



MODELOS DE PREVISÃO DE DEMANDA DE CURTO PRAZO NO VAREJO SUPERMERCADISTA: UMA ANÁLISE ENTRE MÉDIA MÓVEL E *HOLTWINTERS*

Marina Costa Fogaça - marina.costa.fogaca@gmail.com
Universidade Federal do Espírito Santo (UFES)

Maria Clara de Oliveira Leite - leite.mariaclaraoliveira@gmail.com
Universidade Federal do Espírito Santo (UFES)

Hélio Zanquetto Filho - zanquetto@gmail.com
Universidade Federal do Espírito Santo (UFES)

RESUMO

O objetivo geral é identificar qual das duas técnicas de previsão (média móvel e *holt-winters*) resulta em maior acurácia no caso da rede de supermercado X, realizando uma análise entre o método adotado atualmente pelo supermercado (média móvel) e o *Holt-Winters*, escolhido principalmente por levar em consideração a sazonalidade da série. A medida de acurácia utilizada foi o RMSE (*Root Mean Squared Error*), por ser o mais utilizado na literatura e por penalizar erros com maiores amplitudes, visto que grandes excessos ou faltas de estoque podem gerar prejuízos mais graves. Trata-se de uma pesquisa quantitativa, com uso de dados secundários disponibilizados pela organização e foco no setor de congelados do supermercado, dado seu elevado custo de armazenagem e sua característica perecível. Foram analisados oito produtos pelo período de 24 meses por meio do software R Project. Nenhuma das técnicas utilizadas reduziu significativamente o erro da série, sendo a melhor acurácia correspondente à 50% do valor médio de venda do produto. Após a análise dos resíduos, não foi encontrada uma explicação clara para resultados tão próximos, no entanto, foram propostos estudos futuros para aprimorar a capacidade preditiva levantando questionamentos sobre os métodos de acurácia, *input* de novas variáveis nos modelos e outros.

Palavras-chave: *Data Science*. Varejo Supermercadista. Séries Temporais. *Holt-Winters*. Previsão de Demanda.

1. INTRODUÇÃO

A presente pesquisa trata de *Data Science* aplicada ao setor supermercadista. *Data Science* é uma ferramenta responsável por nortear a extração de conhecimento útil através dos dados, por uma análise computadorizada, cujo potencial de melhorar o desempenho nos negócios por meio de uma tomada de decisões mais orientada está comprovado no ambiente empresarial da atualidade. *Data Science* é um conjunto de princípios, processos e técnicas que permitem a extração de conhecimento útil a partir de dados, visando aprimorar a tomada de decisão. Esse pensamento analítico torna a empresa estatisticamente mais produtiva, com maior retorno sobre ativos, além de agregar valor de mercado. Esta é uma importante ferramenta estratégica visto que ultrapassa os limites da intuição do gestor. Além disso, permite que novos atributos de interesse sejam sistematicamente descobertos, contextualizados e agregados na formulação de soluções para os problemas do negócio (PROVOST; FAWCETT, 2016).

Das aplicações de *data Science* disponíveis, a previsão de demanda permite fazer planos de produção, estoque, distribuição e compras de forma adequada e monitorada. Esse planejamento possibilita que a empresa busque identificar um padrão de vendas dos produtos, minimizando erros na sua oferta e agregando valor no atendimento aos clientes. No entanto, ainda existem fatores que não podem ser previstos interferindo nesse comportamento, o que aumenta a complexidade do processo preditivo (CECATTO; BELFIORE, 2015). Para compreender e analisar esse contexto, buscou-se estudar uma rede de supermercados do Espírito Santo – que por motivos de sigilo será chamado de X – que conta com lojas e um centro de distribuição (C.D) responsável pelo abastecimento diário.

O objetivo geral deste trabalho é, portanto, identificar qual das duas técnicas de previsão testadas (média móvel e *holt-winters*) resultam em maior acurácia no caso da rede de supermercado X, especificamente da loja 1. Lembrando que, conforme Heizer e Render (2001), um modelo de previsão não é necessariamente superior ao outro, visto que seus resultados dependem de cada caso analisado. Para isto, foram analisados os dados presentes na base disponibilizada pela organização para a realização deste estudo, aplicadas as técnicas de previsão média móvel e Holt-Winters, e, por fim, os resultados foram comparados através da análise da acurácia das previsões.

A relevância e as contribuições práticas desta pesquisa estão relacionadas ao aumento da necessidade de tratar e compreender dados, tanto textuais quanto numéricos, transformandoos em informações úteis que podem ser interpretadas e trabalhadas gerando novos conhecimentos ainda mais profundos, dado o crescimento do volume de informações disponíveis (PROVOST; FAWCETT, 2016). Além disso, ao unir as áreas de estatística, tecnologia da informação e administração em uma mesma pesquisa, o pensamento analítico é potencializado pois agrega diversas ferramentas e conhecimentos ao mesmo processo. De acordo com Provost e Fawcett (2016), quanto mais desenvolvido é o pensamento analítico, maiores são as capacidades de aplicar conhecimento, intuição e criatividade no processo.

Mercadologicamente este trabalho aumenta a capacidade gerencial de interpretação e manipulação de dados para o setor varejista brasileiro. As empresas comerciais brasileiras se dividem em três segmentos distintos: a) comércio de veículos, peças e motocicletas; b) comércio por atacado; c) e comércio varejista. Com base na Pesquisa Anual de Comércio – PAC, as empresas comerciais registraram, somente no comércio varejista, em 2019, uma receita bruta de R\$ 2,0 trilhões. Ao todo (três segmentos), registrou-se uma receita operacional líquida de aproximadamente R\$ 4,0 trilhões, das quais 44,9% foi gerada pelo setor varejista. Dos 22 subgrupos que compõem o setor comercial, o de hipermercados e supermercados constituiu um dos três principais e foi responsável por cerca de 12,9% da receita operacional líquida gerada em 2019. Relacionado ao consumo das famílias, o setor avançou 2,3 pontos percentuais no período entre 2010 e 2019 (IBGE, 2019). Além disso, de acordo com Fildes *et al* (2019), Hoeltgebaum *et al* (2021) e Levy, Weitz, & Grewal (2012 *apud Fildes et al, 2019*), as decisões estratégicas a serem tomadas pelos varejistas normalmente dependem de previsões e de sua precisão.

