

Aplicação de Inteligência Artificial e ARIMA na Previsão de Demanda no setor metal mecânico

Renan Borsato e Leandro Luís Corso

Resumo

A utilização de modelos de previsão de demanda é uma maneira de obter-se vantagens competitivas e melhorar o gerenciamento de recursos produtivos. Identificar qual modelo de predição utilizar pode facilitar o dia-a-dia e o planejamento estratégico. Este estudo tem por objetivo realizar a aplicação de métodos de previsão de demanda em uma empresa que atua no setor metal mecânico. Propõe-se a comparação do modelo ARIMA (Auto Regressive Integrated Moving Averages) com o modelo de Redes Neurais Artificiais (RNA). Para a utilização das RNA se desenvolveu um modelo matemático de otimização capaz de encontrar a melhor quantidade de neurônios e função matemática de treinamento e *delay* da rede por meio de Algoritmos Genéticos, minimizando os erros de previsão. A partir da comparação dos métodos, observou-se que o modelo RNA otimizado apresentou menor percentual de erro, aumentando a confiabilidade e aceitabilidade do modelo. O desempenho e comparativo estatístico dos métodos foram avaliados a partir do MAPE e MAE.

Palavras-chave

Indústria 4.0, estocasticidade dos dados; previsão de demanda.

Artificial Intelligence and ARIMA application in Demand Forecasting in the metal-mechanic branch

Abstract

Using demand forecasting models is a way of gaining competitive advantage and improving productive resource management. Identifying which prediction model to use can facilitate day-to-day and strategic planning. This study aims to perform the application of demand forecasting methods in a company that operates in the metalworking sector. It is proposed to compare the Auto Regressive Integrated Moving Averages (ARIMA) model with the Artificial Neural Networks (RNA) model. For the use of ANNs, a mathematical optimization model was developed capable of finding the best amount of neurons and mathematical training and delay function of the network through Genetic Algorithms, minimizing the prediction errors. From the comparison of the methods, it was observed that the optimized RNA model presented lower error percentage, increasing the model reliability and acceptability. The performance and statistical comparison of the methods were evaluated from the MAPE and MAE.

Keywords

Industry 4.0, stochasticity of data; demand forecasting.

I. INTRODUÇÃO

Nos últimos anos, diversas pesquisas sobre modelos de previsões de demanda foram conduzidos com diferentes técnicas, as quais sobressaem-se sob duas categorias: técnicas de computação estatística e de técnicas de Inteligência Artificial [1]. Em virtude da redução de custos de produção ser o ponto chave do planejamento das indústrias, uma vez que, a incerteza do futuro de vendas é o principal obstáculo para maximizar a eficiência produtiva [2].

A previsão de demanda pode ser considerada um importante suporte à tomada de decisão, que integra o gerenciamento de processos de negócios das instituições com o objetivo em estimar a demanda futura a partir de dados históricos e o estudo atual do ambiente, formando a base das decisões gerenciais, logísticos e gerenciamento da cadeia de suprimentos, independentemente do tipo de

processo [3]. Na literatura, encontra-se diversas técnicas propostas de previsões de demanda em geral, tais quais, não pode-se afirmar qual técnica deve ser usada para os problemas de previsão. Contudo, o modelo de previsão Redes Neurais Artificiais (RNA) apresenta superioridade literária nos últimos anos [4].

Um ponto fundamental na construção de modelos de previsão é encontrar uma distribuição de probabilidade subjacente para representar a incerteza. As previsões de demanda formam a base de decisões gerenciais, sendo o ponto de partida para o planejamento e execução de processos [5 e 6]. Os processos estocásticos das séries temporais, quando utilizados para previsão de processos univariados, visam identificar valores recentes para previsão do próximo período baseado em modelos computacionais recursivos [7].

Por conseguinte, a Indústria 4.0 está entrelaçada a integração de novas tecnologias, juntando a produção enxuta

a nova revolução industrial com a finalidade de aumentar performances operacionais e financeiras a um nível significativamente mais elevado [8]. Permitindo que os profissionais determinem o status real da instituição dentro da cadeia de suprimentos e possam realizar previsões em seus dados de entrada, apoiando o objetivo geral de aprimorar a satisfação do cliente [9].

