

A APLICAÇÃO COMBINADA DE MÉTODOS DE PREVISÃO DE DEMANDA EM PRODUTOS FUNDIDOS: UM ESTUDO DE CASO EM UMA INDÚSTRIA METALMECÂNICA

THE COMBINED APPLICATION OF DEMAND FORECASTING METHODS IN CAST PRODUCTS: A CASE STUDY IN A METALLURGICAL INDUSTRY

Mônica Pasolini¹, Amanda Dalla Rosa Monegat², Mateus Müller Franco³, Bruna Caroline Orlandin⁴, Leandro Luis Corso⁵

¹Universidade de Caxias do Sul, Área do Conhecimento de Ciências Exatas e Engenharias, Curso de Engenharia de Produção, Rua Francisco Getúlio Vargas, 1130, Bairro Petrópolis, 95070-560 – Caxias do Sul - RS – Brasil. E-mail: mpasolini@ucs.br

² Universidade de Caxias do Sul, Área do Conhecimento de Ciências Exatas e Engenharias, Curso de Engenharia de Produção, Rua Francisco Getúlio Vargas, 1130, Bairro Petrópolis, 95070-560 – Caxias do Sul - RS – Brasil. E-mail: admonegat@ucs.br

³Universidade de Caxias do Sul, Área do Conhecimento de Ciências Exatas e Engenharias, Curso de Engenharia de Produção, Rua Francisco Getúlio Vargas, 1130, Bairro Petrópolis, 95070-560 – Caxias do Sul - RS – Brasil. E-mail: mmfranco1@ucs.br

⁴Universidade de Caxias do Sul, Área do Conhecimento de Ciências Exatas e Engenharias, Curso de Engenharia de Produção, Rua Francisco Getúlio Vargas, 1130, Bairro Petrópolis, 95070-560 – Caxias do Sul - RS – Brasil. E-mail: bcorlandin@ucs.br

⁵Universidade de Caxias do Sul, Área do Conhecimento de Ciências Exatas e Engenharias, Curso de Engenharia de Produção, Rua Francisco Getúlio Vargas, 1130, Bairro Petrópolis, 95070-560 – Caxias do Sul - RS – Brasil. E-mail: llcorso@ucs.br

RESUMO

A previsão de demanda é essencial para a melhoria da performance operacional das organizações, bem como na tomada de decisão nos processos de planejamento e programação da produção. Diante deste contexto, esta pesquisa objetivou aplicar e comparar os resultados de oito métodos quantitativos de previsão de demanda, classificados como sazonais e não sazonais, em um estudo de caso em uma indústria metalmeccânica. Desta forma, os métodos foram utilizados na previsão de três produtos fundidos, denominados arbitrariamente como A, B e C, e os dados foram obtidos na empresa fabricante destes produtos. Para tanto, utilizou-se o *software* Excel para realizar as aplicações e a criação das séries temporais e das métricas de acuracidade. Como conclusões, destaca-se que o Método Multiplicativo de *Winters* obteve o melhor resultado para os produtos A e C. Por outro lado, para o produto B, o melhor resultado foi encontrado com o Método Aditivo de *Winters*. Logo, os modelos sazonais apresentaram os melhores resultados para os presentes produtos. Isto posto, com a atuação com os métodos de previsão de demanda nesta pesquisa, foi possível demonstrar a aplicação teórico-prática em um estudo de caso, entender o comportamento dos produtos analisados, e apoiar a organização em questão, no que tange a tomada de decisão e a formulação de estratégias eficientes na área.

Palavras-chave: Pesquisa Operacional, Previsão de demanda, Séries temporais, Produtos fundidos, Indústria metalmeccânica.

ABSTRACT

Demand forecasting is essential for improving the operational performance of organizations, as well as for decision making in production planning and scheduling processes. Given this context, this research aimed to apply and compare the results of eight quantitative demand forecast methods, classified as seasonal and non-seasonal, in a case study in a metalworking industry. Thus, the methods were used in the forecast of three cast products, arbitrarily denominated as A, B, and C, and the data were obtained from the company that manufactures these products. For this, Excel software was used to perform the applications and to create the time series and the accuracy metrics. As conclusions, the Winters Multiplicative Method obtained the best results for products A and C. On the other hand, for product B, the best result was found with the Winters Additive Method. Therefore, the seasonal models presented the best results for these products. That said,

with the performance with the demand forecast methods in this research, it was possible to demonstrate the theoretical-practical application in a case study, to understand the behavior of the products analyzed, and to support the organization in question, with regard to decision making and the formulation of efficient strategies in the area.

Keywords: Operations Research, Demand forecasting, Time series, Cast products, Metallurgical industry.

