

Aplicação de Inteligência Artificial e Modelos Matemáticos para Previsão de Demanda em uma indústria do ramo plástico

Daniela de Lima e Leandro Luís Corso

Resumo

As constantes mudanças nos hábitos dos consumidores de utensílios domésticos evidenciam a importância do gerenciamento dos estoques, a fim de reduzir o valor investido e evitar obsolescência. O planejamento estratégico das organizações depende da identificação e previsão correta das mudanças emergentes no mercado. Embora existam diferentes métodos desenvolvidos na leitura, uma das principais dificuldades que se encontra é a escolha do método mais apropriado a ser utilizado. Este estudo tem por objetivo realizar a aplicação de inteligência artificial e métodos matemáticos de previsão de demanda em uma empresa que atua no setor de plásticos e identificar qual técnica apresenta melhores resultados na acuracidade da previsão, onde foram analisadas 365 bases históricas de diferentes produtos. Apresenta-se a comparação de modelos matemáticos com o modelo Redes Neurais Artificiais (RNA). Para a utilização do modelo RNA se desenvolveu um modelo matemático de otimização capaz de encontrar a melhor quantidade de neurônios, função matemática de treinamento e *delay* da rede por meio de Algoritmos Genéticos, minimizando os erros de previsão. Por meio da análise dos resultados observou-se que o modelo RNA otimizado apresentou menor percentual de erro dos dados realizados quando comparados com os demais modelos aplicados nesse estudo. Desta forma aumentando a confiabilidade e aceitabilidade do modelo, podendo ser utilizado em casos similares. A performance e comparativo estatístico dos métodos foram realizados a partir do MAPE e MAE, onde constatou-se que em 95% das vezes o modelo de RNA com otimização determinou as melhores previsões.

Palavras-chave

Gestão de estoque, previsão de demanda; rede neural artificial.

Application for Artificial Intelligence and Mathematical Models for Demand Forecasting in a plastic industry

Abstract

The constant changes in the habits of household appliances consumers highlight the importance of inventory management in order to reduce the amount invested and avoid obsolescence. Strategic planning of organizations depends on identifying and accurately forecasting emerging market changes. One of the biggest difficulties with the use of demand forecasting is the choice of the forecasting method to be used. This study aims to carry out the application of artificial intelligence and mathematical methods of forecasting demand in a company that operates in the plastics sector and to identify which technique presents better results in the accuracy of the forecast, where 365 historical bases of different products were analyzed. The comparison of mathematical models with the Artificial Neural Networks (RNA) model is presented. For the use of the RNA model 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. Through the analysis of the results it was observed that the optimized RNA model presented smaller percentage of error of the data when compared with the other models applied in this study, increasing the reliability and acceptability of the model, being able to be used in similar cases. The performance and statistical comparison of the methods were evaluated from the MAPE and MAE, where it was found that 95% of the time the RNA model with optimization determined the best predictions.

Keywords

Inventory management, demand forecasting; artificial neural network.

I. INTRODUÇÃO

O constante crescimento da participação dos utensílios plásticos é uma tendência mundial em virtude da substituição de diversos materiais, especialmente vidro, madeira e metal pelo plástico devido ao seu custo benefício [1]. O ramo de produtos transformados de plástico no Brasil conta com 11.127 empresas, 312.934 empregos, produção física de 6,2 milhões de toneladas, representando um faturamento de R\$ 78,3 bilhões ao ano [2].

A concorrência se mostra severa e muitas vezes obriga as empresas a reduzirem os seus prazos de entrega sem sacrificar a qualidade e a competitividade de custos. Nesses casos a estratégia indicada é iniciar a produção antecipadamente mesmo sem ter pedidos confirmados, ou seja, produção por estoque Make to Stock – MTS [3]. Um dos maiores desafios no modelo MTS é definir os parâmetros de reposição de estoque quando os pedidos dos clientes não são conhecidos antecipadamente [4].

Os riscos de uma demanda futura incerta podem ser amenizados com uma previsão de demanda instituída com base em dados históricos e análise do cenário atual, estabelecendo premissas para as tomadas de decisões gerenciais, logísticas e gestão da cadeia de suprimentos [5].

Na literatura, apresentam-se inúmeras técnicas de previsão de demanda, onde, não se pode assegurar qual a melhor técnica a ser aplicada a fim de resolver os problemas de previsão. Entretanto, nos últimos anos as previsões realizadas com o modelo RNA apresentam crescimento nas citações literárias [6].