2. REVISÃO BIBLIOGRÁFICA

2.1. PREVISÃO DE DEMANDA

Para realizar as previsões, pode-se adotar basicamente dois métodos: a) quantitativos, que envolvem dados históricos e modelos matemáticos para analisá-los; b) qualitativos, que são baseados nas intuições e expertises de especialistas na área. Nenhum método é perfeito, portanto, trabalhar com previsões é exercer um esforço contínuo em reduzir o erro dos resultados obtidos. Acredita-se que unir os métodos (quantitativos e qualitativos) resulta em um modelo preditivo de maior sucesso. (GONÇALVES, 2007; WANKE, 2010; STEVENSON, 2001; SLACK; CHAMBERS; JHONSTON, 2009; DAVIS; AQUILANO; CHASE, 2003; HEIZNER; RENDER, 2001).

O enfoque empregado nesta pesquisa é quantitativo. A abordagem quantitativa, conforme descrição de Davis, Aquilano e Chase (2003), subdivide-se em séries temporais (onde o futuro está relacionado com as características da demanda passada) e modelos causais (que, a partir de uma relação causa-e-efeito, pode-se analisar a demanda através das inferências de fatores internos e externos). São utilizadas aqui as séries temporais. O modelo causal não será adotado.

2.2. SÉRIES TEMPORAIS

Séries temporais acompanham o desenvolvimento de uma variável em um período. Após remover a informações que tem causa conhecida, extrapolam-se as características descobertas desse comportamento passado para prever o futuro (SLACK; CHAMBERS; JHONSTON, 2009). As séries temporais podem ser decompostas em tendência, efeitos sazonais, efeitos cíclicos e variável aleatória (Figura 1), sendo a primeira é caracterizada por uma alteração gradual nos dados, inclinando o gráfico de demanda para cima ou para baixo. Os efeitos sazonais são conhecidos pela repetição da incidência em um dado período, normalmente entre dias, semanas e trimestres. Já os efeitos cíclicos ocorrem periodicamente anualmente. E por fim, as variações aleatórias, que são acidentais e não podem ser previstas (HEIZNER; RENDER, 2001). De acordo com Fildes *et al* (2019), vendas de produtos no varejo costumam ter um forte fator sazonal com ciclos diferentes para produtos diferentes e por isso, as técnicas de previsão adotadas precisam ser capazes de lidar com isto.

Para realizar tais previsões podemos adotar diversas técnicas diferentes. Por exemplo, a tentativa simples, que parte do pressuposto de que a demanda do período seguinte será igual à demanda do período mais recente (HEIZNER; RENDER, 2001). Outra técnica de previsão é a média móvel (MM), utilizada nesta pesquisa. Segundo a MM, admite-se que a demanda se manterá constante com ao longo do tempo. Ela é a média de um período determinado de tempo (n), e que, conforme vai-se avançando, os dados vão sendo alterados de maneira que nenhum valor mais antigo do que n períodos interfere no resultado (SLACK; CHAMBERS; JHONSTON, 2009; HEIZNER; RENDER, 2001).

A suavização exponencial sazonal de *Holt-Winters* (HW) (HYNDMAN, ATHANASOPOULOS, 2012; MORETTIN e TOLOI, 2006) leva em consideração o nível

($a[t]$), a tendência ($b[t]$) e a sazonalidade ($s[t]$) da série e pode ser dividida em dois procedimentos, aditivo e multiplicativo. Daremos foco apenas ao método aditivo, utilizado neste trabalho, preferencialmente adotado quando as mudanças sazonais da série temporal ocorrem de maneira constante. Segundo *R Core Team* (2016), esse método é calculado através de quatro equações que estão detalhadas na tabela 1, a seguir, onde h indica o número de passos à frente e p é a dimensão do período.

TABELA 1 - EQUAÇÕES PARA *HOLT-WINTERS* ADITIVO

Método Aditivo	
Sazonalidade	$s[t] = \gamma (Y[t] - a[t]) + (1-\gamma) s[t-p]$
Nível	$a[t] = \alpha (Y[t] - s[t-p]) + (1-\alpha) (a[t-1] + b[t-1])$
Tendência	$b[t] = \beta (a[t] - a[t-1]) + (1-\beta) b[t-1]$
Previsão	$\hat{Y}_{t+h} = a[t] + h * b[t] + s[t - p + 1 + (h - 1) \bmod p]$

Fonte: Elaboração Própria

2.3. ACURÁCIA

Como a previsão de demanda traz um resultado aproximado do real, raramente com exatidão, o controle da sua margem de erro é vital para que o modelo seja útil (STEVENSON, 2001). A medida mais utilizada é a acurácia (SILVA; PERES; BOSCAROLI, 2016), que, conforme Han, Kamber e Pei (2011), também é conhecida como precisão e representa a capacidade preditiva do modelo.

O erro ou resíduo da série temporal é a diferença entre o valor observado e a previsão realizada. Uma previsão gera bons resíduos quando estes não têm autocorrelação e apresentam média zero. Caso a primeira propriedade não seja satisfeita, isto indica que existem informações no resíduo que podem ser computadas no modelo. Ao apresentar uma média diferente de zero, a previsão está enviesada. Se uma dessas propriedades não for satisfeita, ou ambas, o método pode ser aprimorado para alcançar melhores resultados (HYNDMAN, ATHANASOPOULOS, 2012). Para saber se os resultados do modelo de previsão são bons e se trazem resultados melhores (ou seja, com erros menores), é preciso conhecer as técnicas de previsão, a acurácia e a base de dados que estão sendo adotados para o caso específico (HYNDMAN, 2014).

