



03 a 05 de dezembro de 2025

As Engenharias na Transformação Digital das PMEs

Aplicação de ARIMA para Previsão de Demanda em Pequena Empresa do Interior de Minas Gerais

Antonio Mendes Magalhães Junior

DECP – Universidade do Estado de Minas Gerais

Breno Henrique Cardoso de Paula

DECP – Universidade do Estado de Minas Gerais

Bruno Martins Moreira

DECP – Universidade do Estado de Minas Gerais

Letícia Santana Azevedo

DECP – Universidade do Estado de Minas Gerais

Sophia de Souza Almeida

DECP – Universidade do Estado de Minas Gerais

Resumo: Este estudo avalia, em condições reais de operação, a aplicação do modelo ARIMA (Autoregressive Integrated Moving Average) para previsão de demanda em uma pequena empresa comercial localizada no interior de Minas Gerais. A análise foi realizada com base em 18 meses de vendas (julho de 2023 a dezembro de 2024), com foco nos cinco itens com maior volume. Utilizando o software Minitab 22, as séries temporais foram investigadas por meio de visualizações e funções de autocorrelação, que indicaram uma tendência baixa e nenhuma sazonalidade relevante. Com base nesse diagnóstico, foram selecionados modelos ARIMA capazes de capturar a dinâmica de curto prazo. Em comparação com o método empírico adotado pela empresa, houve uma redução média de 85,8% no Erro Percentual Absoluto Médio (MAPE) nas estimativas de vendas. Para o item com maior variabilidade, por exemplo, o erro caiu de 72,09% para 11,63%. Os resultados sugerem que métodos quantitativos acessíveis podem aumentar substancialmente a precisão das previsões e apoiar decisões mais assertivas de compras e gestão de estoque, mesmo na ausência de um departamento de planejamento dedicado.

Palavras-chave: ARIMA, séries temporais, previsão de demanda.

Application of ARIMA for Demand Forecasting in a Small Company in the Interior of Minas Gerais

Abstract: This study evaluates, under real operating conditions, the application of the ARIMA (Autoregressive Integrated Moving Average) model for demand forecasting in a small commercial company located in the interior of Minas Gerais. The analysis was conducted based on 18 months of sales (July 2023 to December 2024), focusing on the five items with the highest volume. Using Minitab 22 software, the time series were investigated through visualizations and autocorrelation functions, which indicated a low trend and no relevant seasonality. Based on this diagnosis, ARIMA models capable of capturing short-term dynamics were selected. Compared to the empirical method adopted by the company, there was an average reduction of 85.8% in the Mean Absolute Percentage Error (MAPE) in sales estimates. For the item with the highest variability, for example, the error fell from 72.09% to 11.63%. The findings suggest that accessible quantitative methods can substantially increase the accuracy of forecasts and support more assertive purchasing and inventory management decisions, even in the absence of a dedicated planning department.

Keywords: ARIMA, time series, demand forecasting.

1. Introdução

Em um mundo onde as coisas mudam o tempo todo e a concorrência entre as organizações vem crescendo sucessivamente, se torna indispensável que as empresas saibam se adaptar a essas mudanças. Dentro dessa realidade, o Planejamento e Controle da Produção (PCP), junto com a previsão de demanda, se tornaram ferramentas muito importantes para que uma empresa consiga se destacar e se manter no mercado.

Melwyn (2022) ressalta que, mesmo possuindo as suas particularidades, toda empresa enfrenta dificuldades quando o assunto é produzir e entregar seus produtos ou serviços. Entretanto, no caso de negócios de pequeno a médio porte, isso acaba sendo ainda mais complexo, já que normalmente essas possuem menos recursos e não contam com setores especializados para lidar com essas questões. Ainda assim, a necessidade de entender e conseguir antecipar as mudanças do mercado é substancial, pois isso se mostra extremamente importante para que continuem competitivas. Sendo assim, usar métodos e ferramentas que ajudem a prever essas demandas é vital, visto que essas previsões influenciam diretamente a eficiência operacional e a capacidade de atender os clientes. Negligenciar essa etapa pode comprometer o equilíbrio do estoque, gerando falta de produto em momentos críticos ou acúmulo de itens que possuem baixa rotatividade.

