



LÉCIO DAVID
PEREIRA

FRAMEWORK PARA A REDUÇÃO DE INVENTÁRIO NUMA EMPRESA FARMACÊUTICA

Relatório de projeto de investigação do Mestrado em
Logística e Gestão da Cadeia de Abastecimento

ORIENTADOR

Professor João Catarino

31 outubro 2025

Dedicatória

Ao meu pai, Valdemar Pereira, que, mesmo não estando fisicamente presente, continua a ser a minha maior inspiração.

Agradeço por cada ensinamento, pelo amor incondicional e pelos valores que me transmitiu. A sua força, dedicação e exemplo de vida foram fundamentais para que eu chegasse até aqui. Ainda que a saudade seja imensa, carrego comigo tudo o que me ensinou e dedico-lhe esta conquista, que também é sua.

Onde quer que esteja, espero que se orgulhe de mim.

Agradecimentos

A minha esposa Sofia por toda a sua paciência e apoio nesta jornada, sem ela nunca teria conseguido.

Aos meus filhos Manuel, Maria Clara e Francisco por serem uma fonte de motivação constante.

A minha mãe por estar sempre presente ao longo de toda a minha vida.

Aos meus sogros Anabela e António, pelo suporte e dedicação à minha família.

Sem todos eles teria sido uma tarefa impossível.

Resumo

A gestão de inventário desempenha um papel crítico na eficiência logística e financeira das empresas. O setor farmacêutico não é uma exceção, dado o seu carácter extremamente regulado, sensível ao tempo e com produtos de elevado valor.

Segundo Ahmadi et al. (2022), “As despesas globais com cuidados de saúde representaram cerca de 9,8% do PIB mundial em 2019, atingindo 8,5 biliões de dólares. Os medicamentos representam aproximadamente 10 a 30% das despesas globais com saúde (McKone-Sweet et al., 2005), sendo que uma parte significativa destes medicamentos é perdida devido à má gestão de inventário e logística (Boerma et al., 2009).” (p.1 (*Tradução livre do original em inglês.*))

Este trabalho tem como objetivo apresentar um *framework* (modelo) de melhorias no processo de gestão de inventário de uma empresa farmacêutica, com vista à redução de ineficiências, aumento da visibilidade operacional e otimização dos níveis de inventário.

A investigação segue uma abordagem de estudo de caso, envolvendo a recolha de dados, análise documental e questionários aplicados a colaboradores-chave da organização.

Através dos dados recolhidos, foram identificados os principais desafios enfrentados pela empresa, como previsões imprecisas, excesso ou falta de inventário de segurança e dificuldades de integração entre sistemas. Com base nos resultados, é apresentada uma proposta de melhoria fundamentada em boas práticas logísticas, Key Performance Indicator (KPI) e apoio de modelos estatísticos de previsão robustos, como Autoregressive Integrated Moving Average (ARIMA), Holt-Winters e Prophet.

A proposta visa não só a eficiência operacional, mas também a conformidade regulatória. Este estudo contribui para o conhecimento aplicado da gestão de inventário no setor farmacêutico e oferece uma base prática para futuras intervenções organizacionais.

Palavras-chave: Inventário, modelos estatísticos, eficiência, redução de custos

Abstract

Inventory management plays a critical role in ensuring the logistical and financial efficiency of companies. The pharmaceutical sector is no exception, given its highly regulated nature, time sensitivity, and the high value of its products.

According to Ahmadi et al. (2022), “Global healthcare expenditures accounted for around 9.8% of the world’s GDP in 2019, reaching \$8.5 trillion. Medicines represent approximately 10 to 30% of global healthcare expenditures (McKone-Sweet et al., 2005), while a significant portion of these medicines is lost due to poor inventory and logistics management (Boerma et al., 2009).” (p.1, free translation from the original in English).

The purpose of this study is to present a framework for improving the inventory management process of a pharmaceutical company, aiming at reducing inefficiencies, enhancing operational visibility, and optimizing inventory levels.

The research adopts a case study approach, involving data collection, document analysis, and questionnaires administered to key organizational stakeholders. Based on the data collected, the main challenges faced by the company were identified, such as inaccurate forecasts, excess or shortage of safety inventory, and difficulties in system integration. From these findings, an improvement proposal is presented, grounded in logistics best practices, Key Performance Indicators (KPI), and supported by robust statistical forecasting models such as Autoregressive Integrated Moving Average (ARIMA), Holt-Winters, and Prophet.

The proposal aims not only at operational efficiency but also at regulatory compliance. This study contributes to applied knowledge in inventory management within the pharmaceutical sector and provides a practical foundation for future organizational interventions.

Keywords: Inventory, statistical models, efficiency, cost reduction

Índice

Dedicatória	i
Agradecimentos	ii
Resumo.....	iii
Palavras-chave:	iii
Abstract.....	iv
Keywords:.....	iv
Índice de figuras.....	vii
Índice de gráficos	vii
Índice de tabelas	vii
Lista de abreviaturas	viii
1. Introdução.....	1
1.1. Enquadramento do tema.....	1
1.2. Problema de investigação	2
1.3. Objetivos da investigação	2
1.4. Questões de Investigação.....	2
1.5. Relevância do Estudo	3
1.6. Estrutura do projeto.....	3
2. Revisão da literatura	4
2.1. Gestão de Inventário: Conceitos Fundamentais.....	4
2.2. Inventário no Setor Farmacêutico	5
2.3. Desafios Atuais da Gestão de Inventário	6
2.4. Boas Práticas e Modelos de Otimização	6
2.5. Modelos Estatísticos Avançados de Previsão na Gestão de Inventário.....	7
2.5.1. Modelos Clássicos: ARIMA e Holt-Winters.....	8
2.5.2. Modelos Emergentes: Prophet e Híbridos	8
2.5.3. Aplicações em Inventário Farmacêutico	8
2.6. Síntese da Fundamentação	8
3. Metodologia	9
3.1. Natureza e Abordagem	9
3.2. Técnicas de Recolha de Dados.....	9
3.3. Indicadores em análise	10
3.4. Limitações do Estudo	10
3.5. Validação da Proposta	10
3.6. Síntese da Metodologia.....	11
4. Diagnóstico e Resultados	12
4.1. Diagnóstico	12
4.1.1 Perceções relativas aos questionários aplicados a membros da equipa	12

4.2.	Análise detalhada dos indicadores	15
4.2.1.	Análises ABC e ABC-XYZ	15
4.2.2	Análise MAPE	16
4.2.3	Análise inventário de Segurança em Dias	17
4.2.4	Percentagem de Caducidade	19
4.2.5	Custo de Inventário em relação à faturação anual	20
4.2.6	Rotação de inventário	21
4.2.7	Síntese Global dos Indicadores.....	22
5.	Framework e Validação	23
5.1	Modelos selecionados para o projeto piloto.....	24
5.2	Previsão da procura (Excel vs ARIMA/Holt-Winters/Prophet).....	25
5.2.1.	Parametrização e Afinação dos Modelos	28
5.2	Parametrização de Inventário.....	29
5.3	Processos Colaborativos (S&OP)	31
5.4	Monitorização Contínua por KPI.....	33
5.5	Piloto e Validação (“Antes vs Depois”)	34
6.	Conclusões, Recomendações, Limitações e Futuro	35
6.1	Conclusões	35
6.2	Recomendações	36
6.3	Limitações do estudo	37
6.4	Trabalhos futuros	37
7.	Bibliografia	39
8.	Anexos	44
	Anexo 1 – Questionários	45
	Anexo 2 – Formulário.....	51
	Anexo 3 – Equações Matemáticas dos Modelos	52
	Anexo 4 – Código Python utilizado para calculo dos modelos	53
	Anexo 5 – Vendas reais	64
	Anexo 6 – Política Stock Segurança	66
	Anexo 7 – Definição de Classes ABC-XYZ	67
	Anexo 8 – Resultados por SKU’s.....	68

Índice de figuras

Figura 1 – Fluxograma da Metodologia

Figura 2 – Problemas Detetados na Gestão de Inventário

Figura 3 – Síntese Global dos Indicadores

Índice de gráficos

Gráfico 1 – Avaliação da Gestão de Inventário (colaborador sénior)

Gráfico 2 – Avaliação da Gestão de Inventário (colaborador operacional)

Gráfico 3 – Resultado entre os vários modelos estatísticos

Gráfico 4 – Resultado do SKU 5000643

Gráfico 5 – Resultado do SKU 5002078

Índice de tabelas

Tabela 1 – Segmentação ABC-XYZ

Tabela 2 – Resultados da análise do MAPE por classe

Tabela 3 – Resultados em valor do SS atual e atualizado para 100 dias

Tabela 4 – Resultados Inventário Segurança

Tabela 5 – Resultados Valor Caducidades

Tabela 6 – Resultado Custo do Inventário em relação à faturação anual

Tabela 7 – Resultado Rotação Inventário

Tabela 8 – Resultado entre os vários modelos estatísticos

Tabela 9 – Resultados Classe ABC_XYZ

Tabela 10 – Resultado Inventário Segurança

Tabela 11 – Resultado Matriz RACI

Tabela 12 – Resultado Atual VS Proposto

Lista de abreviaturas

TE – Tecnologias emergentes

KPI – Key Performance Indicator

MRP – Material Requirements Planning

IoT – Internet of Things

MAPE – Mean Absolute Percentage Error

ETS – Exponential Smoothing (Holt-Winters)

ARIMA – Autoregressive Integrated Moving Average

DRP – Distribution Requirements Planning

GDP – Good Distribution Practice

ERP – Enterprise Resource Planning

MOQ – Minim Order Quantity

WMS – Warehouse Management System

JIT– Just in Time

FIFO – First In First Out

COGS - Cost of Goods Sold

S&OP – Sales and Operations Planning

SAP – System Analysis Program Development

SS – Stock de Segurança

IBP – Integrated Business Planning

LSTM – Long Short-Term Memory

1. Introdução

1.1. Enquadramento do tema

Num contexto empresarial marcado por elevada competitividade, inovação constante e rigor regulatório, a otimização de inventário torna-se essencial para garantir a sustentabilidade e a performance organizacional. No setor farmacêutico, estas exigências são particularmente acentuadas, dada a natureza sensível dos produtos, a complexidade dos fluxos e de altos níveis de serviço. Nesse cenário, a empresa X_Farma enfrenta o desafio de modernizar a sua gestão de inventário para se alinhar com as melhores práticas do setor e manter a sua posição competitiva face aos principais concorrentes.

A crescente pressão do mercado, impulsionada pela procura de novos produtos e materiais, exige níveis crescentes de eficiência operacional, visibilidade de processos e controlo rigoroso de custos.

Os custos associados à cadeia de abastecimento representam uma parcela significativa do orçamento das organizações, sendo o inventário um dos elementos com maior impacto financeiro. No caso da X_Farma, os custos de inventário representam aproximadamente 20% do volume de faturação anual, o que o torna um fator estratégico para a sustentabilidade do negócio.

Reduzir níveis de inventário sem comprometer a qualidade do serviço é um dos grandes desafios da gestão moderna. Para tal, é necessário adotar novas abordagens que superem os limites dos sistemas manuais atualmente utilizados. Assim, este trabalho propõe o desenvolvimento de um *framework*, com vista à melhoria da tomada de decisão e da eficiência operacional na gestão de inventário.

A presente investigação adota a metodologia de estudo de caso como quadro metodológico central, direcionando a análise para a especificidade organizacional da empresa selecionada e visando ao delineamento de uma solução prática e aplicável ao contexto real. Com esta abordagem, pretende-se promover uma melhoria substancial no desempenho do sistema de gestão de inventário da organização

1.2. Problema de investigação

Apesar dos investimentos financeiros e tempo que se tem aplicado nos últimos anos em controlo de inventário e melhorias operacionais, a X_Farma continua a apresentar níveis de inventário acima do desejável, representando cerca de 20% da sua faturação anual. A previsão de procura pouco precisa, aliada à falta de integração entre sistemas e departamentos, contribui para excesso de inventário, rutura de produtos críticos e desperdício por caducidade.

O problema central consiste em compreender como a empresa pode melhorar a eficiência do seu processo de gestão.

1.3. Objetivos da investigação

Objetivo Geral:

- Avaliar o impacto financeiro e logístico do excesso de inventário numa empresa farmacêutica e propor um *framework* de melhoria orientado para a redução de ineficiências e otimização do processo de gestão de inventário.

Objetivos Específicos:

- Identificar os principais fatores que contribuem para o excesso de inventário na empresa;
- Analisar as limitações dos sistemas atuais de previsão da procura e gestão de inventário;
- Avaliar o potencial de aplicação de modelos estatísticos robustos de previsão, como ARIMA, Holt-Winters e Prophet;
- Propor um *framework* estruturado para melhoria da gestão de inventário;
- Avaliar o potencial impacto deste *framework* em termos de eficiência operacional, custos.

1.4. Questões de Investigação

A questão central do projeto está assente na redução de inventário sem comprometer o nível de serviço. Sendo a resposta a esta questão desdobra-se em várias sub-perguntas.

Tais como:

- Quais são os principais fatores que contribuem para o excesso de inventário da empresa?
- A forma de previsão atual influencia os níveis de inventário?
- É possível reduzir o inventário mantendo os níveis de serviço?

- Que indicadores devem ser monitorizados para avaliar a eficácia da estratégia de redução de inventário?

1.5. Relevância do Estudo

O presente trabalho reveste-se de importância a dois níveis:

1. Académico: contribui para o avanço do conhecimento aplicado em gestão de inventário no setor farmacêutico, um contexto ainda pouco explorado em termos de integração entre práticas logísticas tradicionais e metodologias estatísticas avançadas de previsão.
2. Prático: fornece uma proposta metodológica robusta e aplicável em ambiente organizacional real, permitindo às empresas melhorar a eficiência logística, reduzir custos associados ao excesso de inventário, aumentar a resiliência da cadeia de abastecimento e garantir níveis de serviço adequados.

1.6. Estrutura do projeto

A organização do trabalho é criada com o seguinte racional:

Capítulo 1; Introdução: apresenta o enquadramento, problema, objetivos e relevância do estudo.

Capítulo 2; Revisão da Literatura: conceitos-chave como gestão de inventário, previsão de procura e KPI.

Capítulo 3; Metodologia: descreve o tipo de estudo, instrumentos de recolha de dados, amostra e técnicas de análise.

Capítulo 4; Diagnóstico e Resultados: apresenta os dados recolhidos.

Capítulo 5; Validação do *Framework*: Apresenta os cinco pilares para melhoria e aplicação do *Framework*.

Capítulo 6; Conclusões, Recomendações, Limitações e Futuro; Resume as principais orientações, limitações do estudo e propostas para investigações futuras.

2. Revisão da literatura

A presente revisão de literatura tem como objetivo explorar os principais conceitos, abordagens e tecnologias relacionadas à gestão de inventários no setor farmacêutico. Procurando identificar contribuições teóricas e práticas relevantes.

2.1. Gestão de Inventário: Conceitos Fundamentais

A gestão de inventário é um dos pilares centrais da logística e do *supply chain management*, com impacto direto na eficiência operacional e financeira das organizações. De acordo com Ballou (2006), o inventário representa não apenas um conjunto de bens armazenados, mas também uma estratégia essencial para equilibrar a oferta e a procura, apoiar processos produtivos e assegurar continuidade nos níveis de serviço.

O grande desafio desta gestão reside no *trade-off* entre os custos de posse de inventário e o risco de rutura no abastecimento (Chopra & Meindl, 2019). Custos de armazenagem, caducidade e capital bloqueado devem ser meticulosamente ponderados face às exigências de disponibilidade imediata e fiabilidade de entrega.

Historicamente, a gestão de inventário tem sido suportada por modelos determinísticos clássicos, como o EOQ (Economic Order Quantity), que define a quantidade ótima de encomenda ao minimizar o somatório dos custos de posse e de encomenda (Silver, Pyke & Peterson, 1998). Outro modelo amplamente utilizado é o Ponto de Encomenda (Reorder Point – ROP), que determina o momento exato de reposição com base no consumo médio e no tempo de entrega (*lead time*), frequentemente associado ao stock de segurança (SS) para compensar incertezas na procura (Ballou, 2006).

Com a evolução das cadeias de abastecimento, surgiram modelos mais integrados, como o MRP (Material Requirements Planning), que planeia as necessidades de materiais a partir de planos de produção, e o DRP (Distribution Requirements Planning), voltado para a distribuição física e gestão de inventário em múltiplos níveis da cadeia (Zipkin, 2000; Axsäter, 2015). Estes sistemas foram fundamentais para alinhar os níveis de inventário com a procura real, especialmente em ambientes industriais.

Paralelamente, abordagens como o JIT (Just in Time) e o *Lean Management* procuram eliminar desperdícios, reduzindo o inventário ao mínimo necessário e promovendo fluxos contínuos de materiais (Heizer, Render & Munson, 2017). Contudo, estas práticas exigem cadeias altamente estáveis e previsíveis, o que raramente se verifica no setor farmacêutico, caracterizado por elevada variabilidade de procura, rigor regulatório e restrições de validade dos produtos.

Face a esta incerteza, modelos probabilísticos de inventário de segurança passaram a ser aplicados para ajustar os níveis de inventário ao nível de serviço pretendido, através de parâmetros estatísticos como o desvio padrão da procura e o coeficiente z da distribuição normal (Axsäter, 2015; Ballou, 2006). Estes modelos permitem calcular o stock adicional necessário para garantir a cobertura da procura durante o lead time, equilibrando o risco de rutura e o custo de posse.

