REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

PREVISÃO DE DEMANDA EM E-COMMERCE COM MACHINE LEARNING

E-COMMERCE DEMAND FORECASTING WITH MACHINE LEARNING

PREDICCIÓN DE LA DEMANDA EN EL COMERCIO ELECTRÓNICO CON APRENDIZAJE AUTOMÁTICO

Guilherme Alberto Leão Damico[1]

https://doi.org/10.47820/recima21.v7i12.9796

PUBLICADO: 11/2026

RESUMO

A previsão de demanda pode apoiar decisões de compras e controle de estoque em operações de comércio eletrônico. Este estudo investiga a aplicação de modelos de aprendizado de máquina para prever vendas diárias de produtos comercializados no Mercado Livre e relacionar as estimativas a sugestões de reposição. Foram utilizados dados de um relatório de vendas exportado em outubro de 2026, com seleção de três códigos de produto (SKUs). Após a filtragem de registros com status “Entregue”, as séries diárias foram construídas para o período de 26 de setembro a 25 de outubro de 2026. Foram avaliados os modelos de Regressão Linear e Árvore de Decisão, comparados a uma referência sazonal baseada nas vendas de sete dias antes. A avaliação reservou cronologicamente os sete últimos dias disponíveis para teste e utilizou MAE, RMSE e R^2. Os resultados variaram conforme o produto: a Regressão Linear apresentou menor MAE em dois SKUs, enquanto a referência sazonal foi superior no terceiro. Os valores de R^2 negativos em dois dos três casos, além do curto histórico e do pequeno conjunto de teste, indicam que as previsões são preliminares e não devem ser aplicadas sem validação adicional. A sugestão de compra foi calculada com margem de segurança de 10%, considerando o estoque informado. O estudo demonstra uma aplicação inicial de previsão de demanda com dados reais de uma operação de comércio eletrônico.

PALAVRAS-CHAVE: Previsão de demanda. Comércio eletrônico. Aprendizado de máquina. Gestão de estoque. Regressão linear. Árvores de decisão.

ABSTRACT

Demand forecasting can support purchasing and inventory-control decisions in e-commerce operations. This study investigates machine-learning models to forecast daily sales of products marketed on Mercado Livre and relate the estimates to replenishment suggestions. The study used a sales report exported in October 2026, from which three product identifiers (SKUs) were selected. After filtering records with the status “Delivered”, daily series were constructed for September 26 through October 25, 2026. Linear Regression and Decision Tree models were evaluated against a seasonal reference based on sales seven days earlier. The last seven available observations were reserved chronologically for testing, using MAE, RMSE, and R^2. Results varied by product: Linear Regression achieved the lowest MAE for two SKUs, while the seasonal reference performed best for the third. Negative R^2 values in two of the three cases, together with the short history and small test set, indicate that the forecasts are preliminary and require further validation. The replenishment suggestion was calculated with a 10% safety margin and the reported inventory. The study presents an initial demand-forecasting application using real data from an e-commerce operation.

[1] UNIARA, graduando em Engenharia de Computação.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

KEYWORDS: *Demand forecasting. E-commerce. Machine learning. Inventory management. Linear regression. Decision trees.*

RESUMEN
La previsión de la demanda puede apoyar las decisiones de compra y control de inventario en el comercio electrónico. Este estudio investiga modelos de aprendizaje automático para predecir las ventas diarias de productos comercializados en Mercado Livre y relacionar las estimaciones con sugerencias de reposición. Se utilizó un informe de ventas exportado en octubre de 2026, del que se seleccionaron tres códigos de producto (SKU). Tras filtrar los registros con estado "Entregado", se construyeron series diarias para el período del 26 de septiembre al 25 de octubre de 2026. Se evaluaron los modelos de Regresión Lineal y Árbol de Decisión frente a una referencia estacional basada en las ventas de siete días antes. Los últimos siete registros disponibles se reservaron cronológicamente para prueba, utilizando MAE, RMSE y R^2. Los resultados variaron según el producto: la Regresión Lineal obtuvo el menor MAE para dos SKU, mientras que la referencia estacional fue superior para el tercero. Los valores negativos de R^2 en dos de los tres casos, junto con el historial corto y el pequeño conjunto de prueba, indican que las previsiones son preliminares y requieren validación adicional. La sugerencia de compra se calculó con un margen de seguridad del 10% y el inventario informado. El estudio presenta una aplicación inicial de previsión de demanda con datos reales de una operación de comercio electrónico.

PALABRAS CLAVE: *Predicción de la demanda. Comercio electrónico. Aprendizaje automático. Gestión de inventario. Regresión lineal. Árboles de decisión.*

1. INTRODUÇÃO

O crescimento do comércio eletrônico ampliou a quantidade de informações disponíveis sobre transações, produtos e comportamento de compra. Em plataformas digitais, os registros de pedidos podem ser utilizados não apenas para acompanhar o desempenho comercial, mas também para apoiar decisões operacionais, entre elas o planejamento de compras e a manutenção de níveis adequados de estoque. Essa possibilidade torna a análise de dados uma atividade relevante para negócios de diferentes portes.

A gestão de estoque envolve um equilíbrio entre disponibilidade de produtos e custos associados à manutenção de mercadorias. Quando a quantidade armazenada é insuficiente, a empresa pode perder vendas e comprometer a experiência do consumidor. Por outro lado, a aquisição excessiva pode imobilizar recursos financeiros e aumentar o risco de mercadorias permanecerem paradas. Ballou (2006) discute a relação entre logística, estoques e nível de serviço, evidenciando a importância de decisões coordenadas ao longo da cadeia de suprimentos.

A previsão de demanda busca estimar a quantidade que poderá ser vendida em determinado horizonte temporal. Em sua forma mais simples, pode utilizar médias de vendas

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

passadas; em abordagens mais elaboradas, pode incorporar atributos temporais, preços, promoções e informações sobre os produtos. Nenhuma abordagem elimina a incerteza, mas uma estimativa estruturada pode oferecer uma referência quantitativa para apoiar o planejamento.

