ajustá-la com base em fatores contextuais. Lawrence *et al.* (2006) exemplificam o ajuste para uma previsão de vendas, onde os dados históricos (geradores da previsão quantitativa) são o histórico de vendas e os fatores contextuais são promoções, dados de produção e fatores macroeconômicos. A Figura 1 ilustra o ajuste subjetivo.

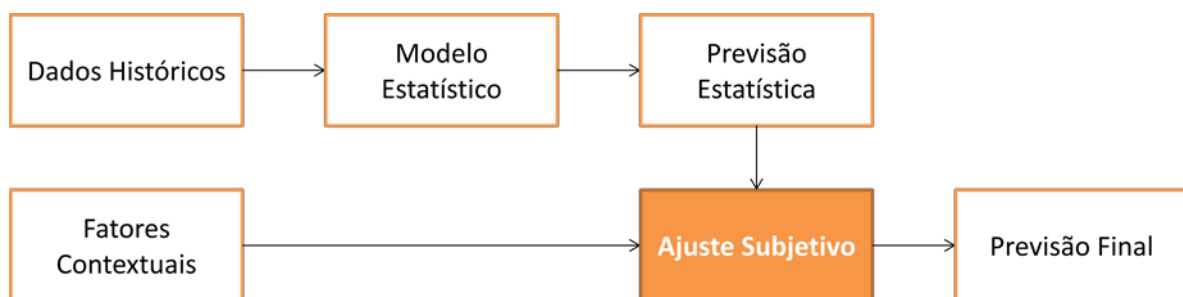


Figura 1 – Ajuste Subjetivo (Fonte: WEBBY e O'CONNOR, 1996)

A aplicação do ajuste subjetivo é vasta. Fildes *et al.* (2009) analisaram o ajuste subjetivo de especialistas em quatro diferentes empresas (farmacêutica, de alimentos, de produtos domésticos e de varejo) e, depois de geradas as previsões estatísticas baseadas em variações da suavização exponencial por meio de um software, concluíram que em três delas a intervenção dos especialistas neste resultado aumentou a precisão da previsão. Song *et al.* (2013) realizaram a previsão de chegadas de turistas a Hong Kong através de um modelo causal para então realizar um ajuste com base na opinião de estudantes especializados em turismo, o que melhorou a previsão final. Forrest *et al.* (2010) utilizaram sua própria experiência com fatores contextuais para ajustar a previsão estatística do número de medalhas que os países participantes das Olimpíadas de Pequim de 2008 alcançariam.

Sanders e Ritzman (2004) citam como vantagens do ajuste subjetivo o alto senso de propriedade e a capacidade de incorporar rapidamente informações contextuais. Webby e

O'Connor (1996) também encontram vantagens semelhantes e enfatizam que o ajuste subjetivo possui o melhor custo benefício dentre os métodos. Entretanto, Goodwin e Wright (2010) ressaltam a desvantagem do método de ser suscetível a tendências.

Davydenko e Fildes (2013) postulam que o ajuste subjetivo deve ocorrer quando há a necessidade de considerar alguns fatores excluídos da previsão quantitativa. Para Armstrong e Collopy (1998), uma vez que o modelo quantitativo não é capaz de incluir esses fatores, torna-se importante a opinião de especialistas para fazê-lo. Reimers e Harvey (2011) reforçam a importância da opinião, afirmando que as pessoas tendem a melhorar suas previsões quando os fatores contextuais fazem parte do seu ambiente.

Reafirmando esta última colocação, Önkal *et al.* (2003) realizaram um estudo sobre a previsão da taxa de câmbio e concluíram que operadores que trabalham diariamente com essa operação em suas empresas obtiveram, em sua grande maioria, previsões melhores do que estudantes universitários de *business*. Em uma pesquisa nas eleições nacionais da Alemanha de 2005, Andersson *et al.* (2006) mostraram que especialistas em política obtiveram previsões mais precisas do que cidadãos alemães votantes e estrangeiros. Conforme Sanders e Ritzman (2004), simplesmente integrar fatores subjetivos arbitrários com um método quantitativo, sem levar em conta o domínio do conhecimento, pode prejudicar a precisão dos resultados.

Todavia, Lawrence *et al.* (2006) acreditam que o julgamento humano traz benefícios à previsão mas também pode acarretar viés. Armstrong (2006) exemplifica: gerentes podem superestimar a previsão de vendas por acreditar que isso motivaria os empregados ou que vendedores poderiam estimar uma previsão mais baixa por ser mais fácil de alcançá-la. Conforme Eroglu e Croxton (2010), fatores como a personalidade e a motivação do previsor são grandes fontes de viés. Além disso, para Sanders e Manrodt (2003), pessoas possuem capacidade limitada para considerar e processar grandes quantidades de informação.

Werner e Ribeiro (2006) citam cinco tipos de viés: (i) Inconsistência: incapacidade de aplicar o mesmo critério de decisão em ocasiões semelhantes; (ii) Ancoramento: tendência dos especialistas a serem influenciados por informações iniciais (âncoras); (iii) Conservadorismo: previsores partem do pressuposto de que a variável em estudo seguirá o mesmo padrão de comportamento do que teve no passado; (iv) Otimismo: pensamento do tomador de decisão que o motiva a realizar a previsão mais favorável do que se seria com base em fatos; (v) Correlação Ilusória: acreditar que duas variáveis estão relacionadas quando na verdade elas

não estão. Para os autores, previsões com viés podem incorrer em perda de pedidos, prestação de serviço inadequado e má utilização dos recursos organizacionais.

