

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ECONOMIA
GRADUAÇÃO EM ECONOMIA**

Ítalo de Paula Bellozi

Modelo de previsão de faturamento no setor moveleiro: Um estudo de caso

Juiz de Fora
2025

Ítalo de Paula Bellozi

Modelo de previsão de faturamento no setor moveleiro: Um estudo de caso

Monografia ao curso de Ciências Econômicas da Universidade Federal de Juiz de Fora, como requisito para a obtenção do título de Bacharel em Ciências Econômicas.

Orientador: Dr. Alexandre Zanini

Juiz de Fora

2025

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Bellozi, Ítalo de Paula.

Modelo de previsão de faturamento no setor moveleiro : Um estudo de caso / Ítalo de Paula Bellozi. -- 2025.

48 p. : il.

Orientador: Alexandre Zanini

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Juiz de Fora, Faculdade de Economia, 2025.

1. Análise de Séries Temporais. 2. Métodos de Previsão. 3. Sazonalidade. 4. Planejamento Financeiro. 5. Validação de Modelos e Métricas de Desempenho. I. Zanini, Alexandre, orient. II. Título.



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
REITORIA - FACECON - Depto. de Economia

FACULDADE DE ECONOMIA / UFJF

ATA DE APROVAÇÃO DE MONOGRAFIA II (MONO B)

Na data de 18/02/2025, a Banca Examinadora, composta pelos professores

1 – Alexandre Zanini - orientador; e

2 – Rogério Silva de Mattos,

reuniu-se para avaliar a monografia do acadêmico **ÍTALO DE PAULA BELLOZI**, intitulada:
MODELO DE PREVISÃO DE FATURAMENTO NO SETOR MOVELEIRO: UM ESTUDO DE CASO.

Após primeira avaliação, resolveu a Banca sugerir alterações ao texto apresentado, conforme relatório sintetizado pelo orientador. A Banca, delegando ao orientador a observância das alterações propostas, resolveu **APROVAR** a referida monografia.

ASSINATURA ELETRÔNICA DOS PROFESSORES AVALIADORES



Documento assinado eletronicamente por **Alexandre Zanini, Professor(a)**, em 18/02/2025, às 17:43, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Rogério Silva de Mattos, Professor(a)**, em 19/02/2025, às 06:58, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **2254131** e o código CRC **A5DCBF44**.

AGRADECIMENTO

Primeiramente, gostaria de expressar minha gratidão ao professor Dr. Alexandre Zanini por todo o aprendizado em suas disciplinas, por sua orientação neste trabalho e, principalmente, por ter me introduzido ao campo das séries temporais, onde encontrei minha vocação como aluno de Economia. Ao professor Dr. Rogério Mattos, agradeço pela participação como membro da banca examinadora e pelos conhecimentos transmitidos em suas disciplinas de Econometria III e Aprendizado de Máquina, os quais tenho certeza de que serão de suma importância em minha carreira.

Ao pesquisador Dr. Glauco Carvalho, meu orientador de estágio, agradeço por fundamentar a ponte entre a teoria acadêmica e a prática profissional, essencial não apenas para consolidar este estudo, mas também para compreender como um economista atua na realidade. Junto a ele, agradeço à Embrapa Gado de Leite pela oportunidade de estágio, local onde adquiri conhecimentos que enriqueceram minha formação, e à Universidade Federal de Juiz de Fora, pela estrutura e oportunidades em projetos que tornaram minha graduação possível.

A Carlos Augusto, meu padrinho, dedico um agradecimento especial por viabilizar este estudo ao ceder a base de dados que fundamentou toda a análise. Sem esse gesto, este trabalho não existiria. A Lázaro Cordeiro, amigo de faculdade, expressei meu profundo reconhecimento pelo auxílio na escritura da monografia e por sua disponibilidade, que foram fundamentais. Aos amigos e companheiros de faculdade, Pedro, Eduardo, Gustavo e Pablo, agradeço pela parceria ao longo dos anos de curso e pelo apoio mútuo, que tornaram essa jornada mais leve. À Poliana, minha namorada, dedico este marco pelo seu apoio emocional, compreensão nos momentos de dificuldade e, sobretudo, por sua presença constante ao meu lado.

À minha tia Mariza, agradeço por ter me acolhido em sua casa durante todos esses anos de faculdade, proporcionando-me um ambiente estável para me dedicar aos estudos. Ao meu primo Carlos, meu reconhecimento pelo apoio constante e incentivos em vários momentos desta jornada.

Aos meus pais, Marcelo e Iasmirine, e ao meu irmão, Tales, agradeço por serem minha base, por acreditarem em meu potencial mesmo quando eu duvidava e por transformarem nossa casa em um porto seguro para meus objetivos. E a todos da minha família e amigos próximos que me apoiaram até o ponto em que estou hoje — meus primos, tios, tias, avó e companheiros —, muito obrigado a todos.

RESUMO

Este trabalho teve como objetivo aplicar e avaliar métodos de previsão de faturamento no setor moveleiro, utilizando o Método de Amortecimento Exponencial (MAE) e o modelo ARIMA, a partir de uma série temporal de dados históricos de uma fábrica de móveis entre janeiro de 2017 e novembro de 2024. A pesquisa incluiu uma análise *in-sample* e *out-of-sample* para comparar o desempenho dos modelos em termos de ajuste e capacidade preditiva, considerando métricas como MAPE, MAD e R^2 ajustado. O MAE foi identificado como o melhor modelo para horizontes de previsão mais longos, destacando-se pela capacidade de capturar tendências de crescimento e padrões sazonais na série histórica. As projeções indicaram uma continuidade do crescimento do faturamento, com sazonalidade nos meses finais do ano, alinhada às características do setor. A análise reforça a relevância da previsão como ferramenta estratégica para o planejamento financeiro, permitindo que empresas ajustem operações, otimizem recursos e tomem decisões informadas em um mercado competitivo. Como contribuição, o estudo oferece uma aplicação prática de métodos estatísticos no setor moveleiro.

Palavras-chave: previsão de faturamento, setor moveleiro, séries temporais, Método de Amortecimento Exponencial, modelo ARIMA.

ABSTRACT

This study aimed to apply and evaluate revenue forecasting methods in the furniture sector, using the Exponential Smoothing Method (ESM) and the ARIMA model, based on a time series of historical data from a furniture factory between January 2017 and November 2024. The research included in-sample and out-of-sample analyses to compare the models' performance in terms of fit and predictive ability, considering metrics such as MAPE, MAD, and adjusted R^2 . The ESM was identified as the most robust model for longer forecasting horizons, standing out for its ability to capture growth trends and seasonal patterns in the historical series. The projections indicated continued revenue growth with marked seasonality in the year's final months, aligned with the sector's characteristics. The analysis reinforces the relevance of forecasting as a strategic tool for financial planning, enabling companies to adjust operations, optimize resources, and make informed decisions in a competitive market. As a contribution, the study provides a practical application of statistical methods in the furniture sector.

Keywords: revenue forecasting, furniture sector, time series, Exponential Smoothing Method, ARIMA model.

LISTA DE ILUSTRAÇÕES

Figura 1: Procedimento de <i>out-of-sample rolling evaluation</i>	34
Figura 2: Faturamento Mensal de janeiro - 2017 a novembro - 2024.....	36
Figura 3: Faturamento da fábrica de móveis (R\$) – período de janeiro -2017 a novembro - 2025.....	42
Figura 4: Função de Autocorrelação do Erro – MAE	44

LISTA DE TABELAS

Tabela 1: Resumo das características teóricas da FAC e da FACP dos modelos AR(p), MA(q) e ARMA (p,q)	30
Tabela 2: Análise In-Sample e Out-Of-Sample.....	39
Tabela 3: Parâmetros do MAE.....	40
Tabela 4: Índices Sazonais.....	41
Tabela 5: Previsões dos faturamentos (R\$) – Intervalo de confiança de 95%	42
Tabela 6: Faturamento anualizado (R\$)	43

LISTA DE ABREVIATURAS E SIGLAS

ABIMÓVEL	Associação Brasileira das Indústrias do Mobiliário
MAE	Método de Amortecimento Exponencial
MBJ	Metodologia Box & Jenkins
ARIMA	<i>AutoRegressive Integrated Moving Average</i>
FAC	Função de Autocorrelação do Erro
MAPE	<i>Mean Absolute Percentual Error</i>
MAD	<i>Mean Absolute Deviation</i>
GMRAE	<i>Geometric Mean Relative Absolute Error</i>

SUMÁRIO

1. INTRODUÇÃO:	12
2. REVISÃO DE LITERATURA:	16
2.1 PLANEAMENTO FINANCEIRO:	16
2.2 MÉTODOS DE PREVISÃO APLICADOS:.....	18
3. METODOLOGIA:	20
3.2.2 MÉTODO DE AMORTECIMENTO EXPONENCIAL:.....	21
3.1.1 DESCRIÇÃO E ATUALIZAÇÃO PARAMÉTRICA:	22
3.1.2 AMORTECIMENTO EXPONENCIAL SIMPLES:.....	23
3.1.3 AMORTECIMENTO EXPONENCIAL COM TENDÊNCIA: MODELO DE HOLT:.....	23
3.1.4 AMORTECIMENTO EXPONENCIAL COM TENDÊNCIA E SAZONALIDADE: MODELO DE HOLT-WINTERS:	24
3.1.5 PROCEDIMENTO DE OTIMIZAÇÃO E APLICAÇÃO DO <i>DAMPED TREND</i> :25	
3.1.6 EQUAÇÕES DE PREVISÕES:	26
3.2 MODELOS BOX & JENKINS:	27
3.2.1 FUNDAMENTO TEÓRICO:.....	27
3.2.2 A METODOLOGIA BOX & JENKINS:	29
3.3 AVALIAÇÃO DO DESEMPENHO PREDITIVO DO MODELO DE PREVISÃO:.....	31
3.3.1 AVALIAÇÃO <i>IN-SAMPLE</i> :.....	31
3.3.2 ERRO MÉDIO ABSOLUTO PERCENTUAL (MAPE):.....	31
3.3.3 ERRO MÉDIO ABSOLUTO (MAD):	32
3.3.4 COEFICIENTE DE DETERMINAÇÃO AJUSTADO ($R^2_{ajustado}$):	32
3.3.5 AVALIAÇÃO <i>OUT-OF-SAMPLE E ROLLING EVALUATION</i>	33
3.4 SELEÇÃO DO MELHOR MODELO:.....	35
4 ANÁLISE DE DADOS E RESULTADOS	36
4.1 ANÁLISE DA SÉRIE HISTÓRICA	36
4.2 COMPETIÇÃO DE MÉTODOS.....	37
4.2.1 METODOLOGIA DE AVALIAÇÃO	37
4.2.2 ANÁLISE DO MÉTODO DE AMORTECIMENTO EXPONENCIAL .	38
4.2.3 ANÁLISE DO ARIMA (1,1,0) (1,0,0)	38
4.3 ESCOLHA DO MELHOR MODELO	39
4.4 PREVISÃO DO FATURAMENTO DA FÁBRICA DE MÓVEIS	40
5. CONCLUSÃO	45
6 REFERÊNCIAS:	47

