

ESTUDO E IMPLEMENTAÇÃO DE REDES NEURAIS ARTIFICIAIS COM O OBJETIVO DE PREVER OS COMPORTAMENTOS DE ATIVOS FINANCEIROS

Lucas Meneghelli Pereira¹.

¹ Acadêmico (a) do Curso de Bacharelado em Ciências da Computação – Bolsista GRADIS

Na economia mundial atual, é fundamental que haja uma boa administração dos recursos financeiros, de modo que os órgãos gerenciais detentores de capital possam financiar órgãos produtivos consumidores de capital (NETO, 1999). O conjunto de mecanismos para o gerenciamento dessa necessidade é denominado mercado financeiro. O mercado de capitais é uma sub-área do mercado financeiro, e é responsável pelo financiamento das atividades de órgãos produtores ao longo prazo.

Nelre se encontram as bolsas de valores, responsáveis pela negociação de títulos que representam frações de empresas, denominados ações. Através da bolsa de valores, parte do objetivo do mercado de ativos é cumprido, ao passo que empresas podem estrategicamente vender frações próprias com o objetivo de arrecadar capital sem a necessidade de realizar financiamentos com instituições bancárias (ROCHA; MACEDO, 2011).

Essas ações são classificadas como títulos de renda variável, ou seja, seu valor flutua ao longo do tempo e seus compradores/vendedores, não possuem garantia de perda/lucro. Os títulos de fundos imobiliários e commodities também podem ser classificados como renda variável. Há também títulos de renda fixa, esses são promessas de pagamento ao fim de um prazo final de emissão que possuem sua rentabilidade fixada em uma taxa pré determinada ou em algum índice de mercado (NETO, 1999). Sendo assim, tais títulos proporcionam segurança para investidores, no entanto, com a redução significativa da taxa anual de juros que vinha sendo praticada pelo mercado, atualmente os títulos de renda fixa, não oferecem mais retornos tão atrativos aos investidores quanto os de renda variável. Alguns exemplos de renda fixa são títulos do tesouro direto, CDBs, CDIs e debêntures.

Atualmente é notável o impacto e crescimento do mercado financeiro mundialmente, visto que cada vez mais pessoas aderem a investimentos em bolsas de valores em busca de ganhos financeiros. Com isso, cresce também o volume de operações do mercado (RAMINELLI; SANTOS, 2019) e consequentemente a possibilidade de maximização de lucro. Para tais investimentos, dada a complexidade do mercado financeiro e a diversidade de seus produtos, para a formação de um portfólio de investimentos, cabe ao investidor utilizar métodos para auxílio de tomada de decisão, o que tende a reduzir o risco e aumentar a possibilidade de aumento na lucratividade das operações (GIACOMEL, 2016).

Um portfólio ou carteira de investimentos é um conjunto de ativos financeiros. Pode ser composto por um ou mais tipos de ativos, e pode ser homogêneo, ou seja, possuir apenas ativos do mesmo tipo, ou heterogêneo, ou seja, composto por dois ou mais tipos de ativos financeiros. Cada um desses ativos possui risco e retorno e sua combinação influencia o risco e retorno do portfólio de investimentos (MARKOWITZ, 1952).

O risco de investimento corresponde ao grau de incerteza a respeito da oscilação do preço desses ativos e sua compensação deve ser o retorno pelo menos equivalente ao risco (NETO, 1999). O retorno diz respeito à diferença entre duas medidas históricas de preço de um ativo, nesse caso, o lucro se caracteriza através do valor positivo de um retorno entre suas datas de compra e venda.

Dada a revisão bibliográfica realizada, há duas abordagens atualmente amplamente difundidas e que são realizadas para se realizar a análise e projeção de preço futuro de ativos, sendo essas a abordagem fundamentalista e a abordagem técnica (COHEN; KUDRYAVTSEV; HON-SNIR, 2011). A análise fundamentalista realiza a análise de desempenho do valor de um ativo ou ação, considerando os dados históricos, que são publicados e estão disponíveis nos balanços da empresa, bem como baseia-se a análise também em indicadores macroeconômicos. Já a abordagem técnica conta com o conceito de que toda a informação necessária para analisar o ativo se encontra em indicadores e métricas geradas coletando os dados sobre os valores históricos dos valores de preço dos ativos. Essa análise é realizada considerando indicadores técnicos, tais como: médias móveis, Commodity Channel Index (CCI), Oscilador Estocástico e Relative Strength Index (RSI) (EBERMAM, 2018).

