



***Análise preditiva na gestão de pequenos negócios: previsão de demanda, redução de desperdícios e otimização operacional***

*Predictive analytics in small business management: demand forecasting, waste reduction, and operational optimization*

Análisis predictivo en la gestión de pequeñas empresas: previsión de la demanda, reducción de residuos y optimización operativa

**Autor: José Cordeiro Pereira de Sá<sup>1</sup>**

**RESUMO**

Este artigo examina a aplicação da análise preditiva na gestão de pequenos negócios, com ênfase na previsão de demanda como instrumento para a redução de desperdícios, a prevenção de rupturas de estoque e a melhoria da eficiência operacional. A pesquisa adota uma abordagem qualitativa, exploratória e aplicada, fundamentada em revisão bibliográfica sobre Business Analytics, séries temporais, machine learning, gestão de estoques, safety stock e ajustes gerenciais em previsões. Discute-se como restaurantes, varejos locais e empresas de serviços podem utilizar dados transacionais, sistemas POS, planilhas e métodos estatísticos acessíveis para qualificar decisões de compra, produção, reposição e alocação de pessoal. Conclui-se que previsões integradas a custos, sazonalidade, confiabilidade de suprimento e julgamento gerencial controlado ampliam a precisão decisória e reduzem improvisações operacionais.

**Palavras-chave:** Análise preditiva. Previsão de Demanda. Pequenos Negócios. Business Analytics. Gestão de Estoques. Desperdício. Eficiência Operacional.

**ABSTRACT**

This article examines the application of predictive analytics in small business management, emphasizing demand forecasting as a tool for waste reduction, stockout prevention, and operational efficiency improvement. The study adopts a qualitative, exploratory, and applied approach, grounded in a bibliographic review of Business Analytics, time series, machine learning, inventory management, safety stock, and judgmental adjustments in forecasting. It discusses how restaurants, local retailers, and service firms can use transactional data, POS systems, spreadsheets, and accessible statistical methods to improve purchasing, production, replenishment, and staffing decisions. It concludes that forecasts integrated with costs, seasonality, supply reliability, and controlled managerial judgment increase decision accuracy and reduce operational improvisation.

**Keywords:** Predictive Analytics. Demand Forecasting. Small Businesses. Business Analytics. Inventory Management. Waste Reduction—Operational Efficiency.

**1 INTRODUÇÃO**

A digitalização das transações comerciais ampliou a disponibilidade de dados operacionais nos pequenos negócios. Sistemas de ponto de venda, plataformas de pagamento, aplicativos de delivery, agendas digitais, planilhas de estoque e relatórios financeiros passaram a registrar vendas, horários, categorias, clientes, perdas, formas de pagamento e padrões sazonais. Contudo, a existência desses

---

<sup>1</sup> Estudante do Master of Science in Business Analytics Management pela Avila University. Bacharel em Jornalismo, com experiência em análise financeira, empreendedorismo e gestão operacional.

dados não garante sua conversão em decisão. Em grande parte das empresas de menor porte, a informação permanece dispersa, subutilizada ou limitada a controles administrativos, sem ser incorporada aos processos de previsão, planejamento e alocação de recursos.

Esse descompasso torna-se particularmente relevante em restaurantes, cafeterias, mercados locais, lojas de bairro, clínicas, salões, oficinas e empresas de serviços. Nessas operações, decisões recorrentes são tomadas sob restrição de tempo, capital e pessoal: compra-se antes de conhecer a demanda efetiva, prepara-se antes de observar o fluxo real, escala-se a equipe com base em padrões anteriores e repõe-se o estoque com base na percepção do proprietário ou do gerente. A experiência prática é indispensável, mas, quando não sistematizada, pode levar a decisões reativas, pouco comparáveis e vulneráveis a vieses de memória.