Neste trabalho foi realizada a previsão da demanda das cinco principais famílias de produtos de uma empresa do ramo metalomecânico, associados a uma previsão de demanda, tendo como base um histórico de faturamento dos últimos 4 anos para apoiar o planejamento estratégico da cadeia de suprimentos, para a determinação do modelo de previsão, foi realizada uma comparação do modelo ARIMA (*Auto Regressive Integrated Moving Averages*) e RNA. O modelo de RNA é o *NonLinear Autoregressive*, e se obteve o número de neurônios, número de *delays* e o tipo de algoritmo de treinamento otimizados por um modelo matemático de minimização de erros de previsão, que utiliza o método dos Algoritmos Genéticos (AG).

II. REFERENCIAL TEÓRICO

A. Indústria 4.0

Na Indústria 4.0, apresenta o conceito de fábricas independentes e promove-se a compreensão global a emergir nesta linha de pensamento dia-a-dia [10]. O que é recomendado para empresas e países mais conectados em todo o mundo por meio de cadeias de suprimentos e redes de sensores. A fim de superar os obstáculos, permitindo-se que as empresas transfiram suas ideias, bem como os respectivos sistemas, incluindo o *software* com redes de manufatura protegidas [10]. A quarta revolução industrial continua transformando a força de trabalho industrial, contudo, não significa que o ser humano possa ser substituído por máquinas (robôs). Como alcançar a integração perfeita entre humanos e máquinas, e aproveitar todo o potencial humano, são questões críticas para o sucesso da Indústria 4.0 [11].

Para métodos estatísticos inteligentes, propõe-se a previsão com métodos estocásticos. Tais métodos referem-se à utilização da teoria matemática, conhecimentos estatísticos, teoria das probabilidades e processos estocásticos [12]. Com o desenvolvimento de aprendizado de máquina e inteligência artificial, modelos inteligentes de previsão otimizados estão sendo cada vez mais utilizados em estudos de previsão de demanda, principalmente em indústrias que propõem um novo conceito em suas organizações [12].

A metodologia da Indústria 4.0 define-se em transformar a manufatura dominante por máquinas em manufatura digital. Esta transformação está abrindo as portas para novas tecnologias aplicadas à indústria, robôs inteligentes, manufatura aditiva e híbrida, simulação virtual, integração de sistemas, internet das coisas, *big data* e *analytics*, *cloud computing*, sistemas cyber-físicos e realidade aumentada, são conhecidos como os pilares da nova revolução industrial, um grande desafio para as empresas é determinar o nível de maturidade dentro da Indústria 4.0 [10 e 8].

A Inteligência Artificial (IA), está cada vez mais tomando forma nas empresas, dado que, por meio de algoritmos

capazes de se adaptar a dados, apresenta níveis de maturidade [13]:

- a) IA Limitada: que possui funções inteligentes básicas para completar uma tarefa industrial;
- b) IA Geral: onde um sistema industrial tem a capacidade de raciocinar e decidir como ser humano;
- c) IA Superinteligente: no qual define-se como mais inteligente que seres humanos em quase todos os domínios.

Como suporte e base para elevar o nível de maturidade das indústrias, se faz necessário a associação da Indústria 3.0 com a Indústria 4.0, principalmente o conceito de *lean production* destaca-se em pesquisas de gestões de operações, tornando-se possível a personalização no design, planejamento, produção, mudanças de últimas horas, por meio da interconectividade para agilidade na tomada de decisão, onde pequenos lotes de produção podem se tornar lucrativos [8 e 9].

B. Estocasticidade dos Dados

Para aprimorar as pesquisas de gestão de operações, utiliza-se medidas de eficiência estocásticas com dados correlacionados. Estes dados são aplicados com a finalidade de medição do desempenho passado, usando as entradas consumidas e as saídas produzidas durante um determinado período de tempo, estes dados também são utilizados a fim de planejamento e controle de produção [14].

A previsão de demanda do mercado de reposição está entrelaçada a cadeia de suprimentos de peças automotivas, sendo este difícil de monitorar devido à complexidade dos fatores externos, RNA são os métodos mais utilizados para a resolução de problemas que envolvem aprendizagem e reconhecimento de padrões [15].

C. Métodos de Previsão de Demanda

Dentro deste contexto, 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 [3].

