

USO DE REDE NEURAL NO ESTUDO DA VARIAÇÃO DO DÓLAR PARA A TOMADA DE DECISÃO DE COMPRAS NA INDÚSTRIA AUTOMOBILÍSTICA

Leonardo de Mello Ferreira Silva Andrade¹; Chrislaine do Bomfim Marinho²; Leonardo Sanches de Carvalho³; Vitorio Donato⁴; Ricardo de Oliveira Monteiro Russel⁵; Herman Augusto Lepikson⁶

¹Bolsista – Embrapii; leonardo.mfs.andrade@gmail.com

²Ms em Modelagem Computacional e Tecnologia Industrial; Centro Universitário SENAI CIMATEC; Salvador-BA;

⁴⁻⁵Gerentes e Consultores de Projeto; Centro Universitário SENAI CIMATEC

⁶Dr em Engenharia Mecânica; Centro Universitário SENAI CIMATEC; Salvador-BA; herman.lepikson@fieb.org.br

RESUMO

Visto que as distintas abordagens durante a tomada de decisão podem implicar no sucesso ou desempenho insatisfatório dos projetos, o presente trabalho propõe um modelo de previsão da variável dólar para fornecer subsídios à empresa durante a tomada de decisão em processos de compra em prazos longos, onde o fator cambial é representativo. Como resultado, o grau de correlação entre os dados simulados e reais, obtido pelo modelo baseado em rede neural artificial (RNA) com autorregressores, superou 99%. Isto indica que esta RNA pode atuar como uma opção de ferramenta a ser utilizada no apoio para a tomada de decisão de compras.

PALAVRAS-CHAVE: Tomada de decisão, dólar, rede neural artificial.

1. INTRODUÇÃO

A Logística 4.0 surge para conectar os diversos atores da atividade logística, facilitando e impulsionando a produção, reduzindo os riscos e custos e melhorando a qualidade do serviço.¹ Com a logística 4.0 há a possibilidade de sincronizar a previsão de eventos em tempo real, de modo a atender a necessidade de clientes e a melhorar a confiabilidade da rede logística da empresa.¹


Visto que as distintas abordagens durante a tomada de decisão podem implicar no sucesso ou desempenho insatisfatório dos projetos,² o presente trabalho visa propor um modelo de previsão do dólar, com um mês a frente, para fornecer subsídios à empresa durante o processo de tomada de decisão de compras, onde o fator cambial é representativo e pode implicar em grandes perdas se o momento adequado de compra não for bem planejado. Este é o caso, por exemplo, de empresas que importam componentes em grandes lotes para posterior utilização nos seus processos de montagem, cujo tempo decorrido entre colocar um pedido para os componentes e vender o produto acabado no mercado pode chegar a 6 meses.

O comportamento da variação cambial ao longo do tempo tem se mostrado não linear³. Para tanto, a Rede Neural Artificial (RNA) se mostra uma ferramenta assertiva para prever o valor futuro do dólar. Neste sentido, foi desenvolvida uma abordagem específica baseada na combinação de uma RNA com arquitetura não linear com autoregressores (onde os neurônios são agrupados em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída) e o algoritmo de Levenberg-Marquardt, a fim de fornecer subsídios aos decisores durante o processo de avaliação de compras com prazos longos de realização. A RNA não linear com autoregressores é comumente utilizada para aplicações de séries temporais com alta variação. Esse algoritmo é interessante para previsões de resultados futuros em função do histórico dos dados passados.⁴

2. METODOLOGIA

Com o intuito de contribuir com os estudos de ferramentas para a previsão de variáveis que influenciam no processo decisório, o presente trabalho adotou uma RNA para desenvolver um modelo de previsão da variação do dólar com um mês à frente (desconsiderando os finais de semana). Esse intervalo de tempo na previsão condiz com o limite de segurança que a indústria tem, até o final do processo decisório da compra, sem afetar sua linha de produção. Para tanto, a RNA foi otimizada com base no algoritmo de treinamento de Levenberg-Marquardt, uma estrutura de autorregressores racionalizados em 1:4, uma camada escondida (composta pela função de ativação Tansig) e uma camada de saída (composta pela função de ativação Purelin), conforme representado na Figura 1.

Figura 1 – Configuração estrutural da rede neural artificial.



Onde W é o peso, b é o viés neural, $Y(t)$ é a entrada e saída e 67 é o número de neurônios utilizados. O $Y(t)$ é a entrada e saída.


Como condição de contorno foi utilizada uma série histórica com 2.658 registros diários do dólar, cotados em um período de pouco mais de 10 anos (de 11/01/2010 a 17/03/2020). Tais registros foram obtidos em ⁵.

Durante o treinamento da rede neural, os dados foram segregados em três etapas: 70% dos dados serão responsáveis pelo treinamento da rede; 15% para a validação da rede e 15% para o teste de confiabilidade da rede; sendo desconsiderados da amostra os sábados e domingos. A validação do modelo ocorre mediante análise estatística com o *mean square error* (MSE), regressão linear e correlação de autorregressores sobre os valores simulados e os observados. A ferramenta computacional utilizada para processar a simulação foi o MATLAB.