Mais recentemente, com o avanço da digitalização e do *Business Intelligence*, a gestão de inventário evoluiu para uma vertente analítica e preditiva, apoiada em modelos estatísticos e probabilísticos de previsão da procura, como o ARIMA (Autoregressive Integrated Moving Average), o Holt-Winters (Exponential Smoothing – ETS) e o Prophet, amplamente reconhecidos pela sua robustez na análise de séries temporais (Box et al., 2015; Hyndman & Athanasopoulos, 2018; Rodríguez González et al., 2021). Estes modelos permitem antecipar flutuações sazonais e tendências, otimizando decisões de reabastecimento e reduzindo o risco de excesso ou falta de stock.

A literatura recente também aponta para o surgimento de modelos híbridos e baseados em inteligência artificial, como o ARIMA-LSTM (Long Short-Term Memory), que combinam a capacidade de modelar componentes lineares e não lineares das séries temporais, aumentando a precisão das previsões (Mbonyinshuti et al., 2024). Tais ferramentas são particularmente úteis em contextos complexos, como o farmacêutico, onde a variabilidade da procura é elevada e as consequências de falhas no abastecimento são críticas.

2.2. Inventário no Setor Farmacêutico

A gestão de inventário no setor farmacêutico enfrenta especificidades que a distinguem de outros setores industriais. Os produtos normalmente apresentam valor monetário elevado, prazos de validade rigorosos e condições restritas de conservação, frequentemente dependentes da cadeia de frio, estando ainda sujeitos a uma regulamentação com forte incidência na rastreabilidade e no cumprimento das GDP (Good Distribution Practice) (Shah, 2004).

Estudos indicam que ruturas de inventário em medicamentos críticos têm consequências diretas para a prestação de cuidados de saúde, comprometendo não apenas a eficiência logística, mas também a saúde pública e a reputação empresarial (Allenet & Barry, 2015). Por outro lado, o excesso de inventário conduz a riscos de caducidade precoce e custos acrescidos de armazenagem (Srirangam & Banerjee, 2018).

A combinação destes fatores exige soluções robustas, orientadas não apenas para a eficiência operacional, mas igualmente para a conformidade regulatória e a sustentabilidade das cadeias de abastecimento farmacêuticas.

2.3. Desafios Atuais da Gestão de Inventário

Apesar das ferramentas consolidadas, persistem dificuldades práticas que limitam o desempenho da gestão de inventário. Segundo Christopher (2016), previsões imprecisas da procura continuam a ser uma das causas mais recorrentes de excesso ou falta de inventário. Particularmente na indústria farmacêutica, a procura pode ser influenciada por surtos epidemiológicos, variações sazonais e introdução de novos tratamentos, aumentando a complexidade do processo de planeamento (Reddy & Ranganath, 2019).

Adicionalmente, a falta de integração entre sistemas, frequentemente fragmentados entre ERP (Enterprise Resource Planning), WMS (Warehouse Management System) e plataformas complementares, compromete a visibilidade ponta-a-ponta da cadeia de abastecimento (Ivanov, 2020). Estes fatores resultam frequentemente em desequilíbrios entre inventário excessivo e ruturas pontuais em produtos críticos, refletindo falhas de coordenação e insuficiência das metodologias tradicionais.

2.4. Boas Práticas e Modelos de Otimização

A literatura recente destaca que a gestão de inventário eficaz não depende apenas de técnicas tradicionais de reposição, mas de um conjunto de boas práticas integradas que combinam planeamento, tecnologia e análise de dados. As empresas mais eficientes adotam abordagens que permitem equilibrar custos, disponibilidade e risco operacional, transformando o inventário num elemento estratégico de competitividade.

Entre as práticas mais consolidadas encontra-se o planeamento integrado de materiais e distribuição, suportado por sistemas como o MRP e o DRP, que asseguram a sincronização entre produção, compras e distribuição. Estas ferramentas permitem ajustar os níveis de stock às necessidades reais, reduzindo simultaneamente ruturas e excesso de inventário (Zipkin, 2000; Axsäter, 2015).

Outro conjunto de práticas amplamente difundido são as filosofias Lean e Just in Time (JIT), centradas na eliminação de desperdícios e na eficiência contínua dos fluxos logísticos (Heizer, Render & Munson, 2017). Embora nem sempre plenamente aplicáveis em contextos farmacêuticos — devido a exigências regulatórias e variabilidade da procura —, princípios como a redução de lead times, a padronização de processos e o controlo visual do inventário são altamente recomendáveis.

A utilização de indicadores de desempenho (KPI) também é reconhecida como uma boa prática essencial para suportar decisões baseadas em evidência. Indicadores como rotação de inventário, nível de serviço, taxa de caducidade e custo de posse permitem monitorizar a

eficácia das políticas adotadas e promover ciclos de melhoria contínua (Chopra & Meindl, 2019).

Mais recentemente, as boas práticas de otimização têm evoluído para incorporar o uso de modelos quantitativos e analíticos. Ferramentas baseadas em simulação, análise preditiva e algoritmos de otimização possibilitam ajustar parâmetros de inventário de forma dinâmica, considerando variações sazonais, incertezas na procura e restrições logísticas (Hyndman & Athanasopoulos, 2018).

No setor farmacêutico, estas práticas são particularmente valiosas, pois permitem reduzir o risco de caducidade, garantir rastreabilidade e melhorar o planeamento do stock de segurança. Assim, a integração entre boas práticas operacionais, monitorização por KPI e modelos analíticos avançados constitui o alicerce de uma gestão de inventário moderna, orientada para a eficiência, a conformidade e a sustentabilidade.

2.5. Modelos Estatísticos Avançados de Previsão na Gestão de Inventário

O avanço da digitalização, tecnologias emergentes assumem um papel cada vez mais influente na gestão de inventário. Soluções de *Business Intelligence* e *Big Data* têm sido exploradas para criação de dados históricos e reconhecimento de padrões de consumo em grande escala (Choi, 2020).

Particular atenção tem sido dada à aplicação de modelos estatísticos de previsão, como ARIMA, Holt-Winters e Prophet, amplamente usados pela sua robustez em séries temporais. Estas ferramentas revelam elevado potencial para previsões de procura, ajuste dinâmico de parâmetros de inventário e otimização de políticas de abastecimento. Estudos recentes reforçam que modelos estatísticos avançados permitem capturar padrões de sazonalidade e tendência de forma eficaz, oferecendo previsões mais consistentes em séries temporais de curta e média duração (Syntetos, Boylan & Disney, 2009).

A integração de sistemas ERP avançados, soluções de IoT (Internet of Things) para monitorização em tempo real e plataformas colaborativas com fornecedores aumentam ainda mais a resiliência das cadeias (Kaur & Singh, 2018; Ivanov, Dolgui & Sokolov, 2019).

Contudo, a literatura também alerta para desafios associados à escolha do modelo adequado e à necessidade de validação contínua, uma vez que a procura pode ser altamente volátil (Choi, 2020).

2.5.1. Modelos Clássicos: ARIMA e Holt-Winters

O modelo ARIMA é amplamente utilizado pela sua abordagem probabilística e versatilidade. Rodríguez González et al. (2021) aplicaram ARIMA $(0,1,1) \times (0,1,1)_{12}$ na previsão de procura de medicamentos, combinando dados epidemiológicos para um ajuste mais preciso.

Rathipriya et al. (2022) reforça que ARIMA é um modelo de referência, embora limitado em contextos de rutura estrutural.

Já o método Holt-Winters é preferido para séries com forte sazonalidade. Dogan et al. (2025) demonstraram que Holt-Winters obtém os erros mais baixos (MAE, RMSE, MAPE) em inventários de empresas de retalho, superando ARIMA e Prophet.

Waheed et al. (2024) também observou a vantagem de Holt-Winters sobre Prophet em séries com sazonalidade pronunciada.

2.5.2. Modelos Emergentes: Prophet e Híbridos

O modelo Prophet, desenvolvido pelo Facebook, apresenta elevada robustez a falhas de dados e mudanças abruptas de tendência. Siddiqui et al. (2022) propõem um modelo híbrido de previsão para o setor farmacêutico, integrando técnicas estatísticas e machine learning, melhorando a previsão em relação a modelos isolados.

Combinações de ARIMA e LSTM (Long Short-Term Memory) também demonstra bons resultados (Mbonyinshuti et al., 2024), analisa componentes lineares e não lineares.

2.5.3. Aplicações em Inventário Farmacêutico

Estudos comparativos, como Ersoz et al. (2022), validam a aplicabilidade dos modelos ARIMA, Holt-Winters e Prophet em contextos reais, demonstrando desempenho variável conforme a natureza da série.

Em cadeias de abastecimento hospitalares, Mbonyinshuti et al. (2024) confirmaram a utilidade do ARIMA na previsão de consumo de medicamentos, enquanto Holt-Winters apresentou melhor ajuste em padrões sazonais.

2.6. Síntese da Fundamentação

A revisão da literatura revela que, embora existam modelos e boas práticas consolidadas para a gestão de inventário, persistem limitações críticas relacionadas com previsões imprecisas, roturas e excesso de inventário. No setor farmacêutico, estas limitações são ampliadas pela elevada regulação, pela criticidade dos produtos e pela variabilidade da procura.

Os modelos estatísticos de previsão, surgem como potenciadores de mudança capazes de suportar *frameworks* inovadores, que conciliem eficiência logística, conformidade regulatória e qualidade do serviço. Nesse sentido, este trabalho posiciona-se para propor um *framework* integrado, direcionado à realidade farmacêutica, como ferramenta prática e cientificamente fundamentada para a redução do inventário sem comprometer o nível de serviço.

3. Metodologia

Este projeto segue uma abordagem qualitativa, exploratória e aplicada, utilizando a metodologia de estudo de caso único, centrado na realidade da empresa farmacêutica X_Farma.

O estudo de caso é apropriado quando se pretende analisar uma situação real e complexa, dentro do seu contexto organizacional, permitindo observar em profundidade fenómenos como a ineficiência do inventário e os seus impactos logísticos e financeiros (Yin, 2018).

3.1. Natureza e Abordagem

A escolha de um estudo de caso justifica-se pelos seguintes motivos:

Permite uma análise detalhada da realidade organizacional, incluindo cultura, processos e limitações práticas;

Oferece flexibilidade para recolher e integrar dados quantitativos (relatórios de inventário, KPI) e qualitativos (percepções dos colaboradores).

3.2. Técnicas de Recolha de Dados

Foram utilizadas três técnicas principais:

1. Análise documental

- Relatórios de inventário, relatórios financeiros, registos de rotatividade de inventário, históricos de vendas;
- Políticas de inventário de segurança, impactos financeiros do excesso de armazenagem e ruturas de inventário;

2. Questionários

- Aplicados a colaboradores-chave das áreas de logística, compras e planeamento;
- Objetivo: identificar percepções sobre causas do excesso de inventário, limitações atuais, práticas utilizadas e abertura para inovação tecnológica;

3. Observação direta

- Observação dos fluxos de entrada e saída e controlo de inventário físicos.

3.3. Indicadores em análise

A investigação avalia os fatores críticos através de indicadores financeiros e logísticos.

As principais métricas em observação:

- MAPE (Mean Absolute Percentage Error);
- Stock de Segurança;
- Rotação de Inventário;
- Percentagem de Caducidade;

3.4. Limitações do Estudo

Algumas limitações são reconhecidas:

- O estudo foi realizado numa única empresa, o que limita a possibilidade de generalização;
- O número de participantes é reduzido, apesar de todos serem diretamente relevantes para o tema;
- Tempo de análise circunscrita a um horizonte temporal limitado de 12 meses;
- A adoção de tecnologias emergentes enfrenta barreiras humanas e organizacionais que podem condicionar resultados;

3.5. Validação da Proposta


O *framework* proposto será avaliado em termos de viabilidade e validade através de:

- Comparação Antes vs. Depois: análise de KPI históricos (MAPE 43%, 120-150 dias de cobertura, 20-22% inventário/faturação) e metas estabelecidas ($\leq 15\%$ MAPE, 100 dias de cobertura, 15% inventário/faturação).
- Simulação Piloto: aplicação do *framework* a uma família de produtos (top 10 SKUs A), avaliando os ganhos esperados

3.6. Síntese da Metodologia

- A investigação recorre a uma abordagem mista, assente numa análise em profundidade da realidade de uma empresa farmacêutica. A triangulação de dados qualitativos e quantitativos pretende fornecer robustez à análise, ao mesmo tempo que assegura uma ligação pragmática entre os desafios identificados e a proposta de *framework* para redução do inventário.

Figura 1 – Fluxograma da Metodologia



Fonte: Elaboração própria

4. Diagnóstico e Resultados

4.1. Diagnóstico

As causas e consequências associadas ao excesso de inventário e às ruturas por falta de produtos são variadas. A seguinte tabela demonstra os problemas identificados.

Figura 2 – Problemas Detetados na Gestão de Inventário

	1	2	3
	Identificação do problema	Impacto	Fonte de verificação
 Planeamento	Previsões MAPE > 43%	Excesso de stock em produtos	Relatórios Forecast vs Real
 Compras	MOQ elevados em fornecedores críticos	Aumento do stock de segurança	ERP + Entrevistas
 Logística	Falta de controlo do FIFO	Aumento de produtos caducados	ERP + Relatório Excel
 Dados	Dados mestres desatualizados	Reposições erradas no MRP	Checklist Master Data

Fonte: Elaboração própria

4.1.1 Perceções relativas aos questionários aplicados a membros da equipa


Questionário 1:

A análise das respostas de um colaborador sénior da área de planeamento, com mais de seis anos de experiência e responsável pelo departamento de Logística e Compras, permitiu identificar pontos fortes e fragilidades no processo de gestão de inventário da organização. O colaborador considera as previsões de compras razoavelmente precisas, mas aponta limitações relevantes como dados de vendas inconsistentes, previsões pouco fiáveis, lead times longos e variáveis e dificuldades de comunicação interdepartamental. Apesar de considerar a comunicação interna satisfatória, refere que a colaboração com as áreas de vendas e marketing ocorre apenas ocasionalmente e defende a implementação de um processo estruturado de S&OP (*Sales and Operations Planning*) para alinhar o planeamento de inventário com os objetivos estratégicos.

Foi ainda mencionada satisfação com as ferramentas tecnológicas em uso ERP (Enterprise Resource Planning) e reconhecida a existência de práticas proativas de monitorização de KPI, como ruturas de inventário e volume de inventário face aos custos de vendas. Como prioridades de melhoria, destacou o reforço da integração com a área comercial e o acesso atempado a dados de mercado para antecipar flutuações da procura.

A perceção do colaborador está alinhada com a literatura, que associa a eficácia da gestão de inventário à qualidade dos dados, à redução da variabilidade do lead times e à colaboração interdepartamental (Chopra & Meindl, 2021; Cachon & Terwiesch, 2019; Lapide, 2005).

Gráfico 1 – Avaliação da Gestão de Inventário (colaborador sénior)



Fonte: Elaboração própria

Questionário 2;


A análise das respostas de um colaborador com experiência operacional permitiu identificar limitações relevantes na gestão de inventário da organização. O colaborador refere que a comunicação interna é razoável, mas que a colaboração com áreas como vendas e marketing é esporádica e não estruturada. Este desalinhamento afeta a precisão das previsões,

consideradas apenas moderadamente fiáveis, devido à ausência de processos formais como o S&OP e à falta de acesso atempado a dados do mercado.

Apesar de reconhecer a existência de algumas práticas proativas, como o acompanhamento de indicadores básicos, o diagnóstico revela dificuldades na integração comercial, na fiabilidade dos dados e na antecipação de necessidades. Em contraste, é evidente satisfação com as ferramentas tecnológicas utilizadas, como SAP e Excel, consideradas adequadas ao contexto atual, mas insuficientes para suportar decisões estratégicas de médio prazo.

A perceção do colaborador confirma os desafios identificados nos dados quantitativos e está alinhada com a literatura, que associa a eficácia da gestão de inventário à colaboração interfuncional, à qualidade da informação e à capacidade de resposta à procura (Christopher, 2016; Heizer, Render & Munson, 2020; Coyle et al., 2017).

Gráfico 2 – Avaliação da Gestão de Inventário (colaborador operacional)



Fonte: Elaboração própria

4.2. Análise detalhada dos indicadores

4.2.1. Análises ABC e ABC-XYZ

A classificação ABC é uma técnica amplamente utilizada na gestão de inventário para hierarquizar os produtos de acordo com a sua importância económica. Baseia-se no princípio de Pareto (80/20), segundo o qual uma pequena percentagem dos itens representa a maior parte do valor total movimentado.

Esta análise permite segmentar os produtos em três categorias principais:

- Classe A – artigos de maior valor e criticidade, que normalmente correspondem a 10 % a 20 % do total de SKU, mas representam 70 % a 80 % do valor total do inventário.
- Classe B – produtos de valor intermédio, que representam cerca de 30 % a 40 % dos SKU e 15 % a 25 % do valor total.
- Classe C – artigos de baixo valor, geralmente mais de 50 % dos SKU, mas com apenas 5 % a 10 % de participação no valor global.