Com isso, dependendo do perfil do investidor, esse pode optar por utilizar uma ou ambas as duas estratégias para selecionar ativos, a fim de obter o melhor retorno financeiro, dentro de um determinado período de tempo (NELSON, 2017). (NETO, 1999) descreve em seu trabalho os conceitos de tradeoff bem como a análise do perfil de investidor. Com base nestas duas estratégias é possível construir portfólios de investimentos, compostos por ativos, e que estejam de acordo com o perfil do investidor, a fim de maximizar o lucro e reduzir os riscos.

Dentre esses métodos com base em análise técnica disponíveis, um dos mais utilizados é a previsão das séries temporais relacionadas a variáveis relacionadas ao preço das ações dos ativos financeiros, como por exemplo as séries temporais de valor de abertura, fechamento, máxima, mínima, volume, retorno e momentum (MADSEN, 2008). Essas séries são basicamente a observação do valor histórico de uma variável, nesse caso o preço das ações, e trazem informações valiosas visto que podem identificar eventos de sazonalidade, tendências e comportamentos anormais (GIACOMEL, 2016). Além disso, as séries temporais permitem a realização de comparativos de qualidade ao se utilizar métricas como a Mean Absolute Error (MAE) ou Mean Squared Error (MSE) (DIETSCHE, 2019), ou seja, quanto menor essa métrica, mais iguais são duas séries temporais.

No entanto, a previsão de séries temporais de ativos financeiros não é uma tarefa trivial, visto que, o preço de ativos podem ser influenciados pelos seguintes fatores: risco sistemático do mercado financeiro, de natureza econômica, política ou social, e risco não sistemático, inerente ao ativo (COHEN; KUDRYAVTSEV; HON-SNIR, 2011). Este fato, combinado com o aumento da volatilidade do mercado, proporciona um tema de pesquisa interessante, no sentido de tentar especificar e desenvolver métodos que proporcionem uma melhor previsão de séries temporais para ativos financeiros (DIETSCHE, 2019). Esse assunto é relevante visto que segundo (GIACOMEL, 2016) diversas pesquisas têm sido desenvolvidas a fim de propor métodos e algoritmos para otimizar distintas estratégias de mercado, denominados algorithmic trading (algotrading).

Além das abordagens clássicas de análise fundamentalista e técnica, há diversas ferramentas na literatura que podem ser aplicadas ao problema da previsão de séries temporais. Algumas delas seriam a utilização de heurísticas e meta-heurísticas, que buscam gerar soluções

satisfatórias aproximadas à solução ótima quando a solução ótima é impraticável (CAMPIGOTTO, 2019). Alguns dos algoritmos utilizados para esse fim são o Algoritmo Genético e suas variações, como o NSGA-II e o BRKGA.

Ainda entre as ferramentas disponíveis para a previsão de séries temporais de ativos se destaca o uso de Redes Neurais Artificiais (RNAs) (RUSSELL S. J; NORVING, 2009). Na revisão bibliográfica realizada, identificou-se diversos trabalhos que utilizam RNAs para resolver o problema de previsão de séries temporais para o mercado financeiro. Dentre eles, os modelos de RNAs utilizados foram majoritariamente as redes MLPs (FELIZARDO, 2017) (ZUPPINI et al., 2018) (GAMBOGI, 2013), seguidas de LSTMs (DIETSCHE, 2019) (RUBIM, 2019), bem como modelos híbridos (GIACOMEI, 2016).

Com o objetivo de estudar a aplicação de RNAs para a previsão de séries temporais de ativos financeiras, buscou-se através desse trabalho a implementação de 3 RNAs idênticas às presentes na literatura, sendo essas as duas MLPs desenvolvidas por (FELIZARDO, 2017) e a LSTM desenvolvida por (DIETSCHE, 2019). Todas as redes foram implementadas utilizando a linguagem de programação Python e as ferramentas TensorFlow e Keras, desenvolvidas para o desenvolvimento de RNAs. Essas redes possuem como entrada indicadores técnicos e/ou fundamentalistas e como saída a variação do retorno do ativo.