Para comparar modelos de previsão com o mesmo tamanho da base de dados, Hyndman e Koehler (2005), afirmam que as medidas mais usadas na literatura são *Root Mean Square Error* e *Mean Square Error*, que, por serem mais sensíveis aos *outliers*, dão mais peso aos erros maiores, sendo úteis quando, por exemplo, errar o dobro causa um prejuízo maior do que efetivamente o dobro do valor.

$$MSE = \text{mean} \left(e_i \right)$$

Erro Quadrático Médio

(Mean Square Error) (1)

Raíz do Erro Quadrático Médio
(Root Mean Square Error) $RMSE = \sqrt{\frac{\text{média}(e^2_i)}{2}}$ (2)

Onde: $e_i = y_i - \hat{y}_i$, sendo y o valor real, \hat{y} o valor previsto e i o período, que deve ser sempre igual.

Já as medidas de acurácia, dadas em porcentagem, são independentes da escala da base de dados, trazendo a vantagem de possibilitar a comparação entre diferentes dados (HYNDMAN, KOEHLER, 2005). Nesse caso, a grande desvantagem dessas medidas é Além disso, as medidas MAPE e MdAPE consideram um peso maior para erros positivos do quando y , ou muito próximo deste valor, pois o resultado se torna infinito ou indefinido. que negativos (HYNDMAN, KOEHLER, 2005). Como não são o foco deste trabalho, suas equações não serão representadas.

3. PROCEDIMENTOS METODOLÓGICOS

A pesquisa, por meio da aplicação de procedimentos estatísticos em uma base de dados disponibilizada pela organização e da medição da acurácia das técnicas de previsão, tem como objetivo identificar qual das duas técnicas de previsão (média móvel e *holt-winters*) resulta em maior acurácia no caso da rede de supermercado X. Por seu enfoque e objetivo, trata-se de uma pesquisa que se utiliza de abordagem quantitativa, ao visar mensurar e comparar variáveis (CRESWELL, 2010; LACRUZ, LEITE, 2021).

Para analisar os dados disponibilizados pela organização, primeiramente foi necessário remover da base de dados todos os elementos desnecessários para a pesquisa. Inicialmente, foi escolhido um setor para o estudo, por restrições de tempo para analisar todos os produtos do supermercado. Para essa delimitação, lembrou-se que, como ressaltado por Pick, Diesel e Sellito (2011), o estoque é a parte mais importante das redes varejistas, pois resultam em grandes perdas quando controlados de forma errônea, relacionadas tanto a prejuízos em questão

de produtos não vendidos, quanto a perdas com estoques equivocados (produtos a mais ou faltantes, por exemplo), além de ser importante entender também se o produto precisa de cuidados especiais na estocagem, que elevam o custo de estocagem. A partir da importância de manter-se um estoque adequado à demanda, o presente trabalho se preocupou com o setor de congelados, pois estes precisam de cuidados especiais, visto que são mantidos refrigerados, aumentando o custo de armazenagem, além de serem perecíveis com curto prazo de validade.

Após removidos todos os produtos que não estão contidos no setor escolhido, restaram oito produtos a serem estudados, a saber: a) Coxa e sobre coxa de frango da marca A; b) Coxa e sobre coxa de frango da marca B; c) Peito de frango da marca B; d) Peito de frango sem pele e sem osso da marca B; e) Frango da marca B; f) Empanado de frango marca C; g) Empanado de frango marca D; h) Hambúrguer bovino da marca E. Destes, nem todos tinham dados disponíveis em todo o período de tempo da base inicial (de 01/2007 a 07/2016), assim sendo, os períodos não coincidentes foram removidos da análise, restando o ano de 2014 a partir de outubro até Julho de 2016.

A partir da amostra de interesse desta pesquisa, deu-se início a etapa de préprocessamento de dados. Por se tratar de uma série temporal, é necessário que os dados estejam uniformemente espaçados no tempo (HEIZER, RENDER, 2001). Assim, os dias referentes a feriados - ou que, por motivos diversos, levaram ao não-funcionamento do supermercado - devem, ainda assim, ser considerados na previsão para que seja mantido o padrão de dias de funcionamento. Além disso, quando o estoque acaba, mesmo que haja demanda, não há venda realizada, e, portanto, o valor registrado nesse dia, também não corresponde à realidade do que teria sido vendido. Nesse caso, os dados referentes a esses dias são os chamados valores ausentes, que acarretam problemas à análise da base e à aplicação do algoritmo (SILVA, PERES, BOSCAROLI, 2016).

Silva, Peres e Boscaroli (2016) propõem que para solucionar o problema de valores ausentes, deve ser adotado a técnica de *data cleaning* (limpeza de dados), segundo o qual, dentre os procedimentos mais utilizados se encontram a remoção do exemplar, o preenchimento manual dos valores e o preenchimento automático dos valores. Como dito anteriormente, a remoção do valor não é possível, pois é necessário ter um espaço uniforme de tempo entre os dados (que no caso é de segunda à sábado). O presente trabalho adotou o preenchimento automático através da inclusão do mesmo valor de venda do dia da semana anterior, visando manter o padrão da sazonalidade da base, indicado pelos resultados da autocorrelação realizados no início dessa análise.

As técnicas de previsão escolhidas para teste foram as de Média móvel simples e *HoltWinters* aditivo. A média móvel está sendo utilizada na pesquisa por se tratar da técnica atual de previsão do supermercado e, portanto, ser o ponto de partida. Atualmente, faz-se a média dos últimos 60 dias e, com esse dado, prevê-se a demanda da próxima semana. Já *HoltWinters* (HW) foi preferido quando comparado a outras técnicas porque a série em questão envolve nível, tendência e sazonalidade, e as técnicas mais simples disponíveis não suavizam a previsão levando em consideração todas essas variáveis ao mesmo tempo. Além disso, trata-se de uma técnica de curto prazo, que é o objetivo da previsão para o

supermercado X, visto que o modelo atual foca na previsão de uma semana à frente, ou seja, um ciclo. Ademais, o método escolhido para esse caso específico foi o aditivo, uma vez que a série temporal tem uma sazonalidade mais ou menos constante.