A previsão de demanda impacta diretamente em diversas decisões dentro da empresa, desde o planejamento da capacidade de atender os pedidos até o controle de estoque e reposição de materiais importantes para o funcionamento diário. Essa previsão abrange não somente o setor operacional, mas também áreas de finanças, marketing e compras. Em organizações que o fluxo de vendas é muito sensível, ou seja, oscilam significativamente dia após dia, ter uma previsão bem feita faz toda a diferença para manter o equilíbrio entre oferta e demanda, evitando perdas e melhorando o desempenho geral do negócio (Stevenson, 2011).

Apesar de ser um tema tão importante, é comum que muitas empresas ainda façam as suas estimativas de vendas usando experiências práticas antigas ou na intuição dos gestores. Embora esse tipo de prática funcione em alguns casos, com o tempo ela tende a provocar resultados instáveis, algumas falhas no planejamento de compras, desorganização no estoque e dificuldades no atendimento ao cliente.

Diante desse cenário, o presente trabalho tem como objetivo aplicar o modelo estatístico ARIMA (Autoregressive Integrated Moving Average) em uma empresa de pequeno porte do setor comercial, localizada no interior de Minas Gerais. A organização atua na venda de peças de bicicletas e motos, bicicletas e serviços de oficina, sendo reconhecida regionalmente pela tradição e atendimento. Para análise, foram utilizados dados reais de vendas referentes a um período de 18 meses, com foco nos cinco produtos mais comercializados nesse intervalo.

A proposta é avaliar se a aplicação de um modelo quantitativo pode contribuir para previsões mais precisas em empresas que ainda usam métodos empíricos, auxiliando no equilíbrio do estoque e na tomada de decisões mais eficazes no dia a dia do negócio. Essa dúvida guia o desenvolvimento deste trabalho, buscando comprovar se a sua aplicação é viável e eficaz nesse contexto.

2. Referencial Teórico

2.1 Planejamento e controle de produção

Krajewski, Ritzman e Malhotra (2009), mostram que PCP tem como principal objetivo equilibrar a capacidade de produção com as demandas do mercado. Isso envolve otimizar o uso de recursos, reduzindo os custos operacionais e garantir que os produtos estejam disponíveis quando necessário.

Tubino (2017) complementa que o PCP exige um gerenciamento cuidadoso e bem detalhado dos estoques. É fundamental que a organização tenha a quantidade certa de produtos para atender à demanda dos consumidores. Esse equilíbrio é vital para que a empresa possa responder de forma eficiente às necessidades do mercado, evitando a possibilidade de faltar mercadorias ou acumular itens em excesso. Quando esse controle não é feito da maneira correta, pode acabar afetando negativamente o fluxo de caixa, já que um estoque parado significa dinheiro que não está sendo utilizado. Por isso, o PCP se torna uma peça-chave na gestão, ajudando a alinhar recursos disponíveis com o que o mercado realmente procura.

A tomada de decisão e a implementação de mudanças nos processos operacionais dependem diretamente de um planejamento e controle eficaz, como afirmam Bueno, Godinho Filho e Frank (2020). Desta forma, compreender como o mercado funciona e antecipar tendências futuras se torna mais fácil com o uso de ferramentas de previsão de demanda. Isso ajuda e possibilita as empresas a se ajustarem de forma proativa às mudanças e flutuações do mercado.

