v7.n12.2026

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL E CLASSIFICAÇÃO ABC NA PROGRAMAÇÃO E CONTROLE DE MATERIAIS

APPLICATION OF ARTIFICIAL INTELLIGENCE AND ABC CLASSIFICATION IN MATERIALS PLANNING AND CONTROL

APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL Y DE LA CLASIFICACIÓN ABC EN LA PROGRAMACIÓN Y EL CONTROL DE MATERIALES

Luiz Felipe Xavier Soares[1]

https://doi.org/10.47820/recima21.v7i12.9805

PUBLICADO: 12/2026

RESUMO

Este trabalho teve como objetivo desenvolver uma metodologia de apoio à programação e ao controle de materiais por meio da integração da classificação ABC com modelos de Inteligência Artificial para previsão de demanda. A planilha atualizada contém 53.927 registros de consumo e 425 materiais válidos na base de estoque, após a desconsideração de 13 linhas finais sem identificação de material. Para evitar distorções decorrentes de mês incompleto, a modelagem considerou 25 meses completos, de agosto de 2024 a agosto de 2026. A classificação ABC foi calculada pelo valor de consumo no período, resultando em 55 itens Classe A, 88 Classe B e 282 Classe C. Os itens A concentraram 79,82% do valor de consumo. Entre os itens A, 36 apresentaram histórico suficiente para comparação entre método ingênuo, média móvel, *Random Forest* e *Gradient Boosting*. O *Random Forest* apresentou o menor MAPE médio, 61,39%, e o menor MAE médio, 241,61, enquanto a média móvel obteve o menor RMSE, 291,84. Os resultados indicam que a combinação entre priorização econômica e aprendizado de máquina pode apoiar a identificação de materiais críticos e a previsão de consumo, sem substituir os parâmetros operacionais necessários à decisão final de reposição.

PALAVRAS-CHAVE: Aprendizado de máquina. Classificação ABC. Gestão de materiais. Inteligência artificial. Previsão de demanda.

ABSTRACT

This study developed a materials planning support methodology integrating ABC inventory classification and Artificial Intelligence demand forecasting. The updated database contained 53,927 consumption records and 425 valid materials in the inventory dataset, after excluding 13 final rows without material identification. The modeling used 25 complete months, from August 2024 to August 2026. ABC classification based on consumption value resulted in 55 class A, 88 class B and 282 class C items; class A concentrated 79.82% of consumption value. Among class A items, 36 had sufficient history for forecasting experiments. Random Forest achieved the lowest mean MAPE (61.39%) and MAE (241.61), while the three-month moving average achieved the lowest RMSE (291.84). The results show that economic prioritization combined with machine learning can support materials planning and demand forecasting.

KEYWORDS: *ABC classification. Artificial intelligence. Demand forecasting. Machine learning. Materials management.*

[1] Graduando em Engenharia de Computação pelo Centro Universitário de Araraquara (UNIARA) e atuante na área de programação e controle de materiais.

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

RESUMEN
Este trabajo tuvo como objetivo desarrollar una metodología de apoyo a la programación y al control de materiales mediante la integración de la clasificación ABC con modelos de Inteligencia Artificial para la previsión de la demanda. La hoja de cálculo actualizada contiene 53.927 registros de consumo y 425 materiales válidos en la base de existencias, tras descartar 13 líneas finales sin identificación de material. Para evitar distorsiones derivadas de meses incompletos, el modelado consideró 25 meses completos, de agosto de 2024 a agosto de 2026. La clasificación ABC se calculó según el valor de consumo en el periodo, dando como resultado 55 artículos Clase A, 88 Clase B y 282 Clase C. Los artículos A concentraron el 79,82% del valor de consumo. Entre los artículos A, 36 presentaron un historial suficiente para la comparación entre el método ingenuo (naïve), la media móvil, Random Forest y Gradient Boosting. El Random Forest presentó el menor MAPE promedio, 61,39%, y el menor MAE promedio, 241,61, mientras que la media móvil obtuvo el menor RMSE, 291,84. Los resultados indican que la combinación entre la priorización económica y el aprendizaje automático puede apoyar la identificación de materiales críticos y la previsión de consumo, sin sustituir los parámetros operativos necesarios para la decisión final de reposición.

PALABRAS CLAVE: *Aprendizaje automático. Clasificación ABC. Gestión de materiales. Inteligencia artificial. Previsión de la demanda.*

1. INTRODUÇÃO

A programação de materiais em ambientes industriais exige equilíbrio entre disponibilidade, capital empregado em estoque e risco de ruptura. Quando todos os itens são tratados com o mesmo nível de atenção, recursos de planejamento podem ser direcionados a materiais de baixo impacto enquanto itens financeiramente relevantes permanecem expostos a oscilações de consumo. Nesse contexto, a classificação ABC permite estabelecer prioridades econômicas e a Inteligência Artificial oferece instrumentos para analisar padrões históricos e apoiar previsões de demanda.