1. INTRODUÇÃO:

A previsão de mercado, bem como o planejamento financeiro, é uma atividade crucial para qualquer setor industrial, desempenhando um papel fundamental na orientação das estratégias de negócios e no sucesso das empresas. No entanto, sua importância é ainda mais evidente em setores altamente dinâmicos e competitivos, como o setor moveleiro. Tendo isso em mente, segundo Faller & Almeida (2014), “sabe-se, no entanto, que somente por meio da análise contínua das interações entre as empresas e o seu ambiente é possível estabelecer objetivos adequados e melhor aproveitar seus recursos”, o que por sua vez leva a crer que as empresas possam definir metas apropriadas e aproveitar ao máximo seus recursos, é fundamental realizar uma análise constante das interações que ocorrem entre as empresas e o ambiente em que estão inseridas.

Em outras palavras, o sucesso das empresas está intrinsecamente ligado à sua capacidade de compreender como as influências externas afetam suas operações e, com base nessa compreensão, estabelecer metas e utilizar eficientemente os recursos disponíveis. Essa análise contínua ajuda as empresas a se adaptarem às mudanças do ambiente e a tomar decisões informadas para alcançar seus objetivos.

A indústria de móveis é classificada como um setor tradicional da economia, caracterizado por sua falta de dinamismo tecnológico, sua alta dependência de mão de obra manual e o uso de materiais de origem animal ou vegetal (ROSA, 2007). No entanto, o setor se destaca por não apresentar barreiras substanciais à entrada de novos participantes relacionadas às economias de escala, o que significa que empresas que desejam ingressar no mercado de móveis não enfrentam obstáculos significativos devido ao tamanho ou à escala da produção. Essas características o distinguem das empresas

industriais modernas que muitas vezes se apoiam em tecnologia avançada e economias de escala para se destacarem (ROSA, 2007).

Em adição às complexidades do setor moveleiro, é importante considerar o panorama geral da indústria. De acordo com a Associação Brasileira das Indústrias do Mobiliário (ABIMÓVEL) – (2023), o setor moveleiro brasileiro, no ano de 2021, foi composto por 21.700 mil empresas. Essas empresas têm realizado investimentos significativos, totalizando mais de R\$ 1,26 bilhões. Além disso, a produção de peças atingiu a marca de 443,2 milhões.

No contexto das exportações, o setor moveleiro é uma parte fundamental da economia brasileira, com destaque para os Estados Unidos, que representam 31,9% das exportações, seguidos por Uruguai (10,9%), Chile (6,6%), Reino Unido (6,5%) e Paraguai (4,0%). O faturamento da indústria moveleira brasileira em 2023 atingiu R\$ 81,667 bilhões em receita, destacando sua importância econômica. (ABIMÓVEL) – (2023)

O setor moveleiro também desempenha um papel fundamental na geração de empregos, contribuindo com 270.267 mil trabalhadores diretos, e 1,1 milhão de trabalhadores indiretos (ABIMÓVEL) – (2023). As exportações são dominadas por móveis de madeira, representando 83,7% do total, seguidos por estofados (10,2%) e móveis de metal (3,4%). É importante destacar que o setor moveleiro brasileiro é a 8ª cadeia que mais emprega, contribuindo com 1,2% do Produto Interno Bruto (PIB) do país e classificando o Brasil como o 6º maior produtor mundial de móveis. (ABIMÓVEL) – (2022)

Em termos de comércio exterior, o setor moveleiro brasileiro exportou US\$ 937,9 milhões em móveis e colchões, com presença em 167 destinos de exportação. As importações totalizaram US\$ 262,4 milhões. No cenário global, o Brasil ocupa a posição de 26º maior exportador e 56º maior importador de móveis prontos e colchões. Esses dados, disponibilizados pela Abimóvel, demonstram a relevância do setor moveleiro na economia brasileira e global, enfatizando a necessidade de estratégias de previsão de mercado eficazes para sustentar o crescimento contínuo e a competitividade da indústria. (ABIMÓVEL) – (2022)

“A previsão ainda permanece como uma das ferramentas mais poderosas e importantes no auxílio do planejamento de qualquer empresa, independente da sua localização e tamanho” (SOARES, 2019). Dito isso, a previsão é uma

atividade crítica para direcionar as estratégias de negócios e impulsionar o sucesso das empresas, sobretudo em setores dinâmicos e altamente competitivos, como o setor moveleiro. A indústria de móveis é notória por sua constante evolução, estreitamente ligada às tendências de design, mudanças nos estilos de vida e às preferências em constante mutação dos consumidores. Essa complexidade torna a previsão de mercado no setor moveleiro um desafio intrigante, exigindo uma abordagem fundamentada em dados sólidos. (BESSA, 2023)

A escolha deste tema se justifica pelo papel que a previsão de mercado e o planejamento financeiro desempenham, dentro desse tipo de indústria, e como destacado pela Associação Brasileira das Indústrias do Mobiliário (ABIMÓVEL) – (2023), é composta por um vasto número de empresas e envolve investimentos, produzindo milhões de peças, e como pode ser complementado por Tarapanoff (2001, p.43), na sociedade de informação ou na “sociedade pós-industrial”, [...] a hegemonia econômica e social é exercida não mais pelos proprietários dos meios de produção, e sim por aqueles que administram o conhecimento e podem planejar a inovação.

Do ponto de vista prático, a previsão de mercado é vital para a tomada de decisões informadas e estratégicas no setor. Investidores, empresários e estrategistas precisam de informações precisas para orientar suas ações, seja na gestão de operações ou na busca de oportunidades de mercado. Nesse contexto, este trabalho visa preencher uma lacuna na compreensão do setor moveleiro, oferecendo uma perspectiva prática sobre como a previsão de mercado e de fluxos financeiros pode ser aplicada. Salienta-se que o foco do trabalho é o planejamento financeiro.

Dada a importância do setor moveleiro e das técnicas de previsão de mercado e de fluxos financeiros, o objetivo geral deste trabalho consiste em auxiliar o planejamento financeiro de uma empresa do setor de móveis através da aplicação de métodos de previsão no estudo de uma série temporal de dados coletados desta empresa do setor moveleiro, a qual será referida como uma empresa anônima. A meta é projetar o faturamento esperado nos meses subsequentes, com o intuito de simplificar a criação de um planejamento financeiro eficaz, que capacite a empresa a administrar suas operações com eficiência e antecipar as necessidades financeiras. Esta projeção visa aprimorar

a capacidade da empresa de se adaptar às mudanças do mercado e de tomar decisões de negócios embasadas em dados sólidos, contribuindo assim para sua sustentabilidade e crescimento a longo prazo no setor moveleiro.

Os objetivos específicos deste trabalho baseiam-se em coletar e organizar dados históricos de uma empresa anônima, aplicar métodos estatísticos e matemáticos para desenvolver um modelo de projeção de faturamento da empresa para os próximos meses, analisar a qualidade e a significância das projeções geradas pelo modelo e avaliar como essas projeções podem ser utilizadas de forma efetiva para auxiliar a tomada de decisão. Em conjunto, esses objetivos buscam aprofundar a compreensão sobre como a previsão de faturamento pode ser aplicada no contexto dessa empresa, demonstrando como a análise estatística e matemática dos dados históricos pode fornecer informações valiosas para investidores e estrategistas, auxiliando-os na tomada de decisões de investimento a longo prazo.

Este trabalho está estruturado em cinco capítulos. O capítulo 1 se dá por essa introdução. No capítulo 2 é apresentada parte da literatura base desse trabalho, revisando assuntos como planejamento financeiro e métodos de previsão aplicados. No capítulo 3 são apresentadas as metodologias utilizadas para realizar as previsões com base nos modelos ARIMA e Amortecimento Exponencial. O capítulo 4 discute os dados utilizados para a realização das previsões e os resultados obtidos pelos modelos. Por fim, o capítulo 6 traz as conclusões deste trabalho.

2. REVISÃO DE LITERATURA:

2.1 PLANEJAMENTO FINANCEIRO:

O planejamento financeiro é uma ferramenta utilizada para a gestão eficaz das finanças pessoais e empresariais. Ele envolve a definição de metas financeiras, a alocação de recursos de forma estratégica e o acompanhamento regular das despesas e receitas. Seja para indivíduos ou organizações, o planejamento financeiro desempenha um papel na busca pela segurança financeira, na realização de objetivos e na garantia de estabilidade econômica.

Planejamento financeiro estabelece diretrizes de mudança na empresa. Essas diretrizes devem incluir uma identificação das metas financeiras da empresa, uma análise das diferenças entre tais metas e situação financeira corrente da empresa e um pronunciamento quanto às providências necessárias para que a empresa atinja suas metas financeiras. (ROSS & WESTERFIELD, 2002, p.589)

Consistindo em antecipar e planejar as ações necessárias para atingir metas financeiras específicas, o planejamento envolve a preparação e coordenação cuidadosas de atividades relacionadas com finanças para atingir os objetivos financeiros desejados. Nas palavras de Gitman (2001), o planejamento financeiro mapeia os caminhos que guiarão, coordenarão e controlarão as ações de empresas e famílias para atingir seus objetivos financeiros.