O aprendizado de máquina permite construir modelos que identificam relações a partir de exemplos históricos. Entretanto, a utilidade de um algoritmo depende da adequação entre o problema, os dados, os atributos e o processo de avaliação. Um modelo complexo não necessariamente supera uma regra simples, especialmente quando o histórico é curto, apresenta ruído ou não representa adequadamente mudanças futuras. Por isso, comparações empíricas são fundamentais.

Este trabalho investiga o uso de Regressão Linear e Árvore de Decisão para prever a demanda de produtos de comércio eletrônico, utilizando um relatório real de vendas do Mercado Livre. O recorte experimental concentra-se em três SKUs, com previsão para sete dias e cálculo demonstrativo de reposição de estoque. A análise compara os modelos com uma referência sazonal simples, utilizando métricas de erro em uma separação temporal entre treinamento e teste.

O objetivo geral é avaliar, de forma preliminar, o desempenho de modelos de aprendizado de máquina na previsão diária de vendas e analisar como suas estimativas podem ser relacionadas a uma regra de reposição. Os objetivos específicos são: organizar os registros comerciais em séries temporais por SKU; construir atributos baseados no calendário e no histórico recente; treinar e avaliar Regressão Linear e Árvore de Decisão; comparar os modelos com uma referência sazonal; calcular métricas de erro; e demonstrar uma regra de reposição que considere a demanda prevista, o estoque atual e uma margem de segurança.

A justificativa do estudo está relacionada à possibilidade de aproveitar dados que pequenos vendedores já possuem em relatórios de plataformas de comércio eletrônico. Mesmo quando não há integração com um sistema avançado de planejamento, o histórico de vendas pode ser organizado e analisado para apoiar decisões. Contudo, o valor prático de uma recomendação depende de sua confiabilidade, de modo que a avaliação do erro e a explicitação das limitações fazem parte central do trabalho.

O problema de pesquisa pode ser formulado da seguinte maneira: em que medida modelos simples de aprendizado de máquina conseguem prever a demanda de produtos de e-commerce a partir de um histórico comercial curto, e como as estimativas obtidas podem ser utilizadas em uma regra preliminar de reposição de estoque? A resposta exige considerar tanto os resultados numéricos quanto as limitações do conjunto de dados.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

2. REFERENCIAL TEÓRICO

2.1. Aprendizado de máquina

O aprendizado de máquina é um campo da Inteligência Artificial voltado à construção de sistemas que identificam padrões a partir de dados. Mitchell (1997) relaciona o aprendizado à melhoria do desempenho de um programa em determinada tarefa por meio da experiência. Em termos práticos, um modelo recebe exemplos, ajusta seus parâmetros ou regras e utiliza o conhecimento aprendido para produzir estimativas sobre observações não vistas durante o treinamento.

Em uma tarefa de previsão de demanda, a variável-alvo representa a quantidade vendida em um intervalo definido. As variáveis de entrada podem incluir informações sobre datas, vendas anteriores, preço, categoria e promoções. O processo de aprendizagem procura relacionar essas características à demanda observada. A capacidade de generalização deve ser verificada com dados separados do treinamento, pois um modelo pode ajustar-se aos exemplos conhecidos sem prever adequadamente situações futuras.

Os algoritmos supervisionados são treinados com exemplos que possuem uma resposta conhecida. Na regressão, essa resposta geralmente é numérica, como unidades vendidas por dia. A qualidade do modelo é avaliada comparando as previsões com valores reais reservados para teste. Esse procedimento permite estimar a magnitude dos erros, embora o resultado dependa da representatividade do período avaliado.

2.2. Previsão de demanda no comércio eletrônico

A previsão de demanda tem aplicações no planejamento de compras, na distribuição e no dimensionamento dos estoques. Em plataformas de e-commerce, o comportamento de compra pode mudar rapidamente em função de preços, campanhas promocionais, sazonalidade, avaliações de consumidores e disponibilidade dos produtos. A análise do histórico deve, portanto, considerar o contexto em que as vendas ocorreram.

Uma previsão superestimada pode resultar em aquisição de quantidades excessivas, enquanto uma previsão subestimada pode elevar o risco de ruptura. A consequência econômica de cada erro nem sempre é simétrica: faltar um produto de alta saída pode ser mais prejudicial do que manter algumas unidades adicionais, mas isso depende do custo, do prazo de reposição e da margem do produto. Uma política de estoque deve combinar previsão, restrições operacionais e critérios comerciais.

Os dados transacionais normalmente registram cada pedido individualmente, enquanto os modelos de séries temporais exigem observações organizadas por intervalos. Por esse

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

motivo, uma etapa frequente é agregar as quantidades por dia e por produto. Dias sem vendas devem ser representados explicitamente como zero apenas quando o período estiver completamente observado; datas incompletas ou falhas na coleta não devem ser automaticamente interpretadas como ausência de demanda.

2.3. Regressão linear

A Regressão Linear estima uma relação entre uma variável dependente e um conjunto de variáveis explicativas por meio de uma combinação linear dos atributos. Em uma formulação geral, a previsão pode ser expressa como uma constante somada aos produtos entre coeficientes e variáveis de entrada. Os coeficientes são ajustados para reduzir uma função de erro no conjunto de treinamento.

A simplicidade é uma das vantagens da Regressão Linear. O modelo costuma ser relativamente rápido e oferece coeficientes que podem ajudar a interpretar a contribuição associada a cada atributo. Entretanto, a hipótese de linearidade limita sua capacidade de representar padrões complexos, mudanças abruptas e interações não lineares. Também pode produzir valores negativos em problemas de contagem, motivo pelo qual, neste experimento, previsões negativas foram limitadas a zero para fins de apresentação.

