

APLICAÇÃO DE PREVISÃO DE DEMANDA CONSIDERANDO INTELIGÊNCIA ARTIFICIAL OTIMIZADA POR MEIO DE ALGORITMOS GENÉTICOS

APPLICATION OF DEMAND FORECAST CONSIDERING ARTIFICIAL INTELLIGENCE OPTIMIZED THROUGH GENETIC ALGORITHMS

Nathalia Tessari Moraes¹, Bruna Caroline Orlandin², Paulo Cesar Pizzato³, Leandro Luís Corso⁴

¹ Universidade de Caxias do Sul, Área do Conhecimento de Ciências Exatas e Engenharias, Mestrado Profissional em Engenharia Mecânica, Rua Francisco Getúlio Vargas, 1130, Bairro Petrópolis, 95070-560 –Caxias do Sul-RS – Brasil. Email: ntmoraes1@ucs.br

² Universidade de Caxias do Sul, Programa de Pós-Graduação em Ciências da Saúde, Mestrado Acadêmico em Ciências da Saúde, Rua Francisco Getúlio Vargas, 1130, Bairro Petrópolis, 95070-560 –Caxias do Sul-RS – Brasil. Email: bcorlandin@ucs.br

³ Universidade de Caxias do Sul, Área do Conhecimento de Ciências Exatas e Engenharias, Administração, Rua Francisco Getúlio Vargas, 1130, Bairro Petrópolis, 95070-560 –Caxias do Sul-RS – Brasil. Email: pc pizzato@hotmail.com

⁴ Universidade de Caxias do Sul, Área do Conhecimento de Ciências Exatas e Engenharias, Mestrado Profissional em Engenharia Mecânica, Rua Francisco Getúlio Vargas, 1130, Bairro Petrópolis, 95070-560 –Caxias do Sul-RS – Brasil. Email: llcorso@ucs.br

RESUMO

Modelos matemáticos de previsão de demanda são ferramentas cada vez mais utilizadas para as empresas gerenciarem melhor seus recursos e buscar vantagens competitivas. Para tanto, é fundamental identificar o modelo que melhor se adapta aos dados, de forma a deixar o resultado mais preciso e, ao mesmo tempo, facilitar a tomada de decisão. Este estudo tem por objetivo aplicar métodos de previsão de demanda em uma empresa que atua no ramo industrial sobre itens importados. Buscou-se a comparação entre os modelos de Suavização Exponencial, ARIMA, modelo de Redes Neurais Artificiais (RNA) com parâmetros otimizados. Esta comparação visou mostrar diferença entre os erros de previsão de cada um dos métodos. Com a aplicação dos modelos matemáticos sobre a base de dados histórica de uma empresa do ramo metal mecânico, observou-se que o modelo RNA otimizada apresentou o menor percentual de erro na maioria dos casos, proporcionando maior confiabilidade para aplicações práticas. A avaliação do desempenho e comparativo entre os métodos foram baseados sobre os dados do MAPE e MAE.

Palavras chave: Pesquisa operacional, Modelagem matemática, Previsão de demanda, Estoque.

ABSTRACT

Mathematical models of demand forecasting are increasingly used tools for companies to better manage their resources and seek competitive advantages. Therefore, it is essential to identify the model that best fits the data, in order to make the result more accurate and, at the same time, facilitate decision making. This study aims to apply demand forecasting methods in a company that operates in the industrial sector on imported items. We sought to compare the Exponential Smoothing, ARIMA and Artificial Neural Networks with optimized parameters. This comparison aimed to show a difference between the prediction errors of each method. With the application of mathematical models on the historical database of a company of the mechanical metal industry, it was observed that the optimized RNA model presented the lowest error percentage in most case analyzed, providing greater reliability for practical applications. Performance evaluation and comparative methods were based on MAPE and MAE data.

Keywords: Operational Research, Mathematical Modeling, Demand Forecasting, Inventory.

1. INTRODUÇÃO

O termo Indústria 4.0 foi criado para definir o impacto potencialmente revolucionário que esta tendência segue diretamente nos passos das três revoluções industriais anteriores (STUDIE, 2019). Os mercados consumidores estão exigindo cada vez mais produtos personalizados de alta qualidade e em tempo cada vez mais curto, forçando as empresas a buscarem formas e sistemas que possam tornar seus processos mais flexíveis e com maior capacidade de desempenho a longo prazo (TRENTESAUX; BORANGIU; THOMAS, 2016).

