

A ACURACIDADE DOS MODELOS DE PREVISÃO DE DEMANDA COMO FATOR CRÍTICO PARA O DESEMPENHO FINANCEIRO NA INDÚSTRIA DE ALIMENTOS

Cassia Rita Pereira da Veiga

Mestranda do Programa de Pós-graduação em Administração Estratégica

Pontifícia Universidade Católica do Paraná (PUCPR), Brasil

cassia.veig@gmail.com

Claudimar Pereira da Veiga

Mestre em Engenharia de Produção e Sistemas

Pontifícia Universidade Católica do Paraná (PUCPR), Brasil

claudimar.veiga@gmail.com

Luiz Carlos Duclós

Ph.D. em Computer Applications in Industrial and Systems Engineering

University of Southern California (USC), Los Angeles, EUA

Luiz.duclos@pucpr.br

RESUMO

Toda organização precisa saber dimensionar suas capacidades produtivas de modo que estas se encaixem perfeitamente com as demandas. O papel da previsão de demanda é fornecer subsídios para o planejamento estratégico da organização. Este processo permite que os administradores antecipem o futuro e planejem de forma mais conveniente as suas ações. Não basta, entretanto, ter um sistema de previsão de demanda. É a qualidade da informação obtida por este sistema que capacita a organização a obter melhor planejamento das operações. Dentro deste contexto, este trabalho apresenta um estudo de caso com os objetivos de: (a) definir o modelo quantitativo de previsão de demanda de maior grau de acurácia e (b) verificar a influência da acuracidade da previsão de demanda no desempenho financeiro da organização. Trata-se de uma pesquisa descritiva *ex-post fact* em que foram utilizados dados históricos de demanda de cinco grupos de produto, no período de 2004 a 2008. Os resultados demonstram que se a empresa empregasse o modelo ARIMA para os grupos A, B e E, o

modelo de Holt para o grupo D e o modelo de Winter para o grupo C, o faturamento poderia ser aumentado em, aproximadamente, dois milhões e oitocentos mil reais anuais.

Palavras chave: Acurácia. Previsão de demanda. Desempenho financeiro.

THE ACCURACY OF DEMAND FORECAST MODELS AS A CRITICAL FACTOR IN THE FINANCIAL PERFORMANCE OF THE FOOD INDUSTRY

ABSTRACT

Every organization needs to balance their production capacities with their demands. The role of demand forecasting is to provide subsidies for the organization's strategic planning. This process allows administrators to anticipate the future and plan their actions more conveniently. However, it is not enough has a system of demand forecasting. It is the quality information obtained by this system which enables the organization to achieve better planning of operations. In this context, this paper presents case study research to: (a) define the quantitative model to forecast demand for greater accuracy and (b) to verify the influence of the accuracy in demand forecasting on the financial performance. This is an *ex-post facto* descriptive inquiry with a time series in which we made use of historical data from five groups of products from 2004 to 2008. The results suggest that if the company employing the ARIMA model for groups A, B and E, the Holt model for group D and Winter model for the C group, revenues could be increased by approximately one million six hundred thousand dollars annually.

Key-words: Accuracy. Demand forecasting. Financial performance.

1 INTRODUÇÃO

Algumas alterações ocorridas no âmbito econômico e político no Brasil nas últimas décadas obrigaram as empresas a explorarem soluções geradoras de renda, essenciais para a manutenção do próprio negócio. Para alcançar vantagem competitiva em um ambiente de constantes flutuações, a organização deve tomar decisões certas, em tempo adequado e com base em informações de qualidade. Neste sentido, a previsão de demanda representa uma importante ferramenta gerencial estratégica para a tomada de decisão.

Para DeLurgio (1998) existem basicamente três tipos de métodos de previsão: qualitativo e quantitativo, sendo este último dividido em séries temporais e modelos multivariados (causais). As técnicas quantitativas utilizam procedimentos especificados e sistemáticos, enquanto que as qualitativas envolvem aspectos como intuição, julgamento pessoal e experiências. Na prática, a previsão de demanda é comumente utilizada em organizações que operam em mercados de consumo. Quando os padrões da demanda variam pouco, a previsão de demanda pode ser realizada apenas com base na demanda histórica aliada à intuição pessoal do gestor. Em ambientes mais voláteis, este método não prediz a necessidade futura de maneira adequada, então, a aplicação de modelos quantitativos de previsão de demanda assume um papel primordial.

Queiroz e Cavalheiro (2003) descrevem que a indústria de alimentos constitui um setor representativo na economia nacional e, como em outros segmentos, precisa planejar sua produção, cujos produtos são sensíveis à sazonalidade de oferta e de demanda, perecíveis e de acentuada diversidade. Toda organização precisa, de alguma forma, saber dimensionar suas capacidades produtivas de modo que estas se encaixem perfeitamente com as demandas. Seja em uma empresa de alimentos ou em outro segmento, o papel das previsões é fornecer subsídios para o planejamento estratégico da organização. Neste contexto, a previsão permite que os administradores antecipem o futuro e planejem de forma mais conveniente as suas ações.

Não basta, entretanto, ter um sistema de previsão de demanda na organização. É a qualidade da informação obtida por este sistema que capacita a organização a obter melhor planejamento de suas operações. Para Kuo e Xue (1999), obter uma previsão de demanda precisa é o ponto crítico da qualidade do processo decisório. A previsão tenta calcular e predizer uma circunstância futura providenciando a melhor avaliação da informação comercial disponível.

A acuracidade da previsão tem uma influência direta no nível de serviço oferecido ao consumidor, no nível de estoque de segurança e no custo total da cadeia de suprimentos. Se uma previsão é mais acurada significa que a produção pode antecipar melhor a demanda do cliente (Meijden, Nunen & Ramondt, 1994). Ao contrário, uma previsão inadequada pode comprometer os resultados da cadeia de suprimentos e gerar três situações: *stockouts* (não atendimento de demanda), *backlogs* (demanda atendida com atraso) e/ou excesso de estoque. Estas situações, além de aumentar os custos do produto, comprometem o fluxo de caixa e a rentabilidade do negócio.

No mundo altamente competitivo de hoje, o balanço entre falha e sucesso é tão fino que a sobrevivência depende significativamente da qualidade da informação que molda as decisões gerenciais. Finne (2000) descreve o processo sequencial para que os dados de uma organização produzam ações: o homem processa dados para produzir a informação, e a informação para produzir conhecimento.

O conhecimento, por sua vez, é utilizado para a tomada de decisão que gera a ação final. Desta forma, as informações obtidas pela utilização de modelos quantitativos específicos providenciam suporte para a decisão gerencial e auxiliam nas atividades de departamentos ou áreas funcionais. Martinsons, Davidson e Tse (1999) afirmam que na "era da informação", as companhias precisam da tecnologia para garantir eficiência na produção e na entrega de seus produtos e serviços.

É difícil mensurar os custos gerados pelo erro de previsão, assim como encontrar no mercado um modelo que assimile adequadamente as particularidades do funcionamento de cada empresa. Portanto, diante de diferentes possibilidades de métodos de previsão, torna-se necessário identificar por índices de desempenho qual a metodologia mais adequada para cada caso. Surgem, neste ponto, as duas preocupações centrais deste estudo: (a) qual o modelo quantitativo de previsão de demanda de maior acurácia para 5 grupos de produto do portfólio de uma empresa de alimentos? (b) qual a influência da acuracidade da previsão de demanda no desempenho financeiro da organização?

