



Previsão de perdas por vencimento de produto usando séries temporais

Forecasting product losses by expiration date using time series analysis

Recebimento dos originais: 24/02/2023

Aceitação para publicação: 31/03/2023

Wilson Castello Branco Neto

Doutorado em Ciência da Computação - Inteligência Computacional

Instituição: Instituto Federal de Santa Catarina

Endereço: Rua Heitor Vila Lobos, 225, São Francisco, Lages - SC, CEP: 88506-400

E-mail: wilson.castello@ifsc.edu.br

Claidson Correia Haidrick

Graduado em Ciência da Computação

Instituição: Instituto Federal de Santa Catarina

Endereço: Rua Frei Rogério, 587, Centro, Lages - SC, CEP: 88502-161

E-mail: claidson.haidrick@gmail.com

RESUMO

Este artigo apresenta um sistema capaz de estimar quantas unidades de um produto serão vendidos em um determinado período. A partir destes dados, pode-se verificar se as unidades em estoque desta mercadoria têm a possibilidade de expirar a data de validade e se há risco de ruptura no estoque em função do cronograma de reposição. O sistema, em um primeiro momento, adota uma perspectiva quantitativa com o uso dos métodos de Média móvel, Regressão linear simples e Suavização exponencial de Holt-Winters. Contudo, os resultados destes métodos são apresentados ao usuário do sistema como mais um elemento a ser considerado em sua decisão que, em última instância, é qualitativa. Para testar o modelo foram utilizadas séries temporais extraídas de uma empresa real. Os resultados apontam uma taxa de acerto média de 86,13% para o método de Holt-Winters, 82,72% para análise de regressão e 48,79% para média móvel.

Palavras-chave: previsão de perdas, séries temporais, suavização exponencial de holt-winters, regressão linear simples, média móvel.

ABSTRACT

This paper presents a system capable of estimating how many units of a product will be sold in a given period. From this data, it is possible to verify if the units in stock of this merchandise have the possibility of expiring on their expiration date and if there is a risk of stock-outs due to the replenishment schedule. The system, at first, adopts a quantitative perspective with the use of the Moving Average, Simple Linear Regression and Holt-Winters Exponential Smoothing methods. However, the results of these methods are presented to the system's user as yet another element to be considered in his or her decision, which is ultimately a qualitative one. To test the model, time series extracted

from a real company were used. The results show an average accuracy rate of 86.13% for the Holt-Winters method, 82.72% for regression analysis, and 48.79% for moving average.

Keywords: loss prediction, time series, holt-winters exponential smoothing, simple linear regression, moving average.

1 INTRODUÇÃO

Um dos maiores desafios de qualquer empresa que atua no ramo de comércio é evitar perdas financeiras, pois elas diminuem a competitividade, drenam os lucros e podem impactar seriamente o resultado do negócio. O mercado atual tornou-se tão acirrado que se torna vital atuar na prevenção de perdas e o primeiro passo para propor soluções é reconhecer fatores que causam problemas, ou seja, saber que tipos de perdas são mais recorrentes.

Um levantamento realizado pela Sociedade Brasileira de Varejo e Consumo (SBVC) apontou que o supermercado é o segmento que vigora como a operação mais suscetível a perdas no País. Segundo o presidente da Comissão de Prevenção, Auditoria e Gerenciamento de Risco (CPAR), da SBVC, Carlos Eduardo Santos, é preciso conscientizar os empresários do setor sobre a relevância do assunto, já que os donos de supermercados pouco investem em medidas para prevenir e evitar que essas perdas impactem o faturamento de suas operações. “É muito mais difícil aumentar as vendas do que reduzir as perdas, e nosso papel é fazer com que as empresas saibam mais sobre prevenção, pois ela gera bons resultados rapidamente”, disse Santos (SBVC, 2016).

De acordo com pesquisa realizada em 2018 pela Associação Brasileira de Supermercados (ABRAS), o setor supermercadista perdeu, em 2017, R\$ 6,4 bilhões, o que representa 1,82% do faturamento bruto do setor no ano citado (ABRAS, 2018). O relatório de prevenção de perdas apresentado pela Associação Paulista de Supermercados (APAS), em 2016, mostra que do total de perdas de mercadoria que ocorrem nos supermercados, a perda por data de validade representa 50% das ocorrências, sendo que 70% desses vencimentos não é tratado previamente, o que comprova que os controles manuais realizados se mostram pouco eficientes (Santos, 2016).

O uso da tecnologia é crucial para aprimorar os processos logísticos, financeiros e de segurança que exigem um alto nível de integração e comunicação eficiente. Ainda assim, mesmo com o avanço dos softwares de gestão, no cenário atual é difícil atuar em dois problemas que geram muito prejuízo: perda por validade expirada e perda por ruptura de estoque.

Na perda por validade o prejuízo é alto, pois, além do descarte da mercadoria, o estabelecimento também corre o risco de receber autuações e multas. Já a ruptura de estoque se dá quando o estabelecimento vende todo o estoque de determinada mercadoria antes que ela seja repostada pelo fornecedor, assim, a perda financeira ocorre porque a venda deixa de ocorrer pela falta do produto.

Tais perdas são o resultado de procedimentos de controle de estoque e logística pouco eficientes. O formato de identificação de cada mercadoria baseada em código de barras (EAN - *European Article Number*) contribui para a ineficiência devido ao fato de o identificador não armazenar dados sobre o lote/entrada/fabricação do produto. Assim, no momento da venda e baixa de estoque pelos *softwares* de controle, não se sabe a que lote a mercadoria pertence, o que obriga a adoção de métodos manuais de controle.

Este trabalho apresenta um sistema capaz de estimar a quantidade a ser vendida de uma mercadoria em um determinado período, no momento do registro de sua entrada, para, a partir destes dados, determinar se as unidades em estoque desta mercadoria têm a possibilidade de expirar a data de validade para o consumo. Para alcançar este objetivo, foram implementados e testados diferentes métodos de previsão de vendas baseados na análise de séries temporais, tais como Análise de Média Móvel, Análise de Regressão e Suavização Exponencial de Holt-Winters.

Para testar o modelo foram utilizadas séries temporais extraídas de uma empresa real. Os resultados apontam uma taxa de acerto média de 86,13% para o método de Holt-Winters, 82,72% para análise de regressão e 48,79% para média móvel. Contudo, os resultados destes métodos são apresentados ao usuário do sistema como mais um elemento a ser considerado em sua decisão que, em última instância, é qualitativa.