Segundo Armstrong (2006), estudos indicam que ajustes subjetivos não estruturados geralmente prejudicam a previsão, pois podem gerar viés. Para Bunn e Salo (1993), existe uma necessidade de fazer um balanço entre o ajuste subjetivo informal com um processo mais estruturado, isto é, mais “defensivo”. Dessa forma, estudos têm desenvolvido métodos de estruturação de ajuste subjetivo.

Wolfe e Flores (1990) realizaram um ajuste em uma previsão de lucros através do Processo Hierárquico Analítico (AHP), aumentando consideravelmente a acurácia dos resultados. Flores *et al.* (1992), por sua vez, compararam o ajuste realizado pelo AHP ao ajuste do método Centróide, concluindo que o AHP obtém melhores precisões nos resultados, mas pouco significativas pela complexidade e pela dificuldade de aplicação do método em relação ao outro. Duru *et al.* (2012) realizaram um ajuste subjetivo no setor de transporte hidroviário, utilizando um método Delphi adaptado para reduzir viés. Conforme Werner e Ribeiro (2006), outros métodos de ajuste subjetivo podem ser encontrados na literatura, tais como decomposição de séries temporais, métodos gráficos e o método de Theil.

3. Procedimentos Metodológicos

Segundo Da Silva e Menezes (2005), esta pesquisa é de natureza aplicada, pois tem por objetivo gerar conhecimentos para aplicação prática e voltados para a solução de problemas específicos. A abordagem é quantitativa, uma vez que utiliza métodos estatísticos e permite traduzir opiniões em números. Do ponto de vista de seus objetivos, a pesquisa é exploratória, pelo fato de visar proporcionar maior familiaridade com o problema. Quanto aos procedimentos técnicos, trata-se de uma pesquisa-ação, visto que o pesquisador e os participantes estão envolvidos com o intuito de resolver um problema coletivo.

O método para ajuste da previsão de demanda quantitativa proposto está dividido em cinco etapas: (i) Coleta de dados históricos de demanda (ii) Modelagem quantitativa; (iii) Levantamento de fatores contextuais; (iv) Ajuste subjetivo; e (v) Validação do método. Tais etapas são detalhadas na sequência.

3.1. Coleta de dados históricos de demanda

A primeira etapa tem por objetivo verificar se existem dados suficientes para a aplicação do método. Inicialmente, avalia-se a disponibilidade de dados históricos de demanda do produto a ser analisado, bem como a qualidade dos mesmos. Na sequência, verifica-se a existência de especialistas com condições de realizarem o ajuste subjetivo.

3.2. Modelagem quantitativa

Na etapa seguinte é realizada uma previsão puramente quantitativa da demanda. Deve-se então definir o método de previsão de demanda quantitativo que melhor se adapta aos dados históricos de demanda. Para tal, dividem-se os dados coletados em dois grupos: treino e teste. O primeiro utiliza 80% dos dados (para a construção do modelo) e o segundo os 20% restantes (dados mais recentes, com vista à validação da modelagem), como indica a Figura 3.




Figura 3 – Grupo de dados: Treino e Teste (Fonte: Autores)

São eleitos n modelos de previsão candidatos a serem testados e então, utilizando apenas os dados do grupo de treino, ajustados aos dados de treino com vistas à predição dos níveis de demanda para as observações do grupo de teste. Por exemplo, se foram coletados 30 dados, as previsões dos métodos são baseadas nos primeiros 24 dados (grupo de treino, 80% dos dados), realizando a predição para seis períodos à frente (grupo de teste, 20% dos dados). Dessa forma, cada modelo gera um coeficiente de determinação R^2 , que representa o grau de ajuste daquele modelo aos dados históricos. Valores elevados de R^2 são desejados, visto que denotam uma boa aderência do modelo aos dados.

Na sequência, são comparadas as previsões realizadas por cada modelo matemático com os dados do grupo de teste. Essa etapa objetiva avaliar a capacidade preditiva de cada modelo construído frente a dados já existentes. Conforme Makridakis *et al.* (1998), acurácia representa o grau de habilidade com que os métodos preveem dados já existentes. Nas proposições deste artigo, utiliza-se o MAPE (*Mean Absolute Percentage Error*), que calcula a média das diferenças absolutas entre o valor real e o valor previsto. Valores reduzidos de MAPE são desejados, visto que denotam boa capacidade preditiva do modelo gerado. Por fim,

são calculados os índices I de cada método, dado pela Equação (5). O modelo que possuir o maior valor para I será escolhida.

$$I_n = \frac{R^2_n}{MAPE_n} \quad (1)$$

Por fim, é realizada uma previsão F_t para o período t desejado com o modelo selecionado, utilizando agora como base para a extrapolação tanto dados de treino como de teste.

3.3. Levantamento de fatores contextuais

A finalidade deste passo é descobrir se existem fatores contextuais (qualitativos) que permitam a realização do ajuste na previsão estatística. Estes fatores são acontecimentos do ambiente que influem na demanda, como promoções de vendas, introdução de um novo produto da marca, reforma da loja e marketing mais agressivo. Os especialistas são entrevistados, individualmente, apontando possíveis fatores que possam influenciar a demanda da variável em estudo. Na sequência, realiza-se uma reunião com os especialistas selecionados e definem-se os fatores. Caso não exista nenhum fator do contexto capaz de alterar a demanda, a previsão por método quantitativo realizada na etapa anterior é suficiente, não sendo necessário o ajuste subjetivo.