Quanto às RNAs de Felizardo, todas as configurações presentes no trabalho de origem foram utilizadas, por isso não se faz necessário descrevê-las neste trabalho. Foram implementadas as redes de melhor performance, sendo uma para o ativo BBAS3 e outra para o ativo ITUB4. O período de treino de ambas as redes foi de 01/01/2013 a 01/01/2015, enquanto os períodos de teste foi de 01/01/2015 a 01/01/2016. A seguir se encontram os resultados gerados por ambas as redes, de forma que é plotado a previsão x valores reais.

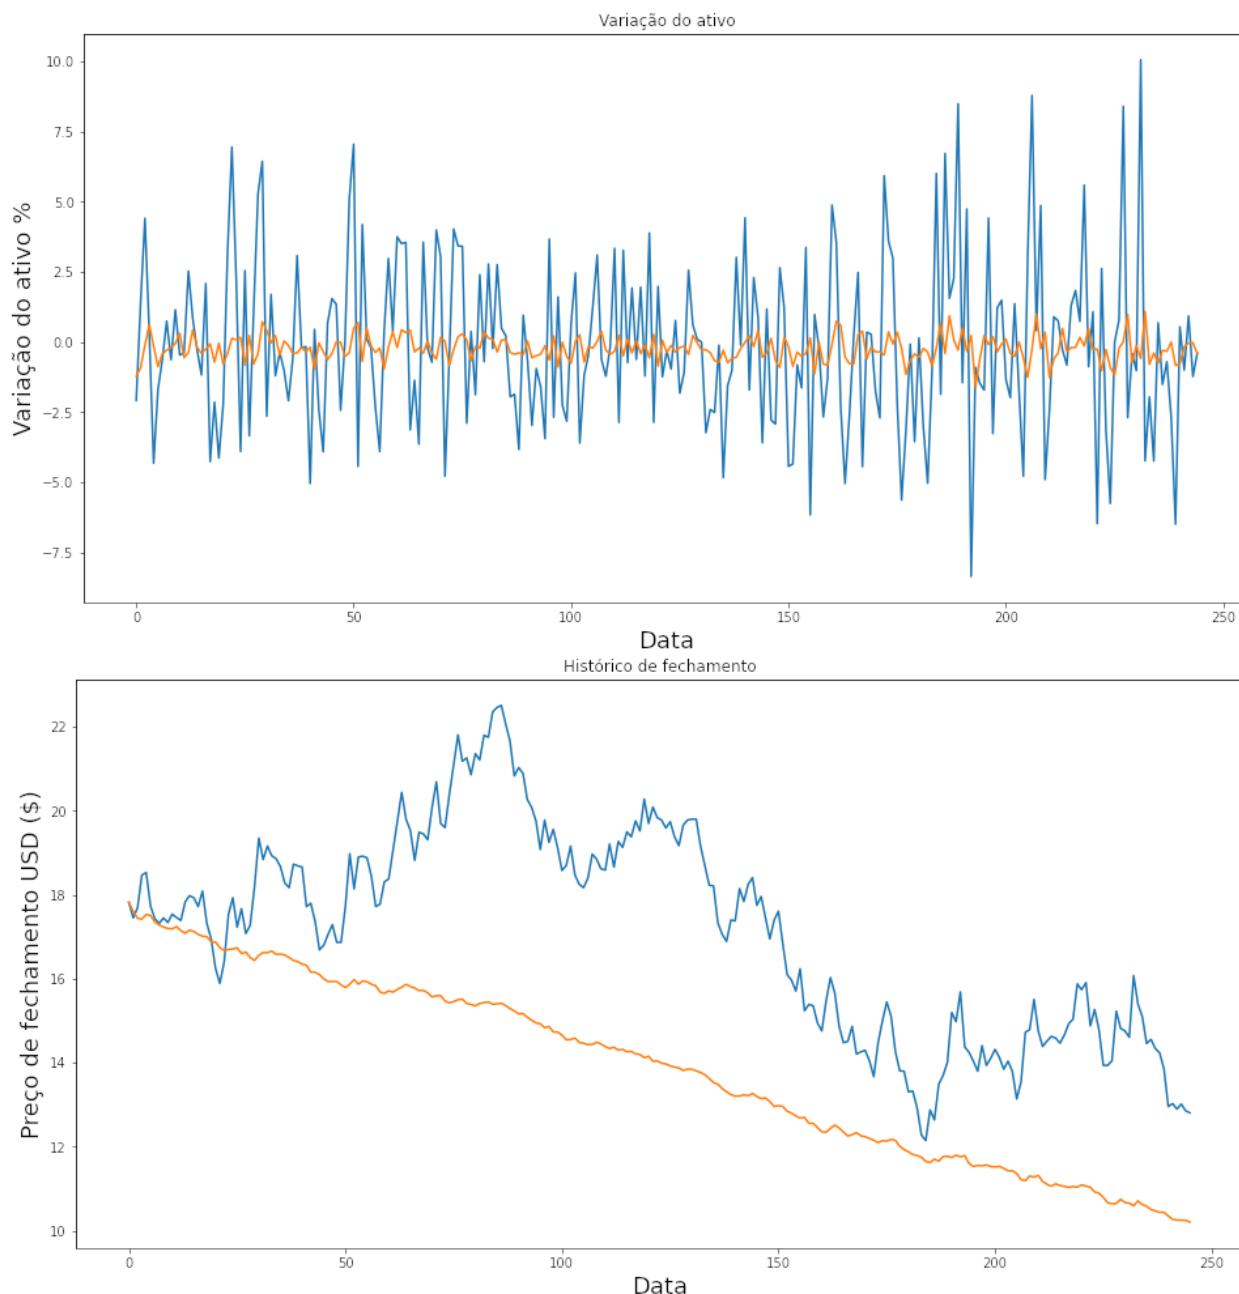


Figura 1. Resultados da rede de Felizardo voltada a previsão do ativo BBAS3

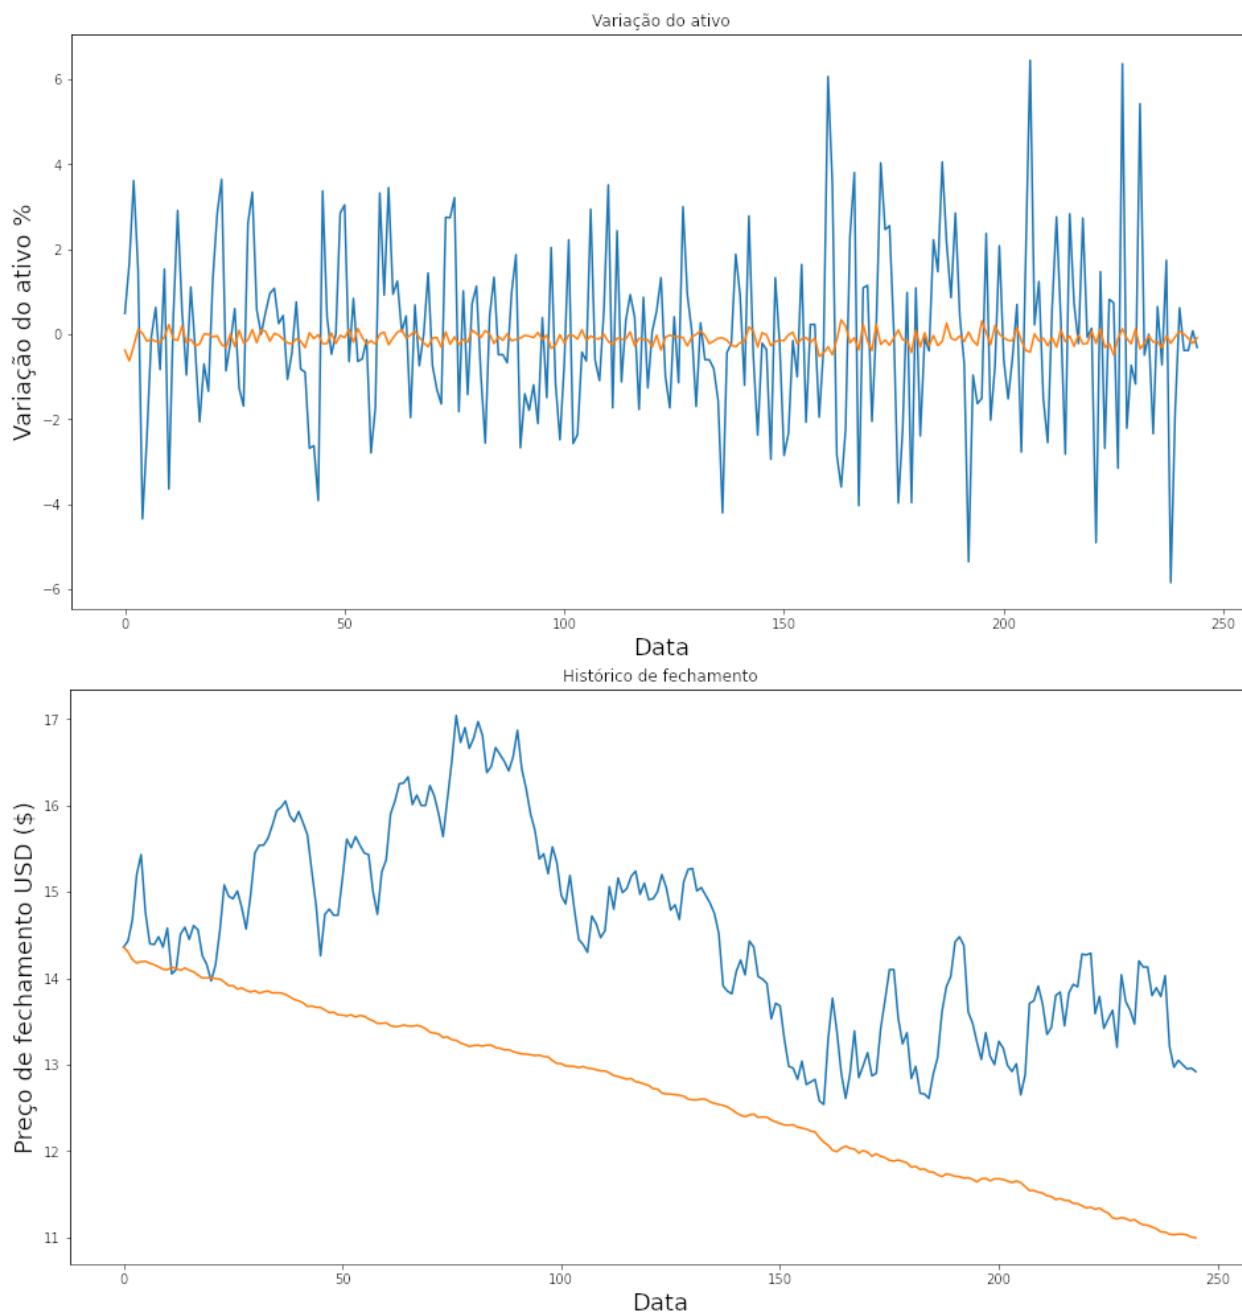


Figura 2. Resultados da rede de Felizardo voltada a previsão do ativo ITUB4

Em relação a rede de Giacomet, também foram utilizadas todas as configurações mencionadas no trabalho de origem por isso não serão abordadas. Em relação às variáveis de entrada, apenas se conseguiu angariar 54 das 64 utilizadas, isso porque (DIETSCHE, 2019) utilizou uma ferramenta paga para levantar essas variáveis, enquanto neste trabalho essas variáveis precisavam ser calculadas. Quanto aos períodos de teste e treino, em todas as redes treinadas para a previsão de ativos foram utilizados o período de 02/01/2017 a 28/12/2020, sendo que 70% dos dados desse período foram utilizados para treino e o restante para testes. A seguir estão os resultados dos testes realizados para os ativos financeiros BBDC3, BBDC4, ITUB3 e ITUB4 de forma similar a análise feita anteriormente.