1. INTRODUÇÃO

Ambientes de negócio cada vez mais complexos vem promovendo incertezas no âmbito corporativo. No que tange a planejamento, tais incertezas estão atreladas a demandas variáveis devido a diferentes fatores de influência interferentes, como influências sazonais, políticas de preço e sortimento (MOROFF; KURT; KAMPHUES, 2021). Diante de fatores externos não controláveis, minimizar erros de planejamento é uma importante forma de mitigar riscos (FONSECA; MAGNO, 2022). Prever é uma maneira analítica de descrever o futuro com a qual a organização poderá confrontar-se (DOANE; SEWARD, 2014).

Nos dias atuais, tal planejamento é realizado por multiníveis, sendo a base para uma visão de curto, médio ou longo prazo, norteando as tomadas de decisão (PINTO, 2022). Bugor e Lucca Filho (2021), nos conduzem a entender que as previsões são vitais para todas as organizações e para cada decisão administrativa significativa. Observando através desse horizonte, o processo de previsão de vendas é considerado o principal processo de entrada de dados para o planejamento de áreas na empresa (BUGOR; LUCCA FILHO, 2021), sendo crucial implementar modelos de previsão eficientes que permitam que as empresas se preparem antecipadamente para situações futuras (MOROFF; KURT; KAMPHUES, 2021). Neste contexto, métodos de previsão de demanda estão sendo largamente utilizados pelos importantes benefícios apresentados. Monegat et al. (2020) utilizaram métodos de previsão de demanda para projeção de vendas de produtos de uma indústria do ramo moveleiro, Neto e Trentin (2019) os aplicaram para previsão de demanda de curto prazo para o mix de produtos de uma indústria metalmeccânica. E Silva et al. (2021), aplicaram modelos de previsão de demanda com o intuito de prever o faturamento de uma empresa de logística.

Para Rozanec e Mladenec (2021) e Tubino (2008), a previsão de demanda de vendas é um componente crítico do gerenciamento industrial, sendo o elo existente entre departamentos, tendo impacto direto em toda a cadeia de suprimentos, atendimento de pedidos e fábrica. Para o departamento de produção, obter dados concisos de previsão de vendas é crucial para estabelecer os níveis de capacidade de produção. Já para a área de suprimentos, é fundamental para a otimização da aquisição de matéria-prima, sendo um processo estratégico dentro das organizações (FONSECA; MAGNO, 2022). Segundo Moroff, Kurt e Kamphues (2021), previsões de demanda precisas são uma alavanca essencial para otimizar o desempenho operacional.

Neste contexto, este estudo possui o propósito de responder a seguinte questão-problema: “Como otimizar a compra de matéria-prima e prever mais assertivamente a capacidade produtiva em uma empresa fabricante de peças de alto valor agregado para o setor automotivo? Para isso, esta pesquisa detém como objetivo principal aplicar métodos quantitativos para prever a demanda de vendas de três diferentes peças estampadas, com o intuito de apoiar o processo de tomada de decisão do departamento de planejamento e programação da produção e analisar os possíveis cenários futuros relacionados a capacidade de produção.

Para tal fim, foram utilizados dados reais de vendas para os produtos em questão, possibilitando o uso destes modelos matemáticos. A vista disso, este estudo foi dividido em seis principais seções, com o intuito de atingir os objetivos da pesquisa. Desta maneira, elas são denominadas, respectivamente como introdução, revisão bibliográfica, metodologia, resultados e discussões, considerações finais e referências.

2. REVISÃO BIBLIOGRÁFICA

Nesta seção serão apresentados os referenciais *teóricos* necessários para a compreensão das teorias adotadas neste estudo.

2.1 *Previsão de Demanda*

De acordo com Borsato e Corso (2019), a previsão de demanda está entre os principais métodos utilizados para gerenciamento de processos. Apesar de sua complexidade de aplicação, o objetivo consiste em obter uma estimativa da demanda futura a partir de dados e acontecimentos históricos. Como complemento, Dezordi, Silva e Ribeiro (2019), afirmam que é possível planejar com precedência, para que todos os recursos necessários estejam disponíveis, com as quantidades e qualidade necessária, no momento correto. Desta forma, obtém-se o menor estoque, com baixo custo e menor tempo de entrega, gerando satisfação do consumidor.

Segundo Zanella, Vieira e Barichello (2016) os métodos podem ser divididos em qualitativos e quantitativos, além de uma combinação de ambos. Os modelos qualitativos geralmente são indicados para situações nas quais não existem dados históricos como base para as previsões. No que se refere aos métodos quantitativos, para Martins e Laugen (2015), a previsão é a determinação de valores futuros, obtidas por meio de uma fonte de dados passados, que são aplicados em métodos ou modelos matemáticos que estão associados a uma metodologia de trabalho previamente definida.

Segundo Tubino (2009), a modelagem de previsão de demanda segue cinco etapas básicas: objetivo do modelo; coleta e análise de dados; seleção da temática de previsão; obtenção das previsões; e por fim, monitoração do modelo. Logo, para este estudo, foram selecionados modelos de previsão não sazonais e sazonais, a fim de identificar qual melhor se adequa e representa os dados e produtos analisados nesta pesquisa.