Géron (2019) apresenta a Regressão Linear entre os métodos fundamentais de aprendizado supervisionado e destaca a importância de avaliar os modelos em dados não utilizados no ajuste. A escolha desse algoritmo neste estudo busca estabelecer um ponto de comparação interpretável e de implementação simples.

2.4. Árvores de decisão

As Árvores de Decisão organizam a previsão em uma estrutura de divisões sucessivas dos atributos. Cada divisão separa observações de acordo com uma regra, e as folhas finais fornecem a previsão correspondente. Em tarefas de regressão, a estimativa de uma folha geralmente se baseia nos valores das observações de treinamento que chegaram àquela região.

Uma árvore pode representar relações não lineares e interações sem exigir que todas elas sejam especificadas previamente. Ao mesmo tempo, árvores muito profundas podem adaptar-se excessivamente aos dados de treinamento, reduzindo a capacidade de generalização. O controle da profundidade e a avaliação cronológica ajudam a reduzir esse risco, embora não eliminem a necessidade de validação com mais dados.

Neste estudo, foi utilizada uma profundidade máxima de três níveis. Essa escolha limita a complexidade do modelo para um conjunto de dados pequeno. A configuração não deve ser

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

interpretada como a melhor possível para todos os produtos; trata-se de uma escolha experimental inicial que poderá ser ajustada em estudos posteriores.

2.5. Modelos de referência e comparação

A avaliação de um modelo preditivo deve considerar uma referência simples. Sem esse parâmetro, uma métrica isolada pode sugerir desempenho aparentemente aceitável sem demonstrar que o algoritmo acrescenta valor em relação a uma estratégia trivial. Em séries temporais, uma referência sazonal pode utilizar a observação do mesmo dia da semana anterior, isto é, a venda registrada sete dias antes.

Neste experimento, a previsão sazonal foi calculada usando o valor de sete dias antes como estimativa para o dia correspondente. A abordagem foi comparada à Regressão Linear e à Árvore de Decisão nos mesmos sete dias de teste. A comparação não pressupõe que a referência seja sempre superior, mas permite verificar se a complexidade adicional dos modelos resulta em redução de erro.

Em aplicações futuras, outras referências podem ser avaliadas, como a média móvel dos últimos sete dias ou a repetição da última observação. A escolha deve ser coerente com a frequência dos dados e com o comportamento do negócio. O mais importante é que todos os métodos sejam avaliados no mesmo intervalo e contra os mesmos valores observados.

2.6. Qualidade dos dados e engenharia de atributos

A qualidade dos dados influencia diretamente o processo de aprendizagem. Registros duplicados podem aumentar artificialmente a frequência de determinadas vendas; datas inconsistentes podem deslocar transações entre períodos; e status de pedidos diferentes podem representar situações comerciais distintas. Por isso, a preparação precisa identificar os campos relevantes e definir regras explícitas para inclusão e exclusão de registros.

A engenharia de atributos consiste em transformar dados brutos em variáveis que representem características úteis ao problema. Para uma série diária, atributos comuns incluem o dia da semana, a venda do dia anterior, a venda de sete dias antes e a média móvel de uma janela recente. Esses atributos resumem parte do comportamento recente e permitem que modelos tabulares sejam aplicados a uma tarefa temporal.

Um risco importante é o vazamento de dados, que ocorre quando informações que não estariam disponíveis no momento da previsão acabam sendo utilizadas no treinamento ou na avaliação. Para evitá-lo, as variáveis de defasagem devem ser calculadas somente a partir de valores anteriores à data prevista, e a divisão entre treino e teste deve respeitar a ordem

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

cronológica. A validação aleatória, comum em outros problemas, pode ser inadequada quando a sequência temporal é essencial.

2.7. Métricas de avaliação

O Erro Absoluto Médio (MAE) é calculado pela média dos valores absolutos da diferença entre a demanda real e a previsão. Como permanece na mesma unidade da variável-alvo, facilita a interpretação operacional. Por exemplo, um MAE de quatro significa que, em média, a diferença absoluta entre previsão e observação foi de quatro unidades por dia no período de teste.

O Erro Quadrático Médio (MSE) calcula a média dos erros elevados ao quadrado, penalizando mais fortemente erros grandes. A Raiz do Erro Quadrático Médio (RMSE) corresponde à raiz quadrada do MSE e retorna à unidade original da demanda. O RMSE é útil quando erros grandes são especialmente relevantes, mas pode ser influenciado por observações extremas.

O coeficiente de determinação R^2 compara o erro do modelo com a variabilidade dos valores observados em relação à média. Um valor negativo pode ocorrer quando o modelo apresenta desempenho inferior ao de uma previsão constante igual à média do conjunto de teste. Em séries curtas e com muitos zeros, o R^2 pode variar substancialmente; por isso, deve ser interpretado junto com MAE, RMSE e a inspeção dos valores reais.

Nenhuma métrica deve ser interpretada isoladamente. O MAE informa a magnitude média do erro absoluto, o RMSE evidencia a influência de erros maiores e o R^2 oferece uma comparação relativa à variabilidade do teste. Em aplicações de estoque, também pode ser útil medir a frequência de rupturas, o excesso previsto e o custo de decisões, desde que existam dados econômicos confiáveis para esse cálculo.

2.8. Previsão e política de reposição

A previsão de demanda não é equivalente a uma decisão de compra. A primeira estima o que poderá ser vendido; a segunda considera essa estimativa, o estoque disponível e restrições do processo de abastecimento. Mesmo uma previsão precisa pode gerar uma decisão inadequada se ignorar o prazo de entrega, o estoque já comprometido, as quantidades mínimas de pedido ou a frequência de compra.