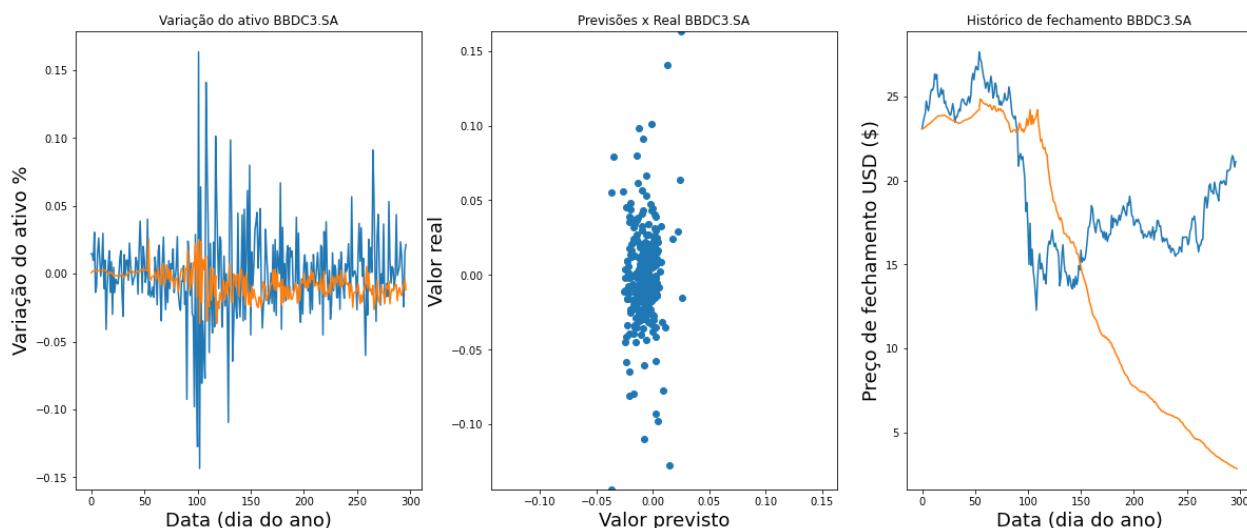


Figura 3. Resultados da rede de Dietsche voltada a previsão do ativo BBDC3

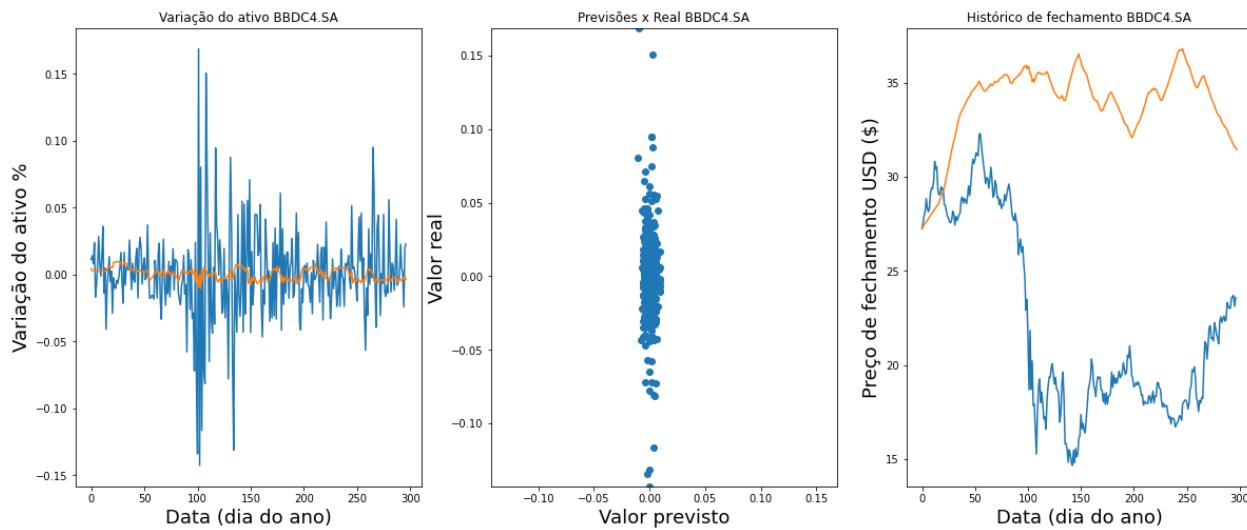


Figura 4. Resultados da rede de Dietsche voltada a previsão do ativo BBDC4

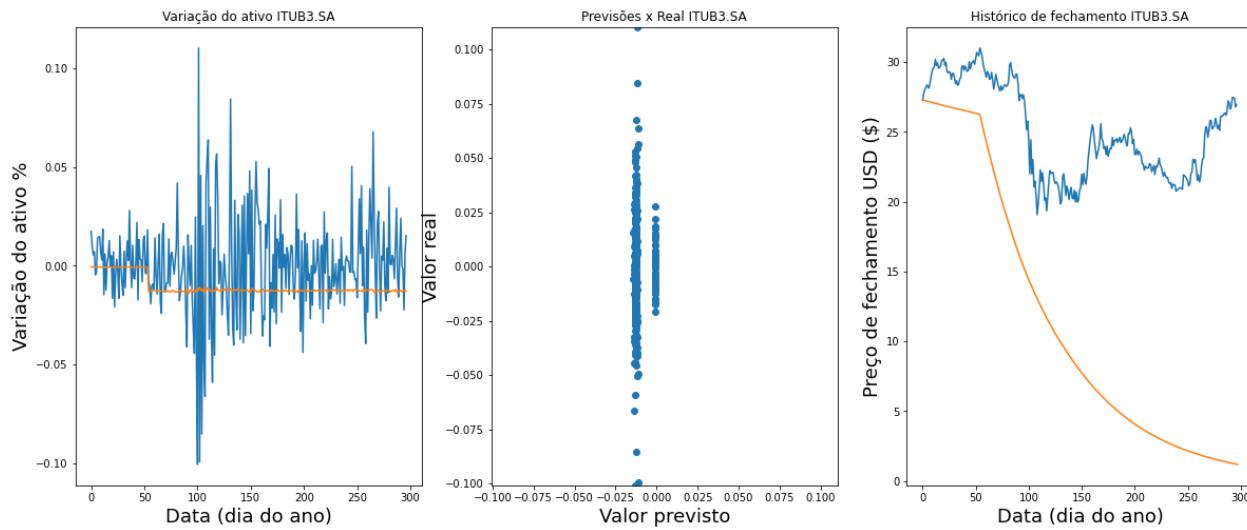


Figura 5. Resultados da rede de Dietsche voltada a previsão do ativo ITUB3

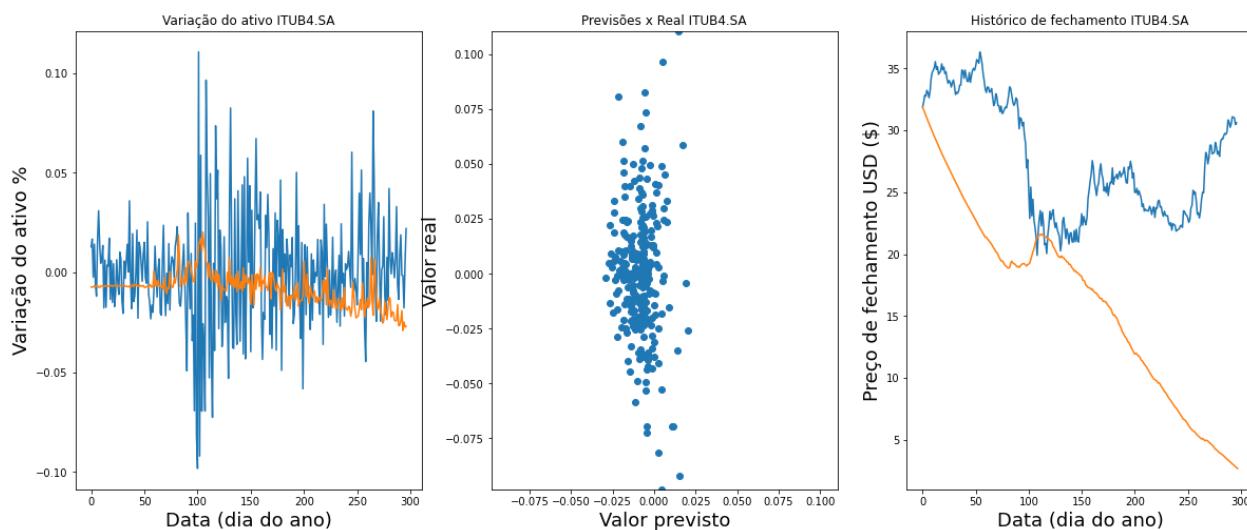


Figura 6. Resultados da rede de Dietsche voltada a previsão do ativo ITUB4

Como se pode verificar, os resultados não foram satisfatórios para as implementações realizadas, os motivos disso podem ser 2: alguma configuração não foi feita de acordo com a rede original; ou o período de treino e testes escolhido foi muito grande e por isso muito enviesado.

Palavras-chave: Mercado Financeiro, Séries Temporais, Redes Neurais Artificiais.

REFERÊNCIAS

- CAMPIGOTTO, P. Otimização na seleção de portfólios de investimento utilizando meta-heurística evolutiva e rede neural artificial. 2019. Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Ciência da Computação como requisito parcial para a obtenção do título de Bacharel em Ciência da Computação.