Atualmente tem sido um desafio para empresas se manterem competitivas em mercados voltados a tecnologias e inovações. A busca de métodos para melhorar sua eficiência e se tornarem mais produtivas perante seus concorrentes pode ser imprescindível. O gerenciamento de estoques e a previsão de demanda são fatores importantes que influenciam e contribuem diretamente para melhorar os níveis de eficiência e atendimento de seus clientes (TRATAR, 2010).

Para que as empresas possam atender seus clientes da maneira mais rápida possível e evitar perdas por falta de materiais disponíveis em estoque, as mesmas precisam dispor de recursos que propiciem o gerenciamento e controle desses estoques. Para tanto é preciso prever as inúmeras variáveis que possam afetar os mesmos, pois isso afeta o sistema de controle, bem como níveis de estoque e atrasos (BARROW; KOURENTZES, 2016). Em determinadas situações, também existem as questões de materiais importados, onde a complexidade pode envolver fatores sazonais ou até mesmo cambiais. Neste caso, o fato de não se ter um método eficaz de previsão de demanda pode acarretar em níveis expressivos de estoque, falta de material ou riscos de obsolescência. Caso as importações não sejam cuidadosamente planejadas e as variáveis que as afetam sejam mapeadas e consideradas nos prazos de reposição de estoques (ZHOU; DONG, 2012).

Pode-se considerar que previsões de demanda e controle de estoque contribuem igualmente para o nível de atendimento ao cliente (TRATAR, 2010). Ao mesmo tempo, caso as previsões não seja precisas, se pode correr o risco de aumento de custo expressivos ou mesmo a falta de materiais (FATTAH *et al.*, 2018). Obter dados concisos de previsão de vendas é um processo que pode ser estratégico dentro das organizações, uma vez que podem ser utilizados diretamente para estabelecer níveis de capacidade de produção e para otimização de quantidade de matéria-prima (FONSECA; MAGNO, 2022).

Frente a este cenário, a Pesquisa Operacional (PO) se torna uma ferramenta com potencial de auxiliar, com seus métodos, a melhor previsão de saída dos produtos das organizações.

O presente estudo tem o objetivo de identificar um modelo de previsão eficaz para prever a demanda de itens importados utilizados em uma indústria metal-mecânica. Para isso modelos matemáticos de suavização exponencial, ARIMA e Inteligência Artificial (IA), por meio de Redes Neurais Artificiais (RNA), foram aplicados para definir o melhor método.

2. REFERENCIAL TEÓRICO

Nesta seção será abordado a fundamentação teórica necessária para a compreensão das teorias adotadas neste trabalho.

2.1. Previsão de demanda

Os processos da cadeia de suprimentos são afetados por três variáveis principais que são a demanda, a produção e a distribuição que envolvem não somente fornecedores e fabricantes, bem como transportadoras, estoques e clientes, onde o fluxo de informações, recursos e produtos devem ser geridos de forma adequada (EFENDIGIL; ÖNÜT; KAHRAMAN, 2009).

A base comum para o planejamento é a previsão de demanda. Considerada o princípio para tomadas de decisão dentro de uma organização, pode-se defini-la como uma busca de informações das vendas futuras de um item/grupo de itens (MOREIRA, 2004; ZHENG; FU; LI; ZHANG, 2022). A previsão de demanda representa um campo de pesquisa que está em contínuo desenvolvimento (ZHU; ZHANG; SUN, 2019). De acordo com Fernandes e Filho (2009), a previsão é a técnica de encontrar informações relevantes sobre o futuro sendo um dos principais dados de entrada para várias funções e decisões do PCP. Tubino (2009) cita a previsão como a base estratégica da produção, vendas e finanças das empresas, sendo a ferramenta fundamental para os administradores planejarem suas ações. Ainda segundo o mesmo autor, as previsões permitem aos gestores das empresas anteverem o futuro e planejarem adequadamente suas ações. Por meio da aplicação dos métodos de previsão de demanda é possível planejar para que todos os recursos necessários estejam disponíveis com as quantidades e qualidade necessária no momento correto (DEZORDI; SILVA; RIBEIRO, 2019).

Os métodos para previsão de demanda podem ser divididos em qualitativos, quantitativos ou uma combinação de ambos. Quando não existem dados históricos geralmente são indicados os modelos qualitativos. Já os modelos quantitativos são indicados para determinar previsões futuras por meio de uma fonte de dados passados (ZANELLA; VIEIRA; BARICHELLO, 2016).