Inúmeros estudos como o citado em [7], demonstram aderência da previsão de demanda aos dados experimentais quando utilizou uma RNA para prever a demanda diária de um centro de tratamento de encomendas durante 15 dias. Estudos realizados com RNAs, conforme [5] também comprovaram a acurácia das RNAs em previsões, estimando por exemplo a demanda turística em Londres e Atenas, em que as RNAs mostraram um desempenho superior ao modelo ARIMA. O uso de RNAs também pode ser aplicado em previsões de demanda no ramo industrial como apresentado em [8] onde foram realizadas previsão em uma indústria do setor metalomecânico utilizando RNA otimizada por meio de um Algoritmo Genético (AG) e obteve-se resultados significativos nos erros de previsão de demanda.

Nesse trabalho foi realizada a previsão de demanda utilizando os modelos matemáticos clássicos e inteligência artificial, comparado os resultados de acuracidade de previsão dos métodos. Utilizou-se os métodos ARIMA, suavização exponencial simples, *holtz*, redes neurais artificiais e redes neurais artificiais otimizadas. Como dados de entradas para a realização das previsões foram utilizados os dados do histórico de vendas de 365 produtos que constituem a curva A de faturamento da empresa estudada.

II. REFERENCIAL TEÓRICO

A. Gestão de Estoque

A gestão de estoque tem por objetivo principal a rápida e adequada integração das necessidades percebidas no mercado na direção dos fornecedores, de modo a balancear e alinhar estrategicamente a demanda com a capacidade operacional ao longo da cadeia de suprimentos [9].

Em um ambiente de produção MTS a gestão de demanda toma uma importância maior ainda, pois existe uma dificuldade nesse ambiente em prover o grau de assertividade da previsão de demanda [10]. A seguir, os modelos de previsão de demanda utilizados no trabalho estão apresentados.

B. Previsão de Demanda

A previsão de demanda é um tópico de pesquisa bem estabelecido em muitas áreas, que utiliza dados do passado para fazer uma estimativa de valores ou variáveis para o futuro. Nas últimas décadas muitos estudos foram realizados para desenvolver novas abordagens de previsão e melhorar a precisão das previsões [11].

As técnicas de previsão podem ser agrupadas em métodos quantitativos, que são fundamentados em séries temporais históricas ou causais e os qualitativos que incluem estimativas subjetivas por meio da opinião de especialistas [7].

Os modelos de séries temporais podem ser presumidos por modelos matemáticos como por exemplo suavização exponencial, média simples, média móvel, Box & Jenkins. Enquanto as técnicas causais podem ser obtidas com a utilização de métodos, como, por exemplo, de regressão linear, regressão múltipla e inteligência artificial [12].

C. Rede Neural Artificial

Redes Neurais artificiais (RNA) fazem parte de uma área da ciência da computação ligada à inteligência artificial buscando implementar modelos matemáticos que representam as estruturas neurais humanas.

A ideia é reproduzir o processamento de informações do cérebro humano com um modelo artificial de neurônios, que tal como os pares biológicos, se unem funcionalmente com a utilização de conexões, formando, assim, as redes neurais artificiais [6].

A capacidade de aprendizado de uma RNA, para diferentes variáveis de entrada, torna-as capazes de resolver problemas muito complexos em diversas áreas do conhecimento. O desenvolvimento de uma RNA consiste em determinar sua arquitetura, isto é, os números de camadas e de neurônios em cada camada, bem como ajustar seus parâmetros livres, etapa conhecida como treinamento [13].

III. MATERIAL E MÉTODOS

Considerando-se a proposta de trabalho, utilizou-se para o estudo os dados do histórico mensal dos últimos 30 meses, posteriormente gerou-se as previsões de demanda pelo emprego de modelos matemáticos 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 365 produtos que constituem a curva A do faturamento dos produtos comercializados pela empresa estudada, durante o período Setembro de 2016 à de Março de 2019.