Para demonstrar a ligação entre previsão e reposição, este estudo definiu uma regra simples: multiplicar a demanda estimada para sete dias por 1,10, arredondar para cima e subtrair o estoque disponível. Se o resultado for negativo, a compra sugerida é zero. O fator 1,10 representa uma margem de segurança de 10%, estabelecida como hipótese de trabalho, e não como parâmetro comprovadamente ótimo.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

Essa regra não incorpora prazo de entrega, estoque de segurança calculado estatisticamente, pedidos em trânsito, estoque reservado nem sazonalidade futura. Portanto, seu propósito é ilustrar o fluxo de decisão e não substituir um sistema completo de planejamento. Uma implementação mais robusta deverá incluir esses fatores e validar o efeito econômico das recomendações.

3. METODOLOGIA

3.1. Classificação e desenho experimental

A pesquisa é aplicada, quantitativa e experimental. É aplicada porque investiga uma possibilidade de uso em um problema operacional; quantitativa porque utiliza valores numéricos e métricas para avaliar previsões; e experimental porque envolve a preparação dos dados, treinamento dos modelos e comparação dos resultados em um conjunto separado.

O desenho experimental foi organizado em etapas: obtenção do arquivo; inspeção dos campos; seleção de três SKUs; filtragem por status; agregação por data e produto; construção dos atributos temporais; separação cronológica em treino e teste; ajuste dos modelos; cálculo das métricas; geração das previsões para sete dias; e demonstração da regra de reposição. Cada etapa foi definida para que os resultados possam ser reproduzidos a partir do arquivo original e das regras descritas.

O experimento apresentado neste artigo utiliza exclusivamente dados reais de vendas do Mercado Livre e Mercado Shops. A análise foi delimitada a três SKUs, com o objetivo de demonstrar um fluxo aplicado de preparação dos dados, treinamento e avaliação de modelos e cálculo ilustrativo de reposição. Não se pretende generalizar os resultados para outras lojas, plataformas ou categorias de produtos.

3.2. Fonte e estrutura dos dados

O arquivo analisado foi um relatório Excel de vendas do Mercado Livre e Mercado Shops, exportado em 26 de outubro de 2026. A planilha contém várias colunas administrativas, financeiras e logísticas, incluindo número da venda, data, estado, quantidade, SKU, título do anúncio e informações de entrega. O relatório também apresenta dados pessoais de compradores, que não foram utilizados no estudo.

A estrutura do arquivo exigiu identificar a linha que continha os cabeçalhos, pois as primeiras linhas apresentavam avisos e informações de navegação da plataforma. Após a identificação das colunas, foram selecionados os campos necessários à análise: data da venda,

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

estado/status, quantidade de unidades, SKU e título do anúncio. A seleção de somente três produtos reduziu a abrangência do experimento, mas tornou a análise inicial mais delimitada.

Os produtos escolhidos foram 00691-002-G, 00691-002-M e 40300-001-G. Os dois primeiros correspondem a anúncios de kits de cuecas Lupo em tamanhos diferentes; o terceiro corresponde a um kit de calcinhas Lupo Loba. O estoque atual informado foi de 50 unidades para cada um dos dois primeiros SKUs e 90 unidades para o terceiro.

Na planilha original, os status de venda representam etapas distintas, como entrega, transporte, preparação de etiqueta, cancelamento ou devolução. Para esta análise inicial, foram considerados apenas os registros cujo campo de estado indicava “Entregue”. Essa regra reduz a mistura de vendas concluídas com pedidos ainda em processamento. Ela não elimina todos os riscos de distorção, pois devoluções posteriores e diferenças de registro também precisam ser verificadas em uma análise operacional definitiva.

3.3. Seleção dos SKUs e descrição inicial

A seleção dos SKUs considerou a presença de registros suficientes para formar uma série temporal diária durante o período disponível. A Tabela 1 apresenta o número de registros com status “Entregue” e a soma de unidades desses registros. O número de registros não deve ser confundido com a quantidade de unidades, pois uma transação pode conter mais de uma unidade.

Tabela 1. Registros de venda concluída e unidades por SKU

SKU	Descrição resumida	Registros entregues	Unidades
00691-002-G	Kit 5 cuecas Lupo, tamanho G	318	338
00691-002-M	Kit 5 cuecas Lupo, tamanho M	280	290
40300-001-G	Kit 5 calcinhas Lupo Loba, tamanho G	142	148

Fonte: Elaborado pelo autor a partir do relatório exportado do Mercado Livre.

Os registros entregues dos dois SKUs de cuecas apresentam maior quantidade de transações e unidades do que o SKU de calcinhas no período analisado. Essa diferença descreve apenas o intervalo observado e não deve ser generalizada para outros meses, campanhas ou períodos sazonais. A seleção também não implica que os produtos sejam comparáveis em preço, margem ou perfil de consumidor, pois essas variáveis não foram incorporadas à modelagem.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

3.4. Tratamento e agregação temporal

As datas foram convertidas para um formato de data padronizado, e as quantidades foram tratadas como valores numéricos. Para cada SKU, foram somadas as unidades dos registros entregues em cada data. Em seguida, foi criada uma sequência diária contínua entre 26 de setembro e 25 de outubro de 2026. Datas sem vendas entregues registradas nesse intervalo foram representadas por zero, sob a hipótese de que o relatório contém a cobertura necessária para o período.

A data de 26 de outubro foi excluída da série diária utilizada no teste por não constituir um dia completo de vendas concluídas no relatório analisado. O relatório foi exportado durante o próprio dia e inclui transações em diferentes estados de processamento. A inclusão de uma data incompleta como zero poderia introduzir um viés artificial para baixo, razão pela qual o intervalo final foi limitado a 25 de outubro.

Após a agregação, cada SKU foi tratado como uma série independente. Essa decisão evita que os padrões de um tamanho ou produto sejam confundidos com os de outro. Em uma pesquisa futura, seria possível avaliar modelos globais que utilizem dados de vários SKUs, incluindo atributos que identifiquem o produto, mas essa estratégia exigiria maior cuidado com as diferenças entre séries.