2.2 Previsão de demanda

A previsão de demanda se mostra como um dos pilares fundamentais da gestão das organizações. É por meio dessa que é possível se ter uma noção de quantos produtos ou serviços serão requeridos em um período próximo. De acordo com Corrêa, Gianesi e Caon (2014), tanto a logística quanto o planejamento de recursos produtivos de uma empresa dependem demasiadamente da previsão de demanda. A qual ajuda a tomar decisões com mais segurança, evitando desperdícios, atrasos e problemas como a falta ou excesso de estoque.

Por isso, é substancial que a empresa entenda como essas previsões são elaboradas, quais métodos são utilizados e até onde essas conseguem chegar, para que as decisões tomadas estejam realmente alinhadas com a sua realidade. Em negócios de pequeno a médio porte, que normalmente não contam com um setor específico só para a análise de demanda ou o planejamento de estoque, essa responsabilidade acaba sendo designada para profissionais que já exercem outras funções na organização. Isso pode afetar a qualidade das análises feitas e gerar desequilíbrio no estoque (Tubino, 2007).

Complementando essa perspectiva, Chopra e Meindl (2015) reforçam que quando todas as partes da cadeia de suprimento conseguem trabalhar em conjunto, cada uma sabendo o seu papel e quando agir, tem-se o aumento significativo da precisão da previsão, o que evita que a empresa produza ou compre algo que o mercado na prática não está pedindo.

Entretanto, como evidencia Slack, Chamber e Jonhston (2009), para tomar uma decisão estratégica não é suficiente saber apenas se a demanda de produtos e serviços está em crescimento ou queda. É preciso ir além e entender com que intensidade essas mudanças estão acontecendo ao longo do tempo. Quando a empresa consegue ver essas alterações com antecedência tem-se uma maior segurança para planejar ações e tomar decisões assertivas. Na prática, isso ajudará a garantir que a organização se mantenha competitiva e alinhada às futuras demandas do mercado.

2.3 Métodos de previsão

Os métodos qualitativos e quantitativos são as principais abordagens usadas na previsão de demanda. Essa distinção pode ser compreendida a partir do seguinte trecho:

Existem duas abordagens gerais para a realização de previsões, assim como há duas maneiras de lidar com modelos de tomada de decisão. Uma delas é a análise quantitativa; a outra, a abordagem qualitativa. As previsões quantitativas utilizam uma variedade de modelos matemáticos que dependem de dados históricos e/ou variáveis associativas para projetar a demanda. As previsões subjetivas ou qualitativas, por sua vez, incorporam fatores como a intuição do tomador de decisão, suas emoções, experiências pessoais e sistemas de valores para alcançar uma estimativa. Algumas empresas utilizam uma abordagem, outras utilizam a outra. Na prática, a combinação de ambas costuma ser a mais eficaz. (HEIZER; RENDER; MUNSON, 2020, p. 111, tradução nossa).

Complementando essa ideia, Makridakis, Wheelwright e Hyndman (1998), argumentam que, apesar de os métodos intuitivos serem considerados simples e mais acessíveis, eles possuem mais limitações, principalmente quando se trata de precisão, e geralmente não fornecem informações bem detalhadas sobre a exatidão das previsões. Por conta disso, o uso de métodos mais formais e matemáticos tem crescido cada vez mais. No entanto, ainda assim, muitas empresas menores continuam utilizando métodos intuitivos, seja pela falta de conhecimentos acerca de outros métodos formais, por limitações financeiras ou pela valorização do julgamento humano.

2.4 Séries temporais

Entre os métodos quantitativos aplicados à previsão de demanda, destacam-se os modelos baseados em séries temporais, devido à capacidade de perceber como os dados se comportam com o passar do tempo. Segundo Morettin e Toloi (2006), séries temporais são registros de dados feitos em sequência, ao longo do tempo, e servem para identificar padrões e tentar prever o que acontece no futuro. Esse tipo de análise é usado em várias áreas, como economia, meteorologia e controle de processos industriais, sendo utilizada para auxiliar na tomada de decisões.