Esta segmentação permite priorizar recursos de planeamento, previsão e controlo sobre os itens de maior impacto financeiro (Classe A), enquanto os de menor valor podem ser geridos com políticas mais simples e ciclos de revisão mais longos (Ballou, 2006; Chopra & Meindl, 2019).

Contudo, a análise ABC, por si só, não considera a variabilidade da procura. Para colmatar essa limitação, é comum combiná-la com a análise XYZ, que classifica os produtos de acordo com a previsibilidade e estabilidade da procura, normalmente calculada pelo coeficiente de variação (CV):

- Classe X – produtos com procura estável e previsível ($CV \leq 0,25$);
- Classe Y – produtos com procura moderadamente variável ($0,25 < CV \leq 0,50$);
- Classe Z – produtos com procura irregular ou intermitente ($CV > 0,50$).

A combinação das duas análises origina a matriz ABC-XYZ, que fornece uma perspetiva integrada da importância económica e da estabilidade da procura de cada produto. Esta abordagem possibilita a definição de políticas diferenciadas de stock e previsão, conforme o perfil de cada segmento:

Tabela 1– Segmentação ABC-XYZ

Segmento	Características	Política recomendada
AX / AY	Alto valor e procura estável	Elevado nível de serviço; revisão contínua e previsão detalhada
AZ	Alto valor e procura irregular	Reposição sob pedido; monitorização frequente
BX / BY	Valor médio; procura previsível ou moderada	Políticas híbridas; revisão periódica
BZ / CZ	Baixo valor; procura irregular	Stocks mínimos; reposição eventual

Fonte: Elaboração própria

4.2.2 Análise MAPE

No que respeita à análise quantitativa da precisão, observou-se que o MAPE médio do portefólio é de 43% (amostra de 253 SKU's), Segundo Lewis (1982, p. 40), valores de MAPE inferiores a 10% indicam elevada precisão, entre 10% e 20% boa precisão, entre 20% e 50% precisão razoável e superiores a 50% baixa precisão. A desagregação por classes ABC evidencia diferenças relevantes de desempenho:

- Classe A – apresenta um MAPE médio de 37%. Este resultado demonstra que, mesmo nos produtos de maior valor, existem falhas significativas na previsão que impactam diretamente a eficiência da gestão de inventário.
- Classe B – regista um MAPE médio de 43%, em linha com a média global. Sendo produtos de valor intermédio, o impacto financeiro é relevante e deve ser considerado nas políticas de reposição.
- Classe C – apresenta um MAPE médio de 62%, o mais elevado entre as classes. Apesar do impacto financeiro ser menor, a baixa previsibilidade destes produtos contribui para ineficiências, excesso de inventário e risco de caducidade.

Tabela 2– Resultados da análise do MAPE por classe

Classes	Média MAPE
A	37%
B	43%
C	62%
Grand Total	43%

Nota: Amostra 253 SKU's

Fonte: Elaboração própria

Estes resultados confirmam que:

O modelo atual de previsão apresenta elevada variabilidade e baixa precisão, independentemente da classe de produtos.

Os produtos classe A, por representarem maior valor, devem ser priorizados na aplicação do novo *framework*.

A dispersão significativa da classe C indica a necessidade de políticas diferenciadas (ex.: revisão periódica simples ou reposição sob pedido).

Esta análise evidencia a urgência de rever os métodos de previsão e parametrização de inventário, reforçando a relevância da *framework* proposta para reduzir o erro médio e alinhar os níveis de inventário com a procura real.

4.2.3 Análise inventário de Segurança em Dias

A análise do inventário de segurança em dias evidencia uma situação de excesso generalizado de inventário. O valor médio global situa-se em 150 dias de cobertura, muito acima da meta estabelecida (<100 dias). Este resultado confirma que a organização mantém inventário excessivos como forma de compensar a elevada incerteza na previsão da procura, o que representa custos significativos de capital imobilizado e risco acrescido de caducidade.

Tabela 3 – Resultados em valor do SS atual e atualizado para 100 dias

Classes	Média SS (dias)	Média SS (objetivo)	SS em valor (€)	SS em valor (objetivo)
A	154	100	3 460 239,14 €	2 306 826,09 €
B	145	100	709 851,30 €	473 234,20 €
C	144	100	283 908,31 €	189 272,21 €
Grand Total	150	100	4 453 998,74 €	2 969 332,50 €

Nota: Amostra 253 SKU's

Fonte: Elaboração própria

Atualmente, observa-se que, no momento do lançamento, a empresa estabelece um stock de segurança equivalente a cerca de um ano de consumo, como medida preventiva para mitigar incertezas iniciais na procura. Com o amadurecimento do produto no mercado, este nível é gradualmente reduzido, porém nunca abaixo de 120 dias de cobertura, independentemente da previsibilidade ou histórico de vendas. Esta abordagem, embora cautelosa, conduz a níveis de inventário sistematicamente elevados, sem correlação direta com a variabilidade da procura ou o nível de serviço pretendido.

Ao analisar por classes ABC, observa-se que a classe A apresenta o maior nível, com 154 dias de inventário de segurança. Este facto é particularmente crítico, dado que se trata dos produtos de maior valor e impacto financeiro, resultando em maior pressão sobre os recursos da empresa. As classes B e C, embora com valores ligeiramente inferiores (145 e 144 dias, respetivamente), também apresentam níveis insustentáveis para padrões de excelência logística.

Segundo Ballou (2006) e Christopher (2016), a definição de inventário de segurança deve equilibrar os custos de posse com o nível de serviço pretendido. No entanto, o indicador analisado revela que a empresa privilegia níveis excessivos de proteção, não ajustados à variabilidade real da procura. Este desequilíbrio compromete a eficiência financeira, ao mesmo tempo que não elimina as ruturas, já que coexistem com previsões imprecisas (MAPE elevado).

Em síntese, o excesso de inventário de segurança identificado reforça a necessidade de aplicar uma *framework* de otimização baseada na segmentação ABC-XYZ, na parametrização adequada dos níveis Stock de Segurança (SS), e na melhoria da previsão através de ferramentas analíticas avançadas. A redução progressiva para valores próximos da meta

proposta (100 dias) poderá libertar até 33 % do capital imobilizado, reduzir perdas por caducidade e alinhar a operação com as boas práticas internacionais de gestão de inventário.

Tabela 4 – Resultados Inventário Segurança

CLASSE	STOCK SEGURANÇA EM DIAS
A	154
B	145
C	144
Total	150

Nota: Amostra 253 SKU'S

Fonte: Elaboração própria

4.2.4 Percentagem de Caducidade

A análise da percentagem de caducidade ou pré-caducidade (produtos < 180 dias de validade) revela um nível preocupante de ineficiência na gestão de inventário. Em média, 6% do valor do inventário encontra-se em pré-caducidade ou caducado, o que representa aproximadamente 335 mil euros de perdas potenciais anuais. Este valor está significativamente acima das boas práticas internacionais, que recomendam taxas abaixo de 2–3% em setores regulados (Heizer, Render & Munson, 2017).

Tabela 5 – Resultados Valor Caducidades

CLASSE	STATUS	TOTAL VALOR
A	PRECADUCADO OU CADUCADO	163 251,85 €
B	PRECADUCADO OU CADUCADO	103 191,62 €
C	PRECADUCADO OU CADUCADO	68 474,69 €
Total		334 918,16 €

6% Caducidades

Nota: Amostra 253 SKU'S

Fonte: Elaboração própria

A distribuição por classes mostra que o problema não está restrito aos produtos de menor relevância: a classe A, que representa os artigos de maior valor e criticidade, concentra o maior montante (cerca de 163 mil euros). Este facto amplifica o impacto financeiro e demonstra falhas na aplicação de políticas de rotação (FIFO) e na monitorização sistemática da validade residual.

Segundo Allenet & Barry (2015), a caducidade de medicamentos tem consequências que vão além da perda económica, afetando também a segurança do paciente, a reputação da empresa e o cumprimento das Boas Práticas de Distribuição (GDP). Christopher (2016) reforça que inventários elevados e previsões imprecisas estão entre os principais fatores que contribuem para o problema.

Deste modo, a taxa de 6% de caducidade identificada confirma a necessidade de reforçar o controlo da validade residual, implementar dashboards de monitorização contínua e promover uma maior integração entre logística, qualidade e planeamento. A redução progressiva deste indicador permitirá ganhos financeiros, maior conformidade regulatória e sustentabilidade operacional.

4.2.5 Custo de Inventário em relação à faturação anual

A análise do custo de inventário em relação à faturação demonstra que, em média, o inventário representa 20% da faturação anual da empresa. Este valor encontra-se acima das boas práticas de gestão de inventário, onde a literatura recomenda rácios entre 15% e 18% em setores de elevada complexidade logística (Ballou, 2006; Chopra & Meindl, 2019).

Um rácio elevado significa maior capital imobilizado, custos de posse acrescidos (armazenagem, seguros, manutenção e risco de caducidade) e menor flexibilidade financeira para investir em inovação ou expansão comercial.

De acordo com Christopher (2016), o equilíbrio entre disponibilidade de produto e custos financeiros do inventário é um dos principais trade-offs da gestão da cadeia de abastecimento. No setor farmacêutico, este desafio é ainda mais crítico, dada a perecibilidade dos produtos e as exigências regulatórias de armazenamento.

Assim, a redução progressiva do rácio de inventário/faturação para valores próximos da meta proposta ($\leq 15\%$) constitui uma prioridade estratégica para a empresa, permitindo maior eficiência financeira, melhoria dos fluxos de caixa e alinhamento com padrões internacionais de excelência

Tabela 6 – Resultado Custo do Inventário em relação à faturação anual

FATURAÇÃO ANUAL	INVENTÁRIO MÉDIO A 12 MESES	CUSTO DO INVENTÁRIO FASE À FATURAÇÃO
26 710 947,61 €	5 352 931,72 €	20%

Nota Amostra 253 SKU'S

Fonte: Elaboração própria

4.2.6 Rotação de inventário

A rotação de inventário observada demonstra que o inventário médio é renovado apenas 1,45 vezes ao ano, o que evidencia uma utilização pouco eficiente dos recursos disponíveis. Este resultado significa que os produtos permanecem armazenados por períodos prolongados antes de serem consumidos ou expedidos, aumentando o risco de obsolescência e caducidade.

Na literatura, valores reduzidos de rotação estão associados a excesso de inventário, capital imobilizado e custos de posse elevados (Coyle et al., 2017). No setor farmacêutico, onde a validade dos medicamentos é limitada, níveis abaixo de 2 são considerados críticos (Heizer, Render & Munson, 2017).

O valor identificado reforça os sinais já evidenciados por outros indicadores, como o inventário de segurança médio de 150 dias e a taxa de caducidade de 6%. Christopher (2016) sublinha que cadeias de abastecimento eficientes devem encontrar o equilíbrio entre a disponibilidade de produto e a sustentabilidade financeira, algo que este indicador mostra estar desalinhado. Deste modo, torna-se prioritário implementar medidas que permitam aumentar a rotação do inventário, nomeadamente através da melhoria da previsão da procura, ajustamento dos parâmetros de reposição e monitorização contínua da cobertura de inventário.

Tabela 7 – Resultado Rotação Inventário

CONSUMO ANUAL (UN)	INVENTÁRIO MÉDIO (UN)	ROTAÇÃO DO INVENTÁRIO
3 858 326	2 669 224	1,45

Nota: Amostra 253 SKU'S

Fonte: Elaboração própria

4.2.7 Síntese Global dos Indicadores

Os resultados obtidos na análise dos principais KPI confirmam a existência de desequilíbrios significativos na gestão de inventário da X_Farma. A avaliação conjunta dos indicadores evidencia ineficiências tanto na previsão da procura como na definição de políticas de inventário, traduzindo-se em elevados custos de posse, perdas por caducidade e baixa rotação dos produtos.

- MAPE (43%): revela previsões com baixa precisão, especialmente nos produtos de classe C (62%), mas também com impacto relevante nos produtos de maior valor (classe A – 37%).
- Stock de segurança (150 dias): encontra-se muito acima das melhores práticas (<100 dias), refletindo uma política defensiva de inventário elevado, que imobiliza capital e não elimina o risco de ruturas.
- Caducidades (6%): representam perdas anuais significativas (~335 mil €), em particular na classe A, expondo falhas na rotação e monitorização de validade residual.
- Inventário/faturação (20%): supera o intervalo recomendado (15–18%), indicando custos de posse elevados e redução da flexibilidade financeira.
- Rotação (1,45x/ano): confirma a baixa eficiência na utilização do inventário, associada a níveis de inventário excessivos e elevada permanência de produtos em armazém.

No seu conjunto, os indicadores revelam uma política de inventário orientada para o excesso de proteção, mas incapaz de assegurar eficiência logística ou eliminar desperdícios. A coexistência de inventário excessivo, caducidade e previsões imprecisas reforça a necessidade de redefinir as práticas de gestão, através de um *framework* que integre métodos analíticos mais robustos, segmentação adequada e maior colaboração interdepartamental.

Figura 3 – Síntese Global dos Indicadores

	Indicador	Valor Atual	Meta Proposta	Gap Identificado
	MAPE	43%	$\leq 23\%$	Erro elevado de previsão, especialmente nos produtos de menor valor.
	Stock de Segurança (dias)	150 dias	≤ 100 dias	Níveis de inventário muito acima do recomendado, capital imobilizado.
	Percentagem de Caducidade	6% (~335 mil €/ano)	$\leq 3-4\%$	Perdas financeiras relevantes, especialmente em produtos de maior valor.
	Inventário/Faturação	20%	15%	Rácio acima das boas práticas, custos de posse elevados.
	Rotação de Inventário	1,45x/ano	$\geq 2x$ /ano	Baixa renovação do stock, indicando inventário acumulado e pouco dinâmico.

Fonte: Elaboração própria

A tabela apresentada consolida os principais indicadores avaliados e evidencia discrepâncias significativas entre o desempenho atual e as metas propostas. Estes resultados reforçam a urgência de redefinir as práticas de gestão de inventário, criando as bases para a *framework* de melhoria que será apresentada no capítulo seguinte.

5. Framework e Validação

A análise realizada no capítulo anterior demonstrou que a gestão de inventário da X_Farma apresenta fragilidades estruturais, refletidas em previsões imprecisas, níveis excessivos de inventário de segurança, perdas por caducidade, custos de posse elevados e baixa rotação de produtos. A consolidação destes indicadores confirma que a estratégia atual privilegia a acumulação de inventário como forma de proteção, mas sem assegurar eficiência logística ou sustentabilidade financeira.

Face a este diagnóstico, torna-se necessário propor um *framework* estruturado de melhoria, concebido a partir das boas práticas identificadas na literatura e das necessidades específicas da empresa.

O modelo é construído em torno de quatro pilares fundamentais:

1. Previsão da Procura, através da integração de dados e utilização de ferramentas analíticas avançadas;
2. Parametrização de Inventário, com políticas diferenciadas por criticidade e variabilidade;
3. Processos Colaborativos, com destaque para a implementação de S&OP;
4. Monitorização Contínua por KPI, suportando a melhoria contínua.

Nos pontos seguintes, cada pilar será detalhado, demonstrando de que forma contribui para transformar a gestão de inventário da X_Farma num processo mais ágil, colaborativo e digitalizado.

5.1 Modelos selecionados para o projeto piloto

A seleção dos modelos ARIMA, Holt-Winters e Prophet para aplicação no projeto-piloto na empresa X_Farma fundamenta-se na validação consolidada desses métodos na literatura especializada em séries temporais e gestão de inventário. O modelo ARIMA (Auto-Regressive Integrated Moving Average) é amplamente reconhecido pela sua capacidade de modelar séries temporais não estacionárias, detetando autocorrekções, tendências e ciclos complexos, o que o torna uma ferramenta eficaz para previsões em ambientes de procura dinâmica (Box, Jenkins, & Reinsel, 2015; Silva, 2015; Domenico, 2020). A robustez do ARIMA tem sido confirmada em diversas aplicações industriais e comerciais, onde proporciona previsões precisas e ajustáveis a padrões históricos variados (Brasil, 2021; CABIDigitalLibrary, 2020). O método Holt-Winters, clássico na previsão de séries temporais, destaca-se pela simplicidade e eficiência na identificação e ajuste de tendências e sazonalidades lineares, permitindo interpretação clara e rápida implementação prática, especialmente em contextos onde padrões sazonais são evidentes (Gardner, 1985; Hyndman et al., 2008; Maxwell, 2008). Tendo uma menor necessidade computacional o que o torna atraente para cenários empresariais que requerem respostas ágeis em gestão de inventários (VIISIMEP, 2023; FatecRL, 2020).

Por fim, o Prophet, desenvolvido por Taylor e Letham (2017) para o Facebook, tem se destacado pela sua flexibilidade e robustez em lidar com múltiplos padrões sazonais, ruturas e tendências não lineares comuns em séries temporais. As suas automações facilitam a modelagem, intuitiva de grandes conjuntos de dados, resultando em previsões robustas e confiáveis (Taylor & Letham, 2017; Meta, 2022; Sampaio, 2022).

