

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS JURÍDICAS E ECONÔMICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO**

HENRIQUE GAVA SERRANO

**PREVISÃO DE VENDAS DE ALTA FREQUÊNCIA COM MODELOS
DE SÉRIES TEMPORAIS: O CASO DE UMA REDE DE
SUPERMERCADOS**

VITÓRIA

2022

HENRIQUE GAVA SERRANO

**PREVISÃO DE VENDAS DE ALTA FREQUÊNCIA COM MODELOS
DE SÉRIES TEMPORAIS: O CASO DE UMA REDE DE
SUPERMERCADOS**

Dissertação apresentada ao Programa de Pós-Graduação em Administração do Centro de Ciências Jurídicas e Econômicas da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do título de Mestre em Administração, na linha de pesquisa Desempenho e Competitividade Organizacional.

Orientador: Prof. Dr. Hélio Zanquetto Filho

VITÓRIA

2022

Ficha catalográfica disponibilizada pelo Sistema Integrado de Bibliotecas - SIBI/UFES e elaborada pelo autor

S487p Serrano, Henrique Gava, 1995-
PREVISÃO DE VENDAS DE ALTA FREQUÊNCIA COM
MODELOS DE SÉRIES TEMPORAIS: O CASO DE UMA
REDE DE SUPERMERCADOS / Henrique Gava Serrano. -
2022.
75 f.

Orientador: Hélio Zanquetto Filho.
Coorientador: Adonai José Lacruz.
Dissertação (Mestrado em Administração) - Universidade
Federal do Espírito Santo, Centro de Ciências Jurídicas e
Econômicas.

1. Operações no Varejo Alimentício. 2. Programação para o
Reabastecimento de Loja. 3. Previsão de Vendas de Alta
Frequência. 4. Horizonte de Tempo de Previsão. 5. Previsão
Estática e Dinâmica. I. Filho, Hélio Zanquetto. II. Lacruz,
Adonai José. III. Universidade Federal do Espírito Santo. Centro
de Ciências Jurídicas e Econômicas. IV. Título.

CDU: 65

HENRIQUE GAVA SERRANO

**PREVISÃO DE VENDAS DE ALTA FREQUÊNCIA COM MODELOS
DE SÉRIES TEMPORAIS: O CASO DE UMA REDE DE
SUPERMERCADOS**

Dissertação apresentada ao Programa de Pós-Graduação em Administração do Centro de Ciências Jurídicas e Econômicas da Universidade do Espírito Santo, como requisito parcial para obtenção do título de Mestre em Administração.

Aprovado em _____/_____/_____

COMISSÃO EXAMINADORA

Hélio Zanquetto Filho, D. Sc.
Universidade Federal do Espírito Santo
Orientador

Andrew Beheregarai Finger, D. Sc.
Universidade Federal de Alagoas

Marcos Paulo V. de Oliveira, D. Sc.
Universidade Federal do Espírito Santo

(...) “A vida é uma longa corrida onde a persistência e a integridade são absolutamente necessárias para alcançarmos nossas metas.”

Benjamin Franklin

AGRADECIMENTOS

Acredito que nos movemos na vida por meio da nossa fé. Agradeço a Deus pelo dom da vida e pela oportunidade de trilhar mais um desafio, por me capacitar e me fortalecer diante das adversidades.

Agradeço a minha família pelo amor e carinho depositado.

Em especial, a minha mãe, Rozânia, por ser o meu pilar e porto seguro. Desde o início da minha vida oferecendo acolhimento e proteção, sem medir esforços para me nutrir e educar. A meu pai, por cada momento, conversa e aprendizado compartilhado. Aos meus tios, Elizandra e Agnaldo por todo suporte dado, pela presença e consideração. São pessoas que carrego um apreço enorme e muita admiração. A tia Lidiane, pelo apoio e força dada, em diversos instantes. Aos meus tios, Gorete e Eduardo, por ofertarem colo, carinho e orientações em momentos bem delicados da minha vida. A vovó Lourdes pelo otimismo, fé e história de vida. Ao vovô Euginor, pela atenção e preocupação com a minha caminhada.

Ao meu orientador, pela paciência e simplicidade ao passar seus conhecimentos e fornecer inúmeras diretrizes para reflexões acerca da presente pesquisa. Por ser compreensivo e ter me apoiado tanto. Sei o quanto se esforçou para me dar suporte e contribuir para o desenvolvimento da dissertação.

Aos amigos, agradeço pelos momentos compartilhados e laços criados.

RESUMO

As pesquisas recentes sobre previsões de vendas no nível de produtos individuais são feitas com granularidade semanal, para supermercados (FILDES et al., 2019). A presente pesquisa tem como objetivo principal comparar modelos diários de previsão de vendas com os semanais, no contexto do varejo supermercadista. De forma secundária, pretende-se discutir sobre os modelos estáticos e dinâmicos e apresentar o impacto do horizonte de previsão e da frequência de treinamento sobre o desempenho dos modelos de previsão. Na realização da presente pesquisa, utilizou-se uma base de dados de uma loja de uma Rede de Supermercados do Espírito Santo. Para a realização da modelagem de previsão de vendas, optou-se pela escolha de modelos de séries temporais (Holt-Winters e ARIMA) e do TBATS, pois considera as sazonalidades múltiplas na previsão de alta frequência (diária). Como resultado, nota-se que a previsão diária possibilita melhor desempenho preditivo do que a semanal, para o contexto em questão. Além disso, os modelos dinâmicos proporcionaram previsões mais acuradas do que os estáticos. E quando se compara o desempenho dos modelos Holt-Winters, ARIMA e TBATS, o último apresentou maior assertividade, o que pode ser explicado pela presença de uma sazonalidade complexa nos dados de vendas do varejo supermercadista.

Palavras-Chave: Operações no Varejo Alimentício; Programação para o Reabastecimento de Loja; Previsão de Vendas de Alta Frequência; Horizonte de Tempo de Previsão; Previsão Estática e Dinâmica.

ABSTRACT

Recent research on sales forecasting at the individual product level is done with weekly granularity for supermarkets (FILDES et al., 2019). The main objective of the present research is to compare daily sales forecasting models with weekly ones in the context of supermarket retailing. Secondly, it is intended to discuss static and dynamic models and present the impact of the forecast horizon and training frequency on the performance of forecast models. In this research, a database of one store of a Supermarket Chain in Espírito Santo was used. We chose time series models (Holt-Winters and ARIMA) and TBATS because it considers multiple seasonalities in the high frequency (daily) forecast to perform the sales forecast. As a result, it is noted that the daily forecast provides better predictive performance than the weekly forecast for the context in question. In addition, the dynamic models provided more accurate forecasts than the static models. And when comparing the performance of the Holt-Winters, ARIMA, and TBATS models, the latter showed greater assertiveness, which can be explained by the presence of complex seasonality in supermarket retail sales data.

Keywords: Food Retail Operations; Store-Replenishment Schedule; High-frequency Forecasting; Forecast Horizon; Static and Dynamic Prediction.

LISTA DE TABELAS

Tabela 01 – Comparação Acurácia (RMSE): ARIMA dinâmico (1 passo à frente) x ARIMA dinâmico (6 passos à frente)	33
Tabela 02 – Comparação Acurácia (RMSE): Holt-Winters dinâmico (1 passo à frente) x Holt-Winters dinâmico (6 passos à frente)	34
Tabela 03 – Comparação Acurácia (RMSE): ARIMA dinâmico (1 passo à frente) x ARIMA estático	35
Tabela 04 – Comparação Acurácia (RMSE): Holt-Winters dinâmico (1 passo à frente) x Holt-Winters estático	36
Tabela 05 – Comparação Acurácia (RMSE): ARIMA dinâmico (1 passo à frente) x Holt-Winters dinâmico (1 passo à frente)	37
Tabela 06 – Comparação Acurácia (RMSE): ARIMA dinâmico (1 passo) x Média do Gestor	38
Tabela 07 – Comparação Acurácia (RMSE): ARIMA dinâmico (1 passo) x TBATS.....	39
Tabela 08 – TREINO, VALIDAÇÃO E TESTE x TBATS	40

SUMÁRIO

1 INTRODUÇÃO	9
1.1 OBJETIVO.....	13
1.2 JUSTIFICATIVA	13
1.3 ESTRUTURA DA DISSERTAÇÃO	15
2 REVISÃO BIBLIOGRÁFICA	17
2.1 REVISÃO SISTEMÁTICA DE LITERATURA	17
2.2 PREVISÃO DE VENDAS E SEUS USOS OPERACIONAIS NO VAREJO ALIMENTÍCIO	19
2.3 PREVISÃO DE VENDAS DE ALTA FREQUÊNCIA: UM ESTUDO DE TRÊS ABORDAGENS	20
2.4 TBATS.....	23
2.5 AS INFLUÊNCIAS DO HORIZONTE DE TEMPO PARA A PREVISÃO E DO TREINAMENTO NA MODELAGEM	25
3 PROCEDIMENTOS METODOLÓGICOS.....	27
3.1 MOTIVAÇÃO PARA A SELEÇÃO DA EMPRESA DO ESTUDO DE CASO	27
3.2 COLETA E TRATAMENTO DE DADOS	27
3.3 MODELAGEM DE PREVISÃO DE VENDAS	28
3.4 PRESSUPOSTOS DA PREVISÃO DE VENDAS COM SÉRIES TEMPORAIS..	30
3.5 SOFTWARE E PACOTES UTILIZADOS.....	31
4 RESULTADOS	33
5 CONSIDERAÇÕES FINAIS	42
6 REFERÊNCIAS.....	44
APÊNDICE A – SCRIPT.....	48

1 INTRODUÇÃO

No varejo, a previsão de vendas é comumente realizada em uma periodicidade semanal e por esse motivo, a previsão de vendas em intervalos menores (como diário, por exemplo) pode ser vista como de alta frequência (FILDES et al., 2019).

As previsões de alta frequência (diárias) contribuem para a identificação de níveis granulares de sazonalidade na demanda (FILDES et al., 2019), o que colabora para o aumento da disponibilidade dos produtos em prateleira e reduz o excesso de estoques e os seus custos, incluindo inclusive os de deterioração (DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021).

A previsão de vendas no varejo pode ser caracterizada como complexa, pois as vendas nas organizações têm sido impactadas por múltiplos fatores micro e macroeconômicos, além de ser um ambiente marcado pelo aumento das expectativas dos clientes, mudanças significativas frequentes e situações de compras cada vez mais complexas e maior diversidade no comportamento dos clientes (INGRAM, 2004).

O varejo supermercadista é um ambiente complexo marcado por rápidas mudanças e pressão persistente para o desempenho em níveis cada vez mais altos, em função da forte competitividade. A complexidade do varejo supermercadista também está associada as características específicas de produtos ou grupos de produtos, de unidades de lojas de portes distintos, e a particularidades no comportamento do consumidor, entre outros fatores (INGRAM, 2004).

O setor de varejo supermercadista é marcado por margens de lucro baixas, devido à forte competição de preços entre concorrentes (KOTZAB; TELLER, 2003, RITZMAN; KRAJEWSKI, 2009). Nesse contexto, o fornecimento de produtos aos clientes requer disponibilidade de itens demandados, redução do tempo de espera de clientes e entregas rápidas. A insuficiência de produtos pode resultar na perda de clientes e de vendas, pois as suas necessidades podem não ser atendidas, além de reduzir a lucratividade e competitividade do mercado. Por outro lado, estoques excessivos geram elevados custos de armazenamento, perda de mercadorias perecíveis e perda de receita (KARAN et al., 2014, GRUBER et al., 2016, HUANG, 2017).

Os estudiosos de gestão de operações têm depositado esforços para aumentar a eficiência e desempenho organizacional. Para se tornarem competitivas nesse cenário, as empresas estão adotando tecnologias modernas e processos organizacionais, buscando integrar técnicas de previsão já consolidadas ou inovadoras em sistemas de reabastecimento com base em informações de dados de vendas, o que pode contribuir para a manutenção dos níveis de qualidade de serviço. Nesta vertente, as técnicas de previsão de vendas automatizadas merecem ênfase (TAYLOR, 2007, MARTELLI; DANDARO, 2015, FISHER; RAMAN, 2018).

No entanto, pode-se observar que as pesquisas recentes sobre previsões de vendas no nível de produtos individuais são feitas com granularidade semanal, para supermercados (FILDES et al., 2019). Mesmo diante da alta relevância prática, a previsão diária no nível do produto não foi abordada na literatura desde o estudo de Taylor (2007), no qual efetuou uma previsão de venda diária para produtos no contexto de uma mercearia (DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021).

Nota-se que existe um desafio prático e tecnológico, que seria a previsão diária - alta frequência para produtos específicos, no contexto dos supermercados, de modo que possa apoiar os sistemas de reposição alimentícios (EHRENTAHAL et al., 2014).

Além de buscar explorar sobre a previsão diária, esse estudo visa confrontar os modelos de previsão estáticos – que são comumente adotados na literatura – com modelos dinâmicos, tendo por finalidade desenvolver uma previsão de vendas diária no contexto dos supermercados e atuar na perspectiva de apontar novos caminhos para discussões sobre a previsão de vendas automatizada.

Ao selecionar a granularidade apropriada (horizonte de tempo para a previsão) e a classe de modelo mais assertiva (estático ou dinâmico) para a previsão de vendas do varejo supermercadista, é possível reduzir a ocorrência dos erros nas previsões, mesmo em modelos mais simples.

Fildes e outros (2019) abordam em seu trabalho que ao usar horizontes de previsão mais curtos em uma base, é necessário treinar novamente os modelos de previsão mais frequentemente. Já Poler e Mula (2011) indicam que a precisão da previsão é comumente avaliada na literatura usando um erro de previsão um passo à frente. Neste estudo, os pesquisadores apresentam que na prática as empresas geralmente estão interessadas em avaliar as previsões por um período mais longo de

horizonte temporal, de modo que a literatura carece desses estudos. Um caminho para explorar essa avaliação por horizontes mais longos, é por meio da previsão estática (de treino e teste).

O trabalho de Dharmawardane, Sillanpää, Holmström (2021) aponta que ainda não foi encontrada nenhuma literatura que discuta ou forneça diretrizes acerca de como escolher o horizonte de previsão ou a frequência de retreinamento para um modelo de previsão.

A presente pesquisa foi desenvolvida em conjunto com uma loja de grande porte de uma Rede de Supermercados do Espírito Santo, com produtos da classe A, da curva ABC da unidade de loja. O gestor dessa loja utiliza um modelo de média móvel para as previsões, no qual considera os últimos sessenta dias de vendas para prever as vendas da próxima semana.


A empresa foi escolhida pois possui um problema real para ser resolvido: aumentar a disponibilidade de produtos aos clientes, com o menor estoque possível. E, portanto, de posse de um modelo de previsão acurado, a presente pesquisa visa reduzir a possibilidade de ocorrência de rupturas de estoques por meio da simulação. Para isso, a empresa aceitou disponibilizar os dados para a pesquisa, sendo que a principal motivação para o supermercado compartilhar os dados foi devido a insatisfação do próprio gestor com o modelo de previsão de vendas que estava utilizando. Entende-se que a empresa do estudo de caso tem adotado um modelo de previsão de vendas semanal simples, que atende as suas necessidades.

No entanto, observa-se que o modelo de previsão de vendas elaborado pelo gestor tem por finalidade dimensionar a quantidade de mercadoria a ser enviada do centro de distribuição para a loja física. E, portanto, a modelagem desenvolvida no trabalho atua nesta perspectiva. Essa concepção surgiu a partir de contatos iniciais com a empresa e avaliação do gestor da organização, de modo que foi observado que as técnicas adotadas pela empresa apresentam capacidade preditiva insatisfatória, resultando em rupturas de estoques em algumas situações e excesso de estoque em outras. Sendo assim, o gestor interessou-se em desenvolver um trabalho em conjunto, com a finalidade de encontrar métodos de previsão mais assertivos.

Para facilitar a visualização do campo de atuação do pesquisador será apresentada a figura a seguir, a qual explicita um exemplo de rede de suprimentos

para o varejo e representa o caso estudado. A rede de supermercados possui algumas unidades de lojas e um centro de distribuição (CD) responsável pelo abastecimento diário de produtos.

Figura 01 - Rede de Suprimentos no Varejo



Fonte: https://www.sintec.com/pt-br/p_innovador/varejo2-0/varejo2-0-11-2/

Acesso em: 14 ago. 2018

A imagem ilustra que o presente trabalho é realizado na etapa da cadeia de suprimentos de número (2), a qual é originada no centro de distribuição (CD) e destinada às lojas (varejo supermercadista). A atuação do (CD) é pautada no fornecimento diário de produtos para o supermercado devido a necessidade da reposição dos produtos vendidos nas gôndolas, gerando custos logísticos, além do alto risco de falta ou sobra de produtos na loja.

Nota-se também que a realização da previsão de demanda na etapa (2) da rede de suprimentos foi delimitada no campo descrito de atuação do pesquisador. Portanto, o desenvolvimento do trabalho foi possibilitado a partir da disponibilização de uma base de dados gerencial referente às vendas diárias de apenas uma unidade de loja. Além disso, pode-se destacar que seria possível efetuar uma previsão de demanda na etapa de número (1), a qual emerge do fabricante/fornecedor dos produtos com designação ao centro de distribuição das lojas (CD). Contudo, para fazer isso, seria

necessário deter uma base de dados com os registros do comportamento das vendas de todas as lojas.

Apesar de não ser o foco desta pesquisa, em um âmbito de dimensão mais ampla, pode-se notar que atualmente os supermercados enfrentam um desafio ainda maior no contexto da pandemia, a previsão de vendas para o e-commerce. Durante a pandemia, a alternativa de ofertar produtos essenciais de maneira virtual ganhou destaque e varejistas que estavam preparados para efetuar operações on-line obtiveram ganhos substanciais diante da concorrência. De fato, os supermercados que não pretendem atuar no e-commerce tendem a perder espaço no mercado, visto que os consumidores estão cada vez mais habituados a realizarem compras virtuais. E para se manter competitivo é necessário atender as necessidades dos clientes e entregar soluções que agregam valor. E como há uma forte tendência em busca por conveniência, as vendas on-line vêm ganhando força.

1.1 OBJETIVO

A presente pesquisa tem como objetivo principal comparar modelos de previsão de vendas com a lógica de alta frequência (diária) com os semanais, no contexto do varejo supermercadista.

Como objetivo secundário, pretende-se simular modelos estáticos e dinâmicos, assim como o modelo desenvolvido pelo gestor para fins de comparações e apresentar o impacto do horizonte de previsão e da frequência de treinamento sobre o desempenho dos modelos de previsão.

1.2 JUSTIFICATIVA

As técnicas de previsão de vendas são capazes de auxiliar na busca pela eficiência nos processos organizacionais. Pode-se notar na literatura que apesar da temática ser amplamente discutida, ainda há bastante espaço para discussões sobre as suas perspectivas nos campos de cunho teórico e prático, principalmente em contextos específicos, como é o caso do varejo (NUNES, 2019).

A previsão de vendas atua como um ponto de partida no que diz respeito a estimação de vendas de produtos ou serviços no futuro. Portanto, uma empresa que realiza vendas adota um modelo de previsão, por mais imperfeito que seja, em relação aos seus resultados. Contudo, erros de previsões muito elevados podem provocar rupturas de estoques e proporcionar baixos níveis de serviços aos clientes. (CHAMBERS; MULLICK; SMITH, 1971, HOFMANN; RUTSCHMANN, 2018, AMALNICK et al., 2019). Além disso, previsões mal estruturadas são capazes de elevar entre 10% a 30% dos custos operacionais da empresa, o que pode comprometer a sua lucratividade (SANDERS; GRAMAN, 2009).