2 MODELOS PARA PREVISÃO

Realizar prognósticos sobre o desempenho futuro de dados estocásticos com base em dados passados não é uma novidade (Armstrong, 1988). Diferentes métodos, oriundos de diferentes áreas do conhecimento vêm sendo propostos ao longo das últimas décadas. Contudo, segundo Lindberg e Zackrisson (1991), existem limitadores que devem ser considerados com o uso de previsões no apoio à tomada de decisões, são eles:

- a incerteza sobre o futuro, a qual está conectada ao grau de precisão da previsão;
- a escolha do método aplicado para gerar a previsão;
- a qualidade e confiabilidade do conjunto de dados de entrada do método; e
- a interpretação correta da previsão, ou seja, a maneira como serão utilizadas as previsões na tomada de decisão.

Métodos para previsão servem como guia para a política de decisões de médio e longo prazo e, também, são úteis no monitoramento do desempenho de sistemas por meio de previsões frequentes de curto prazo. Tais métodos são divididos em duas categorias: qualitativos e quantitativos. Estes grupos diferem em termos de exatidão dos resultados previstos, nível de complexidade do modelo criado e a base lógica (dados históricos, opiniões de especialistas, ou estudos) a partir da qual a previsão é derivada (Ballou, 2006).

Métodos quantitativos costumam ser rígidos, mas consistentes, e podem trabalhar com um grande volume de dados, utilizando-se de dados históricos para detectar padrões de comportamento e estimá-los no futuro (Lindberg e Zackrisson, 1991). Tais modelos empregam ferramental matemático-estatístico para representar a realidade para a qual foram criados. Esta abordagem é essencial devido às particularidades de negócio envolvidas no competitivo ramo do varejo, sendo fundamental adotar estratégias pragmáticas para potencializar os resultados da empresa.

Por outro lado, ao utilizar apenas métodos quantitativos pode-se ignorar conhecimentos tácitos importantes para a tomada de decisão (West, 1994) e (Goodwin, 2002). Assim, uma abordagem para a obtenção de previsões mais acuradas é a integração de métodos quantitativos e qualitativos, sintetizando os benefícios da precisão mecânica dos métodos matemáticos e habilidades interpretativas dos especialistas (Webby e O'Connor, 1996).



Dentro desse contexto, a análise da demanda futura é utilizada neste artigo, como forma de estimar o período necessário para a venda de determinado lote de uma mercadoria e, com isso, determinar se haverá problemas com a data de validade do lote. Ao inserir a quantidade adquirida de um produto, é calculada a previsão de demanda. Como a validade do lote é conhecida, é aferido se o número de dias previstos para a venda é inferior ao número de dias até a data de validade. Da mesma forma, a previsão pode ser usada como indicativo se dentro do período compreendido entre os intervalos de reposição de um produto pelo fornecedor, pode ocorrer a falta do produto no estoque. Para isso, inicialmente são utilizados os métodos quantitativos para análise de séries temporais descritos na seção 2.1. Após a execução dos métodos, os diferentes resultados são apresentados ao responsável pela empresa para que ele possa tomar a decisão, considerando sua experiência, ou seja, acrescentando um caráter qualitativo a ela.

2.1 ANÁLISE DE SÉRIES TEMPORAIS

No estudo de técnicas de previsão de vendas, uma série temporal consiste em dados observados e armazenados em sucessivos incrementos de tempo. A análise do histórico das vendas é realizada por meio da construção de modelos matemáticos que procuram ajustar a série no decorrer do tempo para projetar resultados para períodos futuros. A análise de séries temporais exige somente valores passados da demanda, ou seja, da própria variável que se quer prever. A expectativa é de que o padrão observado nos valores passados forneça informação adequada para a previsão de valores futuros da demanda, sendo assim considerados métodos de extrapolação.

Na literatura existem vários métodos sugeridos para a modelagem de uma série temporal, tais como: média móvel; suavização exponencial; ARIMA (*Autoregressive Integrated Moving Average*) (Box e Jenkins, 1976); modelos estruturais (Harvey e Koopman, 1989) e Correa e Portugal (1998); redes neurais artificiais (Haykin, 2001) e Portugal e Fernandez (1996), entre outros.

As técnicas para análise de séries temporais são baseadas na identificação de padrões existentes nos dados históricos para posterior utilização no cálculo do valor



previsto (Wanke e Julianelli, 2006). Assim, todas essas técnicas consideram uma ou mais das cinco principais componentes das séries temporais:

- **Nível:** representa o comportamento das vendas caso não existisse nenhuma outra componente. Geralmente, é simplesmente o ponto inicial de uma série de vendas;
- **Tendência:** componente que representa o crescimento ou declínio de uma série no médio ou longo prazo;
- **Sazonalidade:** componente que representa um comportamento periódico de curto ou médio prazo. Por exemplo, as influências que a estação do ano provoca na vendas de determinado produto.
- **Ciclo:** semelhante à sazonalidade, mas reflete as flutuações ocorridas no longo prazo, sendo repetidas a cada três, quatro ou mais anos. Geralmente, esta componente é afetada pelas variações econômicas das nações;
- **Aleatoriedade:** as demais variações, não explicadas pela tendência, ciclo e sazonalidade, são denominadas variações aleatórias. Estas são causadas principalmente por eventos particulares e não recorrentes.

As próximas seções apresentam diferentes técnicas para estimar os valores de uma série temporal.

2.1.1 Análise de média móvel

Este método utiliza a média aritmética ou ponderada dos últimos n valores para prever o próximo valor. Desta forma, a cada nova observação disponível, o valor mais antigo é descartado e o mais recente é inserido para o cálculo da nova média (Wanke e Julianelli, 2006). Por necessitar de poucos dados históricos, e ser de fácil implementação e manutenção, o método da média móvel é bem difundido, porém deve apenas ser empregado para previsões de curto prazo (Makridakis, Wheelwright e Hyndman, 1997).

O cálculo de uma média móvel aritmética é definido por

$$MA = \frac{\sum V}{n} \quad (1)$$

onde V corresponde aos valores das observações e n ao período.

As desvantagens desse modelo estão relacionadas à falta de precisão ao trabalhar com séries que apresentam tendência ou sazonalidade.

2.1.2 Suavização exponencial

Modelos de suavização também se baseiam na ideia de que observações passadas contêm informações sobre o padrão da série temporal. O propósito de tais métodos é distinguir um padrão de comportamento de qualquer outro ruído que possa estar contido nas observações da série e então usar esse padrão para prever valores futuros da mesma. Este é um método popular e com bom custo benefício entre os métodos de extrapolação (Armstrong e Brodie, 1999). Ele consiste em aplicar uma média ponderada das observações de uma série temporal. Os pesos aplicados no método são determinados em progressão geométrica, atribuindo pesos maiores às informações mais recentes (Archer, 1980).

As maiores vantagens dos métodos de suavização são sua simplicidade e baixo custo, pontos importantes quando há a necessidade de previsão de milhares de itens, como no caso de sistemas de controle de estoque (Lemos, 2006).