O problema de pesquisa é definido pela seguinte questão: de que forma a integração entre classificação ABC e modelos de Inteligência Artificial para previsão de demanda pode contribuir para a priorização e o apoio à programação de materiais em ambiente industrial? Parte-se da hipótese de que a classificação ABC permite concentrar a análise nos itens de maior impacto financeiro e que modelos de aprendizado de máquina podem apresentar ganho de acuracidade em relação a referências tradicionais para parte desses materiais.

O objetivo geral é desenvolver e avaliar uma metodologia de apoio à programação e ao controle de materiais que integre classificação ABC, parâmetros de estoque e modelos de Inteligência Artificial para previsão de demanda.

Como objetivos específicos, busca-se: organizar e tratar os dados históricos de consumo; calcular a classificação ABC a partir do valor de consumo; identificar a posição de estoque dos materiais em relação ao estoque de segurança; selecionar os materiais Classe A

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.

com histórico suficiente; comparar métodos tradicionais e modelos de aprendizado de máquina; avaliar MAE, MAPE e RMSE; e discutir como as informações obtidas podem apoiar a priorização das decisões de programação.

A pesquisa classifica-se como aplicada, exploratória e descritiva, com abordagem quantitativa e delineamento de estudo de caso. Os procedimentos metodológicos, a origem dos dados e o ambiente computacional utilizado são detalhados na seção 3.

2. REFERENCIAL TEÓRICO

A gestão de materiais busca garantir a disponibilidade de insumos ao mesmo tempo em que controla custos e níveis de estoque. Ballou (2006) relaciona a logística à disponibilização de materiais no local e momento adequados, enquanto Chopra e Meindl (2016) destacam a necessidade de equilibrar capacidade de resposta e eficiência de custos, em linha com os princípios de administração da produção discutidos por Corrêa e Corrêa (2012) e por Slack, Brandon-Jones e Johnston (2018). A previsão de demanda, portanto, influencia diretamente decisões de compra, reposição e planejamento.

A classificação ABC é uma técnica de priorização de estoques baseada no princípio de Pareto. Ramanathan (2006) observa que a classificação tradicional utiliza o valor de uso, obtido pela combinação entre demanda e preço unitário, de modo que poucos itens podem representar parcela elevada do valor movimentado. Neste estudo, por haver 25 meses completos disponíveis, empregou-se o valor de consumo no período, calculado pela multiplicação do consumo acumulado pelo valor unitário. Foram adotadas faixas acumuladas de aproximadamente 80% para A, de 80% a 95% para B e de 95% a 100% para C. Esses limites são critérios de segmentação e não significam que quantidade de itens e participação financeira devam obedecer exatamente à regra 80/20.

A Inteligência Artificial compreende técnicas computacionais capazes de executar tarefas associadas a aprendizado, reconhecimento de padrões e tomada de decisão (RUSSELL; NORVIG, 2013). Dentro desse campo, o aprendizado de máquina permite construir modelos a partir de exemplos históricos, sem que cada regra de previsão seja programada individualmente (MITCHELL, 1997). Para a previsão de consumo, essa abordagem permite combinar informações do comportamento recente e buscar relações não lineares nos dados.

> “Random forests are a combination of tree predictors such that each tree depends on the values of a random vector sampled independently and with the same distribution for all trees in the forest.” (BREIMAN, 2001, p. 5)

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.

Em tradução nossa, florestas aleatórias são uma combinação de preditores em árvore, de modo que cada árvore depende dos valores de um vetor aleatório amostrado de forma independente e com a mesma distribuição para todas as árvores da floresta (BREIMAN, 2001, p. 5).

Em linguagem prática, o *Random Forest* combina diversas árvores de decisão e consolida suas previsões (GÉRON, 2019). O *Gradient Boosting* também utiliza modelos baseados em árvores, porém os constrói sequencialmente, de forma que novas etapas procuram reduzir erros deixados pelas anteriores (FRIEDMAN, 2001).

O método ingênuo considera o último consumo observado como previsão do período seguinte. A média móvel de três meses utiliza a média dos três consumos anteriores e funciona como referência estatística simples. O *Random Forest* e o *Gradient Boosting* representam os modelos de aprendizado de máquina avaliados. A comparação utiliza MAE, MAPE e RMSE: o MAE indica o erro absoluto médio em unidades; o MAPE expressa o erro médio em percentual; e o RMSE também mede erro em unidades, mas atribui maior peso aos desvios de maior magnitude (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; HYNDMAN; ATHANASOPOULOS, 2018).