Dharmawardane e outros (2021) realizaram uma revisão de literatura e direcionaram algumas orientações para pesquisas futuras em operações de lojas no varejo. Apontou-se neste estudo que a maioria das pesquisas desenvolvidas no âmbito da previsão de vendas não têm levado em consideração o nível de granularidade diário para a previsão de vendas, indicando uma lacuna existente.

As previsões diárias são importantes principalmente para itens perecíveis, com poucos dias de validade. Elas favorecem a otimização da reposição de produtos e alocação de processos para os clientes. As previsões diárias são capazes de proporcionar maior disponibilidade de itens em prateleira e redução do desperdício de produtos. Em consonância, questões como espaço disponível e planejamento de mão de obra também são bastante influenciados (MOU et al., 2018).

Dessa forma, o presente estudo tem o potencial de contribuir para resultados gerenciais, abordando sobre a previsão de alta frequência (diária) para o varejo supermercadista. Além disso, examina como o horizonte de previsão pode ser capaz de influenciar no desempenho e classificação dos modelos, de modo a questionar um procedimento adotado atualmente, acerca dos modelos de previsão de treinamento em intervalos fixos.

Nessa vertente, identificou-se a partir da revisão de literatura, que os modelos Holt-Winters e o ARIMA podem ser utilizados para a previsão de alta frequência (previsão diária) no nível do produto.

Depois de comparar o desempenho preditivo de ambos os modelos, considerando a granularidade diária para as previsões, optou-se por utilizar o TBATS (LIVERA et al., 2011) nesta pesquisa. Esperava-se que o TBATS proporcionasse

resultados mais acurados do que o Holt-Winters e o ARIMA, visto que o TBATS é capaz de capturar diversas sazonalidades para a modelagem. Em uma pesquisa anterior efetuada, pelo autor desta, foi possível observar a existência destas sazonalidades complexas para esta mesma rede de supermercado do estudo de caso da presente dissertação. Algo que pode ser explicado pelo fato de que as vendas nos supermercados são influenciadas pelo dia do mês e dia da semana (por exemplo: as vendas aumentam nas datas próximas ao pagamento do salário dos clientes; além da média das vendas serem maiores na quinta-feira, sexta-feira e sábado, em detrimento dos demais dias da semana – o supermercado do estudo de caso em questão não abre no domingo).

1.3 ESTRUTURA DA DISSERTAÇÃO

Esta dissertação é dividida em quatro capítulos.

O primeiro capítulo introduz o trabalho, apresentando as considerações iniciais, o tema, o objetivo e a justificativa. Além de ser levantado sobre a estrutura que se pretende organizar a dissertação.

O segundo capítulo aborda sobre a revisão de literatura da dissertação e é dividido em quatro seções: A previsão de vendas e seus usos operacionais no varejo alimentício; A previsão de vendas de alta frequência: um estudo de três abordagens; TBATS; e as influências do horizonte de tempo para a previsão e do treinamento na modelagem.

A primeira seção apresenta sobre as pesquisas de previsão de vendas no varejo e os desafios operacionais enfrentados pelos gestores varejistas. A segunda seção levanta uma discussão sobre as abordagens de Holt-Winters, ARIMA e o modelo adotado pelo gestor. A terceira seção aborda sobre o TBATS. E a última seção, discute sobre o horizonte de tempo adotado para a estimação de parâmetros para a modelagem em questão e as influências do treinamento para a previsão, levando em consideração a modelagem estática e dinâmica.

O terceiro capítulo engloba os procedimentos metodológicos para a realização desta dissertação.

O quarto capítulo apresenta os resultados.

O quinto capítulo levanta as considerações finais.

2 REVISÃO BIBLIOGRÁFICA

No presente capítulo, apresentou-se a sistemática elaborada para a revisão de literatura. Revisou-se a temática previsão de vendas e seus usos operacionais em um supermercado. Além disso, examinou-se três abordagens de séries temporais para a previsão de demanda, no nível do produto (Holt-Winters, ARIMA e TBATS). Após, comparou-se o desempenho das técnicas, considerando operacionalmente o horizonte de previsão e o conjunto de dados utilizado para treinamento das previsões estáticas e dinâmicas.

Para a realização da modelagem de previsão de vendas optou-se pela escolha de modelos de séries temporais, mesmo compreendendo que fatores como preço, produtos complementares e substitutos, características do produto, número de visita de clientes, eventos e clima interferem nas vendas dos supermercados (ARUNRAJ; AHRENS, 2015). A escolha foi feita em razão da dificuldade de acesso aos dados em campo, que poderiam contribuir para a elaboração de modelos causais, sendo que a pandemia foi um componente determinante para essa limitação.

Contudo, notou-se por meio da revisão de literatura, a ausência de estudos que relatam sobre o fato de modelos causais serem melhores que os de séries temporais e, portanto, optou-se por delimitar a modelagem da presente dissertação nas técnicas de séries temporais.

2.1 REVISÃO SISTEMÁTICA DE LITERATURA

Para efetuar a revisão de literatura, a pesquisa contou principalmente com a banco de dados da Scopus. O fato da previsão de vendas ser um tópico abrangente tem tornado a coleta de documentos da previsão no varejo uma tarefa árdua, de modo que vários trabalhos do campo não possuem como palavra-chave o termo “varejo”, e sim outros mais específicos, como: “promoção”, “cadeia de suprimentos”, “loja”, “produto”, “demanda” e “vendas”. Com a finalidade de garantir uma revisão abrangente, foi elaborada uma sistemática que engloba composições de palavras-chave, como por exemplo: “(retail OR demand OR sales)” e “(forecasting OR prediction)”. Em seguida, para selecionar os artigos mais relevantes para a pesquisa,

foi feita a leitura do resumo dos trabalhos, com o objetivo de filtrar os voltados para a previsão de varejo, dada a relevância.

Quadro 01 – Principais trabalhos selecionados e as suas contribuições

Trabalhos	Contribuições
(CORSTEM; GRUEN, 2003)	O trabalho aborda sobre a disponibilidade de itens em prateleira no varejo. Para tal, avalia as causas e a resposta dos consumidores à falta de estoques. Além disso, o trabalho discute acerca da sazonalidade existente no varejo e as previsões de venda de granularidade diária.
(TAYLOR, 2007)	Foi o trabalho pioneiro a realizar a previsão de vendas com granularidade diária, para produtos no nível individual.
(MA et al., 2016)	A pesquisa aborda sobre a previsão de vendas estática e julga esses modelos como úteis para a horizontes de previsão mais longos.
(RAMOS; FILDES, 2017),	O trabalho realiza uma previsão semanal dinâmica para a demanda de mantimentos. Sendo assim, os autores efetuam apenas uma previsão por vez, para cada produto e discutem os benefícios de atuar com modelos dinâmicos em detrimento dos estáticos.
(FILDES et al., 2019)	Este estudo efetua uma revisão abrangente de literatura que discute sobre a previsão de vendas no varejo e aborda sobre os principais problemas enfrentados pelos gestores nos âmbitos estratégicos, táticos e operacional. Para a presente dissertação, destaca-se o interesse em explorar principalmente a discussão no nível operacional.
(DHARMAWARDANE et al., 2021)	O estudo de Dharmawardane e outros (2021) é a pesquisa mais recente que retrata sobre a previsão de vendas no âmbito diário. Por meio de revisão de literatura, o trabalho apontou orientações para pesquisas futuras sobre operações de lojas no varejo. Foi o primeiro estudo a utilizar o TBATS para o varejo alimentício.

Fonte: Elaboração própria.

2.2 PREVISÃO DE VENDAS E SEUS USOS OPERACIONAIS NO VAREJO ALIMENTÍCIO

O trabalho de Fildes e outros (2019) efetua uma revisão de literatura sobre a previsão de vendas no varejo e retrata acerca dos problemas de previsão enfrentados pelos gestores do varejo, discutindo sobre a previsão nos níveis estratégicos, tático e operacional.

No nível operacional, a previsão de vendas atualizada é capaz de gerar muitos benefícios, como a elevação da receita e maior satisfação do cliente (DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021). No entanto, apesar de existirem estudos que realizam a previsão de vendas no nível diário para produtos individuais (SKU), como Taylor (2007), grande parte da literatura considera a previsão semanal um passo à frente para a demanda de alimentos (FILDES et al., 2019, DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021).

A previsão de demanda atualizada em conjunto com a reposição eficiente de estoques pode contribuir para a redução de rupturas de estoque e também para o aumento da satisfação e fidelização de clientes (CORSTEN; GRUEN, 2003). No entanto, diante da ocorrência de rupturas de estoques, os clientes podem optar por não fazer compras ou procurar outra loja, e por esse motivo, a falta de itens pode levar os varejistas a perderem vendas e receita (FERNIE; GRANT, 2008).

O estudo de Corsten e Gruen (2003) aborda que os níveis de demanda costumam ser diferentes durante a semana (com base no dia da semana e hora do dia), além disso relata que as taxas de falta de estoque no varejo não são aleatórias, de modo que variam conforme o dia da semana de maneira distinta. Por exemplo: Em um supermercado, é mais fácil encontrar pessoas fazendo compras na sexta-feira à noite, do que nas quartas-feiras. Desse modo, observa-se a presença de sazonalidade diária na demanda de um supermercado, aspecto que justifica a necessidade de alinhar a reposição de mercadorias de um supermercado com as previsões de granularidade diária, a fim de evitar a ocorrência de rupturas de estoques ao longo da semana (FILDES, 2019).

Apesar disso, a literatura ainda carece de estudos que adotam a granularidade de tempo no nível diário (a maior parte dos estudos adota o nível da semana) para a previsão de alimentos (FILDES et al., 2019, DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021). Um motivo atrelado pode ser a dificuldade que os varejistas têm em realizar previsões automatizadas diárias em seus sistemas de abastecimento (EHRENTHAL et al., 2014). No entanto, é necessário atentar-se ao fato de que os varejistas de alimentos possuem diversos produtos perecíveis e o seu excesso pode provocar desperdício e por outro lado a falta de itens em prateleira pode afetar negativamente a retenção de clientes (FERNIE; GRANT, 2008).

Observa-se que as previsões diárias são relevantes especialmente para produtos perecíveis e podem contribuir para o aumento da competitividade varejista (DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021).

2.3 PREVISÃO DE VENDAS DE ALTA FREQUÊNCIA: UM ESTUDO DE TRÊS ABORDAGENS

Apesar de existirem estudos sobre a previsão de demanda de alta frequência (previsão diária), como o de Taylor (2007) – feito no contexto de uma mercearia, essa temática foi pouco discutida no ambiente do varejo supermercadista. Nesta perspectiva, observou-se na literatura, que as técnicas de Holt-Winters e ARIMA podem ser utilizadas para a previsão de alta frequência (previsão diária), de modo que ambas são escolhas válidas para a previsão diária no nível do produto (DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021).

O ARIMA (Box et al. 2008) é um modelo comumente adotado por profissionais para realizar previsões. O modelo ARIMA pode ser visto como uma referência na literatura de previsão de séries temporais e sua aplicação tornou-se conhecida principalmente com ênfase no contexto de curto prazo (RAMOS et al., 2015). Sua nomenclatura significa Modelo Auto Regressivo Integrado de Médias Móveis. Os parâmetros p , d e q são adotados para classificar um modelo ARIMA e caracterizar a ordem da parte Auto Regressiva, o grau de diferenciação e a ordem da média móvel do modelo. Os modelos AR (autorregressivo) e MA (de média móvel) adotam dados

de etapas anteriores de tempo como entrada para realizar previsões para estágios futuros (HYNDMAN, ATHANASOPOULOS, 2018).

Em um Modelo Autorregressivo (AR), a variável de interesse é prevista por meio de uma combinação linear de dados anteriores da variável, sendo assim, o termo autorregressivo aponta uma regressão da variável contra si mesma. Os modelos de AR são capazes de lidar com uma ampla gama de padrões de séries temporais (HYNDMAN, ATHANASOPOULOS, 2018).

Já os modelos de Média Móvel (MA) podem adotar diferentes intervalos de tempo para efetuar cálculos de uma média. No entanto, quanto mais curto é o período de tempo selecionado para criar a média, mais sensível é a alteração dos valores calculados, e quanto maior for o prazo estabelecido, menos sensível será a média (HYNDMAN, ATHANASOPOULOS, 2018).

O Modelo Auto Regressivo Integrado de Médias Móveis (ARIMA) combina os modelos AR e MA, de modo que o modelo ARIMA utiliza o AR para incluir dados históricos e MA para inserir o histórico de erros residuais. O ARIMA integra os dois termos por meio da diferenciação, com a finalidade de estacionarizar séries temporais com tendência (HYNDMAN, ATHANASOPOULOS, 2018).

Pelo fato de o ARIMA combinar o AR e MA, este modelo se torna flexível diante de diversos padrões de séries temporais, sendo capaz de lidar com a tendência. Além disso, o ARIMA pode ser utilizado para séries que apresentam sazonalidade ou não, de modo que um parâmetro sazonal pode ser incluído no modelo ARIMA (SARIMA) (HYNDMAN, ATHANASOPOULOS, 2018).

O modelo Holt-Winters é um dos modelos mais conhecidos e utilizados no varejo alimentício. Ele é capaz de lidar com dados univariados, que podem ser estendidos para suportar dados com uma tendência sistemática ou componente sazonal (HYNDMAN, ATHANASOPOULOS, 2018).

O Holt-Winters se destaca principalmente devido a sua robustez, simplicidade e confiabilidade (GARDNER JR, 2006). Ele pode se caracterizar como uma extensão da suavização exponencial e possui três equações para tendência, nível e sazonalidade, além de um parâmetro de suavização para cada uma delas (WINTERS, 1960). Além disso, o modelo de Holt-Winters atribui um peso que decresce

exponencialmente para as observações de dados anteriores, de modo que quanto mais recente é o dado, maior o peso associado (HYNDMAN, ATHANASOPOULOS, 2018).

Apesar desse modelo ser mais simples que o ARIMA, o Holt-Winters é muito sensível aos valores discrepantes. No entanto, pesquisadores estão buscando aprimorá-lo, inclusive, ampliando horizontes de previsões, a fim de capturar as incertezas das previsões (DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021).

Por fim, os modelos de séries temporais apresentam como vantagens a interpretação da modelagem e eficiência computacional, visto que os modelos são facilmente implementados e os seus resultados são intuitivos. Todavia, é preciso atentar-se aos pressupostos estabelecidos pelos processos estocásticos, os quais geralmente simplificam o contexto organizacional vivenciado (GE et al., 2019).

Quadro 1.1 - Resumo das três abordagens: Média Móvel, ARIMA e Holt-Winters

Média móvel

Característica: A variável dependente é uma combinação linear de valores previstos anteriormente.

Vantagem: Lida com tendências significativas.

Desvantagem: o modelo precisa ser invertível.

ARIMA

Característica: A variável dependente é uma combinação de seus valores defasados e o valor presente do termo de erros aleatórios.

Vantagem: Flexível a diferentes padrões de séries temporais e lida com a tendência.

Desvantagem: Requer estacionariedade, as séries precisam ser invertíveis e apresentar relações lineares.

Holt-Winters

Característica: A variável dependente é uma função de valores históricos com pesos atribuídos aos componentes.

Vantagem: Atua com dados univariados, lida com a tendência e sazonalidade.

Desvantagem: Não considera os termos de erro.

Fonte: Adaptado de Hyndman e Athanasopoulos, 2018.

2.4 TBATS

O TBATS (DE LIVERA et al., 2011) é um modelo de previsão personalizado para considerar a sazonalidade múltipla em questão. Essa técnica tem sido notada em estudos de previsão de demanda para concessionárias automotivas. O TBATS utiliza funções trigonométricas que permitem lidar com padrões de demanda e de sazonalidade complexa (GRAMANOVÁ et al., 2016). O estudo de Lago e outros (2018) adotou o TBATS para efetuar a previsão de demanda para serviços públicos, de modo que este estudo demonstrou alto nível de precisão do modelo escolhido.

Observa-se também que, o TBATS foi utilizado apenas em um estudo para a previsão de vendas do varejo supermercadista (DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021).

Os modelos tradicionais de previsão têm enfrentado dificuldades na presença de padrões sazonais complexos, por exemplo: quando a previsão é feita diariamente ou quando a série temporal utilizada para treinar o modelo é superior a um ano. Portanto, uma das maiores vantagens do TBATS é que ele permite o uso de frequências não inteiras para lidar com padrões sazonais complexos (LIVERA et al., 2011).

Os erros podem se correlacionar quando padrões sazonais não são capturados adequadamente por parâmetros dos modelos (TAYLOR, 2003). O TBATS considera o fato de que os erros podem ser correlacionados e visa modelá-lo para tornar as previsões mais precisas (LIVERA et al., 2011). Pelo fato de considerar a correlação em erros automaticamente, o TBATS torna o processo de previsão mais fácil.

O TBATS foi introduzido no ano de 2011 e pode ser notado em um número limitado de estudos no âmbito da previsão, principalmente no varejo. O estudo de Livera e outros (2011), que introduziu o uso da técnica, foi feito com dados de postos de gasolina nos EUA. Pereira (2016) abordou em seu trabalho sobre a previsão de ocupações hoteleiras. No estudo de Pereira (2016), foi feita uma comparação de desempenho entre os modelos tradicionais de previsão com o TBATS para ocupações hoteleiras, e houve uma descoberta de que o TBATS geralmente superou os demais por conta da sua capacidade de lidar com padrões sazonais complexos. Contudo, a maioria dos estudos que envolvem o TBATS são desenvolvidos para a previsão no setor de energia elétrica (BROZYNA et al., 2018).

No âmbito da energia elétrica, poucas previsões são feitas e vários padrões de sazonalidade são considerados (nos níveis diário, semanal e anual). Veit e outros (2014) testaram técnicas robustas para a previsão de demanda de eletricidade, e quando as comparou com o TBATS, obteve um desempenho preciso da mesma forma, mesmo quando os horizontes de previsão foram aumentados. Esse achado é útil, pois a robustez é um requisito para a previsão de vendas no varejo supermercadista (DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021).

Outro fator a ser considerado é que o contexto do varejo é bem diferente dos setores em que o TBATS foi aplicado anteriormente. Ao alterar o foco da utilização do TBATS na previsão de demanda de eletricidade para a previsão de vendas do varejo

supermercadista, cria-se o risco de obtenção de um desempenho inferior, devido a sua complexidade inerente. Sendo assim, o uso da combinação dos vários parâmetros do TBATS pode contribuir para a criação de um modelo de previsão super ajustado ao treinamento dos dados, produzindo resultados com baixa capacidade preditiva. Outro elemento a se destacar é a enorme produção de previsões do varejo, em detrimento do setor elétrico. Com a elevação da quantidade de previsões, eleva-se o tempo de processamento de máquina.

2.5 AS INFLUÊNCIAS DO HORIZONTE DE TEMPO PARA A PREVISÃO E DO TREINAMENTO NA MODELAGEM

Existem estudos na literatura mostraram que a precisão dos modelos de previsão de vendas depende do horizonte de previsão em questão (KOEHLER; MURPHREE, 1988, FILDES et al., 1998, DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021).

No âmbito da previsão, tanto na teoria quanto na prática, é bem consolidada a informação de que as previsões para um futuro distante são menos confiáveis do que para previsões próximas do presente (CHAND et al., 2002). Partindo dessa premissa, diversos modelos de previsão vigentes na literatura têm reestimado parâmetros da modelagem em intervalos de tempo regulares, com dados mais recentes, tendo por finalidade melhorar a precisão da previsão (treinamento de dados). Em conformidade, neste trabalho acredita-se que seja mais adequado atuar com horizontes de previsões diários e não semanais, visto que se pretende desenvolver um modelo de previsão para o envio de produtos do centro de distribuição de um supermercado para a loja física e não para a compra de mercadorias.