3.4. Ajuste subjetivo

Esta fase ajusta as predições geradas pelo modelo quantitativo, feito na etapa (ii), com base nos fatores contextuais levantados pelos especialistas na etapa (iii), conforme definição de ajuste subjetivo de Webby e O'Connor (1996). Primeiramente, é atribuído um peso à contribuição de cada especialista: objetiva-se quantificar a importância da opinião de especialistas mais experientes. Entretanto, deve existir um peso mínimo, o qual representa a divisão igual entre todos sobre 50% da opinião geral. Por exemplo, se existirem três especialistas, o peso mínimo de cada um é 50% dividido por 3, ou seja, 16,67%. Os demais 50% da opinião geral são utilizados para ponderar a importância dos especialistas individualmente. Tal proposição é operacionalizada da seguinte forma: os especialistas avaliam uns aos outros, comentando se consideram o colega mais, igual ou menos experiente do que ele próprio. É montada uma matriz listando os especialistas nas linhas e, nas colunas, coloca-se -1 quando o especialista se considera menos experiente do que o outro, 0 quando se considera com igual experiência e 1 quando se considera mais experiente. Posteriormente, é feito o somatório individual da pontuação do especialista e então calculado o percentual sobre

a soma geral dos pontos. Caso o somatório individual for menor do que zero, quando for feito a soma geral dos pontos, dever-se-á considerá-lo como zero. Este valor diz respeito aos 50% que restaram da opinião geral para a ponderação. Assim, multiplica-se esse valor por 50% e soma-se a ele o peso mínimo, resultando no peso w da opinião do especialista. A Tabela 1 exemplifica tal proposição.

Tabela 1 – Exemplo do método de ponderação da opinião dos especialistas (Fonte: Autores).

	Espec. 1	Espec. 2	Espec. 3	Soma	Percentual	Peso (w)
Espec. 1	0	1	1	2	66,67%	50%
Espec. 2	0	0	1	1	33,33%	33,33%
Espec. 3	-1	1	0	0	0%	16,67%
Total	-1	2	2	3	100%	100%

O próximo passo consiste em coletar as opiniões dos especialistas a respeito da variação da demanda. Isso deve ser feito com entrevistas individuais. O especialista deve fornecer dois palpites sobre a mudança na demanda em cada fator (em escala percentual): otimista e pessimista. Por exemplo, o fator promoção, na opinião do especialista 1, aumentará a demanda em 5% na pior das hipóteses, e 8% na melhor das hipóteses. Na sequência, calcula-se a média de ambos os cenários e multiplica-se este valor pelo peso w da opinião do especialista. Essa operação se repete para todos os especialistas e, após, são somados os resultados de cada um, obtendo o coeficiente de ajuste a do fator em questão. Esse processo é realizado para os outros fatores e, por fim, é realizada a soma de todos os coeficientes de ajuste a , obtendo o coeficiente de ajuste final a' . Dessa forma, a previsão de demanda P para período t é definida pela Equação (6):

$$P_t = F_t(1 + a') \quad (2)$$

onde P é a previsão ajustada, F é a previsão quantitativa e a' é o coeficiente de ajuste final.

3.5. Validação do método

A última etapa tem por objetivo avaliar o desempenho do método. Para tal, as previsões realizadas com o ajuste subjetivo são comparadas com a demanda real do período e com as previsões obtidas apenas com o método quantitativo. Com isso, é possível avaliar a importância da inclusão da experiência dos especialistas no ajuste da previsão de demanda.

4. Resultados

O presente trabalho foi aplicado em uma franquia de uma das maiores redes de *fast food* do mundo, localizada em Porto Alegre. O grupo que controla a loja possui outras três franquias da mesma rede no estado do Rio Grande do Sul.

A rede, por ter como foco a venda de sanduíches, trabalha com diferentes tipos de carnes. Entretanto, o hambúrguer é o produto vendido em maior escala: esse tipo de carne representa cerca de 80% da quantidade total de carne consumida na franquia; existem quatro tipos distintos de carne de hambúrguer utilizados nos sanduíches, sendo que um mesmo tipo pode compor diferentes sanduíches.

O processo de colocação de pedido, como é chamado na empresa, trata-se da compra de insumos para o restaurante. Esse processo ocorre quatro vezes por semana, onde existe uma pessoa responsável por indicar as quantidades a serem compradas em um *software* da rede de *fast food*. O custo dos insumos é a maior despesa da loja, representando aproximadamente 25% do valor do faturamento mensal, justificando a necessidade de se prever com maior precisão possível a demanda das vendas. Como a empresa não possuía nenhum processo formal de previsão de demanda, o objetivo deste trabalho foi aplicar o método de previsão de demanda proposto para algum produto do restaurante.

Através de entrevista ao responsável pelo processo de colocação de pedido, decidiu-se aplicar o método proposto em dois tipos de carne de hambúrguer (A e B). Os resultados, alinhados com as seções propostas no método, são apresentados na sequência.

4.1. Coleta de dados históricos de demanda e identificação de especialistas para ajuste subjetivo

Nesta etapa, foram coletados dados diários de consumo de carne de hambúrguer dos tipos A e B do banco de dados da rede de *fast food*. O período coletado compreende 75 dias (entre 01/07/2013 e 13/09/2013). Vale lembrar que o dado de consumo engloba, além da venda ao cliente, refeição para funcionários e desperdício.