Quando se tratam de métodos qualitativos, os mesmos se dividem em dois grandes grupos, técnicas baseadas em séries temporais e técnicas causais (VERRUCK; BAMPI; MILAN 2009). A previsão de demanda de uma série temporal é o espelho dos dados passados multiplicado por um coeficiente que irá projetar o futuro dos componentes atuais de tendência, flutuação, sazonalidade e aleatoriedade, enquanto que os modelos causais utilizam outras variáveis para prever a demanda (MOREIRA, 2001; SHARPE; VEAUX; VALLEMAN, 2011).

2.1.1. ARIMA

Com ênfase somente na técnica baseada em séries temporais com previsão adaptável, os modelos clássicos mais divulgados na literatura são: média móvel, média móvel dupla, suavização exponencial simples, suavização exponencial dupla, suavização exponencial com tendência, suavização exponencial com tendência e sazonalidade e os modelos de Box-Jenkins (ARIMA).

De acordo com Mueller (1996) o modelo de George Box e Gwilyn Jenkins, também conhecido como ARIMA, possui capacidade de manipular séries temporais de qualquer natureza. Este método é utilizado quando se tem por finalidade analisar a similaridade entre os valores de uma determinada série de tempo para com base neste comportamento realizar previsões futuras, além de compreender o comportamento da correlação seriada (BORSATO; CORSO, 2019). O ARIMA foi desenvolvido para ser utilizado em série de dados temporais com fortes padrões de sazonalidade (BORSATO; CORSO, 2019). O mesmo tornou-se amplamente utilizado devido a sua flexibilidade e simplicidade em representar diversas variedades de séries temporais (XU; CHAN; ZHANG, 2019).

Modelos Autorregressivos e de Médias Móveis (ARMA) obtêm a previsão de valor futuro da série temporal pela combinação dos valores reais passados ou dos erros ocorridos, em algumas situações utilizando ambos. O método ARIMA consiste na busca de um modelo autorregressivos integrados e de médias móveis que represente o processo estocástico gerador da série temporal, a partir de um modelo

ARMA aplicável na descrição de séries temporais estacionárias, ou seja, que não variam em relação ao tempo, estendendo esse conceito para séries temporais não estacionárias (MUELLER, 1996).

Fava (2000) enfatiza a combinação de três filtros que sustentam os modelos ARIMA: o filtro auto regressivo (AR), o filtro de integração (I) e o filtro de médias móveis (MA); e, para a modelagem de uma determinada série temporal, tanto pode-se utilizar os três, quanto apenas um subconjunto destes. Estes filtros são, na maioria das vezes, representados por (p, d, q) , sendo que p representa defasagem, d refere-se ao grau e q é a ordem da média móvel (BOX; JENKINS, 1976). O modelo ARIMA pode ser representado pela Equação 1:

$$Y_t = \phi_1 Y_{t-1} + \theta_0 + \varepsilon_t \quad (1)$$

Onde $\varepsilon_t = Y_t - \hat{Y}_t$ é a diferença entre o valor real e o valor previsto da série.

2.1.2. Modelo de Holt

Dentre os métodos de suavização, a exponencial dupla foi desenvolvida por Holt e tem como diferença do modelo simples a utilização de duas constantes de suavização, α e β , com valores entre zero e um para calcular o nível e a inclinação da série temporal (HOLT, 1957). Nesse método, também chamado de modelo de Holt ou de Média Móvel Exponencialmente Ponderada de 2ª ordem, é possível fazer a análise de séries temporais com tendência linear crescente ou decrescente (VERRÍSIMO *et al.*, 2013). As equações deste modelo são consideradas como:

$$P_{t+n} = L_t + nT_t \quad (2)$$

$$L_t = \alpha R_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (3)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (4)$$

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 o período t ;

n é a quantidade de períodos;

α = constante de amortecimento ($0 \leq \alpha \leq 1$);

β = constante de tendência ($0 \leq \beta \leq 1$).

2.1.3. Inteligência Artificial

Com a revolução constante nas tecnologias da informação e comunicação bem como o desenvolvimento de mecanismos para coleta de informações a cada momento, bancos de dados gigantescos são gerados, abrindo possibilidades de desenvolvimento de ferramentas de gerenciamento destes dados para previsões por meio de RNAs (PEREA *et al.*, 2019). A Inteligência Artificial (IA) é um campo da ciência da computação que visa a implementação e criação de modelos cognitivos

(BITTENCOURT, 2001). Um dos modelos de IA mais utilizados são as RNAs, onde modelos de previsão podem ser otimizados por meio da utilização de algoritmos evolutivos (XU; CHAN; ZHANG, 2019).