Uma série temporal é chamada de estacionária quando as suas características estatísticas, como variância e média, permanecem constantes, ou seja, não mudam ao passar do tempo. Já quando esses valores mudam bastante ao longo do tempo, ela é considerada não estacionária. Esse tipo de série costuma ser mais difícil de analisar e prever, o que dificulta a modelagem e a análise de seu comportamento futuro, exigindo o uso de técnicas específicas para lidar com essa instabilidade (Análise Macro, 2025).

Existem diferentes abordagens estatísticas para modelagem de séries temporais. Morettin e Toloi (2006) destacam que os modelos de ARIMA são bastante utilizados na análise de séries, sejam elas estacionárias ou não. Esses modelos funcionam ao combinar relações entre valores passados da própria série com médias móveis, facilitando a identificação de padrões e a realização de previsões mais acuradas. São especialmente úteis quando os dados coletados seguem uma estrutura que precisa ser ajustada para garantir previsões confiáveis.

2.5 Modelo ARIMA

O modelo ARIMA é amplamente utilizado para prever séries temporais. Montgomery, Jennings e Kulahci (2008) explicam que a sua construção acontece por meio de três processos fundamentais. Primeiro, é analisado o comportamento anterior da série para tentar identificar um modelo inicial. Em seguida, os parâmetros são ajustados para que o modelo se encaixe bem nos dados reais. Por fim, é feita uma verificação cuidadosa dos resíduos, ou seja, a diferença entre os valores previstos e os reais, para avaliar se o modelo

é suficientemente bom ou se ainda necessita de ajustes. Se os resultados ainda não forem satisfatórios, o processo retorna à primeira etapa, para que sofra ajustes até que os resultados se tornem satisfatórios.

Morettin e Toloi (2006) também discutem essa metodologia e destacam a etapa de identificação como uma das mais sensíveis do processo. Para eles, a análise das funções de autocorrelação e autocorrelação parcial é essencial nesse momento, pois ajuda a enxergar padrões dentro da própria série, como repetições ou dependências de dados. Os autores ainda reforçam que, especialmente em contextos onde a previsão é o foco principal, o modelo ideal será aquele que apresentar os menores níveis de erro e maior consistência em seus resultados.

Além disso, conforme Brockwell e Davis (2006), a construção do ARIMA depende de três elementos. O parâmetro p mostra quantos valores anteriores são considerados na previsão. Já o q representa a quantidade de erros anteriores usados para prever os próximos valores. O d expõe quantas vezes a série precisou ser transformada até atingir uma forma mais estável. Esses parâmetros são definidos com base nas características da própria série.

2.6 Erros de previsão

Conforme discutido por Fernandes e Godinho Filho (2010), é essencial avaliar continuamente o sistema de previsão para que os erros que ocorrem entre os valores estimados e a demanda real observada sejam identificados e minimizados. Embora seja normal que parte dos erros ocorra devido à própria aleatoriedade dos dados ou do ambiente em que a aplicação foi aplicada, outra parte pode ser atribuída à inadequação de métodos ou dos parâmetros usados. Assim, controlar e analisar esses desvios é fundamental para garantir uma maior precisão e confiabilidade nas previsões que orientam a tomada de decisões.

Em seus estudos Makridakis, Wheelwright e Hyndaman (1998) ressaltam que o Erro Percentual Absoluto Médio (MAPE) consiste na média dos erros percentuais observados em um conjunto de dados. Para obtê-lo, calcula-se o valor absoluto de cada erro percentual, logo após, é determinada a média desses valores. Essa métrica é bastante utilizada em modelos quantitativos de previsão, pois oferece um entendimento claro da precisão do modelo, mostrando o erro em porcentagem e permitindo a comparação entre diferentes séries temporais. O cálculo do MAPE é de acordo com a Equação (1).

$$MAPE = 100 \cdot \frac{\sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|}{n},$$

em que:

A_t = Demanda real no período t .

F_t = Demanda prevista para o período t . n = Número total de períodos.


t = Número total do período.