Existem abordagens diferentes, de acordo com o tipo de série de dados a ser analisada (Makridakis, Wheelwright e Hyndman, 1997). Os métodos de suavização exponencial dividem-se em:

- Suavização Exponencial Simples;
- Suavização Exponencial Linear de *Holt*; e
- Método de *Holt-Winters*.

O método de suavização exponencial simples pode ser utilizado em séries sem tendência. Quando há dados que apontam uma tendência linear crescente ou decrescente, de acordo Martins e Laugeni (2006), recomenda-se o modelo linear de *Holt*, pois se deve considerar as constantes de suavização α e β . No caso de séries que apresentam um comportamento um pouco mais complexo, como sazonalidade, é utilizado o método multiplicativo de *Holt-Winters*. Essa técnica envolve, também, três equações com três



constantes de suavização que são associados a cada componente da série: nível, tendência e sazonalidade. Tendo em vista que as vendas de supermercados são fortemente influenciadas pelo componente de sazonalidade, este é o modelo utilizado neste trabalho. Suas fórmulas de cálculo estão definidas a seguir:

Modelo *Holt-Winters* (método multiplicativo):

$$V_t = (L_t + b_t) S_{t-s} \quad (2)$$

$$L_t = \alpha \left(\frac{Y_t}{S_{t-s}} \right) + (1 - \alpha) (L_{t-1} + b_{t-1}) \quad (3)$$

$$b_t = \beta (L_t - L_{t-1}) + (1 - \beta) b_{t-1} \quad (4)$$

$$S_t = \gamma \left(\frac{Y_t}{L_t} \right) + (1 - \gamma) S_{t-s} \quad (5)$$

Onde:

V_t : Valor da observação prevista no instante t ;

L_t : Estimativa do nível da série temporal no instante t ;

Y_t : Demanda real no instante t ;

b_t : Estimativa de tendência da série temporal no instante t ;

S_t : Componente sazonal t ;

s : Comprimento da sazonalidade;

L_{t-1} : Estimativa do nível da série temporal no instante anterior;

b_{t-1} : Estimativa de tendência da série temporal no instante anterior;

α , β e γ : Constante de suavização (com valores entre 0 e 1, não correlacionados, que controlam o peso relativo ao nível, à tendência e à sazonalidade, respectivamente).

Como todos os métodos de suavização exponencial, o modelo de *Holt-Winters* necessita de valores iniciais de componentes (neste caso, nível, tendência e sazonalidade) para dar início aos cálculos. Para a estimativa do componente sazonal, necessita-se no mínimo de uma estação completa da série de dados. A Constante de Suavização Exponencial deve ser escolhida de forma apropriada já que, quanto maior, maior o peso

atribuído às últimas observações. Constantes de Suavização baixas geram resultados que tendem ao valor médio da série e constantes altas produzem uma maior variabilidade dos resultados. Se a Constante de Suavização Exponencial for igual à zero, o modelo assemelha-se ao Modelo de Média Móvel. Alguns valores da Constante de Suavização Exponencial devem ser testados para cada série, a fim de determinar a sensibilidade da previsão comparada aos valores reais (McClave, Benson e Sincich, 2004).

2.1.3 Análise de regressão

Este é um modelo matemático que busca estabelecer se duas ou mais variáveis estão relacionadas de alguma forma. Métodos causais, como a regressão, procuram estabelecer uma relação entre a variável dependente, a demanda por exemplo, e as variáveis independentes, como outras variáveis internas ou externas à organização que afetam a demanda, tais como investimento em propaganda, qualidade do produto/serviço, preço, serviços oferecidos ao cliente, ou simplesmente a passagem do tempo. Variáveis independentes e a série histórica de demanda são analisadas para determinar a intensidade e tipo de relacionamento entre as variáveis. Se uma relação causal intensa é encontrada, as variáveis independentes podem ser usadas para prever demandas futuras (Mentzer e Gomes, 1989).

Quando se busca a relação de apenas uma variável de entrada com a variável resposta, tem-se a Regressão Linear Simples. Mas se deseja-se relacionar a variável resposta com mais de uma variável regressora, a Regressão Linear Múltipla é utilizada.

O método de Regressão Linear Simples, que é utilizado neste trabalho, considera uma relação linear entre Y e X e é dado pela equação (10) (Makridakis, Wheelwright e Hyndman, 1997).

$$V_t = \alpha + \beta X_t + e_t \quad (10)$$

Onde:

V_t : Valor da observação prevista no período t ;

α : Coeficiente linear (ponto que intercepta o eixo y);

β : Coeficiente angular (declividade da reta);

e_t : erro aleatório no período t (desvio da observação em relação ao modelo linear);

X_t : Variável preditora X no período t ;

A utilização do método de Análise de Regressão para prever demanda futura assume que os valores dos parâmetros do modelo matemático de análise de regressão permanecem constantes com o tempo, consideração que é mais apropriada para previsões de curto e médio prazo (Archer, 1980).

2.2 TRABALHOS RELACIONADOS

A previsão de valores futuros analisando-se uma série de dados é possível por diferentes métodos, porém no setor supermercadista é desejado que a abordagem da metodologia de previsão trate a questão da sazonalidade e tendência. No caso específico dos supermercados, sazonalidade significa que uma análise para previsão de vendas deve levar em consideração os diversos agentes que podem influenciar no aumento de vendas no comércio em datas especiais, como dia das mães, dia dos pais, natal e ano novo, por exemplo. Outros fatores externos como índices econômicos, concorrência, aspectos estocásticos também podem reduzir a demanda e impactar a assertividade de uma previsão.

Favero (2015) efetuou um estudo de caso numa rede varejista, usando métodos de projeção histórica e relatou que a utilização de métodos que incluem o componente de sazonalidade tem resultados superiores. Nos itens que estudou, métodos de suavização exponencial têm erros muito menores que os métodos de média móvel e seu uso pode levar a reduções de mais de 20 pontos percentuais no erro de previsão da demanda, em comparação com média móvel. Outro ponto importante, refere-se ao método de *Holt Winters*, que no estudo do mesmo autor apresentou os melhores resultados.

O método de *Holt Winters* também apresentou bom desempenho no estudo de Schrippe, Santos, Vincenzi, Moreira Junior e Iarczewski (2015) que analisou dados reais de uma empresa de cosméticos com vistas a previsão de lucros. Os autores afirmam que o fácil uso e o baixo custo de utilização do método de *Holt Winter* favorece sua viabilidade, sendo que em seus resultados os valores previstos se aproximam aos valores

reais com um erro percentual médio de apenas 16,09%. Porém, eles ressaltam que o método aplicado tem como premissa que fatores temporais (sazonais) semelhantes ocorridos em outros anos continuem ocorrendo nos próximos anos, em períodos semelhantes. Portanto, caso não ocorra mudanças bruscas na economia, o método costuma apresentar um percentual de aceitação satisfatório (Morettin e Snyder, 2012) e (Schrippe, Santos, Vincenzi, Moreira Junior e Iarczewski, 2015).