Na sequência, três funcionários foram identificados para o fornecimento das informações qualitativas: o atual responsável pelo processo de colocação de pedido (Especialista 1) e outros dois funcionários que já atuaram nesta área (Especialista 2 e Especialista 3). Os critérios levados em conta na decisão foram a experiência do funcionário no setor e na

operação do restaurante, grau de escolaridade e familiaridade com previsão de demanda. Os especialistas selecionados apresentam as seguintes credenciais:

(i) *Especialista 1*: Pouco mais de seis meses na função. Foi contratado para fazer isso, uma vez que é graduando em Engenharia de Produção;

(ii) *Especialista 2*: Permaneceu um ano no cargo e saiu da empresa há cerca de seis meses. É formado em Engenharia de Produção; e

(iii) *Especialista 3*: Desempenhou a função por quatro anos; possui 14 anos de empresa e de contato com as operações da rede de *fast food*. Trabalha como gerente da cozinha do restaurante. Possui ensino médio completo.

4.2. Modelagem quantitativa

Inicialmente, geraram-se gráficos com os perfis de demanda diária das carnes, possibilitando a identificação de 10 dados considerados espúrios (associados a eventos atípicos e com pouca/nenhuma possibilidade de repetição no período de análise), os quais poderiam comprometer a previsão. Tais dados foram substituídos pela média da demanda daquele dia da semana em períodos passados (por exemplo, substituição de dados de uma sexta-feira atípica pela média das quatro semanas anteriores). Finalizado este processo, gerou-se um novo gráfico de demanda para cada tipo de carne, percebendo-se a existência da componente sazonal nos tipos A e B.

Por conta da componente sazonal, os seguintes modelos de previsão foram testados: Suavização Exponencial Sazonal de Holt-Winters aditiva e multiplicativa (HWA e HWM, respectivamente) e a Média Móvel (MM). Este último método representa, segundo Ritzman e Krajewski (2004), o cálculo da demanda média para os últimos n períodos que, por sua vez, será adotada como previsão para o próximo período. No presente trabalho serão utilizados dois e três períodos anteriores (MM2 e MM3, respectivamente). Embora não considerado um modelo recomendado para perfis com sazonalidade, a MM será testada por conta de sua ampla utilização em contexto prático de previsão de demanda.

Seguindo o método deste trabalho, que utiliza 80% dos dados para treino e 20% para teste, foram utilizados os 60 dados mais antigos para a primeira fase, onde será calculado o coeficiente de determinação R^2 . Os modelos HWA e HWM foram modelados pelo software *NCSS 6.0*, e MM2 e MM3 por planilha eletrônica. Os modelos de Média Móvel utilizaram os

mesmos dias da semana nas semanas anteriores, pois a demanda de uma quinta-feira, por exemplo, se assemelha mais com a da quinta-feira passada do que com o dia anterior (quarta-feira). Dessa forma, foi necessário coletar dados de três semanas antes do dia 01/07/2013. Para a fase de teste, onde foram utilizados os 15 dados restantes, foi calculado o MAPE de cada modelo com o auxílio de planilha eletrônica. Por fim, foi possível determinar os índices *I* para modelos testados, conforme a Tabela 2; o modelo responsável pelo maior *I* é recomendado para a realização da previsão.

Tabela 2 – Desempenho dos modelos de previsão de demanda para o hambúrguer do tipo A e tipo B (Fonte: Autores).

Hambúrguer Tipo A			
Modelo de previsão	<i>R</i>²	<i>MAPE</i>	<i>I (R²/MAPE)</i>
HWA	0,83	0,103	8,06
HWM	0,82	0,105	7,80
MM2	0,73	0,101	7,21
MM3	0,68	0,119	5,69
Hambúrguer Tipo B			
Modelo de previsão	<i>R</i>²	<i>MAPE</i>	<i>I (R²/MAPE)</i>
HWA	0,66	0,104	6,34
HWM	0,66	0,127	5,21
MM2	0,55	0,104	5,29
MM3	0,54	0,086	6,31

Conforme os dados da tabela, o modelo HWA apresentou melhor desempenho em termos de aderência aos dados e capacidade preditiva, sendo então utilizado para previsão dos próximos 14 dias (14/09/2013 a 27/09/2013). As Figuras 5 e 6 ilustram os gráficos com os dados históricos e o ajuste do HWA; os valores preditos para os 14 dias estão no apêndice (A3 e A4).

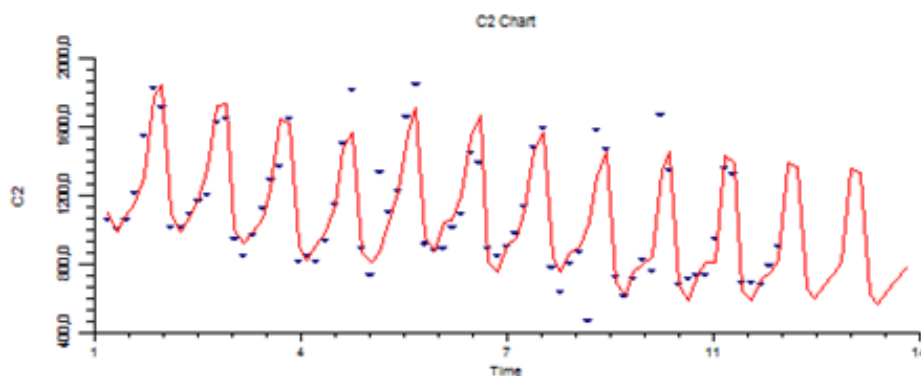


Figura 5 – Gráfico de previsão de demanda para hambúrgueres do tipo A gerado pelo NCSS 6.0 (Fonte: Autores)