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 [14]:

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

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 [15].

c) Modelo Suavização Exponencial Simples:

O método aplica uma média ponderada nas observações de uma série temporal. Matematicamente o modelo é expresso conforme [16]:

$$F_{t+1} = F_t + \alpha \cdot (D_t - F_t) \quad (2)$$

Onde F_{t+1} é a previsão para $t + 1$, F_t é a previsão para o período t , D_t é a demanda realizada no período t e α é constante de suavização com valor entre 0 e 1.

d) Modelo Suavização Exponencial Dupla:

Este modelo também conhecido como modelo de *Holt* pode ser utilizado em series temporais com tendência linear. O modelo é expresso matematicamente conforme a equação (3).

$$F_{t+k} = A_t + k \cdot T_t \quad (3)$$

Onde A_t é a previsão para o período t , T_t é a tendência para o período [16].

e) Redes Neurais Artificiais: Para este método, de acordo com [17], o modelo de RNA de previsão apresentado para os dados não-lineares é representado da seguinte forma:

$$O_k = \varphi \left(\sum_{j=1}^q a_j \omega_{jk} \cdot \phi \left(\sum_{i=1}^p a_i \omega_{ij} \cdot x_i \right) + b_k \right) \quad (4)$$

Onde q e p 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 ativação da camada oculta e da camada de saída, respectivamente [17].

Este modelo de RNA é utilizado para resolução de problemas de séries temporais não estacionárias. Segue Figura 1, representando um modelo RNA típico de camada escondida (*hidden layers*) [17], que foi o modelo utilizado neste trabalho.




Figura 1: Estrutura de RNA

f) O método RNA possui etapas principais: treinamento, teste e validação a partir dos dados de entrada. Os dados foram distribuídos de forma aleatória em 70% como treinamento, 15% teste e 15% como validação. No modelo de RNA padrão utilizado aqui, considerou-se 10 neurônios e *delay* igual a 3 e o algoritmo de treinamento utilizado foi: *Levenberg-Marquardt* (LM).

O algoritmo de treinamento LM, de acordo com [18], pode ser descrita conforme a equação (7):

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

Onde J é a matriz jacobiana que recebe e controla as primeiras derivadas dos erros da RNA, μ é a taxa de aprendizagem. Neste caso x é a variável (ou conjuntos delas) que minimiza o valor da função, o termo e é o erro, neste caso é o erro de treinamento, I é a matriz identidade. 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 [19].

g) 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, a quantidade de neurônios variou de 10 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 Gradient* (SCG).

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.

Entretanto 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 [19]. Sendo expressa pelas equações seguintes:

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

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

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 vetor conjugado de peso temporal k-ésimo período, sendo d_k^T a transposta de d_k , e α_k é o passo do cálculo de otimização, que é feito a cada iteração do modelo.

O modelo matemático de otimização foi 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), e o algoritmo de treinamento (AT). Desta forma, o modelo matemático que representa o modelo de otimização pode ser escrito como:

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

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. 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 [20] e [21]. A implementação foi feita em linguagem 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
    Aplicação dos operadores genéticos
        Crossover/Reprodução
        Mutação
        Elitismo
    Aptidão/Avaliação dos dados previstos
    Armazenar os valores
Seleção/Verificação da condição de parada
Fim do Algoritmo
    