Para facilitar a comparação entre ambas as técnicas, o *Holt-Winters* foi executado analisando uma amostra de 60 dados, e prevendo um ciclo de 6 dias (segunda à sábado). Em outras palavras, um grupo de 6 dias corresponde a um passo à frente na análise desta série temporal dada a sua frequência semanal. Assim, ao tornar relevante para a análise o período da semana, informando que, a cada 6 dias, reinicia-se o processo, faz-se importante, por consequência, o fator dia da semana na análise. Desta maneira, analisar-se-á, pela técnica, não só o nível, a tendência e sazonalidade geral da série como variáveis influentes na previsão, como dito anteriormente, mas será gerado um parâmetro sazonal para cada dia da semana (R CORE TEAM, 2016), aproximando *Holt-Winters* da regressão linear, pertencente ao universo de estudo de modelos causais, que, apesar de não fazer parte desta pesquisa, abre portas para aprofundamentos diversos.

Como para ambas as técnicas os primeiros 60 dias da base de dados serão utilizados apenas de base para início dos cálculos, não havendo previsão para cada um deles, por motivos estéticos, optou-se por iniciar as análises no dia 24 de outubro de 2014, exatos 60 dias antes do início do ano de 2015. Essa alteração não afeta os resultados dos modelos, visto que ambos são utilizados para o curto prazo e dados muito antigos perdem a influência na previsão. Assim, os resultados não conterão valores para 2014.

Para mensurar a acuracidade dos modelos, optou-se por utilizar o RMSE (*Root Mean Square Error*), que é o mais comum na literatura para analisar previsões de demanda, uma vez que, no caso desta pesquisa, errar para mais é tão ruim quanto errar para menos. E, ao atribuir pesos maiores para erros extremos, este método também se torna útil, pois, erros altos tanto para falta ou sobra de estoque podem causar prejuízos maiores (CHAI; DRAXLER, 2014).

Os testes foram realizados através da linguagem R, ferramenta de programação estatística livre, distribuída pelo projeto *Free Software Foundation's GNU*, utilizada por milhares de pessoas diariamente para gerar resultados de pesquisas estatísticas e representações gráficas, e a implementação desta ferramenta é uma realização coletiva de pesquisadores (SILVA; PERES; BOSCAROLI, 2016; TEETOR, 2011). Devido ao livre acesso ao R, e a sua versatilidade, esta ferramenta tem se mostrado acessível para produções científicas.

4. APRESENTAÇÃO DOS RESULTADOS DA PESQUISA

A Tabela 2, a seguir, traz o resumo dos dados da base, facilitando uma compreensão geral das diferenças tanto de amplitude quanto de dispersão dos dados, sendo Coxa e Sobrecoxa representados por CSC; Frango por Fg; Peito de Frango por Pf; Peito de Frango sem pele e sem osso por Pf.spso; Empanado de frango por Ef e Hambúrguer por H.

	CSC (A)	CSC (B)	Fg (B)	Pf (B)	Pf,spso (B)	Ef (C)	Ef (D)	H (E)
Valor	1,77	62,94	2,368	24,27	3,23	1	2	2
Mínimo								

Primeiro Quartil	29,92	166,47	33,785	151,93	201,32	11	35	100	
Mediana	52,64	237,61	54,124	198,23	252,73	28	65	146,5	
Média	84,88	117,7	318,29	70,071	244,98	279,32	48,68	77,82	153,3
Terceiro Quartil		397,03	91,258	286,02	318,33	64	108,75	194	
Valor Máximo	854,55	1367,78	522,261	926,9	1111,22	361	320	590	

TABELA 2– RESUMO BASE DE DADOS

Fonte: Elaboração Própria

A partir dessas informações básicas, é importante ainda analisar a variação e o formato da base de dados utilizando as medidas de amplitude, variância, desvio padrão e coeficiente de variação (Tabela 3).

TABELA 3 – MEDIDAS DE DISPERSÃO

	Amplitude	Variância	Desvio Padrão	Coeficiente de Variação
CSC (A)	852,78	7.923,166	89,01216	104,8682 %
CSC (B)	1.304,84	49.904,600	223,39338	70,18548 %
Fg (B)	519,89	2.902,937	53,87891	76,89188 %
Pf (B)	902,63	21.238,624	145,73477	59,48844 %
Pf.spso (B)	1.107,99	21.024,906	144,99968	51,91167 %
Ef (C)	360	3.344,143	57,82857	118,7933 %
Ef (D)	318	3.125,503	55,90620	71,8404 %
H (E)	588	5.686,498	75,40887	49,19039 %

Fonte: Elaboração Própria

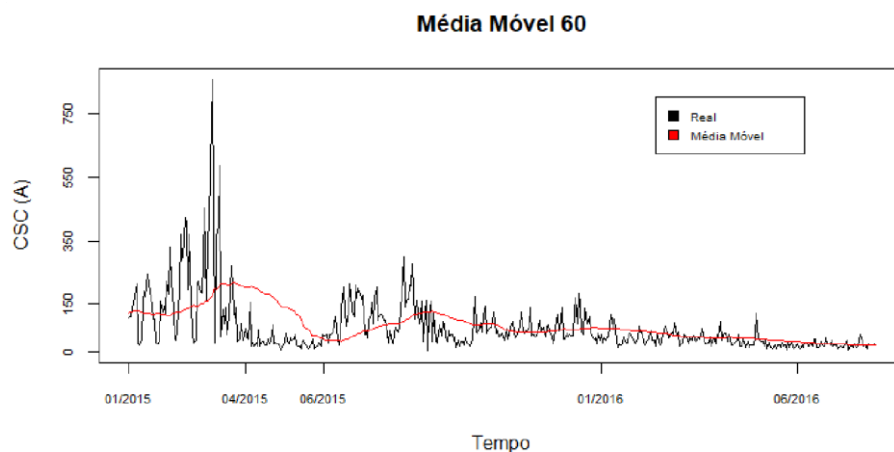
Os dados foram calculados visando tornar possível a comparação entre os produtos no que tange à dispersão dos dados da base. Os resultados, por sua vez, apresentam que há uma variação muito grande dos valores das demandas, conforme esperado, considerando os diversos picos de vendas no decorrer do tempo. Os produtos com menores coeficientes de variação são Pf (B), Pf.spso (B) e H (E), no entanto, ainda com valores em torno de 50% da média aritmética.