3. Metodologia

Este estudo caracteriza-se como pesquisa aplicada, de natureza quantitativa, estruturada como estudo de caso em empresa de pequeno porte do setor comercial. A organização atua na venda de bicicletas, peças para bicicletas e motocicletas e em serviços de oficina especializada. Situada no interior de Minas Gerais, conta com cerca de dez colaboradores e atende um mercado regional há 33 anos.

O percurso metodológico foi organizado em cinco etapas principais: (i) coleta de dados; (ii) identificação de produtos-chave; (iii) análise das séries; (iv) modelagem ARIMA; e (v) comparação de resultados por meio do MAPE. As etapas são sintetizadas no fluxograma a seguir.

Figura 1 – Fluxograma Metodológico



Fonte: Elaborado pelos autores (2025)

- Etapa 1 – Coleta de dados: Foram reunidas vendas mensais entre julho de 2023 e dezembro de 2024 (18 meses), contemplando todo o portfólio comercializado.
- Etapa 2 – Identificação dos produtos-chave: A partir do volume vendido, listaram-se os dez itens mais relevantes e selecionaram-se os cinco primeiros para análise detalhada, por representarem a parcela predominante do faturamento.

Figura 2 – Ranking de vendas no período

TOP 10 VENDAS	QUANTIDADE
Produto 1	1431
Produto 2	952
Produto 3	913
Produto 4	860
Produto 5	843
Produto 6	756
Produto 7	663
Produto 8	661
Produto 9	618
Produto 10	505

Fonte: os autores (2025)


- Etapa 3 – Análise das séries temporais: Com o Minitab 22, foram produzidos gráficos das séries e estimadas as funções de autocorrelação (ACF) para examinar tendências, sazonalidade e estacionariedade.
- Etapa 4 – Modelagem ARIMA: Com base em ACF/PACF e nos critérios de informação (AIC e BIC), ajustaram-se modelos ARIMA candidatos, seguindo-se a verificação de resíduos.

- Etapa 5 – Comparação de resultados: Comparou-se o MAPE do método empírico (prática vigente) com o MAPE dos modelos ARIMA selecionados, para aferir ganhos de precisão.

4. Resultados e discussões

Aos observar o comportamento das séries temporais, nota-se que tem uma grande variabilidade nos dados. Em alguns meses, aconteceram picos de vendas isolados que não voltaram a se repetir ao longo do período analisado. Em razão da irregularidade, não foi possível identificar nenhum indício claro de sazonalidade. Essa ausência de padrão pode ser percebida na Figura 3.

Figura 3 – Serie Temporal Venda dos Produtos



Fonte: os autores (2025)

Atualmente, a forma como a empresa faz suas previsões é bastante simples, considerando a demanda do mesmo período do ano anterior e acrescentando 20% do valor obtido. Embora seja uma solução prática no dia a dia, esse tipo de estimativa tende a apresentar imprecisões, já que desconsidera possíveis mudanças no comportamento do mercado ao longo do tempo. Por conta disso, foram calculados os erros percentuais médios para os cinco produtos mais vendidos, conforme mostrado na Figura 4.


Figura 4 – MAPE método empírico

	Produto 1	Produto 2	Produto 3	Produto 4	Produto 5
MAPE	3,89	20,67	3,89	28,93	18,15

Fonte: os autores (2025)

O método atualmente utilizado tem mostrado bons resultados nos casos dos produtos 1 e 3. No entanto, para os demais itens, ainda há espaço para aprimoramento, especialmente com o apoio de técnicas estatísticas mais robustas. Pensando nisso, foi aplicada a função de autocorrelação aos produtos 2, 4 e 5, conforme Figura 4. Essa análise ajuda a entender como as vendas de um determinado período se relacionam com as vendas de períodos anteriores, permitindo identificar padrões, indícios de sazonalidade e o quanto os dados passados influenciam os resultados futuros.