As redes neurais baseiam-se no funcionamento dos neurônios biológicos do cérebro humano (BITTENCOURT, 2001). Para que seja possível entender o funcionamento das RNAs primeiramente é preciso conhecer sobre os neurônios biológicos e seu funcionamento (HAYKIN, 2001). Os neurônios são conhecidos como as unidades funcionais do cérebro (MARTIN, 2013). As informações vindas de outros neurônios são recebidas por meio dos dendritos, após o corpo celular executa uma resposta em função das entradas que recebe e por fim conduz as informações codificadas pelo axônio até as terminações. O contato entre o dendrito de um neurônio e o axônio de outro é chamado de sinapse (SNELL, 2019). Nas RNAs, cada terminal de entrada, reproduzindo a função de um dendrito, recebe um valor, esses valores recebem um peso sináptico w , ou seja, são ponderados e após combinados por uma função matemática f_a e no final a saída de um neurônio é a informação de entrada para o próximo, simulando o processo de sinapse (FACELI *et al.*, 2011).

A IA apresenta um ótimo desempenho na resolução de problemas complexos e não lineares, sendo amplamente utilizada na engenharia e na ciência. Uma das estruturas de RNA mais utilizadas é o *multilayer perceptron* (MLP) – perceptron multicamada, ele consiste em neurônios de unidades de processamento simples e conexões ponderadas entre estes neurônios. Os dados de entrada são transmitidos para a camada de saída após serem mapeados pela camada oculta (LIU *et al.*, 2019). A Figura 1 apresenta uma rede de múltiplas camadas.




Figura 1 - Rede de múltiplas camadas.
Fonte: Adaptado de Faceli *et al.*, (2011).

Perante a necessidade de tomada de decisão cada vez mais precisa em ambientes instáveis e incertos, as informações coletadas e organizadas utilizando sistemas de IA podem resultar em tomada de decisões com maior agilidade (LIN; LEE, 2009). Dentre os modelos presentes na literatura, pode-se considerar a previsão não linear dada por:

$$O_k = \varphi \left(\sum_{j=1}^q \omega_{jk} \cdot \varphi \left(\sum_{i=1}^p \omega_{ij} \cdot x_i \right) + b_k \right) \quad (5)$$

Para isso, os termos q e n , respectivamente representam os números de neurônios de entrada e ocultos. O termo ω é considerado o peso de cada uma das camadas do modelo; a_j e b_k representam os

limites das camadas oculta e de saída, $\emptyset$ e φ são as funções matemáticas da camada oculta e da camada de saída. O treinamento do modelo pode ser feito com diferentes algoritmos, como, por exemplo, *Levenberg-Marquardt* (LM) e *Bayesian Regularization* (BR), ambos os modelos são amplamente utilizados na resolução de problemas de otimização. Para este trabalho, o foco foi dado também na seleção destes algoritmos (LIU *et al.*, 2019). O algoritmo de LM utilizado pode ser escrito da seguinte forma:

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (6)$$

Neste modelo, μ é a taxa de aprendizagem do modelo, J é a matriz das primeiras derivadas (ou jacobiana) onde busca-se a minimização dos erros com um algoritmo iterativo. O algoritmo BR apresenta um conjunto de dados de treinamento dados por C e a forma funcional do modelo é representada por F , ficando da seguinte forma:

$$p(C, F) = \frac{p(C | \emptyset, F) p(\emptyset | F)}{p(C | F)} \quad (7)$$

As RNAs no modelo *NonLinear Autoregressive* (NAR), podem ser treinadas para prever uma série temporal a partir dos valores anteriores dessa série, que foi o caso deste trabalho. Os valores futuros de uma série temporal $y(t)$ são previstos apenas a partir de valores passados dessa série. NAR e pode ser escrito da seguinte maneira: $y(t) = f(y(t-1), \dots, y(t-d))$.

$$y(t) = f(y(t-1), \dots, y(t-d)) \quad (8)$$

A arquitetura de uma rede recorrente de entrada-saída apresenta a forma MPL com realimentação de sua saída para a entrada por meio de período de tempo de *delay*.

3. MATERIAIS E MÉTODOS

O presente trabalho baseou-se no estudo de cinco itens importados utilizados no processo produtivo de uma empresa do ramo metal mecânico no período de janeiro de 2017 a julho de 2019. A pesquisa é classificada como de abordagem quantitativa e de natureza aplicada. Para tanto este estudo foi dividido em quatro etapas conforme apresentado na Figura 2.




Figura 2 - Etapas do trabalho.
Fonte: os Autores (2022).

Apresenta-se a seguir a descrição de cada uma das etapas deste estudo, com o intuito de facilitar a compreensão das mesmas.

3.1. Coletar e estruturar a base de dados

Nesta etapa foi realizada a coleta de dados na empresa estudada no período de janeiro de 2017 a julho de 2019. Os dados referem-se a cinco itens utilizados na produção que são importados. Os mesmos foram classificados em famílias. Nesta empresa, as previsões de demanda não são definidas ou baseadas em métodos científicos de cálculos de demanda, mas sim pela estimativa de vendas informada pela área comercial ao PCP que, por sua vez efetua a distribuição da mesma para a aquisição dos materiais necessários. Entretanto, tal método se torna incerto para produtos importados que demandam um longo tempo entre o planejamento de compra e a disponibilidade de estoque, fator este que pode ocasionar desabastecimento ou excesso de estoque nos casos em que a demanda variar, além de gerar uma série de transtornos para a empresa, sejam de ordem financeira, logística ou mesmo de imagem perante seus clientes.

3.2. Implementar computacionalmente os modelos

Com posse dos dados utilizou-se das metodologias ARIMA, Holt e RNA e RNA otimizada para cálculo das previsões de demanda. Para otimização da RNA, utilizou-se um Algoritmo Genético (AG), com base no pseudocódigo da Figura 3 baseado em Corso e Wallace (2015) e Borsato e Corso (2019). A implementação foi feita no *software Python*.

Geração/Iniciar com o tamanho da população: “m” é o número de indivíduos, que simulam as variáveis do modelo”.
Aptidão/Avaliação e validação dos dados de entrada
Verificar a convergência dos dados
Seleção das famílias de produto
Aplicação dos operadores genéticos
Crossover/Reprodução
Mutação
Elitismo
Aptidão/Avaliação dos dados previstos
Armazenar os valores
Seleção/Verificação da condição de terminação
Fim do Algoritmo

Figura 3 – Pseudocódigo do AG.

Fonte: Adaptado de Corso e Wallace (2015) e Borsato e Corso (2019).

Os parâmetros do AG consideram fator de cruzamento 0,75, o número de indivíduos igual a 50 para um total de 100 gerações. A taxa de elitismo considerou 2 indivíduos. A quantidade de neurônios variou de 5 até 200, o número de *delay* ficou entre 2 e 7. Como seleção dos algoritmos de treinamentos foram utilizados: LM e BR. O algoritmo de otimização proposto realiza a minimização dos erros de previsão (*ER*), e considera como variável o número de neurônios na camada oculta (*nn*), a seleção do algoritmo de otimização (*AO*), e o número de delay (*nd*) sendo representado por:

$$\text{Minimizar } ER(nn, nd, AO) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

Sujeita a:

$$\begin{aligned} 5 &\leq nn \leq 200 \\ 2 &\leq nd \leq 7 \end{aligned}$$

O fato de se utilizar o AG diz respeito a função ser não linear e ao mesmo tempo considerar variáveis discretas. Por isso, evitou-se métodos clássicos de otimização que consideram derivadas e podem convergir para o primeiro mínimo local que encontrar.

3.3. Analisar os resultados obtidos e definir o modelo mais adequado

Por fim, são analisados os resultados oriundos das metodologias aplicadas e comparados com a metodologia utilizada pela empresa. Por meio da análise dos erros de previsão obtidos é definido qual o modelo mais eficaz para prever a demanda de cada uma das famílias de produtos estudada. As métricas de avaliação neste trabalho são dados pelo erro médio absoluto (MAE) e pelo erro percentual médio absoluto (MAPE), conforme equações (10) e (11), respectivamente:

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (10)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|e_i|}{Y_i} \times 100 \quad (11)$$

Sendo e_i a diferença do valor real com o valor previsto do i -ésimo período e Y_i é o valor real para o respectivo período.

4. RESULTADOS OBTIDOS

Nesta seção estão dispostos os resultados obtidos por meio da aplicação deste estudo.

4.1. Coleta e estruturação da base de dados

Conforme mencionado na metodologia, os dados coletados referem-se a cinco famílias de itens que são importados pela empresa estudada. Os mesmos foram classificados em famílias. Na Tabela 1 tem-se a demanda mensal dos itens estudados por mês no período analisado.

Tabela 1 – Demanda mensal distribuída por família de itens.
Fonte: os Autores (2022).