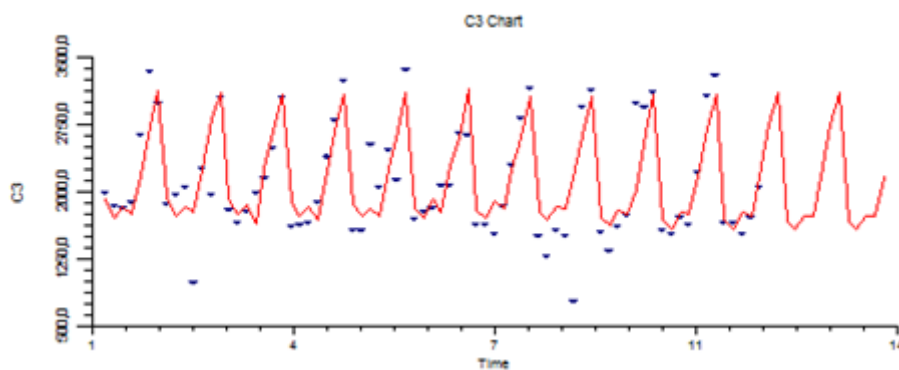


Figura 6 – Gráfico de previsão de demanda para hambúrgueres do tipo B gerado pelo NCSS 6.0 (Fonte: Autores)

4.3. Levantamento de fatores contextuais

Concluída a modelagem matemática da demanda, iniciou-se a parte qualitativa do trabalho. Para tal, foram reunidos os três especialistas com o objetivo de levantar fatores do contexto capazes de influir na venda dos hambúrgueres. A identificação de tais fatores visa a elencar atributos não presentes nos dados históricos modelados e que possam alterar a previsão sugerida pelo método quantitativo. Quatro fatores foram elencados:

Fator Promoção: No dia 14/09/2013 seria iniciada a promoção de um sanduíche que utiliza duas carnes do tipo B. Essa promoção substituiria um sanduíche produzido com um hambúrguer do tipo A. Dessa forma, os especialistas acreditam em uma variação para ambas.

Fator Reforma: O restaurante em análise entrou em reforma de suas acomodações no início de junho de 2013. Segundo os especialistas, as vendas reduziram daquela data até setembro.

Entretanto, agora a obra está em fase final e há menos transtorno para o consumidor, levando a crer na retomada do consumo normal.

Fator Outubro: Para os entrevistados, outubro é uma época de elevadas vendas devido ao Dia da Criança. Com a proximidade da data, a demanda pode aumentar nessa transição de mês.

Fator Clima: O clima interfere diretamente no movimento do restaurante, conforme os especialistas. Finais de semana com sol e calor atraem famílias para desfrutarem da infraestrutura que a loja possui para crianças, ao passo que dias chuvosos espantam clientes para os shoppings, por exemplo.

4.4. Ajuste Subjetivo

Na sequência, cada especialista avaliou seu colega em termos de experiência; objetiva-se ponderar sua opinião acerca da influência dos fatores sobre a demanda prevista. Visto que três especialistas foram consultados, o peso mínimo de sua opinião é de 16,67% (um terço de 50% da opinião geral). A Tabela 3 ilustra a avaliação, a ponderação dos 50% restantes da opinião geral e o peso final de cada entrevistado.

Tabela 3 – Avaliação entre especialistas e o peso final da opinião. (Fonte: Autores)

	Espec. 1	Espec. 2	Espec. 3	Soma	Percentual	Peso (w)
Espec. 1	0	-1	0	-1 (0)	0	16,67%
Espec. 2	1	0	1	2	50%	41,67%
Espec. 3	1	1	0	2	50%	41,67%
Total	-1	2	2	4	100%	100%

De forma separada, cada especialista quantificou a influência de cada fator sobre a demanda para as próximas duas semanas (apresentando um palpite otimista e um pessimista), medida em escala percentual. As médias de tais resultados são apresentadas na Tabela 4, e os valores individuais nos apêndices (A1 e A2).

Tabela 4 – Média entre os palpites dos especialistas (otimista e pessimista) para cada fator. (Fonte: Autores)

<i>Palpite especialistas</i>	Tipo A			Tipo B		
	Esp. 1	Esp. 2	Esp. 3	Esp. 1	Esp. 2	Esp. 3
Promoção	-40%	-38%	-18%	65%	63%	45%

Reforma	8%	10%	6%	8%	10%	12%
Outubro	3%	0%	6%	3%	0%	6%
Clima	0%	-4%	0%	0%	-4%	5%

O palpite de cada especialista foi multiplicado pelo peso w de seu palpite e então feito um somatório deste resultado para cada fator, encontrando os coeficientes de ajuste de cada fator j para cada tipo de hambúrguer i (a_{ij}), onde $i=1$ e $i=2$ representam, respectivamente, os hambúrgueres do tipo A e tipo B. A Tabela 5 indica o cálculo.