Para definir o objetivo deste trabalho, recorreremos ao mapa estratégico recortado da organização em estudo, demonstrado na Figura 1. Um mapa estratégico é uma ilustração da estratégia da organização, ou seja, uma representação visual das relações de causa-efeito entre os componentes-chave da estratégia de uma organização. Através do mapa estratégico, é possível

visualizar como diferentes partes de uma organização contribuem direta ou indiretamente para o desempenho como um todo (Buytendijk, Hatch, & Micheli, 2010).

A Figura 1 demonstra a relação de causa efeito entre a acuracidade da previsão, a responsividade da demanda e o faturamento da empresa. Esta ilustração destaca que a acuracidade do método de previsão de demanda empregado é um fator crítico e exerce grande influência no desempenho financeiro da empresa. Pelas medidas de acuracidade da previsão, o administrador consegue analisar se a organização está cumprindo com as estratégias planejadas, além de propiciar a oportunidade de antecipar informações, de promover reduções nos custos da cadeia de suprimentos e melhorias na responsividade do cliente.

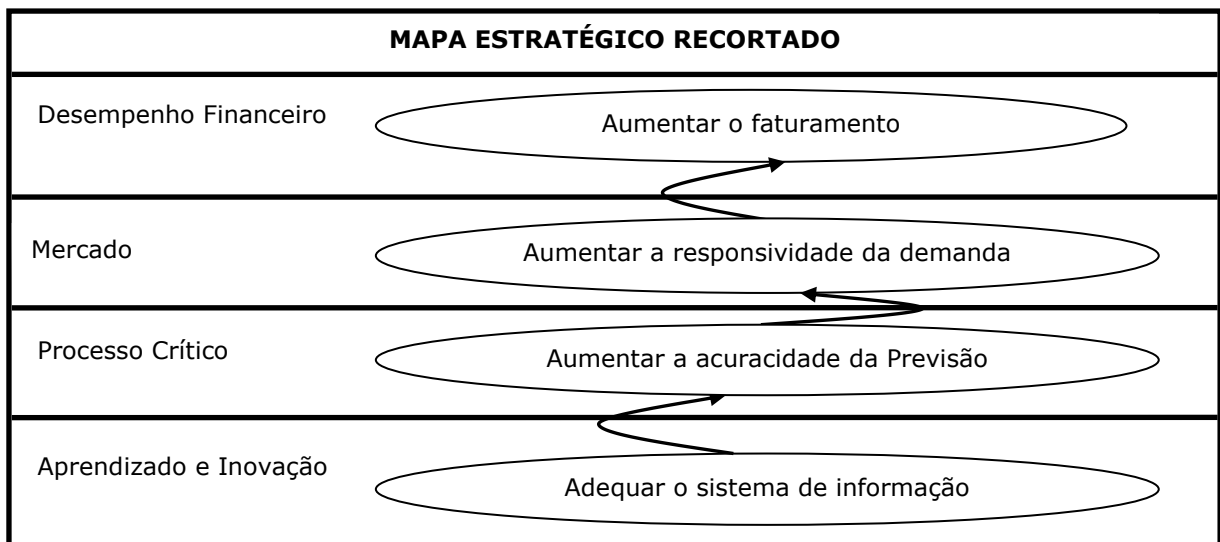


Figura 1: Mapa estratégico recortado para a organização em estudo

Fonte: Adaptado de Duclós e Santana (2009)

Neste contexto, o objetivo do presente trabalho é determinar o método de previsão de demanda que apresenta maior grau de acurácia em comparação ao atual método utilizado pela empresa. Os resultados desta análise servirão como subsídio para avaliar a influência dos erros de previsão de demanda no desempenho financeiro da empresa, utilizando o *fill rate* como indicador do nível de serviço oferecido ao consumidor, assim como do custo de oportunidade em resposta à demanda. O estudo será conduzido em cinco grupos de produtos do portfólio de uma empresa de alimentos perecíveis, com dados históricos de demanda abrangendo o período de 2004 a 2008.

2 REFERENCIAL TEÓRICO

A previsão é uma estimativa probabilística ou descrição de um valor ou condição futura. A previsão inclui uma média, uma variação dentro de certos limites e uma estimativa probabilística da variação. Existem muitos diferentes métodos que podem ser utilizados na previsão, entretanto, o conceito básico da grande maioria é o mesmo: os padrões de comportamento do passado continuarão no futuro, ou seja, assume-se que as vendas de um período de tempo passado serão equivalentes às vendas de um período correspondente no futuro. No geral, quase todos os métodos de previsão se fundamentam na ideia central de que o passado se repetirá (Morettin & Toloi, 1987; DeLúrgio, 1998; Makridakis, wheelwright & Hyndman, 1998; Chopra & Meindl, 2003).

Praticamente todas as empresas, sejam elas de pequeno, médio ou grande porte, estatais, nacionais privadas ou multinacionais, necessitam planejar seus recursos de produção, distribuição e compra de insumos ou serviços em face às condições futuras incertas. Além disso, a necessidade por previsão de demanda é comum em uma empresa, tanto no âmbito macro, quanto no âmbito dos seus departamentos funcionais (*marketing*, produção, vendas, logística e financeiro). A previsão de demanda é um elemento fundamental no processo de tomada de decisão. Existem pelo menos 70 técnicas diferentes para previsão quantitativa de demanda (Kerkanen, Korpela & Huiskonen, 2009).

O Quadro 1 descreve os dois modelos quantitativos utilizados neste estudo que não consideram tendência e/ou sazonalidade contidas na série temporal.

MODELOS	FÓRMULA	APLICACÃO
Médias Móveis Simples (MMS)	$M_t = \frac{Z_t + Z_{t-1} + \dots + Z_{t-r+1}}{r}$ <p> M_t = estimativa do nível Z_t = dado de cada período r = media dos períodos (Makridakis et al., 1998; Faria et al., 2008; DeLúrgio, 1998; Camargo & Amarante, 1999) </p>	Para demanda sem tendência ou sazonalidade. Método simples, de fácil implantação.
Suavização Exponencial Simples	$\bar{Z}_t = \alpha \bar{Z}_t + \alpha(1 - \alpha) \bar{Z}_{t-1} + \alpha(1 - \alpha)^2 \bar{Z}_{t-2} + \dots$ <p> \bar{Z}_t = valor exponencial suavizado α = constante de suavização (Souto et al., 2006; Martinez & Zamprogno 2003; Taylor, 2007; (Baldeon & Russo, 2006) </p>	Para demanda sem tendência ou sazonalidade. Utiliza ajuste no erro da última previsão.

Quadro 1: Características dos modelos quantitativos que não consideram tendência e/ou sazonalidade contidas na série temporal

Fonte: Faria et al., 2008; DeLúrgio, 1998; Camargo & Amarante, 1999; Souto et al., 2006; Martinez & Zamprogno, 2003; Taylor, 2007; Baldeon & Russo, 2006

O Quadro 2 demonstra os três modelos quantitativos utilizados neste estudo que abrangem a tendência e/ou sazonalidade contidas na série temporal.