2.2 *Modelos de previsão não sazonais*

Em sequência, para as análises de previsão não sazonais, os métodos selecionados para este estudo são descritos brevemente a seguir, apresentando as suas particularidades e principais diferenças.

2.2.1 *Modelo exponencial simples*

O método estatístico de Suavização Exponencial Simples (SES) é apropriado para séries com dados estacionários, as quais não apresentam comportamento de tendência no decorrer do tempo, ou seja, a série temporal se mantém constante sob um valor médio (ALVES et al., 2019; FERRO; LIMA; TRENTIN, 2019). Assim, conforme Gaither e Frazier (2002), a modelagem do método consiste na previsão correspondente ao período anterior, acrescida de uma proporção do erro entre demanda projetada e realizada, associada ao período anterior. Em complemento, vale ressaltar que o valor da constante alfa (α) é arbitrário.

2.2.2 *Modelo linear de Holt*

O método de *Holt* amplia a SES para dados de séries temporais que apresentem tendência linear, por meio da aplicação de uma constante que afeta a tendência da série histórica (HOLT, 1957; VERÍSSIMO, 2012). Para isso, o método considera duas constantes de suavização α e B , com

valores entre 0 e 1 para calcular o nível e a inclinação da série temporal (PELLEGRINI; FOGLIATTO, 2001).

2.2.3 Modelo linear de Brown

O método de *Brown* é utilizado para séries temporais que apresentam tendência linear. O funcionamento lógico do método é o seguinte: como os resultados obtidos pela suavização linear simples e dupla são diferentes do real quando existe uma tendência, a diferença entre eles poderá ser adicionada ao valor da suavização simples, para que esta seja ajustada de acordo com a tendência. Novamente, utiliza-se a constante de suavização α podendo assumir valores entre 0 e 1.

2.2.4 Tendência amortecida

O método de tendência amortecida foi desenvolvido em uma série de três trabalhos, e foi baseado no método de *Holt–Winters*. Logo, este método visa suavizar a tendência existente em um período de dados. O Método de Tendência Amortecida para suavizações exponenciais é um método que geralmente produz os melhores resultados em testes empíricos de comparações de métodos de previsão de demanda (KAHMANN ET AL; 2013).

2.3 Modelos de previsão sazonais

Para análises de previsão sazonais os métodos selecionados para este estudo são descritos a seguir.

2.3.1 Modelo sazonal simples

No Modelo Sazonal Simples, a suavização exponencial simples ocorre de forma satisfatória na série temporal quando a aleatoriedade domina a tendência-ciclo, dado que muitos métodos de decomposição levam em consideração a tendência e o ciclo sendo um único componente (PELLEGRINI et al., 2001). Sendo assim, se uma série temporal se mantém de forma constante sobre um nível médio, a suavização exponencial simples pode ser utilizada para a previsão dos valores futuros da série (PELLEGRINI et al., 2000).

2.3.2 Modelo aditivo e multiplicativo Winters

Os modelos de *Winters*, conforme Pellegrini (2000) dividem-se em dois grupos: aditivo e multiplicativo. No modelo aditivo, a amplitude da variação sazonal é constante ao longo do tempo, ou seja, a diferença entre o maior e menor valor de demanda dentro das estações permanece relativamente constante no tempo. Já no modelo multiplicativo, a amplitude da variação sazonal aumenta ou diminui como função do tempo.

O modelo multiplicativo de *Winters* é utilizado na modelagem de dados sazonais, onde a amplitude do ciclo sazonal varia com o passar do tempo. O modelo aditivo de *Winters* é utilizado na modelagem de dados sazonais, onde a amplitude do ciclo sazonal permanece constante com o passar do tempo (PELLEGRINI; 2000).

2.3.3 ARIMA

Segundo Borsato e Corso (2019), utilizam-se os modelos de previsão de demanda *Box-Jenkins*, também conhecidos como ARIMA, quando se tem por finalidade compreender o comportamento da correlação seriada ou analisar a similaridade entre os valores de uma

determinada série de tempo e com base no comportamento destes valores, determinar previsões futuras. Os modelos de previsão ARIMA foram desenvolvidos para serem utilizados em análises de dados temporais com padrão forte de sazonalidade.

Segundo Box e Jenkins (1976), a estratégia para a construção de um modelo ARIMA envolve uma abordagem iterativa que pode ser descrita nos seguintes passos: i) identificação – o objetivo é determinar os valores de p , d e q do modelo $ARIMA(p,d,q)$, sendo uma fase crucial do método; ii) estimação – nesta fase os parâmetros são estimados utilizando o algoritmo de programação não-linear (Marquardt); iii) verificação - pela análise de resíduos, verifica-se se o modelo é bom ou não, caso seja, pode-se passar para a última fase e iv) previsão – depois de identificado o modelo, estimado e verificado, pode-se realizar previsões para períodos futuros. No modelo ARIMA, os valores futuros de uma série temporal são supostos como associados, tanto aos valores passados da série (a componente autorregressivo), quanto aos erros das observações passadas (a componente média móvel).