Tabela 5 – Peso (w) x Opinião (% da Tabela 4) e os coeficientes de ajuste de cada fator. (Fonte: Autores)

Coef. de ajuste		Tipo A				Tipo B			
j	Fator	Esp. 1	Esp. 2	Esp. 3	a_{1j}	Esp. 1	Esp. 2	Esp. 3	a_{2j}
1	Promoção	-6,7%	-15,6%	-7,3%	-29,6%	10,8%	26,0%	18,8%	55,6%
2	Reforma	1,3%	4,0%	2,5%	7,7%	1,3%	4,0%	4,8%	10,0%
3	Outubro	0,5%	0,0%	2,5%	3,0%	0,5%	0,0%	2,5%	3,0%
4	Clima	0,0%	-1,5%	0,0%	-1,5%	0,0%	-1,5%	2,1%	0,6%

A soma dos coeficientes de ajuste a_{1j} e a_{2j} resulta nos coeficientes de ajuste final a'_1 e a'_2 , respectivamente, onde o primeiro representa hambúrgueres do tipo A e o segundo hambúrgueres do tipo B.

$$a'_1 = \sum_{j=1}^4 a_{1j} = -29,6\% + 7,7\% + 3\% - 1,5\% = -20,3\% = -0,203$$

$$a'_2 = \sum_{j=1}^4 a_{2j} = 55,6\% + 10\% + 3\% + 0,6\% = 69,3\% = 0,693$$

Dessa forma, a previsão realizada pelo modelo HWA deve ter sua previsão alterada segundo a Equação (2), que representa a previsão ajustada de hambúrgueres do tipo A,

$$P_{t1} = F_{t1}(1 - 0,203)$$

e do tipo B,

$$P_{t2} = F_{t2}(1 + 0,693).$$

Por fim, foi feita a comparação entre as previsões puramente quantitativas (HWA) e as geradas pelo método proposto frente à demanda real verificada no período analisado (14 dias subsequentes). As Figuras 7 e 8 e a Tabela 6 mostram os resultados. Os valores reais foram multiplicados por um coeficiente aleatório a fim de manter o sigilo dos dados, devido a uma exigência da empresa. As tabelas com o comparativo dos valores individuais estão nos apêndices (A3 e A4).




Figura 7 – Comparativo entre a demanda real, o HWA e o método proposto para o hambúrguer do tipo A.

(Fonte: Autores)




Figura 8 – Comparativo entre o consumo real, o HWA e o método proposto para o hambúrguer do tipo B.

(Fonte: Autores)

Tabela 6 – Comparativo da média do erro percentual para o consumo real entre o modelo matemático e o método proposto. (Fonte: Autores)

<i>Erro percentual para o consumo real</i>		
Tipo de hambúrguer	HWA	Método Proposto
A	38%	10%
B	-37%	7%

Pelos gráficos de comparação e pela tabela de erro percentual, percebe-se o aumento na acurácia da previsão de consumo para ambos os hambúrgueres pelo método proposto: o erro percentual médio do método proposto chega até 7% quando comparado à demanda real verificada no período, ao passo que a previsão puramente quantitativa (HWA) gera desvios na casa dos 38%. Os fatores Reforma, Outubro e Clima oferecem contribuição moderada para a modificação; o fator Promoção, no entanto, tem papel fundamental nessa mudança ocorrida exatamente no dia 14/09/2013, quando houve a troca de promoção entre o sanduíche com carne tipo A para o outro com carne tipo B.

5. Considerações finais

Neste artigo foi proposto um método de previsão de demanda utilizando modelagem quantitativa ajustada com base em fatores qualitativos. Para testar sua eficácia, o mesmo foi aplicado em um restaurante *fast food*, onde foram comparadas as previsões de um modelo puramente quantitativo com as do método proposto; a acurácia dos resultados do segundo foi significativamente maior. Dessa forma, concluiu-se que a influência de fatores contextuais qualitativos não inclusos na base de dados do modelo matemático impactam significativamente as previsões.

Neste estudo, os especialistas foram essenciais para uma previsão de demanda mais precisa. Seu conhecimento acerca do processo de compra de insumos e dos fatores que influenciam o consumo de carnes proveram informações não existentes nos bancos de dados modelados, justificando a importância de mesclar modelos matemáticos com subjetivismo.

Para a escolha dos especialistas, foram consideradas qualificações como experiência, escolaridade e tempo de empresa. Para realizar o ajuste baseado na opinião dos especialistas (Ajuste Subjetivo) foram feitas ponderações em seus palpites (para que o funcionário com melhor qualificação tivesse opinião mais relevante). Como resultado do ajuste, foi obtido um

erro máximo de 10% frente à demanda real, enquanto que o modelo matemático isolado incorreu em erro de até 38%.

Desdobramentos futuros incluem uma análise mais aprofundada na parte qualitativa do método, uma vez que o objetivo deste trabalho foi validar a importância da inclusão dos fatores contextuais. Sugere-se a adoção de métodos formais de entrevistas para a caracterização mais aprofundada do problema. Ainda, a abordagem deste trabalho poderia ser aprimorada com a modificação do horizonte de previsão, buscando esmiuçar o tempo em horas, separando os horários de pico de movimento no restaurante, por exemplo.

APÊNDICE

A1. Opinião pessimista dos especialistas.