No entanto, em grande parte dos estudos da literatura a frequência do treinamento depende do planejamento de pedidos do varejista e por isso, o treinamento é feito com a frequência de um passo à frente (geralmente de uma semana para o varejo alimentício), incluindo os novos valores previstos (MA et al., 2016).

Pode-se citar como exemplo o trabalho de Ramos e Fildes (2017), que realiza uma previsão de demanda semanal de mantimentos. Os autores efetuam apenas uma previsão por vez, para cada produto. Após cada previsão, eles inserem dados de

vendas reais, do conjunto de testes, para treinar novamente o modelo de previsão, antes de desenvolver a próxima previsão (previsão dinâmica).

Em contrapartida, alguns pesquisadores optaram por não realizar previsões dinâmicas, e desenvolveram um esquema de previsão fixo. Ma e outros (2016) efetuam previsões para todo o conjunto de teste utilizando apenas um único conjunto de dados de treinamento. Nesse caso específico, não é preciso treinar novamente o modelo. No entanto, esses mesmos autores afirmaram que essa abordagem não é tão utilizada na prática, apesar de ser potencialmente útil para avaliar a robustez do modelo em horizontes de previsão mais longos.

Destaca-se que a frequência de treinamento de um modelo de previsão é capaz de influenciar seu desempenho. Além disso, observa-se que o treinamento em intervalos menores pode ser capaz de melhorar o desempenho da previsão. No entanto, nota-se a presença de um trade-off entre a frequência de retreinamento e os custos em termos de tempo computacional. Quanto menor a frequência de retreinamento, maiores serão os custos em termos de tempo computacional (DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021).

3 PROCEDIMENTOS METODOLÓGICOS

3.1 MOTIVAÇÃO PARA A SELEÇÃO DA EMPRESA DO ESTUDO DE CASO

A empresa do varejo supermercadista pretende explorar novas possibilidades para automatizar o seu sistema de previsão de vendas. Este estudo de caso apresenta o desafio de proporcionar a utilização da previsão de alta frequência (previsão diária) no contexto prático. Explorar esse desafio se tornou a principal motivação para iniciar a realização do trabalho.

A rede de supermercados do estudo de caso possui seis unidades de loja em duas cidades do Espírito Santo, sendo quatro unidades de loja, incluindo a sua sede em Cachoeiro de Itapemirim e duas lojas em Castelo. A rede pretende inaugurar mais uma unidade de loja em breve, na cidade de Cachoeiro de Itapemirim. Além disso, atualmente oferece um serviço de compras on-line, o Compra Fácil.

A empresa selecionada para o estudo de caso forneceu o banco de dados para a realização modelagem da previsão de vendas. Além disso, o gestor desta Rede de Supermercados pretende comparar o desempenho das soluções atuais adotadas com o modelo automatizado criado.

3.2 COLETA E TRATAMENTO DE DADOS

A etapa inicial para o desenvolvimento da modelagem foi composta pela aquisição de uma base de dados secundária, obtida em uma parceria com uma Rede de Supermercados Varejista, tendo por finalidade realizar a modelagem dos dados históricos de vendas. Os dados obtidos são do período de 31 de janeiro de 2019 a 17 de agosto de 2020 e os produtos selecionados para a modelagem foram codificados, de modo que o pesquisador não é capaz de identificar os produtos utilizados para efetuar o trabalho. A fim de desenvolver a seleção de produtos, optou-se pela escolha dos cinquenta itens mais vendidos pela loja. Para o desenvolvimento da modelagem foi verificado o comportamento dos dados, considerando dados ausentes e valores discrepantes. Nesta etapa foram analisadas informações como a média das vendas no período, desvio-padrão e amplitude, além do coeficiente de variação. Na ocorrência

de dados ausentes, foram imputados valores referentes à média das vendas do mês anterior.

3.3 MODELAGEM DE PREVISÃO DE VENDAS

Para a realização desta etapa, de maneira prévia, foi realizada uma análise gráfica para verificar a existência ou não de padrões, tendências, sazonalidade e estacionariedade na série temporal. Para comprovar que todas as séries temporais abordadas são estacionárias, verificou-se o gráfico das séries e efetuou-se o teste de Dickey-Fuller (adf).

Em seguida, os esforços foram concentrados para a definição de um método estatístico que melhor se adapta aos dados históricos de vendas. Para avaliar a qualidade preditiva da modelagem estática, os dados foram divididos em dois subconjuntos de dados: treino e teste. A primeira é efetuada para estimar os parâmetros significativos do modelo e a segunda para avaliar a sua capacidade preditiva.

Como sugere Nunes (2019), a porção de treino será composta por 50% dos dados mais antigos e a porção de teste por 50% dos dados restantes, tendo em mente a validação do método. Foi necessário adotar uma técnica para avaliar as medidas de acurácia e mensurar os erros de previsão. Para tal, optou-se pela medida RMSE, visto que é comumente adotada na literatura e atende as necessidades.

Para comparar a capacidade preditiva dos modelos de previsão de vendas diários (de alta frequência) com os modelos de previsão semanal, adotou-se os modelos de Holt-Winters e ARIMA, simulando ambos com um passo à frente (um dia) e também com seis passos à frente (seis dias).

A fim de avaliar a capacidade preditiva dos modelos em horizontes de previsão mais longos, comparou-se o desempenho preditivo dos modelos de Holt-Winters e ARIMA, simulando ambos de modo estático (treino e teste) e de maneira dinâmica.

Para efetuar a modelagem, desenvolveu-se oito modelos:

- Média (6 passos à frente) – adotada pelo gestor
- Holt-Winters andando (6 passos à frente)

- Holt-Winters andando (1 passo à frente)
- Holt-Winters (treino e teste)
- ARIMA andando (6 passos à frente)
- ARIMA andando (1 passo à frente)
- ARIMA (treino e teste)
- TBATS

A média do gestor foi calculada com o objetivo de simular o modelo de previsão atual da Rede de Supermercados. Para efetuar a previsão de vendas para a próxima semana, o gestor seleciona os valores das vendas reais dos respectivos últimos sessenta da base de dados e cria uma média aritmética simples para prever as vendas dos próximos seis dias. O prognóstico desempenhado resulta em seis valores semelhantes para os próximos seis dias. Assim, na próxima previsão, são desconsiderados pelo gestor os valores dos primeiros seis dias (6 passos à frente). Dessa forma, é operacionalizada uma nova média aritmética com as vendas dos cinquenta e quatro dias anteriores acrescidos dos últimos seis dias previstos.

O “Holt-Winters andando (6 passos à frente)” e o “ARIMA andando (6 passos à frente)” correspondem a modelos de previsão que consideram os últimos 60 dias de vendas para estimar os parâmetros do algoritmo e prever as vendas da próxima semana (6 passos à frente).

O “Holt-Winters andando (1 passo à frente)” e o “ARIMA andando (1 passo à frente)” correspondem a modelos de previsão que consideram os últimos 60 dias de vendas para estimar os parâmetros do algoritmo e prever as vendas do próximo dia (1 passos à frente).

Já o “Holt-Winters treino e teste” e o “ARIMA treino e teste” configuram modelos de previsão que utilizam 242 dias de vendas (metade das observações da base de dados) para estimar os parâmetros do algoritmo e realizar previsões para 242 dias (número de observações restantes).

Os modelos andando (dinâmicos) foram criados com a finalidade de comparar os seus desempenhos preditivos em relação aos modelos mais estáticos (de treino e teste) – confrontou-se o Holt-Winters andando (1 e 6 passos à frente) x Holt-Winters treino e teste, assim como ARIMA andando (1 e 6 passos à frente) x ARIMA treino e

teste. Posteriormente, selecionou-se os dois melhores modelos para fins de comparação (contrastando as técnicas de Holt-Winters x ARIMA). E por fim, confrontou-se o modelo que apresentou melhor desempenho em relação à média adotada pelo gestor.

As comparações feitas têm por finalidade analisar se o comportamento das previsões de vendas de uma unidade de loja de um supermercado pode ser melhor explicado quando se adota um conjunto de dados mais recente (número de observações de vendas), no qual é atualizado diariamente ou semanalmente para efetuar a previsão de vendas diárias ou semanais – modelos andando, ou se é mais interessante adotar um conjunto de dados mais amplo (com quantidade maior de observações de vendas) para efetuar uma única previsão de vendas para várias semanas – modelos estáticos. Por fim, comparou-se o desempenho das técnicas de Holt-Winters x ARIMA, para assim, confrontar com a média do gestor.

O TBATS é um modelo que foi selecionado com a finalidade de capturar a existência de sazonalidade múltipla das séries temporais. Sob tal perspectiva, o TBATS considera várias alternativas para a modelagem, como a realização ou não de uma transformação Box-Cox, com ou sem tendência, com ou sem processo ARMA (p, q) para modelar resíduos, modelo não sazonal e processos harmônicos utilizados para modelar efeitos sazonais, de modo que o modelo final é escolhido usando o critério de informação de Akaike (AIC). Adotou-se a abordagem dinâmica de alta frequência - diária (de um passo à frente). Além disso, comparou-se o seu desempenho com o ARIMA dinâmico, de um passo à frente.

3.4 PRESSUPOSTOS DA PREVISÃO DE VENDAS COM SÉRIES TEMPORAIS

Para desenvolver a modelagem de séries temporais e efetuar a análise dos dados, foi necessário verificar três condições básicas. A normalidade dos resíduos, onde os resíduos gerados pelo ajuste da reta devem apresentar distribuição normal. Homocedasticidade, de modo que a variância de Y seja constante para todos os valores de X . E independência, de forma que não exista estrutura de dependência

entre os dados, assim os resíduos precisam ser independentes e identicamente distribuídos.

Para verificar as condições de normalidade dos resíduos, desenvolveu-se o teste Shapiro Wilk, visto que é um dos testes mais utilizados para tal finalidade na literatura. A fim de avaliar a homocedasticidade das variâncias, realizou-se o teste de Barlett.

Foram desenvolvidos oito testes distintos, tanto para o teste Shapiro Wilk, quanto para o teste de Barlett, de modo que os testes apresentaram resultados esperados conforme os pressupostos, e por esse motivo, o autor da presente dissertação optou por criar uma pasta contendo a base de dados e o script e disponibilizá-la para a visualização dos resultados dos testes pelos leitores, devido a quantidade elevada de testes.

Para verificar se os resíduos são independentes e identicamente distribuídos, foi feita uma análise gráfica por meio dos plots de autocorrelação dos resíduos. Acerca da abordagem de autocorrelação dos resíduos, como a quantidade de gráficos a ser analisada é elevada, o autor verificou que os modelos atendem os pressupostos e optou por apresentar apenas no script, de forma breve, os códigos para o plot de autocorrelação para um produto, a fim de evitar um acréscimo significativo no tamanho do script, assim como da presente dissertação.¹

3.5 SOFTWARE E PACOTES UTILIZADOS

Os testes foram efetuados por meio da linguagem R (R Core Team, 2019) - ferramenta de programação estatística livre ofertada pelo Free Software Foundation's GNU, utilizada mundialmente para realizar pesquisas estatísticas e representações gráficas (SILVA; PERES; BOSCAROLI, 2016). Esta linguagem foi desenvolvida em um software livre, elaborado por John Chambers e seus colegas (team). Segundo

¹ O autor pretende disponibilizar a base de dados em uma base de dados comum com a finalidade de permitir que outras pessoas possam verificar estes e outros resultados. Não fez isso até o momento, pois ainda foi possível.

seus criadores, o software foi criado para a manipulação de dados, cálculos e exibições gráficas. Esse ambiente suporta o tratamento e armazenamento dos dados, além de estabelecer um conjunto de operadores para cálculos numéricos em vetores e matrizes, integrar as ferramentas intermediárias para análise de dados, proporcionar gráficos para análise de dados e exibição na tela ou em console, além de ser uma linguagem simples e eficaz. Além disso, possui ampla comunidade acadêmica que oferece suporte aos usuários (CRAN), além de oferecer uma extensão às funções nativas do software, com os pacotes (FERREIRA et al., 2018). Neste trabalho foi utilizado o pacote forecast (HYNDMAN et al., 2021) e o pacote urca (PFAFF, 2008).

4 RESULTADOS

Este capítulo foi criado com a finalidade de apresentar os resultados e análises de acurácia referentes aos modelos desenvolvidos.

As tabelas 01 e 02 foram elaboradas com o propósito de comparar a acurácia dos modelos semanais com a acurácia dos modelos diários (de alta frequência). Os modelos utilizados para a comparação foram o ARIMA dinâmico e o Holt-Winters dinâmico.

Tabela 01 – Comparação Acurácia (RMSE): ARIMA dinâmico (1 passo à frente) x ARIMA dinâmico (6 passos à frente)

Produtos	ARIMA dinâmico 1 passo	ARIMA dinâmico 6 passos	Produtos	ARIMA dinâmico 1 passo	ARIMA dinâmico 6 passos
Produto1	14,80	51,66	Produto26	47,95	49,10
Produto2	59,29	189,86	Produto27	43,08	54,13
Produto3	38,16	87,45	Produto28	29,76	29,25
Produto4	51,18	90,81	Produto29	35,55	41,26
Produto5	17,97	62,40	Produto30	27,68	38,69
Produto6	25,80	43,05	Produto31	32,21	35,42
Produto7	30,04	48,49	Produto32	35,30	39,42
Produto8	38,52	59,03	Produto33	44,92	45,79
Produto9	26,36	43,46	Produto34	55,96	66,03
Produto10	190,44	60,88	Produto35	50,66	55,51
Produto11	188,04	269,35	Produto36	42,31	57,39
Produto12	177,12	207,98	Produto37	21,68	22,56
Produto13	147,25	154,64	Produto38	24,24	31,13
Produto14	37,10	63,98	Produto39	9,46	9,80
Produto15	72,81	194,90	Produto40	36,53	36,71
Produto16	45,14	126,21	Produto41	9,67	12,53
Produto17	47,81	91,84	Produto42	6,81	6,99
Produto18	45,83	77,09	Produto43	11,85	12,94
Produto19	24,70	62,10	Produto44	20,65	22,30
Produto20		34,52	Produto45	10,07	10,58
Produto21	16,35	16,99	Produto46	8,82	9,17
Produto22	24,05	25,08	Produto47	11,14	11,45
Produto23	29,49	28,10	Produto48	14,16	15,10
Produto24	96,39	97,27	Produto49	20,94	21,77
Produto25	76,56	93,88	Produto50	20,24	20,07

Fonte: Elaboração Própria

*Dados realçados em amarelo: Menor RMSE na comparação dos resultados dos modelos.

Tabela 02 – Comparação Acurácia (RMSE): Holt-Winters dinâmico (1 passo à frente) x Holt-Winters dinâmico (6 passos à frente)

Produtos	Holt-Winters dinâmico 1 passo	Holt-Winters dinâmico 6 passos	Produtos	Holt-Winters dinâmico 1 passo	Holt-Winters dinâmico 6 passos
Produto1	67,20	72,26	Produto26		52,20
Produto2		74,99	Produto27	43,12	56,09
Produto3	35,73	49,04	Produto28		
Produto4	55,52	69,71	Produto29	36,41	45,94
Produto5			Produto30	30,42	46,45
Produto6		45,41	Produto31	35,30	45,82
Produto7	32,13	38,49	Produto32		43,60
Produto8	40,90	54,92	Produto33	41,91	47,14
Produto9			Produto34	67,65	87,63
Produto10	191,13	253,61	Produto35	48,41	50,85
Produto11	198,84	261,88	Produto36	48,39	63,44
Produto12	196,56	231,64	Produto37	22,13	23,30
Produto13	129,29	138,66	Produto38		30,28
Produto14			Produto39	10,15	10,26
Produto15	74,70	110,74	Produto40	59,24	38,72
Produto16	47,79	56,36	Produto41	9,37	11,34
Produto17	49,08	72,21	Produto42		
Produto18	44,52	44,57	Produto43	12,44	14,21
Produto19	25,67	35,74	Produto44	22,51	26,51
Produto20		52,74	Produto45		11,35
Produto21		25,50	Produto46	9,37	10,07
Produto22		27,20	Produto47	12,16	13,19
Produto23	31,72	34,97	Produto48	16,30	20,29
Produto24	97,04	123,65	Produto49		
Produto25		107,24	Produto50	22,39	23,53

Fonte: Elaboração Própria

*Dados realçados em amarelo: Menor RMSE na comparação dos resultados dos modelos.

Pode-se constatar, por meio da comparação do desempenho dos modelos abordados nas tabelas 01 e 02, que a previsão de vendas de granularidade diária é mais adequada do que a de granularidade semanal para o contexto situado. Sendo assim, mesmo com uma abordagem mais simples, o fato de trabalhar com uma abordagem diária para a previsão, já possibilita melhores resultados. A descoberta encontrada está em conformidade com as lentes teóricas apontadas por Taylor (2007) e de Dharmawardane e outros (2021). Essa constatação pode contribuir, pois diversos trabalhos na literatura de previsão de vendas e gestores adotam na prática a granularidade semanal para realizar a previsão de vendas. Portanto, pode-se

perceber que é possível reduzir a incidência de erros por meio da previsão de alta frequência (diária). Contudo, a modelagem diária pode elevar os custos computacionais, devido a necessidade de investimentos financeiros.

As tabelas 03 e 04 foram elaboradas com o propósito de comparar o desempenho preditivo dos modelos dinâmicos com o desempenho dos modelos estáticos. Os modelos utilizados para a comparação foram o ARIMA e o Holt-Winters.

Tabela 03 – Comparação Acurácia (RMSE): ARIMA dinâmico (1 passo à frente) x ARIMA estático

Produtos	ARIMA dinâmico 1 passo	ARIMA estático	Produtos	ARIMA dinâmico 1 passo	ARIMA estático
Produto1	14,80	38,71	Produto26	47,95	56,92
Produto2	59,29	205,28	Produto27	43,08	35,35
Produto3	38,16	100,70	Produto28	29,76	27,15
Produto4	51,18	107,98	Produto29	35,55	51,35
Produto5	17,97	63,32	Produto30	27,68	32,45
Produto6	25,80	45,85	Produto31	32,21	48,85
Produto7	30,04	46,11	Produto32	35,30	61,88
Produto8	38,52	41,05	Produto33	44,92	25,27
Produto9	26,36	39,22	Produto34	55,96	81,80
Produto10	190,44	62,49	Produto35	50,66	71,73
Produto11	188,04	331,11	Produto36	42,31	95,93
Produto12	177,12	262,32	Produto37	21,68	23,56
Produto13	147,25	176,02	Produto38	24,24	41,83
Produto14	37,10	74,19	Produto39	9,46	9,02
Produto15	72,81	162,36	Produto40	36,53	9,50
Produto16	45,14	129,78	Produto41	9,67	17,89
Produto17	47,81	94,59	Produto42	6,81	7,56
Produto18	45,83	74,32	Produto43	11,85	11,10
Produto19	24,70	59,88	Produto44	20,65	28,53
Produto20		33,86	Produto45	10,07	9,78
Produto21	16,35	23,10	Produto46	8,82	9,52
Produto22	24,05	46,66	Produto47	11,14	8,47
Produto23	29,49	29,45	Produto48	14,16	15,13
Produto24	96,39	64,63	Produto49	20,94	30,43
Produto25	76,56	80,24	Produto50	20,24	22,69

Fonte: Elaboração Própria

*Dados realçados em amarelo: Menor RMSE na comparação dos resultados dos modelos.