2.4 Modelos Matemáticos

Em consonância, o Quadro 1 e 2 apresentam as equações matemáticas para os métodos de previsão de demanda utilizados nesta pesquisa.

Quadro 1 – Métodos de previsão não sazonais.
Fonte: Os Autores (2022).

Suavização Exponencial Simples	$P_{t+1} = \alpha R_t + (1 - \alpha)P_t$	Onde: P_{t+1} é a previsão para o período $t+1$; R_t é a demanda real para o período t ; P_t é a previsão para o período t ; α é a constante de amortecimento ($0 \leq \alpha \leq 1$).
Suavização Exponencial de Holt	$P_{t+n} = L_t + nT_t$ $L_t = \alpha R_t + (1 - \alpha)(L_{t-1} + T_{t-1})$ $T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$	Onde: P_{t+n} é a previsão para o período $t+n$; L_t é a previsão inicial para o período t ; T_t é a tendência para período t ; n é a quantidade de períodos. α é a constante de amortecimento ($0 \leq \alpha \leq 1$); β é a constante de tendência ($0 \leq \beta \leq 1$).
Suavização Exponencial de Brown	$P_{T+K} = S_T + kT_T$ $P_{T+K} = S_T + kT_T$ $S_T = \alpha d_T + (1 - \alpha)(S_{T-1} + T_{T-1})$ $T_T = \beta(S_T - S_{T-1}) + (1 - \beta)(T_{T-1})$	Onde: S_T Previsão suavizada para período T T_T estimativa de tendência para período k número de períodos futuros a serem previstos α é a constante de amortecimento ($0 \leq \alpha \leq 1$);
Tendência Amortecida	$L_t = L_{t-1} + \theta b_{t-1} + \alpha e_t L_t$ $b_t = \theta b_{t-1} + \alpha \beta e_t$ $P_t = L_t + \theta b_t$	Onde: P_t é a previsão para o período t ; L_t é a estimativa do nível da série no período t ; b_t é a estimativa da tendência da série no período t ; e_t é o “one-step-ahead error”; θ e β são as constantes de suavização.

Quadro 2 – Métodos de previsão sazonais.

Fonte: Os Autores (2022).

Sazonal simples	$\hat{Z}_{t+1} = \alpha Z_t + (1 - \alpha)\hat{Z}_t$	Onde: $\hat{Z}_{t+1}$; é o valor previsto para o período de tempo $t + 1$; α ; é o parâmetro constante de suavização do método, podendo assumir qualquer valor entre 0 e 1; Z é o valor observado para o tempo t ; $\hat{Z}_t$; é o valor previsto para o tempo t .
Suavização Exponencial de Winters Multiplicativo	$P_{t+n} = (L_t + nT_t)S_{t-s+n}$ $L_t = \alpha(R_t/S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1})$ $T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$ $S_t = \gamma(R_t/S_{t-s}) + (1 - \gamma)S_{t-s}$	Onde: P_{t+n} é a previsão para o período $t+n$; L_t é a previsão inicial para o período t ; T_t é a tendência para período t ; S_t é o índice sazonal para o período t ; s é o período de tempo para uma estação completa de sazonalidade. α é a constante de amortecimento ($0 \leq \alpha \leq 1$); β é a constante de tendência ($0 \leq \beta \leq 1$); γ é a constante de sazonalidade ($0 \leq \gamma \leq 1$).
Suavização Exponencial de Winters Aditivo	$P_{t+n} = L_t + nT_t + S_{t-s+n}$ $L_t = \alpha(R_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + S_{t-1})$ $T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}$ $S_t = \gamma(R_t - L_t) + (1 - \gamma)S_{t-s}$	Onde: P_{t+n} é a previsão para o período $t+n$; L_t é a previsão inicial para o período t ; T_t é a tendência para período t ; S_t é o índice sazonal para o período t ; s é o período de tempo para uma estação completa de sazonalidade. α é a constante de amortecimento ($0 \leq \alpha \leq 1$); β é a constante de tendência ($0 \leq \beta \leq 1$); γ é a constante de sazonalidade ($0 \leq \gamma \leq 1$).
ARIMA	$x_t - x_{t-d} = w_t = \Phi(w) + e_t - \theta(e)$ $\Phi(w) = \Phi_1 w_{t-1} + \Phi_2 w_{t-2} + \dots + \Phi_p w_{t-p}$ $\theta(e) = \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} +$	Onde: x_t são valores da série temporal x observados em um tempo t ; e_t é o erro associado aos valores observados no tempo t ; p é a ordem de um modelo autorregressivo de coeficientes Φ ; q é a ordem de um modelo de média móvel de coeficientes θ ; d é a ordem de integração do modelo ARIMA.