A superestimação da demanda tende a gerar compras excessivas, estoque parado, desperdício, perda de qualidade e comprometimento do capital de giro. A subestimação, por sua vez, provoca rupturas, perda de vendas, atrasos, sobrecarga da equipe e deterioração da experiência do cliente. Em operações alimentícias, a perecibilidade dos insumos intensifica o impacto do erro: o excedente pode se transformar rapidamente em descarte, redução de margem ou perda sanitária. Nos varejos locais, o mesmo problema se manifesta como baixa rotação de mercadorias ou indisponibilidade de itens estratégicos. Em empresas de serviços, manifesta-se na ociosidade de profissionais ou na incapacidade de atendimento durante períodos de pico.

A previsão de demanda oferece uma resposta gerencial a esse cenário ao estimar padrões prováveis de procura com base em dados históricos, variáveis contextuais e critérios estatísticos. Sua função não é eliminar a incerteza, mas reduzi-la a um nível operacionalmente administrável. Compras, produção, reposição, escala de funcionários e controle de perdas podem ser ajustados com maior precisão quando o gestor deixa de depender apenas da intuição e passa a trabalhar com parâmetros verificáveis.

Na literatura de operações, de forecasting e de supply chain, a previsão é considerada um componente essencial do planejamento empresarial, pois sustenta decisões sobre capacidade, estoque, produção, logística e atendimento (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; MENTZER; MOON, 2004; CHOPRA; MEINDL, 2019). Estudos recentes ampliam essa discussão ao relacionar a previsão de demanda ao machine learning, ao desperdício alimentar, ao estoque de segurança, à confiabilidade de suprimento e ao julgamento gerencial. Rodrigues et al. (2024), em estudo aplicado a serviços de alimentação, demonstram que modelos de previsão de curto prazo podem reduzir simultaneamente as refeições desperdiçadas e a demanda não atendida. Tadayonrad e Ndiaye (2023) ressaltam que a avaliação de previsões deve considerar não apenas o erro estatístico, mas também os custos de estoque, o risco de ruptura, a sazonalidade e a

confiabilidade da cadeia de suprimentos. Fildes et al. (2009), por sua vez, mostram que ajustes humanos em previsões podem melhorar ou prejudicar a acurácia, conforme a qualidade da informação contextual e o controle dos vieses decisórios.

A aplicação desses fundamentos aos pequenos negócios exige proporcionalidade metodológica. Modelos sofisticados não geram valor quando alimentados por dados frágeis, interpretados de forma imprecisa ou desconectados da rotina operacional. De modo inverso, métodos simples, como médias móveis, suavização exponencial, regressão e análise de sazonalidade, podem produzir ganhos consistentes quando associados a registros confiáveis, à avaliação de erro e à disciplina decisória. A maturidade analítica não começa pela complexidade do algoritmo, mas pela capacidade de registrar, comparar, aprender e corrigir.

Diante desse contexto, este artigo analisa como pequenos negócios podem utilizar previsão de demanda para reduzir desperdícios, evitar stockouts e otimizar compras, estoque, produção e capacidade operacional. Busca-se compreender de que modo dados cotidianos podem ser transformados em parâmetros decisórios úteis, sobretudo em empresas marcadas por recursos limitados, baixa formalização gerencial e necessidade permanente de eficiência.

## **2 REFERENCIAL TEÓRICO**

### **2.1 Business Analytics e decisão em pequenos negócios**

Business Analytics compreende o uso sistemático de dados, métodos quantitativos e ferramentas analíticas para orientar decisões organizacionais. Em sua dimensão gerencial, vai além da elaboração de relatórios e dashboards, pois envolve a conversão de informação em ação. Davenport e Harris (2007) associam a competição baseada em analytics à capacidade de tomar decisões superiores com base em evidências, lógica que pode ser adaptada a empresas de menor porte, desde que respeitadas suas limitações de capital, equipe e estrutura tecnológica.