Siqueira (2016) comparou o desempenho do método de *Holt Winters* com os métodos de *Box-Jenkins* para previsão de demanda de passageiros em empresas de transporte rodoviário. O resultado obtido concluiu que a metodologia de *Box-Jenkins*, historicamente estimada como sendo mais precisa, na série temporal em estudo obteve resultados similares ao método de *Holt Winters*. Assim, evidencia-se que as duas metodologias de modelagem foram capazes de descrever os padrões comportamentais da série estudada, obtendo resultados aceitáveis, próximos aos valores reais observados.

Os métodos de *Holt Winters*, Sazonal Aditivo de *Winters* e *Box-Jenkins* também foram considerados em um estudo para previsão de vendas de uma rede de lojas varejistas. O método *Box-Jenkins* teve resultado superior usando a proposta SARIMA (0,1,1) (0,1,0), apesar de muito próximo aos resultados do método de *Holt-Winters* (Silva, 2008). Porém, este autor ressalta que para uma implementação segura do modelo como padrão para projeção de vendas da empresa, é necessário, após obtenção dos valores quantitativamente, inserir avaliações qualitativas, feitas pelos especialistas da organização, favorecendo um resultado confiável e com menores índices de erros.

3 MATERIAIS E MÉTODOS

Este trabalho propõe uma abordagem para tratamento de um problema específico, por meio de uma pesquisa aplicada, com abordagem quantitativa (Gil, 2010). Para os procedimentos metodológicos adotou-se uma pesquisa bibliográfica, com o intuito de selecionar os tipos de modelos de previsão a serem utilizados, e realizou-se um estudo de caso, para que os modelos pudessem ser implementados e avaliados.



3.1 COLETA E IMPORTAÇÃO DOS DADOS

O estudo de caso foi iniciado coletando-se os dados de venda em uma das lojas pertencente a uma rede de supermercados, que conta com mais de 20 lojas distribuídas na região Sul do Brasil. Foram escolhidos 20 produtos com maior recorrência de problemas com vencimento por data de validade, além de outros 10 produtos aleatórios, com o objetivo de avaliar as previsões para produtos com diferentes comportamentos referentes à perda por vencimento de validade. Os registros são referentes ao período de abril de 2015 até abril de 2019, totalizando um histórico de 4 anos. Após a consulta, separou-se um intervalo de três anos (abril de 2015 a abril de 2018) para treinamento do sistema, reservando o período do último ano dos dados para a comparação dos resultados previstos.

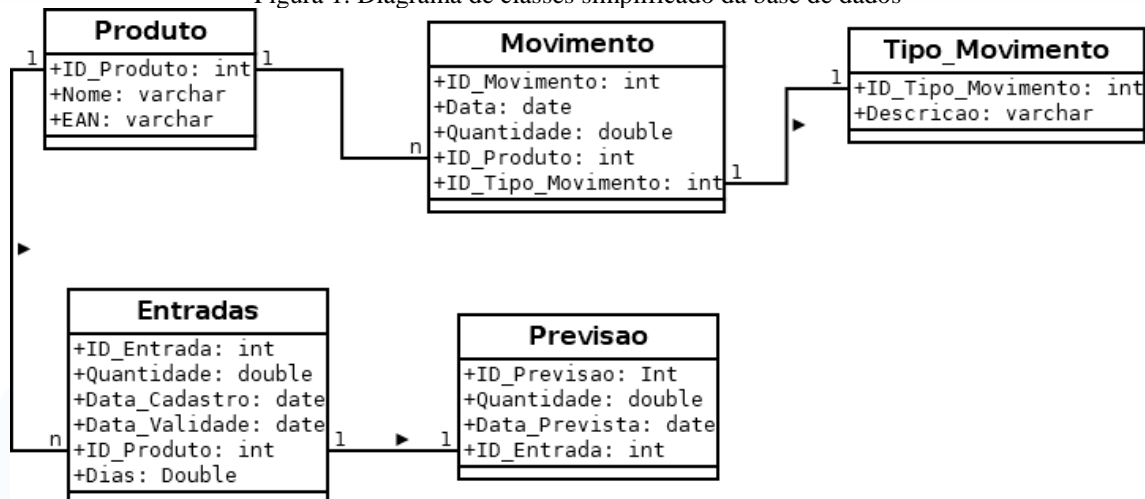
Foram obtidos os registros de todas as movimentações de entrada e saída, suas datas e quantidades envolvidas, organizadas por tipo de movimento. Os tipos de movimentação são classificados por códigos que separam os registros em mais de 60 definições, sendo os de interesse deste trabalho:

- 7 - venda de mercadoria ao consumidor;
- 15 - saída para devolução ao fornecedor (quanto a mercadoria vence e por acordo comercial o custo é absorvido pelo fornecedor);
- 480 - saída mercadoria com curta validade (utilizada quando são identificados produtos com data de validade em situação crítica, colocando-os para venda rápida com preço inferior);
- 10 - quebra, ocorre quando a data de validade do produto expira e o custo da perda é bancado pelo estabelecimento.

Com a série temporal real disponível para análise, seguiu-se para o desenvolvimento de uma solução de *software* que contempla a implementação dos modelos de previsão abordados na seção 2.

A construção do sistema teve início observando a estrutura e relações dos dados importados, de forma a separá-los em classes com suas respectivas associações. Os elementos originados podem ser observados na Figura 1, eles representam, de forma simplificada, os objetos identificados.

Figura 1. Diagrama de classes simplificado da base de dados



Fonte: Elaborada pelos autores

Cada classe do diagrama representa uma tabela do banco de dados e a importação dos dados para essas tabelas é feita pela própria aplicação, permitindo a importação de novos arquivos sempre que necessário. Essa funcionalidade facilita importações de qualquer ferramenta que contenha registros de movimentações de produtos. Ainda na Figura 1, as três entidades situadas na parte superior são populadas na importação de dados e as duas inferiores no uso da aplicação desenvolvida.

3.2 IMPLEMENTAÇÃO DAS INTERFACES DE CADASTRO

Com o objetivo de agregar funcionalidades à aplicação e possibilitar a manipulação dos dados a serem trabalhados, foram criadas páginas WEB para inserção, edição, exclusão e listagem dos registros.