2.5 Erros de previsão

Na última etapa para medir os modelos de previsão de demanda, utiliza-se de modelos estatísticos para calcular o desempenho dos modelos a partir do erro de previsão. O erro de previsão consiste na diferença entre o valor previsto e o valor real observado. Logo, quanto menor for este valor mais próxima da demanda real o método estará (CAVALHEIRO, 2003). Em sequência, a

acuracidade de cada método é mensurada por meio do somatório dos erros associados, assim, o modelo de previsão satisfatório para uma dada série de dados é o que apresentar menor erro. Para tanto, apresenta-se abaixo a formulação matemática desta etapa:

$$E_t = R_t - P_t \quad (1)$$

Onde:

E_t é o erro de previsão para o período t ;

P_t é a previsão para o período t ;

R_t é a demanda real do período t .

Nesta etapa, erros negativos são indesejáveis, pois um erro positivo e um negativo se anulam, porém, o erro absoluto médio (MAE) e o erro percentual absoluto médio (MAPE) são projetados para superar esta desvantagem (XU; CHAN; ZHANG, 2019). Assim, exibe-se abaixo a formulação matemática do MAE e do MAPE.

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (2)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{R_t} \cdot 100 \right| \quad (3)$$

Onde:

MAE é a média absoluta dos erros;

$MAPE$ é a média percentual dos erros;

E_t é o erro de previsão para o período t ;

R_t é a demanda real do período t .

3. METODOLOGIA

Este estudo baseou-se na aplicação teórico-prática de previsão de vendas de produtos fundidos, em um estudo de caso em uma indústria metalmecânica, localizada na Serra Gaúcha. À vista disso, destaca-se que não foi permitida a divulgação do nome da mesma, bem como dos produtos analisados, por motivos de confidencialidade e sigilo de processo. Desta forma, esta pesquisa é classificada como de abordagem quantitativa, de natureza aplicada, com procedimento técnico de pesquisa bibliográfica, e de objetivo exploratório. Assim, ressalta-se que a mesma está enquadrada na área de Pesquisa Operacional e a subárea de Análise de Demanda em Engenharia de Produção. Para tanto, esta pesquisa foi dividida em cinco etapas, conforme elucidado na Figura 1.




Figura 1 – Etapas da metodologia desenvolvida.
Fonte: Os Autores (2022).

De forma complementar, apresenta-se a seguir a descrição de cada uma das etapas deste estudo, com o intuito de facilitar a compreensão das mesmas, e posterior aplicação prática:

- a) Realizar a revisão de literatura: inicialmente, realizou-se uma pesquisa e descrição dos principais conceitos supracitados nesta pesquisa, bem como uma análise dos estudos desta área presentes na literatura.
- b) Coletar dados: após, os dados necessários para a aplicação prática foram levantados em uma indústria metalmeccânica e analisados com o *software* Excel.
- c) Aplicar os métodos: no que diz respeito a execução, com a posse dos dados do histórico de vendas dos produtos fundidos denominados como A, B e C, utilizou-se dos métodos de previsão não sazonais e sazonais para avaliar a previsão de vendas. Além disso, foi feita a construção da visualização gráfica dos resultados gerados pelos métodos.
- d) Calcular os erros e analisar os resultados: nesta etapa, com os cálculos e análises dos erros, identificou-se os métodos mais apropriados para as séries temporais da problemática tratada, concebendo as menores variações entre os dados previstos e os dados reais, possibilitando assim, a análise dos resultados e a obtenção das conclusões e recomendações finais.

4. RESULTADOS E DISCUSSÕES

Na sequência apresenta-se a aplicação e análise de cada uma das etapas deste estudo, considerando as previsões de demanda dos produtos fundidos.

4.1 Coleta de análise dos dados

O estudo de previsão da demanda concentra-se em três produtos do portfólio da empresa em questão. Como supracitado, a divulgação dos produtos bem como da empresa não foi autorizada, sendo assim, os produtos serão identificados como A, B e C. O intervalo de tempo determinado para estudo compreende dados históricos de 36 meses, iniciando em janeiro de 2019 até dezembro de 2021. O Quadro 2 mostra os valores da demanda para os produtos analisados.

Quadro 2 – Dados coletados.
Fonte: Os Autores (2022).