3.5. Engenharia de atributos

Foram construídos quatro atributos de entrada. O primeiro representa o dia da semana da data prevista. O segundo corresponde à quantidade vendida no dia imediatamente anterior (defasagem de um dia). O terceiro representa a quantidade observada sete dias antes. O quarto corresponde à média das vendas dos sete dias anteriores, calculada sem incluir o próprio dia previsto.

A utilização de defasagens busca representar a persistência e a repetição semanal do comportamento de vendas. O dia da semana permite ao modelo diferenciar, por exemplo, dias úteis e finais de semana, caso essa diferença esteja presente nos dados. A média móvel suaviza parte das variações diárias, embora possa atrasar a resposta a mudanças rápidas.

As primeiras observações não possuem todas as defasagens necessárias e foram removidas do conjunto modelado. Esse procedimento reduz o número de linhas disponíveis. Como o histórico tem aproximadamente um mês, a quantidade de exemplos restantes é pequena, o que limita a capacidade de aprender padrões estáveis.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

3.6. Treinamento, teste e prevenção de vazamento

A divisão entre treinamento e teste foi feita cronologicamente. As sete últimas observações válidas de cada série foram reservadas para teste; as observações anteriores foram usadas para treinar os modelos. Essa estratégia imita, de forma simplificada, a situação em que o modelo é ajustado com dados passados e avaliado em dias posteriores.

A Regressão Linear foi treinada com os atributos temporais e as defasagens. A Árvore de Decisão foi configurada com profundidade máxima igual a três e estado aleatório fixado para permitir a repetição do procedimento. A previsão sazonal utilizou a quantidade vendida sete dias antes como estimativa do dia correspondente. As previsões negativas da Regressão Linear, caso ocorram, são limitadas a zero, pois não existe quantidade vendida negativa.

Depois da avaliação, cada modelo foi ajustado novamente utilizando todas as observações disponíveis com atributos completos e empregado para prever os sete dias seguintes. O procedimento recursivo foi realizado dia a dia. Para o primeiro dia do horizonte, utilizaram-se os valores observados disponíveis para calcular as defasagens de um e de sete dias e a média móvel dos sete dias anteriores. Após gerar a previsão do primeiro dia, esse valor previsto passou a integrar o histórico utilizado no cálculo dos atributos do dia seguinte: a defasagem de um dia recebeu a previsão imediatamente anterior; a defasagem de sete dias e a média móvel foram atualizadas com os valores observados ainda disponíveis e, progressivamente, com as previsões já produzidas. O dia da semana foi definido pelo calendário. Esse processo foi repetido até completar os sete dias. Assim, a partir do segundo dia, parte dos atributos deixou de ser formada exclusivamente por vendas observadas e passou a depender de previsões anteriores. Essa abordagem permite gerar o horizonte completo, mas pode propagar e acumular erros ao longo dos dias, sobretudo quando uma estimativa se afasta do padrão histórico.

3.7. Métricas e regra de reposição

Foram calculados MAE, RMSE e R^2 para cada combinação de SKU e modelo. As métricas foram calculadas no mesmo conjunto de teste para permitir comparação direta. O MAE e o RMSE são expressos em unidades vendidas por dia; o R^2 é adimensional e pode assumir valores negativos quando o modelo tem desempenho inferior à previsão pela média do teste.

Para demonstrar a sugestão de compra, foi definida uma regra com margem de segurança de 10%. Primeiro, soma-se a demanda diária prevista para os sete dias seguintes. Em seguida, multiplica-se essa soma por 1,10 e arredonda-se para cima. Por fim, subtrai-se o estoque atual. A quantidade sugerida é limitada a zero caso o cálculo resulte em valor negativo.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

A regra utiliza o estoque informado pelo responsável pelo negócio, e não um campo extraído da planilha de vendas. Não foram considerados pedidos de compra em trânsito, unidades reservadas, prazo de entrega do fornecedor ou lote mínimo. A recomendação deve, portanto, ser interpretada como simulação metodológica, não como instrução definitiva de compra.

3.8. Reprodutibilidade e aspectos de privacidade

A reprodutibilidade exige registrar a fonte dos dados, o período, os filtros, os atributos, os modelos, os parâmetros e a forma de avaliação. No presente estudo, os três SKUs, a filtragem de status, o horizonte de sete dias, o período de teste e a profundidade da árvore foram explicitados para que o procedimento possa ser repetido.

O arquivo original continha informações identificáveis dos compradores e detalhes de entrega. Como esses campos não são necessários à previsão por SKU, eles foram excluídos da modelagem e não são reproduzidos nas tabelas. A análise utiliza apenas informações relacionadas ao produto, à data, ao status da venda e à quantidade. A minimização de dados pessoais é uma prática prudente, inclusive quando o objetivo é exclusivamente acadêmico.

Para uma publicação, recomenda-se manter a base original em ambiente controlado, não divulgar números de pedido, nomes, documentos, endereços ou identificadores de compradores e revisar qualquer arquivo suplementar antes de compartilhá-lo. Os códigos de SKU foram mantidos porque são necessários para distinguir as séries no experimento, mas podem ser substituídos por códigos anônimos caso exista preocupação comercial.

4. RESULTADOS E DISCUSSÃO

4.1. Perfil da base e vendas observadas

A filtragem dos registros entregues resultou em 318 transações e 338 unidades para o SKU 00691-002-G, 280 transações e 290 unidades para o SKU 00691-002-M, e 142 transações e 148 unidades para o SKU 40300-001-G. Esses números foram obtidos pela soma do campo de unidades dos registros cujo estado era “Entregue”. A contagem de transações e a contagem de unidades foram mantidas separadas para evitar interpretação incorreta do volume.

