

Aplicação de Redes Neurais Artificiais e Média Móvel Simples na previsão de demanda em uma empresa do setor metal-mecânico

Lucas de Carvalho Borella¹, Nathalia Tessari Moraes², Bruna Gabriele de Matos³, Bruna Caroline Orlandin⁴, Leandro Luis Corso⁵

Resumo: Atualmente, técnicas de previsão são consideradas necessárias, principalmente para auxiliar no processo de tomada de decisão. No contexto das organizações, as previsões podem auxiliar no planejamento dos recursos, objetivando se aproximar da demanda real. Logo, o objetivo do presente trabalho é desenvolver e comparar dois modelos de previsão de demanda para três produtos diferentes de uma empresa do setor metal-mecânico da cidade de Caxias do Sul. Os três produtos escolhidos são os mais produzidos pela empresa, em termos de volume de produção. Os dados da demanda passada, janeiro de 2016 a dezembro de 2018, foram utilizados para a construção do banco de dados, o qual posteriormente foi usado na aplicação das técnicas da média móvel simples (MMS) e das Redes Neurais Artificiais (RNA). As duas técnicas utilizadas tiveram seu desempenho avaliado pelo Mean Absolute Percentage Error (MAPE). Os resultados obtidos com ambas as técnicas foram considerados relativamente satisfatórios, com um erro médio de previsão inferior a 21% para todos os casos. A técnica das RNA apresentou um desempenho superior ao da MMS. Porém identificou-se que ela não se mostrou efetiva na previsão da série sazonal para este trabalho. Mesmo assim a diferença foi relativamente pequena em relação à previsão pela MMS. Por outro lado, na previsão das séries horizontais as RNAs demonstraram um desempenho relativamente superior à média móvel simples.

Palavras chave: Previsão de demanda, análise de séries temporais, Redes Neurais Artificiais, Média móvel simples

Application of Artificial Neural Networks and Simple Moving Average in demand forecasting at a metalworking company

Abstract: Nowadays, forecasting techniques are considered necessary, mainly in the decision making process. In the context of organizations, the predictions can be used in the resources planning, aiming to approach the actual demand value. The objective of this article is to develop and compare two forecasting models in three different products in a metalworking company at Caxias do Sul city. The chosen products are the ones that the company produces the most, in terms of production volume. The past values of the demand, January 2016 until December 2018, were used to make a database, which was later used in the application of a simple moving average model (SMA), and in an Artificial Neural Networks models (ANN). These models were evaluated by the Mean Absolute Percentage Error (MAPE). The results obtained with both techniques were considered satisfactory, with an average prediction error of less than 21% for all cases. The performance of the RNA model was better than the SMA model. However, it was found that it was not effective in prediction of the seasonal series, identified in this work, showing a relatively small difference from the forecast obtained by the SMA model. On the other hand, in the horizontal series prediction, the RNA model showed a performance relatively superior in comparison with the simple moving average.

Key-words: Demand forecast, Time series analysis, Artificial Neural Networks, Simple moving average.

¹ (Universidade de Caxias do Sul), lcborella@ucs.br.

² (Universidade de Caxias do Sul), ntmoraes1@ucs.br.

³ (Universidade de Caxias do Sul), bgmatos@ucs.br.

⁴ (Universidade de Caxias do Sul), bcorlandin@ucs.br.

⁵ Autor, correspondente, (Universidade de Caxias do Sul), llicorso@ucs.br.

1. Introdução

O ser humano, desde sua origem, busca compreender o mundo físico e os fenômenos que o rodeia. Atualmente, com todo o conhecimento e tecnologia que tem sido gerado, as previsões continuam a ter um papel importante, por auxiliarem nos processos de tomada de decisão, como por exemplo, previsões: de desastres naturais, da bolsa de valores, do clima, entre outras (CORTEZ, 2002).

As técnicas de previsão auxiliam, principalmente, o processo de tomada de decisão em atividades que requerem planejamento, avaliação de políticas e redução de incerteza. Um dos objetivos dessas técnicas é a diminuição das incertezas, sendo essa de especial importância no setor da agricultura, por exemplo (BRESSAN, 2004).