Dados de vendas									
	Mês	Produto A	Produto B	Produto C		Mês	Produto A	Produto B	Produto C
1	jan/19	1596	348	170	19	jul/20	2545	250	203
2	fev/19	2088	396	253	20	ago/20	2837	567	295
3	mar/19	1552	232	202	21	set/20	2909	579	288
4	abr/19	854	163	305	22	out/20	3455	603	218
5	mai/19	866	122	273	23	nov/20	3657	1118	267
6	jun/19	748	137	168	24	dez/20	2475	699	297
7	jul/19	1754	224	231	25	jan/21	2776	599	273
8	ago/19	962	323	396	26	fev/21	4152	548	288
9	set/19	1838	239	268	27	mar/21	2646	337	244
10	out/19	2499	335	339	28	abr/21	2391	269	166
11	nov/19	3250	370	323	29	mai/21	4449	476	349
12	dez/19	1352	96	148	30	jun/21	5145	483	317
13	jan/20	2319	148	87	31	jul/21	6866	629	353
14	fev/20	2461	317	212	32	ago/21	6567	899	371
15	mar/20	1504	443	245	33	set/21	5732	1042	367
16	abr/20	1236	434	189	34	out/21	6079	992	527
17	mai/20	2226	188	188	35	nov/21	5839	641	548
18	jun/20	1552	459	131	36	dez/21	5237	578	589

4.2 Aplicação dos métodos

Nesta etapa foram realizados os cálculos de previsão. Desse modo, foram aplicados oito métodos estatísticos para três séries temporais. Além dos cálculos de previsão, foram calculados os erros atrelados a cada série e a cada método, ambos apresentados abaixo. Ainda, as equações aplicadas em todas as modelagens seguem o referencial teórico desta pesquisa.

4.2.1 Métodos Não Sazonais

Para análise de previsão de demandas não sazonais foram utilizados os modelos: i) suavização exponencial simples (SES); ii) linear de *Holt*; iii) linear de *Brown* e; iv) tendência amortecida. Foram geradas as previsões para cada dado histórico das séries. Para o produto A as previsões estão representadas na Figura 2.




Figura 2 – Previsões não sazonais do produto A.

Fonte: Os Autores (2022).

Para o produto A, pode-se visualizar que o método de SES é o que melhor se adapta a demanda real, percebe-se que as previsões absorvem as variações da demanda, no entanto, o método replica o comportamento da série temporal com defasagem de tempo. A Figura 3 representa as previsões não sazonais para o produto B.




Figura 3 – Previsões não sazonais do produto B.
Fonte: Os Autores (2022).

Conforme Figura 3, os métodos que melhor se adaptam as variações da demanda do Produto B são o de tendência amortecida e o Linear de *Holt*, uma vez que, os mesmos absorvem as variações da demanda, porém com um retardo em relação ao período de acontecimentos. Ou seja, as projeções em relação a demanda são inversas e consequentemente os erros ora seriam maiores ora menores. Na Figura 4 tem-se as previsões para o produto C.




Figura 4 – Previsões não sazonais do produto C.
Fonte: Os Autores (2022).

Por meio da Figura 4 é possível notar que todos os métodos compreendem as variações de comportamento da demanda com uma defasagem de tempo.

4.2.2 Métodos Sazonais

Para análise de previsão de demandas sazonais foram utilizados os modelos: i) sazonal simples; ii) aditivo de *Winters*; iii) multiplicativo de *Winters* e; iv) ARIMA. Foram geradas as previsões para cada dado histórico das séries. A Figura 5 apresenta os métodos de previsão sazonais para o produto A.




Figura 5 – Previsões sazonais do produto A.

Fonte: Os Autores (2022).

Conforme é possível observar na Figura 5 o método de *Winters* Multiplicativo absorve as variações do modelo. A parcela de média e tendência da série também é representada pela previsão. Graficamente, percebe-se que o modelo acompanha o comportamento dos dados reconhecendo a oscilação a curto e longo prazo. Na Figura 6 apresentam-se as previsões sazonais do produto B.




Figura 6 – Previsões sazonais do produto B.

Fonte: Os Autores (2022).

E a Figura 7 mostra as previsões obtidas por meio dos métodos sazonais de previsão de demanda para o produto C.




Figura 7 – Previsões sazonais do produto C.
Fonte: Os Autores (2022).

Conforme demonstrado pelos gráficos das Figuras 6 e 7, qualitativamente é possível constatar que tanto para o produto B quanto para o produto C, os modelos de previsão sazonal são capazes de representar as séries temporais de demanda. Os modelos interpretam as oscilações dos dados reais e seus padrões característicos. No entanto, apenas por meio das métricas obtidas quantitativamente é possível afirmar qual método matemático melhor representa o comportamento estatístico de cada produto.

4.3 Cálculo dos erros e análise dos resultados

De posse das previsões calculadas e dos erros atrelados a cada período histórico, os indicadores de acuracidade MAE e MAPE foram calculados e analisado, a fim de determinar o melhor modelo de previsão para cada série temporal. Os resultados são apresentados no Quadro 3.

Quadro 3 – Indicadores de acuracidade.
Fonte: Os Autores (2022).