4.1. MÉDIA MÓVEL 60

A média móvel foi calculada com base de 60 dias, para simular o modelo de previsão atual do supermercado X, tendo seu primeiro resultado de previsão em 01/01/2015. Foi diagnosticada uma demora da resposta deste método para se adaptar às variações da demanda, bem como a ausência de picos na previsão, visto que suaviza os resultados, não conseguindo

prever os maiores e menores valores. Isso é exemplificado pelo Gráfico 1, a seguir, que traz a demanda e a média móvel da coxa e sobrecoxa de frango da marca A entre abril e junho de 2015. Existe uma queda significativa da demanda e é possível observar que a média móvel reduz seus valores lentamente. Os outros produtos também apresentam esse mesmo comportamento, sendo menos evidente quanto menos a demanda varia de nível de venda.

GRÁFICO 1 – MÉDIA MÓVEL 60 - CSC (A)



Fonte: Elaboração Própria

A Tabela 4, a seguir, contém os resultados do RMSE. Sabendo que seus valores são dados na unidade em que o produto é vendido e que a dimensão do erro está diretamente ligada à amplitude dos dados, optou-se por calcular a porcentagem do RMSE comparado à média de venda de cada produto (Tabela 2). Desta maneira, é possível comparar a acurácia dos modelos entre si, visto que se perde o caráter de unidade do resultado, bem como torna-se irrelevante a amplitude das séries analisadas. Lembrando que o MPE e o MAPE não foram utilizados para comparar as acurácias, pois, apesar de serem percentuais, eles resultam em valores extremos ou infinitos caso alguma das previsões seja um valor próximo ou igual a zero.

O melhor resultado percentual foi com o produto Hambúrguer. No entanto, quando comparados com a média de vendas da série original, estão próximos ou superiores a 50%, sendo assim, valores muito elevados de erro.

TABELA 4 - RESUMO ACURÁCIA MM60

	RMSE	% da média de vendas
CSC (A)	82,6115 KG	97,33 %
CSC (B)	206,9397 KG	65,02 %
Fg (B)	40,6782 KG	58,05 %
Pf (B)	146,4961 KG	59,80 %
Pf.sps (B)	140,6499 KG	50,35 %
Ef (C)	49,3321 UND	101,34 %
Ef (D)	50,4533 UND	64,83 %

H (E)

75,5508 UND

49,28 %

Fonte: Elaboração Própria

4.2. HOLT-WINTERS

Diante da mesma base de dados foi aplicado o método de previsão *Holt-Winters*, resultando em uma tabela de dimensão de 8 colunas por 498 linhas. Esta tabela contém as características dispostas conforme segue (Tabela 5).

TABELA 5 – RESUMO *HOLT-WINTERS*

	CSC (A)	CSC (B)	Fg (B)	Pf (B)	Pf.sps (B)	Ef (C)	Ef (D)	H (E)
Mínimo	-80,27	-100,3	-4,088	-28,03	-26,64	-41,656	-11,19	-85,06
Primeiro Quartil	24,98	164,4	32,212	146,05	189,64	8,804	42,45	113,58
Mediana	53,13	271,5	51,923	221,46	252,61	22,297	78,9	158,57
Média	81,86	310,8	63,409	235,35	282,81	41,225	85,86	161,44
Terceiro Quartil	117,24	419,2	85	308,97	330,16	56,643	122,13	202,95
Máximo	478,15	1188,1	274,922	651,29	1583,52	279,766	274,63	427,05

Fonte: Elaboração Própria

TABELA 6 – RESUMO ACURÁCIA *HOLT-WINTERS*

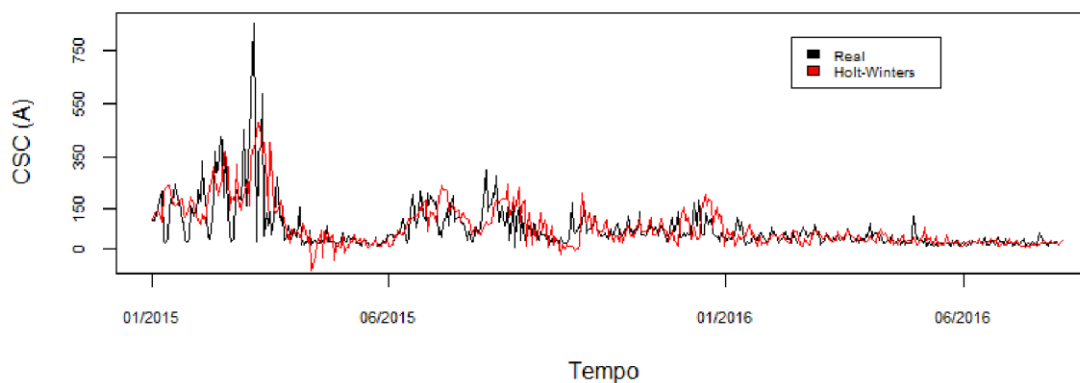
	RMSE	% da média de vendas
CSC (A)	70,0495 KG	82,53 %
CSC (B)	183,5669 KG	57,67 %
Fg (B)	40,0098 KG	57,10 %
Pf (B)	147,733 KG	60,30 %
Pf.sps (B)	171,591 KG	61,14 %
Ef (C)	48,0687 UND	98,74 %
Ef (D)	54,4816 UND	70,01 %
H (E)	78,2969 UND	51,07 %

Fonte: Elaboração Própria

Visualmente, os gráficos do modelo *Holt-Winters* demonstram um melhor acompanhamento da demanda no tempo, como pode ser visto no Gráfico 2, a seguir. No entanto, isso não garante que seu resultado seja melhor do que o apresentado na média móvel. O menor resultado percentual de RMSE (Tabela 7) ainda é com o produto H (E) correspondendo à 51,07% da média de vendas.

