

Universidade Federal de Ouro Preto
Escola de Minas
Departamento de Engenharia de Produção, Administração e Economia

CLAYON DE OLIVEIRA NERES DA SILVA

**Modelo híbrido ARIMA-XGBoost para previsão de
demanda e definição de parâmetros de estoque de
EPIs: Aplicação prática na área de suprimentos de
uma indústria**

Ouro Preto
2026

Clayon de Oliveira Neres da Silva

**Modelo híbrido ARIMA-XGBoost para previsão de demanda e
definição de parâmetros de estoque de EPIs: Aplicação prática
na área de suprimentos de uma indústria**

Monografia apresentada ao Curso de Engenharia de Produção da Universidade Federal de Ouro Preto como parte dos requisitos para a obtenção do Grau de Engenheiro de Produção.

Orientador: Me. Cristiano Luís Turbino de França e Silva

Ouro Preto
2026



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE OURO PRETO
REITORIA
ESCOLA DE MINAS
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO,
ADMINISTRAÇÃO E ECON



FOLHA DE APROVAÇÃO

Clayon de Oliveira Neres da Silva

**Modelo híbrido ARIMA-XGBoost para previsão de demanda e definição de parâmetros de estoque de EPIs:
Aplicação prática na área de suprimentos de uma indústria**

Monografia apresentada ao Curso de Engenharia de Produção da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Engenheiro de Produção

Aprovada em 23 de janeiro de 2026

Membros da banca

Mestre - Cristiano Luís Turbino de Franca e Silva - Orientador - Universidade Federal de Ouro Preto
Doutor - Helton Cristiano Gomes - Universidade Federal de Ouro Preto
Mestre - Davi Neves Pavanelli - Universidade Federal de Ouro Preto

Cristiano Luís Turbino de Franca e Silva, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 23/01/2026.



Documento assinado eletronicamente por **Cristiano Luis Turbino de Franca e Silva, PROFESSOR DE MAGISTERIO SUPERIOR**, em 23/01/2026, às 08:59, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Davi Neves Pavanelli, PROFESSOR DE MAGISTERIO SUPERIOR**, em 23/01/2026, às 15:09, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1046043** e o código CRC **D1031134**.

Dedico este trabalho a Deus, pela vida e pela oportunidade de vivenciar tudo isso. Aos meus pais, Marcela e Francisco, pela exímia educação e por serem meus maiores exemplos de amor, resiliência e fé. Obrigado por me apoiarem e acreditarem em mim durante toda a jornada, juntos, vencemos! Aos meus irmãos, por serem minha motivação, e à Flávia, pelo apoio incondicional.

Agradecimentos

Agradeço ao professor Cristiano pela orientação, seus ensinamentos durante a graduação moldaram este trabalho. À Escola de Minas e à UFOP, pela oportunidade única em minha vida de usufruir de um ensino gratuito de máxima excelência. A todos os professores, com o qual tive a honra de aprender conceitos, métodos e, principalmente, desenvolver um senso crítico para as coisas. Em especial, ao Departamento de Engenharia de Produção, pelo excelentíssimo trabalho desempenhado na docência, meu muito obrigado. A todas as pessoas que tive a honra de conhecer e chamar de amigos nessa belíssima cidade, levarei vocês no peito. Deixo também um agradecimento especial à encantadora cidade de Ouro Preto, por me acolher durante esses anos.

“É absolutamente preciso estudar fatos, observar fenômenos”
CH Gorceix

Resumo

A gestão eficiente de estoques é um fator crítico para a competitividade industrial, exigindo o equilíbrio entre a disponibilidade de materiais, evitando rupturas, e a minimização de capital imobilizado que pode ser investido em outras frentes. O presente trabalho tem como objetivo desenvolver e aplicar um modelo de previsão de demanda híbrido, combinando os métodos ARIMA (AutoRegressive Integrated Moving Average) e XGBoost (Extreme Gradient Boosting), para melhorar a definição dos parâmetros de estoque de equipamentos de proteção individual (EPIs) em uma indústria de aluminas especiais. A metodologia caracterizou-se como um estudo de caso de natureza aplicada, utilizando dados históricos de consumo do período de junho de 2022 a novembro de 2025. O processamento dos dados envolveu a automação da extração via scripts em Python, estruturação em banco de dados SQL e modelagem preditiva em linguagem R. Os resultados demonstraram que o modelo híbrido obteve uma acurácia global ponderada (baseada no WMAPE) de 77,65% nos meses testados para um grupo de itens. A redefinição dos parâmetros sugerida pelo modelo evidenciou oportunidades de redução nos níveis de estoque mínimo de itens de Classe A, liberando capital de giro, além do dimensionamento de itens com Lead Time elevado. Conclui-se que a abordagem proposta oferece um desempenho satisfatório, proporcionando agilidade no processamento das informações e oferecendo uma metodologia para o gestor de estoque.

Palavras-chave: Gestão de Estoques. Previsão de Demanda. Modelo Híbrido. ARIMA-XGBoost. Machine Learning.

Abstract

Efficient inventory management is a critical factor for industrial competitiveness, requiring a balance between material availability, while avoiding stockouts, and the minimization of tied-up capital that can be invested elsewhere. This study aims to develop and apply a hybrid demand forecasting model, combining ARIMA (AutoRegressive Integrated Moving Average) and XGBoost (Extreme Gradient Boosting) methods, to improve the definition of inventory parameters for Personal Protective Equipment (PPE) in a specialty alumina industry. The methodology was characterized as an applied case study, using historical consumption data from June 2022 to November 2025. Data processing involved automating extraction via Python scripts, structuring within a SQL database, and predictive modeling using the R language. The results demonstrated that the hybrid model achieved a weighted global accuracy (based on WMAPE) of 77.65% in the tested months for a group of items. The redefinition of parameters suggested by the model highlighted opportunities for reducing minimum stock levels of Class A items, freeing up working capital, as well as correcting the sizing of items with high Lead Time. It is concluded that the proposed approach offers satisfactory performance, providing agility in information processing and offering a methodology for the inventory manager.

Keywords: Inventory Management. Demand Forecasting. Hybrid Model. ARIMA-XGBoost. Machine Learning.

Lista de figuras

Figura 1 – Análise da Curva ABC	14
Figura 2 – Nível de atendimento e distribuição normal	16
Figura 3 – Representação do gráfico dente de serra	17
Figura 4 – Curva do custo total de estoque	18
Figura 5 – Hipóteses de comportamento	20
Figura 6 – Vendas Mensais de Vinho Tinto por Vinicultores Australianos (1980–1991)	22
Figura 7 – Exemplo de estrutura de árvores em um modelo de Tree Boosting. . . .	24
Figura 8 – Exemplo da planilha de cálculo de parâmetros de estoque utilizada atualmente	27
Figura 9 – Interface de extração de relatórios do sistema <i>ERP</i>	28
Figura 10 – Script em Python para tratamento de dados	28
Figura 11 – Banco de dados local	29
Figura 12 – Dashboard de análise exploratória dos dados	30
Figura 13 – Análise da curva ABC	31
Figura 14 – Resumo da classificação ABC	31
Figura 15 – Previsões obtidas pelo modelo híbrido	32

Lista de tabelas

Tabela 1	– Itens selecionados para análise detalhada	33
Tabela 2	– Comparação entre demanda prevista e real (Setembro de 2025)	34
Tabela 3	– Comparação entre demanda prevista e real (Outubro/2025)	34
Tabela 4	– Comparação entre demanda prevista e real (Novembro/2025)	34
Tabela 5	– MSE e $RMSE$ por item (Setembro, Outubro e Novembro)	35
Tabela 6	– Acuracidade por item e peso no resultado global (Set/Out/Nov)	35
Tabela 7	– Parâmetros de estoque atuais (Política Vigente)	36
Tabela 8	– Estatísticas de compras e consumo dos itens	36
Tabela 9	– Parâmetros de estoque calculados (Baseado na previsão de Out/Nov) .	37

Lista de abreviaturas e siglas

ABC	Classificação baseada no valor de uso (Curva ABC)
ADF	<i>Augmented Dickey-Fuller</i>
ARIMA	<i>AutoRegressive Integrated Moving Average</i> (Média Móvel Integrada Autorregressiva)
ARMA	<i>AutoRegressive Moving Average</i>
CM	Consumo Médio
EPIs	Equipamentos de Proteção Individual
ERP	<i>Enterprise Resource Planning</i> (Sistemas Integrados de Gestão Empresarial)
IDE	<i>Integrated Development Environment</i> (Ambiente de Desenvolvimento Integrado)
IR	Intervalo de Ressuprimento
KPSS	<i>Kwiatkowski-Phillips-Schmidt-Shin</i>
LE	Lote Econômico
MAE	<i>Mean Absolute Error</i> (Erro Absoluto Médio)
MSE	<i>Mean Squared Error</i> (Erro Quadrático Médio)
PP	Ponto de Pedido
RMSE	<i>Root Mean Square Error</i> (Raiz do Erro Quadrático Médio)
SQL	<i>Structured Query Language</i> (Linguagem de Consulta Estruturada)
WMAPE	<i>Weighted Mean Absolute Percentage Error</i> (Erro Percentual Absoluto Médio Ponderado)
XGBoost	<i>Extreme Gradient Boosting</i>

Sumário

1	INTRODUÇÃO	11
2	REFERENCIAL TEÓRICO	12
2.1	Gestão e controle de estoque	12
2.2	Parâmetros clássicos da gestão de estoque	13
2.2.1	Curva ABC	13
2.2.2	Lote econômico de compra	14
2.2.3	Ponto de Pedido	15
2.2.4	Estoque de Segurança	15
2.2.5	Estoque máximo	16
2.3	Custos de estoque	17
2.4	Previsão de demanda	18
2.4.1	Métodos qualitativos	18
2.4.2	Métodos quantitativos	19
2.5	ARIMA	21
2.5.1	Fundamentos de séries temporais e o conceito de estacionariedade	22
2.6	Machine Learning	23
2.6.1	Tipos de Machine Learning	23
2.6.2	O Algoritmo XGBoost (Extreme Gradient Boosting)	23
3	METODOLOGIA	25
4	APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS	27
4.1	Descrição do modelo atual de previsão e controle de estoques	27
4.2	Proposta de melhoria	27
5	CONCLUSÕES E CONSIDERAÇÕES FINAIS	38
	REFERÊNCIAS	39
	ANEXOS	41

1 Introdução

Um dos grandes desafios da indústria manufatureira é atingir um equilíbrio entre a manutenção de estoque e a redução de custos. Se, por um lado, o objetivo é ter um certo nível de estoque, o custo tende a aumentar à medida que os níveis sobem, mas, caso a estratégia seja reduzir custos, baixar os níveis de estoques pode parecer uma solução imediata. Os estoques, quando bem administrados, tornam-se estratégicos para grandes companhias, e se sua gestão não for eficiente, pode acarretar grandes perdas operacionais e financeiras. Atingir um ponto de equilíbrio é de suma importância para garantir segurança operacional e ter a certeza de que não há capital imobilizado em estoques parados. Os métodos quantitativos mais usuais por gestores de estoque se baseiam em médias móveis simples e ponderadas, o que muitas vezes não é capaz de lidar com sazonalidades e comportamentos não lineares. Nessa lacuna, surgem os métodos estatísticos, como o *ARIMA*, e de aprendizado de máquina, como o *XGBoost*, que combinados, são capazes de prever de forma mais assertiva a demanda de itens que não possuem um comportamento fácil de identificar.