Figura 4 – Autocorrelação Produtos 2, 4 e 5



Fonte: os autores (2025)

Ao observar as funções de autocorrelação dos produtos 2, 4 e 5, percebe-se que elas seguem um padrão típico de séries com tendência. Isso porque mostram o padrão de decaimento monotônico, sem oscilações bruscas, algo característico de séries temporais com tendência. Também não foram encontrados sinais de sazonalidade, pois as séries não mostram padrões cíclicos significativos.

Como as séries apresentam pouca tendência e não possuem sazonalidade, o modelo ARIMA acaba sendo uma boa escolha para realizar as previsões de demanda, pois é capaz de capturar padrões de dependência temporal, remover pequenas tendências e ainda fazer previsões curtas e médias com bom desempenho.

Com a aplicação do modelo ARIMA, é possível ajustar a previsão, com intuito a minimizar as oscilações de demanda que a própria série temporal apresentou, desta forma o resultado estabelece uma provável previsão dentro de um determinado intervalo de confiança de 95%. Os modelos utilizados são ARIMA (1,0,1) para o produto 2, ARIMA (1,0,0) para o produto 4 e ARIMA (2,1,2) para o produto 5 e as previsões podem ser vistas na Figura 5.

Figura 5 – ARIMA Produtos 2, 4 e 5



Fonte: os autores (2025)

Depois de aplicar o modelo ARIMA para cada produto, as previsões foram comparadas com os dados reais de demanda da empresa no mês seguinte. A partir dessa comparação, foi calculado o novo erro percentual médio para os produtos, com objetivo de avaliar a efetividade do modelo na prática, os dados seguem sumarizados na Tabela 1

Tabela 1 – Resultado Empírico x ARIMA

	Demanda Real (un.)	Previsão empírico	MAPE empírico	Previsão ARIMA	MAPE ARIMA	Redução MAPE
Produto 2	43	74	72,09%	48	11,63%	83,9%
Produto 4	49	40	18,37%	51	4,08%	77,8%
Produto 5	75	98	30,67%	74	1,33%	95,7%
Média			40,38%		5,68%	85,8%

Fonte: os autores (2025)

Os resultados obtidos demonstram que o modelo ARIMA apresentou desempenho superior ao método empírico, especialmente para produtos com maior variabilidade de demanda. A redução média de 85,8% no MAPE representa ganho substancial em precisão de previsão.

5. Conclusões

O presente trabalho atingiu seu objetivo ao demonstrar que a aplicação do modelo ARIMA em pequena empresa do setor comercial resultou em ganhos significativos de precisão na previsão de demanda. A redução média de 85,8% no MAPE, comparado ao método empírico utilizado, representa melhoria substancial que impacta diretamente na gestão de estoque e planejamento de compras.

Os resultados evidenciam que métodos estatísticos robustos não são exclusivos de grandes organizações com departamentos especializados. Com auxílio de softwares estatísticos acessíveis, pequenas empresas podem implementar ferramentas que proporcionam vantagens competitivas significativas.

O estudo contribui para literatura ao demonstrar aplicação prática do ARIMA em contexto de pequeno porte, onde métodos empíricos ainda predominam. A metodologia apresentada é replicável para outras empresas do setor comercial com características similares, oferecendo roteiro para modernização de processos de previsão.

Recomendações práticas para a empresa:

- Implementar gradualmente o ARIMA, iniciando pelos produtos de maior variabilidade;
- Manter método empírico para produtos de baixa variabilidade (custo-benefício favorável);
- Realizar revisão trimestral dos modelos para incorporar novos dados;
- Considerar implementação de sistema de gestão integrado (ERP) para automatização do processo;
- Capacitar colaboradores em conceitos básicos de análise de séries temporais.

Vale ressaltar que os resultados devem ser lidos à luz de algumas limitações, sendo elas: série temporal curta (18 meses) e validação pontual; estudo de caso único, com escopo limitado de produtos; uso de ARIMA univariado e dados mensais que podem ocultar dinâmica intramensal. Essas limitações sugerem revisão periódica dos modelos, teste de variantes sazonais (SARIMA), e replicação em outros contextos para ampliar a validade externa.