GRÁFICO 2 – *HOLT-WINTERS* – CSC (A)

Holt-Winters




Fonte: Elaboração Própria

Além disso, os produtos CSC (B), Fg (B), Pf (B), Ef (C), Ef (D) e H (E) apresentam um *lag* entre o real e a previsão, quando analisamos os picos de demanda, dado que seria possível acertar mais se a previsão fosse atrasada, ou seja, trazer uma previsão mais à frente no tempo para o presente. Para exemplificar, o Gráfico 3 traz essa característica na demanda do produto Fg (B). Mesmo nos outros produtos, que não demonstram claramente esse *lag*, é possível observar erros grandes, porém, pontuais nos picos de demanda em termos de volume previsto.

GRÁFICO 3 – *HOLT-WINTERS* – FG (B)

Holt-Winters



Fonte: Elaboração Própria

5. ANÁLISE DOS RESULTADOS

Para concluir qual modelo apresenta resultados gerais melhores, é necessário comparar os RMSE calculados para cada caso (Tabela 7). O modelo *Holt-Winters* se apresentou melhor para os produtos CSC (A), CSC (B), Fg(B) e Ef(C), mas na maioria não demonstrou resultados

significativamente melhores ou piores. Os valores mais expressivos se encontram em CSC (A) e CSC (B), positivamente, representando respectivamente uma melhora de 14,8% e 23,01%, mas em Pf.sps (B) houve uma redução da acurácia em 11,08%.

Outra consideração importante sobre os erros das previsões é saber qual modelo ou produto errou para mais, impedindo assim que vendas fossem realizadas visto que a demanda real foi maior do que a prevista, ou quando errou para menos, causando excesso de estoque (Tabela 8 e 9).

TABELA 7 – COMPARAÇÃO ACURÁCIA

	RMSE – MM60	% da média de vendas	RMSE – HW	% da média de vendas	Diferença	% da média de vendas
CSC (A)	82.6115	97,33 %	70,0495	82,53 %	12.562	14,80 %
CSC (B)	206.9397	65,02 %	183,5669	57,67 %	23.3728	23,01 %
Fg (B)	40.6782	58,05 %	40,0098	57,10 %	0.6684	00,95 %
Pf (B)	146.4961	59,80 %	147,733	60,30 %	-1.2369	-00,50 %
Pf.sps (B)	140.6499	50,35 %	171,591	61,14 %	-30.9411	-11,08 %
Ef (C)	49.3321	101,34 %	48,0687	98,74 %	1.2634	2,59 %
Ef (D)	50.4533	64,83 %	54,4816	70,01 %	-4.0283	-5,17 %
H (E)	75.5508	49,28 %	78,2969	51,07 %	-2.7461	-1,79 %

Fonte: Elaboração Própria

	CSC (A)	CSC (B)	Fg (B)	Pf (B)	Pf,sps(B)	Ef (C)	Ef (D)	H (E)
< 0	-14121,1	-39188	-8774,8	-27264,8	-22715,8	-8193,98	-8138,83	-12899,2
≥ 0	11387,91	33816,1	6225,646	25572	22803,31	6848,117	10236,48	15364,1
Total	-2733,18	-5371,86	-2549,16	-1692,83	87,4735	-1345,87	2097,65	2464,933
Total Geral								-9042,83

TABELA 8 – DIFERENÇA ENTRE ERROS POSITIVOS E NEGATIVOS – MÉDIA MÓVEL

Fonte: Elaboração Própria

Analisando a soma das diferenças de todos os produtos, o modelo da média móvel gera um erro negativo maior do que os erros positivos, causando, portanto, excesso de estoque. Já a análise dos produtos individualmente, apenas Pf.sps (B), Ef (D) e H (E) tiveram erros positivos, que resultam em perdas de vendas, conforme apresentado na Tabela 9.

	CSC (A)	CSC (B)	Fg (B)	Pf (B)	Pf,sps(B)	Ef (C)	Ef (D)	H (E)
0	-11697,3	-31404,6	-7009,37	-25879,2	-26762,7	-6448,78	-10278,4	-15110,8
≥ 0	9805,818	32982,1	6923,493	27484,61	25663,67	7207,65	9461,473	14631,99
Total	-1891,51	1577,475	-85,8754	1605,425	-1099	758,8705	-816,96	-478,798
Total Geral								-430,368

TABELA 9 – DIFERENÇA ENTRE ERROS POSITIVOS E NEGATIVOS – *HOLT-WINTERS*

Fonte: Elaboração Própria

No caso do modelo de previsão *Holt-Winters*, apesar de o total geral ser também negativo, o valor está expressivamente mais perto de zero do que a média móvel (8.612,46 de diferença). Os produtos que erraram para mais foram: CSC (B), Pf (B), e Ef (C). As tabelas 10 e 11 mostram os dias da semana em que a previsão errou mais, através da soma dos erros em cada dia. No entanto, todos os valores foram colocados em módulo para que o erro negativo não anulasse com o positivo, gerando assim resultados falsos, pois, ambas as formas de erro geram prejuízos para a organização.

TABELA 10 – ERRO POR DIA DA SEMANA – MÉDIA MÓVEL

	CSC (A)	CSC (B)	Fg (B)	Pf (B)	Pf,sps(B)	Ef (C)	Ef (D)	H (E)
Quinta	18%	17%	17%	16%	15%	17%	17%	14%
Sexta	19%	19%	16%	19%	17%	21%	15%	15%
Sábado	18%	24%	22%	27%	23%	20%	23%	28%
Segunda	15%	13%	15%	14%	15%	13%	14%	16%
Terça	16%	13%	14%	12%	13%	14%	14%	14%
Quarta	15%	14%	15%	12%	17%	15%	16%	13%

Fonte: Elaboração Própria

Os maiores valores de erro da Tabela 10 encontram-se na sexta-feira e aos sábados. No caso do produto CSC (A), não existe grande variação das porcentagens, visto que varia apenas entre 15 % até 19 %.