O objetivo geral deste trabalho é desenvolver e aplicar um modelo híbrido *ARIMA-XGBoost* para a previsão de demanda e a definição de parâmetros de estoque de EPs na área de suprimentos de uma indústria. Para atingir tal propósito, estabeleceram-se os seguintes objetivos específicos: automatizar o tratamento dos relatórios extraídos do sistema ERP, estruturar um banco de dados centralizado, validar as previsões do modelo comparando-as com a demanda real, aferir a acurácia estatística e, por fim, calcular e propor novos parâmetros de controle de estoque.

O trabalho inicia-se com a apresentação da teoria clássica de controle de estoque, abordando conceitos como Curva ABC, lote econômico de compra e ponto de pedido, posteriormente, são apresentados os conceitos de séries temporais, estacionariedade e *machine learning*. A metodologia descreve a natureza, a abordagem, os objetivos e os procedimentos da pesquisa, bem como as ferramentas e os softwares utilizados. Na análise de resultados, são mostrados todos os processos realizados no estudo, bem como suas análises e comparações com o método atual da empresa e, por fim, a conclusão com os dados obtidos.

2 Referencial teórico

2.1 Gestão e controle de estoque

De acordo com Bowersox, Closs e Cooper (2014), o controle de estoque consiste em monitorar as entradas e saídas de materiais, um processo que pode ser realizado por meio de contagens manuais ou pelo uso de sistemas computadorizados, cujo objetivo é definir quando e quanto pedir. Segundo Dias (2010, p. 15) “A função da Administração de Estoques é maximizar o efeito lubrificante do feedback de vendas e o ajuste do planejamento e programação da produção”.

Para Slack, Brandon-Jones e Burgess (2023), a gestão de estoque apresenta uma considerável complexidade no mundo real. Para controlar milhares de itens, é necessário, primeiramente, classificá-los segundo um grau de importância para que recebam tratamentos distintos. Em segundo lugar, é fundamental contar com um sistema de apoio para gerenciar todas as informações relevantes sobre os produtos estocados.

Ainda segundo esses mesmos autores, em um inventário com múltiplos itens, é comum que alguns sejam mais importantes que outros. Certos produtos possuem um giro elevado e sua falta impactaria diretamente o atendimento ao cliente, enquanto outros, de alto custo, representariam um investimento financeiro expressivo se mantidos em grandes volumes. Para diferenciar esses itens, eles propõem a classificação baseada no valor de uso ou ABC, calculado pela multiplicação da taxa de utilização pelo seu custo unitário. Consequentemente, os itens no topo dessa classificação exigem um controle mais rigoroso, cuja intensidade diminui para os itens de menor valor.

Para Ballou (2006, p. 374) “São quatro as razões básicas para que se use espaço de estocagem: 1) reduzir os custos de transporte e produção; 2) coordenar oferta e demanda; 3) assessorar no processo de produção; 4) colaborar no processo de comercialização”.

Para Chapman et al. (2017), a manutenção de estoques oferece vantagens econômicas significativas para empresas do setor de manufatura. A aquisição de insumos em volumes maiores possibilita a negociação de descontos expressivos, o que impacta diretamente na redução do custo por unidade. Essa lógica de redução de custos aplica-se igualmente ao transporte e à produção, pois a fabricação em grandes lotes tende a diluir os custos fixos e a diminuir o valor final por item produzido. Entretanto, ressalta-se a importância de uma gestão criteriosa, pois a manutenção de estoques elevados só se justifica quando os benefícios financeiros superam os custos de mantê-los.

De acordo com Pozo (2015), a previsão do estoque é baseada em informações da área comercial da empresa, que calcula a demanda para que se saiba o que a organização precisará manter em estoque. Contudo, prever essa necessidade com exatidão não é uma tarefa simples. Portanto, a empresa precisa utilizar mecanismos de previsão apurados

para que seu processo produtivo não sofra com interrupções e atrasos, garantindo assim sua capacidade de atender aos clientes.

Segundo Viana (2006), um dos principais motivos para as empresas manterem estoques é garantir a continuidade de seus processos produtivos, evitando interrupções. Dessa forma, o setor de materiais ou suprimentos torna-se uma área estratégica, cujo papel fundamental é abastecer a produção de forma eficiente.

Ao abordar a relação entre estoque e vendas, Silver, Pyke e Thomas (2017), afirma que a equipe de marketing prefere manter níveis elevados de estoque. Por estar em contato direto com os clientes, considera essencial ter produtos disponíveis para atender às suas necessidades. Essa preferência pela pronta-entrega visa evitar atrasos e reclamações. Contudo, picos de venda inesperados impactam diretamente a produção e a cadeia de suprimentos da empresa.

2.2 Parâmetros clássicos da gestão de estoque

Para Bowersox, Closs e Cooper (2014), criar uma política de estoque envolve, primeiramente, saber o que comprar ou produzir, quando fazer o pedido e em qual quantidade. Em sistemas de estoques descentralizados, é necessário também pensar no posicionamento estratégico dos itens. Por exemplo, produtos com alta incerteza de demanda ou de alto valor se beneficiam de uma estratégia geográfica centralizadora. Já para itens com baixo valor relativo ou que exigem pronta-entrega, a abordagem oposta é mais adequada. De fato, desenvolver uma política de estoque sólida é um grande desafio para as empresas.


2.2.1 Curva ABC

De acordo com Ballou (2006), os desafios logísticos enfrentados pelas empresas originam-se da variação no volume de vendas entre seus produtos, o que implica que nem todos os itens devem receber o mesmo tratamento. Para lidar com essa questão, utiliza-se a análise da Curva ABC, que se baseia no Princípio de Pareto, no qual 20% dos produtos correspondem a 80% das vendas. Essa classificação é estruturada da seguinte forma: os 20% de itens mais relevantes recebem a classificação A, os 30% seguintes são classificados como B, e os 50% restantes compõem a classe C.

Segundo Dias (2010), a análise ABC é uma ferramenta importante para o administrador de estoque, pois permite definir o tratamento adequado para cada produto. Além disso, essa classificação auxilia na resolução de diversos problemas empresariais, como a identificação de produtos obsoletos, a definição de prioridades de compra e, no caso de indústrias, um melhor planejamento da produção.

A Figura 1 mostra uma representação da Curva ABC, embora nem sempre 20% dos itens correspondam a exatamente 80% das vendas, essa pequena parcela de produtos sempre possuirá uma participação significativa no resultado total.

Figura 1 – Análise da Curva ABC



Fonte: Dias (2010)

2.2.2 Lote econômico de compra

A administração de estoques frequentemente envolve lidar com situações de trade-off. Segundo Pozo (2015), um exemplo clássico ocorre ao comprar em maiores quantidades: embora o custo por item seja reduzido, em contrapartida, o custo de armazenagem aumenta. Lidar com esses conflitos de custo é uma tarefa constante para o gestor, e o lote econômico de compra surge como uma alternativa para esse dilema.

A Equação 2.1 elucida a fórmula do lote econômico de compra, que é derivada do custo total de estoque. Slack, Brandon-Jones e Burgess (2023) reforça que o objetivo desse método é encontrar o equilíbrio ideal entre o custo de fazer um pedido e o custo de manutenção do estoque.

$$LE = \sqrt{\frac{2 \times C \times C_p}{CA}} \quad (2.1)$$

Fonte: Pozo (2015).

Onde:

 LE : Lote Econômico; C : Quantidade consumida do produto; C_p : Custo do pedido;

CA : Custo de Armazenagem unitário anual.

2.2.3 Ponto de Pedido

Chapman et al. (2017) afirma que um novo pedido deve ser feito quando o estoque atinge uma quantidade pré-determinada. A partir desse ponto, o saldo remanescente precisa ser suficiente para cobrir toda a demanda até a chegada e o recebimento do novo lote.

Já para Silver, Pyke e Thomas (2017), a decisão de fazer um novo pedido baseia-se no nível mínimo que o estoque pode atingir antes do seu reabastecimento. O pedido precisa ser feito com a garantia de que o estoque remanescente seja capaz de atender à demanda durante esse período, evitando o seu esgotamento.


2.2.4 Estoque de Segurança

De acordo com Tubino (2017), quando se utiliza o estoque de segurança, seu objetivo principal é cobrir eventuais variações na demanda, garantindo o atendimento ao cliente durante o tempo de ressuprimento. Esse período é crítico, pois é nele que pode ocorrer uma ruptura no estoque e trazer insegurança operacional.

Segundo Christopher (2024), a preocupação do gestor de estoque se concentra nas ocasiões nas quais a demanda é maior que a média de um determinado período. Considerando uma distribuição normal, a probabilidade de a demanda ser inferior à média é de 50%, o que, por si só, já garante um nível de atendimento de aproximadamente 50% sem a necessidade de estoque de segurança. Para o autor, a atenção deve ser voltada aos períodos em que a demanda excede a média, momento em que o estoque de segurança se torna imprescindível.

A Figura 2, exemplifica que, ao adotar um estoque de segurança equivalente a um desvio padrão acima da demanda média, é possível garantir um nível de atendimento de aproximadamente 84%. Aumentando-se para dois desvios padrão, o nível de serviço chega a 98%, e com três, aproxima-se de 100%.

Figura 2 – Nível de atendimento e distribuição normal




Fonte: Christopher (2024)

2.2.5 Estoque máximo

Dias (2010) define estoque máximo como a soma do estoque segurança mais o lote de compra, que pode ser econômico ou não. Normalmente o estoque irá variar entre os limites do estoque de segurança e o estoque máximo que é bem representado pelo gráfico conhecido como dente de serra. Além disso um outro fator importante é capacidade de armazenagem que pode interferir na decisão do estoque máximo.

A Figura 3 ilustra a movimentação de um estoque durante um certo período. O ciclo inicia com o estoque em seu nível máximo e é consumido ao longo do tempo. Em um determinado instante, é atingido o ponto de pedido (PP), momento em que uma nova ordem de compra é emitida. O consumo continua até que, idealmente no instante em que o estoque atinge seu nível mínimo, ocorre a chegada do novo lote, repondo o inventário ao seu valor máximo. Nesse modelo, o estoque de segurança tem a função de cobrir eventuais atrasos na entrega ou aumentos na demanda durante o tempo de reposição. Por fim, o Intervalo de Ressuprimento (IR) representa o tempo decorrido entre a chegada de um lote e outro.

Figura 3 – Representação do gráfico dente de serra



Fonte: Dias (2010)


2.3 Custos de estoque

Pozo (2015), afirma que o dimensionamento de estoque envolve múltiplos fatores, cujo objetivo principal é suprir as necessidades da empresa para garantir a segurança operacional, ao mesmo tempo em que se busca a minimização dos custos de estoque. Quando uma empresa alcança um alto nível de eficiência em seus custos, ela pode utilizar o capital liberado para investir no aprimoramento de seus recursos produtivos, como na aquisição de máquinas novas ou adicionais, aumentando sua capacidade produtiva e fortalecendo sua estratégia competitiva.

Bowersox, Closs e Cooper (2014), define os custos de estoque como o valor necessário para manter os itens estocados. Esse valor é obtido pela multiplicação da taxa de manutenção de estoque pelo valor do estoque médio. É importante notar que o valor do estoque utilizado é o custo de compra ou fabricação, e não o de venda, ou seja, quanto o item de fato custou para a empresa. De forma geral, o custo de manutenção é baseado em diversos custos, como: impostos, capital, obsolescência, armazenamento, etc.

Em termos gerais, Dias (2010) define o custo total de estoque como a soma do custo de pedido e do custo de armazenagem. A Figura 4 ilustra a curva do custo total como a soma do custo de armazenagem e do custo de pedido. O custo de armazenagem é dado pelo produto entre o estoque médio ($Q/2$), o preço unitário (P) e a taxa de manutenção (I). Já o custo de pedido é o produto do custo por pedido (B) pelo número anual de pedidos (C/Q), onde C representa o consumo total anual e Q o número de peças compradas por pedido.

Figura 4 – Curva do custo total de estoque



Fonte: Dias (2010)

2.4 Previsão de demanda

Segundo Corrêa e Corrêa (2022), a previsão de demanda é o resultado de um conjunto de tarefas que envolvem desde o levantamento e tratamento correto dos dados até a compreensão do comportamento passado para a projeção de tendências futuras. O processo também exige a incorporação de informações qualitativas relevantes e o monitoramento constante dos erros de previsão. Para que esse processo seja eficaz, algumas informações são essenciais, tais como: dados históricos segmentados por período, registros de demanda não atendida, justificativas para atipicidades nos dados e a correlação entre as variáveis analisadas.

Para Batalha (2007), o gerenciamento da demanda é de extrema importância para uma empresa, sendo necessário estipulá-la a curto, médio e longo prazo, além de gerenciar também os seus pedidos. O autor afirma que existem diversas técnicas que levam em consideração o histórico de consumo e avaliações, ou seja, análises quantitativas e qualitativas. Entendê-las é de extrema importância para a estratégia operacional.

2.4.1 Métodos qualitativos

Corrêa e Corrêa (2022), afirmam que os métodos qualitativos incluem, além de julgamento e interpretação, também o conhecimento tácito dos envolvidos. Os autores definem os principais métodos como:

- **Júri de executivos:** um grupo formado por poucas pessoas (geralmente alta gerência) busca prever o comportamento de uma variável. Por envolver poucas pessoas,

concentra-se a opinião em um grupo restrito.

- Método Delphi: um processo iterativo composto por especialistas (geralmente de 6 a 12). É realizada uma pergunta específica sobre a variável a ser prevista e coletam-se as opiniões de forma sigilosa e individual. O responsável trata os dados estatisticamente e retorna o resultado compilado aos participantes. Esse ciclo é refeito até que a convergência das opiniões atinja o nível desejado, buscando o consenso. Por garantir o anonimato, reduz a influência de opiniões dominantes.
- Força de vendas: cada vendedor ou representante contribui com sua estimativa de demanda local, e o conjunto dessas estimativas compõe a previsão global. Nesse método, a estimativa pessoal do vendedor pode exercer influência na previsão.
- Pesquisa de mercado: consiste no levantamento sistemático de informações junto aos clientes para embasar a previsão de demanda.
- Analogia histórica: utilizada para novos produtos. Baseia-se nos dados de um produto semelhante para projetar a previsão do novo item.


Para Slack, Brandon-Jones e Burgess (2023), os gestores utilizam métodos qualitativos baseados na avaliação e no conhecimento cotidiano, embora exista uma preferência pelos métodos quantitativos, principalmente na análise de séries temporais

2.4.2 Métodos quantitativos

Corrêa, Giansesi e Caon (2018), afirmam que o primeiro passo para a modelagem matemática é a análise dos dados históricos e a escolha de uma hipótese de comportamento. Quatro hipóteses podem ser adotadas, conforme ilustra a Figura 5:

- Hipótese de permanência: na qual a demanda é estável e uniforme, sem tendência de aumento ou decréscimo e sem sazonalidades que possam ser identificadas.
- Hipótese sazonal com permanência: na qual existe uma sazonalidade identificável e justificável, mas sem tendência de crescimento ou queda na demanda média.
- Hipótese de trajetória: na qual a demanda têm um comportamento de aumento ou decréscimo com uma taxa uniforme, mas sem a presença de sazonalidade.
- Hipótese sazonal com trajetória: situação em que há sazonalidade identificável e justificável, combinada com uma tendência de aumento ou queda a uma taxa uniforme.

Figura 5 – Hipóteses de comportamento



Fonte: Corrêa, Giansesi e Caon (2018)

Uma vez escolhida a hipótese, pode-se definir o método de previsão que será utilizado.

- **Média móvel:** A Equação 2.2 ilustra a definição de Dias (2010) para a média móvel, na qual o Consumo Médio (CM) é definido pela soma dos consumos em períodos anteriores dividida pelo número de períodos (n). O autor ressalta que, caso a demanda apresente uma tendência de aumento, a previsão gerada por esse método tende a ser menor que a demanda real e caso a tendência seja de queda, a previsão tende a ser maior.

$$CM = \frac{C_1 + C_2 + C_3 + \dots + C_n}{n} \quad (2.2)$$

Fonte: Dias (2010).

Onde:

CM : Consumo médio;

C : Consumo nos períodos anteriores;

n : Número de períodos.

- **Média móvel ponderada:** o mesmo autor também define a Média Móvel Ponderada como uma variação do modelo anterior, na qual são atribuídos pesos aos períodos mais recentes. Dessa forma, a previsão é o resultado da soma dos produtos entre o consumo e os pesos, dividida pela soma total dos pesos, como podemos ver na fórmula a seguir, na qual (C) é o peso atribuído e (X) é a demanda em períodos anteriores conforme Equação 2.3.

$$\overline{X}_i = \frac{\sum_{i=1}^n C_i \cdot X_i}{\sum_{i=1}^n C_i} \quad (2.3)$$

Fonte: Dias (2010).

Onde:

$\overline{X}_i$: Média móvel ponderada;

C_i : Peso atribuído ao período i ;

X_i : Demanda no período i ;

n : Número de períodos.

- Suavização exponencial: a Equação 2.4 elucida a definição de suavização exponencial de Corrêa, Giansesi e Caon (2018), na qual temos uma constante de suavização (α) que varia entre 0 e 1, e a previsão leva em consideração o período anterior para obter a estimativa atual. Além disso, os autores reforçam que a fórmula possui variações a depender da hipótese de comportamento dos dados.

$$\begin{aligned} S_t &= \alpha \times V_t + (1 - \alpha) \times S_{t-1} \\ P_t &= S_{t-1} \end{aligned} \quad (2.4)$$

Fonte: Corrêa, Giansesi e Caon (2018).

Onde:

S_t : Valor da BASE calculado no instante t ;

α : Constante de suavização;

V_t : Valor das vendas reais no período t ;

P_t : Previsão das vendas para o período t .

2.5 ARIMA


O processo de Média Móvel Integrada Autorregressiva (ARIMA) é definido por Box et al. (2016), como uma classe geral de modelos estocásticos capazes de descrever tanto séries temporais estacionárias quanto não estacionárias. O processo é caracterizado pelos parâmetros (p, d, q) , nos quais p refere-se à ordem da parte autorregressiva, d indica a quantidade de vezes que a série precisa ser diferenciada para se tornar estacionária, e q representa a ordem da parte de médias móveis.