Estudos recentes que comparam métodos estatísticos e modelos de aprendizado de máquina em previsão de demanda apresentam resultados heterogêneos. Makridakis, Spiliotis e Assimakopoulos (2018) observaram que, em um grande conjunto de séries mensais, métodos estatísticos tradicionais superaram modelos de *Machine Learning* na maioria dos casos avaliados, enquanto Spiliotis *et al.* (2022), ao comparar os dois grupos de métodos na previsão diária de itens de estoque, verificaram que o desempenho relativo depende do horizonte de previsão, da granularidade dos dados e das características de cada série. Esses achados reforçam que a superioridade de modelos de aprendizado de máquina não deve ser assumida a priori, sendo necessário avaliar o desempenho caso a caso.

Parte dos materiais analisados apresenta consumo irregular, característica associada à chamada demanda intermitente, em que diversos períodos registram consumo nulo. Croston (1972) propôs um método específico para esse tipo de série, tratando separadamente o tamanho da demanda e o intervalo entre ocorrências não nulas; Syntetos e Boylan (2001) demonstraram que a formulação original apresenta viés estatístico e propuseram uma correção posteriormente incorporada a variantes do método. Embora este trabalho não tenha empregado o método de Croston, o reconhecimento dessa literatura é relevante, pois parte da dificuldade de previsão observada nos materiais de menor consumo médio está associada a esse padrão intermitente. Quanto às métricas de avaliação, Hyndman e Koehler (2006) alertam que o MAPE é instável e

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.

pode ser fortemente distorcido quando os valores reais observados se aproximam de zero, o que é especialmente relevante para os materiais de baixo consumo mensal presentes na amostra deste estudo.

3. METODOLOGIA

3.1. Tipo de pesquisa

A pesquisa classifica-se como aplicada quanto à natureza, pois busca gerar conhecimento de uso prático na programação e no controle de materiais. Quanto aos objetivos, é exploratória e descritiva, uma vez que busca compreender o comportamento do consumo dos materiais e descrever os resultados da classificação ABC e da comparação entre métodos de previsão. Quanto à abordagem, é quantitativa e, quanto ao procedimento técnico, caracteriza-se como um estudo de caso único, desenvolvido a partir de dados reais de uma empresa, extraídos do sistema SAP e complementados pela base de estoque descrita na subseção seguinte.

3.2. Base de dados e tratamento

A planilha atualizada contém duas fontes complementares. A aba de estoque apresenta 438 linhas de dados, das quais 425 possuem material identificado e foram consideradas na análise; 13 linhas finais sem identificação foram desconsideradas. Para os materiais válidos estão disponíveis código, descrição, fornecedor, estoque de segurança, estoque atual, valor unitário e valor de estoque. A aba de consumo contém 53.927 registros de saída, referentes a 377 materiais no período total da extração. Os registros de consumo abrangem agosto de 2024 a setembro de 2026. Como a extração de setembro de 2026 foi realizada antes do encerramento do mês, a modelagem temporal foi limitada aos 25 meses completos entre agosto de 2024 e agosto de 2026, evitando comparar um mês parcial com meses completos. Dos 425 materiais da aba de estoque, 377 têm algum registro de consumo na extração; os 48 restantes não tiveram consumo e, assim como qualquer material sem consumo nos 25 meses completos, foram mantidos na classificação ABC com consumo e valor de consumo iguais a zero, o que os posiciona na Classe C. Para a modelagem, a série mensal de cada material foi construída sobre o calendário completo de 25 meses, com preenchimento por zero dos meses sem registro de consumo, de modo que todas as séries têm o mesmo comprimento e os meses nulos permanecem como observações de consumo igual a zero. Por razões de confidencialidade, a empresa não é identificada e os códigos dos materiais apresentados na Tabela 3 foram substituídos por identificadores (M01 a M10).

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.

3.3. Classificação ABC

Para cada material, o consumo acumulado dos 25 meses completos foi multiplicado pelo valor unitário. Os materiais foram ordenados de forma decrescente pelo valor de consumo, calculando-se a participação individual e a participação acumulada. A classe A compreendeu os itens até aproximadamente 80% do valor acumulado; a classe B, os itens seguintes até aproximadamente 95%; e a classe C, os demais itens.

3.4. Relação com estoque atual e estoque de segurança

Além da relevância econômica, a base permitiu comparar estoque atual e estoque de segurança. Na data da extração, 11 materiais Classe A estavam abaixo do estoque de segurança, assim como 16 itens B e 20 itens C. Essa comparação não representa uma ordem automática de compra: *lead time*, pedidos em aberto, lote mínimo, saldo comprometido e programação de produção não estão disponíveis na base e devem ser considerados antes de uma decisão operacional.