Para a realização destas análises temporais, utiliza-se os modelos de previsão de demanda Box-Jenkins, também conhecidos como ARIMA [16]. Que 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 [16]. Os modelos de previsão ARIMA foram desenvolvidos para serem utilizados em análises de dados temporais com padrão forte de sazonalidade, bem como a demanda de peças automotivas de reposição. Um dos modelos de previsão de demanda mais utilizados atualmente dentro da IA são as RNA, onde os modelos de previsão de IA podem ser otimizados pela utilização de algoritmos evolutivos [7].

A última etapa para medir os modelos de previsão de demanda, utiliza-se modelos estatísticos para calcular o desempenho dos modelos a partir do erro de previsão. 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 [7].

III. MATERIAL E MÉTODO

Tendo em vista a proposta de trabalho, utilizou-se para o estudo dados do faturamento mensal dos últimos quatro anos. Posteriormente, gerou-se as previsões de demanda apresentados pelo modelo ARIMA e por RNA respectivamente, segue abaixo de forma reduzida a pesquisa realizada.

a) **Dados de entrada:** Os dados de entrada utilizados para o desenvolvimento do artigo foram agrupadas nas cinco principais famílias de produtos comercializados pela empresa estudada, durante o período de 01 de Janeiro de 2016 à 30 de Abril de 2019, de acordo com a Tabela 3, em anexo.

b) **Modelo ARIMA:** Para a representação do modelo, onde é possível observar que não se trata de um modelo estacionário, foi utilizada a seguinte equação para a demonstração do modelo ARIMA [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.

Os métodos ARIMA (p, d, q) são modelos baseados em identificação, estimativa, diagnóstico e previsão, onde “p” são os parâmetros dos números de defasagem, “d” refere-se ao grau e “q” a ordem do modelo de média móvel [16].

c) **Redes Neurais Artificiais:** Para este método, de acordo com [20], o modelo de RNA de previsão apresentado para os dados não lineares é representado da seguinte forma:

$$O_k = \varphi \left(\sum_{j=1}^q \omega_{jk} \cdot \phi \left(\sum_{i=1}^p \omega_{ij} \cdot x_i \right) + b_k \right) \quad (2)$$

Onde q e n são os números de neurônios de entrada e neurônios ocultos, respectivamente; ω representa o peso entre diferentes camadas; a_j e b_k são os limites da camada oculta e da camada de saída, respectivamente; ϕ e φ são as funções de motivação da camada oculta e da camada de saída, respectivamente [12].

Este modelo de RNA é utilizado para resolução de problemas de séries temporais não estacionárias. Segue abaixo Figura 1, representando um modelo RNA típico de uma multicamada [12].




Figura 1: Estrutura de RNA

O método RNA constitui-se de etapas principais, treinamento, teste e validação a partir dos dados de entrada.

O desempenho dos modelos estatísticos ARIMA e RNA podem ser avaliados usando indicadores principais para comparação dos métodos [4]:

- 1) Erro percentual médio absoluto (MAPE);
- 2) Erro médio absoluto (MAE);

Apresentou-se o MAPE e MAE de cada família de produto, seguindo as seguintes equações:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|e_i|}{Y_i} \times 100 \quad (3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (4)$$

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

d) **Backpropagation:** Para este trabalho, a RNA foi otimizada com relação a quantidade de neurônios (n), algoritmo de treinamento do modelo de previsão e *delays*. Buscou-se a minimização do erro de previsão, ou seja, uma função objetivo que minimize as diferenças entre os resultados apresentados pelo modelo e pelos dados realizados, este processo é conhecido como *backpropagation*. Como padrão, em todas as análises realizadas neste trabalho, os dados foram distribuídos de forma aleatória em 70% como treinamento, 15% teste e 15% como validação. Para implementar o AG na RNA, converteu-se as soluções de matrizes em vetores concatenados juntos. A quantidade de neurônios variou de 5 até 150, o número de *delay* de 2 a 7 e os algoritmos de treinamentos utilizados foram: Levenberg-Marquardt (LM), *Bayesian Regularization* (BR) e *Scaled Conjugate Gradiente* (SCG).

O algoritmo de treinamento LM, de acordo com [17], pode ser descrita conforme a equação (5):

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (5)$$

Onde J é a matriz jacobiana que recebe e controla as primeiras derivadas dos erros da RNA, μ é a taxa de aprendizagem. Este algoritmo pode ser considerado eficiente para redes menores, no qual, utiliza-se o método de *Newton* que aproxima o erro de rede usando uma relação de segunda ordem [18].