De acordo com Montgomery, Jennings e Kulahci (2015), uma série temporal pode ser considerada um processo *ARIMA* quando, após ser diferenciada d vezes, produz um processo *ARMA* estacionário com parâmetros $(p$ e $q)$. Dessa forma, garantimos a condição de estacionariedade necessária para a modelagem. No entanto, temos a necessidade de retornar à escala da série original e o parâmetro d nos remete a esse retorno, fazendo o processo contrário à diferenciação, ou seja, integrando a série diferenciada, daí o termo 'Integrada'.

2.5.1 Fundamentos de séries temporais e o conceito de estacionariedade

De acordo com Brockwell e Davis (2016), uma série temporal é um conjunto de observações que são obtidas em um determinado tempo. A Figura 6 ilustra as vendas mensais de milhares de litros dos vinicultores australianos entre 1980 e 1991, representando um conjunto de observações com intervalos de tempo uniformemente espaçados.

Figura 6 – Vendas Mensais de Vinho Tinto por Vinicultores Australianos (1980–1991)



Fonte: Brockwell e Davis (2016)

Para Penã, Tiao e Tsay (2001), uma série temporal é um conjunto de observações realizadas em intervalos de tempo sequenciais, como preços de ações, leituras de temperatura, etc. Já uma série estacionária apresenta um comportamento estatístico que se mantém ao longo do tempo. Em contrapartida, a série não estacionária não possui um nível de equilíbrio fixo, sendo necessário diferenciá-la para torná-la estacionária. Caso a primeira diferenciação não seja suficiente, aplica-se uma segunda.

Box et al. (2016) definem uma série temporal como um conjunto de observações ordenadas no tempo. Uma série estacionária é descrita como um conjunto de dados que está em equilíbrio estatístico, com média e variância constantes. Já a série não estacionária

é definida como aquela que não possui uma média fixa, mas que, apesar dessa condição, pode apresentar um comportamento homogêneo ao longo do tempo

2.6 Machine Learning

Para Alpaydin (2014), *machine learning* (ou aprendizado de máquina) é definido como a programação de computadores voltada para maximizar um critério de desempenho por meio de dados. Um modelo é constituído por parâmetros, e o aprendizado consiste na busca pelo ajuste ideal desses parâmetros utilizando os dados disponíveis. Os modelos podem ser classificados como preditivos, cujo objetivo é realizar projeções; descritivos, focados na interpretação e extração de conhecimento; ou ambos. Além disso, a análise da inferência do modelo é fundamental, pois é necessária precisão para que os resultados sejam aderentes à realidade.

Segundo Mitchell (1997), *machine learning* é a melhoria de desempenho em alguma tarefa por meio da programação de computadores. Um programa de computador aprende quando o seu desempenho em executar tarefas específicas melhora com base em dados ou na experiência.

2.6.1 Tipos de Machine Learning

De acordo com Bishop (2006), o aprendizado de máquina pode ser classificado em três categorias principais. No aprendizado supervisionado, os dados contêm exemplos dos valores de entrada acompanhados de seus respectivos valores-alvo, sendo utilizado para tarefas de classificação ou regressão. Já no aprendizado não supervisionado, o conjunto de dados consiste apenas em valores de entrada sem alvos correspondentes, com o objetivo de descobrir grupos ou padrões ocultos. O autor também destaca o aprendizado por reforço como uma técnica distinta, preocupada em encontrar ações ótimas para maximizar uma recompensa através de tentativa e erro.

Segundo Mitchell (1997), no aprendizado supervisionado, o objetivo é obter uma função geral ou conceito a partir de um conjunto de exemplos de treinamento específicos que possuem entradas e saídas definidas. Já no aprendizado não supervisionado, utilizado em tarefas como agrupamento, o algoritmo busca identificar regularidades implícitas ou estimar parâmetros em dados onde as variáveis de interesse não são diretamente observáveis. Por fim, o aprendizado por reforço foca em agentes autônomos que devem aprender ações ótimas para cumprir objetivos em um ambiente, neste caso, o aprendizado ocorre através da experimentação e do recebimento de recompensas ou penalidades.


2.6.2 O Algoritmo XGBoost (Extreme Gradient Boosting)

De acordo com os criadores do método Chen e Guestrin (2016), o *XGBoost* é caracterizado como um sistema de aprendizado de máquina altamente escalável focado em

tree boosting ou impulsionamento de árvores. O método diferencia-se por utilizar um modelo regularizado para evitar o sobreajuste (*overfitting*) e por empregar algoritmos capazes de lidar eficientemente com bilhões de exemplos, mesmo em ambientes com recursos computacionais limitados.

A Figura 7 exemplifica um conjunto de árvores de classificação. Na árvore 1 a esquerda temos um nó que representa uma pergunta, há depender da resposta eu posso ter um outro nó ou não. Por exemplo, uma criança do sexo masculino ao passar nessa árvore terá a resposta do primeiro nó como sim pois tem menos que 15 anos de idade, depois verifica se é menino ou menina e só assim é atribuído o valor +2. Na árvore 2 o processo é o mesmo, ao final o algoritmo chega há um resultado somando os valores obtidos em cada árvore.

Figura 7 – Exemplo de estrutura de árvores em um modelo de Tree Boosting.



Fonte: Chen e Guestrin (2016)

A adoção de um modelo híbrido de previsão que une *ARIMA* e *XGBoost* justifica-se pela necessidade de complementação entre os métodos. Segundo Smyl (2019), a combinação dessas abordagens em uma estrutura unificada permite explorar as vantagens de ambas as técnicas. Enquanto os modelos estatísticos são eficazes na captura de componentes principais e locais de cada série individual (como nível e sazonalidade), os algoritmos de aprendizado de máquina complementam essa análise ao modelar tendências não lineares complexas e extrair padrões globais a partir do conjunto de dados.

3 Metodologia

Venanzi e Silva (2016) enfatizam que, em uma pesquisa científica, o autor deve definir com clareza a metodologia a ser utilizada, garantindo que o leitor compreenda plenamente o que está sendo apresentado. Dessa forma, a presente pesquisa classifica-se quanto à sua natureza, abordagem, objetivos e procedimentos técnicos, conforme detalhado a seguir.

- **Natureza:** este estudo classifica-se como de natureza aplicada, pois objetiva gerar soluções para problemas práticos. A partir das previsões de demanda geradas pelo modelo proposto, torna-se possível definir parâmetros fundamentais de controle de estoque como estoque máximo, mínimo e ponto de pedido, que auxiliam na tomada de decisão do gestor. O objetivo é evitar a ruptura de estoque (falta de materiais) e identificar excessos que resultam em capital imobilizado desnecessariamente. O estudo de caso foi conduzido em uma indústria produtora de aluminas especiais, caracterizada por uma alta demanda de Equipamentos de Proteção Individual (EPIs). Nesse cenário, a indisponibilidade de itens obrigatórios, como óculos de proteção, botinas e capacetes, impede a execução das atividades operacionais por normas de segurança, acarretando perdas diretas de produtividade. Além disso, o monitoramento de itens com baixo giro permite liberar capital financeiro para alocação estratégica em outras áreas da organização.
- **Abordagem:** este trabalho adota uma abordagem quantitativa e qualitativa. A vertente quantitativa fundamenta-se na utilização de séries temporais de baixa de estoque para o treinamento do modelo preditivo e para o dimensionamento dos níveis de estoque máximo, mínimo e ponto de pedido. Já a abordagem qualitativa concentra-se na análise estratégica para a tomada de decisão, avaliando as implicações de reduzir ou aumentar os níveis de estoque e definindo políticas de ressuprimento adequadas à realidade da empresa.
- **Objetivos:** esta pesquisa classifica-se como explicativa, pois busca compreender o comportamento da demanda interna de Equipamentos de Proteção Individual (EPIs). Por meio do reconhecimento de padrões realizado pelo modelo, objetiva-se prever a demanda futura com assertividade, auxiliando no dimensionamento de um estoque mais enxuto, capaz de atender às necessidades da empresa sem incorrer em rupturas ou excessos.
- **Procedimentos técnicos:** a realização do estudo de caso foi possível através da extração de dados de baixas de estoques e de compras do *ERP* da empresa. Esses dados foram tratados e centralizados em um banco de dados local. Posteriormente, foi realizada uma análise utilizando a linguagem *SQL* para obter uma visão geral das

informações. Em um ambiente virtual, criou-se um objeto de conexão com o banco de dados, além do modelo híbrido ($ARIMA + XGBoost$), o qual foi treinado com as séries temporais para obter as previsões e calcular os parâmetros de estoque. Além disso, todos os códigos desenvolvidos foram disponibilizados em repositório público no *GitHub* para permitir a replicação da pesquisa.

4 Apresentação e discussão dos resultados

4.1 Descrição do modelo atual de previsão e controle de estoques

Atualmente, o processo de dimensionamento de estoques na empresa inicia-se com a extração de dados do sistema *ERP* em formatos de planilha (.xlsx ou .csv). Visto que esses relatórios são gerados de forma não estruturada, faz-se necessária uma etapa de pré-processamento manual para a higienização e padronização dos dados.

Posteriormente, as informações são consolidadas em uma planilha eletrônica, na qual são calculados os parâmetros de controle, conforme ilustrado na Figura 8. Metodologicamente, a empresa aplica a Curva ABC para classificar os itens conforme sua rotatividade, definindo o Ponto de Pedido (PP) e os níveis de estoque mínimo e máximo. Essa política vigente tem como objetivo mitigar riscos de ruptura no abastecimento e identificar estoques superdimensionados.