As previsões também são utilizadas em organizações, uma vez que boas previsões podem ser consideradas necessárias em todos os aspectos de um negócio. A previsão é a única estimativa da demanda até que a demanda real seja conhecida, nesse caso sendo denominada de previsão de demanda, a qual tem impacto direto sobre os recursos humanos, capacidade e a gestão da cadeia de suprimentos de uma empresa (HEIZER; RENDER, 2001).

O estudo da previsão de demanda é um tema emergente dentro da gestão da cadeia de suprimentos o qual busca rápida e adequada integração das necessidades do mercado na direção dos fornecedores, objetivando assim balancear e alinhar estrategicamente a demanda com a capacidade operacional da cadeia de suprimentos. Esse alinhamento é afetado por certas dificuldades como a falta de precisão nas informações que conseqüentemente: torna o atendimento aos clientes ineficiente, reduz o giro dos estoques e aumenta o índice de obsolescência (MELO; ALCÂNTARA, 2011).

As técnicas de previsão podem ser classificadas em três grupos: qualitativa, análise de análise de séries temporais e modelos causais. A análise de séries temporais se baseia na previsão da demanda futura a partir dos valores de demanda do passado, ou seja, a tendência que gerou demanda no passado tende a continuar gerando demanda no futuro, normalmente sendo utilizada em previsões de curto prazo, como por exemplo, na programação de trabalhadores. As técnicas qualitativas são subjetivas, sendo baseadas em estimativas e opiniões, por outro lado, os modelos causais admitem que a demanda esteja relacionada com fatores no meio ambiente, gerando-se assim um relacionamento de causa-e-efeito (DAVIS; AQUILANO; CHASE, 2001).

A Inteligência Artificial (IA) é considerada um dos campos mais recentes na engenharia, tendo surgido logo após a Segunda Guerra Mundial. As aplicações para seu uso são inúmeras, uma vez que seu conceito é o de aprendizagem e de percepção da situação, utilizada para guiar carros em estradas, diagnosticar doenças, entre outras aplicações. As Redes Neurais podem ser comparadas com técnicas estatísticas de reconhecimento de padrões e de aprendizado, conseguindo também executar previsões de séries temporais, muito utilizada como método de cálculo na IA. Nos trabalhos de Dantas et al. (2016), Munstaser, Da Silva e Penedo (2017) e Norvig e Russell (2013), as Redes Neurais foram utilizadas para executar previsões de precipitações de chuvas e ações na bolsa de valores, respectivamente, onde obtiveram resultados satisfatórios.

O objetivo do presente trabalho é desenvolver e comparar dois modelos de previsão de demanda para três produtos diferentes de uma empresa do setor metal-mecânico, sendo um desses modelos a média móvel simples (MMS) e o outro modelo sendo baseado na Inteligência Artificial (IA).

2. Revisão bibliográfica

Nesta secção é apresentada a revisão da literatura sobre o tema tratado no artigo, onde os conceitos e técnicas revisados são posteriormente aplicados em um caso real.

2.1. Previsão de demanda

As previsões são um fator indispensável no planejamento das organizações, a partir delas é possível projetar os cursos de ações futuras por meio da estimativa de recursos. Prever a demanda futura é a condição essencial para a criação de planos de trabalhos, os quais incluem também o dimensionamento das capacidades envolvidas. É impossível conhecer, com 100% de certeza, o que ocorrerá no futuro, logo meios de prever ou inferir o que acontecerá são necessários (GONÇALVES, 2004).

Segundo Heizer e Render (2001), a criação de modelos de previsões seguem sete etapas básicas: definição do objetivo da previsão, seleção dos itens a serem previstos, determinação do horizonte de tempo da previsão, seleção dos modelos de previsão, obtenção dos dados históricos, realização da previsão e validação dos resultados, ainda segundo os autores, as previsões obtidas raramente são perfeitas, pois existem fatores externos que são imprevisíveis ou incontroláveis que geram impacto sobre as previsões.

A demanda de produtos ou serviços, em muitos casos, pode ser dividida em cinco componentes: demanda média para o período, tendência, influência sazonal, elementos cíclicos e variação aleatória. Os fatores cíclicos são mais complexos de estimar, uma vez que o período considerado ou a causa do ciclo pode não ser conhecida. As variações aleatórias são causadas por eventos casuais, subtraindo-se da demanda total a: média, tendência, sazonalidade e a natureza cíclica, o que sobra é a parte inexplicável da demanda que se não for identificada a mesma é considerada puramente aleatória (DAVIS; AQUILANO; CHASE, 2001).

2.2. Análise de séries temporais

Uma série temporal pode ser definida como uma sequência de dados uniformemente espaçados (diariamente, mensalmente, anualmente, etc.). A previsão desses dados implica que os valores futuros sejam previstos a partir dos valores passados. Analisar uma série temporal significa dividir os dados passados em componentes de depois projeta-los no futuro, sendo esses componentes: a tendência, a sazonalidade, os ciclos e as variações aleatórias (HEIZER; RENDER, 2001).

2.2.1. Técnica da média móvel simples

A previsão pela média aritmética móvel considera que os valores utilizados para o cálculo variam em função do tempo. Essa técnica considera que, embora exista uma tendência nos dados, ela será relativamente pequena e comparação com os erros aleatórios, consequentemente, tendo pouca influência no cálculo do valor futuro. A média móvel pode ser calculada segundo a equação 1 (GONÇALVES, 2004).

$$\text{Média Móvel} = \frac{\sum \text{demanda dos últimos } n \text{ períodos}}{n} \quad (1)$$

Na equação 1, n é referente ao número de períodos considerados, logo, o valor da previsão é dado pela média dos n períodos da série. A média móvel é um método adequado quando a procura do mercado é constante com o passar do tempo. Ela tende a ajustar as irregularidades de curto prazo na série de dados (HEIZER; RENDER, 2001).

2.2.2. Inteligência Artificial

A IA é um ramo da ciência da computação oriunda de ideias filosóficas, científicas e tecnológicas, e tem como objetivo a criação de modelos para a inteligência e a construção de sistemas computacionais. A pesquisa e o desenvolvimento da IA é dividido em três tipos de atividades (BITTENCOURT, 2001):

- desenvolvimento de modelos formais para a inteligência humana;
- desenvolvimento de aplicações educacionais, comerciais ou industriais aplicando-se técnicas de IA;
- exploração e experimentação de técnicas computacionais que apresentem potencial para a simulação do comportamento inteligente.

2.2.2.1. Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) podem ser caracterizadas, de uma forma geral, como modelos computacionais os quais possuem habilidades de: adaptação, aprendizado, reconhecimento de padrões e organização de dados, cujo mecanismo se baseia em processamento paralelo, da mesma forma como os sistemas biológicos presentes no cérebro humano processam os dados. Muitos modelos não neurais já existem e possuem características similares as da RNAs, logo o uso dessa técnica se dá quando esta for mais adequada que os modelos não neurais (KROSE; SMAGT, 1996).

Segundo Haykin, (2001), o neurônio é a fundamental unidade de processamento de informação dentro de uma RNA. A Figura 1 exemplifica a estrutura do neurônio artificial que é constituído por três elementos básicos: o conjunto de sinais de entrada juntamente com os respectivos pesos sinápticos, um somador e uma função de ativação.