Apesar do avanço significativo dos modelos de Machine Learning e redes neurais para séries temporais, tais métodos necessitam de volumes elevados de dados, maior complexidade na interpretação e infraestrutura computacional robusta, o que limita sua aplicabilidade em

projetos-piloto iniciais com recursos restritos (Makridakis et al., 2020; Brownlee, 2018). Assim, a escolha dos modelos ARIMA, Holt-Winters e Prophet oferece um equilíbrio ideal entre rigor técnico, aplicabilidade prática e interoperabilidade, possibilitando uma comparação abrangente e eficaz para a melhoria das previsões de procura e otimização da gestão de inventário.

5.2 Previsão da procura (Excel vs ARIMA/Holt-Winters/Prophet)

A previsão da procura constitui um dos fatores mais determinantes para a eficiência da gestão de inventário. No caso da X_Farma, o MAPE médio identificado (43%) evidencia limitações relevantes dos métodos tradicionais utilizados em Excel, que não incorporam de forma adequada variáveis sazonais, tendências de mercado ou comportamentos não lineares da procura.

Considerando que os produtos de Classe A representam a maior parte do valor financeiro e do risco associado ao inventário, foi desenvolvido um projeto-piloto com 10 SKUs desta classe, utilizando dados reais de vendas e previsões realizadas em 2024. O objetivo deste exercício é comparar o desempenho do método tradicional (Excel) com modelos estatísticos robustos (ARIMA, Holt-Winters e Prophet), de forma a avaliar o impacto potencial dos modelos estatísticos na redução do erro de previsão e, consequentemente, na otimização dos níveis de inventário.

Na Tabela 8 apresentam-se os resultados da comparação entre o modelo atualmente utilizado em Microsoft Excel (média móvel) e os métodos estatísticos Holt-Winters, Prophet e ARIMA, tomando como métrica de avaliação o erro médio absoluto percentual (MAPE) para os dez principais SKUs da Classe A.

De forma abrangente, constata-se que todos os métodos estatísticos superaram o desempenho do modelo em Excel, proporcionando maior precisão preditiva. O valor médio de MAPE do Excel foi de 30,79 %, ao passo que os modelos ARIMA, Holt-Winters e Prophet registaram valores médios de 27,97 %, 29,01 % e 24,21 %, respetivamente. Estes resultados representam uma redução média global de 7,97 pontos percentuais no erro, evidenciando a vantagem das abordagens estatísticas na previsão de consumo. Tal constatação corrobora a literatura académica, que destaca o MAPE como uma das métricas mais amplamente utilizadas pela sua interpretação direta e aplicabilidade em contextos industriais diversos (Taylor & Francis, 2019; Blucher, 2021; Psicothema, 2015).

Em termos desagregados por SKU, o modelo ARIMA destacou-se como o mais robusto em três séries (5000149, 5002370 e 5000875), demonstrando forte capacidade de captura de padrões de tendência e autocorreção inerentes aos dados. O ARIMA é amplamente

referenciado como uma solução eficaz para séries temporais, sobretudo em aplicações de previsão de procura e consumo, pela sua flexibilidade na modelação de processos estocásticos não estacionários (Silva, 2015; Domenico, 2020; Brasil, 2021; CABIDigitalLibrary, 2020).

O modelo Prophet apresentou o melhor desempenho em três séries (5000643, 5003745 e 510242), refletindo elevada adequação a séries com comportamentos não lineares e maior volatilidade. Desenvolvido por Taylor e Letham (2017), o Prophet é reconhecido pela robustez em grandes volumes de dados e pela automação na decomposição das componentes de tendência e sazonalidade (Taylor & Letham, 2017; Meta, 2022; Sampaio, 2022; SciencePublishingGroup, 2025).

Por sua vez, o método Holt-Winters destacou-se em quatro séries (5000687, 5001039, 5002078 e 5003532), confirmando a sua adequação a séries marcadamente sazonais, em linha com o que aponta a literatura clássica (Maxwell, 2008; Blucher, 2021; VIISIMEP, 2023; FatecRL, 2020).


Ainda que se tenham verificado diferenças pontuais entre os SKUs, a análise geral demonstra que os métodos estatísticos — especialmente Prophet e ARIMA — reduzem significativamente o erro de previsão face ao modelo em Excel, sendo recomendada a sua adoção em processos de gestão de inventário e planeamento logístico que requeiram elevado rigor preditivo (UC, 2019; FATEC, 2020)

Tabela 8 – Resultado entre os vários modelos estatísticos

SKU	MAPE_ARIMA_%	MAPE_HW_%	MAPE_Prophet_%	MAPE_Excel_%	Excel vs Melhoria (p.p.)	Melhor Modelo
510242	29,63	22,47	27,38	33,23	10,76	HW
5000149	28,41	30,04	29,71	31,12	2,72	ARIMA
5000643	21,70	14,91	14,00	30,73	16,73	Prophet
5000687	33,49	24,36	24,91	34,28	9,92	HW
5000875	30,50	41,79	32,52	33,86	3,36	ARIMA
5001039	26,49	25,53	27,17	33,61	8,08	HW
5002078	42,89	42,39	24,34	38,84	14,50	Prophet
5002370	17,02	18,81	19,89	18,76	1,74	ARIMA
5003532	16,68	13,42	14,01	19,43	6,01	HW
5003745	32,91	56,32	28,17	34,04	5,87	Prophet
Média	27,97	29,01	24,21	30,79	7,97	

Fonte: Elaboração própria


Gráfico 3 – Resultado entre os vários modelos estatísticos



Fonte: Elaboração própria


As maiores melhorias observadas ocorreram nos SKU 5000643 (16,73 p.p.) e 5002078 (14,50 p.p.), onde o modelo Prophet reduziu significativamente o erro. Estes resultados reforçam a importância de aplicar modelos de previsão mais avançados, que permitem reduzir a incerteza da procura e, consequentemente, suportar a otimização do inventário de segurança apresentada nos pilares seguintes da *framework*.

Gráfico 4 – Resultado do SKU 5000643



Fonte: Gráfico obtido através do PyCharm

Gráfico 5 – Resultado do SKU 5002078



Fonte: Gráfico obtido através do PyCharm

5.2.1. Parametrização e Afinação dos Modelos

Após a definição dos modelos de previsão, procedeu-se à etapa de calibração e suavização dos parâmetros, com o objetivo de reduzir a variabilidade e otimizar a estabilidade das previsões mensais. Esta fase foi conduzida de forma iterativa, por tentativa erro, avaliando diferentes combinações de parâmetros e janelas de suavização até se alcançar o melhor compromisso entre precisão e robustez preditiva.

No caso do ARIMA sazonal, testaram-se variações de ordens (p, d, q) e (P, D, Q, s) , ajustando-se manualmente os termos de diferenciação e sazonalidade, bem como os fatores de clipping superior, de modo a mitigar oscilações excessivas e previsões superestimadas. O modelo foi implementado com transformação logarítmica $\log(1 + y_t)$, seguida de inversão exponencial $\exp(y_t) - 1$, estratégia que demonstrou maior estabilidade face a séries com amplitude elevada.

O modelo Holt-Winters aditivo foi igualmente ajustado por meio da modulação dos coeficientes de suavização (α, β, γ) , privilegiando configurações com menor sensibilidade a variações pontuais. A inclusão de uma janela de média móvel de sete períodos ($\approx$ seis meses de histórico efetivo) revelou-se decisiva para suavizar a componente sazonal sem comprometer a resposta às tendências subjacentes.

Por sua vez, o modelo Prophet foi configurado com prior de mudança (changepoint prior scale) reduzido e escala de sazonalidade (seasonality prior scale) inferior, o que contribuiu para um

comportamento mais conservador e previsões menos voláteis. Foram ainda testadas versões com sazonalidade anual e linearização da tendência (growth = 'flat'), visando reduzir o risco de sobreajuste em séries de curta duração.

Com base nessa calibração, os resultados mais equilibrados foram obtidos com os seguintes parâmetros médios de suavização:

- Janela de suavização: 7 meses;
- Cap de previsão (ARIMA): $1,5 \times$ valor máximo observado no treino;
- Escala pós-suavização: 0,85;
- Média móvel final (pós-previsão): 6 períodos.

Essas configurações proporcionaram a redução média do MAPE para 27,97 % (ARIMA), 29,01 % (Holt-Winters) e 24,21 % (Prophet), contrastando com 30,79 % obtido pelo modelo Excel, e demonstrando a eficácia da suavização empírica no aprimoramento da qualidade das previsões.

5.2 Parametrização de Inventário

A melhoria da previsão, apresentada no ponto anterior através do modelo ARIMA, fornece a base para rever e otimizar os parâmetros de inventário. Contudo, para que os ganhos em precisão se traduzam em redução efetiva de inventário, é fundamental adotar uma abordagem diferenciada que considere simultaneamente o valor e a variabilidade da procura de cada produto.

Neste sentido, aplicou-se a matriz ABC-XYZ aos SKU de Classe A, que representam a maior relevância em termos financeiros e operacionais. A análise (Tabela 9) permitiu identificar quatro artigos classificados como AY (alto valor e procura relativamente estável) e seis artigos como AZ (alto valor, mas com procura mais variável).

Com base nesta segmentação, foram sugeridas políticas de gestão ajustadas a cada perfil:

- **AY** → política (**s,Q**), com revisão semanal e inventário de segurança médio, assegurando disponibilidade com maior previsibilidade.
- **AZ** → política (**R, S**), com revisão quinzenal e foco em limitar excessos, mitigando o risco de excesso de inventário e caducidade associado à maior variabilidade da procura.

Esta parametrização representa um passo decisivo na *framework*, pois permite alinhar a estratégia de inventário com as características reais de consumo de cada artigo, garantindo equilíbrio entre nível de serviço e eficiência financeira.

Tabela 9 – Resultados Classe ABC_XYZ

SKU	Classe_XYZ	Classe_ABC	Classe_ABCXYZ	Política_Sugerida
510242	Z	A	AZ	(R,S) revisão quinzenal
5000149	Z	A	AZ	(R,S) revisão quinzenal
5000643	Y	A	AY	(s,Q); revisão semanal
5000687	Z	A	AZ	(R,S) revisão quinzenal
5000875	Z	A	AZ	(R,S) revisão quinzenal
5001039	Z	A	AZ	(R,S) revisão quinzenal
5002078	Z	A	AZ	(R,S) revisão quinzenal
5002370	Y	A	AY	(s,Q); revisão semanal
5003532	Y	A	AY	(s,Q); revisão semanal
5003745	Y	A	AY	(s,Q); revisão semanal

Fonte: Elaboração própria

A tabela 10 evidencia os ganhos obtidos na redução do inventário de segurança (SS) após a aplicação da parametrização proposta no Pilar 2. Enquanto os níveis atuais de SS se situavam em média em 150 dias de cobertura, a introdução de previsões mais fiáveis combinadas com políticas diferenciadas de inventário (ABC-XYZ) permitiu reduzir o valor médio para 88 dias, representando uma diminuição superior a 40%.

Esta redução traduz-se em menor capital imobilizado, maior rotação de inventário e menor risco de caducidade, sem comprometer o nível de serviço, que foi calibrado entre 95% e 97% de acordo com o perfil de cada artigo. Verifica-se ainda que os SKU classificados como AZ atingiram um patamar médio de 89 dias, enquanto os artigos AY, por apresentarem maior estabilidade de procura, mantêm níveis de SS ligeiramente superiores (106 dias) para garantir continuidade de abastecimento.

Os resultados confirmam que a integração de previsões estatísticas com políticas segmentadas de inventário constitui uma alavanca fundamental para equilibrar eficiência financeira e disponibilidade operacional

Tabela 10 – Resultado Inventário Segurança

SKU	Classe_ABCXYZ	Período Revisão Dias(R)	Nível Serviço	SS_em_dias
510242	AZ	14	0,95	89
5000149	AZ	14	0,95	72
5000643	AY	7	0,97	86
5000687	AZ	14	0,95	89
5000875	AZ	14	0,95	89
5001039	AZ	14	0,95	89
5002078	AZ	14	0,95	72
5002370	AY	7	0,97	106
5003532	AY	7	0,97	86
5003745	AY	7	0,97	106
Média				88

Fonte: Elaboração própria

5.3 Processos Colaborativos (S&OP)

A eficácia das melhorias obtidas através da previsão de procura e da parametrização de inventário depende, em grande medida, da existência de processos colaborativos que garantam a sua aplicação de forma disciplinada e sustentável. Nesse sentido, o Sales and Operations Planning (S&OP) assume-se como um mecanismo essencial para alinhar previsões, planos de abastecimento, políticas de inventário e objetivos estratégicos da organização. Mais do que um exercício técnico, o S&OP constitui um processo de integração interdepartamental, promovendo a tomada de decisões baseadas em dados e reduzindo conflitos entre as áreas de Vendas, Marketing, Produção, Logística e Finanças (Wallace & Stahl, 2008; Lapide, 2004).

A proposta de implementação de S&OP nesta empresa farmacêutica assenta na criação de um ciclo mensal estruturado em quatro etapas:

- Demand Review (1ª semana): atualização das previsões de procura, incorporando inputs de Vendas e Marketing, bem como a saída dos modelos estatísticos.
- Supply Review (2ª semana): análise da capacidade produtiva e logística, avaliação dos níveis de inventário de segurança (SS) e identificação de possíveis restrições na cadeia de abastecimento.

- Pre-S&OP (3ª semana): consolidação da informação, análise de riscos e exceções, preparação de cenários alternativos para decisão.
- Executive S&OP (4ª semana): reunião da direção, onde se validam as metas de inventário, os níveis de serviço e as implicações financeiras do plano.

Este ciclo mensal está alinhado com os modelos de maturidade identificados por Grimson e Pyke (2007) e reforçado na síntese de Thomé, Scavarda e Fernandez (2012), que destacam a importância da estruturação sequencial das reuniões para assegurar consistência no processo.

De forma a assegurar a clareza de responsabilidades, é sugerida a adoção de uma matriz RACI (Responsible, Accountable, Consulted, Informed), onde se define quem é responsável por elaborar as previsões, quem valida, quem ajusta parâmetros de inventário e quem aprova os planos finais. Esta estrutura evita sobreposição de funções e promove maior responsabilização das áreas envolvidas (Tuomikangas & Kaipia, 2014).

Tabela 11 – Resultado Matriz RACI

Atividade / Decisão	Planeamento	Vendas	Marketing	Logística / Supply	Direção
Elaboração da previsão estatística	R	C	C	I	I
Validação da previsão final (forecast)	C	R	R	I	A
Definição de níveis de inventário de segurança	R	I	I	C	A
Ajuste de parâmetros de reposição (s, S)	R	I	I	C	A
Revisão de restrições de capacidade/logística	I	I	I	R	C
Consolidação do plano mensal (Pre-S&OP)	R	C	C	C	A
Aprovação final do plano (Executive S&OP)	I	I	I	I	A
Monitorização de KPI	R	C	C	R	I

Fonte: Elaboração própria

Legenda:

- R (Responsible)** – executa a tarefa
A (Accountable) – responsável último pela decisão
C (Consulted) – consultado antes da decisão
I (Informed) – informado após a decisão

Adicionalmente, propõe-se a integração dos principais KPI da *framework* — MAPE, inventário de segurança (dias), rotação, inventário/faturação e caducidade — como parte obrigatória do

processo mensal de revisão. Estes indicadores devem ser monitorizados através de dashboards dinâmicos, desenvolvidos inicialmente em Excel/ERP e progressivamente migrados para ferramentas de business intelligence (ex.: Power BI), garantindo transparência e rapidez na tomada de decisão.

A implementação do processo de S&OP representa a consolidação dos pilares anteriores, assegurando que as melhorias obtidas na previsão e na parametrização de inventário se traduzem em resultados sustentáveis. Através de um ciclo mensal estruturado, de responsabilidades claramente definidas e da monitorização contínua de KPI, o S&OP promove um alinhamento interdepartamental efetivo, reduzindo ruturas, evitando excessos de inventário e potenciando uma utilização mais eficiente dos recursos financeiros e operacionais. Assim, este pilar garante que a *framework* proposta não se limita a ganhos pontuais, mas se transforma num mecanismo de gestão integrado, capaz de sustentar a competitividade da empresa farmacêutica a médio e longo prazo.

5.4 Monitorização Contínua por KPI

A sustentabilidade de qualquer *framework* de gestão de inventário depende da capacidade de monitorizar de forma sistemática e objetiva os resultados alcançados. Após a implementação de previsões mais robustas (Pilar 1), da revisão dos parâmetros de inventário (Pilar 2) e da criação de processos colaborativos (Pilar 3), torna-se essencial garantir um sistema de monitorização contínua que permita avaliar, em tempo real, a eficácia das decisões tomadas.

Para este fim, foram definidos cinco KPI principais, alinhados com os objetivos da empresa e com as melhores práticas da indústria farmacêutica:

- Precisão da Previsão (MAPE) – mede a fiabilidade das previsões utilizadas no planeamento da procura.
- Cobertura Stock de Segurança (dias) – avalia se os níveis de SS estão ajustados aos objetivos definidos (meta ≤ 100 dias).
- Rácio Inventário/Faturação (%) – mede o peso financeiro do inventário em relação ao volume de vendas (meta $\leq 15\%$).
- Rotação de Inventário (vezes/ano) – indica a eficiência na utilização do inventário (meta $\geq 2x/\text{ano}$).
- Caducidade (%) – controla as perdas por expiração de produtos, crítico no setor farmacêutico (meta $\leq 3\%$).