	CSC (A)	CSC (B)	Fg (B)	Pf (B)	Pf,sps(B)	Ef (C)	Ef (D)	H (E)
Quinta	15%	15%	12%	18%	15%	15%	15%	14%
Sexta	20%	19%	16%	19%	13%	21%	14%	17%
Sábado	20%	25%	23%	27%	17%	20%	23%	23%

Segunda	15%	13%	14%	11%	17%	14%	16%	12%
Terça	15%	14%	16%	12%	17%	15%	16%	17%
Quarta	15%	15%	19%	13%	21%	15%	17%	17%

TABELA 11 – ERRO POR DIA DA SEMANA – *HOLT-WINTERS*

Fonte: Elaboração Própria

Na Tabela 11, acima, a maioria dos erros ainda se encontram na sexta-feira e aos sábados, exceto no caso do Pf.spso, onde seu maior erro é na quarta-feira, além do Fg (B), que o segundo maior erro (19 %) também acontece na quarta-feira.

Na análise de resíduos, vê-se que a amplitude dos erros do *Holt-Winters* é realmente maior do que no caso da média móvel, aumentando o valor final do RMSE. Dessa forma, testouse também o MAE (*Mean Absolute Error*) que considera os valores absolutos dos erros para que estes não se anulem, não dá maior relevância aos erros extremos, não envolve porcentagem, evitando erros grandes ou infinitos em caso de valores próximos a zero, e, também não dão pesos maiores para os erros positivos como por exemplo o MAPE e MdAPE.

A tabela 12, a seguir, traz a comparação entre os dois modelos de previsão quando utilizado o MAE.

TABELA 12 – ACURÁCIA – MAE

	MAE – MM60	% da média de vendas	MAE – HW	% da média Diferença de vendas	% da média de vendas
CSC (A)	51,6345	60,83%	43,52429	51,28%	9,55%
CSC (B)	147,68922	46,40%	130,31725	40,94%	5,46%
Fg (B)	30,27718	43,21%	28,14966	40,17%	3,04%
Pf (B)	106,91799	43,64%	107,78833	44,00%	-0,36%
Pf.spso (B)	92,06640	32,96%	105,97769	37,94%	-4,98%
Ef (C)	30,43495	62,52%	27,62233	56,74%	5,78%
Ef (D)	37,11309	47,69%	39,94432	51,33%	-3,64%
H (E)	57,04318	37,21%	60,14756	39,24%	-2,03%
				-2,8312	
				-3,1044	

Fonte: Elaboração Própria

Utilizando o MSE, a diferença entre as previsões continua sem ser significativa para a maior parte dos produtos, porém, *Holt-Winters* melhorou os resultados da coxa e sobrecoxa de frango (B) em 9,55% e piorou em 4,98% no produto Pf.spso (B). No entanto, se compararmos o RMSE com o MAE para cada previsão, os valores de erro reduzem significativamente (Tabela

	RMSE – MM60 % da média de vendas	MAE – MM60 % da média de vendas	RMSE – HW % da média de vendas	MAE – HW % da média de ¹⁵ vendas	
CSC (A)	97,33 %	60,83%	82,53 %	51,28%	
13). Isso se	CSC (B)	65,02 %	46,40%	57,67 %	40,94%
	Fg (B)	58,05 %	43,21%	57,10 %	40,17%
	Pf (B)	59,80 %	43,64%	60,30 %	44,00%
	Pf.sps0 (B)	50,35 %	32,96%	61,14 %	37,94%
	Ef (C)	101,34 %	62,52%	98,74 %	56,74%
	Ef (D)	64,83 %	47,69%	70,01 %	51,33%
	H (E)	49,28 %	37,21%	51,07 %	39,24%

deve ao fato de que a dispersão dos dados é muito alta, conforme cálculo de variância e desvio-padrão realizados, causando maiores diferenças no cálculo do RMSE.

Fonte: Elaboração Própria

Conforme visto, é esperado que os resíduos não apresentem autocorrelação. Foi possível identificar que, no caso da técnica *Holt-Winters*, ainda existe uma autocorrelação, porém, claramente menor do que a do resíduo da série original, o que não acontece com a média móvel, pois, esta, mantém-se quase sem alteração quando comparada à da base inicial. A existência dessa autocorrelação denota que ainda existem variáveis que, se computadas no modelo, auxiliarão nos resultados aumentando a acurácia.

6. CONCLUSÃO

Partindo da ideia inicial de que a existência de sazonalidade - identificada utilizando a técnica de autocorrelação dos dados - iria auxiliar na previsão da demanda, era esperado que o modelo *Holt-Winters* obtivesse resultados melhores do que a média móvel. No entanto, analisando as acurácias, nenhum dos dois modelos demonstrou uma capacidade preditiva boa, visto que o menor erro corresponde a aproximadamente 50% da média de vendas do produto. No entanto, na análise comparativa entre as duas técnicas de previsão, o *Holt-Winters* resultou em uma acurácia melhor com o CSC (A) representando um acerto de 14,80 % da média de venda do produto a mais do que a outra técnica, e, também com o produto CSC (B), sendo este 23,01 % mais assertivo. Já o produto Pf.sps0 (B), teve a acurácia melhor em 11,08 % com a média móvel. Os outros produtos ficaram equiparados, pois a diferença correspondia a menos do que 6%. Levando em consideração o quadro geral, o *Holt-Winters*, apesar de não apresentar resultados tão bons quanto o esperado, teve maior acurácia do que a média móvel.

A partir da análise de autocorrelação do resíduo houve uma redução dos valores de autocorrelação quando comparado ao valor inicial. Porém, como ainda existe autocorrelação, resta acrescentar na análise uma ou mais variáveis que retirem do resíduo variações de demanda que podem ser mensuradas. Como a análise de resíduos, de maneira geral, acusou melhores resultados para o modelo *Holt-Winters*, é possível que os grandes erros encontrados em momentos de pico - citados tanto na apresentação de resultados da pesquisa quanto na análise de resultados - estejam aumentando o RMSE fazendo o resultado final parecer pior do que é.