<i>Pior hipótese</i>	Tipo A			Tipo B		
Fator	Esp. 1	Esp. 2	Esp. 3	Esp. 1	Esp. 2	Esp. 3
Promoção	-50%	-45%	-25%	60%	55%	40%
Reforma	5%	7%	5%	5%	7%	8%
Outubro	2%	0	5%	2%	0	5%
Clima	-5%	-12%	-10%	-5%	-12%	-5%

A2. Opinião otimista dos especialistas.

<i>Melhor hipótese</i>	Tipo A			Tipo B		
Fator	Esp. 1	Esp. 2	Esp. 3	Esp. 1	Esp. 2	Esp. 3
Promoção	-30%	-30%	-10%	70%	70%	50%
Reforma	10%	12%	7%	10%	12%	15%
Outubro	4%	0	7%	4%	0	7%
Clima	5%	5%	10%	5%	5%	15%

A3. Comparativo de previsões entre o HWA e o método proposto para os 14 dias extrapolados (tipo A).

Data	Consumo Real	HWA	Divergência do real	Método proposto	Divergência do real
14/set	232	348	50%	277	20%
15/set	202	343	70%	273	35%
16/set	113	164	46%	131	16%
17/set	114	151	33%	120	6%
18/set	126	171	36%	137	9%

19/set	141	188	33%	150	6%
20/set	181	205	13%	163	-10%
21/set	217	340	57%	271	25%
22/set	212	335	58%	267	26%
23/set	117	156	34%	124	7%
24/set	106	143	35%	114	8%
25/set	128	163	28%	130	2%
26/set	139	180	30%	143	3%
27/set	178	197	11%	157	-12%
Média	157	220	38%	175	10%

A4. Comparativo de previsões entre o HWA e o método proposto para os 14 dias extrapolados (tipo B).

Data	Real	HWA	Divergência do real	Método proposto	Divergência do real
14/set	755	691	-8%	1169	55%
15/set	1130	778	-31%	1316	17%
16/set	589	420	-29%	711	21%
17/set	712	398	-44%	674	-5%
18/set	747	433	-42%	733	-2%
19/set	751	435	-42%	736	-2%
20/set	912	541	-41%	915	0%
21/set	1080	691	-36%	1169	8%
22/set	1192	778	-35%	1316	10%
23/set	622	420	-33%	711	14%
24/set	739	398	-46%	674	-9%
25/set	749	433	-42%	733	-2%
26/set	760	435	-43%	736	-3%
27/set	916	541	-41%	915	0%
Média	832	528	-37%	893	7%

REFERÊNCIAS

ANDERSSON, P.; GSCHWEND, T.; MEFFERT, M. F.; SCHMIDT, C. **Forecasting the outcome of a national election: the influence of expertise, information, and political preferences**. Paper presented at the 2006 annual meeting of the International Communication Association, Dresden, Germany, June 19 – 23, 2006. Acesso em: <http://www.sowi.uni-mannheim.de/gschwend/pdf/papers/ICA2006-Forecast.pdf>

ANSEL, D.; DYER, C. **A framework for restaurant information technology**. The Cornell Hotel and Restaurant Administration Quarterly. v.40, n. 3, p. 74, jun, 1999.

ARMSTRONG, J. S. **Strategic Planning and Forecasting Fundamentals**. Em: ALBERT, K. The Strategic Management Handbook. New York: McGraw Hill, 1983.

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

ARMSTRONG, J. S.; COLLOPY, F. **Integration of statistical methods and judgment of time series: principles of empirical research**. In: WRIGHT, H.; GOODWIN, P. Forecasting with Judgment. Wiley and Sons. 1998.

BUNN, D. W.; SALO, A. A. **Forecasting with scenarios**. European Journal of Operational Research. v. 68, p. 291-303, 1993.

CHOI, J. G. The restaurant industry: business cycle, strategic financial practices, **economic indicators and forecasting**. Dissertation submitted to the Faculty of the Virginia Polytechnic Institute and State University. 1999.

CORRÊA, H. L.; CORRÊA, C. A. **Administração da produção e de operações**. Edição compacta. São Paulo: Atlas, 2005.

CRANAGE, D. A. **Practical times series forecasting for the hospitality manager**. International Journal of Contemporary Hospitality Management. p. 86, fev, 2003.

CRANAGE, D. A.; ANDREW, W. P. **A comparison of time series and econometric models for forecasting restaurant sales**. International Journal of Hospitality Management. v. 11, n. 2, p. 129-142, 1992.

DA SILVA; E. D.; MENEZES, E. M. **Metodologia da Pesquisa e Elaboração de Dissertação**. 4. ed. rev. atual. Florianópolis: UFSC, 2005.

DAVIS, M. M.; AQUILANO, N. J.; CHASE, R. B. **Fundamentals of operations management**. 4 ed. Boston: McGraw-Hill Irwin, 2003.

DAVYDENKO, A.; FILDES, R. **Measuring forecasting accuracy: The case of judgmental adjustments to SKU-level demand forecasts**. International Journal of Forecasting. 2013. IN PRESS.

DURU, O.; BULUT, E.; YOSHIDA, S. **A fuzzy extended DELPHI method for adjustment of statistical time series prediction: An empirical study on dry bulk freight market case.** Expert Systems with Applications. v. 39, p. 840-848, 2012.

ELSAYED, E. A.; BOUCHER, T. O. **Analysis and control of production systems.** New Jersey: Prentice Hall, 1985.