3.5. Seleção para previsão e variáveis preditivas

A previsão foi concentrada nos itens Classe A, pois são os materiais de maior impacto financeiro no critério adotado. Para evitar modelos com histórico excessivamente esparso, foram mantidos apenas itens A com consumo positivo em pelo menos 18 dos 25 meses (72% do período). Ao final, 36 materiais atenderam ao critério e foram utilizados na comparação preditiva. O valor de 18 meses foi definido de forma exploratória, como um piso para limitar a proporção de meses nulos nas séries. Como as séries foram completadas com zeros (subseção 3.2), todas têm 25 observações mensais. Reservando-se os três primeiros meses para a construção das variáveis de defasagem (*lag1*, *lag2* e *lag3*) e das médias móveis e os quatro últimos para teste, cada material dispõe de 18 observações de treinamento ($25 - 3 - 4$), qualquer que seja o número de meses com consumo positivo. O piso de 18 meses, portanto, não define o tamanho do conjunto de treinamento, mas restringe a presença de zeros: nos materiais selecionados, no máximo 7 dos 25 meses têm consumo nulo. Ainda assim, 18 observações por material constituem um volume reduzido, o que é considerado nas limitações do estudo (seção 5).

Para cada material foram construídas as variáveis: mês do ano; consumo de um, dois e três meses anteriores (*lag1*, *lag2* e *lag3*); média móvel dos três meses anteriores; e desvio-padrão móvel dos três meses anteriores. O mês foi incluído como informação temporal, mas o histórico curto não permite afirmar a existência de sazonalidade robusta.

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.

3.6. Modelos comparados e hiperparâmetros

Foram comparados quatro métodos: o método ingênuo, que utiliza o último consumo observado como previsão; a média móvel de três meses; o *Random Forest*; e o *Gradient Boosting*. Os dois primeiros funcionam como referências de comparação simples, enquanto os dois últimos representam os modelos de aprendizado de máquina avaliados.

O *Random Forest* foi configurado com 300 árvores e profundidade máxima igual a 4. O número de árvores foi definido acima dos valores mínimos usuais (entre 100 e 200) para reduzir a variância das previsões por meio da agregação de um número maior de estimadores, sem custo computacional relevante dado o porte da base. A profundidade máxima foi limitada a 4, valor propositalmente baixo, para conter o risco de sobreajuste diante do número reduzido de observações de treinamento por material, discutido na subseção 3.5.

O *Gradient Boosting* utilizou 200 estimadores, profundidade máxima 2 e taxa de aprendizado 0,05. Diferentemente do *Random Forest*, o *Gradient Boosting* constrói árvores sequencialmente, cada uma corrigindo o erro da anterior, o que o torna mais suscetível a sobreajuste quando o histórico é curto. Por esse motivo, optou-se por árvores mais rasas, com profundidade 2, combinadas a uma taxa de aprendizado baixa, estratégia usual para tornar o aprendizado mais gradual e limitar a capacidade do modelo de memorizar ruído presente nas séries mais curtas.

3.7. Treinamento e período de teste

Para preservar a ordem temporal e evitar vazamento de informação entre treino e teste, os quatro meses mais recentes de cada série foram reservados para teste e os meses anteriores utilizados para treinamento. A escolha de quatro meses buscou equilibrar dois objetivos conflitantes: um período de teste curto o suficiente para não comprometer ainda mais o número já reduzido de observações de treinamento, discutido na subseção 3.5, e longo o suficiente para permitir alguma variabilidade nas previsões avaliadas, evitando que o resultado dependesse de um único mês atípico. A semente aleatória (*random_state*) foi fixada em 42 em todos os modelos para garantir a reprodutibilidade dos resultados.

3.8. Métricas de avaliação e tratamento de valores zero

O desempenho dos modelos foi avaliado por três métricas complementares: o MAE, que expressa o erro em unidades de consumo; o RMSE, também expresso em unidades, mas que penaliza mais fortemente os desvios de maior magnitude; e o MAPE, que expressa o erro em termos relativos e facilita a comparação entre materiais de escalas distintas. Conforme discutido

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.

na revisão bibliográfica, o MAPE é sensível a valores reais próximos de zero, podendo gerar percentuais de erro elevados mesmo quando o erro absoluto é pequeno (HYNDMAN; KOEHLER, 2006). Para reduzir essa distorção, os meses em que o consumo real observado foi igual a zero foram desconsiderados especificamente no cálculo do MAPE, permanecendo, porém, no cálculo do MAE e do RMSE. Essa escolha metodológica deve ser considerada na leitura dos resultados: o MAPE reportado neste trabalho refere-se apenas aos meses de consumo positivo. Cabe observar, ainda, que o MAE e o RMSE são expressos em unidades de consumo e, por isso, suas médias entre materiais refletem sobretudo os itens de maior volume mensal (por exemplo, o material M02, com média de cerca de 2.936 unidades por mês, contra 2,6 do material M05), enquanto o MAPE, por ser relativo, é influenciado principalmente pelos itens de menor volume. Medidas escalonadas, como o erro absoluto escalonado médio (MASE) proposto por Hyndman e Koehler (2006), permitiriam agregar séries de escalas distintas, mas não foram calculadas neste estudo (seção 5).