Figura 8 – Exemplo da planilha de cálculo de parâmetros de estoque utilizada atualmente


CONSUMO (365 DIAS)				R\$ 107.863,67		R\$ 117.222,10		R\$ 175.021,07		CURVA ABC BASE EM GIRO				
Resp. Téc.: Luma Garcia EJE														
Código	Descrição do Itm	Quantidade	Custo Unit.	LEAD TIME (DIAS)	Estoque Mín. Viável	Estoque Mín. Atual	Estoque Máximo Atual	Custo Estoque Mínimo Atual	Estoque Atual	Custo do Estoque Atual	Estoque Máximo Estipulado	%	Acumulado	Classe ABC
373	MASCARA FILTRADORA 3M 801000-RO	2005	R\$ 4,71	13	107,12	R\$ 2.137,32	300	R\$ 2.037,00	288	R\$ 1.955,52	1460,62	8%	16%	A
461	MACACAÇÃO QUIMICO DUPONT PROSHIE	1941	R\$ 41,34	13	102,86	R\$ 4.252,13	100	R\$ 4.134,00	59	R\$ 2.439,06	154,29	8%	16%	A
462	MACACAÇÃO QUIMICO DUPONT PROSHIE	1638	R\$ 28,43	14	94,60	R\$ 2.689,35	80	R\$ 2.274,40	91	R\$ 2.587,13	141,89	7%	23%	A
435	LUVIA PROTEÇÃO VAQUETA 4-FORRO C	1621	R\$ 13,44	16	109,50	R\$ 1.471,69	250	R\$ 2.018,00	138	R\$ 1.854,72	164,25	7%	29%	A
382	FILTRO P25 MÓDULO 7970 SERIE 7 E 9	1064	R\$ 46,23	25	107,84	R\$ 4.985,24	80	R\$ 3.698,40	0	R\$ -	161,75	4%	34%	A
383	ÓCULOS AMPLA VISÃO STEALTH LUXE	950	R\$ 70,35	13	52,15	R\$ 3.668,59	60	R\$ 4.221,00	47	R\$ 3.306,45	78,22	4%	38%	A
384	LENTE INCOLOR PARA RESSACAÇÃO EM L	945	R\$ 25,91	16	62,58	R\$ 1.621,37	80	R\$ 2.077,80	76	R\$ 1.969,16	93,87	4%	41%	A
430	LUVIA DE MALHA TRICOTADA PROMENT	894	R\$ 12,03	15	56,27	R\$ 676,93	67	R\$ 806,01	196	R\$ 2.357,88	84,48	4%	45%	A
431	LUVIA DE SEGURANÇA EM PVC OBRISA	854	R\$ 21,85	27	94,76	R\$ 2.070,48	100	R\$ 2.185,00	115	R\$ 2.512,75	142,14	3%	49%	A
390	CAMISA MANGA LONGA TAMA G	817	R\$ 68,89	44	146,72	R\$ 10.107,83	74	R\$ 5.097,84	74	R\$ 5.097,84	220,09	3%	52%	A
387	PROTECTOR AURICULAR TIPO PLUG PRE	794	R\$ 1,54	16	53,34	R\$ 81,84	100	R\$ 154,00	68	R\$ 104,72	79,71	3%	55%	A
460	MACACAÇÃO QUIMICO DUPONT PROSHIE	678	R\$ 46,69	16	44,91	R\$ 2.096,96	50	R\$ 2.334,50	0	R\$ -	67,37	3%	58%	A
388	PROTECTOR AURICULAR DESCAARTAVEL F	549	R\$ 0,80	16	36,10	R\$ 28,88	40	R\$ 32,00	116	R\$ 92,80	54,15	2%	60%	A
389	CAMISA MANGA LONGA TAMA M	458	R\$ 68,68	44	82,30	R\$ 5.652,58	32	R\$ 2.197,76	26	R\$ 1.785,68	123,45	2%	62%	A
391	CAMISA MANGA LONGA TAMA GG	416	R\$ 68,10	43	73,51	R\$ 5.006,19	43	R\$ 2.928,30	127	R\$ 8.648,70	110,27	2%	64%	A
374	ABRADOR RUDEOS MARE V GREEN TYP	405	R\$ 190,01	14	23,02	R\$ 4.374,79	25	R\$ 4.750,25	17	R\$ 3.220,17	34,54	2%	65%	A
424	CAPACETE SEGURANÇA COM CARNIEIR	373	R\$ 52,01	15	22,90	R\$ 1.191,18	25	R\$ 1.300,25	9	R\$ 468,09	34,35	2%	67%	A
425	CARNEIRA PARA CAPACETE MSA - OBR	322	R\$ 26,14	14	19,14	R\$ 500,41	30	R\$ 784,20	55	R\$ 1.437,70	28,72	1%	68%	A
404	CALÇA JEANS PADRÃO ACTEON N- 44	311	R\$ 66,30	46	59,34	R\$ 3.934,21	30	R\$ 1.980,00	63	R\$ 4.176,90	89,01	1%	70%	A
402	CALÇA JEANS PADRÃO ACTEON N- 40	308	R\$ 67,43	46	58,07	R\$ 3.927,03	30	R\$ 2.028,90	55	R\$ 3.719,65	87,10	1%	71%	A
403	CALÇA JEANS PADRÃO ACTEON N- 42	284	R\$ 66,99	46	53,54	R\$ 3.586,76	35	R\$ 2.344,65	54	R\$ 3.617,46	80,31	1%	72%	A
394	CALÇA DE SEGURANÇA PVC KPSIO ANI	280	R\$ 64,05	32	59,45	R\$ 3.807,90	25	R\$ 1.601,25	82	R\$ 5.252,10	89,18	1%	73%	A
385	BANDA ELÁSTICA CINTA EM TECIDO PVC	246	R\$ 20,74	33	33,89	R\$ 702,83	20	R\$ 414,80	0	R\$ -	50,83	1%	74%	A
478	BOTINA BIQUEIRA DE COMPOSITE N- 4	224	R\$ 32,05	12	11,41	R\$ 365,84	20	R\$ 641,00	5	R\$ 160,25	17,12	1%	75%	A
376	LENTE INCOLOR PROTECTOR KIDAL C&A	221	R\$ 18,74	12	10,51	R\$ 196,95	60	R\$ 1.124,40	50	R\$ 937,00	15,76	1%	76%	A
473	BOTINA BIQUEIRA DE COMPOSITE N- 4	218	R\$ 82,45	12	10,89	R\$ 899,94	20	R\$ 1.653,00	18	R\$ 1.487,70	16,33	1%	77%	A
482	BOTINA BIQUEIRA DE COMPOSITE N- 4	211	R\$ 28,82	12	10,34	R\$ 298,10	20	R\$ 576,40	18	R\$ 518,76	15,52	1%	78%	A
7675	FITA DE SINALIZAÇÃO SEGURANÇA ZEBR	203	R\$ 6,38	29	23,84	R\$ 132,07	0	R\$ -	0	R\$ -	35,75	1%	78%	A
371	CELE DE IMPRESA PARA MÓDULO PROSE	197	R\$ 63,56	35	28,34	R\$ 1.234,30	5	R\$ 217,80	63	R\$ 2.744,28	42,50	1%	79%	A
421	CAPUZ DE BRIM TAMANHO G - CA 414C	193	R\$ 21,25	30	23,95	R\$ 508,98	35	R\$ 743,75	36	R\$ 765,00	35,93	1%	80%	A
401	CALÇA JEANS PADRÃO ACTEON N- 38	171	R\$ 66,03	43	26,36	R\$ 1.740,73	11	R\$ 726,33	17	R\$ 1.122,51	34,27	1%	81%	B
388	CAMISA MANGA LONGA TAMA P	171	R\$ 67,35	44	26,71	R\$ 1.768,97	25	R\$ 1.680,75	41	R\$ 2.761,35	34,72	1%	81%	B
439	LUVIA NITRILICA VERDE SEM FORRO - TI	167	R\$ 21,32	11	6,48	R\$ 138,22	25	R\$ 533,00	22	R\$ 469,04	8,43	1%	82%	B
399	CALÇA DE SEGURANÇA PVC KPSIO ANI	165	R\$ 75,34	36	21,08	R\$ 1.588,37	25	R\$ 1.883,50	33	R\$ 2.486,22	27,41	1%	83%	B
388	CAMISA MANGA LONGA TAMA P	139	R\$ 69,02	44	21,56	R\$ 1.488,17	15	R\$ 1.033,23	28	R\$ 1.932,42	28,03	1%	83%	B
466	BOTA CANO LONGO PVC N- 40 OBRISA	137	R\$ 36,63	31	15,26	R\$ 558,95	30	R\$ 1.098,90	94	R\$ 3.443,22	19,84	1%	84%	B
483	BOTINA BIQUEIRA DE COMPOSITE N- 4	136	R\$ 83,17	13	6,69	R\$ 506,45	10	R\$ 831,70	3	R\$ 249,51	7,92	1%	84%	B
479	BOTINA BIQUEIRA DE COMPOSITE N- 3	134	R\$ 84,39	12	5,70	R\$ 480,06	20	R\$ 1.685,80	15	R\$ 1.264,35	7,60	1%	85%	B
432	CREME LUXE HIDROSOLOVEL (SAI C/5)	128	R\$ 10,59	15	6,09	R\$ 70,81	15	R\$ 158,85	18	R\$ 190,62	8,69	1%	86%	B

Fonte: Dados da pesquisa (2025).

4.2 Proposta de melhoria

O estudo teve início com a extração de dados do sistema *ERP* da empresa, conforme ilustra a Figura 9. Foram coletados registros de baixas de estoque e de compras realizadas no período de junho de 2022 a novembro de 2025. Originalmente, esses relatórios foram exportados em formato .xlsx.

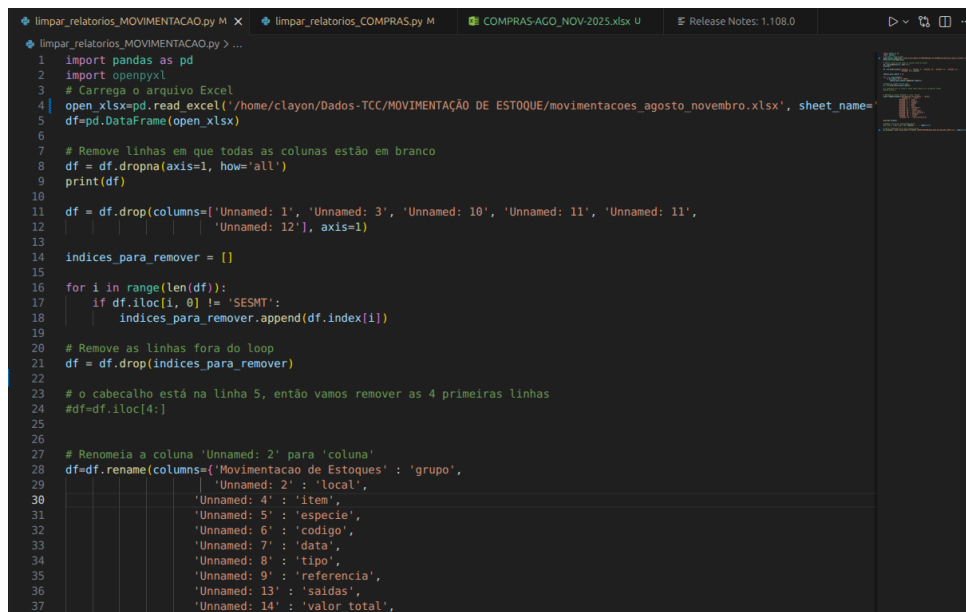
Figura 9 – Interface de extração de relatórios do sistema *ERP*



Fonte: Dados da pesquisa (2025).