A proposta passa pela criação de dashboards dinâmicos, inicialmente em Excel e evoluindo progressivamente para ferramentas de business intelligence como Power BI. Estes painéis devem apresentar a evolução histórica e atual dos KPI, permitindo identificar desvios face às metas estabelecidas e emitir alertas automáticos sempre que os valores ultrapassem limites críticos (ex.: cobertura de SS > 120 dias, caducidade > 5%).

Além dos cinco KPI centrais, recomenda-se o acompanhamento de indicadores complementares, como nível de serviço (% de encomendas servidas), lead time médio de fornecedor e disponibilidade de produtos críticos, que reforçam a visão global da cadeia de abastecimento.

Os benefícios esperados incluem uma maior transparência no processo de tomada de decisão, a possibilidade de reagir rapidamente a desvios, a melhoria contínua através de análises periódicas e a criação de uma cultura organizacional orientada por dados. Ao integrar estes KPI no ciclo de S&OP (Pilar 3), garante-se que as metas são revistas mensalmente, promovendo disciplina e consistência na gestão de inventário.

5.5 Piloto e Validação (“Antes vs Depois”)

O último pilar tem como objetivo validar a *framework* proposta através da realização de um piloto aplicado ao conjunto de SKU's apresentados nas tabelas anteriores. Este piloto permite avaliar, de forma prática e mensurável, o impacto da integração dos quatro pilares — previsão estatística, parametrização de inventário, processos colaborativos (S&OP) e monitorização por KPI — no desempenho da gestão de inventário.

O período de análise considerou o histórico recente de 5 anos de vendas reais e a projeção para os meses subsequentes.

A validação foi conduzida através da comparação entre dois cenários:

- Cenário Atual – valores obtidos a partir do método tradicional em Excel, com as políticas de inventário atualmente em vigor.
- Cenário Proposto (*Framework*) – resultados projetados com base nas previsões obtidas pelos modelos estatísticos (ARIMA, Holt-Winters e Prophet), a nova parametrização de inventário (ABC-XYZ, SS, s, S) e a integração no processo de S&OP.

Esta análise “Antes vs Depois” dos 10 SKU's selecionados para o piloto, permite verificar a aplicação do *framework* que conduz a reduções efetivas em inventário de segurança, melhoria na rotação e inventário/faturação e aumento da fiabilidade da previsão (MAPE).

Tabela 12 – Resultado Atual VS Proposto

KPI	Atual	Proposto	Melhoria
MAPE (%)	31	24	–7,0 p.p.
Inventário de Segurança (dias)	160	89	–71 dias
Inventário/Faturação (%)	13	8	–5,0 p.p.
Rotação (x/ano)	2,07	3,96	1,89%
Caducidade (%)	0	0	0 p.p.

Fonte: Elaboração própria

Nota: No anexo 8 é possível encontrar os SKU's desagregados.

6. Conclusões, Recomendações, Limitações e Futuro

6.1 Conclusões

O presente estudo partiu da constatação de problemas críticos na gestão de inventário da empresa X_Farma, caracterizados por níveis de inventário elevados, representando cerca de 20% da faturação anual, uma cobertura média de 150 dias de inventário de segurança, uma precisão de previsão insuficiente (MAPE médio de 43%), uma taxa de caducidade de aproximadamente 6% e uma rotação reduzida de 1,45 vezes ao ano. Este cenário traduzia não apenas um elevado capital imobilizado, mas também riscos significativos de perdas financeiras e de serviço ao cliente. Face a este contexto, o contributo desta investigação consistiu no desenvolvimento de uma *framework* integrado para a melhoria da gestão de inventário, testada através de um piloto aplicado a dez SKU de Classe A, os mais representativos em termos de valor.

Os resultados obtidos confirmam a eficácia da *framework* proposta e a superioridade dos modelos estatísticos face ao método tradicional em Excel. O MAPE médio reduziu-se de 31% para 24%, o que representa uma melhoria de 7 pontos percentuais na precisão da previsão. Esta melhoria traduziu-se num impacto direto na gestão de inventário, permitindo reduzir o stock de segurança médio de 160 para 89 dias — uma diminuição de 71 dias, equivalente a uma redução de 44% no capital imobilizado.

O indicador Inventário/Faturação passou de 13% para 8%, representando uma melhoria de 5 pontos percentuais, que corresponde a libertação financeira de aproximadamente 1,34 milhões de euros imobilizado em inventário. Paralelamente, a rotação anual de inventário

aumentou de 2,07 para 3,96 vezes, evidenciando maior fluidez operacional e menor tempo médio de permanência de stock. O nível de caducidade (0%), mantém para este piloto a expectativa esperada. Em termos operacionais, a *framework* demonstrou ser escalável, quantitativamente sustentada e de aplicação prática, promovendo decisões baseadas em dados e ajustadas ao perfil de procura de cada produto. Do ponto de vista financeiro, a libertação de capital circulante e a melhoria da rotação representam ganhos diretos de liquidez e eficiência. Já do ponto de vista estratégico e regulatório, a adoção de políticas diferenciadas de inventário reforça a sustentabilidade, rastreabilidade e conformidade com as GDP.

Em síntese, a aplicação do piloto validou que a *framework* proposta reduz custos, melhora a previsibilidade e aumenta a eficiência global da cadeia de abastecimento farmacêutica, contribuindo para a criação de um modelo de gestão mais racional, digital e orientado por dados, capaz de suportar decisões estratégicas sustentáveis na X_Farma e no setor farmacêutico em geral.

6.2 Recomendações

Com base nos resultados obtidos e na análise desenvolvida ao longo do estudo, apresentam-se as seguintes recomendações para a implementação e expansão da *framework*:

- Adoção faseada do *framework*: iniciar pela consolidação dos ganhos nos SKU de Classe A, estendendo posteriormente a Classes B e C com políticas diferenciadas.
- Adoção formal do processo de S&OP: institucionalizar o calendário mensal com reuniões estruturadas, assegurando a participação ativa das áreas de Vendas, Marketing, Logística e Finanças.
- Reforço da governança de dados: implementar práticas de melhoria contínua na qualidade e consistência da informação de vendas e inventário, reduzindo erros de input que afetam as previsões.
- Monitorização regular dos KPI: criar dashboards dinâmicos que permitam acompanhar os indicadores-chave (MAPE, inventário de segurança, rotação, inventário/faturação e caducidade).
- Formação e capacitação de equipas: promover sessões de treino em técnicas de previsão, gestão de inventário e utilização de ferramentas de business intelligence (ex.: Power BI).
- Integração tecnológica: avaliar a evolução de soluções em Excel/ERP para sistemas avançados de planeamento (IBP), potenciando maior automatização e escalabilidade.

Estas recomendações visam assegurar que a *framework* proposta não se limita a uma aplicação pontual, mas se transforma num processo sustentável e replicável, contribuindo para ganhos contínuos de eficiência e competitividade no setor farmacêutico.

6.3 Limitações do estudo

Apesar dos resultados alcançados, o presente estudo apresenta algumas limitações que importa reconhecer:

- Âmbito restrito: a análise foi realizada em apenas uma empresa farmacêutica, o que limita a generalização imediata dos resultados para todo o setor.
- Horizonte temporal: o piloto incidu sobre dados históricos recentes e projeções de curto prazo; uma análise longitudinal mais extensa poderia oferecer maior robustez às conclusões.
- Amostra de SKU: a validação foi centrada em dez artigos de Classe A, representativos, mas não abrangentes de toda a gama de produtos da empresa.
- Modelos de previsão utilizados: foram testados principalmente modelos estatísticos (ARIMA, Holt-Winters, Prophet), não incluindo algoritmos de machine learning mais avançados, que poderiam trazer melhorias adicionais.
- Adoção tecnológica e cultural: a aplicação da *framework* depende também de fatores humanos e organizacionais (resistência à mudança, integração interdepartamental), que não foram objeto de mensuração quantitativa neste estudo.

Estas limitações não invalidam os resultados obtidos, mas indicam que a *framework* deve ser entendida como um ponto de partida para melhorias futuras, a serem validadas em contextos mais amplos e com ferramentas adicionais.

6.4 Trabalhos futuros

Tendo em conta as limitações identificadas, destacam-se várias oportunidades para investigação e evolução futura desta *framework*:

- Aplicação em múltiplas empresas farmacêuticas: ampliar o estudo a diferentes contextos organizacionais, permitindo validar a generalização dos resultados e identificar variações decorrentes de diferentes portfólios e estruturas de cadeia de abastecimento.
- Expansão do horizonte temporal: realizar análises longitudinais, com séries históricas mais extensas e períodos de previsão alargados, de forma a avaliar a estabilidade dos ganhos em contextos de maior volatilidade da procura.

- Testes com algoritmos de machine learning: explorar técnicas mais avançadas, como XGBoost, Random Forest, LSTM (Long Short-Term Memory) ou Redes Neurais, comparando o seu desempenho com os modelos estatísticos já avaliados.
- Simulação integrada de políticas de inventário: desenvolver modelos de simulação que combinem previsão, parametrização e políticas de reabastecimento (s, S), permitindo avaliar cenários alternativos e trade-offs entre custo e nível de serviço.
- Integração tecnológica com IoT e blockchain: analisar o potencial de tecnologias emergentes, como sensores IoT para rastreabilidade de condições ambientais (temperatura, humidade) e blockchain para maior transparência e segurança na gestão de inventário.
- Avaliação do impacto cultural e organizacional: estudar a adoção do S&OP e da *framework* proposta sob a perspetiva de gestão da mudança, identificando barreiras humanas e fatores críticos de sucesso para a sua implementação plena.

Estes trabalhos futuros permitirão não apenas aprofundar a validade científica da *framework*, mas também reforçar a sua aplicabilidade prática, potenciando ganhos contínuos de eficiência, conformidade regulatória e competitividade no setor farmacêutico.

Em conclusão, a presente investigação demonstrou que a adoção de uma abordagem estruturada e suportada por métodos quantitativos e colaborativos pode transformar de forma significativa a gestão de inventário numa empresa farmacêutica. A *framework* proposta revelou-se eficaz na redução de excessos, na melhoria da fiabilidade da previsão e na otimização dos recursos financeiros e a capacidade de resposta às exigências do mercado. Mais do que uma solução técnica, esta proposta constitui um instrumento estratégico de competitividade, cuja replicação e evolução poderão contribuir para elevar os padrões de eficiência e sustentabilidade em toda a indústria farmacêutica.

7. Bibliografia

- Ahmadi, E., Masel, D. T., & Ahmadi, A. (2022). Intelligent inventory management in healthcare supply chains: A reinforcement learning approach. *Computers & Operations Research*, 147, 105968.
- Allenet, B., & Barry, H. (2015). The European challenge: Balancing safe and secure supply with sustainable access to medicines. *Health Policy*, 119(2), 155–160.
- Axsäter, S. (2015). *Inventory control* (3rd ed.). Springer.
- Ballou, R. H. (2006). *Business logistics/supply chain management* (5th ed.). Pearson Education.
- Blucher, E. (2021). *Modelagem e análise de séries temporais com enfoque em previsão de demanda*. São Paulo: Blucher Academic.
- Boerma, T., Chopra, M., & Evans, D. (2009). Health systems performance assessment in the Bulletin. *Bulletin of the World Health Organization*, 87(1), 2–2A.
- Box, G.E.P., Jenkins, G.M., Reinsel, G.C., & Ljung, G.M. (2015). *Time Series Analysis: Forecasting and Control*. Wiley.
- Cachon, G., & Terwiesch, C. (2019). *Matching supply with demand: An introduction to operations management* (4th ed.). McGraw-Hill Education.
- Chatfield, C. (2000). *Time-Series Forecasting*. Chapman & Hall.
- Choi, T. M. (2020). Innovative “bring-service-near-your-home” operations under Corona-virus (COVID-19/SARS-CoV-2) outbreak: Can logistics become the Messiah? *Transportation Research Part E: Logistics and Transportation Review*, 140, Article 101961.
- Chopra, S., & Meindl, P. (2019). *Supply chain management: Strategy, planning, and operation* (7th ed.). Pearson Education.

- Christopher, M. (2016). Logistics and supply chain management (5th ed.). Pearson Education.
- Heizer, J., Render, B., & Munson, C. (2017). Operations management: Sustainability and supply chain management (12th ed.). Pearson Education.
- Coyle, J. J., Langley, C. J., Jr., Novack, R. A., & Gibson, B. J. (2017). Supply chain management: A logistics perspective (10th ed.). Cengage Learning.
- Doğan, A. (2025). Time series-based demand forecasting: A comparative analysis of Holt-Winters, SARIMA, and Prophet models on retail inventory data. *İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi*, 24(53), 641-668. <https://doi.org/10.46928/iticusbe.1725584>
- Domenico, F. R. (2020). Modelos ARIMA aplicados à previsão de consumo industrial: uma revisão prática. *Revista de Estatística Aplicada*, 33(2), 45–62.
- Eisenhardt, K. M. (1989). Building theories from case study research. *Academy of Management Review*, 14(4), 532–550.
- Grimson, J. A., & Pyke, D. F. (2007). Sales and operations planning: An exploratory study and framework. *International Journal of Logistics Management*, 18(3), 322–346.
- Hyndman, R.J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*. OTexts.
- Ivanov, D. (2020). Predicting the impacts of epidemic outbreaks on global supply chains: A simulation-based analysis on the coronavirus outbreak (COVID-19/SARS-CoV-2) case. *Transportation Research Part E: Logistics and Transportation Review*, 136, 101922.
- İnce, M. N., & Taşdemir, Ç. (2024). Forecasting retail sales for furniture and furnishing items through the employment of Multiple Linear Regression and Holt–Winters models. *Systems*, 12(6), 219. <https://doi.org/10.3390/systems12060219>
- Ivanov, D., Dolgui, A., & Sokolov, B. (2019). The impact of digital technology and Industry 4.0 on the ripple effect and supply chain risk analytics. *International Journal of Production Research*, 57(3), 829–846.

- Kaur, H., & Singh, S. P. (2018). Smart supply chain management using IoT and cloud computing. In *Proceedings of the International Conference on Cloud Computing and Big Data Analytics* (pp. 12–19). IEEE.
- Lapide, L. (2005). Sales and operations planning Part III: A diagnostic model. *Journal of Business Forecasting*, 24(1), 13–16.
- Lapide, L. (2004). Sales and operations planning Part I, II, III. *The Journal of Business Forecasting*, 23(3).
- Oliva, R., & Watson, N. (2011). Cross-functional alignment in supply chain planning: A case study of sales and operations planning. *Journal of Operations Management*, 29(5), 434–448.
- Lewis, C. D. (1982). *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting* (p. 40). London: Butterworths.
- Maxwell, J. C. (2008). *Forecasting methods for management*. London: Pitman Publishing.
- McKone-Sweet, K. E., Hamilton, P., & Willis, S. B. (2005). The ailing healthcare supply chain: A prescription for change. *Journal of Supply Chain Management*, 41(1), 4–17.
- Montaño Moreno, J. J., Palmer Pol, A., Sesé Abad, A., & Cajal Blasco, B. (2013). Using the R-MAPE index as a resistant measure of forecast accuracy. *Psicothema*, 25(4), 500–506.
- Rathipriya, R., et al. (2023). Demand forecasting model for time-series pharmaceutical data using shallow and deep neural network models. *Neural Computing and Applications*. Advance online publication. <https://doi.org/10.1007/s00521-022-07889-9>
- Reddy, C. V., & Ranganath, N. (2019). Challenges in pharmaceutical supply chain management. *International Journal of Supply Chain Management*, 8(5), 450–456.
- Rodríguez González, R., León González, J. L., & Álvarez Sánchez, Y. (2021). Forecast of the demand for medications by a pharmaceutical organization using the ARIMA Model. *Universidad y Sociedad*, 13(1), 119–130. Retrieved from <https://rus.ucf.edu.cu/index.php/rus/article/view/1903>

- Shah, N. (2004). Pharmaceutical supply chains: Key issues and strategies for optimisation. *Computers & Chemical Engineering*, 28(6–7), 929–941.
- Silver, E. A., Pyke, D. F., & Peterson, R. (1998). *Inventory management and production planning and scheduling* (3rd ed.). Wiley.
- Silva, P. M. (2015). Aplicação do modelo ARIMA na previsão de séries temporais: estudo de caso no setor farmacêutico. *Revista Brasileira de Estatística Industrial*, 22(1), 55–73.
- Siddiqui, R., et al. (2021). *A hybrid demand forecasting model for greater forecasting accuracy: The case of the pharmaceutical industry*. Aston Publications.
- Srirangan, B., & Banerjee, R. (2018). Pharmaceutical supply chain management: A review. *International Journal of Pharmaceutical and Healthcare Marketing*, 12(3), 294–313.
- Syndetons, A. A., Boylan, J. E., & Disney, S. M. (2009). Forecasting for inventory planning: A 50-year review. *Journal of the Operational Research Society*, 60(s1), S149–S160.
- Taylor, S. J., & Letham, B. (2017). *Forecasting at scale*. *The American Statistician*, 72(1), 37–45.
- Thomé, A. M. T., Scavarda, L. F., & Fernandez, N. S. (2012). Sales and operations planning: A research synthesis. *International Journal of Production Economics*, 138(1), 1–13.
- Tuomikangas, N., & Kaipia, R. (2014). A coordination framework for sales and operations planning (S&OP). *International Journal of Production Economics*, 154, 243–262.
- VIISIMEP. (2023). Técnicas de suavização exponencial e seus usos na previsão de séries temporais. *Revista Brasileira de Métodos Preditivos*, 11(3), 101–118.
- Wallace, T. F., & Stahl, R. A. (2008). *Sales and Operations Planning: The How-To Handbook*. T. F. Wallace & Company.
- Waheed, W., et al. (2024). An efficient load forecasting technique by using Holt-Winters and Prophet algorithms to mitigate the impact on power consumption in COVID-19. *IET Research* (power/energy forecasting context).