- COHEN, G.; KUDRYAVTSEV, A.; HON-SNIR, S. Stock market analysis in practice: Is it technical or fundamental? Journal of Applied Finance and Banking, International Scientific Press, v. 1, n. 3, p. 125, 2011.
- DIETSCHE, L. A. F. Using deep learning in stock price forecasting. Dissertação (Mestrado), 2019.
- EBERMAM, R. K. H. K. E. Desenvolvimento de um método híbrido para negociações de ações na bolsa de valores brasileira. SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, Campinas, Galoá, 2018. Disponível em:
<https://proceedings.science/sbpo/papers/negociacao-de-acoes-usando-topsis-e-analise-tecnica>.
- FELIZARDO, L. K. Um estudo sobre arquitetura de redes neurais aplicado a previsão do retorno de ações brasileiras. Dissertação (Mestrado), 2017.
- GAMBOGI, J. A. Aplicação de redes neurais na tomada de decisão no mercado de ações. Dissertação (Mestrado) — Universidade de São Paulo, 2013.
- GIACOMEL, F. d. S. Um método algorítmico para operações na bolsa de valores baseado em ensembles de redes neurais para modelar e prever os movimentos dos mercados de ações. Dissertação (Mestrado), 2016.

MADSEN, H. Time Series Analysis. 1. ed. Boca Raton: CRC Press, 2008. ISBN 978-1-4200-5967-0. 49

MARKOWITZ, H. Portfolio selection. The Journal of Finance, Wiley, v. 7, n. 1, p. 77–91, mar. 1952.
Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1111/j.1540-6261.1952.tb01525.x>>.

NELSON, D. M. Q. Uso de redes neurais recorrentes para previsão de séries temporais financeiras.
Dissertação (Mestrado), 2017.

NETO, A. MERCADO FINANCEIRO. ATLAS, 1999. ISBN 9788522449880. Disponível em:
<<https://books.google.com.br/books?id=Vv9fPwAACAAJ>>.

PYTHON, I. Python. Citeseer, 2019.

RAMINELLI, D. G. d. T. L.; SANTOS, B. S. dos. Aplicação de técnicas de mineração de dados e
aprendizagem de máquina no mercado de ações: Uma revisão sistemática. IX CONGRESSO
BRASILEIRO DE ENGENHARIA DE PRODUÇÃO, Ponta Grossa, Paraná, 2019.

ROCHA, H.; MACEDO, M. A. Previsão do preço de ações usando redes neurais. In: . [S.l.: s.n.], 2011.

RUBIM, F. H. DEEP LEARNING NO MERCADO ACIONÁRIO BRASILEIRO: FATORES QUE
POSSIBILITAM PREVISÕES CONSISTENTES PARA A TOMADA DE DECISÃO EM CONDIÇÕES
DE RISCO. Dissertação (Mestrado) — Universidade de São Paulo, 2019.

RUSSELL S. J; NORVING, P. Artificial Intelligence: A Modern Approach. 3. ed. New Jersey: Pearson
Education, 2009.

ZUPPINI, M. S. et al. Apreçamento de debêntures ilíquidas utilizando redes neurais e clustering.
Dissertação (Mestrado), 2018