Devido à recorrência das extrações e ao tempo considerável na estruturação manual dos dados, desenvolveu-se um *script* em *Python*, conforme apresentado na Figura 10. Utilizando a biblioteca *Pandas* para a automação da tarefa, o processo de tratamento de dados tornou-se instantâneo, sendo executado em poucos segundos.

Figura 10 – Script em *Python* para tratamento de dados



Fonte: Pesquisa direta (2025).

Devido à considerável quantidade de dados, optou-se pela centralização e estruturação das informações em um ambiente controlado. Dessa forma, foi implementado um banco de dados local (*localhost*), conforme ilustrado na Figura 11.

Figura 11 – Banco de dados local

grupo	local	item	especie	codigo	data	referencia	status	valor
1	SEMT	Almoarifado Ge.	LENTE VERDE T4 P/OCULOS	UN	363	2022-07-06 00:00:00	BAL.	11814
2	SEMT	Almoarifado Ge.	LENTE EXTERNA 90X115 MM P/ MASCARA AUTOMATICA A20 ESAB	UN	367	2022-10-24 00:00:00	BAL.	11824
3	SEMT	Almoarifado Ge.	PROTECTOR AURIOLAR DESCARTAVEL PARA VISITANTES OBRIGATORIO C.A 5674	UN	368	2022-08-19 00:00:00	BAL.	4141
4	SEMT	Almoarifado Ge.	PROTECTOR AURIOLAR DESCARTAVEL PARA VISITANTES OBRIGATORIO C.A 5674	UN	368	2022-10-10 00:00:00	BAL.	10969
5	SEMT	Almoarifado Ge.	PROTECTOR AURIOLAR DESCARTAVEL PARA VISITANTES OBRIGATORIO C.A 5674	UN	368	2022-10-13 00:00:00	BAL.	10967
6	SEMT	Almoarifado Ge.	PROTECTOR AURIOLAR DESCARTAVEL PARA VISITANTES OBRIGATORIO C.A 5674	UN	368	2022-11-04 00:00:00	BAL.	13022
7	SEMT	Almoarifado Ge.	PROTECTOR AURIOLAR DESCARTAVEL PARA VISITANTES OBRIGATORIO C.A 5674	UN	368	2022-11-21 00:00:00	BAL.	13768
8	SEMT	Almoarifado Ge.	OCULOS DE MACARIOQUERO COM ARMACAO UNICA EM PVC-C A 5901	UN	369	2022-08-10 00:00:00	BAL.	3139
9	SEMT	Almoarifado Ge.	OCULOS DE MACARIOQUERO COM ARMACAO UNICA EM PVC-C A 5901	UN	369	2022-08-09 00:00:00	BAL.	5070
10	SEMT	Almoarifado Ge.	OCULOS DE MACARIOQUERO COM ARMACAO UNICA EM PVC-C A 5901	UN	369	2022-09-01 00:00:00	BAL.	5465
11	SEMT	Almoarifado Ge.	OCULOS DE MACARIOQUERO COM ARMACAO UNICA EM PVC-C A 5901	UN	369	2022-10-17 00:00:00	BAL.	10855
12	SEMT	Almoarifado Ge.	OCULOS DE MACARIOQUERO COM ARMACAO UNICA EM PVC-C A 5901	UN	369	2022-10-20 00:00:00	BAL.	11161
13	SEMT	Almoarifado Ge.	OCULOS DE MACARIOQUERO COM ARMACAO UNICA EM PVC-C A 5901	UN	369	2022-10-24 00:00:00	BAL.	11813
14	SEMT	Almoarifado Ge.	OCULOS DE MACARIOQUERO COM ARMACAO UNICA EM PVC-C A 5901	UN	369	2022-10-24 00:00:00	BAL.	11823
15	SEMT	Almoarifado Ge.	OCULOS DE MACARIOQUERO COM ARMACAO UNICA EM PVC-C A 5901	UN	370	2022-08-16 00:00:00	BAL.	3625
16	SEMT	Almoarifado Ge.	OCULOS DE MACARIOQUERO COM ARMACAO UNICA EM PVC-C A 5901	UN	370	2022-08-16 00:00:00	BAL.	3626
17	SEMT	Almoarifado Ge.	OCULOS DE MACARIOQUERO COM ARMACAO UNICA EM PVC-C A 5901	UN	370	2022-08-16 00:00:00	BAL.	3626

Fonte: Pesquisa direta (2025).

Dessa forma, todas as etapas de ingestão tornam-se replicáveis para novos dados, assegurando a alimentação contínua dos modelos adotados. Nesse contexto, a utilização da linguagem *SQL* (*Structured Query Language*) melhora a manipulação desses dados, permitindo filtrar, agregar e estruturar as informações exatas necessárias para o treinamento e validação das previsões.

Inicialmente, conduziu-se uma Análise Exploratória de Dados para compreender o comportamento global das movimentações. Para tanto, utilizou-se o software open source Metabase, conectado ao banco de dados local, para a elaboração de um dashboard como ilustrado na Figura 12. Essa visualização consolidou o volume total de movimentações, contagem de itens e o giro. Adicionalmente, o gráfico de evolução temporal das movimentações agregadas revelou um padrão sazonal nos meses finais de cada ano, caracterizado por uma redução na demanda. Esse comportamento foi validado pela empresa, justificando-se pela queda natural no consumo de EPIs nesses períodos. Ressalta-se que essa análise reflete o cenário geral, ou seja, a soma de todas as movimentações, para a identificação de padrões específicos e tendências individuais, faz-se necessária uma análise por item, tarefa que será desempenhada pelo modelo preditivo proposto.

Figura 12 – Dashboard de análise exploratória dos dados




Fonte: Pesquisa direta (2025).

Outra ferramenta amplamente utilizada na gestão de estoques é a Classificação ABC, fundamentada no Princípio de Pareto (80/20). Esse método relaciona a representatividade financeira de cada material com sua quantidade física, calculada pelo produto entre a demanda do item e seu valor unitário. Com base nesse cálculo, os itens são categorizados nas classes A, B e C.

Essa análise torna-se estratégica, pois permite ao gestor diferenciar o nível de atenção e controle a ser dedicado a cada grupo de materiais. A Figura 13 apresenta a Curva ABC de todos os itens em estoque da empresa estudada no período de Junho de 2022 até Novembro de 2025. Devido à elevada quantidade de itens, os rótulos do eixo X foram retirados para garantir a legibilidade, e optou-se pelo uso de escalas de cinza para facilitar a distinção visual das classes.

Figura 13 – Análise da curva ABC



Fonte: Pesquisa direta (2025).

A figura 14 apresenta a síntese dos dados ilustrados na curva ABC. No estoque da empresa analisada, a Classe A é composta por 51 itens, o que corresponde a 16,14% do total, mas que financeiramente representa a maior parcela do capital investido (79,62%).

A Classe B conta com 63 itens (19,94% do total), respondendo por 15,32% do valor monetário. Por fim, a Classe C engloba a grande maioria, com 202 itens (63,92%), porém sua representatividade financeira é baixa, somando apenas 5,07% do valor total. Essa distribuição confirma a aderência do estoque ao Princípio de Pareto.

Figura 14 – Resumo da classificação ABC

	classe	quantidade_itens	valor_total_classe	porc_itens	porc_valor
1	A	51	2575118.0	16.14	79.62
2	B	63	495445.4	19.94	15.32
3	C	202	163854.9	63.92	5.07

Fonte: Pesquisa direta (2025).


Com a disponibilidade dos dados, deu-se início à etapa de modelagem. A partir desse ponto, adotou-se a linguagem de programação R, executada na *IDE* RStudio, para a condução de todo o processo preditivo. Foram utilizadas bibliotecas específicas para cada função: o pacote *forecast* para a aplicação do modelo estatístico *ARIMA*, o *xgboost* para o modelo de aprendizado de máquina e o *RPostgres* para estabelecer a conexão e extração dos dados do banco. Além dessas, outras bibliotecas auxiliares foram empregadas para a manipulação e configuração das séries temporais.

O algoritmo inicia-se com a instalação e importação dos pacotes necessários. Posteriormente, cria-se um objeto de conexão com o banco de dados, permitindo a execução de consultas (queries) e a atribuição dos resultados a um dataframe. Optou-se por essa abordagem dinâmica para viabilizar a filtragem de movimentações de itens em períodos específicos e a posterior aplicação das previsões.

Na etapa de pré-processamento, realiza-se a conversão do campo de data para o formato adequado (date), seguida pela agregação e ordenação cronológica dos dados por item e dia. Com a base estruturada, aplica-se o modelo *ARIMA* para gerar previsões para os próximos 30 dias. Ressalta-se que este método é capaz de lidar com séries não estacionárias (via diferenciação), embora testes como *ADF* (*Augmented Dickey-Fuller*) e *KPSS* (*Kwiatkowski-Phillips-Schmidt-Shin*) possam ser aplicados para verificação.