Nos pequenos negócios, a tomada de decisão costuma estar concentrada em poucos indivíduos. O proprietário ou gerente acumula funções financeiras, comerciais, operacionais e administrativas, o que aumenta a dependência de experiência prática e, ao mesmo tempo, expõe a empresa a julgamentos pouco documentados. A análise de dados reduz essa vulnerabilidade ao transformar registros dispersos em indicadores de comportamento operacional. Vendas por produto, horários de maior fluxo, itens de baixo giro, perdas recorrentes e variações por dia da semana deixam de ser percepções isoladas e passam a compor um sistema mínimo de gestão.

Esse percurso pode ser compreendido em etapas. A análise descritiva organiza o que ocorreu; a diagnóstica busca compreender as causas prováveis; a preditiva estima comportamentos futuros; e a prescritiva orienta ações. Para pequenos negócios, essa progressão não depende necessariamente de plataformas complexas. Planilhas bem estruturadas, sistemas POS e rotinas simples de consolidação já permitem identificar padrões e formular previsões iniciais. A principal barreira reside na governança dos dados: produtos cadastrados com nomes divergentes, perdas não registradas, estoques atualizados de forma irregular e vendas não segmentadas por horário dificultam qualquer modelagem confiável.

## **2.2 Previsão de demanda, séries temporais e variáveis explicativas**

Prever demanda significa estimar a procura futura por produtos, serviços, categorias ou recursos. A utilidade dessa estimativa depende da coerência entre o horizonte temporal, a granularidade e a decisão que ela apoia. Restaurantes e cafeterias necessitam de previsões diárias ou por turno para organizar as compras de produtos perecíveis, o pré-preparo e a escala de atendimento. Varejos locais podem trabalhar com projeções semanais ou mensais para reposição, composição do mix e controle do capital imobilizado. Empresas de serviços tendem a se beneficiar de estimativas de agenda, de horário e do tipo de atendimento, ajustando a capacidade à procura esperada.

Grande parte desses registros assume a forma de séries temporais. Vendas por dia, fluxo por horário, pedidos por semana, perdas por turno, faturamento mensal e consumo de insumos ao longo do tempo permitem identificar tendência, sazonalidade, ciclos e variações aleatórias (BOX et al., 2015; HYNDMAN; ATHANASOPOULOS, 2021). A tendência indica crescimento ou retração persistente; a sazonalidade revela padrões recorrentes; os ciclos acompanham oscilações econômicas ou setoriais; e o ruído corresponde a variações não explicadas pelos demais componentes.

Métodos como médias móveis, suavização exponencial, Holt-Winters e ARIMA são úteis quando há padrões temporais identificáveis. Entretanto, muitos pequenos negócios são fortemente influenciados por fatores externos: clima, feriados, eventos locais, reservas, promoções, cardápio, calendário escolar e datas de pagamento. Rodrigues et al. (2024) distinguem modelos de séries temporais, baseados principalmente em valores passados, e modelos causais, que incorporam variáveis independentes para representar o ambiente de decisão. Essa distinção é importante porque demonstra que previsões podem ser fortalecidas com dados simples, desde que sejam registrados de forma consistente.

### **2.3 Machine learning, desperdício e desempenho operacional**

O avanço dos modelos de machine learning ampliou as possibilidades de previsão em ambientes de alta variabilidade. Algoritmos como Random Forest, gradient boosting, redes neurais e LSTM captam relações não lineares, interações entre variáveis e padrões que métodos tradicionais nem sempre identificam. Ainda assim, sua adoção exige histórico suficiente, validação adequada e capacidade de interpretação.

Em um estudo com três unidades de food catering, Rodrigues et al. (2024) compararam Random Forest, LightGBM, LSTM e redes Transformer a modelos de referência que simulam práticas usuais de estimativa. Os resultados indicaram melhor desempenho do Random Forest em duas cantinas estudantis e do LSTM em uma cantina corporativa de maior escala e com horizonte histórico mais longo. A redução potencial de refeições desperdiçadas variou de 14% a 52%, ao mesmo tempo em que a demanda não atendida também foi reduzida em determinados cenários.