Diante disso recomenda-se para trabalhos futuros:

- i. Avaliar aplicação de modelos SARIMA para produtos que possam desenvolver padrões sazonais;
- ii. Investigar métodos de aprendizado de máquina (ex: redes neurais) para produtos com comportamento não-linear;
- iii. Expandir análise para demais produtos do portfólio;
- iv. Desenvolver sistema de alertas automáticos para reposição baseado em previsões.

Mesmos com as limitações descritas este trabalho demonstrou que a modernização dos processos de previsão de demanda em pequenas empresas é viável e representa oportunidade concreta de melhoria de desempenho operacional.

Referências

ANÁLISE MACRO. **Estacionariedade em séries temporais: por que é importante?** 2025. Disponível em: <https://www.analisemacro.com.br>. Acesso em: 11 abr. 2025.

BROCKWELL, Peter J.; DAVIS, Richard A. **Time Series: Theory and Methods**. 2. ed. New York: Springer, 2006.

BUENO, Adauto; GODINHO FILHO, Moacir; FRANK, Alejandro G. **Smart production planning and control in the Industry 4.0 context: a systematic literature review**. Computers & Industrial Engineering, v. 149, 2020. Disponível em: <https://doi.org/10.1016/j.cie.2020.106774>. Acesso em: 15 abr. 2025.

CHOPRA, S.; MEINDL, P. **Gerenciamento da cadeia de suprimentos: estratégia, planejamento e operação**. 6. ed. São Paulo: Pearson Prentice Hall, 2015.

CORRÊA, Henrique Luiz; GIANESI, Irineu Gustavo Nogueira; CAON, Mauro. **Planejamento, programação e controle da produção: MRP II/ERP – conceitos, uso e implantação**. 5. ed. São Paulo: Atlas, 2014.

FERNANDES, Flávio César Faria; GODINHO FILHO, Moacir. **Planejamento e controle da produção: dos fundamentos ao essencial**. São Paulo: Atlas, 2010.

HEIZER, Jay; RENDER, Barry; MUNSON, Chuck. **Operations management: sustainability and supply chain management**. Global ed. 13. ed. Harlow: Pearson, 2020.

KRAJEWSKI, Lee J.; RITZMAN, Larry P.; MALHOTRA, Manoj K. **Administração de produção e operações**. 8. ed. São Paulo: Pearson Prentice Hall, 2009.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting: methods and applications**. 3. ed. New York: John Wiley & Sons, 1998.

MELWYN, Alex. **Operations management**. Chennai: Avidus Academy of Management, 2022. Disponível em: <https://avidus.in/wp-content/uploads/2022/08/operations-management.pdf>. Acesso em: 9 jun. 2025.

MONTGOMERY, Douglas C.; JENNINGS, Cheryl L.; KULAHCI, Murat. **Introduction to time series analysis and forecasting**. Hoboken, New Jersey: John Wiley & Sons, 2008.

MOREIRA, Bruno Martins; SILVA, Elisson Souza. **Análise de métodos de previsão de demanda para implementação em uma gelateria no Centro-Oeste mineiro.** In: CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO, 2020. Anais... Disponível em: https://aprepro.org.br/conbrepro/2020/anais/arquivos/09292020_190915_5f73ace736d4f.pdf. Acesso em: 18 maio 2025.

MORETTIN, Pedro A.; TOLOI, Clélia M. C. **Análise de séries temporais.** 2. ed. São Paulo: Blucher, 2006.14

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

TUBINO, D. F. **Planejamento e controle da produção: teoria e prática.** 1. ed. São Paulo: Atlas, 2007.

TUBINO, D. F. **Planejamento e controle da produção: teoria e prática.** 3. ed. São Paulo: Atlas, 2017.