3.9. Ambiente de execução e bibliotecas

A implementação foi desenvolvida em *Python*, com a biblioteca *pandas* para tratamento e manipulação dos dados e a biblioteca *scikit-learn* (PEDREGOSA *et al.*, 2011) para a construção, o treinamento e a avaliação dos modelos *Random Forest* e *Gradient Boosting*. Os gráficos apresentados no trabalho foram gerados com bibliotecas de visualização do mesmo ambiente. Trechos representativos da implementação são apresentados nos Quadros 1 a 4, na seção 4.

4. RESULTADOS E DISCUSSÃO

A classificação ABC resultou em 55 itens A, 88 itens B e 282 itens C. Embora representem apenas 12,9% dos 425 materiais válidos, os itens A concentraram 79,82% do valor de consumo do período. Os itens B responderam por 15,11% e os itens C por 5,06%. O valor de consumo acumulado dos materiais analisados foi de aproximadamente R$ 14,70 milhões. Esse resultado mostra que a priorização econômica reduz o universo de análise sem perder a maior parcela do valor movimentado.

Outro achado relevante está no valor de estoque: a Classe A somava aproximadamente R$ 2.538.074,31, enquanto a Classe C somava cerca de R$ 1.700.753,77. Esses valores não demonstram, isoladamente, excesso ou insuficiência, mas reforçam que classificação por

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.

consumo e posição de estoque são dimensões diferentes e devem ser analisadas conjuntamente.

4.1. Desempenho dos modelos de previsão

Na base analisada, o *Random Forest* apresentou o menor MAPE médio (61,39%) e o menor MAE médio (241,61), enquanto a média móvel obteve o menor RMSE (291,84) (Tabela 2). No MAE, porém, a diferença entre o *Random Forest* e a média móvel (242,35) é de apenas 0,74 unidade, de modo que os dois métodos praticamente empatam nessa métrica. A divergência entre as métricas está relacionada à escala: o MAE e o RMSE médios são dominados pelos materiais de grande volume mensal, ao passo que o MAPE é influenciado sobretudo pelos de baixo volume e pelos meses de consumo reduzido, o que ajuda a explicar por que o *Random Forest* se destaca no MAPE e a média móvel, no RMSE. Um MAPE médio de 61,39% ainda representa uma margem de erro considerável e não deve ser interpretado como evidência de previsão de alta precisão. O resultado indica, de forma mais adequada, que a Inteligência Artificial apresentou desempenho relativamente melhor que os métodos tradicionais em parte das métricas nesta base, com incerteza relevante remanescente, o que reforça a necessidade de avaliar mais de uma métrica e de não assumir previamente que um método mais complexo será sempre superior.

4.2. Desempenho por material

Quando se observa o menor MAPE individual, o *Random Forest* foi o melhor método em 12 dos 36 materiais; o *Gradient Boosting*, em 9; a média móvel, em 9; e o método ingênuo, em 6. Assim, algum modelo de aprendizado de máquina apresentou o menor MAPE em 21 dos 36 materiais analisados, enquanto métodos tradicionais foram melhores em 15 casos.

A alternância do melhor método entre os materiais sugere que o desempenho relativo não depende apenas do algoritmo, mas também do comportamento de cada série. Materiais com consumo mais irregular, ou com meses de consumo nulo, aproximam-se do padrão de demanda intermitente discutido na revisão bibliográfica e tendem a penalizar mais fortemente o MAPE (HYNDMAN; KOEHLER, 2006), o que pode favorecer métodos mais simples nesses casos específicos. Já nos materiais com padrão de consumo mais estável, é possível que os modelos de aprendizado de máquina capturem melhor as relações não lineares entre as variáveis preditivas. Ambas as explicações são hipóteses que não foram testadas neste estudo, pois não se mediu a intermitência de cada série nem se aplicaram métodos específicos para esse padrão. Essa variação reforça que, em um cenário real de aplicação, a escolha do método de previsão

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.