Tabela 04 – Comparação Acurácia (RMSE): Holt-Winters dinâmico (1 passo à frente) x Holt-Winters estático

Produtos	Holt-Winters andando (1 passo à frente)	Holt-Winters estático	Produtos	Holt-Winters andando (1 passo à frente)	Holt-Winters estático
Produto1	67,20	27,23	Produto26		91,99
Produto2		69,33	Produto27	43,12	103,82
Produto3	35,73	65,87	Produto28		
Produto4	55,52	97,74	Produto29	36,41	53,65
Produto5		25,78	Produto30	30,42	60,07
Produto6		54,48	Produto31	35,30	52,12
Produto7	32,13	56,12	Produto32		58,16
Produto8	40,90	60,53	Produto33	41,91	57,18
Produto9		33,05	Produto34	67,65	89,66
Produto10	191,13	202,55	Produto35	48,41	70,38
Produto11	198,84	186,21	Produto36	48,39	83,77
Produto12	196,56	184,42	Produto37	22,13	28,47
Produto13	129,29	148,37	Produto38		24,50
Produto14		37,24	Produto39	10,15	13,20
Produto15	74,70	79,42	Produto40	59,24	37,58
Produto16	47,79	53,69	Produto41	9,37	15,52
Produto17	49,08	47,13	Produto42		
Produto18	44,52	44,15	Produto43	12,44	20,27
Produto19	25,67	25,79	Produto44	22,51	27,85
Produto20			Produto45		22,20
Produto21		28,36	Produto46	9,37	19,12
Produto22		53,59	Produto47	12,16	14,11
Produto23	31,72	36,26	Produto48	16,30	20,39
Produto24	97,04	129,43	Produto49		35,73
Produto25		119,12	Produto50	22,39	31,33

Fonte: Elaboração Própria

*Dados realçados em amarelo: Menor RMSE na comparação dos resultados dos modelos.

A partir da análise dos resultados da tabela 03 e 04, pode-se notar que os modelos de previsão dinâmicos apresentam melhor desempenho preditivo do que os modelos estáticos, tanto na comparação entre os modelos ARIMA, quanto nos de Holt-Winters. Essa comparação pode auxiliar na literatura e prática, pois os modelos estáticos (de treino e teste) possibilitam a avaliação da capacidade preditiva em um horizonte de previsão mais longo. No entanto, percebe-se que mesmo que os modelos estáticos não são tão utilizados na prática, eles são encontrados em diversas literaturas. Os resultados encontrados estão alinhados com a discussão teórica de Ma e outros (2016), que indicam a utilização de modelos dinâmicos para a previsão no varejo.

As tabelas 05, 06 e 07 foram criadas com a finalidade de comparar o desempenho preditivo dos modelos ARIMA, Holt-Winters, Média elaborada pelo gestor e o TBATS e apresentar o mais assertivo para o contexto vigente.

Tabela 05 – Comparação Acurácia (RMSE): ARIMA dinâmico (1 passo à frente) x Holt-Winters dinâmico (1 passo à frente)

Produtos	ARIMA dinâmico 1 passo	Holt-Winters dinâmico 1 passo	Produtos	ARIMA dinâmico 1 passo	Holt-Winters dinâmico 1 passo
Produto1	14,80	67,20	Produto26	47,95	
Produto2	59,29		Produto27	43,08	43,12
Produto3	38,16	35,73	Produto28	29,76	
Produto4	51,18	55,52	Produto29	35,55	36,41
Produto5	17,97		Produto30	27,68	30,42
Produto6	25,80		Produto31	32,21	35,30
Produto7	30,04	32,13	Produto32	35,30	
Produto8	38,52	40,90	Produto33	44,92	41,91
Produto9	26,36		Produto34	55,96	67,65
Produto10	190,44	191,13	Produto35	50,66	48,41
Produto11	188,04	198,84	Produto36	42,31	48,39
Produto12	177,12	196,56	Produto37	21,68	22,13
Produto13	147,25	129,29	Produto38	24,24	
Produto14	37,10		Produto39	9,46	10,15
Produto15	72,81	74,70	Produto40	36,53	59,24
Produto16	45,14	47,79	Produto41	9,67	9,37
Produto17	47,81	49,08	Produto42	6,81	
Produto18	45,83	44,52	Produto43	11,85	12,44
Produto19	24,70	25,67	Produto44	20,65	22,51
Produto20			Produto45	10,07	
Produto21	16,35		Produto46	8,82	9,37
Produto22	24,05		Produto47	11,14	12,16
Produto23	29,49	31,72	Produto48	14,16	16,30
Produto24	96,39	97,04	Produto49	20,94	
Produto25	76,56		Produto50	20,24	22,39

Fonte: Elaboração Própria

*Dados realçados em amarelo: Menor RMSE na comparação dos resultados dos modelos.

A tabela 05 foi elaborada com a finalidade de comparar o desempenho preditivo dos modelos dinâmicos ARIMA e Holt-Winters 1 passo à frente. Pode-se notar que o ARIMA é capaz de gerar resultados mais assertivos e por esse motivo, foi o modelo selecionado para fins de comparação com a técnica que o gestor do supermercado adota para realizar a sua previsão de vendas.

Tabela 06 – Comparação Acurácia (RMSE): ARIMA dinâmico (1 passo) x Média do Gestor

Produtos	ARIMA dinâmico 1 passo	Média do Gestor	(ARIMA dinâmico 1 passo) / (Média do Gestor)	Produtos	ARIMA dinâmico 1 passo	Média do Gestor	(ARIMA dinâmico 1 passo) / (Média do Gestor)
Produto1	14,80	15,99	3,23	Produto26	47,95	52,55	0,93
Produto2	59,29	61,12	3,11	Produto27	43,08	64,66	0,84
Produto3	38,16	39,48	2,22	Produto28	29,76	29,26	1,00
Produto4	51,18	66,84	1,36	Produto29	35,55	40,04	1,03
Produto5	17,97	22,36	2,79	Produto30	27,68	30,75	1,26
Produto6	25,80	37,45	1,15	Produto31	32,21	38,10	0,93
Produto7	30,04	36,77	1,32	Produto32	35,30	37,24	1,06
Produto8	38,52	59,77	0,99	Produto33	44,92	45,14	1,01
Produto9	26,36	32,30	1,35	Produto34	55,96	67,18	0,98
Produto10	190,44	199,21	0,31	Produto35	50,66	54,29	1,02
Produto11	188,04	243,92	1,10	Produto36	42,31	63,13	0,91
Produto12	177,12	208,08	1,00	Produto37	21,68	22,99	0,98
Produto13	147,25	168,17	0,92	Produto38	24,24	24,26	1,28
Produto14	37,10	47,60	1,34	Produto39	9,46	9,95	0,98
Produto15	72,81	85,69	2,27	Produto40	36,53	36,67	1,00
Produto16	45,14	50,05	2,52	Produto41	9,67	13,20	0,95
Produto17	47,81	68,31	1,34	Produto42	6,81	7,05	0,99
Produto18	45,83	50,39	1,53	Produto43	11,85	14,33	0,90
Produto19	24,70	30,56	2,03	Produto44	20,65	22,38	1,00
Produto20				Produto45	10,07	11,24	0,94
Produto21	16,35	18,30	0,93	Produto46	8,82	9,14	1,00
Produto22	24,05	30,79	0,81	Produto47	11,14	11,82	0,97
Produto23	29,49	29,79	0,94	Produto48	14,16	16,41	0,92
Produto24	96,39	102,96	0,94	Produto49	20,94	22,43	0,97
Produto25	76,56	80,85	1,16	Produto50	20,24	19,92	1,01
TOTAL							1062,54

Fonte: Elaboração Própria

*Dados realçados em amarelo: Menor RMSE na comparação dos resultados dos modelos.

A partir da análise dos resultados da tabela 06, quando se efetuou uma comparação do modelo selecionado – o ARIMA dinâmico (1 passo à frente) com a média adotada pelo gestor, notou-se que o ARIMA consegue compreender melhor o comportamento das vendas, possibilitando melhor desempenho preditivo. Diversas pesquisas utilizam o ARIMA para a realização de estudos com séries temporais para o varejo, inclusive no setor supermercadista. O resultado encontrado mostra que o

gestor do supermercado poderá mensurar as suas vendas de maneira mais assertiva caso opte por adotar o ARIMA.

Tabela 07 – Comparação Acurácia (RMSE): ARIMA dinâmico (1 passo) x TBATS

Produtos	ARIMA dinâmico 1 passo	TBATS	Diferença (TBATS – ARIMA)	Produtos	ARIMA dinâmico 1 passo	TBATS	Diferença (TBATS – ARIMA)
Produto1	14,80	14,59	-0,21	Produto26	47,95	48,53	0,58
Produto2	59,29	54,26	-5,03	Produto27	43,08	44,91	1,83
Produto3	38,16	34,30	-3,86	Produto28	29,76		
Produto4	51,18	46,34	-4,84	Produto29	35,55	32,32	-3,23
Produto5	17,97	17,84	-0,13	Produto30	27,68	27,03	-0,65
Produto6	25,80	25,59	-0,21	Produto31	32,21	33,61	1,4
Produto7	30,04	28,88	-1,16	Produto32	35,30	34,06	-1,24
Produto8	38,52	44,99	6,47	Produto33	44,92	38,11	-6,81
Produto9	26,36	26,53	0,17	Produto34	55,96	57,72	1,76
Produto10	190,44	209,08	18,64	Produto35	50,66	47,36	-3,3
Produto11	188,04	194,29	6,25	Produto36	42,31	47,88	5,57
Produto12	177,12	175,16	-1,96	Produto37	21,68	21,24	-0,44
Produto13	147,25	109,59	-37,66	Produto38	24,24	22,61	-1,63
Produto14	37,10	37,30	0,2	Produto39	9,46	9,41	-0,05
Produto15	72,81	72,86	0,05	Produto40	36,53	36,48	-0,05
Produto16	45,14	46,17	1,03	Produto41	9,67	9,95	0,28
Produto17	47,81	47,22	-0,59	Produto42	6,81		
Produto18	45,83	38,39	-7,44	Produto43	11,85	11,87	0,02
Produto19	24,70	23,68	-1,02	Produto44	20,65	21,16	0,51
Produto20				Produto45	10,07	9,48	-0,59
Produto21	16,35	17,42	1,07	Produto46	8,82	8,81	-0,01
Produto22	24,05	23,59	-0,46	Produto47	11,14	10,92	-0,22
Produto23	29,49	27,18	-2,31	Produto48	14,16	13,60	-0,56
Produto24	96,39	94,13	-2,26	Produto49	20,94		
Produto25	76,56	66,08	-10,48	Produto50	20,24	21,13	0,89
TOTAL							-51,68

Fonte: Elaboração Própria

*Dados realçados em amarelo: Menor RMSE na comparação dos resultados dos modelos.

A tabela 07 foi elaborada com a finalidade de comparar o desempenho preditivo do modelo dinâmico ARIMA (1 passo à frente) com o desempenho do TBATS. Notou-se por meio das análises dos resultados da tabela que o TBATS proporcionou um desempenho preditivo semelhante ao ARIMA dinâmico (1 passo à frente) para a maioria dos produtos. Além disso, por meio dos resultados obtidos não foi possível confirmar a hipótese de existência de padrões sazonalidade múltipla no

comportamento das séries temporais estudadas, visto que o desempenho do TBATS não foi tão preponderante quanto comparado com o ARIMA dinâmico (1 passo à frente), apesar de ter sido melhor para vinte e nove produtos. Para avaliar a capacidade preditiva, foi feita uma diferença entre o RMSE de ambos os modelos e computou-se o somatório das diferenças. Foi possível notar que o TBATS apresentou o menor valor de RMSE, em média. Contudo, pode-se observar que tanto o modelo ARIMA dinâmico quanto TBATS possibilitaram resultados preditivos assertivos, e por tanto, sugere-se a elaboração de uma sistemática que desenvolva ambas as modelagens, e que seja capaz de selecionar o melhor modelo para o conjunto de dados de treino e teste.

Tabela 08 – TREINO, VALIDAÇÃO E TESTE x TBATS

A tabela 08 foi criada com a finalidade de comparar o desempenho preditivo de uma modelagem feita, a partir da separação do conjunto de dados estabelecidos para treinamento e validação. Sendo assim, os dados de teste foram divididos em duas etapas. Tal prática pode ser relevante, pois com um conjunto de validação é possível realizar vários experimentos no modelo e testá-lo.

Produtos	TREINO, VALIDAÇÃO E TESTE	TBATS	Produtos	TREINO, VALIDAÇÃO E TESTE	TBATS
Produto1	23,34	14,59	Produto26	69,68	48,53
Produto2	53,06	54,26	Produto27	78,95	44,91
Produto3	37,77	34,30	Produto28	42,01	
Produto4	94,71	46,34	Produto29	44,01	32,32
Produto5	34,96	17,84	Produto30	33,18	27,03
Produto6	66,01	25,59	Produto31	41,40	33,61
Produto7	41,50	28,88	Produto32	63,16	34,06
Produto8	59,03	44,99	Produto33	65,68	38,11
Produto9	224,90	26,53	Produto34	98,49	57,72
Produto10	1123,31	209,08	Produto35	49,21	47,36
Produto11	341,34	194,29	Produto36	66,80	47,88
Produto12	217,95	175,16	Produto37	5489,34	21,24
Produto13	78,64	109,59	Produto38	2376,58	22,61
Produto14	54,11	37,30	Produto39	14,76	9,41
Produto15	113,23	72,86	Produto40	43,53	36,48
Produto16	101,82	46,17	Produto41	23,36	9,95
Produto17	93,56	47,22	Produto42	18,08	
Produto18	80,15	38,39	Produto43	23,75	11,87
Produto19	44,62	23,68	Produto44	22,83	21,16

Produto20			Produto45	12,59	9,48
Produto21	28,03	17,42	Produto46	12,82	8,81
Produto22	107,65	23,59	Produto47		10,92
Produto23	30,51	27,18	Produto48		13,60
Produto24	170,36	94,13	Produto49		
Produto25	86,77	66,08	Produto50		21,13
TOTAL					

Fonte: Elaboração Própria

*Dados realçados em amarelo: Menor RMSE na comparação dos resultados dos modelos.

A partir da análise dos resultados da tabela 08, notou-se que mesmo dividindo o conjunto de dados em treinamento e validação, para posteriormente efetuar a previsão de vendas, o resultado oriundo da modelagem foi inferior ao modelo TBATS dinâmico. No entanto, a abordagem de treinamento, validação e teste tem se destacado pelo fato de contribuir para a realização de vários experimentos no conjunto de dados do modelo, para finalmente testá-lo.

5 CONSIDERAÇÕES FINAIS

No varejo supermercadista considerar a variação da demanda em alta frequência (por exemplo: sazonalidade anual, semanal e diária) sem a introdução de decisões manuais na elaboração do modelo de previsão é um desafio. Para investigar os limites da prática atual e adotar tecnologias já desenvolvidas em outros contextos, explorou-se um modelo de previsão robusto para a demanda de eletricidade, denominado TBATS (LIVERA et al., 2011).

Este estudo utilizou dados reais para um trabalho com possibilidade de aplicação prática para o varejo supermercadista, buscando encontrar modelos de previsão de vendas com a lógica de alta frequência (diária) e compará-los com os semanais (vigentes na maioria dos trabalhos da literatura), para verificar a possibilidade de melhorar os resultados preditivos neste contexto.

Como descoberta, apontou-se que foi possível obter maior precisão na previsão de vendas para o contexto situado ao mudar o foco da previsão semanal para a granularidade diária, de alta frequência – (fato que foi observado em: TAYLOR, 2007, EHRENTAHAL et al., 2014, FILDES et al., 2019, HUBER; STUCKENSCHMIDT, 2020, DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021, HOELTGEBBAUM et al., 2021). Mesmo em modelos mais simples, como o Holt-Winters e o ARIMA, o desempenho da previsão diária foi amplamente superior a previsão semanal. Portanto, a previsão de vendas diária mostra-se mais adequada em detrimento da semanal, visto que a previsão do varejo supermercadista pode ser vista como de curto prazo e o intervalo de uma semana, como médio prazo.

Este estudo questiona uma prática adotada para a modelagem da previsão de vendas no varejo supermercadista, a adoção de modelos estáticos em detrimento de dinâmicos, algo que ainda tem sido feito na literatura e prática. Apesar dos modelos estáticos serem úteis para a avaliação preditiva em horizontes de previsões mais longos, o desempenho dos modelos dinâmicos foi bastante superior em relação ao estático – o que se esperava, conforme relata (MA et al., 2016).

Notou-se também que o desempenho do modelo TBATS foi semelhante ao ARIMA dinâmico. Portanto, pode-se notar que ambas as abordagens são capazes de contribuir para a maior precisão na modelagem de diversos produtos do contexto

abordado. E por esse motivo, não foi possível levantar qual dos dois modelos é melhor para determinado conjunto de dados. Sendo assim, sugere-se que sejam feitas ambas as modelagens, de modo que uma sistemática automatizada seja capaz de selecionar o melhor modelo para o conjunto de dados de treino e teste. Apesar do TBATS lidar com diversos padrões de comportamentos na modelagem de séries temporais, por exemplo: os de sazonalidade complexa (anual, mensal e diária), seu desempenho não foi tão preponderante quando comparado ao do ARIMA. Fato que pode ser explicado em função das variáveis causais que interferem na modelagem (DHARMAWARDANE; SILLANPÄÄ; HOLMSTRÖM, 2021).

Enquanto na modelagem o TBATS inclui tendência e sazonalidade, o ARIMA os exclui da análise porque a tendência e a sazonalidade são consideradas termos de erro. O estudo de Choi (2016) indica ambos os modelos possibilitarem resultados de alta precisão de estimativa e previsão.

Contudo, este estudo apresenta como limitação o fato do pesquisador trabalhar com um grupo de produtos do supermercado, sem deter o conhecimento de quais são, especialmente agrupados. Entende-se também que os resultados da presente pesquisa podem ser diferentes em outros contextos, como por exemplo em lojas menores ou com produtos diferentes.

Apointa-se como sugestões para trabalhos futuros que os estudos discutam a aplicação do TBATS para os setores do varejo, com a finalidade de elaborar a previsão de vendas e desenvolver comparações com outros modelos de previsões de vendas, de séries temporais e modelos causais.

6 REFERÊNCIAS

AGUINIS, H.; HILL, N. S.; BAILEY, J. R. Best practices in data collection and preparation: Recommendations for reviewers, editors, and authors. **Organizational Research Methods**, p. 1094428119836485, 2019.

AMALNICK, M. S. et al. An intelligent algorithm for final product demand forecasting in pharmaceutical units. **International Journal of System Assurance Engineering and Management**, p. 1-13, 2019.

AMINE, A.; CADENAT, S. Efficient retailer assortment: a consumer choice evaluation perspective. **International Journal of Retail & Distribution Management**, 2003.

ARUNRAJ, N. S.; AHRENS, D. A hybrid seasonal autoregressive integrated moving average and quantile regression for daily food sales forecasting. **International Journal of Production Economics**, v. 170, p. 321–335, 2015.

BIANCHI, F. M. et al. Properties and training in recurrent neural networks. **Recurrent Neural Networks for Short-Term Load Forecasting**. Springer, 2017.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis: forecasting and control**. 4. ed. Hoboken, N.J.: John Wiley & Sons, 2008.

CHAMBERS, J.C.; MULLICK, S.K; SMITH, D.D. “How to choose the right forecasting technique”, **Harvard Business Review**, v. 45, p. 45-71, 1971.

CHAND, S.; HSU, V. N.; SETHI, S. Forecast, solution, and rolling horizons in operations management problems: A classified bibliography. **Manufacturing & Service Operations Management**, v. 4, n. 1, p. 25-43, 2002.

CHOI, J. et al. Evaluation of Estimation and Forecast Accuracy on Retail Meat Prices by Seasonal Time-Series Models. **Korean journal of food marketing economics**, 2016.

CORSTEN, D.; GRUEN, T. Desperately seeking shelf availability: an examination of the extent, the causes, and the efforts to address retail out-of-stocks. **International Journal of Retail & Distribution Management**, 2003.