Na aplicação desenvolvida, foram criadas interfaces para as seguintes entidades:

- Produto: Tela de cadastro e edição, listagem de todos os registros e listagem com busca por código EAN.
- Movimento: Tela de cadastro e edição, listagem com busca de produto por nome ou código EAN, filtro por tipo de movimentação e listagem de todas as movimentações.
- Tipo de movimento: Tela de cadastro, edição e listagem de todos os registros.

- Entrada de produto: Tela de cadastro, edição, listagem com busca de produto por nome ou código EAN e listagem de todas os registros.
- Previsão: Listagem com busca de produto por nome ou código EAN.

3.3 CÁLCULOS

Esta seção descreve a implementação dos métodos de análise de séries temporais descritos na seção 2. No sistema proposto neste artigo, o valor da previsão é uma composição dos resultados de diferentes métodos.

3.3.1 Média móvel

A fim de estabelecer uma previsão inicial de venda para cada produto contido na série analisada, faz-se o cálculo da média móvel contemplando os três últimos anos de vendas. Assim, é possível ter uma estimativa do nível de vendas para uma análise primária.

Como o uso de média móvel não é adequado para séries que possuem o componente de sazonalidade, três cálculos de médias móveis adicionais foram feitos de forma a contemplar apenas o período de vendas entre o cadastro do produto e a sua data de validade, nos três últimos anos. No recebimento de um produto são inseridas a data de entrada e data de validade, sendo esse intervalo usado para consultar o mesmo período dos registros de venda dos anos de 2015, 2016 e 2017. Por exemplo, se a entrada de um produto ocorrer em 01/05/2018 e seu vencimento em 15/07/2018, será calculado a média de vendas de 01/05/2017 à 15/07/2017 como média 1, 01/05/2016 à 15/07/2016 como média 2 e 01/05/2015 à 15/07/2015 como média 3.

Por fim, uma média aritmética é calculada considerando a média móvel do período completo e as médias móveis dos últimos três anos, conforme explicado no parágrafo anterior. O objetivo é obter uma amostra que proporcione um cálculo relacionado ao período sazonal do produto, utilizando para isso, as três médias móveis de três anos respectivamente, o que também busca suavizar grandes disparidades.

3.3.2 Análises de regressão

A análise de regressão consiste na verificação da existência de uma relação funcional entre uma variável dependente e uma variável independente. No algoritmo implementado o objetivo foi chegar a um bom ajuste dos valores previstos em função do nível de dados não estocásticos; para isso, adotou-se como variável dependente os valores diários de venda do produto analisado e como variável independente a sequência de dias da série. No ajuste, foi usada a abordagem dos mínimos quadrados que é uma das técnicas mais usuais para regressão linear (Werner, 2004). As listas de variáveis dependente e independente são preenchidas por meio de uma consulta aos registros de venda do produto analisado, contemplando todo o período disponível para treinamento do modelo (três anos).

3.3.3 Métodos de *Holt-Winters*

O algoritmo do método de *Holt-Winters* tem início com a criação de uma lista das movimentações diárias de venda do produto consultado nos três anos destinados ao treinamento e inicialização dos coeficientes de suavização exponencial do nível, tendência e sazonalidade. Inicialmente, fez-se uma simulação de entrada com os três parâmetros de suavização com o valor de 0,5. Na seção de resultados são apresentados resultados obtidos com estes e outros parâmetros testados, com o intuito de ilustrar a importância do ajuste dos mesmos.

Os valores previstos são aplicados de forma regressiva de acordo com o número de dias disponíveis para a venda do produto, desde a consulta até a data de validade compondo a previsão de venda no período.

3.3.4 Medidas de avaliação

Com o objetivo de avaliar o desempenho dos modelos ao prever os valores reais, foram examinadas as propriedades das medidas de erro utilizadas nos trabalhos citados em 2.2, assim como sua adequação às séries temporais analisadas nesse estudo. Um dos principais pontos a serem analisados é a diversidade do volume de vendas dos diferentes

produtos, o que torna mais importante a análise percentual do que em quantidades absolutas.

O erro médio absoluto percentual (MAPE) expressa precisão como uma porcentagem do erro, sendo ele calculado como a média do erro percentual:

$$MAPE = \left(\frac{1}{n} \sum \frac{|Real - Previsão|}{|Real|} \right) * 100 \quad (12)$$

O MAPE indica quanto, em média, o modelo está errando sem compensar erros negativos com erros positivos (Belge, 2012).

3.3.5 Implementações de análise qualitativa

Normalmente, quem está à frente de determinada atividade possui experiência relevante neste aspecto. Deste modo, pode-se dizer que a opinião da equipe é importante como complemento às previsões, uma vez que eles estão em contato direto com a demanda. Para auxiliar na definição de quais entradas são críticas (com risco de vencimento), na interface onde são apresentados os resultados, é possível visualizar a previsão de cada um dos métodos, possibilitando comparar os resultados.

Desta forma, o profissional que utiliza o sistema pode:

- Analisar se os resultados apresentados pelos diferentes métodos convergem para quantidades semelhantes ou não;
- Observar se a previsão de venda total do lote é anterior ou posterior a data de validade do produto, bem como o qual longe está desta data;
- Verificar o histórico de vencimento deste produto;

A partir destas análises e de sua experiência, ele pode considerar outros aspectos não contemplados pela análise quantitativa, para decidir se marca o produto como crítico ou não, utilizando para isso o campo “Marcar como crítico”. Dessa forma, posteriormente os resultados marcados com a definição de críticos podem receber maior acompanhamento do departamento operacional, visando um tratamento adequado

destinado a aumentar a venda e evitar que ainda exista estoque na data de validade do produto.

4 RESULTADOS E DISCUSSÃO

Para avaliar as interfaces do sistema e o desempenho obtido pelos métodos implementados, foram simuladas entradas de produtos com as quantidades e períodos selecionados de acordo com os históricos das movimentações de entrada disponíveis.

4.1 APRESENTAÇÃO DO SISTEMA

As funcionalidades da aplicação foram projetadas para usar os modelos de previsão como uma forma de determinar se a quantidade informada de um produto será vendida antes que a data de vencimento ocorra. Nesta seção, é apresentada a função de entrada de produto, sua previsão de venda, e, também, são mostradas suas interfaces gráficas para uma melhor compreensão.

Com os históricos de venda já importados, conforme visto na seção 3.1, é possível realizar a entrada em estoque de um produto a partir da opção *Entrada*, que fica disponível no menu principal e pode ser visualizada em qualquer tela da aplicação. Para que a entrada ocorra, inicialmente deve-se pesquisar o produto desejado a partir do seu código EAN (código de barras) para que, então, a tela habilite os campos de inserção de quantidade, data da entrada e data da validade.