	Modelo	MAE	MAPE
Produto A	Suavização Exponencial Simples	701,45	30,4%
	Holt	692,01	32,6%
	Brown	778,88	32,9%
	Tendência Amortecida	693,10	32,4%
	Sazonal Simples	455,19	20,6%
	Winters Aditivo	381,65	18,0%
	Winters Multiplicativo	494,63	14,4%
	ARIMA	743,23	31,8%
Produto B	Suavização Exponencial Simples	144,35	40,6%
	Holt	144,06	42,4%
	Brown	165,19	47,0%
	Tendência Amortecida	144,43	40,6%
	Sazonal Simples	105,05	29,5%
	Winters Aditivo	108,05	28,6%
	Winters Multiplicativo	146,60	36,8%
	ARIMA	132,09	42,2%
Produto C	Suavização Exponencial Simples	61,87	27,0%
	Holt	59,78	27,2%
	Brown	60,78	27,9%
	Tendência Amortecida	59,93	27,2%
	Sazonal Simples	52,10	20,7%
	Winters Aditivo	48,28	20,4%
	Winters Multiplicativo	51,34	19,1%
	ARIMA	68,31	28,7%

Desta forma, ao analisar os resultados dos indicadores de acuracidade, quanto menor o resultado do indicador, maior é a precisão da previsão quando comparado com a demanda real. Logo, o indicativo de acuracidade foi estabelecido pelo indicador MAPE e, conforme observado no Quadro 3, o menor erro percentual é alcançado pelo método de *Winters* multiplicativo para duas séries temporais, dos produtos A e C, apresentando erros médios percentuais respectivamente de 14,4% e 19,1%. Já para o produto B, o menor erro percentual alcançado foi pelo método de *Winters* aditivo, sendo ele de 28,6%. Com isso, verifica-se que os métodos sazonais são os que apresentaram as melhores previsões para os produtos fundidos analisados nesta pesquisa.

5. CONSIDERAÇÕES FINAIS

Para a correta administração de uma empresa, um importante aspecto é a previsão de demanda de seus produtos em determinado período. Desta forma, possibilitam a adequação da empresa à sua política de produção, custos e outros fatores que impactam diretamente na produtividade.

Logo, este trabalho, teve como objetivo analisar qual o método de modelagem de séries temporais se adapta melhor aos dados de venda de três produtos fundidos. Assim sendo, destacam-se como principais conclusões os resultados satisfatórios obtidos, assim como o atingimento dos objetivos desta pesquisa, por meio da aplicação de oito métodos quantitativos de previsão de demanda para as séries temporais estabelecidas na problemática deste estudo, levando em considerações os dados de vendas dos produtos fundidos A, B e C.

Desta maneira, com a aplicação destes modelos matemáticos que consideram os dados históricos, foi possível utilizar da premissa que os dados passados são importantes para o futuro e

aplicar métodos estatísticos, gerar as previsões, calcular os erros atrelados a cada método e apresentar graficamente os resultados obtidos.

A partir dos valores previstos, foram utilizadas duas medidas de acuracidade: i) o erro absoluto médio (MAE) e; ii) o erro percentual absoluto médio (MAPE). O método gerador do modelo que mostrar o menor valor nestas medidas foi considerado o mais adequado à série temporal.

Portanto, o resultado que declarou que o método de *Winters* multiplicativo se adequou às séries temporais dos produtos A e C, apresentando erros médios percentuais respectivamente de 14,4% e 19,1%. Por outro lado, para o produto B, destaca-se o método de *Winters* aditivo, sendo o erro médio percentual de 28,6%. Com isso, verificou-se que os métodos sazonais são os que apresentaram as melhores previsões para os produtos fundidos.

Por fim, com o intuito de complementar e apoiar as aplicações matemáticas deste estudo, recomenda-se para trabalhos futuros o uso do *software R Studio* e da linguagem de programação em *Python*. Em consonância, indica-se a utilização de modelos mistos de previsão de demanda, objetivando atuar com séries temporais lineares e não-lineares.

6. REFERÊNCIAS

ALVES, C. C.; HOEPERS, E.; CORAZZA, E. J.; SANTOS, G. J.; CRISTOFOLINI, R.; CRUZ, A. C. Aplicação de métodos estatísticos com suavização exponencial dupla e tripla para previsão de demanda na gestão de estoques. **Revista Produção Online**, v. 19, n. 3, p. 1001-1026, 16 set. 2019.

BORSATO, R.; CORSO, L. L. Aplicação de Inteligência Artificial e ARIMA na Previsão de Demanda no setor metal mecânico. **Scientia Cum Industria**, v. 7, n. 2, p. 165-176, 2019.

BOX, G. E. P.; JENKINS, G. M.; GWIL, Y. M. M. **Time Series Analysis: forecasting and control**. San Francisco, Holden-Day, 1976.

BUGOR, F.; LUCCA FILHO, J. de. A importância do planejamento, programação e controle da produção (PPCP) para o desenvolvimento das indústrias atuais. **Revista Interface Tecnológica**, v. 18, n. 1, p. 461-473, 3 nov. 2021. Interface Tecnológica.