DHARMAWARDANE, C.; SILLANPÄÄ, V.; HOLMSTRÖM, J. High-frequency forecasting for grocery point-of-sales: intervention in practice and theoretical

implications for operational design. **Operations Management Research**, v. 14, n. 1, p. 38-60, 2021.

DUDEK, G. Short-term load forecasting using random forests. **Intelligent Systems**. Springer, 2015

EHRENTHAL, J. C. F.; HONHON, D.; VAN WOENSEL, T. Demand seasonality in retail inventory management. **European Journal of Operational Research**, v. 238, n. 2, p. 527-539, 2014.

FERNIE, J.; GRANT, D. B. On-shelf availability: the case of a UK grocery retailer. **The International Journal of Logistics Management**, 2008.

FERREIRA, P. G. C. et al. **Análise de Séries Temporais em R: curso introdutório**, Rio de Janeiro: Elsevier, 2018.

FILDES, R.; HIBON, M.; MAKRIDAKIS, S.; MEADE, N. Generalising about univariate forecasting methods: further empirical evidence. **International journal of Forecasting**, v. 14, n. 3, p. 339-358, 1998.

FILDES, R.; MA, S.; KOLASSA, S. Retail forecasting: Research and practice. **International Journal of Forecasting**, 2019.

FISHER, M.; RAMAN, A. Using data and big data in retailing. **Production and Operations Management**, v. 27, n. 9, p. 1665-1669, 2018.

GARDNER JR, E. S. Exponential smoothing: The state of the art—Part II. **International journal of forecasting**, v. 22, n. 4, p. 637-666, 2006.

GE, D. et al. Retail supply chain management: a review of theories and practices. **Journal of Data, Information and Management**, v. 1, n. 1-2, p. 45-64, 2019.

GIRARD, A. et al. Gaussian process priors with uncertain inputs application to multiple-step ahead time series forecasting. **Advances in neural information processing systems**, 2003.

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.

HOFMANN, E.; RUTSCHMANN, E. Big data analytics and demand forecasting in supply chains: a conceptual analysis. **The international journal of logistics management**, 2018.

HUANG, J. et al. Improvement of inventory control and forecast according to activity-based classifications: T company as an example. **AIP Conference Proceedings**. AIP Publishing LLC, 2017.

HUBER, J., STUCKENSCHMIDT, H. Daily retail demand forecasting using machine learning with emphasis on calendric special days. **International Journal of Forecasting**, 2020.

HYNDMAN R.; ATHANASOPOULOS G.; BERGMEIR C.; CACERES G.; CHHAY L.; O'HARA-WILD M.; PETROPOULOS F.; RAZBASH S.; WANG E.; YASMEEN G. (2021). **Forecast: Forecasting functions for time series and linear models**. R package version 8.15, link:<<https://pkg.robjhyndman.com/forecast/>>.

INGRAM, T. N. Future themes in sales and sales management: complexity, collaboration, and accountability. **Journal of marketing theory and practice**, 2004.

KARAN, M. et al. The impact of training data tailoring on demand forecasting models in retail. **2014 37th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)**. IEEE,p. 1473-1478, 2014.

KOEHLER, A. B.; MURPHREE, E. S. A comparison of results from state space forecasting with forecasts from the Makridakis competition. **International Journal of Forecasting**, v. 4, n. 1, p. 45-55, 1988.

KUSIAK, A.; ZHENG, H.; SONG, Z. Short-term prediction of wind farm power: A data mining approach. **IEEE Transactions on energy conversion**, v. 24, n. 1, p. 125-136, 2009.

LIN, K.; ER-RAQABI, A. Machine Learning @Carrefour: tackling promotional product shortage. **Horizons Carrefour**. 30, abr. 2021. Disponível em: <<https://horizons.carrefour.com/data/data-driven-forecasting-to-avoid-product-shortage>>. Acesso em 11, nov. 2021.

MA, S.; FILDES, R.; HUANG, T. Demand forecasting with high dimensional data: The case of SKU retail sales forecasting with intra-and inter-category promotional

information. **European Journal of Operational Research**, v. 249, n. 1, p. 245-257, 2016.

MARTELLI, L. L.; DANDARO, F. Planejamento e controle de estoque nas organizações. **Revista Gestão Industrial**, v. 11, n. 02, p. 170-185, 2015.

MOU, S.; ROBB, D. J.; DEHORATIUS, N. Retail store operations: Literature review and research directions. **European Journal of Operational Research**, v. 265, n. 2, p. 399-422, 2018.

NUNES, V. T. **Aplicação de técnicas de previsão de demanda e gestão de estoques em uma empresa misturadora de fertilizantes**. Dissertação. (Dissertação em engenharia de produção) – UFRGS, Porto Alegre, 2019.

PFAFF, B. Analysis of Integrated and Cointegrated Time Series with R. Second Edition. Springer, New York, 2008.

RAMOS, P.; SANTOS, N.; REBELO, R. Performance of state space and ARIMA models for consumer retail sales forecasting. **Robotics and computer-integrated manufacturing**, v. 34, p. 151-163, 2015.

RITZMAN, L. P.; KRAJEWSKI, L. J. **Administração da produção e operações**. Prentice Hall, 2009.

SANDERS, N. R.; GRAMAN, G. A. Quantifying cost of forecast errors: A case study of the warehouse environment. **Omega**, p. 116-125, 2009.

SILVA, L. A.; PERES, S. M.; BOSCARIOLI, C. **Introdução à Mineração de dados com aplicação em R**. 1. ed. Rio de Janeiro: Elsevier, 2016.

TAYLOR, J. W. Forecasting daily supermarket sales using exponentially weighted quantile regression. **European Journal of Operational Research**, v. 178, n. 1, p. 154-167, 2007.

TEAM, R. Core et al. R: A language and environment for statistical computing. 2013.

WINTERS, P. R. Forecasting sales by exponentially weighted moving averages. **Management science**, v. 6, n. 3, p. 324-342, 1960.

ZHENG, Z.; SU, D. Short-term traffic volume forecasting: A k-nearest neighbor approach enhanced by constrained linearly sewing principle componente algorithm. **Transportation Research Part C: Emerging Technologies**, v. 43, p. 143-157, 2014.

APÊNDICE A – SCRIPT

```
#Holt-Winters andando
```

```
library(forecast)
c=3
n=52
previsoes <-list()
resultado <- c()
prev=c()
prevs1=c()

while(c<(3+n))
{
  a=1
  b=60
  corte=ts(base[a:b,],freq=6)
  corte=corte[,c]
  prevs = c()
  while(b<=(NROW(base)))
  {
    corte=ts(base[a:b,],freq=6)
    corte=corte[,c]
    hw=HoltWinters(corte)
    prev=print(forecast(hw,1))
    previsoes <- prev$`Point Forecast`
    prevs<-c(prevs,previsoes)
    a=a+1
    b=b+1
    print(b)
    print(length(prevs))
    print(c)
  }
  paste("ciclo",c)
  # prevs=prevs[1:(NROW(base)-60)]
  prevs1$new <- prevs
  names(prevs1)[names(prevs1) == "new"] <- paste0("P_",colnames(base[,c]))

  c <- c + 1
}
View(as.data.frame(prevs1))
```

#VETORES DE PREVISÃO

vna=rep(NA,60)

p1=c(vna,prevs1\$`P_Produto 6D37067`[1:424])
 p2=c(vna,prevs1\$`P_Produto 8310266`[1:424])
 p3=c(vna,prevs1\$`P_Produto 8D50B89`[1:424])
 p4=c(vna,prevs1\$`P_Produto 9949CC2`[1:424])
 p5=c(vna,prevs1\$`P_Produto 7ACD128`[1:424])
 p6=c(vna,prevs1\$`P_Produto AC707E0`[1:424])
 p7=c(vna,prevs1\$`P_Produto B4A1045`[1:424])
 p8=c(vna,prevs1\$`P_Produto A83CB60`[1:424])
 p9=c(vna,prevs1\$`P_Produto 5B21881`[1:424])
 p10=c(vna,prevs1\$`P_Produto 8AAFAC6`[1:424])
 p11=c(vna,prevs1\$`P_Produto 83FE785`[1:424])
 p12=c(vna,prevs1\$`P_Produto AAD8904`[1:424])
 p13=c(vna,prevs1\$`P_Produto BDC55E6`[1:424])
 p14=c(vna,prevs1\$`P_Produto 4F2E5A7`[1:424])
 p15=c(vna,prevs1\$`P_Produto E8084`[1:424])
 p16=c(vna,prevs1\$`P_Produto D8727`[1:424])
 p17=c(vna,prevs1\$`P_Produto 67B603`[1:424])
 p18=c(vna,prevs1\$`P_Produto 5B1BD43`[1:424])
 p19=c(vna,prevs1\$`P_Produto 55C5E44`[1:424])
 p20=c(vna,prevs1\$`P_Produto 5B1CB08`[1:424])
 p21=c(vna,prevs1\$`P_Produto 1086A5`[1:424])
 p22=c(vna,prevs1\$`P_Produto 50DF202`[1:424])
 p23=c(vna,prevs1\$`P_Produto E2909`[1:424])
 p24=c(vna,prevs1\$`P_Produto EE849`[1:424])
 p25=c(vna,prevs1\$`P_Produto 5DC6186`[1:424])
 p26=c(vna,prevs1\$`P_Produto C7102`[1:424])
 p27=c(vna,prevs1\$`P_Produto B447AE7`[1:424])
 #p28
 p29=c(vna,prevs1\$`P_Produto 625345`[1:424])
 p30=c(vna,prevs1\$`P_Produto E179E9`[1:424])
 p31=c(vna,prevs1\$`P_Produto A8B31C1`[1:424])
 p32=c(vna,prevs1\$`P_Produto 64253A9`[1:424])
 p33=c(vna,prevs1\$`P_Produto 6CFA347`[1:424])
 p34=c(vna,prevs1\$`P_Produto B6D8980`[1:424])
 p35=c(vna,prevs1\$`P_Produto 509C223`[1:424])
 p36=c(vna,prevs1\$`P_Produto 93EAC20`[1:424])
 p37=c(vna,prevs1\$`P_Produto AC838E8`[1:424])
 p38=c(vna,prevs1\$`P_Produto 4C52341`[1:424])
 p39=c(vna,prevs1\$`P_Produto 4C80106`[1:424])
 p40=c(vna,prevs1\$`P_Produto 4C88120`[1:424])
 p41=c(vna,prevs1\$`P_Produto 4D78B26`[1:424])
 #p42=
 p43=c(vna,prevs1\$`P_Produto 4EC8F20`[1:424])
 p44=c(vna,prevs1\$`P_Produto 50DAA27`[1:424])
 p45=c(vna,prevs1\$`P_Produto 5B62560`[1:424])
 p46=c(vna,prevs1\$`P_Produto 5DBBFA4`[1:424])
 p47=c(vna,prevs1\$`P_Produto 6D37606`[1:424])

p48=c(vna,prevs1\$`P_Produto 7BC71C1`[1:424])
 #p49=
 p50=c(vna,prevs1\$`P_Produto 9A2E0A0`[1:424])

#rmse

c=3

a1=accuracy(ts(base[c][250:NROW(base),1],freq=6),p1[250:NROW(base)])
 a2=accuracy(ts(base[c+1][250:NROW(base),1],freq=6),p2[250:NROW(base)])
 a3=accuracy(ts(base[c+2][250:NROW(base),1],freq=6),p3[250:NROW(base)])
 a4=accuracy(ts(base[c+3][250:NROW(base),1],freq=6),p4[250:NROW(base)])
 a5=accuracy(ts(base[c+4][250:NROW(base),1],freq=6),p5[250:NROW(base)])
 a6=accuracy(ts(base[c+5][250:NROW(base),1],freq=6),p6[250:NROW(base)])
 a7=accuracy(ts(base[c+6][250:NROW(base),1],freq=6),p7[250:NROW(base)])
 a8=accuracy(ts(base[c+7][250:NROW(base),1],freq=6),p8[250:NROW(base)])
 a9=accuracy(ts(base[c+8][250:NROW(base),1],freq=6),p9[250:NROW(base)])
 a10=accuracy(ts(base[c+9][250:NROW(base),1],freq=6),p10[250:NROW(base)])
 a11=accuracy(ts(base[c+10][250:NROW(base),1],freq=6),p11[250:NROW(base)])
 a12=accuracy(ts(base[c+11][250:NROW(base),1],freq=6),p12[250:NROW(base)])
 a13=accuracy(ts(base[c+12][250:NROW(base),1],freq=6),p13[250:NROW(base)])
 a14=accuracy(ts(base[c+13][250:NROW(base),1],freq=6),p14[250:NROW(base)])
 a15=accuracy(ts(base[c+14][250:NROW(base),1],freq=6),p15[250:NROW(base)])
 a16=accuracy(ts(base[c+15][250:NROW(base),1],freq=6),p16[250:NROW(base)])
 a17=accuracy(ts(base[c+16][250:NROW(base),1],freq=6),p17[250:NROW(base)])
 a18=accuracy(ts(base[c+17][250:NROW(base),1],freq=6),p18[250:NROW(base)])
 a19=accuracy(ts(base[c+18][250:NROW(base),1],freq=6),p19[250:NROW(base)])
 a20=accuracy(ts(base[c+19][250:NROW(base),1],freq=6),p20[250:NROW(base)])
 a21=accuracy(ts(base[c+20][250:NROW(base),1],freq=6),p21[250:NROW(base)])
 a22=accuracy(ts(base[c+21][250:NROW(base),1],freq=6),p22[250:NROW(base)])
 a23=accuracy(ts(base[c+22][250:NROW(base),1],freq=6),p23[250:NROW(base)])
 a24=accuracy(ts(base[c+23][250:NROW(base),1],freq=6),p24[250:NROW(base)])
 a25=accuracy(ts(base[c+24][250:NROW(base),1],freq=6),p25[250:NROW(base)])
 a26=accuracy(ts(base[c+25][250:NROW(base),1],freq=6),p26[250:NROW(base)])
 a27=accuracy(ts(base[c+26][250:NROW(base),1],freq=6),p27[250:NROW(base)])
 #a28=
 a29=accuracy(ts(base[c+28][250:NROW(base),1],freq=6),p29[250:NROW(base)])
 a30=accuracy(ts(base[c+29][250:NROW(base),1],freq=6),p30[250:NROW(base)])
 a31=accuracy(ts(base[c+30][250:NROW(base),1],freq=6),p31[250:NROW(base)])
 a32=accuracy(ts(base[c+31][250:NROW(base),1],freq=6),p32[250:NROW(base)])
 a33=accuracy(ts(base[c+32][250:NROW(base),1],freq=6),p33[250:NROW(base)])
 a34=accuracy(ts(base[c+33][250:NROW(base),1],freq=6),p34[250:NROW(base)])
 a35=accuracy(ts(base[c+34][250:NROW(base),1],freq=6),p35[250:NROW(base)])
 a36=accuracy(ts(base[c+35][250:NROW(base),1],freq=6),p36[250:NROW(base)])
 a37=accuracy(ts(base[c+36][250:NROW(base),1],freq=6),p37[250:NROW(base)])
 a38=accuracy(ts(base[c+37][250:NROW(base),1],freq=6),p38[250:NROW(base)])
 a39=accuracy(ts(base[c+38][250:NROW(base),1],freq=6),p39[250:NROW(base)])
 a40=accuracy(ts(base[c+39][250:NROW(base),1],freq=6),p40[250:NROW(base)])
 a41=accuracy(ts(base[c+40][250:NROW(base),1],freq=6),p41[250:NROW(base)])
 #a42=
 a43=accuracy(ts(base[c+42][250:NROW(base),1],freq=6),p43[250:NROW(base)])
 a44=accuracy(ts(base[c+43][250:NROW(base),1],freq=6),p44[250:NROW(base)])

a45=accuracy(ts(base[c+44][250:NROW(base),1],freq=6),p45[250:NROW(base)])
a46=accuracy(ts(base[c+45][250:NROW(base),1],freq=6),p46[250:NROW(base)])
a47=accuracy(ts(base[c+46][250:NROW(base),1],freq=6),p47[250:NROW(base)])
a48=accuracy(ts(base[c+47][250:NROW(base),1],freq=6),p48[250:NROW(base)])
#a49=
a50=accuracy(ts(base[c+49][250:NROW(base),1],freq=6),p50[250:NROW(base)])
a1
a2
a3
a4
a5
a6
a7
a8
a9
a10
a11
a12
a13
a14
a15
a16
a17
a18
a19
a20
a21
a22
a23
a24
a25
a26
a27
a28
a29
a30
a31
a32
a33
a34
a35
a36
a37
a38
a39
a40
a41
a42
a43
a44

```
a45
a46
a47
a48
a49
a50
```

```
# ARIMA andando
```

```
library(forecast)
c=3
n=52
previsoes <-list()
resultado <- c()
prev=c()
prevs1=c()

while(c<(3+n))
{
  a=1
  b=60
  corte=ts(base[a:b,],freq=6)
  corte=corte[,c]
  prevs = c()
  while(b<=(NROW(base)))
  {
    corte=ts(base[a:b,],freq=6)
    corte=corte[,c]
    arima1=auto.arima(corte)
    prev=print(forecast(arima1,1))
    previsoes <- prev$`Point Forecast`
    prevs<-c(prevs,previsoes)
    a=a+1
    b=b+1
    print(b)
    print(length(prevs))
    print(c)
  }
  paste("ciclo",c)
  # prevs=prevs[1:(NROW(base)-60)
  prevs1$new <- prevs
  names(prevs1)[names(prevs1) == "new"] <- paste0("P_",colnames(base[,c]))

  c <- c + 1
}
```

```
View(as.data.frame(prevs1))
```

```
#VETORES DE PREVISÃO
```

```
vna=rep(NA,60)
p1=c(vna,prevs1$`P_Produto 6D37067`[1:424])
p2=c(vna,prevs1$`P_Produto 8310266`[1:424])
p3=c(vna,prevs1$`P_Produto 8D50B89`[1:424])
p4=c(vna,prevs1$`P_Produto 9949CC2`[1:424])
p5=c(vna,prevs1$`P_Produto 7ACD128`[1:424])
p6=c(vna,prevs1$`P_Produto AC707E0`[1:424])
p7=c(vna,prevs1$`P_Produto B4A1045`[1:424])
p8=c(vna,prevs1$`P_Produto A83CB60`[1:424])
p9=c(vna,prevs1$`P_Produto 5B21881`[1:424])
p10=c(vna,prevs1$`P_Produto 8AAFAC6`[1:424])
p11=c(vna,prevs1$`P_Produto 83FE785`[1:424])
p12=c(vna,prevs1$`P_Produto AAD8904`[1:424])
p13=c(vna,prevs1$`P_Produto BDC55E6`[1:424])
p14=c(vna,prevs1$`P_Produto 4F2E5A7`[1:424])
p15=c(vna,prevs1$`P_Produto E8084`[1:424])
p16=c(vna,prevs1$`P_Produto D8727`[1:424])
p17=c(vna,prevs1$`P_Produto 67B603`[1:424])
p18=c(vna,prevs1$`P_Produto 5B1BD43`[1:424])
p19=c(vna,prevs1$`P_Produto 55C5E44`[1:424])
p20=c(vna,prevs1$`P_Produto 5B1CB08`[1:424])
p21=c(vna,prevs1$`P_Produto 1086A5`[1:424])
p22=c(vna,prevs1$`P_Produto 50DF202`[1:424])
p23=c(vna,prevs1$`P_Produto E2909`[1:424])
p24=c(vna,prevs1$`P_Produto EE849`[1:424])
p25=c(vna,prevs1$`P_Produto 5DC6186`[1:424])
p26=c(vna,prevs1$`P_Produto C7102`[1:424])
p27=c(vna,prevs1$`P_Produto B447AE7`[1:424])
p28=c(vna,prevs1$`P_Produto 9362DC2`[1:424])
p29=c(vna,prevs1$`P_Produto 625345`[1:424])
p30=c(vna,prevs1$`P_Produto E179E9`[1:424])
p31=c(vna,prevs1$`P_Produto A8B31C1`[1:424])
p32=c(vna,prevs1$`P_Produto 64253A9`[1:424])
p33=c(vna,prevs1$`P_Produto 6CFA347`[1:424])
p34=c(vna,prevs1$`P_Produto B6D8980`[1:424])
p35=c(vna,prevs1$`P_Produto 509C223`[1:424])
p36=c(vna,prevs1$`P_Produto 93EAC20`[1:424])
p37=c(vna,prevs1$`P_Produto AC838E8`[1:424])
p38=c(vna,prevs1$`P_Produto 4C52341`[1:424])
p39=c(vna,prevs1$`P_Produto 4C80106`[1:424])
p40=c(vna,prevs1$`P_Produto 4C88120`[1:424])
p41=c(vna,prevs1$`P_Produto 4D78B26`[1:424])
p42=c(vna,prevs1$`P_Produto 4DF2564`[1:424])
p43=c(vna,prevs1$`P_Produto 4EC8F20`[1:424])
p44=c(vna,prevs1$`P_Produto 50DAA27`[1:424])
p45=c(vna,prevs1$`P_Produto 5B62560`[1:424])
p46=c(vna,prevs1$`P_Produto 5DBBFA4`[1:424])
p47=c(vna,prevs1$`P_Produto 6D37606`[1:424])
p48=c(vna,prevs1$`P_Produto 7BC71C1`[1:424])
p49=c(vna,prevs1$`P_Produto 8AC5007`[1:424])
```

p50=c(vna,prevs1\$`P_Produto 9A2E0A0`[1:424])