O intervalo diário analisado foi de 26 de setembro a 25 de outubro de 2026. O período é curto e não contém um ciclo anual, de modo que não permite avaliar sazonalidade anual nem efeitos de datas comemorativas de forma robusta. O histórico é suficiente para uma

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

demonstração inicial de pipeline, mas não para concluir que os modelos estarão estáveis em outros meses.

A presença de dias sem venda concluída registrada também influencia as métricas. Em produtos de venda frequente, os dias sem vendas podem representar oscilações normais; em outros casos, podem refletir disponibilidade de estoque ou limitações do relatório. Sem um histórico completo de estoque por dia, não é possível distinguir com segurança ausência de demanda de impossibilidade de venda por falta de produto.

4.2. Resultados das métricas de teste

A Tabela 2 apresenta as métricas obtidas nos sete dias reservados para teste, de 19 a 25 de outubro de 2026. Os valores foram calculados após agregação diária e construção dos atributos temporais. Os resultados são apresentados com duas casas decimais para facilitar a leitura.

Tabela 2. Métricas de avaliação por SKU e modelo

SKU	Modelo	MAE	RMSE	R^2
00691-002-G	Regressão Linear	3,76	4,28	0,11
00691-002-G	Árvore de Decisão	5,64	6,08	-0,80
00691-002-G	Referência sazonal	5,29	6,18	-0,85
00691-002-M	Regressão Linear	4,69	5,94	-1,40
00691-002-M	Árvore de Decisão	5,86	7,51	-2,84
00691-002-M	Referência sazonal	3,71	4,34	-0,28
40300-001-G	Regressão Linear	2,79	3,28	-1,37
40300-001-G	Árvore de Decisão	4,05	4,63	-3,73
40300-001-G	Referência sazonal	3,14	4,34	-3,16

Fonte: Elaborado pelo autor a partir da execução dos modelos sobre a base de vendas.

Para o SKU 00691-002-G, a Regressão Linear obteve MAE de 3,76 e RMSE de 4,28, valores inferiores aos da Árvore de Decisão e da referência sazonal no conjunto de teste. O R^2 da Regressão Linear foi 0,11, indicando que, nesse intervalo curto, o modelo apresentou desempenho ligeiramente melhor do que a previsão constante baseada na média dos valores reais, conforme a definição convencional do coeficiente.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

Para o SKU 00691-002-M, a referência sazonal apresentou o menor MAE (3,71) e o menor RMSE (4,34), superando os dois modelos de aprendizado de máquina. A Regressão Linear obteve MAE de 4,69, enquanto a Árvore de Decisão apresentou MAE de 5,86. O R^2 dos três métodos foi negativo, o que indica desempenho inferior à referência constante baseada na média do conjunto de teste, apesar de a referência sazonal ter apresentado o menor erro absoluto e quadrático entre os métodos comparados.

Para o SKU 40300-001-G, a Regressão Linear apresentou o menor MAE (2,79) e o menor RMSE (3,28), enquanto a Árvore de Decisão apresentou MAE de 4,05 e RMSE de 4,63. A referência sazonal ficou entre os dois modelos. Os R^2 foram negativos para todos os métodos, refletindo a baixa variabilidade e a presença de valores baixos ou nulos no período de teste.

A comparação demonstra que nenhum algoritmo foi superior em todos os produtos. A Regressão Linear apresentou menor MAE para dois SKUs, mas não foi a melhor opção para o SKU 00691-002-M. Esse resultado reforça que a escolha de um algoritmo deve ser orientada pela avaliação empírica e pode variar entre produtos. Em um cenário operacional, a seleção do modelo poderia ser feita por SKU, desde que houvesse histórico suficiente e validação em diferentes períodos.

Os valores de R^2 devem ser interpretados com cuidado. O coeficiente é sensível à distribuição dos valores reais e pode ser negativo em amostras curtas. Portanto, a conclusão mais direta neste estudo é baseada na comparação de MAE e RMSE no mesmo conjunto de teste, mantendo explícito que sete dias representam uma amostra pequena e produzem estimativas sujeitas a elevada incerteza. A realização de validação temporal em múltiplas janelas forneceria uma avaliação mais robusta.

4.3. Previsões para os sete dias seguintes

Depois da avaliação, os modelos foram ajustados com o histórico disponível até 25 de outubro de 2026 e utilizados para prever o período de 26 de outubro a 1º de novembro de 2026. A Tabela 3 apresenta a soma das previsões diárias de cada modelo no horizonte de sete dias. As somas foram mantidas com duas casas decimais, embora a demanda real seja composta por unidades inteiras, para preservar a saída numérica dos modelos.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

Tabela 3. Demanda total prevista para o horizonte de sete dias

SKU	Regressão Linear	Árvore de Decisão
00691-002-G	83,35	70,00
00691-002-M	67,28	92,20
40300-001-G	22,21	0,00

Fonte: Elaborado pelo autor a partir da execução experimental.

Para o SKU 00691-002-G, a soma da previsão da Regressão Linear foi de aproximadamente 83,35 unidades, enquanto a Árvore de Decisão estimou 70 unidades. Apesar de a Regressão Linear ter apresentado menor erro no período de teste, a diferença entre as projeções demonstra que o horizonte futuro é sensível ao comportamento recursivo dos atributos.

Para o SKU 00691-002-M, a Regressão Linear estimou aproximadamente 67,28 unidades e a Árvore de Decisão, 92,20 unidades. A referência sazonal obteve o menor erro no teste, por isso pode ser considerada como alternativa simples para esse SKU dentro do experimento inicial. A divergência entre as previsões dos modelos, entretanto, indica incerteza elevada na estimativa futura.

Para o SKU 40300-001-G, a Regressão Linear estimou aproximadamente 22,21 unidades e a Árvore de Decisão produziu previsão total igual a zero. A previsão nula da árvore não deve ser interpretada como ausência garantida de vendas, sobretudo porque o histórico inclui vendas recentes. Esse comportamento indica que a árvore, com a configuração adotada e o histórico curto, não generalizou de maneira satisfatória para o horizonte futuro.