O planejamento financeiro pessoal é um aspecto importante das operações nas empresas e famílias, pois ele mapeia os caminhos para guiar, coordenar e controlar as ações das empresas e das famílias para atingir seus objetivos. (GITMAN 2001, p. 434)

Complementando esse raciocínio, de acordo Frankenberg (1999), “essa estratégia pode estar voltada para curto, médio ou longo prazo, e não é tarefa simples.” Essa estratégia pode ser desenhada de acordo com os objetivos específicos de curto ou longo prazo de cada indivíduo. Basicamente, o planejamento financeiro pessoal consiste em definir metas financeiras específicas, criar um roteiro estruturado para alcançá-las e construir riqueza de maneira planejada e disciplinada.

Segundo Ross et al., (1995), “O planejamento financeiro formaliza o método pelo qual as metas financeiras tanto das empresas quanto das famílias devem ser alcançadas.” Isto significa que o planejamento financeiro não é apenas

uma ferramenta para definir metas, mas também um processo estruturado para determinar como atingir essas metas.

Conforme discute Cerbasi (2009), o planejamento financeiro pessoal é essencial para o uso eficaz da renda, possibilitando decisões sábias de investimentos, controle de custos e construção de riqueza sólida. O planejamento financeiro pessoal é uma abordagem estratégica que se concentra na acumulação de ativos e valor no longo prazo. Abrangendo metas de curto, médio e longo prazo, fornece uma estratégia abrangente para sua vida financeira.

É no começo do mês, e não no final, que você tem condições de mandar no dinheiro e não deixar que ele mande em você. Antes de começar o mês, estude o orçamento do mês que acaba de fechar e veja quais os gastos quer mudar ou reduzir, estabelecendo metas objetivas e, de preferência, por escrito. (CERBASI, 2009, p. 41).

Peter Drucker (1974) enfatiza que a tomada de decisão é apenas uma das muitas tarefas de um gestor. Normalmente, esta tarefa não ocupa muito do seu tempo. No entanto, Drucker enfatiza que a tomada de decisão é uma função importante e especializada dos gestores e que gestores eficazes devem tomar decisões eficazes. Ele enfatiza a importância de um processo sistemático de tomada de decisão com elementos claramente definidos e uma sequência de fases bem estruturada. Isto exige que os gestores adotem uma abordagem deliberada e consciente e garantam que as suas decisões estão alinhadas com as metas e objetivos da organização, em vez de tomarem decisões de forma arbitrária ou impulsiva.

A tomada de decisão é apenas uma das tarefas de um gerente. Normalmente, não exige mais que uma pequena fração de seu tempo. Mas tomar decisões é tarefa específica do gerente (...). Gerentes eficazes, portanto, tomam decisões eficazes (...) por meio de um processo sistemático, com elementos claramente definidos e em uma perfeita sequência de fases. (DRUCKER, 1974, p.124)

O planejamento financeiro é um processo abrangente e dinâmico que desempenha um papel importante na gestão financeira das organizações e na vida das pessoas. Começa com a definição de objetivos claros e depois evolui para planos estratégicos de longo prazo e planos operacionais de curto prazo. A gestão financeira garante que seus planos sejam executados conforme planejado e permite que você se adapte a mudanças inesperadas. Os

procedimentos aplicam-se tanto às empresas como às famílias e a sua importância é inegável. (SILVA SOBRINHO & TOFOLI, 2017)

2.2 MÉTODOS DE PREVISÃO APLICADOS:

A importância da previsão na indústria é inegável, pois a capacidade de prever eventos e tendências desempenha um papel importante na tomada de decisões estratégicas. Em seu artigo, Penha (2020) destaca que a previsão é crucial e dá um exemplo concreto, trabalhando com projeção de faturamento de uma empresa júnior, de como ela pode se tornar uma ferramenta essencial. Adicionalmente, Esposito (2022) contribui para esse entendimento, reforçando a importância da previsão. A autora faz a aplicação de modelos de previsão sobre dados diários de um ponto de venda de jornais específico. Com a ajuda da previsão, as empresas podem planejar com antecedência, otimizar recursos, reduzir custos e minimizar riscos.

Mantendo essa vertente de pensamento, a previsão no setor moveleiro é reforçada por estudos que exploram suas aplicações práticas e os benefícios obtidos. Furukawa et al. (2024) destacaram como a adoção de metodologias preditivas em uma empresa moveleira de Manaus contribuiu para otimizar a produção, reduzir desperdícios e aprimorar a gestão de estoques, aumentando a competitividade no mercado regional. Da mesma forma, Moro et al. (2016) demonstraram, por meio da aplicação do modelo Holt-Winters em uma indústria moveleira, a eficácia desse método em capturar tendências e sazonalidades específicas do setor, permitindo a elaboração de projeções mais assertivas e fundamentadas.

Outro estudo que pode ser citado ao trabalhar com modelos de previsão é Medeiros (2022), ao apresentar um trabalho cujo objetivo principal é o estudo de caso para a estimação de um modelo de previsão para o faturamento de uma padaria. Assim como a pesquisa de Nascimento (2022), que tem como foco construir um modelo de previsão de faturamento no segmento de moda por meio da análise de séries temporais para criar previsões e contribuir para a criação de planos financeiros.

Com esse parâmetro, a previsão não deve ser vista como uma função isolada, mas como parte essencial da gestão da cadeia de suprimentos

(KERKKANEN et al., 2009). Embora muitas empresas meçam a precisão das previsões, a avaliação dos impactos dos erros de previsão na gestão da cadeia de suprimentos geralmente não é realizada com a mesma atenção. É um processo complexo que analisa vários dados, tendências e comportamentos do consumidor para prever como um mercado ou indústria se comportará no futuro. Essa análise é a base para a tomada de decisões estratégicas que impactam diretamente no sucesso e na sobrevivência da sua empresa. No entanto, é importante reconhecer que as previsões nunca são perfeitas e é importante medir, contabilizar e avaliar os erros de previsão para compreender quão próximas ou distantes da realidade as previsões estão. Quando as diferenças entre os resultados previstos e reais ultrapassam um nível aceitável, é essencial investigar as razões dessas diferenças e atribuir responsabilidade pela melhoria das previsões futuras (PEINADO & REIS GRAEML, 2007).

Em linha com este entendimento, (MAKRIDAKIS & WHEELWRIGHT, 1973) enfatizaram a importância de escolher sabiamente os métodos de previsão e observaram que a precisão não é o único fator a considerar na escolha de um método. Eles demonstram a necessidade de uma abordagem equilibrada e consideram fatores como horizonte temporal, padrões de dados e aplicabilidade ao escolher o método de previsão mais apropriado para tomar decisões de negócios informadas. Pode-se reconhecer que outros critérios também desempenham um papel importante e estratégico.

Além disso, é fundamental estabelecer procedimentos para seleção do melhor método em diferentes situações, levando em consideração fatores como período de tempo, padrões de dados e aplicabilidade. Finalmente, as organizações devem fornecer o apoio necessário para a adaptação e utilização eficaz das técnicas de previsão escolhidas, garantindo que sejam integradas de forma eficiente no processo de tomada de decisão. Essas quatro áreas são críticas para o sucesso dos sistemas preditivos e para melhorar a qualidade das decisões de negócios.

A elaboração de um sistema de forecasting requer, de uma organização, conhecimento e habilidade em 4 áreas básicas: (i) identificação e definição dos problemas a serem tratados no forecasting; (ii) aplicação dos métodos de forecasting; (iii) procedimentos para seleção do método apropriado a situações específicas; e (iv) suporte organizacional para adaptar e usar os métodos de forecasting requeridos. (PELLEGRINI & FOGLIATTO, 2001, p.44)

3. METODOLOGIA:

Com o objetivo de estimar o desempenho do faturamento no setor moveleiro de uma empresa anônima, com base na série temporal de suas transações passadas, será recorrido a um conjunto de técnicas analíticas. Essas estratégias incluem a aplicação do Método de Amortecimento Exponencial (MAE)¹ e do Método de Box & Jenkins (MBJ)². Cada uma destas abordagens será aplicada e avaliada pela sua capacidade de desvendar padrões históricos e prever com precisão tendências futuras. Na indústria moveleira, a importância de tais previsões se destacam devido a seu apoio na gestão de estoques, o planejamento da produção e a tomada de decisões estratégicas, impulsionando a eficiência operacional e um sucesso sustentável. Dito isso, cabe discutir os conceitos de series temporais e dos modelos citados. Importante salientar que esta seção está fundamentada em Zanini (2023).

A série temporal é um conjunto de observações de uma variável específica dispostas em ordem cronológica, geralmente com intervalos uniformes (ZANINI, 2023). Cada observação é denotada por Z_t , onde "t" representa o tempo e "Z" é o valor da variável. Essas séries podem ter diferentes periodicidades, como dados diários, semanais, mensais ou anuais, dependendo do contexto. Para caracterizar uma série temporal é importante que os valores observados tenham algum tipo de relação contínua, ou seja, exista uma dependência temporal entre os valores observados (ZANINI, 2023).

Com isso, o conceito de processo estocástico se introduz por uma sequência temporal de variáveis aleatórias. Este é um modelo que descreve as probabilidades subjacentes de um conjunto de observações. Cada ponto no tempo 't' representa uma variável aleatória, e o processo aleatório pode ser contínuo ou discreto. Uma sequência temporal, por outro lado, é uma amostra finita de observações desse processo aleatório (ZANINI, 2023).

Ao modelar sequências temporais, muitas vezes, as funções de distribuição do processo estocástico são desconhecidas. Portanto, os analistas

¹ Montgomery & Johnson (1990).

² Box & Jenkins (1994)

fazem suposições, como estacionariedade e ergodicidade. A estacionariedade implica que o processo não muda com o tempo, e a ergodicidade sugere que uma única realização contém todas as estatísticas necessárias. A análise de sequências temporais pode ocorrer no domínio do tempo ou no domínio da frequência. No domínio do tempo, observa-se a evolução temporal e mede-se a dependência serial com funções de autocovariância e autocorrelação. No domínio da frequência, estuda-se a frequência dos eventos. Isto é útil quando componentes harmônicos estão presentes. A previsão envolve estimar valores futuros com base em informações atuais e históricas. Os modelos preditivos podem ser autoprojativos, utilizando apenas o histórico da própria sequência, ou causais, incorporando informações de outras variáveis. Além dos modelos de regressão, existem vários modelos preditivos, como suavização exponencial e modelos ARIMA (ZANINI, 2023).