#rmse

c=3

a1=accuracy(ts(base[c][250:NROW(base),1],freq=6),p1[250:NROW(base)])
a2=accuracy(ts(base[c+1][250:NROW(base),1],freq=6),p2[250:NROW(base)])
a3=accuracy(ts(base[c+2][250:NROW(base),1],freq=6),p3[250:NROW(base)])
a4=accuracy(ts(base[c+3][250:NROW(base),1],freq=6),p4[250:NROW(base)])
a5=accuracy(ts(base[c+4][250:NROW(base),1],freq=6),p5[250:NROW(base)])
a6=accuracy(ts(base[c+5][250:NROW(base),1],freq=6),p6[250:NROW(base)])
a7=accuracy(ts(base[c+6][250:NROW(base),1],freq=6),p7[250:NROW(base)])
a8=accuracy(ts(base[c+7][250:NROW(base),1],freq=6),p8[250:NROW(base)])
a9=accuracy(ts(base[c+8][250:NROW(base),1],freq=6),p9[250:NROW(base)])
a10=accuracy(ts(base[c+9][250:NROW(base),1],freq=6),p10[250:NROW(base)])
a11=accuracy(ts(base[c+10][250:NROW(base),1],freq=6),p11[250:NROW(base)])
a12=accuracy(ts(base[c+11][250:NROW(base),1],freq=6),p12[250:NROW(base)])
a13=accuracy(ts(base[c+12][250:NROW(base),1],freq=6),p13[250:NROW(base)])
a14=accuracy(ts(base[c+13][250:NROW(base),1],freq=6),p14[250:NROW(base)])
a15=accuracy(ts(base[c+14][250:NROW(base),1],freq=6),p15[250:NROW(base)])
a16=accuracy(ts(base[c+15][250:NROW(base),1],freq=6),p16[250:NROW(base)])
a17=accuracy(ts(base[c+16][250:NROW(base),1],freq=6),p17[250:NROW(base)])
a18=accuracy(ts(base[c+17][250:NROW(base),1],freq=6),p18[250:NROW(base)])
a19=accuracy(ts(base[c+18][250:NROW(base),1],freq=6),p19[250:NROW(base)])
a20=accuracy(ts(base[c+19][250:NROW(base),1],freq=6),p20[250:NROW(base)])
a21=accuracy(ts(base[c+20][250:NROW(base),1],freq=6),p21[250:NROW(base)])
a22=accuracy(ts(base[c+21][250:NROW(base),1],freq=6),p22[250:NROW(base)])
a23=accuracy(ts(base[c+22][250:NROW(base),1],freq=6),p23[250:NROW(base)])
a24=accuracy(ts(base[c+23][250:NROW(base),1],freq=6),p24[250:NROW(base)])
a25=accuracy(ts(base[c+24][250:NROW(base),1],freq=6),p25[250:NROW(base)])
a26=accuracy(ts(base[c+25][250:NROW(base),1],freq=6),p26[250:NROW(base)])
a27=accuracy(ts(base[c+26][250:NROW(base),1],freq=6),p27[250:NROW(base)])
a28=accuracy(ts(base[c+27][250:NROW(base),1],freq=6),p28[250:NROW(base)])
a29=accuracy(ts(base[c+28][250:NROW(base),1],freq=6),p29[250:NROW(base)])
a30=accuracy(ts(base[c+29][250:NROW(base),1],freq=6),p30[250:NROW(base)])
a31=accuracy(ts(base[c+30][250:NROW(base),1],freq=6),p31[250:NROW(base)])
a32=accuracy(ts(base[c+31][250:NROW(base),1],freq=6),p32[250:NROW(base)])
a33=accuracy(ts(base[c+32][250:NROW(base),1],freq=6),p33[250:NROW(base)])
a34=accuracy(ts(base[c+33][250:NROW(base),1],freq=6),p34[250:NROW(base)])
a35=accuracy(ts(base[c+34][250:NROW(base),1],freq=6),p35[250:NROW(base)])
a36=accuracy(ts(base[c+35][250:NROW(base),1],freq=6),p36[250:NROW(base)])
a37=accuracy(ts(base[c+36][250:NROW(base),1],freq=6),p37[250:NROW(base)])
a38=accuracy(ts(base[c+37][250:NROW(base),1],freq=6),p38[250:NROW(base)])
a39=accuracy(ts(base[c+38][250:NROW(base),1],freq=6),p39[250:NROW(base)])
a40=accuracy(ts(base[c+39][250:NROW(base),1],freq=6),p40[250:NROW(base)])
a41=accuracy(ts(base[c+40][250:NROW(base),1],freq=6),p41[250:NROW(base)])
a42=accuracy(ts(base[c+41][250:NROW(base),1],freq=6),p42[250:NROW(base)])
a43=accuracy(ts(base[c+42][250:NROW(base),1],freq=6),p43[250:NROW(base)])
a44=accuracy(ts(base[c+43][250:NROW(base),1],freq=6),p44[250:NROW(base)])
a45=accuracy(ts(base[c+44][250:NROW(base),1],freq=6),p45[250:NROW(base)])
a46=accuracy(ts(base[c+45][250:NROW(base),1],freq=6),p46[250:NROW(base)])


```
a47=accuracy(ts(base[c+46][250:NROW(base),1],freq=6),p47[250:NROW(base)])  
a48=accuracy(ts(base[c+47][250:NROW(base),1],freq=6),p48[250:NROW(base)])  
a49=accuracy(ts(base[c+48][250:NROW(base),1],freq=6),p49[250:NROW(base)])  
a50=accuracy(ts(base[c+49][250:NROW(base),1],freq=6),p50[250:NROW(base)])
```

```
a1  
a2  
a3  
a4  
a5  
a6  
a7  
a8  
a9  
a10  
a11  
a12  
a13  
a14  
a15  
a16  
a17  
a18  
a19  
a20  
a21  
a22  
a23  
a24  
a25  
a26  
a27  
a28  
a29  
a30  
a31  
a32  
a33  
a34  
a35  
a36  
a37  
a38  
a39  
a40  
a41  
a42  
a43  
a44  
a45
```

```
a46
a47
a48
a49
a50
```

```
#Média do Gestor
```

```
library(forecast)
c=3
n=52
previsoes <-list()
resultado <- c()
prev=c()
prevs1=c()

while(c<(3+n))
{
  a=1
  b=60
  corte=ts(base[a:b,],freq=6)
  corte=corte[,c]
  prevs = c()
  while(b<=(NROW(base)))
  {
    corte=ts(base[a:b,],freq=6)
    corte=corte[,c]
    media=mean(corte)
    prev=rep(media,1)
    previsoes <- prev
    prevs<-c(prevs,previsoes)
    a=a+1
    b=b+1
    print(b)
    print(length(prevs))
    print(c)
  }
  paste("ciclo",c)
  # prevs=prevs[1:(NROW(base)-60)
  prevs1$new <- prevs
  names(prevs1)[names(prevs1) == "new"] <- paste0("P_",colnames(base[,c]))

  c <- c + 1
}
```

```
View(as.data.frame(prevs1))
```

```
#VETORES DE PREVISÃO
vna=rep(NA,60)
```

p1=c(vna,prevs1\$`P_Produto 6D37067`[1:424])
p2=c(vna,prevs1\$`P_Produto 8310266`[1:424])
p3=c(vna,prevs1\$`P_Produto 8D50B89`[1:424])
p4=c(vna,prevs1\$`P_Produto 9949CC2`[1:424])
p5=c(vna,prevs1\$`P_Produto 7ACD128`[1:424])
p6=c(vna,prevs1\$`P_Produto AC707E0`[1:424])
p7=c(vna,prevs1\$`P_Produto B4A1045`[1:424])
p8=c(vna,prevs1\$`P_Produto A83CB60`[1:424])
p9=c(vna,prevs1\$`P_Produto 5B21881`[1:424])
p10=c(vna,prevs1\$`P_Produto 8AAFAC6`[1:424])
p11=c(vna,prevs1\$`P_Produto 83FE785`[1:424])
p12=c(vna,prevs1\$`P_Produto AAD8904`[1:424])
p13=c(vna,prevs1\$`P_Produto BDC55E6`[1:424])
p14=c(vna,prevs1\$`P_Produto 4F2E5A7`[1:424])
p15=c(vna,prevs1\$`P_Produto E8084`[1:424])
p16=c(vna,prevs1\$`P_Produto D8727`[1:424])
p17=c(vna,prevs1\$`P_Produto 67B603`[1:424])
p18=c(vna,prevs1\$`P_Produto 5B1BD43`[1:424])
p19=c(vna,prevs1\$`P_Produto 55C5E44`[1:424])
p20=c(vna,prevs1\$`P_Produto 5B1CB08`[1:424])
p21=c(vna,prevs1\$`P_Produto 1086A5`[1:424])
p22=c(vna,prevs1\$`P_Produto 50DF202`[1:424])
p23=c(vna,prevs1\$`P_Produto E2909`[1:424])
p24=c(vna,prevs1\$`P_Produto EE849`[1:424])
p25=c(vna,prevs1\$`P_Produto 5DC6186`[1:424])
p26=c(vna,prevs1\$`P_Produto C7102`[1:424])
p27=c(vna,prevs1\$`P_Produto B447AE7`[1:424])
p28=c(vna,prevs1\$`P_Produto 9362DC2`[1:424])
p29=c(vna,prevs1\$`P_Produto 625345`[1:424])
p30=c(vna,prevs1\$`P_Produto E179E9`[1:424])
p31=c(vna,prevs1\$`P_Produto A8B31C1`[1:424])
p32=c(vna,prevs1\$`P_Produto 64253A9`[1:424])
p33=c(vna,prevs1\$`P_Produto 6CFA347`[1:424])
p34=c(vna,prevs1\$`P_Produto B6D8980`[1:424])
p35=c(vna,prevs1\$`P_Produto 509C223`[1:424])
p36=c(vna,prevs1\$`P_Produto 93EAC20`[1:424])
p37=c(vna,prevs1\$`P_Produto AC838E8`[1:424])
p38=c(vna,prevs1\$`P_Produto 4C52341`[1:424])
p39=c(vna,prevs1\$`P_Produto 4C80106`[1:424])
p40=c(vna,prevs1\$`P_Produto 4C88120`[1:424])
p41=c(vna,prevs1\$`P_Produto 4D78B26`[1:424])
p42=c(vna,prevs1\$`P_Produto 4DF2564`[1:424])
p43=c(vna,prevs1\$`P_Produto 4EC8F20`[1:424])
p44=c(vna,prevs1\$`P_Produto 50DAA27`[1:424])
p45=c(vna,prevs1\$`P_Produto 5B62560`[1:424])
p46=c(vna,prevs1\$`P_Produto 5DBBFA4`[1:424])
p47=c(vna,prevs1\$`P_Produto 6D37606`[1:424])
p48=c(vna,prevs1\$`P_Produto 7BC71C1`[1:424])
p49=c(vna,prevs1\$`P_Produto 8AC5007`[1:424])
p50=c(vna,prevs1\$`P_Produto 9A2E0A0`[1:424])

#rmse

c=3

a1=accuracy(ts(base[c][250:NROW(base),1],freq=6),p1[250:NROW(base)])
a2=accuracy(ts(base[c+1][250:NROW(base),1],freq=6),p2[250:NROW(base)])
a3=accuracy(ts(base[c+2][250:NROW(base),1],freq=6),p3[250:NROW(base)])
a4=accuracy(ts(base[c+3][250:NROW(base),1],freq=6),p4[250:NROW(base)])
a5=accuracy(ts(base[c+4][250:NROW(base),1],freq=6),p5[250:NROW(base)])
a6=accuracy(ts(base[c+5][250:NROW(base),1],freq=6),p6[250:NROW(base)])
a7=accuracy(ts(base[c+6][250:NROW(base),1],freq=6),p7[250:NROW(base)])
a8=accuracy(ts(base[c+7][250:NROW(base),1],freq=6),p8[250:NROW(base)])
a9=accuracy(ts(base[c+8][250:NROW(base),1],freq=6),p9[250:NROW(base)])
a10=accuracy(ts(base[c+9][250:NROW(base),1],freq=6),p10[250:NROW(base)])
a11=accuracy(ts(base[c+10][250:NROW(base),1],freq=6),p11[250:NROW(base)])
a12=accuracy(ts(base[c+11][250:NROW(base),1],freq=6),p12[250:NROW(base)])
a13=accuracy(ts(base[c+12][250:NROW(base),1],freq=6),p13[250:NROW(base)])
a14=accuracy(ts(base[c+13][250:NROW(base),1],freq=6),p14[250:NROW(base)])
a15=accuracy(ts(base[c+14][250:NROW(base),1],freq=6),p15[250:NROW(base)])
a16=accuracy(ts(base[c+15][250:NROW(base),1],freq=6),p16[250:NROW(base)])
a17=accuracy(ts(base[c+16][250:NROW(base),1],freq=6),p17[250:NROW(base)])
a18=accuracy(ts(base[c+17][250:NROW(base),1],freq=6),p18[250:NROW(base)])
a19=accuracy(ts(base[c+18][250:NROW(base),1],freq=6),p19[250:NROW(base)])
a20=accuracy(ts(base[c+19][250:NROW(base),1],freq=6),p20[250:NROW(base)])
a21=accuracy(ts(base[c+20][250:NROW(base),1],freq=6),p21[250:NROW(base)])
a22=accuracy(ts(base[c+21][250:NROW(base),1],freq=6),p22[250:NROW(base)])
a23=accuracy(ts(base[c+22][250:NROW(base),1],freq=6),p23[250:NROW(base)])
a24=accuracy(ts(base[c+23][250:NROW(base),1],freq=6),p24[250:NROW(base)])
a25=accuracy(ts(base[c+24][250:NROW(base),1],freq=6),p25[250:NROW(base)])
a26=accuracy(ts(base[c+25][250:NROW(base),1],freq=6),p26[250:NROW(base)])
a27=accuracy(ts(base[c+26][250:NROW(base),1],freq=6),p27[250:NROW(base)])
a28=accuracy(ts(base[c+27][250:NROW(base),1],freq=6),p28[250:NROW(base)])
a29=accuracy(ts(base[c+28][250:NROW(base),1],freq=6),p29[250:NROW(base)])
a30=accuracy(ts(base[c+29][250:NROW(base),1],freq=6),p30[250:NROW(base)])
a31=accuracy(ts(base[c+30][250:NROW(base),1],freq=6),p31[250:NROW(base)])
a32=accuracy(ts(base[c+31][250:NROW(base),1],freq=6),p32[250:NROW(base)])
a33=accuracy(ts(base[c+32][250:NROW(base),1],freq=6),p33[250:NROW(base)])
a34=accuracy(ts(base[c+33][250:NROW(base),1],freq=6),p34[250:NROW(base)])
a35=accuracy(ts(base[c+34][250:NROW(base),1],freq=6),p35[250:NROW(base)])
a36=accuracy(ts(base[c+35][250:NROW(base),1],freq=6),p36[250:NROW(base)])
a37=accuracy(ts(base[c+36][250:NROW(base),1],freq=6),p37[250:NROW(base)])
a38=accuracy(ts(base[c+37][250:NROW(base),1],freq=6),p38[250:NROW(base)])
a39=accuracy(ts(base[c+38][250:NROW(base),1],freq=6),p39[250:NROW(base)])
a40=accuracy(ts(base[c+39][250:NROW(base),1],freq=6),p40[250:NROW(base)])
a41=accuracy(ts(base[c+40][250:NROW(base),1],freq=6),p41[250:NROW(base)])
a42=accuracy(ts(base[c+41][250:NROW(base),1],freq=6),p42[250:NROW(base)])
a43=accuracy(ts(base[c+42][250:NROW(base),1],freq=6),p43[250:NROW(base)])
a44=accuracy(ts(base[c+43][250:NROW(base),1],freq=6),p44[250:NROW(base)])
a45=accuracy(ts(base[c+44][250:NROW(base),1],freq=6),p45[250:NROW(base)])
a46=accuracy(ts(base[c+45][250:NROW(base),1],freq=6),p46[250:NROW(base)])
a47=accuracy(ts(base[c+46][250:NROW(base),1],freq=6),p47[250:NROW(base)])

```
a48=accuracy(ts(base[c+47][250:NROW(base),1],freq=6),p48[250:NROW(base)])  
a49=accuracy(ts(base[c+48][250:NROW(base),1],freq=6),p49[250:NROW(base)])  
a50=accuracy(ts(base[c+49][250:NROW(base),1],freq=6),p50[250:NROW(base)])
```

```
a1  
a2  
a3  
a4  
a5  
a6  
a7  
a8  
a9  
a10  
a11  
a12  
a13  
a14  
a15  
a16  
a17  
a18  
a19  
a20  
a21  
a22  
a23  
a24  
a25  
a26  
a27  
a28  
a29  
a30  
a31  
a32  
a33  
a34  
a35  
a36  
a37  
a38  
a39  
a40  
a41  
a42  
a43  
a44  
a45  
a46
```

a47
a48
a49
a50

#ARIMA treino e teste

```
library(forecast)
c=3
n=52
treino <- base[1:(nrow(base)/2),]
teste <- base[(nrow(base)/2):(nrow(base)),]

while(c<(3+n))
{
  tstreino <- ts(treino[,c],freq=6,start=4)
  tsteste <- ts(teste[,c],freq=6,start=5)
  arima1=auto.arima(tstreino)
  prev=forecast(arima1,h=nrow(tsteste))
  teste$new <- c(0,prev$fitted)
  print(c)
  names(teste)[names(teste) == "new"] <- paste0("P_",colnames(teste[,c]))
  c <- c + 1
}
View(as.data.frame(teste))
```