```

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

Inicialmente geram-se a previsão dos 365 produtos utilizando os modelos matemáticos chamados de clássicos, ou

seja: ARIMA, suavização exponencial simples e suavização exponencial dupla. Após isso, geraram-se as avaliações dos erros de cada um dos modelos de previsões.

O desempenho dos modelos estatísticos clássicos e RNA podem ser avaliados usando indicadores principais para comparação dos métodos [17]:

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

Foi calculado o MAPE e MAE de cada produto, de acordo com as seguintes equações:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|e_i|}{Y_i} \times 100 \quad (10)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (11)$$

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.

Para cada produto foram testados todos os modelos matemáticos descritos, e desta forma, indicado para cada produto o modelo que apresentou os menores erros ao longo da série histórica. Na Figura 3 pode-se observar o percentual dos modelos indicados como melhor previsão, avaliados com o MAPE. Neste caso, pode-se verificar que o ARIMA foi o melhor método em 57% das vezes.




Figura 3: Modelo Matemático Indicado

Em seguida gerou-se a previsão de demanda utilizando a RNA e por final a previsão com a RNA com o modelo de otimização por AG. Posteriormente, gerou-se um comparativo da média dos erros de previsões apresentados para cada modelo abordado no artigo, considerando também os melhores valores vindos dos modelos considerados clássicos. Ou seja, dos menores erros de previsão com os modelos clássicos e os erros gerados com a RNA padrão e otimizada, conforme apresentado na Figura 4 e Figura 5.

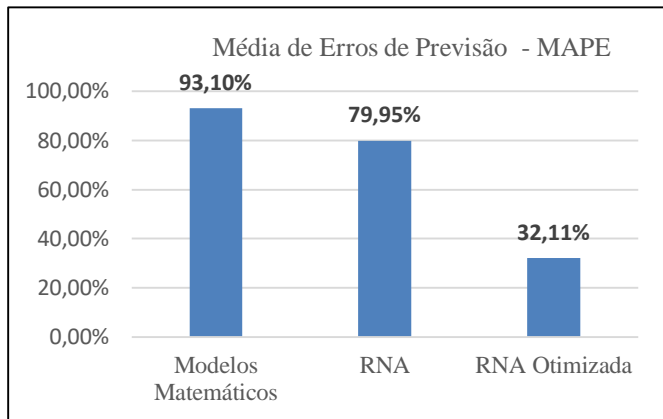


Figura 4: Média Erros de Previsão – MAPE




Figura 5: Média de Erro de Previsão- MAE

Realizou-se uma comparação entre os modelos matemáticos clássicos que geraram as melhores soluções e a RNA considerada padrão neste trabalho. Conforme pode-se observar na Figura 6 para 66,58% dos produtos o melhor método foi a RNA, em relação aos modelos matemáticos clássicos, que foram a melhor opção para 33,42% do total de produtos.

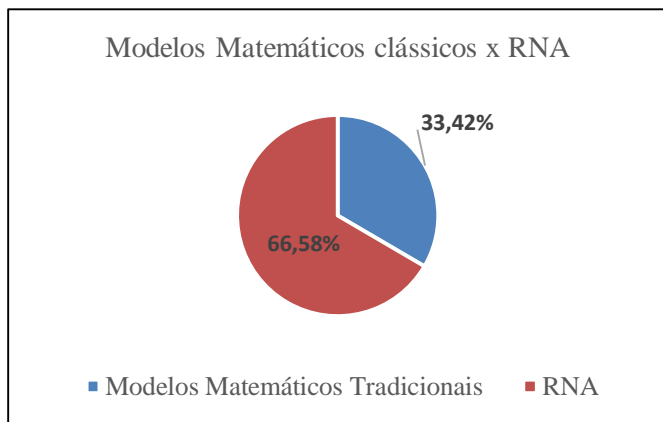


Figura 6: Modelos Matemáticos x RNA

A mesma comparação foi realizada entre a RNA otimizada com AG e os modelos matemáticos clássicos. Pode-se observar que para 94,52% dos produtos o melhor método foi

a RNA otimizada e para os modelos matemáticos 5,48% do total de produtos conforme apresentado na Figura 7.




Figura 7: Modelos Matemáticos x RNA Otimizada

Com o comparativo pode-se observar que o modelo de RNA otimizada apresentou valores consideravelmente superiores ao se comparar a uma RNA sem otimização e modelos matemáticos clássicos, sendo o método com menor percentual de erro em 94,52% dos produtos.

V. CONCLUSÕES

Este artigo teve como objetivo aplicar métodos de previsão de demanda clássicos e previsão de demanda utilizando redes neurais. Utilizou-se para o estudo de caso os dados do histórico de vendas dos últimos 30 meses dos produtos que representam a curva A de faturamento de uma indústria do ramo de plásticos.

Os resultados obtidos por meio dos modelos clássicos foram comparados para cada produto, posteriormente foi realizada uma comparação entre os modelos clássicos e RNA, e por último uma comparação com os resultados obtidos através da RNA otimizada com a utilização de um AG.

Comparando os erros obtidos para cada modelo de previsão ficou evidenciado que a RNA apresentou menor percentual de erro em relação aos outros métodos de previsão clássicos para 66,58% do total de produtos estudados. Realizando a mesma comparação entre os modelos clássicos e a RNA otimizada, a RNA otimizada apresentou menor percentual de erro para 94,52 % dos produtos. Nesse sentido observa-se que a RNA otimizada apresentou melhor desempenho nas previsões de demanda com valores consideravelmente superiores em qualidade ao se comparar a uma RNA sem otimização e pode ser aplicada no dia a dia das organizações a fim de melhorar a assertividade das previsões de demandas futuras.