Após salvar o registro da entrada, a aplicação efetua os cálculos necessários para estimar quantas unidades serão vendidas daquele lote até a data de validade, com base em cada um dos três métodos implementados. Além disto, calcula-se a data prevista pelo método de Holt-Winters em que a quantidade recebida será vendida, auxiliando a tomada de decisão para a reposição do produto, o que é importante no tratamento de rupturas de estoque.

Uma interface importante na aplicação é a listagem de previsões. Nela é possível consultar uma previsão usando uma busca pelo código EAN do produto, pelo nome, intervalo de datas, ou caso nenhum campo seja preenchido retorna-se todos os registros de previsão, como mostra a Figura 2.

Figura 2. Interface para visualização das previsões realizadas

ID	Quantidade	Produto	Data Entrada	Data vencimento	Data prevista pra vender	Dias para venda	Quantidade prevista de venda no período	Situação
751	3500.0	PAO FRANCES K	01/08/2018	20/08/2018	21/08/2018	19.0	3278.0	Crítico
752	3000.0	PAO FRANCES K	10/06/2018	30/06/2018	27/06/2018	20.0	3537.0	Normal
754	8000.0	REFRIG COCA COLA PET 2L	01/09/2018	25/10/2018	24/10/2018	54.0	8445.0	Crítico
755	9000.0	REFRIG COCA COLA PET 2L	01/10/2018	25/11/2018	28/11/2018	55.0	9133.0	Crítico
758	4350.0	CERVEJA BUDWEISER LT 350ML	12/08/2018	24/09/2018	07/09/2018	43.0	7509.0	Normal

Fonte: Elaborada pelos autores

4.2 COMPARAÇÃO DOS RESULTADOS

Com o intuito de analisar os resultados gerados pelo sistema, foram registradas entradas de 30 produtos, sendo:

- Vinte produtos com histórico de problema com vencimento: itens que já tiveram duas ou mais ocorrências de quebra por data de validade em um ano.
- Dez produtos aleatórios sem recorrência de problema com vencimento: itens escolhidos aleatoriamente, com o pré-requisito de histórico de venda dentro de todo o intervalo analisado.

Para cada produto foram cadastradas duas entradas. Estas possuem as mesmas datas de cadastro, validade do produto e quantidades compradas, de registros reais do período entre abril de 2018 a abril de 2019. As entradas contemplavam dois períodos distintos, a fim de simular uma situação sazonal (períodos próximos ao Natal, Páscoa ou Carnaval, de acordo com o tipo de produto) e uma situação estacionária. Os dados de abril de 2015 a abril de 2018 foram utilizados para calcular a previsão de vendas dos produtos em cada um dos períodos cadastrados e este valor foi comparado com as vendas reais realizadas no período de abril de 2018 a abril de 2019 para verificar seu grau de precisão.

Assim, pôde-se avaliar o resultado de previsão dos diferentes modelos para os diferentes produtos e períodos. Os erros correspondem ao valor do MAPE. Os intervalos e quantidades das entradas dos produtos com recorrência de problema com data de validade expirada.

Para facilitar a apresentação, foram selecionados aleatoriamente 8 produtos, dos 20 analisados com recorrência de problemas, e 5 produtos aleatórios dentro os 10 analisados.

Comparando os resultados obtidos pelos métodos de previsão com as vendas reais dos produtos com histórico de problema, percebe-se uma elevada variação no percentual do MAPE, como mostram as Tabelas 1 e 2.

O ajuste da previsão dos modelos de Análise de Regressão e Exponencial de *Holt-Winters* apresentaram desempenho médio melhor que a Média Móvel. Embora tenha-se conseguido um bom ajuste para alguns determinados produtos em todos os métodos, em termos gerais, o erro médio é elevado. Isto ocorre porque as séries temporais dos produtos com histórico de problemas contêm características que não favorecem um melhor resultado.

Tabela 1. Estimativa de vendas pelos diferentes métodos dos produtos com histórico recorrente de perda por vencimento

Código	Venda Real	Holt-Winters	MAPE	Regressão	MAPE	Média	MAPE
1	8199	6199	65,93	7271	60,04	9510	47,74
1	18787	27139	44,45	28035	49,22	22255	18,45
2	158	252	59,49	170	7,59	297	87,97
2	412	658	59,7	408	0,97	815	97,81
3	620	411	33,7	246	60,32	974	57,09
3	594	457	23,06	330	44,44	1326	123,23
4	5296	4563	13,84	5714	7,89	5591	5,57
4	4350	3376	22,39	4606	5,88	5359	23,19
5	338	389	15,08	448	32,54	517	52,95
5	236	213	9,74	188	20,33	227	3,81
6	90	92	2,22	99	10	105	16,66

6	357	799	123,8	747	109,24	606	69,74
7	5375	5638	4,89	4802	10,66	8080	50,32
7	15204	8978	40,94	14103	7,24	21326	40,26
8	1193	1403	17,6	1283	7,54	1279	7,2
8	1415	1353	4,38	1777	25,58	1384	2,19

Fonte: Elaborada pelos autores

Tabela 2. Valores mínimo, médio e máximo da MAPE de cada uma das técnicas para os produtos com histórico recorrente de perda por vencimento

MAPE	Holt-Winters	Análise de Regressão	Média Móvel
Médio	35,79	28,93	46,80
Mínimo	2,22	0,97	2,19
Máximo	123,81	109,24	123,23

Fonte: Elaborada pelos autores

Investigando os registros dos variados tipos de movimentação disponíveis nos dados importados, identificou-se aspectos comuns que podem ser determinantes no desempenho. Como eles já possuem ocorrências em que houve vencimento do produto em estoque, a venda deixa de ocorrer durante períodos variados devido a estes eventos, impactando na análise desses períodos e distorcendo os indicadores de tendência e sazonalidade. Além disso, nesse tipo de produto é comum a ocorrência de promoções e outras ações que promovam uma venda acentuada em um curto período, novamente distorcendo os resultados dos métodos pois são eventos estocásticos.

Para confirmar esta hipótese, foram selecionados 5 produtos aleatórios, sem histórico de problemas com vencimento e com registros de vendas em todo o período analisado. Desta forma, os componentes nível, tendência e sazonalidade podem ser considerados os protagonistas do comportamento da série. Os resultados podem ser visualizados nas Tabelas 3 e 4.

Essa classe de produtos apresentou resultados melhores que os produtos com histórico de vencimento. As médias de erro MAPE dos modelos de *Holt-Winters* e *Análise de Regressão* foram respectivamente: 13,87% e 17,28%.