Período	Família 1	Família 2	Família 3	Família 4	Família 5
JAN/2017	70	52	55	1034	552
FEV/2017	349	125	122	3763	2218
MAR/2017	386	90	83	3190	1924
ABR/2017	347	150	113	3398	1857
MAI/2017	364	93	170	3371	1839
JUN/2017	416	95	103	3657	2104
JUL/2017	481	116	128	3890	2145
AGO/2017	640	111	162	4890	2794
SET/2017	474	45	59	3685	2149
OUT/2017	480	123	140	4129	2271
NOV/2017	366	105	154	3474	1913
DEZ/2017	263	31	152	2603	1473
JAN/2018	542	79	106	4800	2608
FEV/2018	442	127	84	3770	2217
MAR/2018	594	126	88	4765	2556
ABR/2018	538	83	89	4384	2329
MAI/2018	478	141	81	3356	2257
JUN/2018	532	210	116	4908	2876
JUL/2018	501	157	127	4408	2406
AGO/2018	716	184	131	4418	2306
SET/2018	637	117	116	3926	2295
OUT/2018	636	99	116	4518	2527
NOV/2018	537	140	139	2832	1759
DEZ/2018	530	99	101	2675	1637
JAN/2019	584	92	56	2786	1565
FEV/2019	573	183	72	2873	1607
MAR/2019	557	87	92	3438	1958
ABR/2019	603	87	101	3591	2518
MAI/2019	653	167	149	4172	2356
JUN/2019	561	106	126	3126	1679
JUL/2019	737	119	133	3800	2113

Na Figura 4 é apresentada a demanda total de cada família de itens importados no período estudado.




Figura 4 – Demanda total por família de itens importados.
Fonte: os Autores (2022).

Nota-se por meio da Figura 4 que a família com maior demanda é a Família 4. A forma como é feito o planejamento para a aquisição dos materiais importados atualmente é baseada na média histórica de consumo dos itens importados nos últimos três meses somado ao estoque de segurança estipulado pela empresa referente ao volume de produção equivalente a um mês de matérias em estoque. A produção dos bens mencionados ocorre mediante pedido, sendo que a empresa não produz para estoque, permanecendo os materiais em estoque como matéria prima e não como produtos acabados aguardando venda.

4.2. Aplicação dos métodos de previsão de demanda e análise dos resultados obtidos

Nesta etapa foi realizado o cálculo da previsão de demanda para cada uma das famílias de itens visando identificar o método que apresenta menor variação entre o previsto e o realizado. As equações aplicadas em cada modelagem seguem o referencial teórico.

Primeiro gerou-se os modelos de previsão RNA e RNA Otimizada, onde é possível observar os resultados estatísticos dos modelos de previsão. Posteriormente, gerou-se um comparativo entre o modelo ARIMA e Holt-Winters e consequentemente a média dos erros de previsões apresentados para cada modelo abordado no artigo. Os parâmetros encontrados com a otimização, via AG, estão apresentados na Tabela 2.

Tabela 2 – Parâmetros de otimização da RNA.
Fonte: os Autores (2022).

Modelos	Nº de neurônios	Nº de delay	Algoritmo de treinamento
FAMÍLIA 1	77	3	<i>Bayesian Regularization</i>
FAMÍLIA 2	58	4	<i>Bayesian Regularization</i>
FAMÍLIA 3	42	4	<i>Bayesian Regularization</i>
FAMÍLIA 4	65	3	<i>Bayesian Regularization</i>
FAMÍLIA 5	27	5	Levenbrg-Marquardt

Na Figura 5, tem-se para cada uma das famílias de itens as previsões geradas pelos métodos *versus* a demanda real.




Figura 5 – Demanda real versus prevista por cada um dos métodos.
Fonte: os Autores (2022).

É possível observar por meio da Figura 5 que durante o período analisado a Família 1 apresentou uma elevação no consumo, diferentemente das demais famílias, que mantiveram um consumo constante. Para todas as famílias, observou-se também que o modelo ARIMA apresenta resultados com dispersão maior em relação aos demais modelos aplicados. Já RNA e o modelo de Holt-Winters (HOLT) apresentarem resultados similares, enquanto a RNA otimizada apresentou melhor adaptação ao cenário real. Para o grupo de Famílias 2, 3, 4 e 5 apresentou-se os dados previstos no modelo ARIMA (0,0,0), gerando uma média prevista igual para os demais períodos, evidenciando a dificuldade do método ARIMA para previsão com os dados fornecidos.