Yin, R. K. (2018). Case Study Research and Applications: Design and Methods. Sage Publications.

Zipkin, P. H. (2000). Foundations of inventory management. McGraw-Hill.

8. Anexos

Anexo 1 – Questionários


**CIÊNCIAS
EMPRESARIAIS**
ESCOLA SUPERIOR
POLITÉCNICO SETÚBAL

QUESTIONÁRIO SOBRE PLANEAMENTO E GESTÃO DE INVENTÁRIO

Tema: Diagnóstico das Dificuldades e Oportunidades de Melhoria na Previsão de Compras e Gestão de Inventário.

Instruções: Responda de forma objetiva e honesta com base na sua experiência na função. As respostas serão tratadas de forma confidencial e utilizadas apenas para fins académicos.

1. INFORMAÇÕES GERAIS

1.1 Nome (opcional): Tiago Batista

1.2 Cargo/Função: CHEFE DEPARTAMENTO LOGÍSTICA E COMPRAS

1.3 Anos de experiência na área de gestão de stock:

☐ Menos de 1 ano
☐ 1–3 anos
☐ 4–6 anos
☒ Mais de 6 anos

2. PROCESSO ATUAL DE GESTÃO DE INVENTÁRIO

2.1 Como avalia a precisão das previsões de compras?

☒ Muito precisa
☒ Razoavelmente precisa
☐ Pouco precisa
☐ Nada precisa

2.2 Quais são os principais problemas atualmente na gestão de inventário?

☐ Excesso de stock
☐ Rutura de stock
☐ Dados desatualizados ou inconsistentes
☐ Previsão pouco confiável
☐ Lead times longos ou variáveis
☐ Falta de visibilidade sobre campanhas/vendas
☐ Dificuldade de comunicação entre departamentos
☒ Outro: FIABILIDADE DOS FORNECEDORES

2.3 Com que frequência são revistas as previsões de compra?

☐ Semanalmente
☐ Quinzenalmente
☒ Mensalmente

1

- ☐ De forma ad-hoc
- ☐ Não são ajustadas

3. COLABORAÇÃO INTERDEPARTAMENTAL (S&OP)

3.1 O planeamento de compras é realizado de forma colaborativa com as áreas de vendas e marketing?

- ☐ Sempre
- ☒ Às vezes
- ☐ Raramente
- ☐ Nunca

3.2 Como avalia a comunicação entre a equipa de gestão de stock e os outros departamentos?

- ☐ Excelente
- ☒ Boa
- ☐ Regular
- ☐ Fraca

3.3 Considera que a implementação de um processo estruturado de S&OP poderia trazer benefícios?

- ☒ Sim
- ☐ Talvez
- ☐ Não

Se respondeu "Sim" ou "Talvez", quais benefícios espera alcançar?

ADAPTAÇÃO DO PLANEAMENTO À ESTRATÉGIA E OBJECTIVOS DA EMPRESA TENDE EM CONTA OS RECURSOS FINANCEIROS E ORGANIZATIVOS

4. FERRAMENTAS E TECNOLOGIAS

4.1 Quais as ferramentas usadas atualmente para previsão e gestão de stock?

- ☒ Excel
- ☐ SAP / ERP
- ☐ Power BI
- ☐ Ferramentas próprias da empresa
- ☐ Outras: _____

4.2 Está satisfeito com as ferramentas disponíveis atualmente?

- ☒ Sim
- ☐ Parcialmente
- ☐ Não

Se "Não" ou "Parcialmente", o que gostaria de melhorar?

5. INDICADORES E PERFORMANCE

5.1 Acompanha KPIs de inventário?

☒ Sim

☐ Não

Se sim, quais são os principais KPIs utilizados?

VOLUME Stock vs CUSTO DAS VENDAS / VALOR RUPTURAS Stock

5.2 Considera que a empresa atua de forma proativa na gestão de inventário?

☒ Sim

☐ Parcialmente

☐ Não

6. MELHORIAS POTENCIAIS

6.1 O que considera ser prioritário melhorar no processo de previsão ou gestão de inventário?

- COMUNICAÇÃO ESTREITA COM A ÁREA COMERCIAL

- ACESSO AOS REPÓRTE DE VENDAS DO MERCADO PARA ANTICIPAR FLUTUAÇÕES DO MERCADO

6.2 Quais as sugestões para tornar o processo mais eficiente e colaborativo?

- INTEGRAÇÃO TOTAL DA ÁREA VENDAS NO PROCESSO DE PREVISÃO VENDAS

O questionário foi desenvolvido para apoiar o trabalho académico de mestrado em

Logística e Cadeia de Abastecimento do aluno Lécio Pereira N°2024135631 no Instituto

Politécnico de Setúbal.

QUESTIONÁRIO SOBRE PLANEAMENTO E GESTÃO DE INVENTÁRIO

Tema: Diagnóstico das Dificuldades e Oportunidades de Melhoria na Previsão de Compras e Gestão de Inventário.

Instruções: Responda de forma objetiva e honesta com base na sua experiência na função. As respostas serão tratadas de forma confidencial e utilizadas apenas para fins académicos.

1. INFORMAÇÕES GERAIS

1.1 Nome: André Marques Carvalho

1.2 Cargo/Função: Administrativo de compras e planeamento

1.3 Anos de experiência na área de gestão de stock:

- ☐ Menos de 1 ano
- ☐ 1-3 anos
- ☐ 4-6 anos
- ☒ Mais de 6 anos

2. PROCESSO ATUAL DE GESTÃO DE INVENTÁRIO

2.1 Como avalia a precisão das previsões de compras?

- ☐ Muito precisa
- ☒ Razoavelmente precisa
- ☐ Pouco precisa
- ☐ Nada precisa

2.2 Quais são os principais problemas atualmente na gestão de inventário?

- ☒ Excesso de stock
- ☒ Rutura de stock
- ☐ Dados desatualizados ou inconsistentes
- ☐ Previsão pouco confiável
- ☐ Lead times longos ou variáveis
- ☐ Falta de visibilidade sobre campanhas/vendas
- ☒ Dificuldade de comunicação entre departamentos
- ☐ Outro: _____

2.3 Com que frequência são revistas as previsões de compra?

- ☐ Semanalmente
- ☐ Quinzenalmente
- ☒ Mensalmente

- ☐ De forma ad-hoc
☐ Não são ajustadas

3. COLABORAÇÃO INTERDEPARTAMENTAL (S&OP)

3.1 O planeamento de compras é realizado de forma colaborativa com as áreas de vendas e marketing?

- ☐ Sempre
☒ Às vezes
☐ Raramente
☐ Nunca

3.2 Como avalia a comunicação entre a equipa de gestão de stock e os outros departamentos?

- ☐ Excelente
☐ Boa
☒ Regular
☐ Fraca

3.3 Considera que a implementação de um processo estruturado de S&OP poderia trazer benefícios?

- ☒ Sim
☐ Talvez
☐ Não

Se respondeu "Sim" ou "Talvez", quais benefícios espera alcançar?

Seria mais fácil ter toda a empresa alinhada para alcançar objetivos.

4. FERRAMENTAS E TECNOLOGIAS

4.1 Quais as ferramentas usadas atualmente para previsão e gestão de stock?

- ☒ Excel
☒ SAP / ERP
☐ Power BI
☐ Ferramentas próprias da empresa
☐ Outras: _____

4.2 Está satisfeito com as ferramentas disponíveis atualmente?

- ☒ Sim
☐ Parcialmente
☐ Não

Se "Não" ou "Parcialmente", o que gostaria de melhorar?

5. INDICADORES E PERFORMANCE

5.1 Acompanha KPIs de inventário?

☒ Sim

☐ Não

Se sim, quais são os principais KPIs utilizados?

Stock vs custos / Rupturas

5.2 Considera que a empresa atua de forma proativa na gestão de inventário?

☐ Sim

☒ Parcialmente

☐ Não

6. MELHORIAS POTENCIAIS

6.1 O que considera ser prioritário melhorar no processo de previsão ou gestão de inventário?

É essencial melhorar comunicação entre departamentos, melhor relação com os fornecedores.

6.2 Quais as sugestões para tornar o processo mais eficiente e colaborativo?

- Estipular procedimentos semanais/mensais de comunicação de forecasts.
- Análise detalhada de forecasts com auxílio de Inteligência Artificial.

O questionário foi desenvolvido para apoiar o trabalho académico de mestrado em

Logística e Cadeia de Abastecimento do aluno Lécio Pereira N°2024135631 no Instituto

Politécnico de Setúbal.

Anexo 2 – Formulário

Indicador	Fórmula	Dados Necessários	Resultado
MAPE (Mean Absolute Percentage Error)	$(1/n) \times \sum (Real - Previsto) / Real \times 100\%$	- Valores Reais	%
		- Valores Previstos	
Stock Segurança	Inventário Atual / Consumo Médio Diário	- Inventário Atual	Dias
		- Consumo Médio Diário (ex.: vendas médias/dia)	
Rotação de Inventário	Consumo Anual / Inventário Médio	- Consumo/Vendas Anuais	nº vezes
		- Inventário Médio	
Percentagem de Caducidade	$(Valor \text{ de } Produtos \text{ Caducados} / Valor \text{ Total de Inventário}) \times 100\%$	- Valor Produtos Caducados	%
		- Valor Total de Inventário	

Anexo 3 – Equações Matemáticas dos Modelos

Equações Genéricas dos Modelos de Previsão Utilizados no Projeto

Lécio Pereira

October 28, 2025

Modelos

ARIMA sazonal

$$\phi(B) \Phi(B^m) (1 - B)^d (1 - B^m)^D y_t = \theta(B) \Theta(B^m) \varepsilon_t$$

onde B é o operador de atraso, m é a periodicidade sazonal; ϕ, θ são polinómios AR e MA; Φ, Θ os polinómios sazonais; d, D as ordens de diferenciação.

Holt-Winters (aditivo)

$$\begin{aligned}\ell_t &= \alpha y_t + (1 - \alpha)(\ell_{t-1} + b_{t-1}) \\ b_t &= \beta(\ell_t - \ell_{t-1}) + (1 - \beta)b_{t-1} \\ s_t &= \gamma(y_t - \ell_t) + (1 - \gamma)s_{t-m} \\ \hat{y}_{t+h} &= \ell_t + h b_t + s_{t-m+h}\end{aligned}$$

Prophet (modelo aditivo)

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t$$

com $g(t)$ tendência (piecewise linear/logística), $s(t)$ sazonalidades (séries de Fourier) e $h(t)$ efeitos de feriados/eventos.

Notas

As equações acima são formas genéricas teóricas. Os parâmetros são ajustados por SKU com base em 2019–2023 e usados para prever 2024.

Anexo 4 – Código Python utilizado para calculo dos modelos

```
#-*- coding: utf-8 -*-
"""
Comparação de modelos (ARIMA conservador + Holt-Winters + Prophet) vs. Real 2024
+ MAPE do Excel (Piloto de 10 SKU's - Forecast.xlsx)
+ Tabela com Equações (Excel) e exportação LaTeX/PDF

Saídas:
- Excel: Resultados_Modelos_2024 Melhor Final.xlsx
  * Previsoes_2024
  * MAPE_por_SKU
  * MAPE_Detalhe_Mensal
  * Melhor_Modelo_2024
  * Resumo_Global
  * Equacoes_Modelos <-- NOVO
- CSV: MAPE_por_SKU Final.csv
- TeX: Equacoes_Modelos.tex <-- NOVO
- PDF: Equacoes_Modelos.pdf (se tiveres pdflatex instalado) <-- NOVO
- PNGs: plots/<SKU>.png (opcional)
"""

import os, re, warnings, subprocess, pathlib
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from datetime import datetime, date

warnings.filterwarnings("ignore")

# ===== CONFIG =====
EXCEL_FILE = "Piloto de 10 SKU's - Vendas reais.xlsx"
FORECAST_FILE = "Piloto de 10 SKU's - Forecast.xlsx"
SHEET_NAME = None # None => usa folha com 'SKU' no header ou a 1ª folha
SKU_COL_NAME = "SKU"

TRAIN_YEARS = {2019, 2020, 2021, 2022, 2023}
TEST_YEAR = 2024
FREQ = "M" # fim-do-mês

# Controlo de robustez (suavização)
APPLY_SMOOTHING = True
SMOOTH_WIN = 7
FORCAR_NAO_NEGATIVO = True
ARIMA_CLIP_FACTOR = 1.5

# Plots
PLOT_DIR = "plots"
PLOT_ONLY_FIRST_N = None

# Saídas
```

```

OUT_XLSX = "Resultados_Modelos_2024.xlsx"
OUT_CSV = "MAPE_por_SKU Final.csv"
OUT_TEX = "Equacoes_Modelos.tex"
OUT_PDF = "Equacoes_Modelos.pdf"
# =====

# ===== Imports opcionais/alternativos =====
HAVE_PM = HAVE_SM = HAVE_PROPHET = False
try:
    import pmdarima as pm
    HAVE_PM = True
except Exception:
    pass

try:
    from statsmodels.tsa.statespace.sarimax import SARIMAX
    HAVE_SM = True
except Exception:
    pass

try:
    from prophet import Prophet
    HAVE_PROPHET = True
except Exception:
    print("❗ Prophet não disponível (opcional).")
# =====

# ----- Utilitários -----
from typing import Optional

def is_month_header(c) -> bool:
    if c is None: return False
    if isinstance(c, (pd.Timestamp, np.datetime64, datetime, date)): return True
    s = str(c).strip().lower()
    if re.match(r"^[0-9]{2}[-_](0[1-9]|1[0-2])([-_]\d{1,2})?$", s): return True
    if re.match(r"^[a-z]{3,9}[-_]?d{2,4}$", s): return True
    return False

def to_month_end(x) -> pd.Timestamp:
    if isinstance(x, (pd.Timestamp, np.datetime64, datetime, date)):
        return pd.to_datetime(x).to_period("M").to_timestamp("M")
    dt = pd.to_datetime(str(x), errors="coerce")
    if pd.isna(dt): return pd.NaT
    return dt.to_period("M").to_timestamp("M")

def clean_numeric(x):
    if pd.isna(x): return np.nan
    if isinstance(x, (int, float, np.integer, np.floating)): return float(x)
    s = str(x).strip().replace(" ", "").replace(".", "").replace(",", ".")
    s = re.sub(r"^[^d.\-]", "", s)
    try: return float(s)
    except Exception: return np.nan

def read_excel_safely(path: str, sheet: Optional[str]):

```

"""

Lê Excel de forma robusta:

- Se 'sheet' for nome, tenta essa folha;
- Se 'sheet' for None, lê todas (dict) e escolhe a 1ª com coluna 'SKU' (case-insensitive), senão usa a primeira folha.