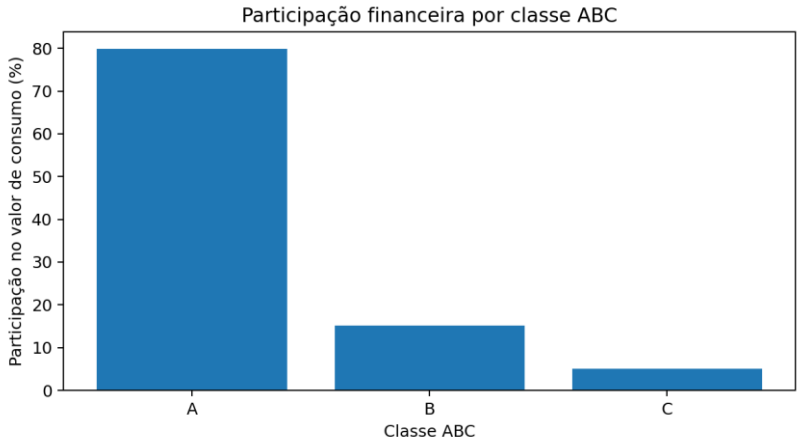
deveria considerar o comportamento individual de cada material, e não apenas o desempenho médio agregado. Cabe destacar, ainda, que o histórico disponível — 25 meses completos, reduzidos a um número relativamente pequeno de observações de treinamento por material após a separação do período de teste, conforme discutido na metodologia — é uma limitação que afeta igualmente todos os modelos comparados e que pode ter contribuído para a magnitude dos erros observados.

4.3. Integração entre ABC, previsão e parâmetros de estoque

A integração proposta deve ser interpretada como apoio à decisão. A classificação ABC indica quais materiais têm maior relevância financeira; a previsão estima o comportamento provável do consumo; o estoque atual mostra a disponibilidade existente; e o estoque de segurança representa um parâmetro de proteção informado pela área. Um item Classe A abaixo do estoque de segurança merece atenção imediata, mas a quantidade efetiva a repor não pode ser definida apenas com esses quatro dados.

A metodologia pode futuramente ser ampliada para gerar recomendações quantitativas de reposição, desde que sejam incorporados *lead time*, pedidos de compra em aberto, lotes mínimos, múltiplos de embalagem, estoque comprometido e programação de produção. Sem essas variáveis, a saída adequada do sistema é uma priorização analítica e uma previsão de consumo, e não uma ordem automática de compra.

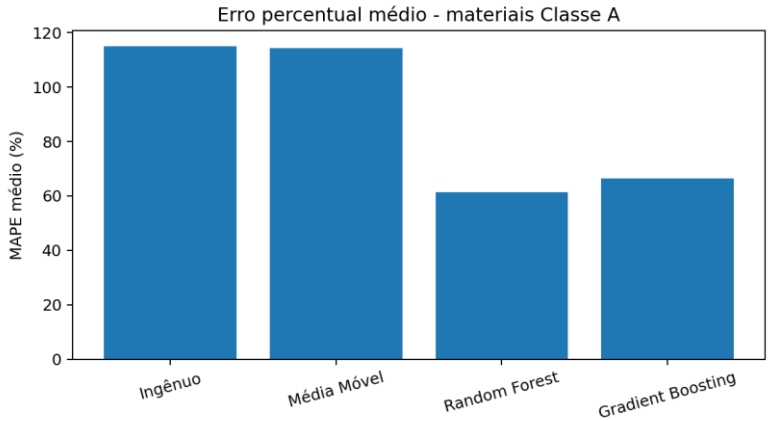
Figura 1. Participação financeira por classe ABC



Fonte: Elaborado pelo autor (2026).

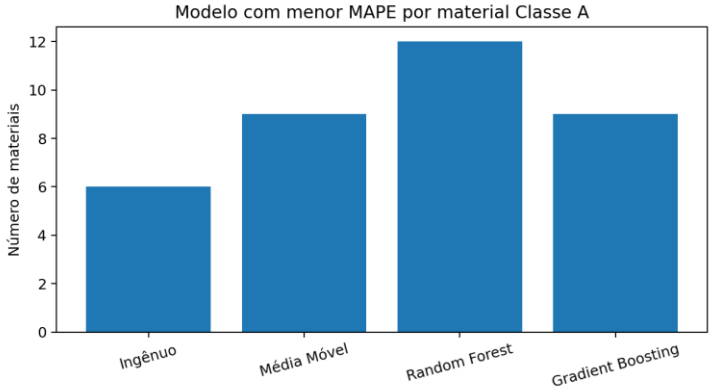
Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 2. MAPE médio por modelo nos materiais Classe A



Fonte: Elaborado pelo autor (2026).

Figura 3. Modelo com menor MAPE por material Classe A



Fonte: Elaborado pelo autor (2026).

Quadro 1. Cálculo da classificação ABC por valor de consumo

```
    # ABC por valor de consumo do periodo.
    agg = consumo_modelo.groupby('Material')['Quantidade'].sum().rename('consumo_total').reset_index()
    agg['media_mes'] = agg['consumo_total']/len(meses)

    base = estoque.merge(agg, on='Material', how='left')
    base[['consumo_total','media_mes']] = base[['consumo_total','media_mes']].fillna(0)
    base['valor_consumo_periodo'] = base['consumo_total'] * base['Vlr un.'].fillna(0)

    base = base.sort_values('valor_consumo_periodo', ascending=False)
    total = base['valor_consumo_periodo'].sum()
    base['participacao_pct'] = base['valor_consumo_periodo']/total*100
    base['acumulado_pct'] = base['participacao_pct'].cumsum()

    base['Classe ABC'] = np.select(
        [base['acumulado_pct'] <= 80, base['acumulado_pct'] <= 95],
        ['A','B'], default='C')
    base.to_excel('classificacao_abc.xlsx', index=False)
```

Fonte: Elaborado pelo autor (2026).