MODELOS	FÓRMULA	APLICAÇÃO
Modelo de Holt	$L_{t+1} = \alpha D_{t+1} + (1 - \alpha) (L_t + T_t)$ $T_{t+1} = \beta(L_{t+1} - L_t) + (1 - \beta)T_t$ $L_t = \text{estimativa do nível do período } t$ $L_{t+1} = \text{estimativa do nível do período } t+1$ $T_t = \text{estimativa de tendência do período } t$ $T_{t+1} = \text{estimativa de tendência do período } t+1$ $D_{t+1} = \text{demanda real observada no período } t+1$ $\alpha = \text{constante de suavização para o nível}$ $\beta = \text{constante de suavização para a tendência}$ (Delurgio, 1998; Holt, 2004; Martinez & Zamprogno, 2003)	Para demanda que apresenta tendência. Requer a utilização de pacotes
Modelo de Winter	$L_{t+1} = \alpha (D_{t+1}/S_{t+1}) + (1 - \alpha) (L_t + T_t)$ $T_{t+1} = \beta(L_{t+1} - L_t) + (1 - \beta)T_t$ $S_{t+p+1} = \gamma (D_{t+1}/L_{t+1}) + (1 - \gamma)S_{t+1}$ $L_t = \text{estimativa do nível do período } t$ $L_{t+1} = \text{estimativa do nível do período } t+1$ $T_t = \text{estimativa de tendência do período } t$ $T_{t+1} = \text{estimativa de tendência do período } t+1$ $S_{t+1} = \text{estimativa do fator de sazonalidade } t+1$ $S_{t+p+1} = \text{estimativa do fator de sazonalidade } t+p+1$ $D_{t+1} = \text{demanda real observada no período } t+1$ $\alpha = \text{constante de suavização para o nível}$ $\beta = \text{constante de suavização para a tendência}$ $\gamma = \text{constante de suavização para a sazonalidade}$ (Delurgio, 1998; Baldeon & Russo, 2006; Segura & Vercher, 2001).	Para demanda que apresenta tendência e/ou sazonalidade. Facilidade de interpretação dos índices de sazonalidade e entendimento gerencial. Pode se adequar a eficientes algoritmos
Modelo ARIMA	$\phi(B)[(1-B)^d y_t - \mu] = \theta(B)u_t$ $\phi = \text{parâmetros autorregressivos}$ $\theta = \text{parâmetro médias móveis}$ $\phi(B) = \text{polinômio de AR}$ $\theta(B) = \text{polinômios MA}$ (Box, Jenkins & Reinesl, 1994; (Zang, 2003)	Para séries temporais que apresentam autocorrelação. Difícil operacionalização. Requer programas

Quadro 2: Características dos modelos quantitativos que consideram tendência e/ou sazonalidade contidas na série temporal

Fonte: Delúrgio, 1998; Martinez e Zamprogno, 2003; Baldeon e Russo, 2006; Holt, 2004; Segura e Vercher, 2001; Box, Jenkins e Reinesl, 1994; Zang, 2003

Estes métodos quantitativos geralmente empregam séries temporais. Uma série temporal é uma seleção de dados numéricos obtidos de períodos regulares de tempo, ou seja, um conjunto de observações ordenadas no tempo. O principal objetivo da análise de séries temporais é investigar o mecanismo gerador de dados, descrever seu comportamento através da construção de gráficos para verificação da existência de tendência, ciclos e variações sazonais (Martinez & Zamprogno, 2003).

Em modelos temporais, toda demanda observada pode ser desmembrada em um componente sistemático e um aleatório. Pelo componente sistemático tem-se o valor esperado de demanda. O componente aleatório, por sua vez, é a parte da previsão desviada da parte sistemática, ou seja, abrange a medida de erro de uma previsão. O objetivo da previsão é eliminar o componente aleatório e estimar o componente sistemático. Portanto, o erro de uma previsão mede a diferença entre a previsão de demanda e a demanda real (Chopra & Meindl, 2003).

Uma previsão de demanda seria perfeita se o erro de previsão fosse zero. Se o erro aumenta de zero para um valor positivo, o custo total, a instabilidade da programação de produção e o nível de serviço aumentam (Xie, Lee & Zhao, 2004). Um viés positivo usualmente melhora o nível de serviço do sistema porque gera melhor uso da capacidade e produz uma quantidade de produtos maior que a necessária. Nesta situação, o custo de uma unidade faltante é reduzido, mas os custos associados com o nível de inventário, assim como o custo total, se elevam acentuadamente.

Quando ocorre um viés negativo, o custo total aumenta enquanto o nível de serviço diminui. Isto ocorre porque o sistema produz uma quantidade menor de produtos do que é realmente necessária. Nesta situação, o nível de serviço é reduzido e o custo de uma unidade faltante aumenta acentuadamente (Xie et al., 2004). Estas observações revelam que a acurácia da previsão de demanda pode melhorar significativamente o desempenho do sistema de produção, com redução dos custos totais e adequação dos níveis de serviço.

Existem diferentes causas para erros de previsão de demanda. Para tornar a situação ainda mais complexa, estas causas podem coexistir e mudam dependendo das condições intrínsecas à organização, da metodologia empregada e das variações de mercado e produto. A literatura descreve várias medidas de erro para a previsão de demanda, entretanto, uma das medidas mais populares é o erro percentual médio absoluto (MAPE). Analisar a acuracidade de uma previsão requer, inicialmente, definir o fluxo de planejamento entre valor previsto e real. Em seguida, deve-se analisar o papel das informações da demanda no processo de planejamento. Em adição, deve-se entender como as previsões são produzidas, quais são as fontes mais substanciais de erro e como estas fontes podem ser afetadas (Kerkanen et al., 2009).

O Instituto Internacional de Previsões foi estabelecido há aproximadamente 30 anos e tem a função de avaliar o progresso de previsões realizadas em séries temporais. Dentro deste período, vários métodos quantitativos de previsão de demanda foram aplicados e comparados em situações diversas, em produtos e mercados específicos. Embora diversos estudos comparativos tenham sido descritos na literatura, as conclusões não sugerem quais condições tornam um método melhor do que outro. Por isso, situações de complexidade, sazonalidade e perecibilidade, como ocorrem no mercado de alimentos, ainda exigem estudos investigativos sobre o método de previsão mais adequado para cada condição de estudo.

Os trabalhos publicados referentes à previsão de demanda já analisaram diversos produtos, tais como cerveja (Calôba, Calôba & Saliby, 2002), leite fresco (Doganis, Alexandridis, Patrinos & Sarimveis, 2006) e outros produtos perecíveis (Higuchi, 2006), varejo de alimentos (Zotteri; Kalchschmidt & Caniato, 2005), assinante de *wireless* (Venkatesan & Kumar, 2002), vendas em supermercados (Taylor, 2007), número de nascimentos (Souto, Baldeon & Russo, 2006), produtos plásticos (Pellegrini & Fogliatto, 2000), previsão de preço (Medeiros, Montevechi, Rezende & Reis, 2006), análise de indicadores do mercado de ações (Faria, Albuquerque, Alfonso, Albuquerque & Cavalcante, 2008), entre outros.

Para a indústria de alimentos, em especial, poucos estudos foram publicados até agora. Além disso, a maioria destes trabalhos envolve uma análise do mercado de alimentos em outros países, tais como a Austrália (Calôba et al., 2002), Holanda (Dekker, Van Donselaar & Ouwehand, 2004), China (Kuo, 2001), Reino Unido (Taylor, 2007), Estados Unidos (Zeng, 2000), Grécia (Doganis et al., 2006), Itália (Zotteri et al., 2005), entre outros. O mercado brasileiro de produtos alimentícios tem sido objeto de pesquisa apenas nos últimos anos (Queiroz & Cavalheiro, 2006; Higuchi, 2006; Medeiros et al., 2006). Estes trabalhos científicos, no entanto, não conseguiram explorar toda a complexidade que este segmento apresenta.

Muitos trabalhos enfatizam a aplicação de um modelo de previsão, mas não pesquisam o uso das informações obtidas no processo de tomada de decisão ou no impacto na cadeia de suprimentos como um todo. Alguns trabalhos avaliam a acurácia do modelo de previsão empregado por uma empresa, mas

não analisam a influência dos erros de previsão no gerenciamento da cadeia de suprimentos. Trabalhos mais recentes têm revisado o impacto dos erros de previsão em alguma parte da cadeia de suprimentos, como por exemplo, na instabilidade da programação de produção (MRP, *Master Production Schedule*) e no nível de serviço oferecido (Xie, Lee & Zhao, 2004).