A técnica de regularização BR baseia-se de acordo com a regra de *Bayes*, representada pela equação (6):

$$p(\Theta|D, M) = \frac{p(D|\Theta, M) p(\Theta|M)}{p(D|M)} \quad (6)$$

Onde D é conjunto de dados de treinamento e M é a forma funcional apresentada do modelo.

Para problemas de grande escala, sugere-se a utilização do algoritmo de treinamento SCG, por abordar aproximações quadráticas com expansões da série de *Taylor* para minimizar a função [18]. Sendo expressa pelas equações seguintes:

$$\alpha_k = \frac{-d_k^T E'_q(\theta_1)}{d_k^T s_k} \quad (8)$$

$$s_k = E''(\theta_k) d_k \approx \frac{E'(\theta_{t,k}) - E'(\theta_k)}{y_k} \quad (7)$$

Sujeita a:

$$0 < y_k \ll 1$$

Onde s_k refere-se a informação de segunda ordem; α_k representa o tamanho do passo do treinamento; E e E' são a primeira e segunda derivadas da função de erro em relação aos respectivos vetores de peso; d_k é o conjugado vetor de peso temporal k-ésimo período, sendo d_k^T a transposta de d_k .

O modelo matemático de otimização desenvolvido para a minimização do erro quadrático médio da previsão realizada pela RNA considerada variáveis e restrições. As variáveis deste modelo de otimização são o número de neurônios (nn) e o número de períodos de *delay* (nd). De forma, o modelo pode ser escrito como:

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

Sujeita a:

$$\begin{aligned} 5 &\leq nn \leq 150 \\ 2 &\leq nd \leq 7 \end{aligned}$$

Onde y_i é o valor real do i-ésimo período e \hat{y}_i é o valor predito para o respectivo período. O *AT* se refere ao algoritmo de treinamento da rede, sendo um parâmetro discreto de otimização.

Para representar o AG, utilizou-se um pseudocódigo que

representa uma linguagem intermediária entre a linguagem natural e a linguagem de programação de algoritmos. Segue na Figura 2, onde pode-se verificar o pseudocódigo utilizado, adaptado de [2].

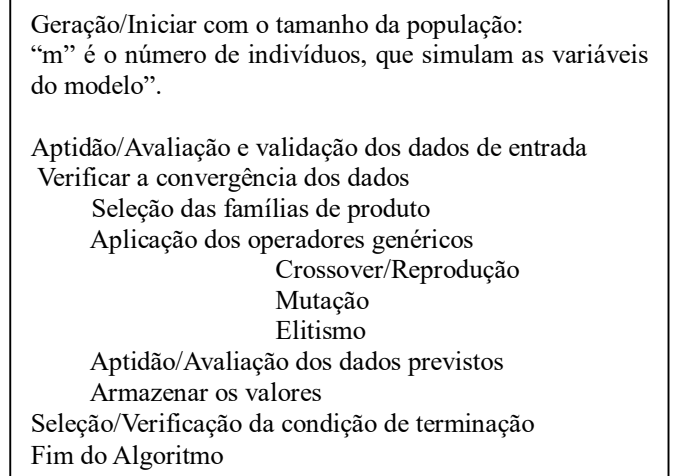


Figura 2: Pseudocódigo do AG

Para este modelo matemático de otimização considerou-se 50 indivíduos e 50 gerações, sendo que o critério de parada foi o final das gerações.

IV. RESULTADOS

Primeiramente, gerou-se o modelo de previsão ARIMA, onde pode-se observar as estatísticas do modelo, de acordo com a Tabela 1 e Tabela 2, onde apresentou-se as estatísticas do modelo de previsão:

Consideraram-se todas as variações possíveis do modelo ARIMA, obtendo a seguinte configuração como resultado dos menores erros. Segue abaixo a descrição do modelo ARIMA com o tipo respectivamente:

Tabela 1 – Tipos de modelo ARIMA

VAR00001	FAMÍLIA 1	ARIMA(0,1,0)
VAR00002	FAMÍLIA 2	ARIMA(0,1,0)
VAR00003	FAMÍLIA 3	ARIMA(0,0,0)
VAR00004	FAMÍLIA 4	ARIMA(1,0,0)
VAR00005	FAMÍLIA 5	ARIMA(1,0,0)