CAVALHEIRO, D. **Método de previsão de demanda aplicada ao planejamento da produção de indústrias de alimentos**. 2003. 125 f. Dissertação (Mestrado) – Programa de Pós-graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis, 2003.

DEZORDI, B.; SILVA, M. M. D. da.; RIBEIRO, R. P. Previsão da demanda no ConformSim utilizando simulação de Monte Carlo. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 39. 2019, Santos, **Anais...** Santos: ENEGEP, 2019, p. 1-10.

DOANE, D.P.; SEWARD, L. E. **Estatística aplicada a administração e economia**. 4. ed. Porto Alegre: Amgh, 2014.

FERRO, W. A.; LIMA, J. D. de; TRENTIN, M. G. Combinations of Quantitative Methods in the Forecast for Demand for Sales of Home Appliances. **Revista Gestão da Produção Operações e Sistemas**, v. 14, n. 5, p. 67-88, 1 nov. 2019.

FONSECA, V. L. A.; MAGNO, R. N. O. Um modelo de previsão de vendas em uma empresa de médio porte na cidade de manaus – Um estudo de caso / A sales forecast model in a medium-sized company in the city of manaus - A case study. **Brazilian Journal of Development**, v. 8, n. 1, p. 5080-5097, 19 jan. 2022.

HOLT, C. E. **Forecasting trends and seasonal by exponentially weighted averages**. ONR Memorandum, v.52, Carnegie Institute of Technology, Pittsburgh, USA, 1957.

KAHMANN, A; FONTOURA, J. F. V.; PETTER, R. R. H.; CASSEL, R. A. Comparação de Métodos de Previsão de Demanda em uma montadora de veículos agrícolas. In: CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO, 3., 2013, Ponta Grossa, **Anais...** Ponta Grossa: ConBRepro, 2013, p. 1-09.

MARTINS, P. G.; LAUGENI, F. P. **Administração da produção**. 3 ed. São Paulo: Saraiva, 2015.

MONEGAT, et al. Análise de métodos de previsão de demanda para projeção de vendas de produtos de uma indústria do ramo moveleiro. In: XL Encontro Nacional de Engenharia de Produção, 40, 2020, Foz do Iguaçu, **Anais...** Paraná: ENEGEP, 2020, p. 1-17.

MOROFF, N. U.; KURT, E.; KAMPHUES, J. Machine Learning and Statistics: a study for assessing innovative demand forecasting models. **Procedia Computer Science**, v. 180, p. 40-49, 2021. Elsevier BV.

NETO, A. F.; TRENTIN M. G.; Previsão de demanda de curto prazo para uma indústria metalmeccânica. In: II Simpósio Nacional de Engenharia de Produção, 2, 2019, Dourados, **Anais...**Mato Grosso do Sul: SINEP: 2019, p. 1-12.

PELLEGRINI, F. R. **Metodologia para implementação de sistemas de previsão de demanda**. 2000. 130 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Engenharia de Produção, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para a implantação de sistemas de previsão de demanda – Técnicas e estudo de caso. **Revista Produção**, v. 11, n. 1, p. 43-64, 2001.

PINTO, M. F. **Proposta de aplicação de programação linear para otimização do planejamento agregado da produção**. 2022. 49 f. TCC (Graduação) - Curso de Engenharia de

Produção, Escola de Engenharia, Universidade Federal Fluminense, Niterói, 2022.

ROŽANEC, J. M.; MLADENIĆ, D. Reframing demand forecasting: a two-fold approach for lumpy and intermittent demand. **Robotics And Computer-Integrated Manufacturing**, [S.L.], v. 1, n. 1, p. 1-28, mar. 2021.

SILVA et al. Comparação entre métodos de previsão: estudo de caso em uma empresa de logística. In: XII FATECLOG, 12, 2021, Mogi das Cruzes, **Anais...** São Paulo: FATECLOG, 2021, p.1-11.

TUBINO, D. F. **Manual de Planejamento e Controle da Produção**. São Paulo: Editora Atlas, 2008.

TUBINO, D. F. **Planejamento e controle da produção**. São Paulo: Atlas, 2009.

VERÍSSIMO, A. J.; ALVES, C. C.; HENNING, E.; AMARAL, C. E.; CRUZ, A. C. Métodos estatísticos de suavização exponencial Holt-Winters para previsão de demanda em uma empresa do setor metal mecânico. **Revista Gestão Industrial**, v. 8, n. 4, p. 1-18, fev. 2013.

XU, S.; CHAN, H. K.; ZHANG, T. Forecasting the demand of the aviation industry using hybrid time series SARIMASVR approach, **Logistics and Transportation Review**, v. 122, p. 169-180, 2019.

ZANELLA, C.; VIEIRA, V.; BARICHELO, R. Previsão de demanda: um estudo de caso em uma agroindústria de carnes do oeste catarinense. **Gepros**, v. 11, n. 1, p. 45-57, jan/mar. 2016.