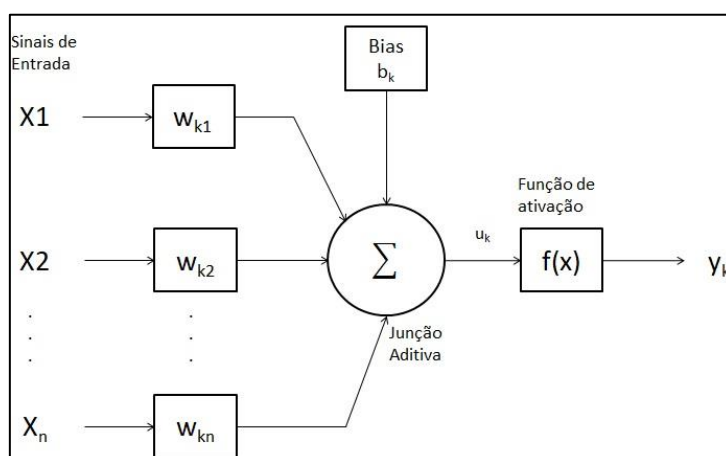


Figura 1 – Modelo de um neurônio artificial. Fonte: Haykin (2001).

Na Figura 1 cada sinal de entrada possui um peso. Um sinal x_j na entrada de um neurônio é multiplicado pelo peso sináptico w_{kj} , em que o índice k se refere ao neurônio onde a entrada de informações ocorre, e o j se refere ao terminal de entrada. Os pesos sinápticos podem ser tanto valores positivos quanto negativos, possuindo a função de ponderar o valor de cada entrada (HAYKIN, 2001).

Consequentemente, o somador realiza a soma dos sinais de entrada após serem multiplicados pelos seus respectivos pesos. A função de ativação tem como função restringir a amplitude de saída de um neurônio. O termo *bias* (b_k) é aplicado externamente e tem como função aumentar ou diminuir a entrada da função de ativação, podendo ser um valor negativo ou positivo. Um neurônio artificial pode ser escrito matematicamente de acordo com as equações 2 e 3 (HAYKIN, 2001).

$$u_k = \sum_{j=1}^m w_{kj}x_j \quad (2)$$

$$y_k = \varphi(u_k + b_k) \quad (3)$$

Nas equações 2 e 3 os valores de x_1, x_2, \dots, x_n representam os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{kn}$ referem-se aos pesos sinápticos do neurônio k , enquanto u_k é a função somatória. Na segunda equação o b_k representa o bias, φ representa a função de ativação e y_k é o sinal de saída do neurônio (HAYKIN, 2001).

3. Metodologia

As técnicas utilizadas no tratamento dos dados são detalhadas nesse capítulo, bem como a análise e interpretação dos resultados.

3.1 Construção do banco de dados

Os dados foram obtidos em uma empresa do setor metal-mecânico da cidade de Caxias do Sul durante o período de janeiro de 2016 a dezembro de 2018. Os três produtos presentes neste estudo são os três mais produzidos pela empresa, em termos de volume de produção. Os dados foram alocados em uma planilha eletrônica, onde posteriormente foram analisados.

3.2 Aplicação da média móvel simples

A média móvel simples é uma das técnicas mais utilizadas para a estimativa da demanda em empresas, logo, essa técnica foi aplicada para cada um dos três produtos estudados neste trabalho. O valor do “n”, referente à equação 1, foi variado de 2 até 12 para todos os casos. A previsão, a qual o valor de “n” resultou no menor erro, foi utilizada para a comparação com as demais técnicas aplicadas.

3.3 Aplicação das Redes Neurais Artificiais

A previsão pelo método das Redes Neurais Artificiais foi desenvolvida fornecendo-se como valores de entrada: o número do período e o mês do ano, enquanto o valor real da demanda foi fornecido como sendo a resposta desejada da rede. Desenvolveram-se três redes (uma para cada produto), onde em cada uma delas a função de ativação foi variada até a obtenção do menor erro de previsão. O desempenho das redes foi avaliado pelo *Mean Absolute Percentage Error* (MAPE), o qual é calculado segundo a equação 4.

$$MAPE = \frac{1}{N} \sum \frac{|Y_r - Y_f|}{Y_r} \cdot 100\% \quad (4)$$

Na equação 4, o Y_r representa o valor real da demanda registrado pela empresa no respectivo período, enquanto o Y_f é referente ao valor previsto pelo modelo de série temporal utilizado. O valor de N é definido como o número total de períodos analisados.