#VETORES DE PREVISÃO

```
vna=rep(NA,60)
p1=c(vna,teste$`P_Produto 6D37067`[2:243])
p2=c(vna,teste$`P_Produto 8310266`[2:243])
p3=c(vna,teste$`P_Produto 8D50B89`[2:243])
p4=c(vna,teste$`P_Produto 9949CC2`[2:243])
p5=c(vna,teste$`P_Produto 7ACD128`[2:243])
p6=c(vna,teste$`P_Produto AC707E0`[2:243])
p7=c(vna,teste$`P_Produto B4A1045`[2:243])
p8=c(vna,teste$`P_Produto A83CB60`[2:243])
p9=c(vna,teste$`P_Produto 5B21881`[2:243])
p10=c(vna,teste$`P_Produto 8AAFAC6`[2:243])
p11=c(vna,teste$`P_Produto 83FE785`[2:243])
p12=c(vna,teste$`P_Produto AAD8904`[2:243])
p13=c(vna,teste$`P_Produto BDC55E6`[2:243])
p14=c(vna,teste$`P_Produto 4F2E5A7`[2:243])
p15=c(vna,teste$`P_Produto E8084`[2:243])
p16=c(vna,teste$`P_Produto D8727`[2:243])
p17=c(vna,teste$`P_Produto 67B603`[2:243])
p18=c(vna,teste$`P_Produto 5B1BD43`[2:243])
p19=c(vna,teste$`P_Produto 55C5E44`[2:243])
p20=c(vna,teste$`P_Produto 5B1CB08`[2:243])
```

p21=c(vna,teste\$`P_Produto 1086A5` [2:243])
 p22=c(vna,teste\$`P_Produto 50DF202` [2:243])
 p23=c(vna,teste\$`P_Produto E2909` [2:243])
 p24=c(vna,teste\$`P_Produto EE849` [2:243])
 p25=c(vna,teste\$`P_Produto 5DC6186` [2:243])
 p26=c(vna,teste\$`P_Produto C7102` [2:243])
 p27=c(vna,teste\$`P_Produto B447AE7` [2:243])
 p28=c(vna,teste\$`P_Produto 9362DC2` [2:243])
 p29=c(vna,teste\$`P_Produto 625345` [2:243])
 p30=c(vna,teste\$`P_Produto E179E9` [2:243])
 p31=c(vna,teste\$`P_Produto A8B31C1` [2:243])
 p32=c(vna,teste\$`P_Produto 64253A9` [2:243])
 p33=c(vna,teste\$`P_Produto 6CFA347` [2:243])
 p34=c(vna,teste\$`P_Produto B6D8980` [2:243])
 p35=c(vna,teste\$`P_Produto 509C223` [2:243])
 p36=c(vna,teste\$`P_Produto 93EAC20` [2:243])
 p37=c(vna,teste\$`P_Produto AC838E8` [2:243])
 p38=c(vna,teste\$`P_Produto 4C52341` [2:243])
 p39=c(vna,teste\$`P_Produto 4C80106` [2:243])
 p40=c(vna,teste\$`P_Produto 4C88120` [2:243])
 p41=c(vna,teste\$`P_Produto 4D78B26` [2:243])
 p42=c(vna,teste\$`P_Produto 4DF2564` [2:243])
 p43=c(vna,teste\$`P_Produto 4EC8F20` [2:243])
 p44=c(vna,teste\$`P_Produto 50DAA27` [2:243])
 p45=c(vna,teste\$`P_Produto 5B62560` [2:243])
 p46=c(vna,teste\$`P_Produto 5DBBFA4` [2:243])
 p47=c(vna,teste\$`P_Produto 6D37606` [2:243])
 p48=c(vna,teste\$`P_Produto 7BC71C1` [2:243])
 p49=c(vna,teste\$`P_Produto 8AC5007` [2:243])
 p50=c(vna,teste\$`P_Produto 9A2E0A0` [2:243])

#rmse

c=3

a1=accuracy(ts(base[c][250:NROW(base),1],freq=6),p1[250:NROW(base)])
 a2=accuracy(ts(base[c+1][250:NROW(base),1],freq=6),p2[250:NROW(base)])
 a3=accuracy(ts(base[c+2][250:NROW(base),1],freq=6),p3[250:NROW(base)])
 a4=accuracy(ts(base[c+3][250:NROW(base),1],freq=6),p4[250:NROW(base)])
 a5=accuracy(ts(base[c+4][250:NROW(base),1],freq=6),p5[250:NROW(base)])
 a6=accuracy(ts(base[c+5][250:NROW(base),1],freq=6),p6[250:NROW(base)])
 a7=accuracy(ts(base[c+6][250:NROW(base),1],freq=6),p7[250:NROW(base)])
 a8=accuracy(ts(base[c+7][250:NROW(base),1],freq=6),p8[250:NROW(base)])
 a9=accuracy(ts(base[c+8][250:NROW(base),1],freq=6),p9[250:NROW(base)])
 a10=accuracy(ts(base[c+9][250:NROW(base),1],freq=6),p10[250:NROW(base)])
 a11=accuracy(ts(base[c+10][250:NROW(base),1],freq=6),p11[250:NROW(base)])
 a12=accuracy(ts(base[c+11][250:NROW(base),1],freq=6),p12[250:NROW(base)])
 a13=accuracy(ts(base[c+12][250:NROW(base),1],freq=6),p13[250:NROW(base)])
 a14=accuracy(ts(base[c+13][250:NROW(base),1],freq=6),p14[250:NROW(base)])
 a15=accuracy(ts(base[c+14][250:NROW(base),1],freq=6),p15[250:NROW(base)])
 a16=accuracy(ts(base[c+15][250:NROW(base),1],freq=6),p16[250:NROW(base)])
 a17=accuracy(ts(base[c+16][250:NROW(base),1],freq=6),p17[250:NROW(base)])

a18=accuracy(ts(base[c+17][250:NROW(base),1],freq=6),p18[250:NROW(base)])
a19=accuracy(ts(base[c+18][250:NROW(base),1],freq=6),p19[250:NROW(base)])
a20=accuracy(ts(base[c+19][250:NROW(base),1],freq=6),p20[250:NROW(base)])
a21=accuracy(ts(base[c+20][250:NROW(base),1],freq=6),p21[250:NROW(base)])
a22=accuracy(ts(base[c+21][250:NROW(base),1],freq=6),p22[250:NROW(base)])
a23=accuracy(ts(base[c+22][250:NROW(base),1],freq=6),p23[250:NROW(base)])
a24=accuracy(ts(base[c+23][250:NROW(base),1],freq=6),p24[250:NROW(base)])
a25=accuracy(ts(base[c+24][250:NROW(base),1],freq=6),p25[250:NROW(base)])
a26=accuracy(ts(base[c+25][250:NROW(base),1],freq=6),p26[250:NROW(base)])
a27=accuracy(ts(base[c+26][250:NROW(base),1],freq=6),p27[250:NROW(base)])
a28=accuracy(ts(base[c+27][250:NROW(base),1],freq=6),p28[250:NROW(base)])
a29=accuracy(ts(base[c+28][250:NROW(base),1],freq=6),p29[250:NROW(base)])
a30=accuracy(ts(base[c+29][250:NROW(base),1],freq=6),p30[250:NROW(base)])
a31=accuracy(ts(base[c+30][250:NROW(base),1],freq=6),p31[250:NROW(base)])
a32=accuracy(ts(base[c+31][250:NROW(base),1],freq=6),p32[250:NROW(base)])
a33=accuracy(ts(base[c+32][250:NROW(base),1],freq=6),p33[250:NROW(base)])
a34=accuracy(ts(base[c+33][250:NROW(base),1],freq=6),p34[250:NROW(base)])
a35=accuracy(ts(base[c+34][250:NROW(base),1],freq=6),p35[250:NROW(base)])
a36=accuracy(ts(base[c+35][250:NROW(base),1],freq=6),p36[250:NROW(base)])
a37=accuracy(ts(base[c+36][250:NROW(base),1],freq=6),p37[250:NROW(base)])
a38=accuracy(ts(base[c+37][250:NROW(base),1],freq=6),p38[250:NROW(base)])
a39=accuracy(ts(base[c+38][250:NROW(base),1],freq=6),p39[250:NROW(base)])
a40=accuracy(ts(base[c+39][250:NROW(base),1],freq=6),p40[250:NROW(base)])
a41=accuracy(ts(base[c+40][250:NROW(base),1],freq=6),p41[250:NROW(base)])
a42=accuracy(ts(base[c+41][250:NROW(base),1],freq=6),p42[250:NROW(base)])
a43=accuracy(ts(base[c+42][250:NROW(base),1],freq=6),p43[250:NROW(base)])
a44=accuracy(ts(base[c+43][250:NROW(base),1],freq=6),p44[250:NROW(base)])
a45=accuracy(ts(base[c+44][250:NROW(base),1],freq=6),p45[250:NROW(base)])
a46=accuracy(ts(base[c+45][250:NROW(base),1],freq=6),p46[250:NROW(base)])
a47=accuracy(ts(base[c+46][250:NROW(base),1],freq=6),p47[250:NROW(base)])
a48=accuracy(ts(base[c+47][250:NROW(base),1],freq=6),p48[250:NROW(base)])
a49=accuracy(ts(base[c+48][250:NROW(base),1],freq=6),p49[250:NROW(base)])
a50=accuracy(ts(base[c+49][250:NROW(base),1],freq=6),p50[250:NROW(base)])

a1
a2
a3
a4
a5
a6
a7
a8
a9
a10
a11
a12
a13
a14
a15
a16

a17
a18
a19
a20
a21
a22
a23
a24
a25
a26
a27
a28
a29
a30
a31
a32
a33
a34
a35
a36
a37
a38
a39
a40
a41
a42
a43
a44
a45
a46
a47
a48
a49
a50

#Holt-Winters Treino e Teste

```
library(forecast)
c=3
n=52
treino <- base[1:(nrow(base)/2),]
teste <- base[(nrow(base)/2):(nrow(base)),]

while(c<(3+n))
{
  tstreino <- ts(treino[,c],freq=6,start=4)
  tsteste <- ts(teste[,c],freq=6,start=5)
  hw1=HoltWinters(tstreino)
  prev=forecast(hw1,h=nrow(tsteste))
}
```

```

teste$new <- c(0,prev$fitted)
print(c)
names(teste)[names(teste) == "new"] <- paste0("P_",colnames(teste[,c]))

c <- c + 1
}
View(as.data.frame(teste))

#VETORES DE PREVISÃO
vna=rep(NA,242)
p1=c(vna,teste$`P_Produto 6D37067`[1:243])
p2=c(vna,teste$`P_Produto 8310266`[1:243])
p3=c(vna,teste$`P_Produto 8D50B89`[1:243])
p4=c(vna,teste$`P_Produto 9949CC2`[1:243])
p5=c(vna,teste$`P_Produto 7ACD128`[1:243])
p6=c(vna,teste$`P_Produto AC707E0`[1:243])
p7=c(vna,teste$`P_Produto B4A1045`[1:243])
p8=c(vna,teste$`P_Produto A83CB60`[1:243])
p9=c(vna,teste$`P_Produto 5B21881`[1:243])
p10=c(vna,teste$`P_Produto 8AAFAC6`[1:243])
p11=c(vna,teste$`Produto 83FE785`[1:243])
p12=c(vna,teste$`Produto AAD8904`[1:243])
p13=c(vna,teste$`Produto BDC55E6`[1:243])
p14=c(vna,teste$`Produto 4F2E5A7`[1:243])
p15=c(vna,teste$`Produto E8084`[1:243])
p16=c(vna,teste$`Produto D8727`[1:243])
p17=c(vna,teste$`Produto 67B603`[1:243])
p18=c(vna,teste$`Produto 5B1BD43`[1:243])
p19=c(vna,teste$`Produto 55C5E44`[1:243])
p20=c(vna,teste$`Produto 5B1CB08`[1:243])
p21=c(vna,teste$`P_Produto 1086A5`[1:243])
p22=c(vna,teste$`P_Produto 50DF202`[1:243])
p23=c(vna,teste$`P_Produto E2909`[1:243])
p24=c(vna,teste$`P_Produto EE849`[1:243])
p25=c(vna,teste$`P_Produto 5DC6186`[1:243])
p26=c(vna,teste$`P_Produto C7102`[1:243])
p27=c(vna,teste$`P_Produto B447AE7`[1:243])
p28=c(vna,teste$`P_Produto 9362DC2`[1:243])
p29=c(vna,teste$`P_Produto 625345`[1:243])
p30=c(vna,teste$`P_Produto E179E9`[1:243])
p31=c(vna,teste$`P_Produto A8B31C1`[1:243])
p32=c(vna,teste$`P_Produto 64253A9`[1:243])
p33=c(vna,teste$`P_Produto 6CFA347`[1:243])
p34=c(vna,teste$`P_Produto B6D8980`[1:243])
p35=c(vna,teste$`P_Produto 509C223`[1:243])
p36=c(vna,teste$`P_Produto 93EAC20`[1:243])
p37=c(vna,teste$`P_Produto AC838E8`[1:243])
p38=c(vna,teste$`P_Produto 4C52341`[1:243])
p39=c(vna,teste$`P_Produto 4C80106`[1:243])
p40=c(vna,teste$`P_Produto 4C88120`[1:243])

```

p41=c(vna,teste\$`P_Produto 4D78B26`[1:243])
 p42=c(vna,teste\$`P_Produto 4DF2564`[1:243])
 p43=c(vna,teste\$`P_Produto 4EC8F20`[1:243])
 p44=c(vna,teste\$`P_Produto 50DAA27`[1:243])
 p45=c(vna,teste\$`P_Produto 5B62560`[1:243])
 p46=c(vna,teste\$`P_Produto 5DBBFA4`[1:243])
 p47=c(vna,teste\$`P_Produto 6D37606`[1:243])
 p48=c(vna,teste\$`P_Produto 7BC71C1`[1:243])
 p49=c(vna,teste\$`P_Produto 8AC5007`[1:243])
 p50=c(vna,teste\$`P_Produto 9A2E0A0`[1:243])

#rmse

c=3

a1=accuracy(ts(base[c][250:NROW(base),1],freq=6),p1[250:NROW(base)])
 a2=accuracy(ts(base[c+1][250:NROW(base),1],freq=6),p2[250:NROW(base)])
 a3=accuracy(ts(base[c+2][250:NROW(base),1],freq=6),p3[250:NROW(base)])
 a4=accuracy(ts(base[c+3][250:NROW(base),1],freq=6),p4[250:NROW(base)])
 a5=accuracy(ts(base[c+4][250:NROW(base),1],freq=6),p5[250:NROW(base)])
 a6=accuracy(ts(base[c+5][250:NROW(base),1],freq=6),p6[250:NROW(base)])
 a7=accuracy(ts(base[c+6][250:NROW(base),1],freq=6),p7[250:NROW(base)])
 a8=accuracy(ts(base[c+7][250:NROW(base),1],freq=6),p8[250:NROW(base)])
 a9=accuracy(ts(base[c+8][250:NROW(base),1],freq=6),p9[250:NROW(base)])
 a10=accuracy(ts(base[c+9][250:NROW(base),1],freq=6),p10[250:NROW(base)])
 a11=accuracy(ts(base[c+10][250:NROW(base),1],freq=6),p11[250:NROW(base)])
 a12=accuracy(ts(base[c+11][250:NROW(base),1],freq=6),p12[250:NROW(base)])
 a13=accuracy(ts(base[c+12][250:NROW(base),1],freq=6),p13[250:NROW(base)])
 a14=accuracy(ts(base[c+13][250:NROW(base),1],freq=6),p14[250:NROW(base)])
 a15=accuracy(ts(base[c+14][250:NROW(base),1],freq=6),p15[250:NROW(base)])
 a16=accuracy(ts(base[c+15][250:NROW(base),1],freq=6),p16[250:NROW(base)])
 a17=accuracy(ts(base[c+16][250:NROW(base),1],freq=6),p17[250:NROW(base)])
 a18=accuracy(ts(base[c+17][250:NROW(base),1],freq=6),p18[250:NROW(base)])
 a19=accuracy(ts(base[c+18][250:NROW(base),1],freq=6),p19[250:NROW(base)])
 a20=accuracy(ts(base[c+19][250:NROW(base),1],freq=6),p20[250:NROW(base)])
 a21=accuracy(ts(base[c+20][250:NROW(base),1],freq=6),p21[250:NROW(base)])
 a22=accuracy(ts(base[c+21][250:NROW(base),1],freq=6),p22[250:NROW(base)])
 a23=accuracy(ts(base[c+22][250:NROW(base),1],freq=6),p23[250:NROW(base)])
 a24=accuracy(ts(base[c+23][250:NROW(base),1],freq=6),p24[250:NROW(base)])
 a25=accuracy(ts(base[c+24][250:NROW(base),1],freq=6),p25[250:NROW(base)])
 a26=accuracy(ts(base[c+25][250:NROW(base),1],freq=6),p26[250:NROW(base)])
 a27=accuracy(ts(base[c+26][250:NROW(base),1],freq=6),p27[250:NROW(base)])
 a28=accuracy(ts(base[c+27][250:NROW(base),1],freq=6),p28[250:NROW(base)])
 a29=accuracy(ts(base[c+28][250:NROW(base),1],freq=6),p29[250:NROW(base)])
 a30=accuracy(ts(base[c+29][250:NROW(base),1],freq=6),p30[250:NROW(base)])
 a31=accuracy(ts(base[c+30][250:NROW(base),1],freq=6),p31[250:NROW(base)])
 a32=accuracy(ts(base[c+31][250:NROW(base),1],freq=6),p32[250:NROW(base)])
 a33=accuracy(ts(base[c+32][250:NROW(base),1],freq=6),p33[250:NROW(base)])
 a34=accuracy(ts(base[c+33][250:NROW(base),1],freq=6),p34[250:NROW(base)])
 a35=accuracy(ts(base[c+34][250:NROW(base),1],freq=6),p35[250:NROW(base)])
 a36=accuracy(ts(base[c+35][250:NROW(base),1],freq=6),p36[250:NROW(base)])
 a37=accuracy(ts(base[c+36][250:NROW(base),1],freq=6),p37[250:NROW(base)])

a38=accuracy(ts(base[c+37][250:NROW(base),1],freq=6),p38[250:NROW(base)])
a39=accuracy(ts(base[c+38][250:NROW(base),1],freq=6),p39[250:NROW(base)])
a40=accuracy(ts(base[c+39][250:NROW(base),1],freq=6),p40[250:NROW(base)])
a41=accuracy(ts(base[c+40][250:NROW(base),1],freq=6),p41[250:NROW(base)])
a42=accuracy(ts(base[c+41][250:NROW(base),1],freq=6),p42[250:NROW(base)])
a43=accuracy(ts(base[c+42][250:NROW(base),1],freq=6),p43[250:NROW(base)])
a44=accuracy(ts(base[c+43][250:NROW(base),1],freq=6),p44[250:NROW(base)])
a45=accuracy(ts(base[c+44][250:NROW(base),1],freq=6),p45[250:NROW(base)])
a46=accuracy(ts(base[c+45][250:NROW(base),1],freq=6),p46[250:NROW(base)])
a47=accuracy(ts(base[c+46][250:NROW(base),1],freq=6),p47[250:NROW(base)])
a48=accuracy(ts(base[c+47][250:NROW(base),1],freq=6),p48[250:NROW(base)])
a49=accuracy(ts(base[c+48][250:NROW(base),1],freq=6),p49[250:NROW(base)])
a50=accuracy(ts(base[c+49][250:NROW(base),1],freq=6),p50[250:NROW(base)])

a1
a2
a3
a4
a5
a6
a7
a8
a9
a10
a11
a12
a13
a14
a15
a16
a17
a18
a19
a20
a21
a22
a23
a24
a25
a26
a27
a28
a29
a30
a31
a32
a33
a34
a35
a36

```
a37  
a38  
a39  
a40  
a41  
a42  
a43  
a44  
a45  
a46  
a47  
a48  
a49  
a50
```

```
#TBATS andando
```

```
library(forecast)
```

```
c=3
```

```
n=52
```

```
previsoes <-list()
```

```
resultado <- c()
```

```
prev=c()
```

```
prevs1=c()
```

```
while(c<(3+n))
```

```
{
```

```
  a=1
```

```
  b=60
```

```
  corte=ts(base[a:b,],freq=6)
```

```
  corte=corte[,c]
```

```
  prevs = c()
```

```
  while(b<=(NROW(base)))
```

```
  {
```

```
    corte=ts(base[a:b,],freq=6)
```

```
    corte=corte[,c]
```

```

tba=tbats(y=corte)
prev=print(forecast(tba,1))
previsoes <- prev$`Point Forecast`
prevs<-c(prevs,previsoes)
a=a+1
b=b+1
print(b)
print(length(prevs))
print(c)
}
paste("ciclo",c)
# prevs=prevs[1:(NROW(base)-60)]
prevs1$new <- prevs
names(prevs1)[names(prevs1) == "new"] <- paste0("P_",colnames(base[,c]))

c <- c + 1
}

View(as.data.frame(prevs1))