As previsões recursivas podem amplificar erros porque a estimativa de um dia passa a ser utilizada como atributo para o dia seguinte. Quando a previsão de um modelo se afasta do padrão histórico, essa diferença pode propagar-se ao longo do horizonte. Uma abordagem futura poderia comparar estratégias diretas para cada horizonte, modelos de séries temporais ou métodos que imponham restrições adequadas a dados de contagem.

4.4. Aplicação da regra de reposição

Para demonstrar o cálculo da reposição, foi selecionada a previsão com menor MAE no teste para cada SKU: Regressão Linear para 00691-002-G, referência sazonal para 00691-002-M e Regressão Linear para 40300-001-G. Para a referência sazonal no horizonte futuro, considerou-se a repetição dos sete valores diários mais recentes. Essa escolha é ilustrativa e não deve ser entendida como uma validação definitiva de modelo, pois o conjunto de teste possui apenas sete observações.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

Tabela 4. Simulação de reposição usando o modelo com menor MAE no teste

SKU	Modelo escolhido	Estoque atual	Demanda prevista	Demanda + 10%	Compra sugerida
00691-002-G	Regressão Linear	50	83,35	92	42
00691-002-M	Referência sazonal	50	50,00	55	5
40300-001-G	Regressão Linear	90	22,21	25	0

Fonte: Elaborado pelo autor. A regra de reposição é demonstrativa e utiliza estoques informados pelo responsável pelo negócio.

Com a regra definida, o SKU 00691-002-G apresenta demanda prevista de aproximadamente 83,35 unidades. Aplicando-se a margem de segurança de 10% e arredondando-se para cima, a quantidade de cobertura utilizada no cálculo é de 92 unidades. Subtraindo-se o estoque atual de 50 unidades, a compra sugerida pela regra é de 42 unidades.

Para o SKU 00691-002-M, a referência sazonal projeta 50 unidades no horizonte de sete dias, considerando a repetição do padrão observado nos sete dias mais recentes. Com a margem de 10%, a necessidade calculada é de 55 unidades. Após subtrair o estoque atual de 50 unidades, a sugestão ilustrativa é de cinco unidades.

Para o SKU 40300-001-G, a Regressão Linear projeta aproximadamente 22,21 unidades. A aplicação da margem de segurança e do arredondamento resulta em 25 unidades. Como o estoque informado é de 90 unidades, a regra sugere compra igual a zero no horizonte analisado.

Essas quantidades não devem ser usadas como recomendações definitivas de compra. As previsões ainda são instáveis, o histórico é curto e não foram considerados prazo de entrega, estoque reservado, pedidos em trânsito, lote mínimo, sazonalidade, custo de aquisição ou margem comercial. A tabela demonstra apenas como converter uma estimativa de demanda em uma regra simples e transparente de reposição.

4.5. Interpretação dos resultados em relação ao objetivo

O objetivo do estudo foi investigar se os modelos selecionados poderiam apoiar a previsão de vendas e demonstrar sua ligação com uma regra de reposição. Os resultados mostram que é tecnicamente possível organizar um relatório comercial em séries diárias, construir atributos temporais, treinar modelos e calcular métricas de avaliação. Nesse sentido, o experimento demonstra um fluxo de análise reprodutível e aplicável ao problema.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

Entretanto, a qualidade preditiva não foi uniforme. A Regressão Linear foi mais adequada para dois dos produtos no período de teste, enquanto uma referência sazonal simples foi superior para o SKU 00691-002-M. A Árvore de Decisão apresentou maior erro em todos os três SKUs quando comparada à melhor alternativa de cada produto. Esse resultado é coerente com a possibilidade de modelos mais flexíveis sofrerem com dados insuficientes ou mudanças abruptas no conjunto de teste.

A regra de reposição também pode ser calculada a partir das previsões, mas a utilidade operacional depende da confiança nas estimativas. Se a demanda prevista for superestimada, a regra pode recomendar compras excessivas; se for subestimada, pode aumentar o risco de ruptura. Por isso, a regra precisa ser validada com dados históricos mais extensos e, idealmente, com indicadores econômicos que permitam avaliar o custo das decisões.

Os resultados não permitem afirmar que aprendizado de máquina sempre supera métodos tradicionais. Pelo contrário, a comparação com a referência sazonal demonstra que uma estratégia simples pode ser competitiva. A contribuição do experimento consiste em apresentar uma avaliação inicial e mostrar a necessidade de medir o desempenho antes de selecionar um modelo para uso real.

4.6. Limitações do estudo

A primeira limitação é o período curto de dados, com aproximadamente trinta dias. Esse intervalo não representa diferentes épocas do ano e não permite analisar padrões anuais ou efeitos de campanhas promocionais. Uma série mais longa permitiria estudar se os comportamentos observados são persistentes ou específicos do mês analisado.

A segunda limitação é o tamanho reduzido do conjunto de teste. Apenas sete observações foram utilizadas para calcular cada conjunto de métricas. Com uma amostra tão pequena, poucos dias atípicos podem alterar significativamente o MAE, o RMSE e o R^2. A validação temporal com várias janelas deve ser considerada antes de qualquer conclusão sobre a superioridade de um modelo.

A terceira limitação está relacionada à informação de estoque. Foram fornecidas quantidades atuais para os três SKUs, mas não existe no experimento uma série histórica de estoque disponível por dia. Dessa forma, não é possível identificar se dias sem vendas decorreram de baixa procura ou de indisponibilidade do produto. A ausência dessa informação pode afetar a interpretação da demanda observada.