Duas implicações decorrem desses achados. Primeiramente, previsões mais precisas podem aproximar a sustentabilidade do desempenho econômico, pois a redução do desperdício não precisa ocorrer à custa da perda de vendas. Em segundo lugar, não há algoritmo universal. Cada operação possui características próprias de volume, sazonalidade, estabilidade e disponibilidade de variáveis. Pequenos negócios devem, portanto, evitar soluções tecnológicas adotadas por modismo e priorizar validação gradual, começando por métodos interpretáveis e evoluindo conforme a maturidade dos dados.

### **2.4 Estoque, custos e julgamento gerencial**

A previsão de demanda e a gestão de estoque são processos interdependentes. A estimativa futura orienta as compras e a reposição; o estoque de segurança protege contra incertezas na demanda e no suprimento. Tadayonrad e Ndiaye (2023) defendem que a avaliação de previsões deve incorporar custos de estoque, sazonalidade, confiabilidade dos fornecedores e risco de ruptura. Um modelo com erro médio aparentemente baixo pode gerar prejuízos se errar em produtos de alta margem, itens perecíveis, períodos de pico ou mercadorias de reposição lenta.

Em pequenos negócios, essa integração é decisiva. A dependência de poucos fornecedores, o capital de giro limitado e a baixa capacidade de armazenagem tornam o erro de estoque mais oneroso. Produtos com demanda sazonal exigem parâmetros distintos ao longo do tempo. Fornecedores com atrasos frequentes demandam maior proteção. Itens perecíveis, por outro lado, exigem cautela adicional, pois elevar o estoque reduz o risco de falta, mas aumenta o de descarte. O ponto adequado

depende da combinação entre a demanda esperada, a validade, a margem, o lead time, o custo da falta e o custo do excesso.

O julgamento gerencial continua necessário porque os modelos estatísticos não capturam todos os eventos contextuais. Mudanças climáticas, obras próximas, reservas inesperadas, eventos locais, campanhas promocionais e falhas de fornecedores podem justificar ajustes na previsão original. Fildes et al. (2009), entretanto, demonstram que intervenções humanas podem deteriorar a acurácia quando realizadas sem critério, especialmente em ajustes pequenos, intuitivos ou enviesados. O desafio é transformar a experiência em uma variável controlada: registrar a previsão original, documentar o ajuste, explicitar a justificativa e, posteriormente, comparar o resultado com a demanda real.

### 3 METODOLOGIA

Este estudo adota uma abordagem qualitativa, exploratória e aplicada, fundamentada em revisão bibliográfica narrativa e em análise teórico-aplicada. Não se pretende testar empiricamente um modelo em uma empresa específica, mas sim sistematizar fundamentos científicos e operacionais capazes de orientar a adoção de modelos de previsão de demanda em pequenos negócios.

Foram examinados obras e artigos relacionados a Business Analytics, forecasting, séries temporais, machine learning, gestão de estoques, safety stock, desperdício em operações alimentícias e julgamento gerencial em previsões. A seleção priorizou publicações com aderência direta ao problema investigado, relevância acadêmica e aplicabilidade ao contexto de empresas com recursos limitados.

Três estudos receberam atenção central. Rodrigues et al. (2024) fundamentam a discussão sobre a previsão de curto prazo nos serviços de alimentação e seus efeitos no desperdício e na demanda não atendida. Tadayonrad e Ndiaye (2023) sustentam a análise sobre previsão de demanda, custos de estoque, sazonalidade, confiabilidade de suprimento e safety stock. Fildes et al. (2009) orientam a reflexão sobre ajustes gerenciais, vieses e governança da previsão.

A interpretação foi organizada em quatro eixos: qualidade dos dados operacionais; adequação dos métodos preditivos à maturidade analítica do negócio; integração entre previsão, estoque, produção e capacidade; e controle dos ajustes humanos sobre previsões estatísticas. Por se tratar de um estudo bibliográfico aplicado, a contribuição reside na articulação crítica da literatura e na proposição de diretrizes compatíveis com restaurantes, varejos locais e empresas de serviços.