EROGLU, C.; CROXTON, K. L. **Biases in judgmental adjustments of statistical forecasts: The role of individual differences.** International Journal of Forecasting. v. 26, p. 116–133, 2010.

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

FLORES, B. E.; OLSON, D. L.; WOLFE, C. **Judgmental adjustment of forecasts: A comparison of methods.** International Journal of Forecasting. v. 7, p. 421–433, 1992.

FORREST, D.; SANZ, I.; TENA, J. D. **Forecasting national team medal totals at the Summer Olympic Games.** International Journal of Forecasting. v. 26, p. 576–588, 2010.

GOODWIN, P; FILDES, R.; LAWRENCE, M.; NIKOLOPOULOS, K. **The process of using a forecasting support system.** International Journal of Forecasting. v. 23, p. 391-404, 2007.

GOODWIN, P; WRIGHT, G. **The limits of forecasting methods in anticipating rare events.** International Journal of Forecasting. v. 77, p. 355-368, 2010.

LAWRENCE, M.; GOODWIN, P; O'CONNOR M.; ÖNKAL, D. **Judgmental forecasting: A review of progress over the last 25 years.** International Journal of Forecasting. v. 22, p. 493-518, 2006.

LIU, L. M.; BHATTACHARYYA, S.; SCLOVE, S. L.; CHEN, R.; LATTYAK, W. J. **Data mining on time series: an illustration using fast-food restaurant franchise data.** Computational Statistics & Data Analysis. p. 455-476, 2001.

MACHADO, M. D.; QUEIROZ, T. R.; MARTINS, M. F. **Mensuração da qualidade de serviços em empresas de *fast food*.** Revista Gestão & Produção. v. 13, n. 2, p. 261-270, maio, 2006.

MAKRIDAKIS, S. **Metaforecasting: ways of improving forecasting accuracy and usefulness.** International Journal of Forecasting. v. 4, n. 3, p. 467-491, 1988.

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

MATHEWS, P.; DIAMANTOPOULOS, A. **Managerial intervention in forecasting: an empirical investigation manipulation.** International Journal of Research in Marketing. v. 3, p. 3-10, 1986.

MOON, M. A.; MENTZER, J. T.; SMITH, C. D.; GARVER, M. S. **Seven keys to better forecasting.** Business Horizons. p. 44-52, set-out, 1998.

ÖNKAL, D.; YATES, J. G.; SIMGA-MUGAN, C.; ÖZTIN, S. **Professional vs. Amateur judgment accuracy: the case of foreign exchange rates.** Organizational Behavior and Human Decision Processes. v. 91, p. 169-185, 2003.

PELLEGRINI, F. R. **Metodologia para a implementação de sistemas de previsão de demanda.** Dissertação de mestrado submetida ao Programa de Pós-Graduação em Engenharia de Produção. Universidade Federal do Rio Grande do Sul. 2000.

REIMERS, S.; HARVEY, N. **Sensitivity to autocorrelation in judgmental time series forecasting.** International Journal of Forecasting. v. 27, p. 1196-1214, 2011.

REYNOLDS, D.; RAHMAN, I.; BALINBIN, W. **Econometric modeling of the U.S. restaurant industry.** International Journal of Hospitality Management. v. 34, p. 317-323, 2013.

RITZMAN, L. P.; KRAJEWSKI, L. J. **Administração da Produção e Operações.** Tradução Roberto Galman. Revisão técnica Carlos Eduardo Mariano da Silva. São Paulo: Pearson Prentice Hall, 2004.

SANDERS, N. R. **Accuracy of judgmental forecasts: a comparison.** Omega. v. 20, n. 3, p. 353-364, 1992.

SANDERS, N. R.; MANRODT, K. B. **The efficacy of using judgmental versus quantitative forecasting methods in practice.** Omega. v. 31, p. 511-522, 2003.

SANDERS, N. R.; RITZMAN, L. P. **Integrating judgmental and quantitative forecasts: methodologies for pooling marketing and operations information.** International Journal of Operations e Production Management. v. 25, n. 5, p. 514-529, 2004.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Administração da Produção.** Tradução Henrique Luiz Corrêa. 3ª ed. São Paulo: Atlas, 2009.

SONG, C.; BOULIER, B. L.; STEKLER, H. O. **The comparative accuracy of judgmental and model forecasts of American football games.** International Journal of Forecasting. v. 23, p. 405-413, 2007.

SONG, H.; GAO, B. Z.; LIN, V. S. **Combining statistical and judgmental forecasts via a web-based tourism demand forecasting system.** International Journal of Forecasting. v. 29, p. 295-310, 2013.

TUBINO, D. F. **Manual de planejamento e controle da produção.** 2ª ed. São Paulo: Atlas, 2000.

WEBBY, R.; O'CONNOR, M. **Judgemental and statistical time series forecasting: a review of literature.** International Journal of Forecasting. v. 12, p. 91-118, 1996.

WERNER, L.; RIBEIRO, J. L. D. **Modelo composto para prever demanda através da integração de previsões.** Revista Produção. v. 16, n. 3, p. 493-509, set/dez, 2006.

WOLF, C.; FLORES, B. **Judgemental adjustment of earnings forecasts.** International Journal of Forecasting. v. 9, p. 380-405, 1990.

WRIGHT, G.; LAWRENCE, M. J.; COLLOPY, F. **The role and the validity of judgment in forecasting.** International Journal of Forecasting. v. 12, p. 1-8, 1996.