A quarta limitação é a ausência de atributos comerciais e operacionais adicionais na modelagem, como preço, promoções, datas comemorativas, disponibilidade histórica, prazo de

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

entrega e pedidos em trânsito. Esses fatores podem explicar variações que não são capturadas apenas pelo calendário e pelas defasagens de vendas. Além disso, mudanças repentinas no comportamento do consumidor podem alterar as relações identificadas a partir do histórico, fenômeno associado ao conceito de *concept drift*. Produtos com baixa frequência de vendas também podem apresentar maior dificuldade de previsão, característica relacionada aos itens de *long tail*. Esses fenômenos não foram medidos diretamente neste experimento e são apontados como aspectos relevantes para pesquisas futuras. A inclusão dessas variáveis e análises exige dados consistentes e disponíveis no momento da previsão, sem utilização de informações futuras.

Por fim, a regra de reposição utiliza uma margem de segurança fixa de 10% e não inclui parâmetros logísticos completos. Essa simplificação é adequada para demonstrar o conceito, mas não substitui uma política de estoque que considere o prazo de fornecimento, o nível de serviço desejado, os custos de falta e excesso e as restrições de compra.

4.7. Melhorias e trabalhos futuros

A primeira melhoria recomendada é ampliar o histórico de vendas para vários meses, preferencialmente um ano ou mais, quando disponível. Um intervalo maior permitirá avaliar efeitos de calendário, sazonalidade e campanhas comerciais e reduzirá a dependência de poucos dias de teste. A atualização periódica do relatório também ajudará a verificar se o desempenho permanece estável ao longo do tempo.

A segunda melhoria é executar validação temporal com múltiplas janelas. Em vez de depender de um único período de sete dias, o treinamento pode ser repetido em datas de corte diferentes, sempre utilizando o passado para prever o futuro. As métricas podem então ser agregadas entre as janelas, fornecendo uma visão mais estável do desempenho esperado.

A terceira melhoria é ampliar a variedade de produtos analisados e verificar se os resultados observados se mantêm em SKUs com diferentes níveis de demanda, preços e características comerciais. Também será importante documentar os critérios de seleção dos produtos e repetir o procedimento em períodos distintos, evitando que as conclusões dependam de poucos itens ou de uma única janela temporal.

A quarta melhoria é comparar mais estratégias de previsão, como média móvel, suavização exponencial ou modelos específicos de séries temporais, desde que o escopo e os dados justifiquem essa ampliação. Também será útil testar diferentes profundidades para a Árvore de Decisão e avaliar o efeito da escolha de atributos. Qualquer ajuste deve ser realizado usando validação e não com base no conjunto final de teste.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

A quinta melhoria é transformar a regra de reposição em uma política operacional mais realista. Para isso, devem ser incorporados o prazo de entrega, estoque disponível e reservado, compras em trânsito, quantidade mínima de pedido e nível de serviço desejado. Uma avaliação retrospectiva pode comparar a política sugerida com o que ocorreu historicamente, estimando rupturas e excesso de estoque quando os dados necessários estiverem disponíveis.

A sexta melhoria é avaliar o erro em termos comerciais. O MAE e o RMSE descrevem a precisão estatística, mas não refletem integralmente o custo de uma previsão. Em estudos futuros, podem ser estimados os custos de falta, excesso e compra, desde que os valores sejam fornecidos e as hipóteses sejam explicitadas. Essa avaliação ajudaria a determinar se uma redução de erro se traduz em benefício econômico.

5. CONSIDERAÇÕES FINAIS

Este trabalho investigou a aplicação de modelos de aprendizado de máquina na previsão de demanda de produtos comercializados em ambiente de e-commerce. O experimento inicial utilizou um relatório real do Mercado Livre, selecionou três SKUs e organizou os registros entregues em séries temporais diárias. Foram implementadas a Regressão Linear e a Árvore de Decisão, comparadas a uma referência sazonal baseada nas vendas de sete dias antes.

Os resultados indicaram que a Regressão Linear apresentou menor MAE para os SKUs 00691-002-G e 40300-001-G, enquanto a referência sazonal foi superior para 00691-002-M. A Árvore de Decisão não apresentou o melhor desempenho em nenhum dos três casos avaliados. Essa diferença mostra que a escolha de modelo deve ser orientada por testes empíricos e pode depender das características de cada produto.

A análise também demonstrou como as previsões podem ser utilizadas em uma regra preliminar de reposição, combinando a demanda prevista para sete dias, uma margem de segurança de 10% e o estoque atual informado. As quantidades calculadas são ilustrativas e não devem ser adotadas como decisões de compra sem validação adicional, pois o histórico é curto e a previsão futura apresenta incerteza.

As limitações mais importantes foram o período de observação reduzido, o conjunto de teste de apenas sete dias, a ausência de histórico diário de estoque e a não incorporação de variáveis como preço e promoções. Por esses motivos, o estudo deve ser entendido como uma avaliação experimental inicial, e não como comprovação definitiva de que os modelos já estejam prontos para operação. A ampliação do histórico e a validação em diferentes períodos são necessárias antes de utilizar as previsões como base para decisões reais de compra.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

Conclui-se que a previsão de demanda por aprendizado de máquina pode ser estruturada com dados comerciais existentes, mas sua utilidade prática depende da qualidade dos dados, da validação temporal, da comparação com referências simples e da integração com as regras reais de estoque. Como continuidade, recomenda-se ampliar a base histórica, realizar validação em múltiplos períodos e desenvolver uma política de reposição que considere prazo de entrega, disponibilidade de estoque e custos operacionais.

REFERÊNCIAS

BALLOU, Ronald H. Gerenciamento da cadeia de suprimentos: logística empresarial. 5. ed. Porto Alegre: Bookman, 2006.

GÉRON, Aurélien. Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow. 2. ed. Sebastopol: O'Reilly Media, 2019.

MITCHELL, Tom M. Machine Learning. New York: McGraw-Hill, 1997.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.