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.

Quadro 2. Criação das variáveis utilizadas pelos modelos de previsão

```python
def criar_features(s):
    b = pd.DataFrame({'quantidade': s.values}, index=s.index)
    b['mes'] = [p.month for p in s.index]

    for k in (1,2,3):
        b[f'lag{k}'] = b['quantidade'].shift(k)

    b['media_movel_3'] = b['quantidade'].shift(1).rolling(3).mean()
    b['desvio_movel_3'] = b['quantidade'].shift(1).rolling(3).std()
    return b.dropna()
```

Fonte: Elaborado pelo autor (2026).

Quadro 3. Separação temporal, treinamento e geração das previsões

```python
    treino, teste = f.iloc[:-MESES_TESTE], f.iloc[-MESES_TESTE:]
    cols=['mes','lag1','lag2','lag3','media_movel_3','desvio_movel_3']
    Xtr,ytr=treino[cols],treino['quantidade']; Xte,yte=teste[cols],teste['quantidade']
    previsoes={'Ingenuo':Xte['lag1'].values,'Media Movel (3m)':Xte['media_movel_3'].values}

    rf= RandomForestRegressor(
        n_estimators=300,
        max_depth=4,
        random_state=SEMENTE).fit(Xtr,ytr)

    gb= GradientBoostingRegressor(
        n_estimators=200,
        max_depth=2,
        learning_rate=.05,
        random_state=SEMENTE).fit(Xtr,ytr)

    previsoes['Random Forest']=rf.predict(Xte);
    previsoes['Gradient Boosting']=gb.predict(Xte)
```

Fonte: Elaborado pelo autor (2026).

Quadro 4. Cálculo das métricas de avaliação

```python
def metricas(y, p):
    mae = mean_absolute_error(y, p)
    rmse = np.sqrt(mean_squared_error(y, p))
    mask = y != 0
    mape = np.mean(
        np.abs((y[mask]-p[mask])/y[mask]))*100 if mask.any() else np.nan
    return {'MAE': mae, 'MAPE (%)': mape, 'RMSE': rmse}
```

Fonte: Elaborado pelo autor (2026).

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.

Tabela 1. Resultado da Classificação ABC

Classe	Itens	% dos itens	Valor de consumo no período	Participação
A	55	12,9%	R$ 11.736.703,44	79,82%
B	88	20,7%	R$ 2.222.076,33	15,11%
C	282	66,4%	R$ 744.353,25	5,06%

Fonte: Elaborado pelo autor (2026).

Tabela 2. Desempenho médio nos 36 materiais Classe A

Modelo	MAE	MAPE (%)	RMSE
Ingênuo	263,51	115,00%	314,86
Média Móvel	242,35	114,22%	291,84
Random Forest	241,61	61,39%	311,10
Gradient Boosting	251,41	66,46%	325,53

Fonte: Elaborado pelo autor (2026).

Tabela 3. Dez primeiros materiais Classe A por valor de consumo

ID	Descrição	Vlr. un.	Est. atual	Est. seg.	Média/mês
M01	Matriz de conformação (tipo A)	R$ 5.529,06	9	50	17,8
M02	Solvente (*thinner*)	R$ 14,77	3200	3000	2936,0
M03	Granalha angular	R$ 13,69	14000	6000	2360,0
M04	Punção de conformação	R$ 3.618,78	76	40	8,4
M05	Matriz de conformação (tipo B)	R$ 5.526,83	84	50	2,6
M06	Filtro para poeiras e vapores	R$ 19,13	1182	800	749,1
M07	Mangueira de jato (51 mm)	R$ 555,83	480	320	25,6
M08	Rolo de pano para limpeza	R$ 106,00	162	100	128,2
M09	Mangueira de jato (38 mm)	R$ 903,52	320	160	12,8
M10	Disco flap abrasivo	R$ 16,27	630	700	692,3

Fonte: Elaborado pelo autor (2026).

5. CONSIDERAÇÕES FINAIS

O trabalho demonstrou a viabilidade de integrar classificação ABC e Inteligência Artificial em uma metodologia de apoio à programação e ao controle de materiais. Considerando os 425 materiais válidos da planilha atualizada, a classificação ABC direcionou o foco para 55 itens Classe A, que concentraram 79,82% do valor de consumo no período analisado. Entre esses itens, 36 apresentaram histórico suficiente para avaliação preditiva.