Para cada uma das famílias de itens estudadas também foi gerado o cálculo de erros de previsão MAPE e MAE, de acordo com as equações (10) e (11), respectivamente. Na Figura 6 é possível observar os erros de previsão obtidos pelo método MAPE.




Figura 6 – Erros obtidos MAPE.

Fonte: os Autores (2022).

Para a Família 1 o método que apresentou maior erro foi o ARIMA e o método que apresentou menor erro foi a RNA otimizada. Já na Família 2 o maior erro ocorreu com a aplicação da RNA e o menor também foi obtido por meio da aplicação da RNA otimizada. Para Família 3, o maior erro foi com a metodologia ARIMA e o menor com a RNA otimizada. Na Família 4 o maior erro ocorreu por meio da aplicação da RNA sem otimização, enquanto que o menor erro foi para a RNA otimizada. Por fim, na Família 5 o maior erro foi na metodologia ARIMA e o menor foi obtido por meio da aplicação da metodologia RNA otimizada. Em todas as famílias é possível observar que a metodologia mais eficaz para realizar a previsão de demanda foi a RNA otimizada, uma vez que, a mesma apresentou menores percentuais de erro entre o previsto e o real. Na Figura 7 foi realizada a mesma análise por meio da aplicação MAE.




Figura 7 – Erros obtidos MAE.

Fonte: os Autores (2022).

Por meio da Figura 7, nota-se que assim como na metodologia MAPE, no método MAE, o menor erro entre o previsto e o realizado para todas as famílias de itens também foi obtido na metodologia de

RNA otimizada. Logo, é possível concluir que no estudo em questão a metodologia mais eficaz para prever a demanda das famílias de itens importados seria a aplicação de uma RNA otimizada.

5. CONSIDERAÇÕES FINAIS

Este trabalho realizou análise quantitativa entre quatro diferentes modelos matemáticos de previsão de demanda aplicados ao consumo de cinco famílias de produto importados de uma empresa metalúrgica. Realizou-se uma comparação entre os métodos Holt-Winters, ARIMA, RNA e RNA otimizada com o uso de AG. Os resultados obtidos proporcionaram uma comparação da acuracidade de dos métodos. Desta forma, por meio dos valores de MAPE e MAE gerados pelos modelos, pode-se averiguar que o método RNA otimizada apresentou dados com menor erro. Este fato pode se dever a adaptação do tipo de algoritmo a dados complexos.

Os resultados evidenciados revelaram que os modelos estudados podem apresentar uma boa previsão de demanda de uma forma geral. O modelo preditivo RNA otimizada demonstrou um melhor desempenho ao longo dos períodos em análise para todos os produtos avaliados, podendo ser envolvido efetivamente no dia a dia das organizações. O fato de não otimizar a RNA, pode gerar previsões com erros consideravelmente maiores. Desta forma, para este tipo de aplicação, recomenda-se o uso da otimização como ferramenta associada a modelagem matemática de previsão.

Para pesquisas futuras e continuidade da pesquisa, recomenda-se aprofundar o assunto em relação a custos de armazenagem, fretes especiais e impactos junto aos clientes por desabastecimento de materiais. Também, sugere-se avaliar com detalhes o filtro do ARIMA, de forma a verificar o comportamento do método para os presentes dados.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES).

6. REFERÊNCIAS

BARROW, Devon K.; KOURENTZES, Nikolaos. Distributions of forecasting errors of forecast combinations: Implications for inventory management, **International Journal of Production Economics**, v. 177, p. 24-33, 2016.

BITTENCOURT, Guilherme. **Inteligência artificial: ferramentas e teorias**. 2. ed. Florianópolis: UFSC, 2001.

BORSATO, Renan.; CORSO, Leandro 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. **Time Series Analysis: Forecasting and Control**. Holden Day, San Francisco: Google Scholar, 1976.

CORSO, Leandro L.; WALLACE, Mark. A hybrid method for transportation with stochastic demand. **International Journal of Logistics**, v. 18, p. 1-13, 2015.

DEZORDI, B.; SILVA, M. M. D.; RIBEIRO, R.P.R. Previsão de 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

EFENDIGIL, Tuğba; ÖNÜT, Semih; KAHRAMAN, Cengiz. A decision support system for demand forecasting with artificial neural Networks and neuro-fuzzy models: A comparative an alysis. **Expert Systems With Applications**, v. 36, n. 3, p. 6697-6707, 2009.