Outros trabalhos têm explorado a relação entre erros de previsão e medidas de desempenho organizacional, entretanto os resultados são contraditórios. Alguns estudos demonstram que os erros de previsão apresentam significativo impacto nos custos totais, na programação da produção e no nível de serviço prestado (Xie et al., 2004), outros demonstram resultados opostos (Price & Sharp, 1985; Ho & Ireland, 1998). Kerkanen, Korpela e Huiskonen (2009) afirmam que o impacto real dos erros de previsão de demanda somente é possível quando a avaliação inclui as características sistemáticas específicas de cada empresa.

Neste sentido, propomos um estudo de caso (Yin, 1994) a fim de analisar de maneira exaustiva e profunda a previsão de demanda em uma empresa de alimentos. O objetivo é alcançar um conhecimento amplo e detalhado da relação de causa-efeito entre a acurácia do modelo de previsão, a responsividade da demanda e o desempenho financeiro da organização. A seção 3 descreve a metodologia para estabelecer a relação entre estas três variáveis.

3 METODOLOGIA

Este trabalho propõe uma investigação da relação causal entre três variáveis: a acurácia da previsão de demanda (variável independente), a responsividade da demanda (variável dependente I) e o desempenho financeiro (variável dependente II). Estas três variáveis apresentam uma relação de causa-efeito, mas não são as únicas condições para que o fenômeno ocorra. Este fato caracteriza o presente trabalho como um estudo descritivo.

A acurácia da previsão de demanda é medida pela diferença entre a previsão para o período t e a demanda real no período t (Chopra & Meindl, 2003). Esta variável será operacionalmente calculada com base no Erro Percentual Absoluto Médio (MAPE), expresso matematicamente pela Equação 1:

$$MAPE_n = \frac{\sum_{t=1}^n \frac{|E_t|}{|D_t|} 100}{n}, \quad (1)$$

Na qual:

$|E_t|$ = valor absoluto do erro no período t ;

$|D_t|$ = valor absoluto de demanda real no período t ;

n = todos os períodos.

A responsividade de atendimento da demanda pode ser definida como o percentual da demanda satisfeita diretamente no ponto de venda durante um ciclo de reabastecimento (Zeng, 2000). O índice de responsividade de atendimento da demanda também é denominado de *fill rate* (FR) e pode ser calculado como demonstrado na Equação 2:

$$FR = 1 - \frac{\text{número de stockouts esperados por ciclo}}{\text{número de unidades exigidas por ciclo}}, \quad (2)$$

O desempenho financeiro é dependente da diferença entre as possíveis receitas e custos (Lima, 2003). Desta forma, o desempenho financeiro será mensurado neste trabalho como custo de oportunidade através do *fill rate*, expresso da seguinte maneira:

$$FR = 1 - \frac{\sigma G_\mu(K)}{Q}, \quad (3)$$

onde:

μ = média,

σ = desvio padrão,

K = fator de segurança,

$\sigma G_\mu(K)$ = função de unidade padrão perdida (*stockout*),

Q = pedido quantitativo.

Com base nos procedimentos técnicos utilizados, a coleta de dados é o elemento mais importante para a identificação do delineamento de uma pesquisa (Gil, 2002). O presente estudo utilizou dados históricos da demanda de cinco

grupos de produtos abrangendo o período de 2004 a 2008. Trata-se de um estudo de caso *ex-post facto* com corte temporal seccional. O estudo foi realizado tomando como base a configuração atual do fenômeno sobre a qual os dados foram coletados. O problema de pesquisa foi abordado de forma quantitativa, justificado pela natureza do objeto de estudo, bem como pelo procedimento utilizado para a coleta dos dados. O período de análise foi selecionado mediante a necessidade de se obter, no mínimo, 60 séries temporais a fim de possibilitar a identificação de padrões como nível, tendência e sazonalidade.

A indústria em estudo é uma empresa de grande representatividade no mercado de alimentos no Brasil e figura entre as cinco líderes de mercado em seu segmento. Ela é composta por unidades industriais e unidades de negócios concentradas nas principais regiões do país. Seu portfólio é composto por uma grande diversificação de mix dentro de cada divisão.

Apesar do portfólio diverso, a análise individual de todos os produtos da empresa não possui relevância para fins gerenciais. Muitos grupos de produtos semelhantes podem ser agregados através de critérios pré-determinado em uma mesma série temporal e analisados conjuntamente. A escolha do nível apropriado de agregação depende do processo de tomada de decisão que a previsão espera suportar (Zotteri et al., 2005).

No estudo em questão, o agrupamento dos produtos ocorreu com base em suas características intrínsecas, reunindo-os por caracteres de similaridade entre si. Pela agregação dos dados foram formados 5 grupos de produtos: (1) grupo A: produtos que representam 70% de todo o volume de vendas da empresa. Esta linha é composta por um total de 59 SKUs (*Stock Keeping Units*); (2) grupo B: produtos que representam 10,5% de todo volume de vendas da empresa. Esta linha é composta por 9 SKUs; (3) grupo C: produtos que representam 8,5% de todo volume de vendas da empresa. Esta linha é composta de 13 SKUs; (4) grupo D: produtos que representam 10% de todo o volume de vendas da empresa. Esta linha é composta de um total de 8 SKUs; (5) grupo E: são produtos que representam 1% de todo o volume de vendas da empresa. Esta linha é composta por 2 SKUs.

Para a série temporal histórica de cada grupo de produtos foram aplicados quatro modelos quantitativos de previsão de demanda: suavização exponencial simples (SES), modelo de Holt (MH), modelo de Winter (MW) e modelo autorregressivo integrado de médias móveis (ARIMA). Os resultados

foram comparados com os valores reais da demanda a fim de escolher o modelo de maior acurácia para cada grupo de produto. Em seguida, foi analisado o índice de responsividade de atendimento de demanda (*fill rate*) do método quantitativo de previsão de demanda de maior grau de acurácia, com base no menor valor do MAPE, para cada um dos cinco grupos de produtos. Estes resultados foram, por fim, comparados com o *fill rate* da empresa em estudo para determinar a diferença entre demanda atendida e demanda real. O desempenho financeiro foi avaliado como um custo de oportunidade em função do *fill rate*.

A limitação deste estudo se deve à qualidade dos dados fornecidos pela empresa em estudo, bem como às diversas variáveis que compõem o referido negócio. Informações mercadológicas sobre o histórico de dados coletados não foram considerados na análise. Desta forma, determinadas condições tais como promoções, campanhas e ações da concorrência podem ter interferido em alguns resultados mensais na variação da demanda. Do mesmo modo, este estudo não considerou possíveis restrições na capacidade de produção da organização em estudo nem tamanho mínimo de lote para comercialização. Na próxima seção serão apresentados os resultados obtidos pela aplicação da metodologia descrita acima.

4 RESULTADOS

Para facilitar a análise dos resultados esta seção será dividida em três partes: (a) análise prévia dos dados, (b) comparação dos métodos de previsão de demanda e c) responsividade da demanda e desempenho financeiro.

4.1 ANÁLISE PRÉVIA

Antes de se aplicar os métodos de previsão, é imprescindível analisar os dados em estudo com a finalidade de identificar os padrões ou fatores componentes da curva, tais como tendência, sazonalidade, variações irregulares e variações randômicas. Estes padrões não são considerados por alguns métodos de previsão de demanda e, nesta situação, reduzem a acurácia da previsão. A Figura 2 representa graficamente a série da demanda agregada dos produtos do grupo A. Observa-se, como citado por Tubino (2000), variações randômica e irregulares, destacadas principalmente no ano de 2006. Também é possível observar tendência e leve sazonalidade.