Atenta-se que, neste trabalho monográfico, serão trabalhados dados no domínio do tempo, ou seja, os dados serão indexados mensalmente. Através do estudo da evolução destes dados no tempo, serão estimados modelos via Método de Amortecimento Exponencial (MAE) e Método de Box & Jenkins (MBJ). Será feita ainda uma competição entre estes dois métodos através de uma análise recursiva fora da amostra, onde será selecionado como modelo vencedor aquele que minimizar o erro de previsão fora da amostra, ou seja, aquele que apresentar um bom poder de generalização. O modelo vencedor será utilizado então para o cálculo das previsões de faturamento da empresa em questão.

3.2.2 MÉTODO DE AMORTECIMENTO EXPONENCIAL:

O Método de Amortecimento Exponencial (MAE) é uma técnica de modelagem de séries temporais que se fundamenta em atribuir pesos decrescentes às observações mais defasadas, ajustando assim a projeção futura com base nas informações mais recentes. Este método é útil para séries que apresentam uma estabilidade relativa, sem mudanças abruptas, e permite atualizações dinâmicas dos parâmetros a cada novo dado disponível. O objetivo do MAE é modelar e prever o comportamento de uma série temporal com base

em um sistema de amortecimento que privilegia as observações mais recentes. (Zanini, 2023).

3.1.1 DESCRIÇÃO E ATUALIZAÇÃO PARAMÉTRICA:

Conforme dito no início dessa seção, uma série temporal pode ser definida como um conjunto de observações de uma variável ordenadas no tempo, em intervalos regulares, e que apresentam correlação serial. O MAE tem por objetivo matematizar essa correlação para projetar o comportamento futuro da série. Suponha-se que uma série temporal Z_1, Z_2, \dots, Z_t , represente a demanda mensal de um produto com nível médio constante ao longo do tempo. A previsão para essa série é dada por:

$$Z_t = a(T) + \varepsilon_t \quad (1)$$

onde:

Z_t representa o valor observado no período t ;

$a(T)$ é o nível médio da série no instante T ;

ε_t é o erro de previsão, assumido como ruído branco $N(0, \sigma^2)$.

A estimativa do parâmetro $a(T)$ pode ser feita por métodos simples, como o modelo ingênuo, que utiliza o último valor da série como previsor:

$$\hat{Z}_T(\tau) = Z_T \quad (2)$$

onde:

$\hat{Z}_T(\tau)$ é a previsão de τ passos à frente;

\hat{Z}_T é o último valor disponível;

τ é o horizonte de previsão.

Outras abordagens incluem a média simples ou a média móvel dos dados históricos, que, embora ofereçam uma estimativa inicial para o nível, atribuem o mesmo peso a todas as observações, independentemente de sua idade.

3.1.2 AMORTECIMENTO EXPONENCIAL SIMPLES:

Para superar a limitação da média simples, o MAE introduz pesos decrescentes às observações passadas, permitindo que as informações mais recentes influenciem mais a previsão. A atualização do parâmetro $a(T)$ com amortecimento exponencial é dada pela equação:

$$S_T = \alpha \cdot Z_T + (1 - \alpha) \cdot S_{T-1} \quad (3)$$

onde:

S_T é o valor amortecido da série no período T;

α é a constante de amortecimento, que varia entre 0 e 1, controlando a influência das observações recentes.

Essa formulação, conhecida como Modelo de Brown, ajusta automaticamente o peso das observações com base em sua “idade” relativa na série (Zanini, 2023).

3.1.3 AMORTECIMENTO EXPONENCIAL COM TENDÊNCIA: MODELO DE HOLT:

Quando a série apresenta uma tendência, o Modelo de Holt se torna uma aplicável, adicionando um parâmetro para capturar a taxa de crescimento ou decréscimo ao longo do tempo:

$$Z_t = \alpha_1(T) + \alpha_2(T) \cdot t + \epsilon_t \quad (4)$$

$\alpha_1(T)$: parâmetro de nível no instante T;

$\alpha_2(T)$: parâmetro de tendência;

T é o tempo.

A atualização dos parâmetros de nível e tendência é feita conforme as seguintes equações:

$$\widehat{\alpha}_1(T) = \alpha \cdot Z_T + (1 - \alpha) \cdot [\widehat{\alpha}_1(T - 1) + \widehat{\alpha}_2(T - 1)] \quad (5)$$

$$\widehat{\alpha}_2(T) = \beta \cdot [\widehat{\alpha}_1(T) - \widehat{\alpha}_1(T - 1)] + (1 - \beta) \cdot [\widehat{\alpha}_2(T - 1)] \quad (6)$$

onde:

α é a constante de amortecimento para o nível;

β é a constante de amortecimento para a tendência.

Essas constantes determinam a suavidade da série, com valores altos de α e β promovendo maior resposta a mudanças recentes (Zanini, 2023).

3.1.4 AMORTECIMENTO EXPONENCIAL COM TENDÊNCIA E SAZONALIDADE: MODELO DE HOLT-WINTERS:

Em séries temporais com sazonalidade, o Modelo de Holt-Winters expande o MAE ao incorporar um componente sazonal. Este modelo é adequado para séries com comportamento cíclico, e é representado pela equação:

$$Z_t = (\alpha_1(T) + \alpha_2(T) \cdot t) \cdot \rho_t + \epsilon_t \quad (7)$$

Onde:

$\alpha_1(T)$: parâmetro de nível no instante T;

$\alpha_2(T)$: parâmetro de tendência no instante T;

t: variável tempo (t = 1, 2, ..., T sendo T é a quantidade de dados existentes);

ρ_t é o fator sazonal para o período T;

ϵ_t é o erro de previsão.

A atualização dos parâmetros segue as fórmulas:

$$\widehat{\alpha}_1(T) = \alpha \cdot \frac{Z_T}{\widehat{\rho}_t(T - 1)} + (1 - \alpha) \cdot [\widehat{\alpha}_1(T - 1) + \widehat{\alpha}_2(T - 1)] \quad (8)$$

$$\widehat{\alpha}_2(T) = \beta \cdot [\widehat{\alpha}_1(T) - \widehat{\alpha}_1(T-1)] + (1 - \beta) \cdot [\widehat{\alpha}_2(T-1)] \quad (9)$$

$$\widehat{\rho}_t(T) = \gamma \cdot \frac{Z_T}{\widehat{\alpha}_1(T)} + (1 - \gamma) \cdot [\widehat{\rho}_t(T-1)] \quad (10)$$

onde L é o comprimento do ciclo sazonal, como 12 para dados mensais, e γ é a constante de amortecimento sazonal.

Essas equações permitem ao modelo capturar a sazonalidade ao ajustar continuamente o peso dos dados passados com base na sua relevância temporal (Zanini, 2023).

3.1.5 PROCEDIMENTO DE OTIMIZAÇÃO E APLICAÇÃO DO DAMPED TREND:

As constantes de amortecimento α , β e γ são determinadas por otimização, comumente realizadas por softwares de previsão que minimizam o erro sobre o histórico de dados. Em casos de tendência acentuada, o uso de um parâmetro adicional, o *damped trend*, reduz a inclinação da tendência ao longo do tempo, evitando previsões explosivas em horizontes mais distantes.

O modelo final com a tendência amortecida (*damped trend*) é expresso por:

$$Z_t = \widehat{\alpha}_1(T) + \sum_{j=1}^{\tau} \varphi^{j-1} \cdot \widehat{\alpha}_2(T) \cdot \tau + \epsilon_t \quad (11)$$

ϕ é o hiperparâmetro para amortecer a tendência, com $0 < \phi < 1$, que limita o impacto da tendência nos valores futuros, especialmente em projeções de longo prazo.

3.1.6 EQUAÇÕES DE PREVISÕES:

Conforme discutido anteriormente, o Método de Amortecimento Exponencial (MAE) oferece diferentes modelos de previsão que podem ser ajustados conforme o comportamento da série temporal. A seguir, apresentam-se as equações de previsão correspondentes a cada situação.

Para séries com dados constantes, a previsão \hat{Z}_t é dada pela estimativa do nível no instante T:

$$\hat{Z}_t(\tau) = \hat{\alpha}_1(T) + \epsilon_t \quad (12)$$

Para séries com dados que apresentam tendência, utiliza-se a estimativa do nível $\hat{\alpha}_1(T)$ e da tendência $\hat{\alpha}_2(T)$ para calcular a previsão τ períodos à frente, conforme a seguinte expressão:

$$\hat{Z}_t(\tau) = \hat{\alpha}_1(T) + \hat{\alpha}_2(T) \cdot \tau + \epsilon_t \quad (13)$$

Quando há dados com tendência e sazonalidade, a previsão é ajustada pelo fator sazonal $\hat{\rho}_p$, conforme representado pela fórmula:

$$\hat{Z}_t(\tau) = (\hat{\alpha}_1(T) + \hat{\alpha}_2(T) \cdot \tau) \cdot \hat{\rho}_p(T + \tau)(T) + \epsilon_t \quad (14)$$

Onde:

$\hat{\alpha}_1(T)$: Estimativa do nível atualizado no em T;

$\hat{\alpha}_2(T)$: Estimativa do parâmetro de tendência em T;

$\hat{\rho}_p(T + \tau)$: Estimativa do parâmetro sazonal para o período $(T + \tau)$;

τ : Horizonte de previsão.

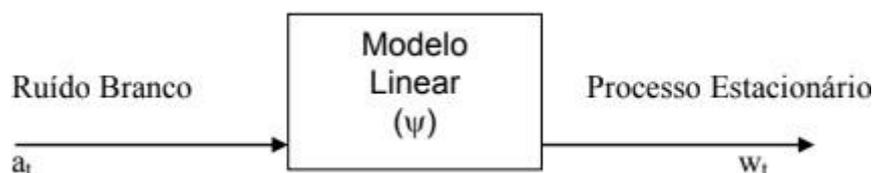
Para modelos de Holt-Winters com tendência amortecida (*damped trend*), incluir-se o parâmetro ϕ na previsão para controlar o impacto da tendência no longo prazo, aplicando-o conforme necessário (Zanini, 2023).