#### 4 DISCUSSÃO TEÓRICO-APLICADA

Pequenos negócios operam com pouca margem de erro. Capital restrito, equipes reduzidas, processos pouco formalizados, dependência de fornecedores próximos e forte exposição ao fluxo diário de clientes tornam as decisões operacionais sensíveis em proporção. Uma compra mal dimensionada pode comprometer o caixa; uma ruptura pontual pode afastar clientes recorrentes; uma escala inadequada pode elevar custos ou prejudicar o atendimento. Nesse ambiente, a previsão de demanda atua como um mecanismo de disciplina gerencial, pois transforma percepções em parâmetros e permite comparar hipóteses com os resultados.

Essa transformação começa pela estruturação dos dados. Nenhuma técnica preditiva compensa uma base inconsistente. Produtos cadastrados de formas diferentes, perdas não registradas, estoques atualizados de forma irregular e categorias mal definidas reduzem a confiabilidade das estimativas. Sistemas POS oferecem um ponto de partida relevante ao registrar produto, horário, quantidade, valor, forma de pagamento e canal. Planilhas complementam esse processo ao consolidar compras, perdas, estoque inicial, estoque final e observações operacionais. Em restaurantes, dados sobre reservas, clima, eventos e cardápio podem ampliar a capacidade explicativa; em serviços, agenda, cancelamentos e duração média do atendimento tornam-se variáveis relevantes.

A escolha do método deve acompanhar a maturidade analítica do negócio. Operações com histórico curto e registros incompletos podem iniciar com médias móveis e com sazonalidade simples por dia da semana. À medida que a base se torna mais confiável, suavização exponencial, Holt-Winters e regressão permitem incorporar a tendência, a sazonalidade e variáveis explicativas. Em estágios mais avançados, modelos de machine learning podem ser testados para captar relações complexas. A pergunta metodológica central não é qual algoritmo é superior em termos absolutos, mas qual técnica produz decisões melhores em determinado contexto operacional.

Também é necessário avaliar a previsão pelos efeitos econômicos do erro. Reduzir desperdício sem considerar a demanda não atendida pode gerar uma falsa eficiência. Um restaurante que prepara pouco descarta menos, mas também pode vender menos; um varejo que reduz o estoque parece mais enxuto, mas pode perder clientes por indisponibilidade de produtos. Métricas como MAE, RMSE e MAPE ajudam a mensurar acurácia, mas devem ser complementadas por indicadores como ruptura, desperdício, margem, estoque parado, vendas perdidas e produtividade por hora trabalhada. O erro estatístico importa, mas sua consequência gerencial importa ainda mais.

A gestão de estoque reforça a necessidade de análise econômica. O safety stock deve refletir tanto a incerteza da demanda quanto a do suprimento. Produtos sazonais precisam de parâmetros distintos

conforme o período; fornecedores instáveis exigem maior proteção; itens críticos, de alta margem ou de difícil substituição não devem ser tratados como mercadorias comuns. Decisões baseadas apenas em médias escondem picos e geram distorções: sobra em dias fracos, falta em dias fortes e alocação de capital inadequada.

A capacidade operacional também deve ser incorporada ao processo preditivo. A demanda não se limita a produtos, mas também a tempo, atenção, espaço e mão de obra. Prever o fluxo de clientes, o número de transações ou o volume de serviços permite ajustar as escalas e reduzir tanto a ociosidade quanto a sobrecarga. Em restaurantes, a falta de equipe nos horários de pico gera atrasos e erros; em lojas, reduz a conversão e o atendimento consultivo; em serviços, compromete a pontualidade e aumenta os cancelamentos. A previsão por turno ou por horário aproxima Business Analytics do workforce planning, mesmo em operações pequenas.

O julgamento humano, por fim, precisa ser preservado, mas controlado. Proprietários e gerentes conhecem informações não capturadas pelo histórico: eventos locais, mudanças climáticas, reservas, alterações de cardápio, atrasos de fornecedores e comportamento de clientes habituais. Esse conhecimento pode melhorar a previsão quando documentado e avaliado. Sem registro, porém, ajustes manuais podem apenas reproduzir medo de ruptura, otimismo excessivo ou memória recente. A governança mínima exige comparar a previsão original, o ajuste realizado, a justificativa e a demanda real posterior. Com isso, a experiência deixa de ser improvisado e passa a integrar o aprendizado organizacional.