Tabela 2: Resultados do modelo ARIMA

Modelo	Nº de preditores	R-quadrado estacionário	R-quadrado	MAPE	MAE
FAMÍLIA 1	0	0	0,846	57,07	1277,95
FAMÍLIA 2	0	2,22E-16	0,927	35,89	994,24
FAMÍLIA 3	0	-2,22E-16	-2,22E-16	63,60	2143,90
FAMÍLIA 4	0	0,276	0,276	16,35	13620,41
FAMÍLIA 5	0	0,139	0,139	19,64	8975,04

Posteriormente, gerou-se um comparativo entre o modelo ARIMA e RNA, e consequentemente a média dos erros de previsões apresentados para cada modelo abordado no artigo.

Na Tabela 3 estão apresentados os parâmetros obtidos com a otimização da RNA para cada um dos produtos.

Tabela 3: Parâmetros de Otimização da RNA

Modelos	Nº de neurônios	Nº de delay	Algoritmo de treinamento
FAMÍLIA 1	22	3	Levenberg-Marquardt
FAMÍLIA 2	34	2	Levenberg-Marquardt
FAMÍLIA 3	30	5	Bayesian Regularization
FAMÍLIA 4	58	5	Bayesian Regularization
FAMÍLIA 5	36	3	Levenberg-Marquardt

Para as duas primeiras famílias de produtos estudadas, verificou-se que durante o ano de 2016, a empresa apresentou uma queda elevada de vendas e nos demais períodos se manteve constante. Analisando os dois modelos, observou-se que o modelo ARIMA demonstra os resultados de previsões com defasagem em relação aos dados realizados, conforme apresentado no Figura 3 e Figura 4. Já as RNA, embora com curvas mais suaves, se adaptaram melhor a estocasticidade dos dados.

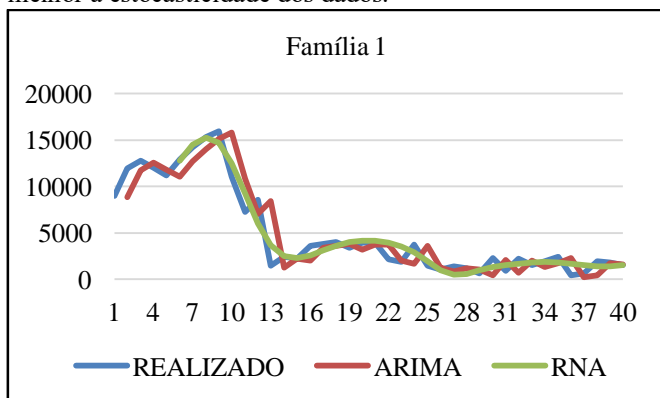


Figura 3: Comparativo dos modelos da família 1




Figura 4: Comparativo dos modelos da família 2

Para o grupo de família 3, apresentou-se os dados previstos do modelo ARIMA (0,0,0), conforme descrito na Tabela 1, gerando uma média prevista igual para os demais períodos, este dado foi obtido devido aos picos de sazonalidade dos primeiros dados apresentados de entrada. Este fato evidencia a dificuldade do método ARIMA para previsão com a estocasticidade presente nestes dados. Contudo, o modelo RNA apresentou dados válidos aos dados de entrada, conforme apresentado no Figura 5.




Figura 5: Comparativo dos modelos da família 3

Para os grupos de famílias 4 e 5, ambos os modelos apresentaram dados compatíveis de previsão de demanda, conforme demonstrado no Figura 6 e Figura 7.




Figura 6: Comparativo dos modelos da família 4




Figura 7: Comparativo dos modelos da família 5




Figura 8: Comparativo MAPE




Figura 9: Comparativo do MAE

De acordo com as Figura 8 e Figura 9, por fim, gerou-se os comparativos referentes aos erros previsões apresentados para cada modelo, obteve-se os dados de acordo com as

equações (3) e (4), sendo possível identificar os erros apresentados para cada família de produto estudada.

Por conseguinte, com o comparativo dos erros de previsões, pode-se observar que o modelo de Redes Neurais

Artificiais apresentou menores percentuais em relação ao modelo ARIMA.