3.2 MODELOS BOX & JENKINS:

Os modelos de Box & Jenkins, também conhecidos como ARIMA (*Autoregressive Integrated Moving Average*), constituem uma classe de modelos estatísticos utilizados para análise e previsão de séries temporais.

3.2.1 FUNDAMENTO TEÓRICO:

A base teórica desses modelos é a Teoria Geral de Sistemas Lineares, a qual afirma que ao aplicar um filtro linear de memória infinita em um processo de ruído branco, gera-se um processo estacionário de segunda ordem. Um processo estacionário é caracterizado pela constância de sua média e variância ao longo do tempo, o que significa que as flutuações do processo giram em torno de um valor médio estável e apresentam uma variabilidade limitada e constante (Zanini, 2023).



No contexto da modelagem Box & Jenkins, define-se o operador de atraso B (*backward shift operator*) como uma ferramenta para representar a estrutura do modelo. Esse operador permite expressar uma observação em termos de valores anteriores da série, onde $B^k Z_t = Z_{t-k}$, ou seja, o operador de atraso “desloca” a série temporal em k períodos para trás.

De acordo com a Teoria Geral de Sistemas, a representação do processo estacionário w_t por meio do operador B é dada pela relação:

$$w_t = (1 - \Psi_1 B - \Psi_2 B^2 - \dots) a_t = \Psi(B) a_t \quad (15)$$

em que:

w_t é o processo estacionário resultante;

a_t representa o ruído branco (um processo com média zero e variância constante);

$\Psi(B)$ é uma função com infinitos parâmetros que descreve a série temporal.

No entanto, o uso de uma série infinita de parâmetros torna o modelo não muito prático para aplicação real. Para contornar essa limitação, Box e Jenkins propuseram uma simplificação na qual o polinômio infinito pode ser aproximado pelo quociente de dois polinômios finitos. Essa aproximação resulta nos modelos ARMA (p, q), que integram componentes autorregressivos (AR) e de médias móveis (MA). A formulação geral do modelo ARMA (p, q) é dada por:

$$\phi(B)w_t = \theta(B)a_t \quad (16)$$

Onde:

$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_p B^p \rightarrow$ é o polinômio autorregressivo de ordem p;

$\phi(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \rightarrow$ é o polinômio de médias móveis de ordem q.

Os modelos ARMA(p,q) são utilizados para séries temporais estacionárias, nas quais a média e a variância não variam com o tempo. No entanto, para séries não estacionárias, onde a média varia ao longo do tempo, é necessária a aplicação de um operador de diferenciação para transformar a série em estacionária. Esse processo resulta nos modelos ARIMA (p, d, q), onde d indica o número de vezes que a série original deve ser diferenciada para alcançar a estacionariedade. A formulação geral do modelo ARIMA é:

$$\phi(B)\nabla^d Z_t = \theta(B)a_t \quad (17)$$

Onde:

$\nabla = (1 - B)$ é o operador de diferenciação, aplicado d vezes à série

original para eliminar sua não-estacionariedade.

3.2.2 A METODOLOGIA BOX & JENKINS:

Segundo Zanini (2023), a metodologia Box & Jenkins para modelagem de séries temporais segue um ciclo de etapas sistemáticas que incluem a identificação do modelo, a estimação dos parâmetros e a validação do modelo, buscando garantir uma representação matemática adequada e eficiente para a série.

O primeiro passo na modelagem Box & Jenkins consiste em determinar a ordem de diferenciação “d” necessária para transformar a série original em uma série estacionária. Esse processo de diferenciação elimina tendências de longo prazo, tornando a média da série aproximadamente constante ao longo do tempo. A análise visual do gráfico da série é uma técnica preliminar para avaliar a necessidade de diferenciação. Séries com tendências de crescimento ou declínio geralmente requerem uma diferenciação de ordem 1 para remover a tendência e alcançar estacionariedade. A observação da Função de Autocorrelação (FAC) também é fundamental. Uma série não estacionária geralmente apresenta uma autocorrelação que decresce lentamente ao longo dos lags, indicando a necessidade de diferenciação (Zanini, 2023).

Após a transformação da série em estacionária, define-se a estrutura do modelo, isto é, as ordens p e q correspondentes aos componentes autorregressivos (AR) e de médias móveis (MA), respectivamente. Esse processo envolve a análise da FAC e da Função de Autocorrelação Parcial (FACP). O comportamento das autocorrelações nessas funções indica a estrutura do modelo. Para modelos $AR(p)$, a FAC apresenta um comportamento de decaimento lento e contínuo, enquanto a FACP exibe um “corte” brusco após o lag p . Para modelos $MA(q)$, ocorre o inverso, a FAC apresenta um corte após o lag q , enquanto a FACP decai lentamente. Em modelos mistos $ARMA(p, q)$, tanto a FAC quanto a FACP exibem padrões de decaimento contínuo, o que requer uma análise mais aprofundada para identificar as ordens corretas. Um resumo pode ser visto na tabela 1 a seguir.

Tabela 1: Resumo das características teóricas da FAC e da FACP dos modelos AR(p), MA(q) e ARMA (p,q)

Modelo	Função de Autocorrelação (ρ^k)	Função de Autocorrelação Parcial (ϕ_{kk})
AR (p)	Infinita (Exponencial e/ou senoides amortecidas)	Finita (Corte após o lag “p”)
MA (q)	Finita (Corte após o lag “q”)	Infinita (Exponencial e/ou senoides amortecidas)
ARMA (p,q)	Infinita (Exponencial e/ou senoides amortecidas após o lag “q-p”)	Infinita (Exponencial e/ou senoides amortecidas após o lag “p-q”)

Fonte: Zanini (2023)

Após a identificação das ordens p, d e q, procede-se à estimação dos parâmetros do modelo. A técnica mais comum utilizada é o método da máxima verossimilhança, que busca os valores de parâmetros que maximizem a probabilidade de observar os dados fornecidos. Em softwares estatísticos, essa estimação é automatizada, facilitando a obtenção dos valores ótimos dos parâmetros.

A última etapa da metodologia Box & Jenkins envolve a validação do modelo ajustado. Nessa fase verifica-se a adequação do modelo aos dados e garantir que ele é capaz de capturar a estrutura da série temporal. A validação inclui o teste dos resíduos, em que ocorre uma verificação se os resíduos do modelo seguem um padrão de ruído branco, isto é, se não apresentam estrutura de autocorrelação, o que indicaria que o modelo explicou adequadamente a série. A outra validação, é o teste de sobrefixação, no qual consiste em ajustar modelos de ordem superior ao modelo identificado para confirmar a pertinência do modelo. Se os modelos superiores não melhorarem a previsão, o modelo de ordem menor é considerado adequado.

3.3 AVALIAÇÃO DO DESEMPENHO PREDITIVO DO MODELO DE PREVISÃO:

A avaliação do desempenho preditivo dos modelos de previsão é uma etapa para verificar a precisão e a confiabilidade das projeções geradas. Após a construção do modelo, é de grande importância aplicar métodos que permitam mensurar a qualidade das previsões ao comparar os valores observados e os valores ajustados pelo modelo. Esses métodos de avaliação são divididos em duas abordagens: *in-sample*, ou seja, dentro da amostra utilizada para estimar os parâmetros, e *out-of-sample*, fora da amostra, em um conjunto de dados reservado especificamente para validação. Tais avaliações são realizadas a partir de várias métricas de erro, como, por exemplo, o Erro Médio Absoluto Percentual (MAPE) e o Erro Médio Absoluto (MAD) que ajudam a mensurar a precisão do modelo (Zanini, 2023).

3.3.1 AVALIAÇÃO IN-SAMPLE:

A avaliação *in-sample* consiste em aplicar o modelo desenvolvido aos mesmos dados utilizados para estimar seus parâmetros, comparando os valores reais com os valores ajustados (ou previstos) pelo modelo. Esse procedimento permite calcular o erro médio de previsão para os dados históricos, servindo como um indicador preliminar de como o modelo poderá se comportar ao projetar valores futuros.

3.3.2 ERRO MÉDIO ABSOLUTO PERCENTUAL (MAPE):

O MAPE mede a precisão do modelo ao calcular a média das diferenças absolutas entre os valores reais e os valores ajustados, expressando o erro em termos percentuais. Essa métrica é especialmente útil quando se deseja avaliar o desempenho do modelo em relação à escala dos dados. A fórmula do MAPE é dada por:

$$MAPE = \frac{\sum_{t=1}^N \left| \frac{Y(t) - \hat{Y}(t)}{Y(t)} \right| * 100}{N} \quad (18)$$

Onde:

$Y(t)$: representa o valor real da série temporal no período t ;

$\hat{Y}(t)$: valor ajustado da série temporal para o período (t);

N : é o número total de observações.

3.3.3 ERRO MÉDIO ABSOLUTO (MAD):

O MAD representa a média das diferenças absolutas entre os valores reais e os valores ajustados. Diferentemente do MAPE, o MAD é expresso na mesma unidade da série temporal, sendo indicado para medir a precisão do modelo em termos absolutos:

$$MAD = \frac{\sum_{t=1}^N |Y(t) - \hat{Y}(t)|}{N} \quad (19)$$

Onde:

$Y(t)$: representa o valor real da série temporal no período t ;

$\hat{Y}(t)$: valor ajustado da série temporal para o período (t);

N : é o número total de observações.

Essa métrica é menos sensível a flutuações de escala e fornece uma medida direta do desvio médio das previsões.

3.3.4 COEFICIENTE DE DETERMINAÇÃO AJUSTADO (R^2 ajustado):

O R^2 ajustado mede a proporção da variação total dos dados explicada pelo modelo, semelhante ao R^2 tradicional, mas ajustado pelo número de parâmetros do modelo. Esse ajuste evita superestimar o poder explicativo ao incluir mais variáveis.

$$R^2_{\text{ajust}} = \left(1 - \frac{\sum_{t=1}^N \frac{(Y(t) - \hat{Y}(t))^2}{N - k}}{\sum_{t=1}^N \frac{(Y(t) - \bar{Y})^2}{N - 1}} \right) * 100 \quad (20)$$

Onde:

$Y(t)$: valor da série temporal no período (t);
 $\hat{Y}(t)$: valor ajustado da série temporal para o período (t);
 \bar{Y} : média das observações (média da série temporal);
 N : total de dados utilizados (total de observações);
 k : número de parâmetros do modelo.