Os resíduos (erros) gerados pelo *ARIMA* são utilizados como dados de entrada para o treinamento do *XGBoost*. Dessa forma, o modelo de aprendizado de máquina atua de maneira supervisionada, buscando explicar os padrões não lineares que o modelo estatístico não capturou. Por fim, a previsão final do modelo híbrido é obtida pela soma dos valores previstos pelo *ARIMA* com os resíduos previstos pelo *XGBoost*, conforme ilustrado na Figura 15.

Figura 15 – Previsões obtidas pelo modelo híbrido



	codigo	data	arima	xgb	previsao
1	373	2025-11-27	8.023787	-0.092863455	7.93092390
2	373	2025-11-28	9.335010	-3.358447313	5.97656223
3	373	2025-11-29	8.300975	3.862646341	12.16362125
4	373	2025-11-30	7.984662	-4.427150249	3.55751173
5	373	2025-12-01	8.593454	-3.089053631	5.50440056
6	373	2025-12-02	9.368819	-3.215165377	6.15365377
7	373	2025-12-03	10.160444	-4.193640709	5.96680289
8	373	2025-12-04	9.117863	-1.591817737	7.52604527
9	373	2025-12-05	9.117863	2.927630901	12.04549391
10	373	2025-12-06	9.117863	-4.542225361	4.57563765

Fonte: Pesquisa direta (2025).

Após obter as previsões, realizou-se uma comparação entre os valores estimados pelo modelo e a demanda real. Para a validação de desempenho, foram calculadas métricas estatísticas como *MAE* (*Mean Absolute Error*), *MSE* (*Mean Squared Error*), *RMSE* (*Root Mean Square Error*) e a acurácia geral. Subsequentemente, realizou-se o cálculo dos parâmetros de gestão (ponto de pedido, estoque mínimo e máximo). Por fim, compararam-se

os resultados propostos com a política de estoque vigente na empresa, visando determinar a necessidade de ajustes ou não.

Para as comparações, o trabalho restringiu-se a 5 itens devido ao grande volume do estoque, embora o processo possa ser replicado para qualquer material seguindo o mesmo passo a passo. Selecionaram-se 2 itens da Classe A, 2 da Classe B e 1 item da Classe C, pois, em um cenário real, é fundamental gerenciar com eficiência tanto itens de alto giro quanto os de baixa movimentação.

A Tabela 1 apresenta os materiais escolhidos com seus respectivos códigos, *Lead Time* (tempo de reposição), classificações e preços unitários. Tais comparações basearam-se nos dados de setembro, outubro e novembro de 2025.

Tabela 1 – Itens selecionados para análise detalhada

Item	Código	Lead Time	Class.	Valor Unit.
MASCARA FILTRADORA 3M 8801 (CX-80PC) OBRIGATORIO CA 2072	373	13 dias	A	6,72
MACACAO QUIMICO DUPONT PROSHIELD 50 NB127S BRANCO TAMANHO G CA 38648	461	13 dias	A	40,80
CREME LUVEX HIDROSOLUVEL (SAI C/AGUA) AZUL POTE 200G C.A 4114	432	15 dias	B	8,70
SUPORTE UNIVER P/PROTETOR FACIAL CAMPER MODELO 800302	377	13 dias	B	30,80
CAMISA POLO MASCULINA GG	11665	64 dias	C	54,90

Fonte: Dados da pesquisa(2025).

O modelo foi executado uma vez para cada mês analisado. Para gerar a previsão de setembro de 2025, por exemplo, foram fornecidos ao modelo apenas os dados até agosto, seguindo esse padrão de atualização (dados até o mês anterior) para todas as previsões subsequentes. O código mostrou-se dinâmico na etapa de extração de dados, visto que o objeto de conexão com o banco, criado dentro do RStudio, é reutilizável. Isso permitiu que as consultas fossem realizadas de forma ágil a cada nova rodada do algoritmo.

A seguir, serão realizadas as comparações entre os valores previstos pelo modelo e a demanda real. Após essa etapa, serão calculados os novos parâmetros de gestão de estoque, confrontando-os com a política vigente para identificar potenciais riscos de ruptura ou de superdimensionamento do inventário.

A Tabela 2 mostra a comparação do mês de setembro, na qual foram considerados dados apenas de janeiro de 2024 até agosto de 2025. Ela detalha o previsto, o real e o erro absoluto por código. Os itens 373 e 11665 obtiveram os menores erros absolutos. Já para os itens 461 e 377, o erro não foi significativo, mas o item 432 apresentou uma discrepância elevada. Dessa forma, conclui-se que são necessários alguns ajustes para aproximar o previsto do real. Neste primeiro momento, não serão consideradas questões

como demanda não atendida ou erros de registro, conclusões mais definitivas serão obtidas após a comparação completa dos três meses

Tabela 2 – Comparação entre demanda prevista e real (Setembro de 2025)

Código	Demanda Prevista	Demanda Real	MAE (Erro Abs.)
373	197	189	8
461	130	147	17
432	55	5	50
377	25	12	13
11665	5	1	4

Fonte: Pesquisa direta (2025).

Para o mês de outubro de 2025, foram considerados os dados seguindo o mesmo padrão do mês anterior, lógica que também será utilizada para novembro. A Tabela 3 apresenta o resultado das comparações para este mês. O primeiro destaque é o item 432, que saiu de um erro absoluto de 50 no mês anterior para 3 em outubro. Os itens 461, 377 e 11665 também apresentaram um erro menor em relação à comparação passada. Apenas o item 373 obteve um aumento no seu erro absoluto.

Tabela 3 – Comparação entre demanda prevista e real (Outubro/2025)

Código	Demanda Prevista	Demanda Real	MAE (Erro Abs.)
373	179	141	38
461	104	108	4
432	8	5	3
377	17	19	2
11665	7	4	3

Fonte: Pesquisa direta (2025).

Para a última rodada de comparações, o modelo recebeu mais um mês de dados, o que evidencia sua capacidade de aprender com novas informações. A Tabela 4 mostra os resultados para o mês de dezembro de 2025, onde é possível observar uma variação de apenas 1 unidade no erro dos itens 461, 432, 377 e 11665. Apesar da variação do item 373 em relação ao mês anterior ser baixa, nota-se a permanência de um erro absoluto considerável.

Tabela 4 – Comparação entre demanda prevista e real (Novembro/2025)

Código	Demanda Prevista	Demanda Real	MAE (Erro Abs.)
373	105	147	42
461	93	88	5
432	7	5	2
377	7	6	1
11665	4	0	4

Fonte: Pesquisa direta (2025).

A Tabela 5 apresenta o Erro Quadrático Médio (MSE) e a Raiz do Erro Quadrático Médio ($RMSE$), importantes indicadores sobre a precisão do modelo. Esses valores foram calculados com base nos erros absolutos dos três meses de análise. Para o item 373, tanto o MSE quanto o $RMSE$ apresentaram valores altos, o que sugere que o modelo não conseguiu identificar o padrão de demanda. Já para os itens 461, 377 e 11665, as métricas foram baixas, indicando que o modelo se ajustou bem ao comportamento desses materiais. Por fim, o item 432 apresentou valores elevados devido ao erro discrepante de setembro, que penalizou a média global, embora em outubro e novembro de 2025 seus erros absolutos tenham sido de apenas 3 e 2, respectivamente.

Tabela 5 – MSE e $RMSE$ por item (Setembro, Outubro e Novembro)

Código	MSE	RMSE
373	1.090,67	33,03
461	110,00	10,49
432	837,67	28,94
377	58,00	7,62
11665	13,67	3,70

Fonte: Pesquisa direta (2025).

A Tabela 6 apresenta os resultados de precisão do modelo, apesar do item 373 ter obtido erros absolutos notáveis, nota-se que, devido à sua grande movimentação, sua acuracidade ficou em 81,55%. O destaque, porém, vai para o item 461, com assertividade maior que 92%. Já os itens 432 e 11665 tiveram erros absolutos maiores que a demanda real, por isso, em termos técnicos, sua acurácia foi de 0%. Globalmente, o modelo obteve uma acuracidade superior a 77%, apresentando um desempenho satisfatório. Para medir a acurácia do modelo, utilizou-se o indicador $WMAPE$, no qual os itens com maior movimentação exercem um peso maior no resultado final. O cálculo é feito dividindo o somatório do erro absoluto pelo somatório da demanda total.

Tabela 6 – Acuracidade por item e peso no resultado global (Set/Out/Nov)

Código	Demanda Real	Erro Total	Acuracidade do Item	Peso na Acuracidade Geral
373	477	88	81,55%	54,39%
461	343	26	92,42%	39,11%
377	37	16	56,76%	4,22%
432	15	55	0,00%*	1,71%
11665	5	11	0,00%*	0,57%
TOTAL	877	196	77,65% (Global)	100,00%

Fonte: Pesquisa direta (2025).

Com as previsões geradas pelo modelo, é possível calcular os parâmetros de estoque, como estoque mínimo, máximo e ponto de pedido. A Tabela 7 mostra os dados fornecidos pela empresa com os parâmetros atuais.

Nota-se que todos os pontos de pedido são inferiores aos estoques mínimos, o que tecnicamente não deveria ocorrer. Essa configuração pode implicar ruptura de estoque, visto que o pedido de compra é feito tardiamente, quando o nível de segurança já está sendo utilizado.

Tabela 7 – Parâmetros de estoque atuais (Política Vigente)

Código	Estoque Mínimo	Estoque Máximo	Ponto de Pedido
373	108	160	72
461	103	155	70
432	7	9	6
377	6	8	5
11665	12	16	10

Fonte: Dados da pesquisa (2025).

Para o cálculo dos parâmetros, foram utilizados dados estatísticos do período de janeiro de 2025 a novembro de 2025, tais como a média de consumo e o desvio padrão. Além disso, considerou-se a média da quantidade comprada de cada item, que servirá de base para o lote de compra, conforme demonstra a Tabela 8.

Tabela 8 – Estatísticas de compras e consumo dos itens

Código	Média Qtd. Comprada	Média (Saídas)	Desvio Padrão
373	219	3,08	3,33
461	90	1,08	0,66
432	30	1,11	0,64
377	16	1	0,09
11665	45	1,59	1

Fonte: Pesquisa direta (2025).