## **5 MODELO TEÓRICO-APLICADO PARA PEQUENOS NEGÓCIOS**

A adoção da previsão de demanda deve ser compreendida como construção gradual de capacidade analítica. O ponto de partida consiste em consolidar os registros de vendas, compras, estoque, perdas, horários, categorias e canais. Quanto mais consistente for a base, menor será o risco de previsões instáveis. Em operações alimentícias, convém acrescentar dados sobre cardápio, insumos críticos, reservas, clima e eventos; em serviços, devem ser observados a agenda, a duração do atendimento, os cancelamentos e os períodos de maior procura.

Com a base organizada, a empresa precisa definir qual decisão pretende qualificar. Compras exigem previsão por produto, categoria ou insumo crítico; a produção demanda leitura por turno, dia da semana e item de maior saída; a escala de equipe depende do fluxo, do número de transações, da duração média do atendimento e dos horários de pico. Essa definição evita previsões genéricas, que podem ser estatisticamente interessantes, mas pouco úteis na rotina.

A etapa seguinte consiste em selecionar um método compatível com a maturidade informacional. Médias móveis, médias ponderadas e sazonalidade semanal podem sustentar os primeiros ciclos. Depois, a suavização exponencial, o Holt-Winters e a regressão permitem um refinamento mais aprofundado. Modelos de machine learning podem ser incorporados em fases posteriores, desde que haja volume de dados, variáveis relevantes e capacidade de validação. Em qualquer nível, a previsão deve ser avaliada com base em métricas estatísticas e em indicadores operacionais.

A estimativa precisa, então, ser convertida em ação. Prever alta demanda deve orientar compras ajustadas, reforço da equipe, preparo adequado ou revisão do estoque de segurança. Prever a queda deve apoiar a redução da produção, o controle de perdas, a negociação com fornecedores ou a realização de promoções direcionadas. Quando não altera a decisão, a previsão permanece como um exercício técnico de baixa utilidade gerencial.

Esse ciclo deve ser continuamente revisado. A empresa registra dados, estima demanda, decide, executa, mede o erro e aperfeiçoa o modelo. Ajustes humanos podem ser admitidos quando houver informação contextual relevante, desde que documentados e comparados posteriormente ao resultado real. Assim, a previsão torna-se uma rotina de aprendizagem, e não um procedimento isolado.

## CONSIDERAÇÕES FINAIS

A análise preditiva aplicada a pequenos negócios constitui uma ferramenta relevante para a eficiência operacional, o controle financeiro e a qualificação da tomada de decisão. Ao transformar dados históricos em estimativas de demanda, reduz a dependência de improviso e apoia decisões recorrentes de compra, produção, estoque, equipe e capacidade.

A literatura examinada demonstra que pequenos negócios já dispõem, em muitos casos, de infraestrutura mínima para iniciar práticas de forecasting. Sistemas POS, planilhas, registros de estoque, relatórios de perdas e históricos de atendimento podem sustentar modelos simples e úteis. O desafio central está menos na tecnologia do que na padronização dos dados, na rotina analítica e na integração entre previsão e decisão.

Previsões mais precisas podem reduzir desperdício e a demanda não atendida, especialmente em operações alimentícias. Contudo, a avaliação do modelo deve considerar custos de estoque, sazonalidade, confiabilidade do suprimento, risco de ruptura e o impacto econômico do erro. Acurácia estatística isolada não garante uma melhor decisão quando os custos de errar para cima e para baixo são assimétricos.

O julgamento gerencial permanece indispensável, mas precisa ser disciplinado. A experiência prática complementa modelos ao incorporar informação contextual não registrada; sem controle, pode introduzir vieses e ampliar erros. Registrar, justificar e avaliar ajustes transforma intuição em conhecimento organizacional.