3.3.5 AVALIAÇÃO *OUT-OF-SAMPLE* E *ROLLING EVALUATION*

A avaliação *out-of-sample* envolve testar o modelo em um conjunto de dados não utilizado na etapa de estimação, validando assim a capacidade preditiva do modelo em dados futuros. Esse procedimento avalia a robustez do modelo fora do período amostral, permitindo verificar se ele mantém um bom desempenho preditivo ao longo do tempo.

Um método frequentemente utilizado em avaliações *out-of-sample* é o *rolling evaluation*, que consiste em movimentar a origem da previsão para períodos consecutivos fora da amostra, recalculando as previsões a cada passo. Faz-se então uma análise recursiva fora da amostra. Nesse procedimento, define-se um conjunto de dados *out-of-sample* (por exemplo, os últimos 12 meses) e realiza-se a previsão um passo à frente, dois passos à frente, e assim por diante, até que todas as observações fora da amostra tenham sido projetadas. Esse processo gera uma série de previsões *out-of-sample* com diferentes horizontes, permitindo a comparação do desempenho para previsões de curto e longo prazo.

O procedimento pode envolver ainda o que se denomina de *out-of-sample rolling evaluation*, ou seja, com os mesmos parâmetros estimados para os dados passados, move-se a origem da previsão no período *out-of-sample*, fazendo-se previsões para cada origem. Caso sejam retirados os últimos 12 dados³, isso significa que serão feitas no período *out-of-sample* um total de 78 previsões (12 previsões para um passo à frente, 11 previsões para 2 passos à frente, 10 previsões para 3 passos à frente e assim sucessivamente). Este procedimento permite avaliar como o modelo se comporta com previsões para

³ Obviamente retirar os últimos dados é apenas um procedimento de análise para seleção de modelos. Para se obter as previsões desejadas, depois de feita análise *in-sample* e *out-of-sample*, os dados retirados são novamente incorporados e os parâmetros atualizados. Foi dado como exemplo a retirada dos últimos 12 dados o que geraria um total de 78 previsões fora da amostra. Entretanto, este “período de corte” pode ser definido de acordo com cada problema. Como exemplo, se são retirados os últimos 6 dados, geram-se 21 previsões fora da amostra.

diferentes horizontes e ajuda a identificar a eficácia do modelo para diferentes intervalos de tempo.

Pode-se definir como critério, por exemplo, que o método vencedor a ser selecionado será aquele que minimizar o MAD (*Mean Absolute Deviation*) acumulado ou erro médio absoluto acumulado fora da amostra. Para entender melhor o procedimento de *rolling evaluation*, observar a Figura 1 a seguir, que exemplifica o deslocamento da origem da previsão e a geração das previsões para cada horizonte.

Figura 1: Procedimento de *out-of-sample rolling evaluation*

		Horizonte											
		dez	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov
		A	A	A	A	A	A	A	A	A	A	A	A
Origem	nov	F	F	F	F	F	F	F	F	F	F	F	F
	dez	A	F	F	F	F	F	F	F	F	F	F	F
	jan	A	A	F	F	F	F	F	F	F	F	F	F
	fev	A	A	A	F	F	F	F	F	F	F	F	F
	mar	A	A	A	A	F	F	F	F	F	F	F	F
	abr	A	A	A	A	A	F	F	F	F	F	F	F
	mai	A	A	A	A	A	A	F	F	F	F	F	F
	jun	A	A	A	A	A	A	A	F	F	F	F	F
	jul	A	A	A	A	A	A	A	A	F	F	F	F
	ago	A	A	A	A	A	A	A	A	A	F	F	F
	set	A	A	A	A	A	A	A	A	A	A	F	F
	out	A	A	A	A	A	A	A	A	A	A	A	F

Fonte: Elaboração própria a partir de Zanini (2023). Nota: F = *Forecast* e A = *Actual*.

Para cada horizonte de previsão, calculam-se métricas como o MAPE e o MAD, possibilitando avaliar a precisão acumulada das previsões. Uma métrica adicional aplicada neste contexto é a Média Geométrica do Erro Absoluto

Relativo (GMRAE), que compara o erro do modelo com o erro do modelo ingênuo (que utiliza o último valor observado como previsão para o próximo período). O GMRAE é calculado pela média geométrica da razão entre o erro absoluto do modelo estimado e o erro absoluto do modelo ingênuo:

$$\text{GMRAE} = \sqrt[N]{\prod_{t=1}^N \left(\frac{|Y(t) - \hat{Y}(t)|}{|Y(t) - Y(t-1)|} \right)} \quad (21)$$

Onde:

$Y(t)$ é o valor real da série no período (t);

$\hat{Y}(t)$ é a previsão gerada pelo modelo para o período (t);

$Y(t-1)$ é o valor da série temporal no período (t-1);

N é o número de observações.

O GMRAE é utilizado como uma referência relativa, facilitando a comparação com um modelo mais simples. Um valor de GMRAE menor ou igual a 1 indica que o modelo desenvolvido possui desempenho superior ou igual ao modelo ingênuo.

3.4 SELEÇÃO DO MELHOR MODELO:

Após realizar a análise *in-sample* e *out-of-sample*, o modelo com menor erro acumulado ou menor valor de MAPE, MAD ou GMRAE é selecionado como o mais adequado para a série temporal em questão. É importante destacar que, após essa seleção, os dados *out-of-sample* previamente reservados são reincorporados à série original, atualizando-se os parâmetros do modelo e proporcionando uma base mais sólida para a previsão final.

4 ANÁLISE DE DADOS E RESULTADOS

Os dados históricos obtidos para a aplicação desta monografia têm origem em um sistema de controle financeiro de uma fábrica de móveis, cujo nome será mantido em anonimato para preservar a confidencialidade das informações. A base de dados utilizada compreende uma amostra de 95 observações mensais, correspondentes ao faturamento da empresa no período de janeiro de 2017 a novembro de 2024.

O faturamento mensal foi registrado em reais, e para fins de análise gráfica, os valores foram representados em escala reduzida. Dessa forma, os números no gráfico estão expressos em milhões.

Figura 2: Faturamento Mensal de janeiro - 2017 a novembro - 2024.



Fonte: Elaboração própria.

A visualização da série tem sua importância no aspecto de identificar características importantes que serão utilizadas nas etapas subsequentes de modelagem, tais como tendências, sazonalidade e flutuações e irregularidades.

4.1 ANÁLISE DA SÉRIE HISTÓRICA

Ao analisar a série, observa-se uma tendência geral de crescimento, que se torna particularmente evidente a partir de 2020, quando há um aumento nos faturamentos. Nos últimos meses de 2024, os índices superaram a marca de 35

milhões de reais, indicando que o faturamento da empresa triplicou em relação ao início da série, em janeiro de 2017.

Outro aspecto relevante identificado na série é a presença de sazonalidade, com flutuações regulares em determinados períodos do ano. Essas variações sugerem um padrão sazonal, com aumentos nos meses finais, como outubro e novembro em vários anos. Esse comportamento pode estar relacionado a uma maior demanda por móveis nessas épocas, possivelmente motivada por promoções sazonais, eventos econômicos ou maior disposição dos consumidores para realizar compras.

Além da sazonalidade, a série também evidencia impactos específicos, como o observado em fevereiro de 2022, quando ocorre uma queda abrupta seguido por um retorno no crescimento. Esse movimento é reflexo de um incêndio que atingiu a fábrica nesse mês prejudicando a produção e consequentemente o faturamento.

De modo geral, a análise inicial da série histórica fornece subsídios para as etapas subsequentes de modelagem quantitativa e da previsão. A identificação das tendências de crescimento, dos padrões sazonais e das flutuações específicas serão utilizadas para ajustar os modelos discutidos na metodologia, como os modelos Box & Jenkins e o Método de Amortecimento Exponencial.

4.2 COMPETIÇÃO DE MÉTODOS

Nesta seção, apresentam-se os resultados da competição entre os dois métodos de previsão utilizados: o Método de Amortecimento Exponencial (MAE) e o modelo ARIMA (1,1,0) (1,0,0). O objetivo desta análise é identificar qual modelo apresenta o melhor desempenho preditivo, tanto *in-sample* (dentro da amostra), quanto *out-of-sample* (fora da amostra), utilizando métricas estatísticas como R^2 , MAPE, MAD e GMRAE.

4.2.1 METODOLOGIA DE AVALIAÇÃO

Para a análise *in-sample*, avaliou-se a capacidade de ajuste dos modelos aos dados históricos de faturamento da empresa, considerando métricas que indicam o grau de explicação da variabilidade da série (R^2 ajustado) e a precisão

do ajuste (MAPE e MAD).

Na análise *out-of-sample*, os modelos foram aplicados para prever 12 passos à frente, acumulando previsões para até 78 passos. O critério principal para determinar o método vencedor foi a minimização dos erros acumulados fora da amostra, com ênfase para os valores do MAD e MAPE acumulados ao longo dos horizontes avaliados.

4.2.2 ANÁLISE DO MÉTODO DE AMORTECIMENTO EXPONENCIAL

O MAE foi ajustado utilizando sazonalidade multiplicativa e com componente de tendência (ver equação 7) conforme o comportamento observado na série histórica. Esse modelo apresentou um ajuste inicial aos dados com um R^2 ajustado de 91,2% e MAPE de 16,77%.

Os índices sazonais ajustados pelo modelo indicaram maior concentração de faturamento no último trimestre do ano (outubro a dezembro), enquanto os meses de abril a junho apresentaram os menores índices. Esses padrões refletem características do setor de atuação, como sazonalidade associada à demanda por móveis ao final do ano.

Na análise *out-of-sample*, o MAE obteve para as primeiras 12 previsões um MAPE de 9,0.

4.2.3 ANÁLISE DO ARIMA (1,1,0) (1,0,0)

O modelo ARIMA (1,1,0) (1,0,0) foi ajustado após a transformação logarítmica dos dados para garantir a estacionariedade de segunda ordem (relativa à variância). Na análise *in-sample*, o ARIMA apresentou um R^2 ajustado de 93%, superior ao observado no MAE. O MAPE foi de 16,07%, indicando que o modelo capturou bem as flutuações históricas, mas apresentou leve superioridade em termos de precisão sobre o MAE.