V. CONCLUSÕES

Este trabalho buscou propor um método de previsão de demanda, com dados obtidos por meio do histórico de vendas das cinco principais famílias de produto de uma empresa metalúrgica, realizou-se um comparativo entre os métodos ARIMA e RNA, onde a RNA foi otimizada através de um AG.

Os resultados obtidos no comparativo foram evidenciados e relacionados aos dados realizados. No qual, por meio do erro de previsão entre os modelos, pode-se averiguar que o método RNA apresentou dados com menor percentual de erro absoluto.

Assim como em [1], os resultados revelaram tanto o modelo ARIMA e o modelo RNA otimizado podem apresentar uma boa previsão de demanda, mesmo o modelo ARIMA apresentando dados não satisfatórios nos dados previstos da família 3, neste caso sugere-se a verificação dos dados de entrada e do modelo de previsão. O modelo preditivo RNA otimizada demonstrou um melhor desempenho ao longo dos períodos em análise pode ser envolvido efetivamente no dia-a-dia das organizações.

Também é possível analisar a superioridade do modelo RNA em [4], no qual fica evidenciado a importância do número de períodos e neurônios de entrada e saída para a obtenção de uma previsão com menor percentual de erro.

Desta forma, apesar do modelo ARIMA ser utilizado há décadas, conclui-se, que o modelo RNA apresentou dados bem-sucedidos de previsão. Para o novo conceito de Indústria 4.0, sugere-se a empresa estudada, a utilização deste modelo de previsão de demanda. Esta pesquisa pode auxiliar significativamente as empresas que desejam utilizar os métodos abordados em seus planos gerenciais.

Para melhorar o modelo de previsão, propõe-se modificações do treinamento da RNA, tais como, maior volume de dados de treinamento, teste com outros parâmetros de treinamento, examinar mais métodos de aprendizagem de máquina, como o algoritmo evolutivo utilizado para resolver problemas de otimização de multiobjetivo (NSGA II).

VI. BIBLIOGRAFIA

- [1] Adebisi, A.; Adewumi, A.; Ayo, C. "Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction," *Journal of Applied Mathematics*, pp. 1-7, 2014.
- [2] Corso, Leandro L.; Wallace, Mark. "A hybrid method for transportation with stochastic demand," *International Journal of Logistics*, v. 18, pp. 1-13, 2015.
- [3] Merkurjeva, G.; Valberga, A., Smirnov, A. "Demand forecasting in pharmaceutical supply chains: A case study," *Procedia Computer Science*, vol 149, pp. 3-10, 2019.
- [4] Hamzaçebi, C.; Es, H.A. & Çakmak. "Forecasting of Turkey's monthly electricity demand by seasonal artificial neural network," *Neural Computing and Applications*, v. 31, pp. 2217-2231, 2019.
- [5] Rahimian, H.; G. Bayraksan; T. Homem-de-Mello, "Identifying Effective Scenarios in Distributionally Robust Stochastic Programs with Total Variation Distance," *Mathematical Programming*, vol 173, pp. 393 – 430, 2019.
- [6] Merkurjeva, G.; Valberga, A.; Smirnov, A. "Demand forecasting in pharmaceutical supply chains: A case study," *Procedia Computer Science*, vol 149, pp. 3-10, 2019.
- [7] Xu, Shuojiang; Chan, Hing Kai; Zhang, Tiantian. "Forecasting the demand of the aviation industry using hybrid time series SARIMA-SVR approach," *Logistics and Transportation Review*, vol 122, pp. 169-180, 2019.
- [8] Rossini, M.; Costa, F.; Tortorella, GL et al. "The interrelation between Industry 4.0 and lean production: an empirical study on European manufacturers," *International Journal of Advanced Manufacturing Technology*, vol 102, pp. 3963–3976, 2019.
- [9] Bär, K.; Herbert-Hansen; Z. N. L.; & Khalid. "Considering Industry 4.0 aspects in the supply chain for an SME," *Production Engineering*, vol 12(6), pp. 747-758, 2018.
- [10] Oztemel, E.; Gursev, S. "Literature review of Industry 4.0 and related Technologies," *Journal of Intelligent Manufacturing*, pp. 1-56, 2018.
- [11] Kong, X.T.R.; Luo, H.; Huang, G.Q.; Yang, X. "Industrial wearable system: The human-centric empowering technology in Industry 4.0," *Journal of Intelligent Manufacturing*, vol 17, pp. 1–17, 2018.
- [12] Liu Huai; Chen Chao, et al. "Deterministic wind energy forecasting: A review of intelligent predictors and auxiliary methods," *Energy Conversion and Management*, v. 195, pp. 328-345, 2019.
- [13] Zhang, X.; Ming, X.; Liu, Z. et al. "A reference framework and overall planning of industrial artificial intelligence (I-AI) for new application scenarios," *International Journal of Advanced Manufacturing Technology*, vol 101, pp. 2367–2389, 2019.
- [14] Kao, Chiang; Liu, Shiang-Tai. "Stochastic efficiency measures for production units with correlated data," *European Journal of Operational Research*, vol 273 (1), pp. 278-287, 2019.
- [15] Afolabi, Mark O.; Olude, Olatoyosi. "Predicting Stock Prices Using a Hybrid Kohonen Self Organizing Map (SOM)," *Proceeding of 40th International Conference on Systems Sciences*, 1560-1605, 2007.
- [16] G.E.P. Box; G.M. Jenkins. "Time Series Analysis: Forecasting and Control," *Holden Day*, San Francisco. Google Scholar, 1976.
- [17] Hosseinzadeh Talae, P. "Multilayer perceptron with different training algorithms for streamflow forecasting," *Neural Computing and Applications*, v. 24, pp. 695-703, 2014.
- [18] Mustafa, M.R.; Rezaur, R.B., Saiedi, S. et al. "River Suspended Sediment Prediction Using Various Multilayer Perceptron Neural Network Training Algorithms - A Case Study in Malaysia," *Water Resources Management*, v. 26, pp. 1879-1897, 2012.