Conclui-se que a previsão de demanda é estratégica porque aproxima o consumo esperado da alocação de recursos. Quando aplicada de forma gradual, interpretável e vinculada a indicadores operacionais, reduz desperdício, stockouts, ociosidade e capital parado, fortalecendo a competitividade de empresas com recursos limitados.

## REFERÊNCIAS

ARMSTRONG, J. Scott. *Principles of forecasting: a handbook for researchers and practitioners*. Boston: Kluwer Academic Publishers, 2001.

BOX, George E. P.; JENKINS, Gwilym M.; REINSEL, Gregory C.; LJUNG, Greta M. *Time series analysis: forecasting and control*. 5. ed. Hoboken: Wiley, 2015.

CHOPRA, Sunil; MEINDL, Peter. *Supply chain management: strategy, planning, and operation*. 7. ed. Boston: Pearson, 2019.

DAVENPORT, Thomas H.; HARRIS, Jeanne G. *Competing on analytics: the new science of winning*. Boston: Harvard Business School Press, 2007.

FILDES, Robert; GOODWIN, Paul; LAWRENCE, Michael; NIKOLOPOULOS, Konstantinos. Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning. *International Journal of Forecasting*, v. 25, n. 1, p. 3–23, 2009. DOI: 10.1016/j.ijforecast.2008.11.010.

GIL, Antônio Carlos. *Métodos e técnicas de pesquisa social*. 7. ed. São Paulo: Atlas, 2017.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. *Forecasting: principles and practice*. 3. ed. Melbourne: OTexts, 2021.

HYNDMAN, Rob J.; KOEHLER, Anne B. Another look at measures of forecast accuracy—*International Journal of Forecasting*, v. 22, n. 4, p. 679–688, 2006.

KOLASSA, Stephan; SIEMSEN, Enno. *Demand forecasting for managers*. New York: Business Expert Press, 2016.

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

MENTZER, John T.; MOON, Mark A. *Sales forecasting management: a demand management approach*. 2. ed. Thousand Oaks: Sage Publications, 2004.

PROVOST, Foster; FAWCETT, Tom. *Data science for business: what you need to know about data mining and data-analytic thinking*. Sebastopol: O'Reilly Media, 2013.



RODRIGUES, Miguel; MIGUÉIS, Vera; FREITAS, Susana; MACHADO, Telmo. Machine learning models for short-term demand forecasting in food catering services: a solution to reduce food waste. *Journal of Cleaner Production*, v. 435, 140265, 2024. DOI: 10.1016/j.jclepro.2023.140265.

SHMUELI, Galit; KOPPIUS, Otto R. Predictive analytics in information systems research. *MIS Quarterly*, v. 35, n. 3, p. 553–572, 2011.

SILVER, Edward A.; PYKE, David F.; THOMAS, Douglas J. *Inventory and production management in supply chains*. 4. ed. Boca Raton: CRC Press, 2016.

SLACK, Nigel; BRANDON-JONES, Alistair. *Operations management*. 9. ed. Harlow: Pearson, 2019.

SYNTETOS, Aris A.; BOYLAN, John E.; CROSTON, J. D. On the categorization of demand patterns. *Journal of the Operational Research Society*, v. 56, n. 5, p. 495–503, 2005.

TADAYONRAD, Yasin; NDIAYE, Alassane Balle. A new key performance indicator model for demand forecasting in inventory management considering supply chain reliability and seasonality. *Supply Chain Analytics*, v. 3, 100026, 2023. DOI: 10.1016/j.sca.2023.100026.

TURBAN, Efraim; SHARDA, Ramesh; DELEN, Dursun. *Business intelligence, analytics, and data science: a managerial perspective*. 4. ed. Boston: Pearson, 2018.

WALLER, Matthew A.; FAWCETT, Stanley E. Data science, predictive analytics, and big data: a revolution that will transform supply chain design and management. *Journal of Business Logistics*, v. 34, n. 2, p. 77-84, 2013.