Na análise *out-of-sample*, o ARIMA apresentou desempenho superior ao MAE nos horizontes iniciais de previsão. Para as primeiras 12 previsões fora da amostra, o modelo obteve um MAPE de 6,9.

4.3 ESCOLHA DO MELHOR MODELO

A Tabela 2 abaixo apresenta os resultados das métricas R^2 ajustado e MAPE (%) calculados com base nos dados *in-sample*. Essas métricas fornecem uma medida da adequação dos modelos aos dados disponíveis. O R^2 ajustado avalia a proporção da variância explicada pelo modelo, ajustando-se ao número de variáveis incluídas, enquanto o MAPE (%) reflete o erro percentual médio absoluto, indicando a precisão das previsões realizadas.

Para os dados out-of-sample, foram calculados o MAPE (%) para um horizonte de previsão ($H = 1$, $N = 12$) e acumulado (78 previsões). Além disso, utilizou-se a métrica GMRAE (*Geometric Mean Relative Absolute Error*), que compara o desempenho do modelo com um modelo de referência simples, normalmente representado pela média histórica.

Tabela 2: *Análise In-Sample e Out-Of-Sample*

MÉTODO	IN-SAMPLE		OUT-OF-SAMPLE			
	R^2 Ajustado (%)	MAPE (%)	MAPE (%) (H = 1, N = 12)	MAPE (%) ACUMULADO	GMRAE (H = 1, N = 12)	GMRAE ACUMULADO
MAE	91,2	16,77	9,0	8,9	1,669	0,645
ARIMA	93,1	16,07	6,9	9,3	1,217	0,707

Fonte: Elaboração própria com base em Zanini (2023). Nota: H = Horizonte de Previsão e Acumulado (78 previsões).

Os resultados indicam que, dentro da amostra, o modelo ARIMA apresentou superioridade em termos de explicação da variabilidade da série, com R^2 ajustado maior e MAPE menor. Entretanto, fora da amostra, o Método de Amortecimento Exponencial (MAE) apresentou menores erros acumulados (MAD e MAPE).

Assim, considerando os critérios adotados, principalmente o erro acumulado nas 78 previsões fora da amostra, o método vencedor foi o Método de Amortecimento Exponencial (MAE), que será utilizado para calcular as previsões futuras do faturamento da empresa. Os dados fora da amostra foram reincorporados à série, e os parâmetros do modelo foram atualizados para a geração das projeções finais, conforme detalhado nas seções subsequentes.

4.4 PREVISÃO DO FATURAMENTO DA FÁBRICA DE MÓVEIS

A previsão do faturamento foi realizada com base no Método de Amortecimento Exponencial (MAE). O MAE foi ajustado considerando sazonalidade multiplicativa, alinhada ao comportamento observado na série histórica de faturamento da empresa, que compreende o período de janeiro de 2017 a novembro de 2024. Os parâmetros finais estimados para o modelo podem ser visualizados na tabela 2.

Tabela 3: Parâmetros do MAE

COMPONENTE	PARÂMETROS	HIPERPARÂMETROS
NÍVEL	3.520.300	0,52237
TENDÊNCIA	26.873	0,00677
SAZONALIDADE	*	0,11058

Fonte: Elaboração própria. Nota: * Fatores sazonais são apresentados na tabela 4.

O parâmetro de nível estimado foi 3.520.300, com hiperparâmetro $\alpha = 0,52237$, indicando maior peso às observações recentes. A fórmula de atualização utilizada, descrita na equação (8), combina o último valor observado e o valor amortecido anterior, ponderados por α e $1 - \alpha$, respectivamente. Isso ajusta o parâmetro de nível de acordo com os dados mais recentes da série.

O parâmetro de tendência foi estimado em 26.873, com hiperparâmetro $\beta = 0,00677$, o que implica uma menor influência das observações recentes na atualização da tendência. Conforme descrito na equação (9), o modelo pondera as diferenças entre os níveis atual e anterior, atribuindo menos peso a alterações recentes e mais peso à estimativa anterior da tendência.

O componente sazonal foi ajustado com o hiperparâmetro $\gamma = 0,11058$, resultando em menor influência dos dados mais recentes nos fatores sazonais. A equação (10) define a atualização do fator sazonal como uma combinação do valor dessazonalizado e do fator sazonal anterior, ponderados por γ e $1 - \gamma$. Essa configuração prioriza a consistência dos fatores sazonais ao longo do tempo.

Os índices sazonais ajustados pelo modelo revelaram que os meses de outubro a dezembro apresentam fatores sazonais superiores a 1,0, indicando incremento no faturamento durante esse período. O fator sazonal de dezembro,

por exemplo, reflete um aumento de cerca de 8,7% no faturamento, enquanto novembro e outubro mostram aumentos de 8,1% e 6,9%, respectivamente. No trimestre de julho a setembro, destaca-se o mês de agosto, com um fator sazonal de 1,06921, ou seja, um incremento de 6,9%.

Por outro lado, os meses com fatores sazonais inferiores a 1,0 incluem fevereiro, que apresenta a maior redução, com uma queda de 12% no faturamento. Outros meses que mostram redução incluem abril (-7%), janeiro (-3%), e setembro (-4%), como é ilustrado na tabela 4.

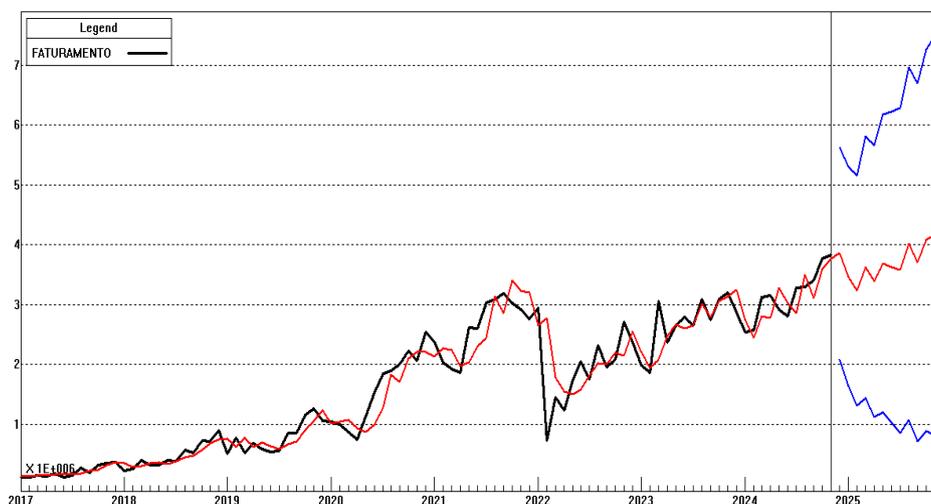
Tabela 4: Índices Sazonais

PERÍODO	FATORES SAZONAIS		
JAN – MAR	0,97239	0,89988	0,99969
ABR – JUN	0,92781	1,00221	0,97717
JUL – SET	0,95795	1,06921	0,97730
OUT – DEZ	1,06895	1,08140	1,08728

Fonte: Elaboração própria .

As previsões futuras geradas pelo modelo são apresentadas com um intervalo de confiança de 95%. Os valores projetados para os próximos 12 meses indicam a continuidade da tendência de crescimento observada na série histórica como está presente na figura 3. Por exemplo, a previsão central para dezembro de 2024 é de aproximadamente R\$ 3.856.794,75, com limites inferior e superior variando entre R\$ 2.089.903,88 e R\$ 5.623.685,50. Esse intervalo de confiança possibilita a elaboração de cenários distintos para a tomada de decisões, podendo o limite inferior ser visto como um cenário conservador e o limite superior como um cenário otimista como está na tabela 5 abaixo. Importante observar também que uma maior variabilidade dos valores passados acaba por impactar na amplitude do intervalo de confiança que capta esta “incerteza” vista no passado.

Figura 3: Faturamento da fábrica de móveis (R\$) – período de janeiro - 2017 a dezembro - 2025.



Fonte: Elaboração própria. Nota: ____ Faturamento ____ Valores ajustados/Projeções ____ Intervalo de confiança de 95%

Tabela 5: Previsões dos faturamentos (R\$) – Intervalo de confiança de 95%

Mês	Limite Inferior	Previsão	Limite Superior
2024-12	2.089.903,88	3.856.794,75	5.623.685,50
2025-01	1.642.229,25	3.475.369,75	5.308.510,00
2025-02	1.318.812,50	3.240.398,50	5.161.984,50
2025-03	1.439.298,25	3.626.676,25	5.814.054,00
2025-04	1.121.787,00	3.390.858,25	5.659.929,50
2025-05	1.208.429,13	3.689.675,75	6.170.922,50
2025-06	1.023.886,44	3.623.752,25	6.223.618,00
2025-07	865.583,63	3.578.242,00	6.290.900,50
2025-08	1.085.833,25	4.022.560,00	6.959.287,00
2025-09	709.272,25	3.703.033,50	6.696.794,50
2025-10	892.270,81	4.079.034,00	7.265.797,00
2025-11	829.844,31	4.155.613,50	7.481.382,50
2025-12	750.758,75	4.207.424,00	7.664.089,50

Fonte: Elaboração própria .

A Tabela 6 apresenta os faturamentos anuais da fábrica de móveis de 2017 a 2025, evidenciando a tendência de crescimento do negócio ao longo dos anos. Observa-se um aumento até 2021, seguido por uma queda em 2022 e uma recuperação nos anos subsequentes. Para 2024 e 2025, as previsões indicam continuidade na expansão do faturamento, com crescimento anual de 19% e 16%, respectivamente, refletindo a tendência capturada pelo modelo.