3.4 Comparação dos resultados

A comparação dos métodos foi realizada por meio do valor obtido do MAPE para cada caso. Cada um dos três produtos possui: um valor de MAPE gerado pelo método da média móvel simples e um valor de MAPE gerado pelo método das Redes Neurais Artificiais. O erro foi calculado para o mesmo número de períodos para cada um dos produtos, em função do valor de “n” utilizado na MMS, ou seja, os primeiros quatro períodos foram desconsiderados nos Produtos 1 e 2, enquanto o Produto 3 teve seus primeiros 12 períodos excluídos do cálculo do erro.

4. Resultados

Nesta secção são apresentados os resultados obtidos da aplicação da metodologia proposta.

4.1. Demanda real registrada

A partir dos dados registrados pela empresa, no período de janeiro de 2016 a dezembro de 2018, foram construídos três bancos de dados separadamente, um para cada produto estudado. O banco de dados dispõe de três variáveis: o número do período, o mês, e o valor da demanda registrada. O número do período segue uma escala contínua, onde o primeiro tem o valor de um, enquanto o último é representado pelo número 36 que totaliza os 36 meses estudados. A Figura 2 apresenta o gráfico da demanda em função do tempo dos três produtos analisados.

Observando a Figura 2, é possível verificar que o Produto 2 apresenta uma sazonalidade, uma vez que apresenta picos nos mesmos meses de forma repetida. Por outro lado, o Produto 1 e o Produto 3 apresentam uma distribuição horizontal.




Figura 2 – Demanda real dos três produtos em função do tempo.

4.2. Previsão de demanda pela média móvel simples

A média móvel simples é uma técnica que é considerada ideal para a previsão de séries com distribuição horizontal. Esse método considera apenas a média aritmética dos “n” períodos mais recentes. Nesse caso o valor de “n” foi variado, sendo utilizado o que resultou no menor valor de MAPE. O valor de “n” ótimo encontrado foi: $n = 4$ para o Produto 1 e Produto 2, e $n = 12$ para o Produto 3. Os valores de erro de previsão estão presentes na Tabela 1, enquanto o gráfico dos valores previstos está representado na Figura 3.

Observando a Figura 3 é possível verificar que em todos os casos a linha de previsão conseguiu seguir o comportamento da demanda real. O Produto 2 apresenta sazonalidade, porém a média móvel simples resultou num erro médio de aproximadamente 12% o qual não representa um valor alto, uma vez que essa técnica é ideal para a previsão de séries horizontais, logo demonstrou uma adaptação relativamente positiva aplicada a uma série sazonal. A linha de previsão do Produto 3 se assemelha a uma tendência linear crescente que resultou em um erro médio de aproximadamente 19%. Apesar da previsão do Produto 1 ter acompanhado o comportamento da curva real, ela demonstrou o pior desempenho em relação aos outros dois produtos, pelo fato da variabilidade dos dados ter sido maior nesse caso.

Produto	MAPE médio
1	21,47%
2	12,42%
3	19,36%

Fonte: Os Autores (2019).

Tabela 1 – MAPE médio obtido com a previsão pela média móvel simples.

