

ESTUDO DE FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL PARA APLICAÇÃO FUTURA AO MERCADO FINANCEIRO¹

Maurício Losso Salvador², 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 Engenharia de Controle e Automação/UFSC – Bolsista CNPQ/UDESC

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

Tendo em vista a busca contínua das empresas por melhorias em investimento e tomadas de decisão a fim de redução dos prejuízos relacionados às mesmas, faz-se necessário o estudo e a aplicação de ferramentas na área da inteligência artificial que, por sua vez, tem como objetivo a redução das falhas humanas, buscando a otimização e maximização do lucro no escopo estudado.

É nesse contexto que, ao longo do período, assuntos variados de cunho tecnológico voltados à IA foram abordados na tentativa de entender melhor o funcionamento das redes neurais no geral, na sua construção, parâmetros, configurações e da lógica relacionada. O estudo foi realizado semanalmente baseado em livros de *Deep Learning* online e atividades práticas no desenvolvimento de códigos em Python, atrelados às bibliotecas como o *TensorFlow* e *Scikit-learn*. Primeiramente, começamos por aprender um pouco sobre a história da inteligência artificial a fim de compreendermos a lógica e a base das primeiras redes neurais elaboradas no planeta. Seguindo a partir desse conhecimento, fomos capazes de interpretar o funcionamento das redes neurais e as diferenças entre as redes simples e as profundas, sendo essas últimas as que contém várias camadas de neurônios em sua composição. Além disso, ficou claro também o entendimento do que são as funções de ativação e seus respectivos tipos em cada uma das células de nossa rede, bem como dos parâmetros (pesos e *bias*) mutáveis e responsáveis por toda a lógica por trás das redes neurais.

Segundo o estudo realizado até então, uma rede neural pode ser “treinada” através da minimização de uma função erro, que é dependente dos parâmetros pesos e bias, os quais estão relacionados aos neurônios que compõem a rede. A atividade consiste dos seguintes passos: uma base de dados é selecionada, onde entradas e saídas conhecidas são relacionadas e formam o conjunto de dados, chamado “dados de treino” da rede neural. A rede neural, após uma série de erros e ajustes das funções de custo e dos métodos de descida de gradiente, que buscam minimizar a diferença entre os resultados de saída e entrada, atualizam os parâmetros do sistema a fim de alcançar valores adequados, que satisfaçam as imposições propostas pelos dados de treino. Feito isso, é necessário realizar a validação dos resultados a partir de um novo conjunto de dados, chamado “dados de validação”. Essa etapa permite otimizar ainda mais o valor dos parâmetros e conferir se o sistema está realmente funcional. Em seguida, é possível testar a rede neural através de um terceiro conjunto de dados, chamado “dados de teste”. Este último passo permite avaliar o comportamento da rede com um conjunto novo de dados, diferente daqueles usados durante a fase de treinamento. A partir desse procedimento, podemos quantificar o erro gerado pela rede, assim como verificar sua eficiência com valores desconhecidos. Caso o sistema esteja acertando com um percentual acima de 90%, sabemos que o sistema foi bem calibrado e pode ser utilizado para as demais aplicações. Caso tenhamos valores que divergem dos resultados esperados para a rede, é

necessário fazer ajustes finos a fim de obter uma rede bem configurada, que nos forneça valores próximos aos desejados.

Além do procedimento clássico de criação da rede neural, ainda podemos estudar os conceitos de *overfitting*, quando o sistema se adapta tão bem aos dados de treino que acaba não sendo generalizado para todos os problemas, e os possíveis jeitos de solucionar tal empecilho com as regularizações e o *dropout* (processo que consiste na desativação de neurônios aleatórios da rede a fim de atualizarmos melhor e de forma mais rápida os pesos do sistema).

A partir desses conhecimentos e das atividades práticas em Python, conseguimos desenvolver códigos para análises e previsão de resultados que, futuramente, podem ser adaptados para uso amplo na otimização de carteiras de investimento e análises do mercado financeiro, como propõe o estudo em questão.

Palavras-chave: Mercado de ações. Mineração de dados. Inteligência artificial.