No entanto, é necessário avaliar se alterar a avaliação da acurácia para MAE seria suficiente ou se a remoção de *outliers* tornaria o modelo mais assertivo.

Com base nas análises realizadas, será necessário estender e aprofundar os estudos utilizando-se de outras técnicas que permitam melhorar os resultados. Não foi possível realizar mais análises nesta pesquisa dadas as restrições de tempo e de acesso aos dados. Portanto, focou-se em cumprir o objetivo ao qual a pesquisa se propôs. Porém, recomenda-se que outras análises similares e comparativas sejam empreendidas de modo a superar as limitações da presente pesquisa.

É necessário verificar se a remoção de *outliers* auxilia ou atrapalha a previsão, dado que é uma base de dados com um valor elevado de dispersão, mas que esses picos podem ser devidos a uma variável ainda não utilizada. Nesse caso, pode ser melhor adicionar esses valores à previsão do que removê-los ou alterá-los.

Como sugestões de futuros estudos que podem aprofundar a temática aqui em análise, a gama de variáveis que ainda podem ser estudadas é diversa. Pode-se levar em consideração período do mês (início, meio e fim podem ter demandas diferentes), promoção (do produto, de um complementar, concorrente, ou em outro supermercado próximo), feriado (qual o comportamento da demanda antes e depois de feriado), entre outras. Também é interessante fazer um estudo sobre o *lag* percebido em alguns dos resultados, buscando entender se eles podem ser explicados e adicionados ao modelo preditivo. Outra possibilidade é realizar a análise através de um modelo causal, ou um híbrido, apenas entre os de séries temporais apresentados ou também levando em consideração o modelo causal, desde que os resultados melhorem significativamente sem perder a parcimônia do modelo.

Por fim, é possível estudar o impacto gerado pelos erros extremos da previsão, que podem aumentar os prejuízos de sobra de estoque ou perda de vendas, que permitirá compreender com maiores detalhes se o método de acurácia adotado (RMSE) é mesmo melhor para a avaliação desse caso do que o MSE.

REFERÊNCIAS

CECATTO, C.; BELFIORE, P. O uso de métodos de previsão de demanda nas indústrias alimentícias brasileiras. **Gest. Prod.**, São Carlos, v.22, n.2, p.404-418, jun.2015. Disponível em http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0104530X2015000200404&lng=pt&nrm=iso. acessos em 02 nov. 2017. <http://dx.doi.org/10.1590/0104-530X108-12>.

CRESWELL, J. W. **Projeto de pesquisa: métodos qualitativo, quantitativo e misto**. Porto Alegre: Artmed, 2020.

CHAI, T.; DRAXLER, R. R.. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, [s.l.], v. 7, n. 3, p.1247-1250, 30 jun. 2014. Copernicus GmbH. <http://dx.doi.org/10.5194/gmd7-1247-2014>. Disponível em: <www.geosci-model-dev.net/7/1247/2014/>. Acesso em: 29 nov. 2017.

DAVIS, M. M.; AQUILANO, N. J.; CHASE, R. B. **Fundamentos da administração da produção**. 3. ed. Porto Alegre, Bookman, 2003.

- FILDES, R., MA S. AND KOLASSA S., Retail forecasting: research and practice, **International Journal of Forecasting** . 2019. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S016920701930192X>>. Acesso em: 30 set. 2021.
- GONÇALVES, P. S. **Administração de materiais**. 2. ed. Rio de Janeiro. Elsevier, 2007.
- HAN, J.; KAMBER, M.; PEI, J. **Data Mining: Concepts and Techniques**. 3 ed. Waltham, MA: Morgan Kaufmann Series in Data Management Systems, 2011.
- HEIZER, J.; RENDER, B. **Administração de operações - bens e serviços-**. 5. ed. Rio de Janeiro. LTC, 2001.
- HOELTGEBAUM H., BORENSTEIN D., FERNANDES C., VEIGA A., A score-driven model of short-term demand forecasting for retail distribution centers, **Journal of Retailing**, 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0022435921000361>>. Acesso em: 30 set. 2021.
- HYNDMAN, J. R.; **Measuring forecast accuracy** 2012. Disponível em: <https://robjhyndman.com/papers/forecast-accuracy.pdf> [Acessos em 30 Abr. 2018].
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. Heathmont: OTexts. 2012. Disponível em: <https://www.otexts.org/fpp> [Acessos em 21 Nov. 2017]. [Acessos em 29 Nov. 2017].
- IBGE - Instituto Brasileiro de Geografia e estatística. **PAC - Pesquisa Anual de Comércio, 2019**. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/periodicos/55/pac_2019_v31_informativo.pdf>. Acesso em: set. 2021.
- LACRUZ, A. J. LEITE, M. C. O. **Organizando projetos de pesquisa**. Vitória, ES: Instituto Federal do Espírito Santo, 2021.
- MARCONI, M. A.; LAKATOS, E. M.. **Fundamentos da Metodologia Científica**. 5. ed. São Paulo: Editora Atlas S.a., 2003.
- PROVOST, F.; FAWCETT, T. **Data science para negócios**. Rio de Janeiro. Alta Books, 2016.
- R Core Team (2016). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org/>.
- SILVA, L. A. da; PERES, S. M.; BOSCAROLI, C. **Introdução à mineração de dados: com aplicações em R**. Rio de Janeiro. Elsevier, 2016.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R.. **Administração da produção**. 3. ed. São Paulo. Atlas, 2009.

STEVENSON, W. J. **Administração das operações de produção**. 6. ed. Rio de Janeiro. LTC, 2001.

TEETOR, P. **R Cookbook**. 1. ed. Sebastopol. O' Riley Media, Inc. 2011

WANKE, P. F. **Gerência de operações: uma abordagem logística**. São Paulo. Atlas, 2010.