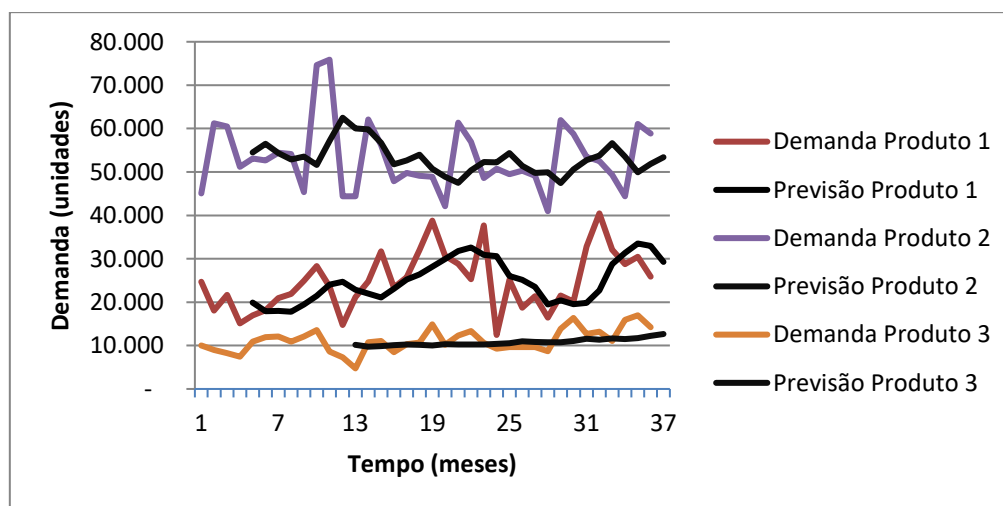


Figura 3 – Valores reais e valores previstos por meio da média móvel simples.

4.3. Previsão de demanda pelas Redes Neurais Artificiais

Utilizando como valores de entrada: o número do período, o mês e a demanda real registrada no respectivo período, criaram-se três RNA (uma para cada produto estudado). Nas redes

referentes aos Produtos 1 e 3 foi utilizado uma função de ativação do tipo sigmoide, enquanto na rede do Produto 2 utilizou-se uma função do tipo hiperbólica-tangente. O desempenho das redes está presente na Tabela 2, enquanto o gráfico dos valores reais e valores previstos está representado na Figura 4.

Observando a Figura 4, é possível verificar que a linha de previsão do Produto 2 não conseguiu acompanhar o comportamento da curva, a previsão resultou em uma série semelhante a uma sazonal, porém com comportamento diferente da demanda real, gerando um erro médio de 10,99%. Por outro lado, a linha de previsão dos Produtos 1 e 3 conseguiu acompanhar o comportamento da curva. A previsão do Produto 1 possui o melhor desempenho, com um erro médio de aproximadamente 5%, enquanto a previsão do Produto 3 resultou num erro médio de aproximadamente 12%.

Produto	MAPE médio
1	5,47%
2	10,99%
3	11,89%

Fonte: Os Autores (2019).

Tabela 2 - MAPE médio obtido com a previsão por meio das Redes Neurais Artificiais




Figura 4 – Valores reais e valores previstos por meio das Redes Neurais Artificiais.

4.4. Comparação das técnicas aplicadas

A previsão por meio das RNA demonstrou melhor desempenho, em todos os casos avaliados neste estudo, em relação à previsão obtida por meio da média móvel simples. Os valores do MAPE médio de cada uma das técnicas aplicadas, e da demanda prevista para o primeiro período de 2019, estão presentes na Tabela 3. Apesar da previsão obtida pelas Redes Neurais do Produto 2 não acompanhar o comportamento da curva real, ela ainda assim apresenta um valor menor de erro médio em comparação com a média móvel simples. Destaca-se que na previsão do Produto 1, as redes apresentaram um erro médio de aproximadamente 5%, valor consideravelmente menor do que o obtido pela outra técnica.

Produto	MAPE médio da MMS	MAPE médio das RNAs	Demanda prevista pela MMS	Demanda prevista RNAs
---------	-------------------	---------------------	---------------------------	-----------------------

1	21,47%	5,47%	29.271 unidades	37.741 unidades
2	12,42%	10,99%	53.398 unidades	50.687 unidades
3	19,36%	11,89%	12.656 unidades	12.803 unidades

Fonte: Os Autores (2019).

Tabela 3 – Comparação dos erros de previsão em relação à técnica aplicada

5. Conclusão

O objetivo do presente trabalho foi desenvolver e comparar dois modelos de previsão de demanda para três produtos diferentes de uma empresa do setor metal-mecânico. Utilizaram-se as técnicas da: média móvel simples e das Redes Neurais Artificiais. MMS é uma técnica ideal para a previsão de séries horizontais, além de ser de simples uso e aplicação, por outro lado as RNAs são ideais para a previsão de séries caóticas, ou, não-lineares.