Para trabalhos futuros sugere-se realizar modificações no treinamento da RNA, como por exemplo, aumentar o volume de dados de treinamento, teste com outros parâmetros de treinamento, explorar mais métodos de aprendizagem de máquina, como o algoritmo evolutivo utilizado para solucionar problemas de otimização multiobjetivo (NSGA II).

VI. Bibliografia

- [1] Adriana Lucia Fachin, Carla Cristina Rosa de Almeida e Silvio Antonio Ferraz Cario. "Análise das condições competitivas da indústria de materiais plásticos de Santa Catarina: um estudo no segmento de embalagens plásticas da grande Florianópolis" *Cadernos de Economia, Chapecó*, v. 23, n. 12, p.7-34, dez. 2008
- [2] ABIPLAST. Associação Brasileira da Indústria do Plástico. Perfil da Indústria Brasileira de Transformação de Material Plástico. Disponível em: <<http://www.abiplast.org.br>>. Acesso em: 18 ago. 2019.
- [3] Katsumi Morikawa; Katsuhiko Takahashi and Daisuke Hirotani. "Make-to-stock policies for a multistage serial system under a make to-order production environment" *International Journal of Production Economics*, v.147, pp 30-37, 2013.
- [4] Klaus altendorfer and Stefan minner "A comparison of make-to-stock and make-to-order in multi-product manufacturing systems with variable due dates" Department of Operations Management, School of Management, Upper Austria University of Applied Sciences, A-4400 Steyr, Austria *IIE Transactions* (2014) 46, 197–212 DOI: 10.1080/0740817X.2013.803638
- [5] Bundchen, C., & Werner, L. (2016). "Comparação da Acurácia de Previsões de Demanda Turística em Sedes Olímpicas". *Revista Turismo em Análise*, 27(1), 85-107.
- [6] FERNEDA, Edberto. "Redes neurais e sua aplicação em sistemas de recuperação de informação". *Ci. Inf.*, Brasília, v. 1, n. 31, p.25-30, abr. 2006.
- [7] Ferreira, A; Ferreira, R, P; da Silva, A. M, Ferreira, A, & Sassi, R.J. (2016). Um estudo sobre previsão de demanda de encomendas utilizando uma rede neural artificial. *Blucher Engineering*,2(1), 353-364.
- [8] Borsato, Renan; Corso, Leandro L. "Aplicação de Inteligência Artificial ARIMA na Previsão de Demanda no setor metal mecânico." *Scientia cum Industria* 7.2 (2019): 165-176.
- [9] Melo, Daniela de Castro; Alcântara, Rosane Lúcia Chicarelli. "Uma abordagem além da previsão de vendas". *Gestão & Produção, São Carlos*, v. 4, n. 18, p.809-824, ago. 2011
- [10] Azevedo, Rodrigo Cambiaghi et al. "O Uso de ERP e CRM no Suporte à Gestão da Demanda em Ambientes de Produção Make-to-Stock". *Gestão & Produção, São Carlos*, v. 2, n. 13, p.179-190, ago. 2006.
- [11] 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.
- [12] Pedroso, Larissa Batisti; Diego, Milena Silveira; Pacheco, Diego Augusto de Jesus. "Impacto da variabilidade da demanda no dimensionamento de estoques de segurança de produtos importados". *Iberoamerican Journal Of Industrial Engineering, Florianópolis*, v. 13, n. 7, p.59-82, dez. 2015.
- [13] Soares, Cibele et al. Redes neurais artificiais na estimativa da retenção de água do solo". *Ciência Rural*, Santa Maria, v. 2, n. 44, p.293-300, fev. 2014
- [14] Adebisi, A.; Adewumi, A.; Ayo, C. "Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction," *Journal of Applied Mathematics*, v. 14 pp. 1-7, 2014.
- [15] G.E.P. Box; G.M. Jenkins. "Time Series Analysis: Forecasting and Control," Holden Day, San Francisco. Google Scholar, 1976.
- [16] 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.
- [17] 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.
- [18] 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.
- [19] 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.
- [20] Gomes, Herbert M.; Corso, Leandro L. "A Hybrid Method for Truss Mass Minimization considering Uncertainties." *Mathematical Problems in Engineering*, v.17, pp 1-14, 2017.
- [21] Corso, Leandro L.; Wallace, Mark. "A hybrid method for transportation with stochastic demand," *International Journal of Logistics* , v. 18, n.3, pp. 1-13, 2015.