Tabela 3. Estimativa de vendas pelos diferentes métodos dos produtos sem histórico recorrente de perda por vencimento

Código	Venda Real	Holt-Winters	MAPE	Regressão	MAPE	Média	MAPE
10	6385	5143	19,45	4105	35,7	10425	63,27
10	14011	13369	4,58	10057	28,22	21010	49,95
11	6936	5934	14,44	5580	19,55	8143	17,40
11	9532	11071	16,14	7553	20,76	16550	73,62
12	6549	6900	5,35	7166	9,42	7084	8,16
12	1412	1566	10,90	1385	1,91	1382	2,12
13	910	764	16,04	726	20,21	1206	32,52
13	4789	5122	6,95	4290	10,41	7649	59,72
14	672	600	10,71	580	13,69	980	45,83
14	1758	2359	34,18	1530	12,96	2805	59,55

Fonte: Elaborada pelos autores

Tabela 4. Valores mínimo, médio e máximo da MAPE de cada uma das técnicas para os produtos sem histórico recorrente de perda por vencimento

MAPE	Holt-Winters	Análise de Regressão	Média Móvel
Médio	13,87	17,28	41,21
Mínimo	4,58	1,91	2,12
Máximo	34,18	35,7	73,63

Fonte: Elaborada pelos autores

É possível avaliar que os métodos de *Holt-Winters* e *Regressão* conseguem um ajuste melhor em séries que não contenham períodos sem registro, com dados históricos em que o comportamento costuma repetir após uma temporada completa.

Após analisar os resultados das duas classes de produtos, pode-se afirmar que os diferentes comportamentos das séries temporais provenientes do caso estudado compõem um desafio para que os modelos de previsão encontrem uma aderência adequada. Um outlier pode deteriorar a qualidade e assertividade do modelo utilizado. Da mesma forma, a análise da fonte da série de dados também se torna relevante, pois como no caso apresentado, pode gerar discrepâncias que influenciam negativamente o resultado do modelo.

Apesar dos erros, os resultados alcançados viabilizam o uso destes modelos de forma a estimar possíveis problemas com data de validade, pois não são determinantes na indicação se o produto terá problemas de vencimento da data de validade, e sim se constituem em mais um dado a ser considerado pelos responsáveis pela decisão.

A análise dos resultados das diferentes técnicas permite que o usuário avalie se eles estão próximos, convergindo na mesma direção, o que significa uma maior confiabilidade das previsões, ou muito distantes. Estes fatores devem influenciar na análise qualitativa pessoal, tornando a experiência do profissional relevante na interpretação, além de possibilitar que ele escolha qual considerar, com base nas simulações anteriores e nas suas percepções, levando em conta, também, fatores como tipo de produto, aspectos econômicos, época do ano, dentre outros.

Uma forma de melhorar os resultados apresentados consiste na realização de acompanhamentos regulares na aplicação desenvolvida. Como exemplo, a inserção semanal do estoque disponível de determinado produto gerará previsões cada vez mais assertivas devido a atualização dos valores que são calculados. Caso seguidas inserções apontem datas previstas para venda do lote que estejam próximas, a interpretação é facilitada, pois uma consulta permite identificar se as vendas reais estão comprovando ou refutando as previsões. Com isso, as previsões auxiliam as tomadas de decisões, fornecendo as informações básicas para planejamento e controle.

Na aplicação desenvolvida é possível realizar consultas ao histórico de previsões de diferentes formas. Um relatório que mostre produtos com seguidas interpretações de situação crítica, deve ser avaliado pela equipe de gestão para que sejam tomadas ações, de forma a promover tratamento adequado e antecipado, evitando seu vencimento.

5 CONCLUSÃO

O uso de modelos combinados de previsão para apurar de forma preditiva o prognóstico do volume de vendas de uma empresa é testado neste artigo como forma de prever a possibilidade de o estoque não ser vendido antes que a data de validade do produto expire.

Os dados de diversos produtos e períodos foram comparados e os resultados obtidos comprovam que os modelos implementados têm boa capacidade de prever a demanda futura, com o modelo de *Holt-Winters* se sobressaindo aos demais com um erro MAPE de 13,87%. Porém, cabe mencionar, que as taxas de erro podem não refletir o ajuste dos modelos a qualquer produto, visto que ainda são necessários estudos para que

se possa desenvolver um modelo de previsão adequado a toda variedade existente em um estabelecimento comercial. Durante o desenvolvimento, uma das dificuldades foi o acesso a um universo maior de históricos de produtos a fim de diversificar os testes, bem como a dificuldade de trabalhar com a previsão do comportamento do tipo de série analisada, já que alguns produtos podem variar a venda em mais de 1200% em um intervalo de 10 dias.

Por fim, a tarefa de fazer previsões não se resume somente a aplicar modelos em séries de dados e, com isso, gerar resultados que serão utilizados em decisões importantes dentro da empresa. Essa atividade é complexa, pois as pessoas envolvidas devem compreender o comportamento da série de dados e buscar através de observações críticas, otimizar o resultado apresentado.

Como resultado deste trabalho, conclui-se que o software desenvolvido pode ter êxito em auxiliar na redução das ocorrências de produto vencido no estoque das empresas. Em uma situação de uso real por uma empresa, cada modelo de previsão precisa ser avaliado e melhorado continuamente através de métodos que contribuam para identificar erros. Com isso, os resultados do modelo podem ser ajustados, tornando-se adaptáveis as mudanças que vão ocorrendo na empresa.

Um exemplo de ajuste é a identificação e tratamento de outliers. Por exemplo, quando um produto deixa de ser vendido por ruptura no estoque, ao invés de considerar a venda como zero naquele dia, pode-se atribuir a média de vendas do período, o que torna a série mais consistente.

Outra possibilidade de melhoria refere-se aos coeficientes do Método de *Holt-Winters*. Nos testes realizados, utilizou-se 0.5 para as três constantes α , β e γ . Um teste realizado com outro produto, usando estes mesmos valores, previu a venda de 6041 unidades enquanto o valor real das vendas foi de 7609, gerando um MAPE de 20,6%. Para o mesmo período e produto o cálculo foi refeito, com os valores de α , β e γ de respectivamente, 0,9; 0,59 e 0,29. A alteração dos valores dos coeficientes proporcionou um melhor ajuste da série, visto que o novo valor de previsão foi de 6950 unidades, reduzindo o MAPE para 8,66%, comprovando o potencial de ajuste que a escolha de coeficientes adequados a série analisada promove. Assim, a implementação de um



algoritmo para determinar o valor dos coeficientes, tomando como base a série história de vendas de cada produto apresenta-se como uma estratégia de melhoria promissora. Para o modelo de análise de regressão, sugere-se incorporar outras variáveis independentes, como por exemplo o preço do produto, criando um modelo de regressão múltipla, o que deve levar a melhores resultados.

Por fim, ressalta-se que é importante entender quais características da série fazem com que um método tenha resultado melhor do que o outro. Assim, além de mostrar os três resultados ao usuário do sistema, pode-se indicar qual dos três métodos provavelmente se adeque melhor àquele produto, tendo um maior peso na decisão.