"""

try:

```

    if sheet is not None:
        return pd.read_excel(path, sheet_name=sheet)
    df = pd.read_excel(path, sheet_name=None)
    if isinstance(df, dict):
        for name, dfi in df.items():
            cols_norm = [str(c).strip().lower() for c in dfi.columns]
            if "sku" in cols_norm:
                print(f"📌 A usar folha '{name}' em {os.path.basename(path)}")
                return dfi
        key0 = list(df.keys())[0]
        print(f"📌 A usar primeira folha '{key0}' em {os.path.basename(path)}")
        return df[key0]
    return df
except Exception as e:
    raise RuntimeError(f"Erro ao ler '{path}': {e}")

```

----- Leitura de vendas (wide -> long) -----

```

def load_sales_wide_to_long(path: str, sheet: Optional[str]) -> pd.DataFrame:
    df0 = read_excel_safely(path, sheet)
    cols = list(df0.columns)

    if SKU_COL_NAME in df0.columns:
        sku_col = SKU_COL_NAME
    else:
        sku_col = None
        for c in cols:
            if re.search(r"\b(sku|codigo|cod|artigo|item|referencia|ref)\b", str(c), re.I):
                sku_col = c; break
        if sku_col is None:
            sku_col = cols[0]

    month_cols = [c for c in cols if c != sku_col and is_month_header(c)]
    if not month_cols:
        for c in cols:
            if c == sku_col: continue
            if pd.notna(to_month_end(c)):
                month_cols.append(c)
    month_cols = [c for c in month_cols if str(c).strip().lower() not in {"descrição", "descricao",
"description"}]
    if not month_cols:
        raise ValueError("Não encontrei colunas de meses no header do Excel.")

    month_cols_sorted = sorted(month_cols, key=lambda c: to_month_end(c))

    df_long = df0[[sku_col] + month_cols_sorted].melt(
        id_vars=[sku_col],

```

```

        value_vars=month_cols_sorted,
        var_name="MonthCol",
        value_name="Value_raw",
    )
    df_long["Date"] = df_long["MonthCol"].apply(to_month_end)
    df_long["Sales"] = df_long["Value_raw"].apply(clean_numeric)
    df_long = df_long.dropna(subset=["Date", sku_col])
    df_long.rename(columns={sku_col: "SKU"}, inplace=True)
    df_long["SKU"] = df_long["SKU"].astype(str)
    df_long = df_long[df_long["Sales"].notna()].copy()

    df = df_long.groupby(["SKU", "Date"], as_index=False)["Sales"].sum()
    years = sorted(df["Date"].dt.year.unique())
    print(f"→ [VENDAS] SKUs={df['SKU'].nunique()} | linhas={len(df)} | anos={years}")
    return df

# ----- Leitura do Forecast Excel -----
def load_forecast_excel(path: str, sheet: Optional[str] = None) -> pd.DataFrame:
    df0 = read_excel_safely(path, sheet)
    df0.columns = [str(c).strip() for c in df0.columns]
    if "SKU" not in df0.columns:
        for c in df0.columns:
            if re.search(r"\b(sku|codigo|cod|artigo|item|referencia|ref)\b", c, re.I):
                df0 = df0.rename(columns={c: "SKU"})
                break
    if "SKU" not in df0.columns:
        raise ValueError("No forecast: coluna SKU não encontrada.")

    month_cols = [c for c in df0.columns if c != "SKU" and is_month_header(c)]
    if not month_cols:
        for c in df0.columns:
            if c == "SKU": continue
            if pd.notna(to_month_end(c)): month_cols.append(c)
    if not month_cols:
        raise ValueError("No forecast: não encontrei colunas de meses.")

    df_long = df0.melt(id_vars=["SKU"], value_vars=month_cols,
                       var_name="Month", value_name="Forecast_Excel")
    df_long["Date"] = df_long["Month"].apply(to_month_end)
    df_long["Forecast_Excel"] = df_long["Forecast_Excel"].apply(clean_numeric)
    df_long = df_long.dropna(subset=["Date", "SKU"])
    df_long["SKU"] = df_long["SKU"].astype(str)

    df_2024 = df_long[df_long["Date"].dt.year == TEST_YEAR].copy()
    df_2024 = df_2024.groupby(["SKU", "Date"], as_index=False)["Forecast_Excel"].sum()
    years = sorted(df_2024["Date"].dt.year.unique())
    print(f"→ [FORECAST] SKUs={df_2024['SKU'].nunique()} | linhas={len(df_2024)} | anos={years if years else '—'}")
    return df_2024

# ----- Métrica -----
def mape(y_true: pd.Series, y_pred: pd.Series) -> float:
    df = pd.concat({"y": y_true, "yhat": y_pred}, axis=1).dropna()

```

```
df = df[df["y"] != 0]
if df.empty: return np.nan
return float((np.abs((df["y"] - df["yhat"]) / df["y"])).mean() * 100.0))
```

----- Modelos -----

```
def forecast_arima_conservador(train: pd.Series, steps=12) -> pd.Series:
    idx = pd.date_range(f"{TEST_YEAR}-01-31", periods=steps, freq="M")
    y = train.dropna().astype(float).asfreq("M")
```

```
if APPLY_SMOOTHING:
    y = y.rolling(SMOOTH_WIN, min_periods=1).mean()
```

```
if len(y) < 12:
    return pd.Series([np.nan]*steps, index=idx)
```

```
y_t = np.log1p(np.clip(y, 0, None))
cap = max(y.max(), y.mean()*1.2) if len(y) else np.nan
cap *= ARIMA_CLIP_FACTOR if pd.notna(cap) else 1.0
```

```
if HAVE_PM:
    try:
        m = pm.auto_arima(
            y_t, seasonal=True, m=12,
            d=0, D=1, start_p=1, start_q=1, max_p=2, max_q=2,
            start_P=0, max_P=1, max_Q=1, trend='n',
            stepwise=True, suppress_warnings=True, error_action="ignore",
        )
        fc_log = m.predict(steps)
        fc = np.expm1(fc_log)
        if FORCAR_NAO_NEGATIVO: fc = np.clip(fc, 0, None)
        if pd.notna(cap): fc = np.clip(fc, 0, cap)
        return pd.Series(fc, index=idx)
    except Exception:
        pass
```

```
if not HAVE_SM:
    return pd.Series([np.nan]*steps, index=idx)
```

```
def fit_fc(order, seasonal_order, trend=None, enforce_stationarity=True):
    model = SARIMAX(
        y_t, order=order, seasonal_order=seasonal_order,
        enforce_stationarity=enforce_stationarity,
        enforce_invertibility=True, trend=trend
    ).fit(dis=False)
    fc_log = model.get_forecast(steps=steps).predicted_mean
    fc = np.expm1(fc_log)
    if FORCAR_NAO_NEGATIVO: fc = np.clip(fc, 0, None)
    if pd.notna(cap): fc = np.clip(fc, 0, cap)
    return pd.Series(fc, index=idx)
```

```
for params in [
    ((1,0,1), (0,1,1,12), None, True),
    ((1,0,0), (0,1,1,12), None, True),
    ((1,1,1), (1,1,1,12), None, True),
```

```

]:
    try:
        return _fit_fc(*params)
    except Exception:
        continue

    return pd.Series([np.nan]*steps, index=idx)

from statsmodels.tsa.holtwinters import ExponentialSmoothing
def forecast_hw(train: pd.Series, steps=12) -> pd.Series:
    idx = pd.date_range(f"{TEST_YEAR}-01-31", periods=steps, freq="M")
    y = train.dropna().astype(float).asfreq("M")
    if APPLY_SMOOTHING: y = y.rolling(SMOOTH_WIN, min_periods=1).mean()
    if len(y) < 12: return pd.Series([np.nan]*steps, index=idx)

    try:
        fit = ExponentialSmoothing(y, trend="add", seasonal="add",
seasonal_periods=12).fit(optimized=True)
        fc = pd.Series(fit.forecast(steps).values, index=idx)
    except Exception:
        try:
            fit = ExponentialSmoothing(y, trend="add", seasonal=None).fit(optimized=True)
            fc = pd.Series(fit.forecast(steps).values, index=idx)
        except Exception:
            fc = pd.Series([np.nan]*steps, index=idx)

    if FORCAR_NAO_NEGATIVO: fc = np.clip(fc, 0, None)
    return fc

def forecast_prophet(train: pd.Series, steps=12) -> pd.Series:
    idx = pd.date_range(f"{TEST_YEAR}-01-31", periods=steps, freq="M")
    if not HAVE_PROPHET: return pd.Series([np.nan]*steps, index=idx)
    y = train.dropna().astype(float).asfreq("M")
    if APPLY_SMOOTHING: y = y.rolling(SMOOTH_WIN, min_periods=1).mean()
    if len(y) < 12: return pd.Series([np.nan]*steps, index=idx)

    dfp = pd.DataFrame({"ds": y.index, "y": y.values})
    dfp["y"] = dfp["y"].clip(lower=0)
    m = Prophet(yearly_seasonality=True, weekly_seasonality=False,
daily_seasonality=False)
    m.fit(dfp)
    future = pd.DataFrame({"ds": idx})
    fc = m.predict(future)["yhat"].values
    if FORCAR_NAO_NEGATIVO: fc = np.clip(fc, 0, None)
    return pd.Series(fc, index=idx)

# ===== Equações (Excel + LaTeX/PDF) =====
def build_equations_dataframe() -> pd.DataFrame:
    return pd.DataFrame([
        {
            "Modelo": "ARIMA(p, d, q)(P, D, Q)_m",
            "Equação (genérica)":  $r^{\phi(B)}\Phi(B^m)(1-B)^d(1-B^m)^D y_t = \epsilon_t$ ,
            "Descrição": "Combina AR, diferenciação (I) e MA, com termo sazonal de período

```

```

m."
    },
    {
        "Modelo": "Holt-Winters (aditivo)",
        "Equação (genérica)": (
            r"$\text{Nível: } \ell_t = \alpha y_t + (1-\alpha)(\ell_{t-1} + b_{t-1})$ \n"
            r"$\text{Tendência: } b_t = \beta(\ell_t - \ell_{t-1}) + (1-\beta)b_{t-1}$ \n"
            r"$\text{Sazonal: } s_t = \gamma(y_t - \ell_t) + (1-\gamma)s_{t-m}$ \n"
            r"$\text{Forecast: } \hat{y}_{t+h} = \ell_t + h b_t + s_{t-m+h}$"
        ),
        "Descrição": "Suavização exponencial tripla (nível, tendência e sazonalidade) –  
versão aditiva."
    },
    {
        "Modelo": "Prophet (aditivo)",
        "Equação (genérica)": r"$y(t) = g(t) + s(t) + h(t) + \varepsilon_t$",
        "Descrição": "Tendência g(t) (piecewise linear/logística), sazonalidades s(t) (Fourier  
e feriados h(t)."
```

```

    }
]

def write_equations_latex(tex_path: str):
    """Cria um .tex com as equações em LaTeX e tenta compilar para PDF."""
    content = r"""
\documentclass[11pt,a4paper]{article}
\usepackage[margin=2.2cm]{geometry}
\usepackage{amsmath,amsfonts,amssymb}
\usepackage{booktabs}
\usepackage{siunitx}
\usepackage{hyperref}
\usepackage{enumitem}
\usepackage{lmodern}
\usepackage[T1]{fontenc}
\usepackage[utf8]{inputenc}

\title{Equações Genéricas dos Modelos de Previsão Utilizados no Projeto}
\author{Lécio Pereira}
\date{\today}

\begin{document}
\maketitle

\section*{Modelos}
\subsection*{ARIMA sazonal}
\begin{align*}
&\phi(B), \Phi(B^m), (1-B)^d, (1-B^m)^D, y_t \text{ ;= ; } \theta(B), \Theta(B^m), \varepsilon_t \\
&\text{onde } B \text{ é o operador de atraso, } m \text{ é a periodicidade sazonal; } \phi, \theta \text{ são} \\
&\text{polinómios AR e MA; } \Phi, \Theta \text{ os polinómios sazonais; } d, D \text{ as ordens de} \\
&\text{diferenciação.}

\subsection*{Holt-Winters (aditivo)}
\begin{align*}
&\ell_t \&= \alpha y_t + (1-\alpha)(\ell_{t-1} + b_{t-1}) \\\

```

```

b_t &= \beta(\ell_t - \ell_{t-1}) + (1-\beta)b_{t-1} \\
s_t &= \gamma(y_t - \ell_t) + (1-\gamma)s_{t-m} \\
\hat{y}_{t+h} &= \ell_t + h\beta_t + s_{t-m+h}
\end{align*}

```

\subsection*{Prophet (modelo aditivo)}

```

\[
y(t) \hat{=} g(t) + s(t) + h(t) + \varepsilon_t
\]

```

com $g(t)$ tendência (piecewise linear/logística), $s(t)$ sazonalidades (séries de Fourier) e $h(t)$ efeitos de feriados/eventos.

\section*{Notas}

As equações acima são formas genéricas teóricas. Os parâmetros são ajustados por SKU com base em 2019--2023 e usados para prever 2024.

\end{document}

"""

```

with open(tex_path, "w", encoding="utf-8") as f:
    f.write(content)

```

```

# tenta compilar com pdflatex (se existir)

```

```

try:

```

```

    # compilar na mesma pasta do tex

```

```

    workdir = str(pathlib.Path(tex_path).parent.resolve())

```

```

    cmd = ["pdflatex", "-interaction=nonstopmode", os.path.basename(tex_path)]

```

```

    subprocess.run(cmd, cwd=workdir, check=True, stdout=subprocess.PIPE,
stderr=subprocess.PIPE)

```

```

    # correr uma 2ª vez para hyperlinks/toc limpos (opcional)

```

```

    subprocess.run(cmd, cwd=workdir, check=True, stdout=subprocess.PIPE,
stderr=subprocess.PIPE)

```

```

    print(f"📄 PDF gerado: {os.path.join(workdir, OUT_PDF)}")

```

```

except Exception as e:

```

```

    print(f"❗ Não consegui compilar para PDF automaticamente ({e}). "

```

```

        f"Compila manualmente com pdflatex: {tex_path}")

```

```

# ----- Pipeline principal -----

```

```

def main():

```

```

    # Vendas reais

```

```

    df = load_sales_wide_to_long(EXCEL_FILE, SHEET_NAME)

```

```

    years = sorted(df["Date"].dt.year.unique())

```

```

    if not set(TRAIN_YEARS).issubset(years) or TEST_YEAR not in years:

```

```

        print(f"⚠️ Anos disponíveis no ficheiro: {years}")

```

```

        raise ValueError("Faltam anos de treino (2019–2023) ou teste (2024).")

```

```

    # Forecast Excel (para MAPE_Excel)

```

```

    try:

```

```

        df_forecast = load_forecast_excel(FORECAST_FILE, SHEET_NAME)

```

```

    except Exception as e:

```

```

        print(f"⚠️ Não consegui ler o forecast do Excel:", e)

```

```

        df_forecast = pd.DataFrame()

```

```

    skus = sorted(df["SKU"].unique())

```

```

print(f"📦 SKUs: {len(skus)}")

# índices-alvo em fim-de-mês
idx_train = pd.date_range("2019-01-31", "2023-12-31", freq="M")
idx_test = pd.date_range(f"{TEST_YEAR}-01-31", f"{TEST_YEAR}-12-31", freq="M")

rows_mape = []
detalhe_rows = []
prev_rows = []

os.makedirs(PLOT_DIR, exist_ok=True)

for i, sku in enumerate(skus):
    g = df[df["SKU"] == sku].copy().set_index("Date").sort_index()
    y_train = g[g.index.year.isin(TRAIN_YEARS)][["Sales"]].astype(float).reindex(idx_train)
    y_test = g[g.index.year == TEST_YEAR][["Sales"]].astype(float).reindex(idx_test)

    if y_train.dropna().shape[0] < 12 or y_test.dropna().shape[0] == 0:
        rows_mape.append({"SKU": sku, "MAPE_ARIMA_%": np.nan, "MAPE_HW_%":
np.nan, "MAPE_Prophet_%": np.nan, "MAPE_Excel_%": np.nan})
        continue

    fc_arima = forecast_arima_conservador(y_train, 12).reindex(y_test.index)
    fc_hw = forecast_hw(y_train, 12).reindex(y_test.index)
    fc_prophet = forecast_prophet(y_train, 12).reindex(y_test.index)

    # Forecast Excel para o SKU (se existir)
    if not df_forecast.empty:
        fc_excel = (
            df_forecast[df_forecast["SKU"] == sku]
            .set_index("Date")["Forecast_Excel"]
            .reindex(y_test.index)
        )
        mape_excel = mape(y_test, fc_excel)
    else:
        fc_excel = pd.Series([np.nan]*len(y_test), index=y_test.index)
        mape_excel = np.nan

    # MAPEs
    rows_mape.append({
        "SKU": sku,
        "MAPE_ARIMA_%": mape(y_test, fc_arima),
        "MAPE_HW_%": mape(y_test, fc_hw),
        "MAPE_Prophet_%": mape(y_test, fc_prophet),
        "MAPE_Excel_%": mape_excel
    })

    # Detalhe mensal (inclui Excel)
    det = pd.DataFrame({
        "SKU": sku,
        "Data": y_test.index,
        "Vendas_2024": y_test.values,
        "ARIMA": fc_arima.values,
        "HW": fc_hw.values,

```

```

        "Prophet": fc_prophet.values,
        "Excel": fc_excel.values
    })
    for col in ["ARIMA", "HW", "Prophet", "Excel"]:
        det[f"APE_{col}_%"] = np.where(det["Vendas_2024"] != 0,
                                       np.abs(det[col] - det["Vendas_2024"]) /
                                       np.abs(det["Vendas_2024"]) * 100.0,
                                       np.nan)
        detalhe_rows.append(det)

    # Previsões (para Excel wide)
    prev_row = {"SKU": sku}
    for ts, val in fc_arima.items(): prev_row[f"Prev_ARIMA_{ts.strftime('%Y-%m')}"] =
float(val) if pd.notna(val) else np.nan
    for ts, val in fc_hw.items(): prev_row[f"Prev_HW_{ts.strftime('%Y-%m')}"] =
float(val) if pd.notna(val) else np.nan
    for ts, val in fc_prophet.items(): prev_row[f"Prev_Prophet_{ts.strftime('%Y-%m')}"] =
float(val) if pd.notna(val) else np.nan
    for ts, val in fc_excel.items(): prev_row[f"Excel_{ts.strftime('%Y-%m')}"] = float(val) if
pd.notna(val) else np.nan
    prev_rows.append(prev_row)

    # Plots (limitados se quiseres)
    if PLOT_ONLY_FIRST_N is None or i < PLOT_ONLY_FIRST_N:
        plt.figure(figsize=(10,4))
        plt.plot(y_train, label="Histórico 2019–2023", linewidth=1, alpha=0.7)
        plt.plot(y_test, label="Real 2024", linewidth=2, color="black")
        plt.plot(fc_arima, label=f"ARIMA (MAPE {mape(y_test, fc_arima):.1f}%)", linestyle="-
-")
        plt.plot(fc_hw, label=f"HW (MAPE {mape(y_test, fc_hw):.1f}%)", linestyle="--")
        plt.plot(fc_prophet, label=f"Prophet (MAPE {mape(y_test, fc_prophet):.1f}%)",
linestyle="--")
        if fc_excel.notna().any():
            plt.plot(fc_excel, label=f"Excel (MAPE {mape_excel:.1f}%)", linestyle="--")
        plt.title(f"SKU {sku} — Real vs. Previsões 2024")
        plt.legend(); plt.grid(alpha=0.3); plt.tight_layout()
        plt.savefig(os.path.join(PLOT_DIR, f"{sku}.png"), dpi=150)
        plt.close()

    # Tabelas finais
    mape_df = pd.DataFrame(rows_mape)
    detalhe_df = pd.concat(detalhe_rows, ignore_index=True) if detalhe_rows else
pd.DataFrame()
    previsoos_wide = pd.DataFrame(prev_rows)

    # Melhor modelo por SKU (ignora Excel aqui por ser baseline externo)
    best_rows = []
    for _, r in mape_df.iterrows():
        cand = {k: r[k] for k in ["MAPE_ARIMA_%", "MAPE_HW_%", "MAPE_Prophet_%"]} if
pd.notna(r[k])
        if not cand:
            best_rows.append({"SKU": r["SKU"], "Melhor_Modelo": None, "MAPE_%": np.nan})
        else:
            best = min(cand, key=cand.get)