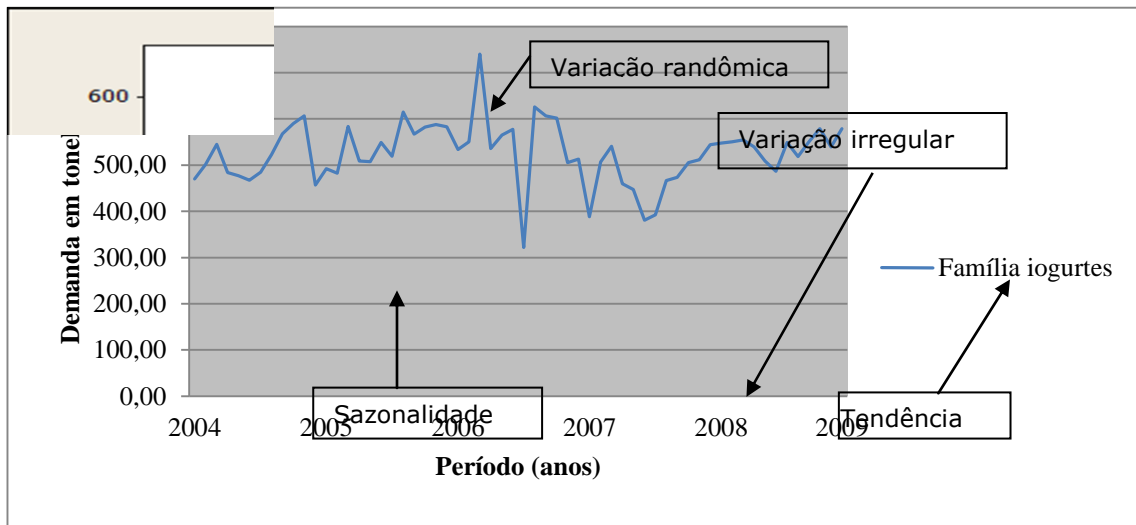


Figura 2: Análise dos dados históricos de demanda dos produtos do grupo A entre 2004 e 2008

Fonte: Resultado de pesquisa

Os mesmos padrões observados na figura 2 podem ser vistos na análise dos dados históricos de demanda para os grupos de produtos B, C, D e E (Figura 3). Em função da variação da escala horizontal (demanda em toneladas), os produtos do Grupo A foram analisados em separado por representarem 70% de todo o volume de vendas da empresa.

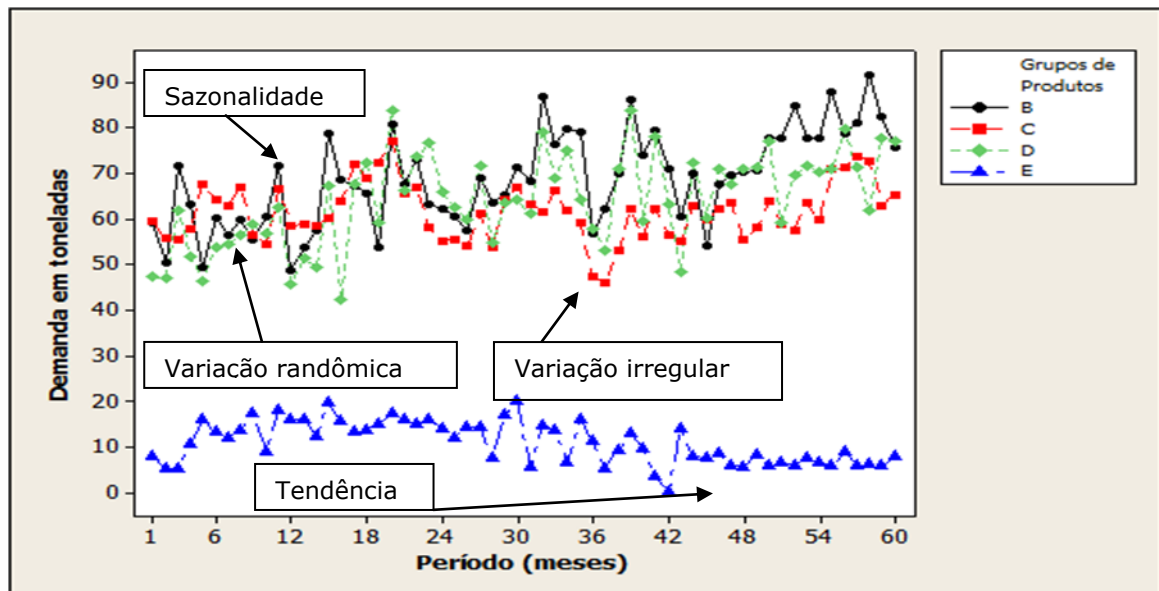


Figura 3: Análise dos dados históricos de demanda dos produtos do grupo B, C, D e E entre 2004 e 2008

Fonte: Resultado de pesquisa

4.2 COMPARAÇÃO DOS MÉTODOS DE PREVISÃO DE DEMANDA

O departamento comercial da empresa em estudo é o atual responsável pela previsão de demanda. Este utiliza o método de médias móveis simples aliadas à valorização qualitativa, que pode oscilar de acordo com as ações de mercado. A previsão tem como base o software Microsoft Excel[®]. Nenhum outro software específico ou matemático é utilizado. A previsão de demanda é realizada por meio de planilhas eletrônicas. Segundo DeLurgio (1998), este método traz bons resultados apenas quando a demanda não apresenta padrão, ou seja, não há tendência ou sazonalidade. O método de médias móveis apresenta diversas limitações por isso sua aplicação prática é restrita. Entretanto, este método é simples, de fácil implantação e com possibilidade processamento manual.

As constantes de suavização ajustadas para os modelos SES, Holt e Winter estão descritas na Tabela 1. Para os modelos de SES, Holt e Winter, os dados de ajustes foram gerados pelo programa estatístico NNQ-STAT[®] para 12 períodos (sazonal). Para o modelo ARIMA, os ajustamentos da previsão foram feitos pelo programa estatístico NCSS[®] (2007). Para este modelo foram considerados os seguintes parâmetros de ajustamento (p, d, q) em função do menor valor de MAPE: produtos do grupo A (1,0,1), produtos do grupo B (1,0,1), produtos do grupo C (1,1,2), produtos do grupo D (1,0,1), produtos do grupo E (2,0,2).

Tabela 1: Valores das constantes de suavização e pesos utilizados nos modelos de previsão de demanda

Modelos	SES	Holt		Winter		
Grupos de produtos	α	α	β	α	β	γ
A	0,57	0,86	0,01	0,75	0,10	0,10
B	0,14	0,01	0,03	0,01	0,01	0,01
C	0,63	0,64	0,01	0,46	0,01	0,01
D	0,18	0,94	0,01	0,22	0,01	0,01
E	0,25	0,05	0,99	0,03	0,99	0,01

Fonte: Resultado de pesquisa

Os ajustes da previsão para todos os grupos de produto foram realizados do ano de 2004 a 2007 a fim de se projetar a previsão de demanda para o ano de 2008, ou seja, os cálculos da previsão, erro e comparações com a demanda real abrangeram um período de 12 meses (01/01/2008 a 31/12/2008).

A Figura 4 demonstra graficamente os resultados obtidos pela aplicação dos modelos de previsão estudados para os produtos do grupo A. Para este grupo de produtos, o modelo ARIMA apresentou maior grau de acurácia com valor de MAPE de 3,71. O modelo de previsão adotado pela empresa apresentou menor grau de acurácia em comparação a todos os modelos de previsão empregados na análise, com MAPE de 6,15.