Os dados analisados representam a demanda real registrada pela empresa desde janeiro de 2016 a dezembro de 2018, enquanto o valor de janeiro de 2019 foi previsto pelos métodos propostos. O desempenho de cada uma das previsões foi avaliado por meio do MAPE, o qual em ambas as técnicas, resultou em um valor inferior a 21% aproximadamente.

A técnica das RNAs apresentou desempenho superior à MMS em todos os casos analisados, porém identificou-se que ela não se mostrou efetiva na previsão da série sazonal identificada neste trabalho, demonstrando uma diferença relativamente pequena em relação a previsão obtida pela MMS. Por outro lado, na previsão das séries horizontais as redes demonstraram um desempenho relativamente superior à MMS.

Os resultados do presente estudo estão limitados ao ambiente da organização analisada, logo o desempenho das técnicas aplicadas fica restrito aos dados trabalhados neste artigo. As RNA utilizadas continham 10 neurônios ocultos, evidenciando assim uma limitação no estudo, uma vez que o valor ótimo de neurônios ocultos resultará em um melhor desempenho das redes.

Referências

Livro

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

Artigo de periódico

BRESSAN, Aureliano Angel. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. **RAE-eletrônica**, São Paulo, v. 3, n. 1, p.1-20, jun. 2004. Disponível em: <<http://www.scielo.br/pdf/%0D/raeel/v3n1/v3n1a04.pdf>>. Acesso em: 10 jul. 2019.

Tese de doutorado

CORTEZ, Paulo Alexandre Ribeiro. **Modelos inspirados na natureza para a previsão de séries temporais**. 2002. 186 f. Tese (Doutorado) - Curso de Informática, Universidade do Minho, Campus de Azurém, 2002. Disponível em: <<https://repositorium.sdum.uminho.pt/bitstream/1822/13/1/cortez.pdf>>. Acesso em: 10 jul. 2019.

Livro

DAVIS, Mark M.; AQUILANO, Nicholas J.; CHASE, Richard B.. **Fundamentos da Administração da Produção**. 3. ed. Porto Alegre: Bookman, 2001.

Artigo de periódico

DANTAS, Daniel et al. Uso de Redes Neurais Artificiais na previsão da precipitação de períodos chuvosos. **Revista Espinhaço**, [S. l.], v. [S.l.], n. [S.l.], p. 11-18, maio 2016. Disponível em: <<http://revistaespinhaco.com/index.php/journal/article/view/96/90>>. Acesso em: 22 ago. 2018.

Livro

GONÇALVES, Paulo Sérgio. **Administração de materiais**. Rio de Janeiro: Campus, 2004.

Livro

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

Livro

HEIZER, Joy; RENDER, Barry. **Administração de Operações: Bens e Serviços**. 5. ed. Rio de Janeiro: Ltc, 2001.

Livro

KROSE, Ben; SMAGT, Patrick van Der. **An introduction to neural networks**. Amsterdã: The University Of Amsterdam, 1996.

Artigo de periódico

MELO, Daniela de Castro; ALCÂNTARA, Rosane Lúcia Chicarelli. A gestão da demanda em cadeias de suprimentos: uma abordagem além da previsão de vendas. **Gestão & Produção**, [S.l.], v. 18, n. 4, p.809-824, 2011. FapUNIFESP (SciELO).

Artigo de periódico

MUNTASER, João Gonçalves Silva; DA SILVA, Valter Pereira; PENEDO, Antonio Sergio Torres. Aplicação de Redes Neurais na Previsão das Ações do Setor de Petróleo e Gás da Bm&FBovespa. **Revista FSA**, [S.l.], v. 14, n. 6, p. 49-71, 1 nov. 2017. Revista FSA. Disponível em: <<http://www4.fsnet.com.br/revista/index.php/fsa/article/view/1456/1350>>. Acesso em: 27 ago. 2018.

Livro

NORVIG, Peter; RUSSELL, Stuart. **Inteligência artificial**. 3. ed. Rio de Janeiro: Elsevier, 2013.

Livro

RABUÑAL, Juan R.; DORADO, Julián. **Artificial neural networks in real-life applications**. Hershey: Idea Group Publishing, 2006.