```

#VETORES DE PREVISÃO

```

vna=rep(NA,60)
p1=c(vna,prevs1$`P_Produto 6D37067`[1:424])
p2=c(vna,prevs1$`P_Produto 8310266`[1:424])
p3=c(vna,prevs1$`P_Produto 8D50B89`[1:424])
p4=c(vna,prevs1$`P_Produto 9949CC2`[1:424])
p5=c(vna,prevs1$`P_Produto 7ACD128`[1:424])
p6=c(vna,prevs1$`P_Produto AC707E0`[1:424])
p7=c(vna,prevs1$`P_Produto B4A1045`[1:424])
p8=c(vna,prevs1$`P_Produto A83CB60`[1:424])
p9=c(vna,prevs1$`P_Produto 5B21881`[1:424])
p10=c(vna,prevs1$`P_Produto 8AAFAC6`[1:424])
p11=c(vna,prevs1$`P_Produto 83FE785`[1:424])
p12=c(vna,prevs1$`P_Produto AAD8904`[1:424])
p13=c(vna,prevs1$`P_Produto BDC55E6`[1:424])
p14=c(vna,prevs1$`P_Produto 4F2E5A7`[1:424])
p15=c(vna,prevs1$`P_Produto E8084`[1:424])
p16=c(vna,prevs1$`P_Produto D8727`[1:424])
p17=c(vna,prevs1$`P_Produto 67B603`[1:424])
p18=c(vna,prevs1$`P_Produto 5B1BD43`[1:424])

```

p19=c(vna,prevs1\$`P_Produto 55C5E44`[1:424])
 p20=c(vna,prevs1\$`P_Produto 5B1CB08`[1:424])
 p21=c(vna,prevs1\$`P_Produto 1086A5` [1:424])
 p22=c(vna,prevs1\$`P_Produto 50DF202`[1:424])
 p23=c(vna,prevs1\$`P_Produto E2909`[1:424])
 p24=c(vna,prevs1\$`P_Produto EE849`[1:424])
 p25=c(vna,prevs1\$`P_Produto 5DC6186`[1:424])
 p26=c(vna,prevs1\$`P_Produto C7102`[1:424])
 p27=c(vna,prevs1\$`P_Produto B447AE7`[1:424])
 p28=c(vna,prevs1\$`P_Produto 9362DC2`[1:424])
 p29=c(vna,prevs1\$`P_Produto 625345`[1:424])
 p30=c(vna,prevs1\$`P_Produto E179E9`[1:424])
 p31=c(vna,prevs1\$`P_Produto A8B31C1`[1:424])
 p32=c(vna,prevs1\$`P_Produto 64253A9`[1:424])
 p33=c(vna,prevs1\$`P_Produto 6CFA347`[1:424])
 p34=c(vna,prevs1\$`P_Produto B6D8980`[1:424])
 p35=c(vna,prevs1\$`P_Produto 509C223`[1:424])
 p36=c(vna,prevs1\$`P_Produto 93EAC20`[1:424])
 p37=c(vna,prevs1\$`P_Produto AC838E8`[1:424])
 p38=c(vna,prevs1\$`P_Produto 4C52341`[1:424])
 p39=c(vna,prevs1\$`P_Produto 4C80106`[1:424])
 p40=c(vna,prevs1\$`P_Produto 4C88120`[1:424])
 p41=c(vna,prevs1\$`P_Produto 4D78B26`[1:424])
 p42=c(vna,prevs1\$`P_Produto 4DF2564`[1:424])
 p43=c(vna,prevs1\$`P_Produto 4EC8F20`[1:424])
 p44=c(vna,prevs1\$`P_Produto 50DAA27`[1:424])
 p45=c(vna,prevs1\$`P_Produto 5B62560`[1:424])
 p46=c(vna,prevs1\$`P_Produto 5DBBFA4`[1:424])
 p47=c(vna,prevs1\$`P_Produto 6D37606`[1:424])
 p48=c(vna,prevs1\$`P_Produto 7BC71C1`[1:424])
 p49=c(vna,prevs1\$`P_Produto 8AC5007`[1:424])
 p50=c(vna,prevs1\$`P_Produto 9A2E0A0`[1:424])

#rmse

c=3

a1=accuracy(ts(base[c][250:NROW(base),1],freq=6),p1[250:NROW(base)])
 a2=accuracy(ts(base[c+1][250:NROW(base),1],freq=6),p2[250:NROW(base)])
 a3=accuracy(ts(base[c+2][250:NROW(base),1],freq=6),p3[250:NROW(base)])
 a4=accuracy(ts(base[c+3][250:NROW(base),1],freq=6),p4[250:NROW(base)])
 a5=accuracy(ts(base[c+4][250:NROW(base),1],freq=6),p5[250:NROW(base)])
 a6=accuracy(ts(base[c+5][250:NROW(base),1],freq=6),p6[250:NROW(base)])
 a7=accuracy(ts(base[c+6][250:NROW(base),1],freq=6),p7[250:NROW(base)])
 a8=accuracy(ts(base[c+7][250:NROW(base),1],freq=6),p8[250:NROW(base)])
 a9=accuracy(ts(base[c+8][250:NROW(base),1],freq=6),p9[250:NROW(base)])
 a10=accuracy(ts(base[c+9][250:NROW(base),1],freq=6),p10[250:NROW(base)])
 a11=accuracy(ts(base[c+10][250:NROW(base),1],freq=6),p11[250:NROW(base)])
 a12=accuracy(ts(base[c+11][250:NROW(base),1],freq=6),p12[250:NROW(base)])
 a13=accuracy(ts(base[c+12][250:NROW(base),1],freq=6),p13[250:NROW(base)])
 a14=accuracy(ts(base[c+13][250:NROW(base),1],freq=6),p14[250:NROW(base)])
 a15=accuracy(ts(base[c+14][250:NROW(base),1],freq=6),p15[250:NROW(base)])

a16=accuracy(ts(base[c+15][250:NROW(base),1],freq=6),p16[250:NROW(base)])
 a17=accuracy(ts(base[c+16][250:NROW(base),1],freq=6),p17[250:NROW(base)])
 a18=accuracy(ts(base[c+17][250:NROW(base),1],freq=6),p18[250:NROW(base)])
 a19=accuracy(ts(base[c+18][250:NROW(base),1],freq=6),p19[250:NROW(base)])
 a20=accuracy(ts(base[c+19][250:NROW(base),1],freq=6),p20[250:NROW(base)])
 a21=accuracy(ts(base[c+20][250:NROW(base),1],freq=6),p21[250:NROW(base)])
 a22=accuracy(ts(base[c+21][250:NROW(base),1],freq=6),p22[250:NROW(base)])
 a23=accuracy(ts(base[c+22][250:NROW(base),1],freq=6),p23[250:NROW(base)])
 a24=accuracy(ts(base[c+23][250:NROW(base),1],freq=6),p24[250:NROW(base)])
 a25=accuracy(ts(base[c+24][250:NROW(base),1],freq=6),p25[250:NROW(base)])
 a26=accuracy(ts(base[c+25][250:NROW(base),1],freq=6),p26[250:NROW(base)])
 a27=accuracy(ts(base[c+26][250:NROW(base),1],freq=6),p27[250:NROW(base)])
 a28=accuracy(ts(base[c+27][250:NROW(base),1],freq=6),p28[250:NROW(base)])
 a29=accuracy(ts(base[c+28][250:NROW(base),1],freq=6),p29[250:NROW(base)])
 a30=accuracy(ts(base[c+29][250:NROW(base),1],freq=6),p30[250:NROW(base)])
 a31=accuracy(ts(base[c+30][250:NROW(base),1],freq=6),p31[250:NROW(base)])
 a32=accuracy(ts(base[c+31][250:NROW(base),1],freq=6),p32[250:NROW(base)])
 a33=accuracy(ts(base[c+32][250:NROW(base),1],freq=6),p33[250:NROW(base)])
 a34=accuracy(ts(base[c+33][250:NROW(base),1],freq=6),p34[250:NROW(base)])
 a35=accuracy(ts(base[c+34][250:NROW(base),1],freq=6),p35[250:NROW(base)])
 a36=accuracy(ts(base[c+35][250:NROW(base),1],freq=6),p36[250:NROW(base)])
 a37=accuracy(ts(base[c+36][250:NROW(base),1],freq=6),p37[250:NROW(base)])
 a38=accuracy(ts(base[c+37][250:NROW(base),1],freq=6),p38[250:NROW(base)])
 a39=accuracy(ts(base[c+38][250:NROW(base),1],freq=6),p39[250:NROW(base)])
 a40=accuracy(ts(base[c+39][250:NROW(base),1],freq=6),p40[250:NROW(base)])
 a41=accuracy(ts(base[c+40][250:NROW(base),1],freq=6),p41[250:NROW(base)])
 a42=accuracy(ts(base[c+41][250:NROW(base),1],freq=6),p42[250:NROW(base)])
 a43=accuracy(ts(base[c+42][250:NROW(base),1],freq=6),p43[250:NROW(base)])
 a44=accuracy(ts(base[c+43][250:NROW(base),1],freq=6),p44[250:NROW(base)])
 a45=accuracy(ts(base[c+44][250:NROW(base),1],freq=6),p45[250:NROW(base)])
 a46=accuracy(ts(base[c+45][250:NROW(base),1],freq=6),p46[250:NROW(base)])
 a47=accuracy(ts(base[c+46][250:NROW(base),1],freq=6),p47[250:NROW(base)])
 a48=accuracy(ts(base[c+47][250:NROW(base),1],freq=6),p48[250:NROW(base)])
 a49=accuracy(ts(base[c+48][250:NROW(base),1],freq=6),p49[250:NROW(base)])
 a50=accuracy(ts(base[c+49][250:NROW(base),1],freq=6),p50[250:NROW(base)])

a1
 a2
 a3
 a4
 a5
 a6
 a7
 a8
 a9
 a10
 a11
 a12
 a13
 a14

a15
 a16
 a17
 a18
 a19
 a20
 a21
 a22
 a23
 a24
 a25
 a26
 a27
 a28
 a29
 a30
 a31
 a32
 a33
 a34
 a35
 a36
 a37
 a38
 a39
 a40
 a41
 a42
 a43
 a44
 a45
 a46
 a47
 a48
 a49
 a50

$e1=(ts(base[c][250:NROW(base),1],freq=6)-p1[250:NROW(base)])$
 $e2=(ts(base[c+1][250:NROW(base),1],freq=6)-p2[250:NROW(base)])$
 $e3=(ts(base[c+2][250:NROW(base),1],freq=6)-p3[250:NROW(base)])$
 $e4=(ts(base[c+3][250:NROW(base),1],freq=6)-p4[250:NROW(base)])$
 $e5=(ts(base[c+4][250:NROW(base),1],freq=6)-p5[250:NROW(base)])$
 $e6=(ts(base[c+5][250:NROW(base),1],freq=6)-p6[250:NROW(base)])$
 $e7=(ts(base[c+6][250:NROW(base),1],freq=6)-p7[250:NROW(base)])$
 $e8=(ts(base[c+7][250:NROW(base),1],freq=6)-p8[250:NROW(base)])$
 $e9=(ts(base[c+8][250:NROW(base),1],freq=6)-p9[250:NROW(base)])$
 $e10=(ts(base[c+9][250:NROW(base),1],freq=6)-p10[250:NROW(base)])$
 $e11=(ts(base[c+10][250:NROW(base),1],freq=6)-p11[250:NROW(base)])$
 $e12=(ts(base[c+11][250:NROW(base),1],freq=6)-p12[250:NROW(base)])$

```

e13=(ts(base[c+12][250:NROW(base),1],freq=6)-p13[250:NROW(base)])
e14=(ts(base[c+13][250:NROW(base),1],freq=6)-p14[250:NROW(base)])
e15=(ts(base[c+14][250:NROW(base),1],freq=6)-p15[250:NROW(base)])
e16=(ts(base[c+15][250:NROW(base),1],freq=6)-p16[250:NROW(base)])
e17=(ts(base[c+16][250:NROW(base),1],freq=6)-p17[250:NROW(base)])
e18=(ts(base[c+17][250:NROW(base),1],freq=6)-p18[250:NROW(base)])
e19=(ts(base[c+18][250:NROW(base),1],freq=6)-p19[250:NROW(base)])
e20=(ts(base[c+19][250:NROW(base),1],freq=6)-p20[250:NROW(base)])
e21=(ts(base[c+20][250:NROW(base),1],freq=6)-p21[250:NROW(base)])
e22=(ts(base[c+21][250:NROW(base),1],freq=6)-p22[250:NROW(base)])
e23=(ts(base[c+22][250:NROW(base),1],freq=6)-p23[250:NROW(base)])
e24=(ts(base[c+23][250:NROW(base),1],freq=6)-p24[250:NROW(base)])
e25=(ts(base[c+24][250:NROW(base),1],freq=6)-p25[250:NROW(base)])
e26=(ts(base[c+25][250:NROW(base),1],freq=6)-p26[250:NROW(base)])
e27=(ts(base[c+26][250:NROW(base),1],freq=6)-p27[250:NROW(base)])
e28=(ts(base[c+27][250:NROW(base),1],freq=6)-p28[250:NROW(base)])
e29=(ts(base[c+28][250:NROW(base),1],freq=6)-p29[250:NROW(base)])
e30=(ts(base[c+29][250:NROW(base),1],freq=6)-p30[250:NROW(base)])
e31=(ts(base[c+30][250:NROW(base),1],freq=6)-p31[250:NROW(base)])
e32=(ts(base[c+31][250:NROW(base),1],freq=6)-p32[250:NROW(base)])
e33=(ts(base[c+32][250:NROW(base),1],freq=6)-p33[250:NROW(base)])
e34=(ts(base[c+33][250:NROW(base),1],freq=6)-p34[250:NROW(base)])
e35=(ts(base[c+34][250:NROW(base),1],freq=6)-p35[250:NROW(base)])
e36=(ts(base[c+35][250:NROW(base),1],freq=6)-p36[250:NROW(base)])
e37=(ts(base[c+36][250:NROW(base),1],freq=6)-p37[250:NROW(base)])
e38=(ts(base[c+37][250:NROW(base),1],freq=6)-p38[250:NROW(base)])
e39=(ts(base[c+38][250:NROW(base),1],freq=6)-p39[250:NROW(base)])
e40=(ts(base[c+39][250:NROW(base),1],freq=6)-p40[250:NROW(base)])
e41=(ts(base[c+40][250:NROW(base),1],freq=6)-p41[250:NROW(base)])
e42=(ts(base[c+41][250:NROW(base),1],freq=6)-p42[250:NROW(base)])
e43=(ts(base[c+42][250:NROW(base),1],freq=6)-p43[250:NROW(base)])
e44=(ts(base[c+43][250:NROW(base),1],freq=6)-p44[250:NROW(base)])
e45=(ts(base[c+44][250:NROW(base),1],freq=6)-p45[250:NROW(base)])
e46=(ts(base[c+45][250:NROW(base),1],freq=6)-p46[250:NROW(base)])
e47=(ts(base[c+46][250:NROW(base),1],freq=6)-p47[250:NROW(base)])
e48=(ts(base[c+47][250:NROW(base),1],freq=6)-p48[250:NROW(base)])
e49=(ts(base[c+48][250:NROW(base),1],freq=6)-p49[250:NROW(base)])
e50=(ts(base[c+49][250:NROW(base),1],freq=6)-p50[250:NROW(base)])

residuos=cbind(e1,e2,e3,e4,e5,e6,e7,e8,e9,e10,e11,e12,e13,e14,e15,e16,e17,e18,e
19,e20,e21,e22,e23,e24,e25,e26,e27,e28,e29,e30,e31,e32,e33,e34,e35,e36,e37,e3
8,e39,e40,e41,e42,e43,e44,e45,e46,e47,e48,e49,e50)
acf(e1)
testebartlett=bartlett.test(list(e1,e2,e3,e4,e5,e6,e7,e8,e9,e10,e11,e12,e13,e14,e15,e
16,e17,e18,e19))
testebartlett
testebartlett=bartlett.test(list(e21,e22,e23,e24,e25,e26,e27,e28,e29,e30,e31,e32,e33
,e34,e35,e36,e37,e38,e39,e40,e41,e42,e43,e44,e45,e46,e47,e48,e49,e50))
testebartlett
testeshapiro=shapiro.test(e1)

```

```

prevx=prev$fitted
tsprev=ts(prevx,freq=6)
tsprev=tsprev[7:160]
a1=auto.arima(prevx)
prev=forecast(a1,h=nrow(tsteste))

```

```

a=1
b=161
prevs = c()
corte=ts(base[a:b,],freq=6)
corte=corte[,c]
tba=tbats(y=corte)
prev=print(forecast(tba,160))
previsoes <- prev$`Point Forecast`
prevs=(ts(previsoes,freq=6))
tbats2=tbats(previsoes)
prev=print(forecast(tbats2,160))

```

#TREINO, VALIDAÇÃO E TESTE

```

library(forecast)
c=3
n=52
previsoes <-list()
resultado <- c()
prev=c()
prevs1=c()

while(c<(3+n))
{
  a=1
  b=161
  corte=ts(base[a:b,],freq=6)
  corte=corte[,c]
  prevs = c()
  while(b<=(NROW(base)))
  {

```

```

corte=ts(base[a:b,],freq=6)
corte=corte[,c]
tba=tbats(y=corte)
prev=print(forecast(tba,160))
previsoes <- prev$`Point Forecast`
prevs<-c(prevs,previsoes)
a=a+160
b=b+160
print(b)
print(length(prevs))
print(c)
}
paste("ciclo",c)
# prevs=prevs[1:(NROW(base)-60)]
prevs1$new <- prevs
names(prevs1)[names(prevs1) == "new"] <- paste0("P_",colnames(base[,c]))

c <- c + 1
}
View(as.data.frame(prevs1))

previsao1=as.data.frame(prevs1)
previsao1=previsao1[1:160,1:52]

c=3
n=52
previsoes <-list()
resultado <- c()
prev=c()
prevs1=c()

while(c<(3+n))
{
a=1
b=161
corte=ts(previsao1[a:b,],freq=6)
corte=corte[,c]
prevs = c()
while(b<=(NROW(base)))
{
corte=ts(previsao1[a:b,],freq=6)
corte=corte[,c]
tba=tbats(y=corte)
prev=print(forecast(tba,160))
previsoes <- prev$`Point Forecast`
prevs<-c(prevs,previsoes)
a=a+160
b=b+160
print(b)
}
}

```

```
print(length(prevs))
print(c)
}
paste("ciclo",c)
# prevs=prevs[1:(NROW(base)-60)]
prevs1$new <- prevs
names(prevs1)[names(prevs1) == "new"] <- paste0("P_",colnames(base[,c]))

c <- c + 1
}
View(as.data.frame(prevs1))
previsao2=(as.data.frame(prevs1))
previsao2=previsao2[1:160,1:50]
```