Na comparação dos modelos, o *Random Forest* apresentou o menor MAPE médio (61,39%) e o menor MAE médio (241,61), enquanto a média móvel apresentou o menor RMSE (291,84). Em análise individual pelo MAPE, *Random Forest* e *Gradient Boosting* foram os melhores em 21 dos 36 materiais. A hipótese foi, portanto, parcialmente confirmada: os modelos de aprendizado de máquina apresentaram desempenho comparativamente melhor que os

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.

métodos de referência em parte das métricas e dos materiais avaliados, mas um MAPE médio superior a 60% ainda representa incerteza relevante, de modo que os resultados não devem ser lidos como evidência de previsão de alta precisão, e sim como um indicativo de que, nesta base, a combinação entre classificação ABC e aprendizado de máquina pode agregar informação útil ao processo de decisão.

A principal contribuição prática está na combinação de três perspectivas: relevância financeira, comportamento de consumo e posição de estoque. Em vez de aplicar o mesmo esforço de análise a todos os materiais, a classificação ABC direciona atenção aos itens de maior impacto; em seguida, os modelos preditivos oferecem informação adicional sobre demanda. A posição em relação ao estoque de segurança complementa a análise de criticidade operacional.

Como limitações, destacam-se o histórico de apenas 25 meses completos, que resulta em 18 observações de treinamento por material após a reserva do período de teste e a construção das variáveis de defasagem; o estudo de caso único, realizado em uma só empresa e com uma única janela de teste de quatro meses, o que limita a generalização dos resultados; a presença de materiais com consumo irregular; a sensibilidade do MAPE quando valores reais são baixos; a agregação de MAE e RMSE entre materiais de escalas muito diferentes; e a ausência de variáveis como *lead time*, pedidos em aberto e programação de produção. Recomenda-se, em trabalhos futuros, ampliar o histórico e o número de empresas, incorporar essas variáveis, testar validação temporal com múltiplas janelas, calcular métricas escalonadas, como o MASE, e comparar variantes do método de Croston, como a correção de Syntetos e Boylan, na previsão dos materiais de consumo intermitente.

REFERÊNCIAS

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

BREIMAN, Leo. Random forests. ***Machine Learning***, v. 45, n. 1, p. 5-32, 2001. DOI: 10.1023/A:1010933404324.

CHOPRA, Sunil; MEINDL, Peter. **Gestão da cadeia de suprimentos**: estratégia, planejamento e operação. 6. ed. São Paulo: Pearson, 2016.

CORRÊA, Henrique L.; CORRÊA, Carlos A. **Administração de produção e operações**. 3. ed. São Paulo: Atlas, 2012.

CROSTON, J. D. Forecasting and stock control for intermittent demands. **Operational Research Quarterly**, v. 23, n. 3, p. 289-303, 1972.

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.

FRIEDMAN, Jerome H. Greedy function approximation: a gradient boosting machine. **The Annals of Statistics**, v. 29, n. 5, p. 1189-1232, 2001. DOI: 10.1214/aos/1013203451.

GÉRON, Aurélien. **Hands-on machine learning with Scikit-Learn, Keras and TensorFlow**. 2. ed. Sebastopol: O'Reilly Media, 2019.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting**: principles and practice. 2. ed. Melbourne: OTexts, 2018.

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. DOI: 10.1016/j.ijforecast.2006.03.001.

MAKRIDAKIS, Spyros; SPILIOTIS, Evangelos; ASSIMAKOPOULOS, Vassilios. Statistical and *Machine Learning* forecasting methods: concerns and ways forward. **PLOS ONE**, v. 13, n. 3, e0194889, 2018. DOI: 10.1371/journal.pone.0194889.

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

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

PEDREGOSA, Fabian *et al.* Scikit-learn: machine learning in *Python*. **Journal of *Machine Learning* Research**, v. 12, p. 2825-2830, 2011.

RAMANATHAN, Ramakrishnan. ABC inventory classification with multiple-criteria using weighted linear optimization. **Computers & Operations Research**, v. 33, n. 3, p. 695-700, 2006.

RUSSELL, Stuart; NORVIG, Peter. **Inteligência artificial**. 3. ed. Rio de Janeiro: Elsevier, 2013.

SLACK, Nigel; BRANDON-JONES, Alistair; JOHNSTON, Robert. **Administração da produção**. 8. ed. São Paulo: Atlas, 2018.

SPILIOTIS, Evangelos *et al.* Comparison of statistical and machine learning methods for daily SKU demand forecasting. **Operational Research**, v. 22, n. 3, p. 3037-3061, 2022. DOI: 10.1007/s12351-020-00605-2.

SYNTETOS, Aris A.; BOYLAN, John E. On the bias of intermittent demand estimates. **International Journal of Production Economics**, v. 71, n. 1-3, p. 457-466, 2001.

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.