3. RESULTADOS E DISCUSSÃO

O treinamento da rede neural com autorregressores resultou em um estudo de correlação da regressão linear que foram separados em quatro etapas: treinamento, validação, teste e análise geral. A Figura 2 exibe os gráficos resultantes do comportamento dessas etapas.

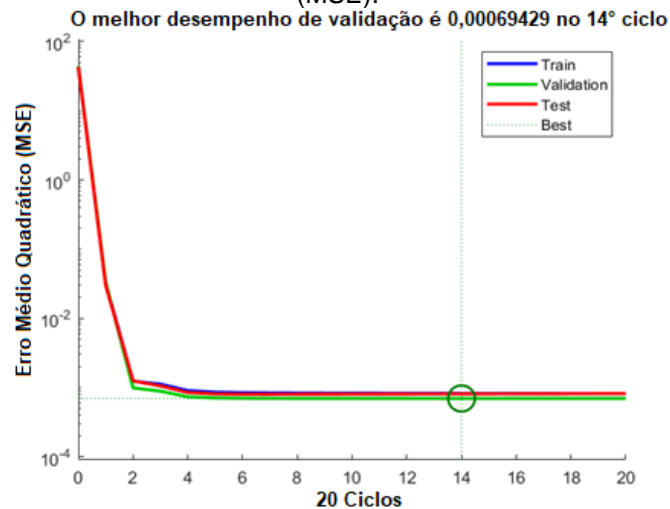
Figura 2 – Etapas do treinamento da rede neural artificial com autorregressores.



Em relação ao treinamento, o coeficiente de correlação gerado na regressão linear, entre os dados simulados e observados, apresenta uma correlação de 99,945% e um erro de apenas 0,055%. Na etapa da validação a correlação atingida foi de 99,951%, nas etapas de teste e análise geral é de 99,946%, com erros de 0,049% e 0,054%, respectivamente. À medida que os dados dos autorregressores são gerados durante a simulação, a curva *Fit* se aproxima da curva ideal $Y = T$, mostrando uma sobreposição dos pontos sobre a reta. Tal aproximação ratifica a existência de uma forte correlação entre o dólar previsto e o observado.

No início do treinamento pôde-se notar um erro maior, que decresce de maneira acentuada ao longo do tempo, de modo que as três curvas (treinamento, teste e validação da rede neural) convergem e se aproximam da faixa de erro estimada. Destarte, o modelo atinge sua melhor performance no 14º ciclo, com um erro de $6,94 \cdot 10^{-4}$.

Figura 3 – Gráfica de desempenho do treinamento da RNA em relação ao Erro Médio Quadrático (MSE).



4. CONSIDERAÇÕES FINAIS

O estudo da predição do dólar, como variável para o apoio de tomada de decisão por intermédio de rede neural artificial, mostrou um comportamento correspondente às tendências dos indicadores exibidos em ⁵, refletindo numa correlação de aproximadamente 99%. O melhor desempenho do modelo ocorreu a partir do 14º ciclo, gerando um erro de $6,94 \cdot 10^{-4}$, (inferior ao estabelecido como *target* 10^{-3} no algoritmo de predição) demonstrando um grau de confiança superior ao esperado.

Por conseguinte, foi comprovado que a Rede Neural Artificial com autorregressores é uma ferramenta viável em processos de predição de séries temporais. Em contrapartida, a fim de aumentar o número de variáveis que influenciam na tomada de decisão de compra do usuário, futuramente, serão agregados parâmetros de perfil e sazonalidade do mercado consumidor brasileiro.

Agradecimentos

Ao Centro Universitário SENAI-CIMATEC, à EMBRAPPII, à Equipe de Gestão da Produção e Logística e aos orientadores.

5. REFERÊNCIAS

¹ DE FREITAS, Matheus Menna Barreto Cardoso; DE FARIAS FRAGA, Manoela Adriana; DE SOUZA, Gilson PL. Logística 4.0: conceitos e aplicabilidade: uma pesquisa-ação em uma empresa de tecnologia para o mercado automobilístico. **Caderno PAIC**, v. 17, n. 1, p. 237-261, 2016.

² NUTT, Paul C. Strategic decisions made by top executives and middle managers with data and process dominant styles. **Journal of Management Studies**, v. 27, n. 2, p. 173-194, 1990.

³ GALESHCHUK, Svitlana. Neural networks performance in exchange rate prediction. **Neurocomputing**, v. 172, p. 446-452, 2016.

⁴ RUIZ, Luis et al. An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings. **Energies**, [s. l.], v. 9, n. 9, p. 684, 2016.

⁵ *br.investing.com*, administrado pela Fusion Media, último acesso em 30/03/2020.