REFERÊNCIAS

Abras, P. (2018). Perdas do setor supermercadista somaram R\$ 6,4 bilhões em 2017. Recuperado de: <http://www.abras.com.br/economia-e-pesquisa/perdas/pesquisa-2018>.

Archer, A. (1980). Forecasting demand: quantitative and intuitive techniques. *International Journal of Tourism Management*, 1(1), 5–12. <https://doi.org/10.1177/004728758001900190>.

Armstrong, J. (1988). Research needs in forecasting. *International Journal of Forecasting*, 4(3), 449–465. [https://doi.org/10.1016/0169-2070\(88\)90111-2](https://doi.org/10.1016/0169-2070(88)90111-2).

Armstrong, J. S. & Brodie, R. J. (1999). Forecasting for marketing. In: Hooley, G. J. & Hussey, M. K. (Eds.), *Quantitative Methods in Marketing* (92-120). London: International Thompson Business Press.

Ballou, R. (2006). *Gerenciamento da Cadeia de Suprimentos: Logística empresarial*. Porto Alegre: Bookman.

Belge, C. (2012). Avaliando e aprimorando previsões com base nos erros. Recuperado de: <http://belge.com.br/blog/2012/02/01/avaliando-e-aprimorando-previsoes-com-base-nos-erros/>.

Box, G. E. P. & Jenkins, G. M. (1976). *Time Series Analysis, Forecasting and Control*. San Francisco: Holden-day.

Correa, W. R. & Portugal, M. S. (1998). Previsão de séries de tempo na presença de mudança estrutural: redes neurais artificiais e modelos estruturais. *Economia Aplicada*, 2(3), 487–518.

Favero, E. P. (2015). *Método de previsão de vendas: um estudo de caso numa rede varejista* (Monografia de Graduação). Recuperado de: Biblioteca Digital USP (<http://www.tcc.sc.usp.br/tce/disponiveis/18/18062300/tce-17112015-123704/publico/FaveroEduardoPerin.pdf>).

Gil, A. C. (2010). *Como Elaborar Projetos de Pesquisa*. São Paulo: Atlas.

Goodwin, P. (2002). Integrating management judgment and statistical methods to improve short-term forecasts. *OMEGA International Journal of Management Science*, 30(2), 127–135. [https://doi.org/10.1016/S0305-0483\(01\)00062-7](https://doi.org/10.1016/S0305-0483(01)00062-7).

Harvey, A. E. & Koopman, S. (1989). *Forecasting Structural Time Series Models and the Kalman Filter*. Cambridge: Cambridge university press.

Haykin, S. (2001). *Redes Neurais: Princípios e prática*. Porto Alegre: Bookman.

Lemos, F. O. (2006). *Metodologia para seleção de métodos de previsão de demanda* (Dissertação de Mestrado). Recuperado de: Escola de Engenharia - UFRGS (<http://www.producao.ufrgs.br/arquivos/publicacoes/fernandooliveiralemos.pdf>).

Lindberg, E. & Zackrisson, U. (1991). Deciding about the uncertain: the use of forecasts as an aid to decision-making. *Scandinavian Journal of Management*, 7(4), 271–283. [https://doi.org/10.1016/0956-5221\(91\)90003-J](https://doi.org/10.1016/0956-5221(91)90003-J).

Makridakis, S., Wheelwright & Hyndman, R. J. (1997). *Forecasting: Methods and applications*. New York: John Wiley.

Martins, P. G. & Laugeni, F. P. (2006). *Administração da Produção*. São Paulo: Saraiva.
McClave, J., Benson, P., & Sincich, T. (2004). *Statistics for Business and Economics*. New Jersey: Prentice Hall.

Mentzer, J. T. & Gomes, R. (1989). Evaluating a decision support forecasting system. *Industrial Marketing Management*, 18(4), 313–323. [https://doi.org/10.1016/0019-8501\(89\)90011-4](https://doi.org/10.1016/0019-8501(89)90011-4).

Morettin, J. W. & Snyder, R. D. (2012). Forecasting intraday time series with multiple seasonal cycles using parsimonious seasonal exponential smoothing. *OMEGA International Journal of Management Science*, 40(6), 748–757. <https://doi.org/10.1016/j.omega.2010.03.004>.

Portugal, M. & Fernandez, G. L. (1996). Redes neurais artificiais e previsão de series econômicas: uma introdução. *Nova Economia*, 6(1), 51–72.

Santos, C. E. (2016). Relatório prevenção de perdas 2016. Recuperado de: [http://www.apasshow.com.br/wp-content/uploads/2016/02/](http://www.apasshow.com.br/wp-content/uploads/2016/02/Apresentacao_APAS_final_revisado.pdf)
[Apresentacao_APAS_final_revisado.pdf](http://www.apasshow.com.br/wp-content/uploads/2016/02/Apresentacao_APAS_final_revisado.pdf).

SBVC, P. (2016). Supermercados têm maior índice de perdas no varejo. Recuperado de: <http://sbvc.com.br/supermercados-indice-perdas>.

Schrippe, P., Santos, S. R., Vincenzi, S. L., Moreira Junior, F. J. e Iarczewski, A. M. W. (2015). Estratégia empresarial para a natura: análise de correlação e previsão dos lucros por meio do modelo holt-winters. *Reuna*, 20 (4), 5–26.

Silva, A. F. (2008). *Definição de um modelo de previsão das vendas da rede varejista Alfabeta* (Monografia de Graduação). Recuperado de: UFJF (http://www.ufjf.br/engenhariadeproducao/files/2014/09/2008_3_Andr%C3%A9.pdf).

Siqueira, A. C. (2016). *Previsão da demanda por meio de técnicas de séries temporais em empresa de serviços de transporte rodoviário* (Monografia de Graduação).

Recuperado de: Centro Universitário Univates (<https://www.univates.br/bdu/handle/10737/1386>).

Wanke, P. & Julianelli, L. (2006). *Previsão de Vendas: Estratégias*. São Paulo: Atlas.

Webby, R. & O'Connor, M. (1996). Judgmental and statistical time series forecasting: a review of the literature. *International Journal of Forecasting*, 12(1), 91–118. [https://doi.org/10.1016/0169-2070\(95\)00644-3](https://doi.org/10.1016/0169-2070(95)00644-3).

Werner, L. (2004). *Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião* (Tese de doutorado). Recuperado de: Repositório digital Lume – UFRGS (<https://lume.ufrgs.br/handle/10183/4189>).

West, D. (1994). Number of sales forecast methods and marketing management. *Journal of Forecasting*, 13(4), 395–407. <https://doi.org/10.1002/for.3980130405>.