Para o cálculo dos parâmetros, seguiram-se as previsões do modelo para os meses de outubro e novembro, conforme as Tabelas 3 e 4. Os cálculos tiveram como base a bibliografia de Dias (2010). O consumo considerado foi a média do que foi previsto pelo modelo nos dois meses. O fator de segurança adotado foi $K = 0,674$, correspondendo a um nível de atendimento de 75%. O Estoque Mínimo foi calculado multiplicando-se o consumo médio mensal pelo fator de segurança (K). O Ponto de Pedido corresponde ao lead time do fornecedor (conforme a Tabela 1) multiplicado pelo consumo médio, ressaltando a necessidade de equivalência nas unidades de medida, somado ao Estoque Mínimo. Já o Estoque Máximo é a soma do Estoque Mínimo com o lote de compra, conforme a Tabela 8.

A Tabela 9 apresenta os cálculos dos parâmetros baseados no modelo, levando em consideração um nível de atendimento de 75%, ou seja, os outros 25% representam a chance de falta de um item. Os Estoques Mínimos diminuíram para todos os materiais, exceto para o item 377, indicando uma oportunidade de liberar capital. Já os Estoques Máximos

aumentaram para todos os itens. Isso não significa que a empresa estará sempre com a lotação máxima, mas serve como um limite de controle, pois quantidades acima desse teto representam capital parado. Além disso, o Ponto de Pedido situou-se corretamente entre o estoque mínimo e o máximo para todos os itens.

Tabela 9 – Parâmetros de estoque calculados (Baseado na previsão de Out/Nov)

Código	Consumo Médio Previsto (Out, Nov)	Estoque Mínimo Estipulado	Estoque Máximo Estipulado	Ponto de Pedido
373	142	96	315	158
461	99	67	157	110
432	8	6	30	10
377	12	9	25	15
11665	6	5	50	18

Fonte: Pesquisa direta (2025).

Essa metodologia apresenta uma nova forma de calcular esses parâmetros, uma vez que não foi fornecido o fator de segurança utilizado atualmente nos cálculos vigentes. Dessa forma, podemos concluir que a metodologia demonstra um desempenho satisfatório quanto à previsão de demanda, à clareza dos cálculos e ao tempo de execução dessas etapas, que podem ser realizadas em minutos.

5 Conclusões e considerações finais

O presente trabalho atingiu seu objetivo principal ao desenvolver e aplicar um modelo híbrido de previsão de demanda (*ARIMA-XGBoost*) para a melhoria da gestão de estoques de equipamentos de proteção individual (EPIs) em uma indústria de alumina. Quanto à modelagem preditiva, a combinação de métodos estatísticos clássicos com algoritmos de machine learning provou-se adequada para lidar com a complexidade das séries temporais analisadas. O modelo alcançou uma acuracidade global ponderada (*WMAPE*) de 77,65%, com destaque para itens de comportamento mais estável, como o item 461, cuja assertividade superou 92%. Mesmo em itens com alta variabilidade e volume, como o 373, o modelo obteve desempenho satisfatório.

Do ponto de vista da gestão de estoques, o diagnóstico mais evidente foi a identificação de que, para os itens analisados, o ponto de pedido atual estava dimensionado abaixo do estoque mínimo, o que pode expor a operação a riscos. A nova metodologia propôs um ajuste nos níveis de reposição para garantir a disponibilidade dos materiais durante o lead time. Simultaneamente, para os itens de Classe A, o modelo sugeriu uma redução segura dos estoques mínimos, evidenciando uma oportunidade clara de redução de capital imobilizado sem comprometer o nível de serviço.

Além dos ganhos estratégicos, a semi-automação do processo representou um avanço operacional significativo. A implementação de scripts em *Python* para o tratamento de dados, aliada ao modelo preditivo integrado a um banco de dados *SQL* estruturado, reduziu o tempo de cálculo dos parâmetros de horas para minutos. Isso elimina a dependência de planilhas manuais suscetíveis a erros e libera o gestor para focar em análises estratégicas em vez de tarefas operacionais repetitivas.

Por fim, conclui-se que a metodologia proposta oferece uma solução robusta e replicável. Para trabalhos futuros, sugere-se a utilização de outros métodos de aprendizado de máquina, a automação de todos os processos apresentados e a criação de um dashboard no qual seja possível visualizar os parâmetros de todos os itens com uma taxa de atualização definida. Sugere-se, ainda, uma auditoria interna para apurar a veracidade dos dados e identificar possíveis erros de gravação, bem como uma análise voltada para o negócio e o dimensionamento do custo de armazenagem para a definição do lote econômico de compra, o que pode trazer mais ganhos operacionais e financeiros.

Referências

- ALPAYDIN, E. *Introduction to Machine Learning*. 3rd. ed. Cambridge, Massachusetts: The MIT Press, 2014.
- BALLOU, R. H. *Gerenciamento da cadeia de suprimentos/logística empresarial*. 5. ed. Porto Alegre: Bookman, 2006. E-book. ISBN 9788560031467. Disponível em: <<https://integrada.minhabiblioteca.com.br/reader/books/9788560031467/>>.
- BATALHA, M. *Introdução à Engenharia de Produção*. Rio de Janeiro: GEN LTC, 2007. ISBN 9788595155862. Disponível em: <<https://integrada.minhabiblioteca.com.br/reader/books/9788595155862/>>. Acesso em: 18 dez. 2025.
- BISHOP, C. M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006.
- BOWERSOX, D. J.; CLOSS, D. J.; COOPER, M. B. *Gestão Logística da Cadeia de Suprimentos*. 4. ed. Porto Alegre: Bookman, 2014. E-book. ISBN 9788580553185. Disponível em: <<https://integrada.minhabiblioteca.com.br/reader/books/9788580553185/>>.
- BOX, G. E. P. et al. *Time Series Analysis: Forecasting and Control*. 5. ed. Hoboken, New Jersey: John Wiley & Sons, 2016.
- BROCKWELL, P. J.; DAVIS, R. A. *Introduction to Time Series and Forecasting*. 3. ed. Switzerland: Springer International Publishing, 2016. (Springer Texts in Statistics). ISBN 978-3-319-29852-8.
- CHAPMAN, S. N. et al. *Introduction to Materials Management*. Eighth, global edition. Harlow, England: Pearson Education Limited, 2017. ISBN 978-1-292-16235-5.
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: *KDD '16*. San Francisco, CA, USA: ACM, 2016. ISBN 978-1-4503-4232-2.
- CHRISTOPHER, M. *Logística e gerenciamento da cadeia de suprimentos*. 4. ed. Porto Alegre: +A Educação - Cengage Learning Brasil, 2024. E-book. Disponível em: <https://app.minhabiblioteca.com.br/reader/books/9786555583533/>. Acesso em: 02 set. 2025. ISBN 9786555583533.
- CORRÊA, H. L.; CORRÊA, C. A. *Administração de Produção e Operações: Manufatura e Serviços: Uma Abordagem Estratégica*. 5. ed. Rio de Janeiro: Atlas, 2022. ISBN 9786559773268. Disponível em: <<https://integrada.minhabiblioteca.com.br/reader/books/9786559773268/>>. Acesso em: 07 dez. 2025.
- CORRÊA, H. L.; GIANESI, I. G. N.; CAON, M. *Planejamento, Programação e Controle da Produção: MRP II / ERP*. 6. ed. Rio de Janeiro: Atlas, 2018. ISBN 9788597018554. Disponível em: <<https://integrada.minhabiblioteca.com.br/reader/books/9788597018554/>>. Acesso em: 06 dez. 2025.
- DIAS, M. A. R. *Administração de Materiais: Uma Abordagem Logística*. 5. ed. São Paulo: Atlas, 2010.
- MITCHELL, T. M. *Machine Learning*. 1. ed. New York: McGraw-Hill, 1997. ISBN 0070428077.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. *Introduction to Time Series Analysis and Forecasting*. 2. ed. Hoboken, New Jersey: John Wiley & Sons, Inc., 2015. (Wiley Series in Probability and Statistics).

PENÄ, D.; TIAO, G. C.; TSAY, R. S. (Ed.). *A Course in Time Series Analysis*. New York: John Wiley & Sons, Inc., 2001. (Wiley Series in Probability and Statistics). ISBN 0-471-36164-X.

POZO, H. *Administração de Recursos Materiais e Patrimoniais: Uma Abordagem Logística*. 7. ed. Rio de Janeiro: Atlas, 2015. E-book. Disponível em: <https://integrada.minhabiblioteca.com.br/reader/books/9788597004427/>. Acesso em: 12 jun. 2025. ISBN 9788597004427.

SILVER, E. A.; PYKE, D. F.; THOMAS, D. J. *Inventory and Production Management in Supply Chains*. Fourth. Boca Raton, FL: CRC Press, Taylor & Francis Group, 2017. ISBN 978-1-4665-5861-8.

SLACK, N.; BRANDON-JONES, A.; BURGESS, N. *Administração da Produção*. 10. ed. Rio de Janeiro: Atlas, 2023. E-book. ISBN 9786559775187. Disponível em: <<https://integrada.minhabiblioteca.com.br/reader/books/9786559775187/>>.

SMYL, S. A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, March 2019. Preprint submitted to International Journal of Forecasting.

TUBINO, D. F. *Planejamento e controle da produção: teoria e prática*. 3. ed. São Paulo: Atlas, 2017. ISBN 978-85-97-01023-7.

VENANZI, D.; SILVA, O. R. da. *Introdução à Engenharia de Produção: Conceitos e Casos Práticos*. Rio de Janeiro: LTC, 2016. ISBN 9788521631002. Disponível em: <<https://integrada.minhabiblioteca.com.br/reader/books/9788521631002/>>. Acesso em: 01 jan. 2026.

VIANA, J. J. *Administração de Materiais: Um Enfoque Prático*. 1ª, 6ª reimpressão. ed. São Paulo: Editora Atlas S.A., 2006. ISBN 85-224-2395-4.

Anexos

Todos os anexos deste trabalho encontram-se em um repositório público no GitHub, que pode ser acessado em: <https://github.com/Oclayon/monografia-clayon>