Figura 4: Previsão de demanda dos produtos do grupo A entre 2004 e 2008

Fonte: Resultado de pesquisa




Figura 5: Previsão de demanda dos produtos do grupo B entre 2004 e 2008

Fonte: Resultado de pesquisa

A Figura 5 demonstra graficamente os resultados obtidos pela aplicação dos modelos de previsão estudados para os produtos do grupo B. Para este grupo de produtos, o modelo ARIMA apresentou maior grau de acurácia com valor de MAPE de 7,52. O modelo da empresa apresentou grau de acurácia superior ao modelo SES e resultado inferior aos demais modelos.

A Figura 6 demonstra graficamente os resultados obtidos pela aplicação dos modelos de previsão estudados para os produtos do grupo C. Para este grupo de produto, o modelo Winter apresentou maior grau de acurácia com valor de MAPE de 7,43. O modelo da empresa apresentou grau de acurácia superior aos modelos SES, Holt e ARIMA.

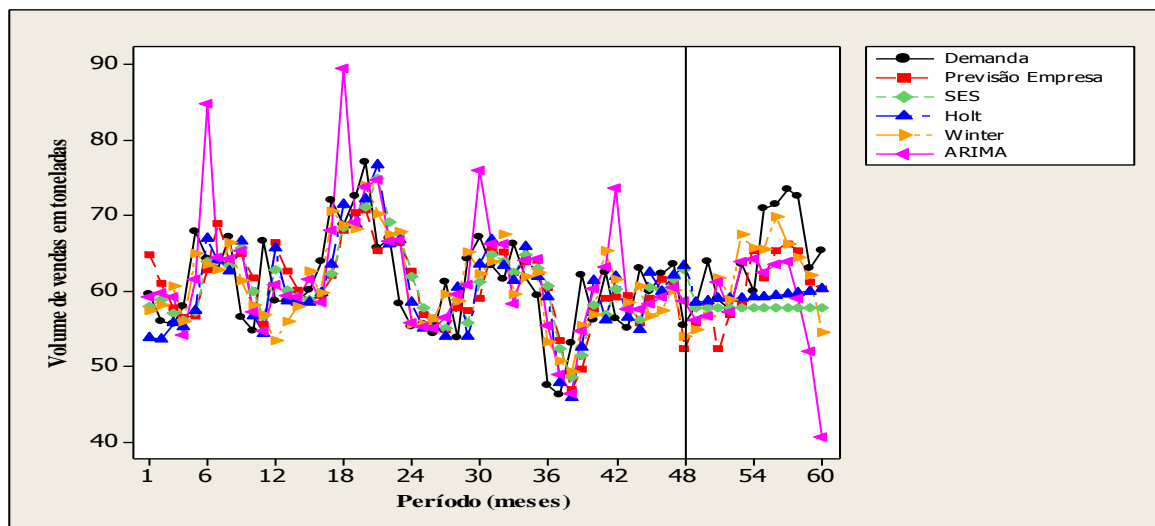


Figura 6: Previsão de demanda dos produtos do grupo C entre 2004 e 2008

Fonte: Resultado de pesquisa

A Figura 7 demonstra graficamente os resultados obtidos pela aplicação dos modelos de previsão estudados para os produtos do grupo D. Para este grupo de produtos, o modelo Holt apresentou maior grau de acurácia com valor de MAPE de 6,44. O modelo da empresa apresentou grau de acurácia superior ao modelo Winter e inferior aos demais.

A Figura 8 demonstra graficamente os resultados obtidos pela aplicação dos modelos de previsão estudados para os produtos do grupo E. Para este grupo de produtos, o modelo ARIMA apresentou maior grau de acurácia com valor de MAPE de 11,49. O modelo adotado pela empresa apresentou grau de acurácia superior aos modelos, SES, Holt e Winter.

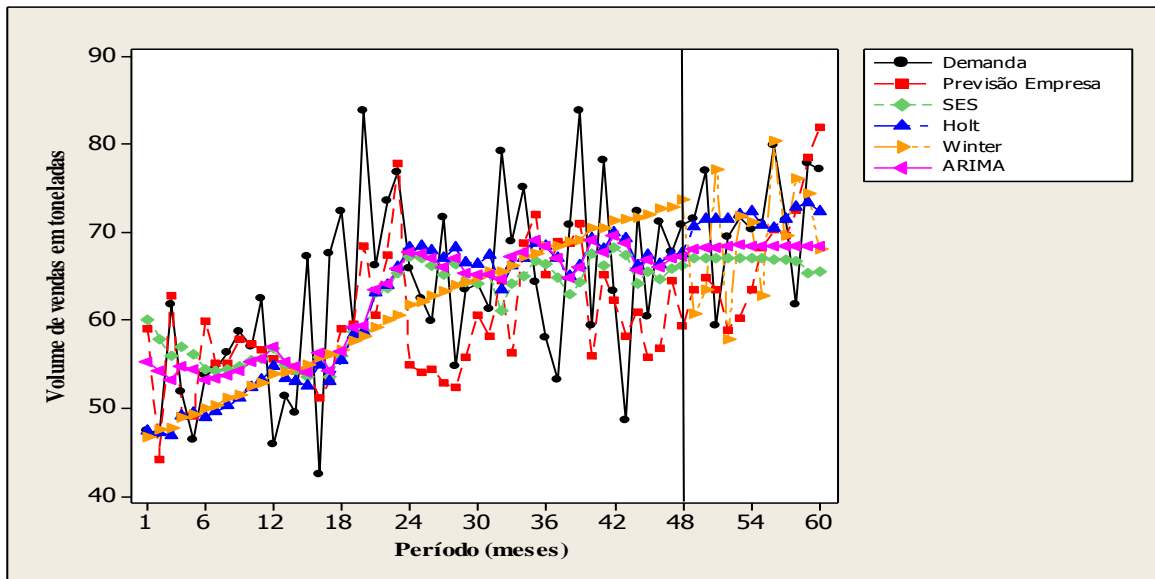


Figura 7: Previsão de demanda dos produtos do grupo D entre 2004 e 2008

Fonte: Resultado de pesquisa




Figura 8: Previsão de demanda dos produtos do grupo E entre 2004 e 2008

Fonte: Resultado de pesquisa

A Tabela 2 resume os resultados de MAPE obtidos pela aplicação dos quatro modelos de previsão de demanda aos grupos de produtos A, B, C, D, e E. Em suma, pode-se dizer que para os grupos de produtos A, B e E, o modelo ARIMA apresentou maior grau de acurácia, para os produtos do grupo C, o modelo de Winter, e para os produtos do grupo D, o modelo de Holt. Em função

deste resultado, foram adotados os modelos ARIMA, Winter e Holt para o cálculo do índice de responsividade da demanda (*fill rate*), conforme demonstrado na subseção 4.3.