VII. ANEXOS

Tabela 3 – Dados de Entrada

PERÍODO	FAMILIA 1	FAMILIA 2	FAMILIA 3	FAMILIA 4	FAMILIA 5
jan/16	9.000	13.036	3.476	92.714	35.165
fev/16	11.938	13.908	13.557	92.392	56.186
mar/16	12.741	14.214	6.745	107.568	56.301
abr/16	11.985	14.989	7.079	97.105	37.876
mai/16	11.213	16.501	6.386	103.891	59.878
jun/16	12.893	13.643	7.804	135.955	71.541
jul/16	14.220	15.158	13.946	99.108	62.182
ago/16	15.314	11.167	6.543	130.754	47.837
set/16	15.968	11.436	4.770	91.058	45.235
out/16	11.031	10.567	5.352	97.319	51.216
nov/16	7.253	7.687	4.677	92.828	33.020
dez/16	8.591	6.527	5.910	85.988	51.185
jan/17	1.443	7.790	851	79.531	30.838
fev/17	2.408	2.594	2.872	68.341	32.568
mar/17	2.225	3.199	2.486	85.257	47.606
abr/17	3.609	3.473	4.181	74.064	32.564
mai/17	3.767	2.787	2.375	84.119	32.853
jun/17	4.006	1.962	3.995	87.972	47.091
jul/17	3.385	1.441	2.979	96.199	50.621
ago/17	3.935	2.092	3.028	117.822	45.972
set/17	3.929	2.731	7.999	83.531	61.103
out/17	2.164	1.158	6.601	117.260	62.331
nov/17	1.854	993	8.839	91.213	51.658
dez/17	3.757	782	3.251	74.653	36.856
jan/18	1.472	623	2.796	57.020	35.575
fev/18	1.033	1.006	2.175	49.507	41.807
mar/18	1.399	1.035	5.527	68.467	52.811
abr/18	1.206	958	5.738	92.770	47.031
mai/18	607	1.160	1.839	77.968	44.430
jun/18	2.252	1.553	1.530	67.521	67.164
jul/18	878	791	5.357	98.317	52.461
ago/18	2.205	1.033	6.701	101.927	74.931
set/18	1.532	902	6.881	94.282	63.157
out/18	1.914	1.323	7.807	109.934	65.698
nov/18	2.439	1.781	6.149	88.747	42.338
dez/18	400	893	6.778	56.741	37.475
jan/19	592	1.775	3.116	49.734	37.000
fev/19	1.911	1.667	5.686	63.502	47.379
mar/19	1.802	2.278	2.562	73.296	50.036
abr/19	1.490	1.131	6.627	63.430	57.930