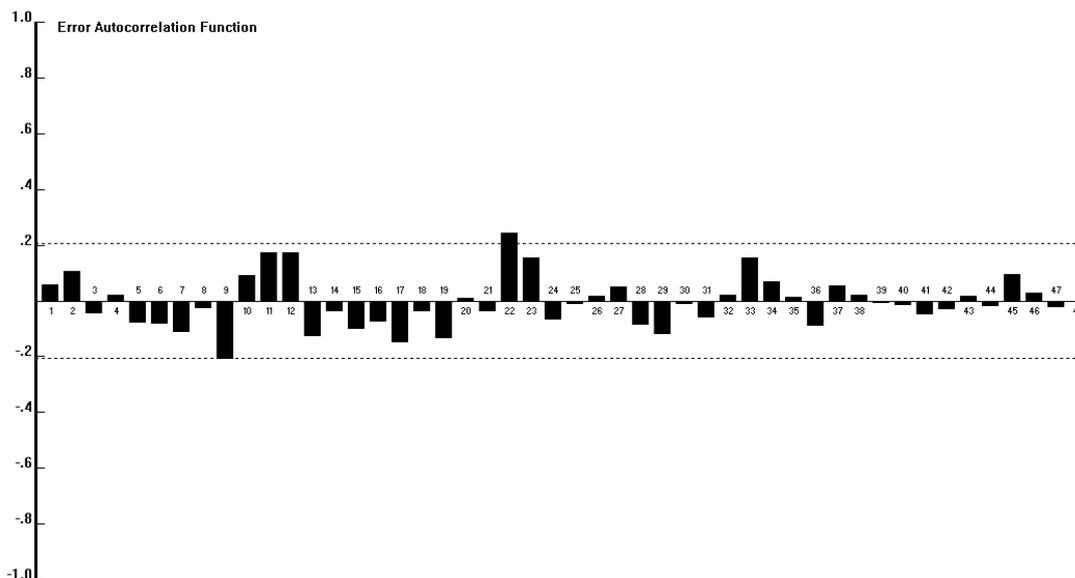
Tabela 6: Faturamento anualizado (R\$)

Ano	Faturamento anual	Varição anual (%)
2017	2.483.742,26	-
2018	5.758.123,92	132%
2019	9.417.487,15	64%
2020	18.944.496,87	101%
2021	31.468.976,25	66%
2022	23.386.415,75	-26%
2023	32.392.529,87	39%
2024*	38.591.419,25	19%
2025*	44.792.637,75	16%

Fonte: Elaboração própria . Nota * Valores estimados.

Além das projeções, a adequação do modelo foi avaliada pela análise da função de autocorrelação dos resíduos (FAC), como indicado na figura 4. Os resultados indicaram que os resíduos são descorrelacionados.

Figura 4: Função de Autocorrelação do Erro – MAE



Fonte: Elaboração própria

A capacidade explicativa do modelo foi validada por métricas como o coeficiente de determinação ajustado (R^2), que alcançou 91,2%, e o Erro Percentual Absoluto Médio (MAPE), que foi de 16,77%.

Os resultados evidenciam que o MAE foi eficaz em capturar tanto a tendência de crescimento quanto os padrões sazonais da série histórica. Assim, o modelo se mostra uma ferramenta funcional para o planejamento estratégico e financeiro da fábrica, permitindo que decisões sejam tomadas com base nas projeções e alinhadas às características do setor.

5. CONCLUSÃO

Este trabalho buscou aplicar e avaliar métodos de previsão de faturamento no setor moveleiro, utilizando o Método de Amortecimento Exponencial (MAE) e o modelo ARIMA. A análise demonstrou que ambos os métodos apresentaram bom desempenho em termos de ajuste e previsão, mas o MAE destacou-se pela análise em horizontes de previsão mais longos, sendo escolhido como o modelo mais adequado para a projeção futura do faturamento da fábrica em estudo.

Os resultados mostraram uma tendência de crescimento sustentado no faturamento da empresa, com sazonalidades nos meses finais do ano. Esse tipo de análise tem sua importância para a aplicação do planejamento financeiro e estratégico, permitindo à fábrica alinhar suas operações às demandas de mercado, otimizar recursos e mitigar riscos.

Além disso, o trabalho reforça a importância da utilização de técnicas de previsão no setor moveleiro, destacando como estas podem contribuir para a eficiência operacional e o sucesso sustentável. A aplicação prática das metodologias empregadas demonstra sua relevância tanto para a tomada de decisão quanto para a adaptação às constantes mudanças no ambiente econômico.

Viu-se, por exemplo, que a utilização de critério objetivos, a aplicação da análise estatística através de séries de tempo, permite gerar não apenas um número, a previsão. A metodologia estima a previsão na forma probabilística, o que permite, por exemplo, usar os limites inferiores e superiores na geração de cenários. O limite inferior poderia ser considerado um cenário “pessimista”. Já o limite superior um cenário “otimista”. A previsão poderia ser considerado o cenário “esperado”.

Para estudos futuros, recomenda-se a ampliação do período de análise, a incorporação de variáveis externas que possam influenciar o faturamento e a aplicação de outras metodologias preditivas, como redes neurais artificiais ou modelos híbridos, para avaliar se estes podem oferecer maior precisão e flexibilidade às projeções.

Assim, este trabalho contribui não apenas para a compreensão da dinâmica do setor moveleiro, mas também para o aprimoramento das práticas de previsão e planejamento financeiro, servindo como referência para empresas e pesquisadores interessados em otimizar a gestão de recursos e estratégias no contexto competitivo do mercado atual.

6 REFERÊNCIAS:

ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS DO MOBILIÁRIO. **Relatório Setorial da Indústria de Móveis no Brasil**. Disponível em: <http://abimovel.com/capa/dados-do-setor/>. Acesso em: 05 Nov, 2023.

BESSA, Carlos. Setor Moveleiro investiga as tendências do mobiliário para 2024. **Setor Moveleiro**, 4 out.2023. Disponível em: <https://setormoveleiro.com.br/tendencias-mobiliario/>. Acesso em: 05 Nov, 2023.

BOX, G. E. P., JENKINS, G. M. **Time Series Analysis, Forecasting and Control**, San Francisco, Holden-Day, 1994.

CERBASI, G. **Como organizar sua vida financeira: Inteligência financeira pessoal na prática**. Rio de Janeiro: Elsevier, 2009.

DRUCKER, P. **O Gerente Eficaz**. 4 ed. Rio de Janeiro: Zahar, 1974.

ESPOSITO, F. R. **Previsão de Vendas Diárias de Jornais: Um Estudo de Caso Para um Ponto de Venda (PDV)**. Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. Juiz de Fora. 2022.

FALLER, L. P.; ALMEIDA, M. I. R. de. Planejamento por cenários: preparando pequenas empresas do varejo de móveis planejados para um futuro competitivo. **Revista de Administração**, [S. l.], v. 49, n. 1, p. 171-187, 2014. DOI: 10.5700/rausp1139. Disponível em: <https://www.revistas.usp.br/rausp/article/view/86377>. Acesso em: 4 nov. 2023.

FRANKENBERG, L. **Seu futuro financeiro**. 8. ed. Rio de Janeiro: Campus, 1999.

Furukawa, Raymundo & Lima, Orlem & Maduro, Marcia & Minori, Américo & Kieling, Antonio. (2024). Utilização de técnicas de previsão de vendas em uma empresa moveleira de Manaus. **Caderno Pedagógico**. 21. e3458. 10.54033/cadpedv21n3-069.

GITMAN, L. J. **Princípios de Administração Financeira – Essencial**. 2. ed. Porto Alegre: Bookman, 2001.

KERKKANEN, A., KORPELA, J., HUISKONEN, J. Demand Forecasting Errors in Industrial Context: Measurement and Impacts. **International Journal of Production Economics**. p.43–48. 2009.

MEDEIROS, N. T. **Modelo de Projeção de Faturamento e a Importância do Planejamento Financeiro: Um Estudo de Caso no Setor de Panificação**. Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. Juiz de Fora. 2022.

MORO, M. F.; SANTOS, B. M. dos; PATIAS, J.; CARDOSO, D.; GODOY, L. P.; VINCENZI, S. L. (2016). **Previsão de vendas: uma aplicação do modelo Holt-Winters em uma indústria moveleira.** Revista Espacios, 37(32), p. 2. <https://www.revistaespacios.com/a16v37n32/16373202.html#bibl>

Nascimento, H. F. T. do. **Projeções de Faturamento de uma Empresa no Segmento de Moda e a Importância do Planejamento Financeiro: Um Estudo de Caso.** Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. Juiz de Fora. 2022.

PEINADO, J.; GRAEML, A. R. **Administração da produção: operações industriais e de serviços.** Curitiba: UnicenP, 2007.

Pellegrini, F. R., & Fogliatto, F. S. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. **Revista PRODUÇÃO**, v. 11 n. 1, p. 43-64, 2001.

Penha, R. M. **Projeções de Faturamento de uma Empresa Júnior e sua Importância no Planejamento Estratégico: Um Estudo de Caso.** Trabalho de Conclusão de Curso. (Graduação em Ciências Econômicas) - Universidade Federal de Juiz de Fora. Juiz de Fora. 2020.

ROSA, S. E. S. da. O setor de móveis na atualidade: uma análise preliminar. **BNDES Setorial**, Rio de Janeiro, n. 25, p. 65-106, mar. 2007.

ROSS, S. A.; WESTERFIELD, R. W.; JORDAM, B. D.; **Princípios de Administração Financeira.** – São Paulo: Atlas, 2002.

ROSS, S. A; WESTERFIELD, R. W.; JAFFE; J. F. **Administração Financeira.** São Paulo: Atlas, 1995.

SILVA SOBRINHO, A. P. S.; TOFOLI, E. T. A Importância do Planejamento Financeiro na Organização. **Colloquium Socialis**, Presidente Prudente, v. 1, n. Especial 2, p.522-552, 2017.

SOARES, T. R. M. **Análise de Séries Temporais para previsão do faturamento mensal de uma empresa.** 52 f. Trabalho de Conclusão de Curso (Graduação em Estatística) - Universidade Federal de Uberlândia, Uberlândia, 2019.

TARAPANOFF, K. **Inteligência organizacional e competitiva.** Brasília: UnB, 2001.

Wheelwright, S.C.; Makridakis, S.G. **Forecasting Methods for Management;** Wiley: Hoboken, NJ, USA, 1973.

ZANINI, A. **Modelos de Previsão para Séries Temporais.** Material Didático. Juiz de Fora, 2023.