Tabela 2: Grau de acurácia dos modelos de previsão de demanda para os grupos de produtos A, B, C, D e E segundo o

Modelo de Previsão	MAPE Grupo A	MAPE Grupo B	MAPE Grupo C	MAPE Grupo D	MAPE Grupo E
Empresa	6,15	9,13	7,93	9,81	14,29
SES	4,88	14,2	10,34	9,50	17,18
Holt	4,16	8,0	8,56	6,44	17,67
Winter	6,14	8,91	7,43	11,26	26,42
ARIMA	3,71	7,52	11,44	7,97	11,49

Fonte: Resultado de pesquisa

4.3 RESPONSABILIDADE DA DEMANDA E DESEMPENHO FINANCEIRO

Assim como ocorreu na subseção anterior, os cálculos de responsividade da demanda e desempenho financeiro abrangeram um período de 12 meses (01/01/2008 a 31/12/2008). A demanda total de produtos do grupo A no ano de 2008 foi de 6.503,26 toneladas. Para este grupo de produtos, o nível de responsividade no atendimento da demanda foi de 94,20% pelo modelo de previsão da empresa e 99,70% pelo modelo ARIMA. Para os produtos do grupo B, a demanda total no ano de 2008 foi de 963,28 toneladas; o nível de responsividade no atendimento da demanda foi de 91,90% pelo modelo de previsão da empresa e 92,65% pelo modelo ARIMA. Para os produtos do grupo C, a demanda total no ano de 2008 foi de 778,54 toneladas; o nível de responsividade no atendimento de demanda foi de 93,31% pelo modelo de previsão da empresa e 96,02% pelo modelo ARIMA. Para os produtos do grupo D, a demanda total no ano de 2008 foi de 858,28 toneladas; o nível de responsividade no atendimento da demanda foi de 95,01% pelo modelo de previsão da empresa e 97,09% pelo modelo Holt. Por fim, para os produtos do grupo E, a demanda total no ano de 2008 foi de 81,09 toneladas; o nível de responsividade no atendimento da demanda foi de 93,40% pelo modelo de previsão da empresa e 98,53% pelo modelo ARIMA.

A Tabela 3 demonstra os resultados de *fill rate* e do impacto financeiro decorrente dos erros de previsão de demanda. Os valores apresentados na Tabela 3 foram calculados dentro das condições normais do varejo/mercado. Neste caso não foram considerados os índices de indenização, quebras e devoluções de produtos gerados por erros de negociação e capacidade de recebimento no varejo. Do mesmo modo, a análise não considerou possíveis restrições na capacidade de produção da organização em estudo nem tamanho mínimo de lote para comercialização.

Tabela 3: Análise do desempenho financeiro da empresa no ano de 2008

Demanda real em toneladas		Vendas concretizadas pelo modelo de Previsão Empresa					Previsão realizada pelo modelo de melhor desempenho com base no MAPE						
Grupos de produtos	toneladas	toneladas	erro (tons)	fill rate	R\$ - valor por kg	perda de faturamento	toneladas	erro (tons)	fill rate	R\$ - valor por kg	perda de faturamento	Modelo	
A	6.503,26	6.126,26	377,00	94,20	6,37	2.401.490,00	6.484,00	19,26	99,70	6,37	122.686,20	ARIMA	
B	963,28	885,29	77,99	91,90	8,27	644.977,30	892,50	70,78	92,65	8,27	585.350,60	ARIMA	
C	778,56	726,50	52,06	93,31	9,69	504.461,40	747,55	31,01	96,02	9,68	300.175,92	WINTER	
D	858,28	815,42	42,86	95,01	9,80	420.028,00	833,30	24,98	97,09	9,80	244.821,32	HOLT	
E	81,09	75,74	5,35	93,40	15,00	80.250,00	79,90	1,19	98,53	15,00	17.850,00	ARIMA	
Total						4.051.206,70	Total						1.270.884,04

Fonte: Resultado de pesquisa

Em suma, os resultados demonstram que o modelo ARIMA estima um atendimento da demanda que varia de 92,65% a 99,70% para os produtos dos grupos A, B e E. O modelo de Winter estima um atendimento da demanda de 96,02% para os produtos do grupo B e o modelo de Holt estima um atendimento da demanda de 97,09% para os produtos do grupo D. De um modo geral, pode-se afirmar que todos os modelos estudados apresentaram uma previsão potencialmente boa, tendo em vista o valor de MAPE em torno de 10%.

Os resultados demonstrados para os grupos de produtos A, B, C, D e E confirmam que a acuracidade da previsão tem influência direta no nível de serviço oferecido ao consumidor e, por conseguinte, no desempenho financeiro da organização como um todo. Para os produtos do grupo A, a empresa deixa de abastecer o mercado/demanda em 377,00 toneladas, com perda de um faturamento aproximado de R\$ 2.401.490,00. Para os produtos do grupo B, ao utilizar o método atual de previsão, a empresa deixa de abastecer o mercado/demanda em 77,99 toneladas, com perda de um faturamento

aproximado de R\$ 644.977,30. Para os produtos do grupo C, esta ruptura chega a 52,06 toneladas, com perda de faturamento aproximado de R\$ 504.461,40. Para os produtos do grupo D, esta deficiência chega em 42,86 toneladas, com perda de um faturamento aproximado de R\$ 420.028,00. Para produtos do grupo E, a ruptura é de 5,35 toneladas, com perda de faturamento aproximado de R\$ 80.250,00. O impacto financeiro total referente aos erros de previsão de demanda para a empresa é de aproximadamente R\$ 4.051.206,70 anuais. Se a empresa empregasse o modelo ARIMA para os produtos dos grupos A, B e E, o modelo de Holt para os produtos do grupo D e o modelo de Winter para os produtos do grupo C, o faturamento poderia ser aumentado em uma média aproximada de R\$ 2.780.322,66 anuais.

5 CONSIDERAÇÕES FINAIS

As incertezas intrínsecas do mercado de alimentos, bem como os objetivos e promoções da empresa em questão, tornam o processo de precisão incerto por natureza. A utilização de modelos de previsão de demanda de maior acurácia possibilita uma menor incerteza associada a decisões gerenciais. As empresas podem obter importantes melhorias como: redução de estoques de produtos acabados e de matérias-primas, melhorias no planejamento da produção, melhor alocação de pessoal e, de maneira geral, redução de perdas financeiras.

Em geral, os modelos de previsão mais convenientes são os parcimoniosos, ou seja, aqueles modelos que contêm poucos parâmetros tendem a fornecer previsões mais precisas. Entretanto, nenhum modelo de previsão pode ser considerado universalmente o melhor, indiscriminando as situações específicas do processo, produto e mercado. Por isso, situações complexas e específicas, como ocorrem no mercado de alimentos, exigem estudos investigativos sobre o método de previsão mais adequado para cada condição de estudo.

Este estudo de caso expôs as dificuldades de modelagem de dados reais, vista da aleatoriedade encontrada em muitas séries temporais, contextualizada com a própria realidade de mercado da empresa. Os resultados obtidos foram satisfatórios se comparados à demanda real e servem para avaliar o

desempenho do processo de previsão da empresa e, ao mesmo tempo, para propor modificações. Melhorias de desempenho exigem grandes mudanças, e isso inclui mudanças nos sistemas de medição e gestão atualmente utilizados.

A partir do desenvolvimento das sociedades, lidar com as informações e processá-las da melhor forma têm sido uma busca contínua da humanidade. A acuracidade do método de previsão empregado demonstrou uma relação causal adequada para avaliar o desempenho financeiro da empresa tendo em vista que a previsão de demanda é um fator crítico para a organização. Previsões eficazes são essenciais para alcançar os objetivos estratégicos e operacionais das organizações e dependem diretamente da qualidade dos dados e da aplicação de um método de previsão adequado. Entretanto, em função do variado portfólio da organização, o estudo demonstrou a necessidade de se empregar modelos quantitativos distintos, o que onera os custos e dificulta a implementação de um processo de mudança na gestão. Por este motivo, apesar de tantos benefícios, a previsão de demanda pode não ser viável para a organização. Para que um modelo de previsão seja seguido rotineiramente, ele deve ser de fácil aplicação e de baixo custo estrutural.