Tabela 4 – Dados Previstos ARIMA

PERÍODO	FAMILIA 1	FAMILIA 2	FAMILIA 3	FAMILIA 4	FAMILIA 5
1	8.807	12.731	5.324	87.006	48.852
2	11.745	13.603	5.324	89.990	43.647
3	12.548	13.909	5.324	89.822	51.641
4	11.792	14.684	5.324	97.757	51.685
5	11.020	16.196	5.324	92.286	44.678
6	12.700	13.338	5.324	95.834	53.045
7	14.027	14.853	5.324	112.598	57.481
8	15.121	10.862	5.324	93.333	53.922
9	15.775	11.131	5.324	109.879	48.466
10	10.838	10.262	5.324	89.125	47.477
11	7.060	7.382	5.324	92.398	49.751
12	8.398	6.222	5.324	90.050	42.831
13	1.250	7.485	5.324	86.474	49.739
14	2.215	2.289	5.324	83.098	42.001
15	2.032	2.894	5.324	77.247	42.659
16	3.416	3.168	5.324	86.092	48.378
17	3.574	2.482	5.324	80.239	42.658
18	3.813	1.657	5.324	85.497	42.768
19	3.192	1.136	5.324	87.511	48.182
20	3.742	1.787	5.324	91.812	49.525
21	3.736	2.426	5.324	103.118	47.757
22	1.971	853	5.324	85.189	53.511
23	1.661	688	5.324	102.824	53.978
24	3.564	477	5.324	89.206	49.919
25	1.279	318	5.324	80.547	44.290
26	840	701	5.324	71.328	43.803
27	1.206	730	5.324	67.400	46.173
28	1.013	653	5.324	77.313	50.358
29	414	855	5.324	90.020	48.160
30	2.059	1.248	5.324	82.281	47.170
31	685	486	5.324	76.819	55.816
32	2.012	728	5.324	92.920	50.225
33	1.339	597	5.324	94.807	58.770
34	1.721	1.018	5.324	90.810	54.292
35	2.246	1.476	5.324	98.994	55.259
36	207	588	5.324	87.916	46.375
37	399	1.470	5.324	71.182	44.525
38	1.718	1.362	5.324	67.519	44.345
39	1.609	1.973	5.324	74.717	48.292
40	1.490	1.131	5.324	79.838	49.302

Tabela 5 – Dados RNA

PERÍODO	FAMILIA 1	FAMILIA 2	FAMILIA 3	FAMILIA 4	FAMILIA 5
1					
2					
3					
4					
5					
6	12.742	14.493	9.790	127.342	66.806
7	14.496	13.420	9.055	121.547	60.919
8	15.282	12.223	7.962	115.303	55.712
9	14.670	10.946	6.675	108.677	51.190
10	12.503	9.649	5.397	101.961	47.262
11	9.259	8.392	4.311	95.698	43.728
12	5.990	7.217	3.512	90.585	40.328
13	3.634	6.134	2.983	87.245	36.934
14	2.473	5.120	2.619	85.991	33.868
15	2.256	4.138	2.314	86.713	32.089
16	2.582	3.186	2.042	88.931	32.713
17	3.111	2.354	1.894	91.943	36.078
18	3.617	1.828	2.067	94.978	41.453
19	3.976	1.789	2.811	97.297	47.750
20	4.138	2.167	4.296	98.180	54.112
21	4.110	2.457	6.339	96.814	59.309
22	3.914	2.067	7.984	92.204	60.074
23	3.530	1.129	7.430	83.510	51.723
24	2.884	518	3.905	71.324	38.327
25	1.956	618	843	59.122	34.935
26	996	907	2.077	52.095	43.734
27	477	1.014	5.439	53.476	52.732
28	563	1.129	5.732	62.697	51.141
29	947	1.284	3.489	76.463	44.502
30	1.296	1.238	3.422	90.699	47.890
31	1.516	1.005	5.149	101.735	61.917
32	1.662	887	6.777	106.583	75.185
33	1.778	1.043	7.489	103.444	76.556
34	1.841	1.285	7.190	92.779	64.628
35	1.806	1.361	6.154	78.105	48.422
36	1.668	1.282	4.851	64.853	38.777
37	1.490	1.282	3.830	57.302	38.619
38	1.366	1.586	3.587	56.542	44.423
39	1.372	2.286	4.428	61.163	51.967
40	1.534	3.348	6.397	68.971	58.773