```

```

        best_rows.append({"SKU": r["SKU"], "Melhor_Modelo": best.replace("MAPE_",
""").replace("_%", ""), "MAPE_%": cand[best]})
    melhor_df = pd.DataFrame(best_rows)

    resumo = pd.DataFrame([
        "Ano": TEST_YEAR,
        "MAPE_ARIMA_%": float(mape_df["MAPE_ARIMA_%"].mean(skipna=True)),
        "MAPE_HW_%": float(mape_df["MAPE_HW_%"].mean(skipna=True)),
        "MAPE_Prophet_%": float(mape_df["MAPE_Prophet_%"].mean(skipna=True)),
        "MAPE_Excel_%": float(mape_df["MAPE_Excel_%"].mean(skipna=True)),
        "SKUs": int(mape_df["SKU"].nunique())
    ])

    # === Equações em DataFrame (para Excel) ===
    equacoes_df = build_equations_dataframe()

    # Guardar
    mape_df.to_csv(OUT_CSV, index=False)
    with pd.ExcelWriter(OUT_XLSX, engine="openpyxl") as xl:
        previsoos_wide.to_excel(xl, sheet_name="Previsoos_2024", index=False)
        mape_df.to_excel(xl, sheet_name="MAPE_por_SKU", index=False)
        melhor_df.to_excel(xl, sheet_name="Melhor_Modelo_2024", index=False)
        if not detalhe_df.empty:
            det2 = detalhe_df.copy()
            det2["Mes"] = det2["Data"].dt.strftime("%Y-%m")
            det2 = det2[["SKU", "Mes", "Vendas_2024", "ARIMA", "HW", "Prophet", "Excel",
"APE_ARIMA_%", "APE_HW_%", "APE_Prophet_%", "APE_Excel_%"]].sort_values(["SKU", "
Mes"])
            det2.to_excel(xl, sheet_name="MAPE_Detalhe_Mensal", index=False)
            resumo.to_excel(xl, sheet_name="Resumo_Global", index=False)
            equacoes_df.to_excel(xl, sheet_name="Equacoes_Modelos", index=False) # <--
NOVO

    # === Escrever LaTeX + tentar compilar para PDF ===
    write_equations_latex(OUT_TEX)

    print("\n✅ Feito.")
    print(mape_df.to_string(index=False, float_format=lambda x: f'{x:.2f}' if pd.notnull(x) else
'nan'))
    print(f"\nFicheiros: {OUT_XLSX} | {OUT_CSV} | {OUT_TEX}"
f'{' | ' + OUT_PDF if os.path.exists(OUT_PDF) else ''} | Plots em: {PLOT_DIR}/')
    if PLOT_ONLY_FIRST_N:
        print(f"(Apenas os primeiros {PLOT_ONLY_FIRST_N} SKUs foram plotados.)")

if __name__ == "__main__":
    main()

```

Anexo 5 – Vendas reais

SKU	jan/19	fev/19	mar/19	abr/19	mai/19	jun/19	jul/19	ago/19	set/19	out/19	nov/19	dez/19	jan/20	fev/20	mar/20	abr/20	mai/20	jun/20	jul/20	ago/20	set/20	out/20	nov/20	dez/20
510242	2 459	2 295	2 282	3 582	1 605	1 749	2 826	952	1 614	2 538	2 391	1 498	2 275	2 110	2 120	3 579	1 646	1 573	2 758	969	1 641	2 694	2 246	1 446
5000149	13 599	10 536	10 628	15 512	8 498	10 022	14 254	6 282	8 704	9 201	15 071	8 481	12 380	10 398	10 320	15 305	8 835	9 945	14 255	6 647	8 572	9 426	13 987	7 514
5000643	3 223	2 803	2 316	3 908	2 083	1 855	3 160	1 465	1 862	3 406	2 518	2 200	2 859	2 553	2 294	3 619	2 210	1 957	3 311	1 541	2 011	3 311	2 676	2 161
5000687	1 425	939	1 223	1 614	1 083	1 156	1 295	552	1 293	1 061	1 025	951	1 268	907	1 131	1 449	1 041	1 170	1 311	530	1 211	1 152	1 103	911
5000875	14 378	13 136	16 194	11 976	8 341	9 765	10 693	4 710	15 796	5 180	16 054	10 764	15 357	11 996	17 778	11 738	9 126	10 075	10 706	4 492	15 220	5 608	14 769	10 557
5001039	3 186	1 674	2 085	2 423	2 114	2 600	2 929	1 383	2 489	2 923	2 282	1 835	3 159	1 723	1 973	2 492	2 249	2 668	3 001	1 422	2 283	2 630	2 417	1 743
5002078	1 697	1 103	1 182	1 578	1 034	1 602	1 501	1 072	651	1 618	1 337	1 117	1 529	1 023	1 198	1 661	1 100	1 459	1 486	1 075	681	1 653	1 254	1 131
5002370	4 988	9 193	4 670	6 082	4 451	5 958	6 166	2 966	4 730	5 814	8 404	5 030	5 305	8 249	5 010	5 484	4 713	5 487	6 586	2 632	5 043	6 197	8 139	4 462
5003532	2 947	2 238	2 041	1 263	3 979	2 055	4 779	666	1 289	1 412	1 837	1 359	2 677	2 400	1 925	1 233	3 845	1 937	4 585	658	1 171	1 457	1 652	1 318
5003745	2 444	1 903	1 814	2 857	1 471	2 079	3 009	1 542	1 481	2 053	1 715	1 072	2 319	1 821	1 945	2 895	1 582	2 064	2 852	1 611	1 400	1 957	1 807	944

SKU	jan/21	fev/21	mar/21	abr/21	mai/21	jun/21	jul/21	ago/21	set/21	out/21	nov/21	dez/21	jan/22	fev/22	mar/22	abr/22	mai/22	jun/22	jul/22	ago/22	set/22	out/22	nov/22	dez/22
510242	2 453	2 264	2 699	4 006	1 854	1 804	2 879	1 132	1 827	2 730	2 358	1 505	2 867	2 656	2 981	4 770	2 036	2 064	3 240	1 317	2 143	3 093	2 684	1 701
5000149	13 233	11 690	12 493	17 580	9 653	12 292	16 289	6 869	10 471	11 365	14 349	8 385	15 283	11 791	12 777	18 168	10 698	12 491	15 819	7 626	12 581	13 365	15 892	10 036
5000643	2 946	2 767	2 614	4 305	2 480	2 164	3 624	1 630	2 480	3 379	3 151	2 564	3 444	2 886	3 012	4 423	2 514	2 591	3 916	1 859	2 743	3 609	3 259	2 653
5000687	1 389	1 046	1 310	1 713	1 190	1 362	1 539	662	1 403	1 397	1 377	1 009	1 482	1 268	1 328	1 986	1 235	1 406	1 503	755	1 498	1 419	1 442	1 166
5000875	17 143	13 187	18 956	13 124	11 245	12 200	11 325	5 250	16 259	6 332	15 437	12 065	17 057	15 925	19 484	13 731	12 298	12 605	11 567	5 989	19 433	6 750	16 420	12 042
5001039	3 291	2 120	2 297	2 755	2 584	3 320	3 068	1 470	2 507	2 705	2 709	2 037	3 359	2 145	2 498	2 870	2 810	3 882	3 352	1 520	2 870	3 235	3 179	2 261
5002078	1 560	1 171	1 361	1 721	1 204	1 519	1 783	1 120	829	1 742	1 292	1 343	1 630	1 264	1 431	2 081	1 299	1 621	1 965	1 170	940	1 773	1 302	1 334
5002370	6 405	10 024	5 597	5 917	5 140	5 772	7 041	3 229	6 105	6 811	10 095	5 399	7 711	11 832	5 706	6 064	5 326	5 888	7 455	3 317	6 224	7 072	10 552	5 350
5003532	2 966	2 529	2 383	1 496	4 684	2 253	4 953	741	1 318	1 525	1 910	1 645	3 166	2 813	2 559	1 756	4 979	2 611	5 253	741	1 618	1 548	2 180	1 894
5003745	2 673	1 997	2 299	3 112	1 717	2 265	3 307	1 834	1 721	2 190	1 862	976	3 028	2 395	2 805	3 673	2 069	2 300	3 517	1 968	2 005	2 662	1 834	965

SKU	jan/23	fev/23	mar/23	abr/23	mai/23	jun/23	jul/23	ago/23	set/23	out/23	nov/23	dez/23	jan/24	fev/24	mar/24	abr/24	mai/24	jun/24	jul/24	ago/24	set/24	out/24	nov/24	dez/24
510242	2 436	1 714	2 705	2 920	2 392	2 033	3 457	1 570	2 071	2 372	1 908	1 404	2 634	1 950	2 161	2 871	1 918	1 805	3 460	1 588	2 077	2 970	1 368	1 080
5000149	14 214	10 900	13 994	14 155	11 690	10 789	16 356	8 983	18 293	24 631	10 768	11 312	19 874	21 830	20 154	19 378	13 242	15 236	20 998	9 563	15 292	19 723	17 209	7 710
5000643	1 108	0	8 017	2 337	1 999	3 118	3 520	1 466	2 805	1 808	4 310	2 355	3 337	3 138	2 912	2 904	3 167	2 861	4 183	2 432	2 789	3 451	3 116	1 782
5000687	1 642	1 329	1 592	0	0	1 642	0	3 180	1 286	1 137	935	659	1 418	1 424	1 127	2 209	1 600	1 773	2 449	1 325	1 784	3 072	1 324	1 075
5000875	17 463	9 254	14 364	8 699	9 163	11 451	15 041	5 371	18 385	13 286	10 810	10 509	16 678	10 277	11 138	13 892	10 532	12 125	17 180	6 140	11 503	10 188	14 463	5 629
5001039	2 775	2 337	2 881	2 289	2 813	2 629	4 095	1 528	2 232	2 478	2 404	1 708	3 378	2 357	3 263	2 430	2 307	2 944	3 438	1 251	2 836	2 972	2 178	1 396
5002078	1 850	1 285	1 453	1	0	4	0	2 276	994	1 138	624	714	945	1 558	761	773	1 009	1 088	1 140	1 318	1 204	1 846	1 308	1 140
5002370	8 615	4 999	6 201	10 437	5 345	5 892	8 354	3 666	6 246	7 422	6 628	8 268	7 870	6 862	7 422	7 963	8 823	6 522	9 230	4 215	7 331	7 357	6 665	4 100
5003532	3 071	1 683	2 670	2 366	2 345	2 415	2 178	1 704	2 125	2 237	2 439	1 867	2 568	2 523	2 060	2 050	2 714	2 405	2 320	1 999	2 261	2 246	2 434	1 349
5003745	2 126	1 553	2 589	3 149	1 826	1 687	2 891	1 460	1 626	1 697	1 911	1 475	1 429	1 566	1 088	931	1 467	1 308	1 541	1 046	1 389	1 771	1 484	1 009

Anexo 6 – Política Stock Segurança

SKU	Classe_ABCXYZ	Media_Diaria	Desvio_Diario	LeadTime_Dias(L)	Periodo_Revisao_Dias(R)	Nivel_Servico	z	Media_LTD	Sigma_LTD	SS	s(ReorderPoint)	Media_(L+R)	Sigma_(L+R)	S(Order-up-to)	SS_em_dias
510242	AZ	98	393,78	180	14	0,95	1,65	17646,82	5283,14	8690,77	26337,59	19019,35	5484,75	28041,76	89
5000875	AZ	529	2126,15	180	14	0,95	1,65	95280,68	28525,33	46924,17	142204,85	102691,40	29613,88	151406,23	89
5000149	AZ	758	3046,08	120	14	0,95	1,65	91004,09	33368,17	54890,63	145894,73	101621,23	35260,96	159625,51	72
5001039	AZ	116	467,85	180	14	0,95	1,65	20965,91	6276,82	10325,36	31291,27	22596,59	6516,35	33315,98	89
5000687	AZ	78	313,11	180	14	0,95	1,65	14031,82	4200,87	6910,44	20942,26	15123,18	4361,18	22297,33	89
5002078	AZ	53	214,37	120	14	0,95	1,65	6404,55	2348,33	3863,01	10267,55	7151,74	2481,54	11233,88	72
5003745	AY	61	243,87	180	7	0,97	1,96	10928,86	3271,91	6412,94	17341,80	11353,88	3334,92	17890,32	106
5002370	AY	320	1283,50	180	7	0,97	1,96	57518,18	17219,91	33751,03	91269,21	59755,00	17551,55	94156,04	106
5000643	AY	137	548,82	120	7	0,97	1,96	16396,36	6012,00	11783,52	28179,88	17352,82	6184,86	29475,15	86
5003532	AY	102	409,71	120	7	0,97	1,96	12240,45	4488,17	8796,81	21037,26	12954,48	4617,22	22004,22	86

Anexo 7 – Definição de Classes ABC-XYZ

SKU	Valor_Anual(€)	Total de vendas	Media_Diária	Media_Mensal	Desvio_Mensal	CV	Classe_X YZ	Participacao_%	Cumul_%	Classe_A BC	Classe_ABCX YZ	Politica_Sugerida
5003745	104 188,50 €	16029	61	1336	261,47	0,2	Y	0,023	0,023	A	AY	(s,Q); revisão semanal
5002370	102 919,20 €	84360	320	7030	1564,11	0,22	Y	0,022	0,045	A	AY	(s,Q); revisão semanal
510242	96 475,16 €	25882	98	2157	702,76	0,33	Z	0,021	0,066	A	AZ	(R,S) revisão quinzenal
5000643	80 877,03 €	36072	137	3006	577,09	0,19	Y	0,018	0,084	A	AY	(s,Q); revisão semanal
5000875	79 235,42 €	139745	529	11645	3582,73	0,31	Z	0,017	0,101	A	AZ	(R,S) revisão quinzenal
5000149	74 998,29 €	200209	758	16684	4584,57	0,27	Z	0,016	0,117	A	AZ	(R,S) revisão quinzenal
5001039	40 682,25 €	30750	116	2563	717,57	0,28	Z	0,009	0,387	A	AZ	(R,S) revisão quinzenal
5000687	40 336,80 €	20580	78	1715	593,82	0,35	Z	0,009	0,404	A	AZ	(R,S) revisão quinzenal
5003532	20 988,46 €	26929	102	2244	357,31	0,16	Y	0,005	0,721	A	AY	(s,Q); revisão semanal
5002078	18 969,37 €	14090	53	1174	310,33	0,26	Z	0,004	0,763	A	AZ	(R,S) revisão quinzenal

Anexo 8- Resultados por SKU's

ABC	SKU	MAPE_A tual (%)	SS_Atual (dias)	Inventário/Fatur ação Atual (%)	Rotação Atual (x/ano)	Caducidade Atual (%)	MAPE_Pro posto (%)	SS_Proposto (dias)	Inventário/Fatur ação Proposto (%)	Rotação Proposta (x/ano)	Caducidade Proposta (%)	Δ MAPE (p.p.)	Δ SS (dias)	Δ Inventário/Fa turação (p.p.)	Δ Rotação (x)	Δ Caducidade (p.p.)
A	510242	33%	180	10%	3,605	0	27%	89	5%	7,29	0	-6%	-91	-5%	3,69	0
A	5000149	31%	180	8%	3,346	0	30%	72	3%	8,37	0	-1%	-108	-5%	5,02	0
A	5000687	34%	150	6%	2,331	0	14%	89	4%	3,93	0	-20%	-61	-3%	1,60	0
A	5000875	34%	150	30%	0,990	0	25%	89	18%	1,67	0	-9%	-61	-12%	0,68	0
A	5001039	34%	150	10%	1,539	0	33%	89	6%	2,59	0	-1%	-61	-4%	1,05	0
A	5002078	39%	150	5%	1,437	0	27%	72	2%	2,99	0	-12%	-78	-3%	1,56	0
A	5002370	19%	150	30%	1,275	0	24%	106	21%	1,80	0	5%	-44	-9%	0,53	0
A	5003532	19%	150	6%	1,336	0	20%	86	3%	2,33	0	1%	-64	-3%	0,99	0
A	5003745	34%	180	14%	2,772	0	14%	106	8%	4,71	0	-20%	-74	-6%	1,94	0
		31%	160	13%	2,07	0%	24%	89	8%	3,96	0%	-7%	-71	-5%	1,89	0%