Diante das limitações deste estudo, sugere-se novas pesquisas investigativas com múltiplos critérios para selecionar e avaliar as técnicas de previsão. Estudos recentes indicam que a utilização de múltiplos modelos de previsão e, posteriormente, a combinação de suas previsões em uma previsão real é mais eficaz que a escolha de um modelo individual. Sugere-se também, para trabalhos futuros, modificação nos níveis de agregação adotados nos dados e aplicação dos modelos de inteligência artificial, redes neurais e lógica *fuzzi (nebulosa)* para comparação com os resultados obtidos neste estudo.

REFERÊNCIAS

- Box, G.E.P., Jenkins, G.M. & Reinsel, G.C. (1994). *Time series analysis: forecasting and control* (3ª ed.). Englewood Cliffs, New Jersey: Prentice-Hall.
- Buytendijk, F., Hatch, T. & Micheli, P. (2010). Scenario-based strategy maps. *Business Horizons*, 53, 335-347.
- Calôba, G.M., Calôba, L.P. & Saliby, E. (2002). Cooperação entre redes neurais artificiais e técnicas "clássicas" para previsão de demanda de uma série de vendas de cerveja na Austrália. *Pesquisa Operacional*, 22, (3), 345-358.

- Camargo, A. de S.A. & Amarante, F.G.C. (1999). *Gestão de estoque*. Recuperado em 14 de junho de 1999, de <http://www.eps.ufsc.br/labs/grad/disciplinas/gerenciademateriais/99.1/gestestoques.ppt>.
- Chopra, S. & Meindl, P. (2003). *Gerenciamento da cadeia de suprimentos: estratégia, planejamento e operações* (2ª ed.). São Paulo: Pearson Prentice Hall.
- Dekker, M., Van Donselaar, K. & Ouwehand, P. (2004). How to use aggregation and combined forecasting to improve seasonal demand forecast. *International Journal of Production Economics*, 90, (2), 151-167.
- DeLurgio, S.A. (1998). *Forecasting principles and applications*. Boston: Irwin McGraw-Hill.
- Doganis, P., Alexandridis, A. Patrinos, P. & Sarimveis, H. (2006). Time series forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing. *Journal of Food Engineering*, 75, 196-204.
- Duclós, L.S. & Santana, V.L. (2009). *Ciclo estratégico da informação: como colocar a TI no seu devido lugar* (1ª ed.). Curitiba: Universitária Champagnat.
- Faria, E.L.; Albuquerque, M.P., Afonso, J.L.G. & Albuquerque, M.P. (2008). *Previsão de séries temporais utilizando métodos estatísticos*. Recuperado em 14 de junho de 2009, de http://cbpfinder.cbpf.br/publication_pdfs.
- Finne, T. (2000). Information systems risk management: key concepts and business processes. *Computers & Security*, 19, 234-242.
- GIL, A.C. (2002). *Como elaborar projetos de pesquisa* (4ª ed.). São Paulo: Atlas.
- Higuchi, A.K. (2006). A previsão de demanda de produtos alimentícios perecíveis: três estudos de caso. *Revista Eletrônica de Administração*, 8, (1), 1-15.
- Ho, C.J., Ireland, T.C. (1998). Correlating MRP system nervousness with forecast errors. *International Journal of Production Research*, 36, 2289-2299.
- Holt, C.C. (2004). Author's retrospective on "Forecasting seasonal and trends by exponentially weighted moving averages". *International Journal of Forecasting*, 20, (1), 11-13.
- Kerkanen, A., Korpela, J. & Huiskonen, J. (2009). Demand forecasting errors in industrial context: measurement and impacts. *International Journal Production Economics*, 118. 43-48.
- Kuo, R.J. (2001). A sales forecasting system based on fuzzy neural network with initial weights generated by genetic algorithm. *European Journal of Operational Research*, 129 (3), 496-517.

- Kuo, R.J. & XUE, K.C. (1999). Fuzzy neural networks with application to sales forecasting. *Fuzzy Sets and Systems*, 108, 123-143.
- Lima, M. (2003). *Estoque: custo de oportunidade e impacto sobre os indicadores financeiros*. Recuperado em 14 de junho de 2009, de <http://www.ilos.com.br>.
- Makridakis, S.; Wheelwright, S.C. & Hyndman, R.J. (1998). *Forecasting: methods and applications* (3ª ed.). New York: John Wiley & Sons.
- Martinez, R. O. & Zamprogno, B. (2003). Comparação de algumas técnicas de previsão em análise de séries temporais. *Revista Colombiana de Estatística*, 26 (2), 129-157.
- Martinsons, M.; Davidson, R. & Tse, D. (1999). The balanced Scorecard: a foundation for the strategic management of information systems. *Decision Support Systems*, 25, 71-88.
- Medeiros, A. L., Montevechi, J.A.B., Rezende, M.L. & Reis, L.P. (2006, Julho). Modelagem ARIMA na previsão do preço da arroba do boi gordo. *Anais do Encontro da Sociedade Brasileira de Economia e Sociologia Rural*, 44, Fortaleza, CE, Brasil.
- Meijden, V.D.L.H., Nunen, J.A.E.E.V. & Ramondt, A. (1994). Forecasting: bridging the gap between sales and manufacturing. *International Journal Production Economics*, 37 (1), 101-114.
- Morettin, P.A. & Toloí, C.M.C. (1987). *Previsão de séries temporais* (2ª ed.). São Paulo: Atual Editora.
- Pellegrini, F.R. & Fogliatto, F.S. (2000). Estudo comparativo entre os modelos de Winters e de Box-Jenkins para previsão de demanda sazonal. *Produto e Produção*, 4, 72-85.
- Price, D.H.R. & Sharp, J.A. (1985). Investigation of the impact of changes in demand forecasting method on the financial performance of an electricity supply undertaking. *International Journal of Electrical Power & Energy Systems*, 7, (3), 131-137.
- Queiroz, A.A. & Cavalheiro, D. (2003). Método de previsão de demanda e detecção de sazonalidade para o planejamento da produção de indústrias de alimentos. *Anais do Encontro Nacional de Engenharia de Produção*, 23, Ouro Preto, MG, Brasil.
- Segura, J.V. & Vercher, E. (2001). A spreadsheet modeling approach to the Holt-Winters optimal forecasting. *European Journal of Operational Research*, 131 (2), 375-388.
- Souto, D.P., Baldeón, R.A., & Russo, S.L. (2006). Estudo dos modelos exponenciais na previsão. *Sistemas e Informática*, 9 (1), 97-103.

- Taylor, J. W. (2007). Forecasting daily supermarket sales using exponentially weighted quantile regression. *European Journal of Operational Research*, 178 (1), 154-167.
- Tubino, D.F. (2000). *Manual de planejamento e controle da produção*. São Paulo: Atlas.
- Venkatesan, R. & Kumar, V. (2002). A genetic algorithms approach to growth phase forecasting of wireless subscribers. *International Journal of Forecasting*, 18 (4) 625-646.
- Xie, J., Lee, T.S. & Zhao, X. (2004). Impact of forecasting error on the performance of capacitated multi-item production systems. *Computers & Industrial Engineering*, 46, 205-219.
- Yin, R.K. (1994). *Case Study Research*. Beverly Hills: Sage Publications.
- Zeng, A.Z. (2000). Efficiency of using fill-rate criterion to determine safety stock: a theoretical perspective and a case study. *Production and Inventory Management Journal*, 41 (2), 41-44.
- Zhang, G.P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50 (1), 159-175.
- Zotteri, G., Kalchschmidt, M.& Caniato, F. (2005). The impact of aggregation level on forecasting performance. *International journal of Production Economics*, 93-94, 479-491.