FACELI, Katti; LORENA, Ana Carolina; GAMA, João; CARVALHO, André C. P. L. F. de. **Inteligência artificial: uma abordagem de aprendizagem de máquina**. Rio de Janeiro: LTC, 2011.

FATTAH, Jamal; EZZINE, Latifa; AMAN, Zineb; MOUSSAMI, Haj El; LACHHAB, Abdeslam. Forecasting of demand using ARIMA model. **International Journal Of Engineering Business Management**, [S.L.], v. 10, p. 1-9, jan. 2018.

FAVA, V. L. **Manual de econometria: nível intermediário**. In Vasconcellos, M. A S.; Alves, D. São Paulo: Atlas, 2000.

FERNANDES, Flavio Cesar Faria; FILHO, Moacir Godinho. **Planejamento e controle da produção, dos fundamentos ao essencial**. São Paulo, ATLAS 2009.

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, 14 nov. 2022.

HAYKIN, Simon. **Redes neurais princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

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

LIU, Huai; CHEN, Chao, et al. Deterministic wind energy forecasting: A review of intelligent predictors and auxiliary methods, **Energy Conversion and Management**, v. 195, p. 328-345, 2019.

LIN, Chin-Tsai; LEE, In-Fun. Artificial intelligence diagnosis algorithm for expanding a precision expert forecasting system. **Expert Systems With Applications**, v..36, n. 4, p.8385-8390, 2009.

MARTIN, John H.. **Neuroanatomia: texto e atlas**. 4. ed. Porto Alegre: AMGH, 2013.

MOREIRA, D. A. **Administração da produção e operações**. São Paulo: Pioneira, 2004.

MUELLER, A. Uma aplicação de redes neurais artificiais na previsão do mercado acionário. 1996 Dissertação (Mestrado em Engenharia de Produção) – Programa de Pós-graduação em Engenharia de Produção, UFSC, Florianópolis.

PEREA, Rafael G.; POYATO, Emilio C.; MONTESINOS, Pilar.; DÍAZ, Juan Antonio R. Optimisation of water demand forecasting by artificial intelligence with short data sets, **Biosystems Engineering**, v. 177, p. 59-66, 2019.

SHARPE, Norean R.; VEAUX, Richard D. de.; VELLEMAN, Paul F. **Estatística Aplicada**. Porto Alegre: Bookman, 2011.

SNELL, Richard S.. **Neuroanatomia clínica**. 7. ed. Rio de Janeiro: Guanabara Koogan, 2019.

STUDIE. Maturity Index eng WEB. Disponível em:
www.acatech.de/wpcontent/uploads/2018/03/acatech. Acesso em : 18Ago. 2022.

TRATAR, Liljana Ferbar. Joint optimization of demand forecasting and stock control parameters. **International Journal of Production Economics**, v. 127, n. 1, p. 173-179, 2010).

TRENTESAUX, Damien; BORANGIU, Theodor; THOMAS, André. Emerging ICT concepts for smart, safe and sustainable industrial Systems. **Computers in Industry**, v. 81, p. 1-15, 2016.

TUBINO, Dalvio Ferrari. **Manual de planejamento e controle da produção**. São Paulo: Atlas, 2009.

VERÍSSIMO, A. J., et al. Métodos estatísticos de suavização exponencial Holt-Winters para previsão de demanda em uma empresa do setor metal mecânico. **Revista Gestão Industrial**, [S.L.], v. 8, n. 4, p. 1-18, fev. 2013.

VERRUCK, F.; BAMPI, R. E.; MILAN, G. S. **Previsão de demanda em operações de serviços**: Um estudo em uma empresa do setor de transportes. SIMPOI, 2009.

ZANELLA, C.; VIEIRA, V.; BARICHELLO, 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.

ZHENG, Yini; FU, Qi; LI, Juan; ZHANG, Lianmin. Demand forecasts with judgement bias in a newsvendor problem. **International Journal Of Production Research**, [S.L.], p. 1-15, 16 ago. 2022. Disponível em:
https://www.researchgate.net/publication/362735309_Demand_forecasts_with_judgement_bias_in_a_newsvendor_problem. Acesso em: 13 nov. 2022.

ZHOU, Zhong-Bing ; DONG, Xiu-Cheng. Analysis about the seasonality of China's crude oil import based on X-12-ARIMA, **Energy**, v. 42, n.1, p.281-288, 2012.

ZHU, X.; ZHANG, G., SUN, B. A comprehensive literature review of the demand forecasting methods of emergency resources from the perspective of artificial intelligence. **Nat Hazards**, v.97, n.1, p. 65-82, 2019.