

ESTUDO DE FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL APLICADAS AO MERCADO FINANCEIRO.

Victor Hugo de Oliveira Mota², Analucia Vieira Fantin³

¹ Vinculado ao projeto “Desenvolvimento de ferramentas computacionais para apoio ao ensino e pesquisa na área de finanças.”

² Acadêmico do Curso de Ciências Econômicas – ESAG – Bolsista PROBIC/UDESC

³ Orientadora, Departamento de Ciências Econômicas – ESAG – analucia.fantin@udesc.br

Com o avanço da tecnologia, o uso de técnicas de Inteligência Artificial (IA) tem se tornado cada vez mais frequente no âmbito do mercado financeiro no auxílio ao tomador de decisões. Especificamente, o uso de *Machine Learning* (ML) tem se mostrado promissor para esse fim. Este trabalho tem como objetivo o estudo sistemático de técnica e aplicações de ML na área de finanças. Para isso, foram utilizadas revisões bibliográficas dos principais conceitos de ML; escolha e estudo de uma linguagem de programação; teste e análise de alguns algoritmos com potenciais aplicações em finanças.

A linguagem escolhida para utilização neste trabalho foi a linguagem Python, que possui uma sintaxe simples e uma grande capacidade computacional. Além disso, possui uma vasta quantidade de bibliotecas disponíveis no próprio Python para utilização em técnicas de ML, como por exemplo, *pandas*, para manipulação de dados; *numpy* para recursos de álgebra linear; *matplotlib*, para visualização de dados; *scikit-learn*, para algoritmos e métricas de avaliação de modelos; *TensorFlow*, também para algoritmos e métricas de avaliação de modelos.

Essencialmente, ML pode ser definido como o aprendizado estatístico, por parte de um computador, através de um conjunto de dados, de como executar uma determinada tarefa sem que seja explicitamente programado para isso. O mundo das finanças é um grande gerador de dados e informações: milhares de ativos são negociados a todo os segundos, com variações nos preços ao longo do tempo. Sendo assim, técnicas de ML podem utilizar essas informações (i.e. dados) para criar modelos e algoritmos capazes de realizar previsões, como por exemplo, previsões sobre preços e variações na bolsa de valores.

Em geral, os problemas que podem ser resolvidos utilizando ML dividem-se em dois tipos: problemas de classificação, que consistem em aprender e classificar corretamente; e os problemas de regressão, que consistem em aprender e predizer um determinado valor numérico.

Entre os algoritmos de ML, destaca-se um grupo conhecido como Redes Neurais Artificiais. Os algoritmos mais rudimentares surgiram em 1943 e tentavam reproduzir artificialmente um neurônio biológico para realizar tarefas computacionais, mas seu uso se acentuou drasticamente a partir dos anos de 1990, com o avanço das capacidades computacionais dos computadores. Os algoritmos de Redes Neurais são poderosas e versáteis ferramentas, muito úteis em problemas complexos e que envolvem grande quantidade de dados.

A arquitetura de uma rede neural consiste em neurônios divididos em camadas: a camada de entrada (input layer); as camadas ocultas (hidden layers); a camada de saída (output layer) (Figura 1). Os problemas de classificação e regressão consistem essencialmente em encontrar um conjunto de parâmetros (pesos e viés), que dado um conjunto de dados de entrada, estimem valores de saída,

de tal modo que minimizem o erro entre o valor predito e o valor esperado. Para a realização dessa tarefa, o conjunto de dados é dividido em três subconjuntos: o conjunto de treino, utilizado para definir os parâmetros ótimos da rede; o conjunto de validação utilizado para avaliar o modelo; e o conjunto de teste utilizado para confirmar os resultados obtidos.

Para estudo de caso foi utilizado uma rede neural artificial para predição do preço de casas na região de Boston, EUA, com base em características da região onde estavam inseridas. Os dados foram obtidos através do serviço de censo estadunidense. As características do modelo, assim como os resultados obtidos, estão organizadas na tabela 1.

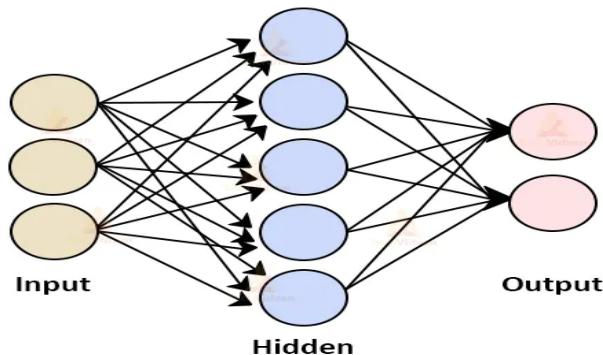


Figura 1. Arquitetura de uma Rede Neural Artificial

Número de camadas	3
Número de neurônios	Entrada: 13 Ocultas: 128, 128, 256 Saída: 1
Otimizador	Adam
Taxa de aprendizado	0,025
Épocas	50
Regularizador	Ridge (L1) 0,001
Função <i>Loss</i>	Erro quadrático médio (EQM)
Avaliação final (Raiz do EQM)	4,12

Tabela 1. Descrição da Rede Utilizada.

Esse estudo terá continuidade dentro de um novo projeto, iniciado em agosto de 2021, voltado ao desenvolvimento de aplicações de ML em problemas relacionados ao mercado financeiro.

Palavras-chave: Finanças. Machine Learning. Redes Neurais.

Apoio: