


UNIVERSIDADE FEDERAL DO PARANÁ

LUÍS ANTONIO RUIZ MARTINS PASTRE

SMART STOCK



CURITIBA

2021

LUÍS ANTONIO RUIZ MARTINS PASTRE

SMART STOCK

Monografia apresentada ao curso de Pós-Graduação em Inteligência Artificial Aplicada, Setor de Educação Profissional e Tecnológica, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Especialista em Inteligência Artificial Aplicada.

Orientador: Prof. Dr. Razer Anthom Nizer Rojas Montaña

Coordenador: Prof. Dr. Razer Anthom Nizer Rojas Montaña

CURITIBA

2021




MINISTÉRIO DA EDUCAÇÃO
SETOR DE EDUCAÇÃO PROFISSIONAL E
TECNOLÓGICA UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
CURSO DE PÓS-GRADUAÇÃO INTELIGÊNCIA
ARTIFICIAL APLICADA - 40001016348E1

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação INTELIGÊNCIA ARTIFICIAL APLICADA da Universidade Federal do Paraná foram convocados para realizar a arguição da Monografia de Especialização de **LUIS ANTONIO RUIZ MARTINS PASTRE** intitulada: **Smart Stock**, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

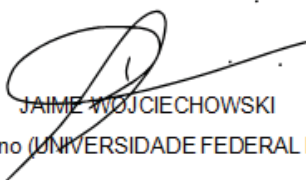
A outorga do título de especialista está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 25 de Novembro de 2021.



RAZER ANTHOM NIZER ROJAS MONTAÑO

Presidente da Banca Examinadora



JAIME WOJCIECHOWSKI

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Dedico esse trabalho à minha esposa Taciane Aparecida Siqueira Pastre, minha companheira, que está comigo em todos os momentos e sempre torce por mim.

AGRADECIMENTOS

Primeiramente, agradeço a Deus pela oportunidade que me proporcionou para a realização dessa especialização. Depois, a minha esposa Taciane Pastre, que me apoiou durante todo o curso, abrindo mão de viagens e tempo juntos para que eu pudesse alcançar meu objetivo e aos meus pais, que sempre me mostraram o valor do esforço e da dedicação. Gostaria também de agradecer a Universidade Federal do Paraná, que ofertou o curso e em especial os coordenadores, professores e aos demais, que idealizaram e trabalharam para que essa especialização fosse realizada de forma excepcional e com um grau elevado de qualidade.

14. Pois a sabedoria é mais proveitosa do que a prata e rende mais do que o ouro. 15. É mais preciosa do que rubis; nada do que você possa desejar se compara a ela. (Provérbios 14-15)

RESUMO

O mercado financeiro influencia em todas esferas da sociedade mundial, despertando assim, a necessidade de mecanismos que possam auxiliar neste processo e, conseqüentemente num maior equilíbrio da economia. Pensando nisso, este trabalho foi desenvolvido para criar uma ferramenta que auxilie grandes, médios e pequenos investidores do mercado financeiro em suas negociações, onde usando a Inteligência Artificial como base, possam prever preços futuros das ações, a partir do padrão de preços históricos registrados num período aproximado de um ano e meio.

Para o estudo foram selecionadas 5 ações aleatórias de segmentos diferentes, a fim de atestar a eficácia das técnicas usadas. O experimento contemplou a implementação de um sistema, em que é possível realizar a importação dos dados históricos, acompanhar o comportamento das ações e realizar a comparação dos valores reais dos preços das ações com o que foi predito pelo sistema. As técnicas usadas na construção desta pesquisa são as mais modernas disponíveis no mercado atual no que se refere a Inteligência Artificial e classificação das séries temporais, quais sejam: Machine Learning, Deep Learning, Redes Neurais Recorrentes (RNN) e Long Short-Term Memory (LTSM). Do estudo foi possível prever através dos algoritmos os valores médios das ações junto a bolsa de valores. Em que pese o mercado financeiro seja especulativo, baseado em informações diárias imprevisíveis que valorizam e desvalorizam as ações, espera-se com este trabalho contribuir na predição da tendência monetária.

Palavras-chave: Inteligência Artificial. Machine Learning. Deep Learning. Redes Neurais Recorrentes. RNN. Long Short-Term Memory. LTSM.

ABSTRACT

The financial market influences all spheres of world society, thus awakening the need for mechanisms that can help in this process and, consequently, in a greater balance in the economy. With that in mind, this work was developed to create a tool to help large, medium and small investors in the financial market in their negotiations, where using Artificial Intelligence as a basis, they can predict future stock prices, based on the pattern of historical prices recorded in a period of approximately one and a half year.

For the study, 5 random actions from different segments were selected, in order to attest the effectiveness of the techniques used. The experiment included the implementation of a system, in which it is possible to import historical data, monitor the behavior of stocks and compare the actual values of stock prices with what was predicted by the system. The techniques used in the construction of this research are the most modern available in the current market with regard to Artificial Intelligence and classification of time series, namely: Machine Learning, Deep Learning, Recurrent Neural Networks (RNN) and Long Short-Term Memory (LSTM). From the study, it was possible to predict through the algorithms the average values of shares with the stock exchange.

Although the financial market is speculative, based on unpredictable daily information that value and devalue stocks, it is expected that this work contributes to the prediction of monetary trends.

Keywords: Artificial Intelligence. Machine Learning. Deep Learning. Recurring Neural Networks. RNN. Long Short-Term Memory. LSTM.

LISTA DE FIGURAS

FIGURA 1 – Arquitetura Deep Learning	24
FIGURA 2 – Sistema nervoso biológico	25
FIGURA 3 – Modelo de Neurônio Artificial	26
FIGURA 4 – Modelo de Rede Neural Artificial Perceptron	26
FIGURA 5 – Arquitetura da RNA.....	27
FIGURA 6 – Arquitetura da RNN.....	29
FIGURA 7 – Arquitetura da RNN.....	30
FIGURA 8 – Ciclo da Interação do Scrum.....	34
FIGURA 9 – Planejamento das Sprints	35
FIGURA 10 – Cronograma Gantt	35
FIGURA 11 – Planilha eletrônica do GoogleDocs com os valores das ações.....	37
FIGURA 12 – Desenho da solução	43
FIGURA 13 – Tela de importação dos dados das ações do sistema	44
FIGURA 14 – Tela de importação dos dados em andamento	44
FIGURA 15 – Tela de monitoramento	57
FIGURA 16 – Botão que inicia a simulação da tela de monitoramento.....	58
FIGURA 17 – Tela de simulação de preço de ação	59
FIGURA 18 – Tela de monitoramento alertando o comportamento das ações	60

LISTA DE GRÁFICOS

GRÁFICO 1 – Gráfico do 1º treinamento e teste do preço de fechamento da ação da SQIA3.	44
GRÁFICO 2 – Gráfico de comparação do valor real x previsto do 1º experimento da SQIA3	46
GRÁFICO 3 – Gráfico do 2º treinamento e teste do preço de fechamento da ação da SQIA3.	46
GRÁFICO 4 – Gráfico de comparação do valor real x previsto do 2º experimento da SQIA3	47
GRÁFICO 5 – Gráfico do 1º treinamento e teste do preço de fechamento da PETR4.	47
GRÁFICO 6 – Gráfico de comparação do valor real x previsto do 1º experimento da PETR4	48
GRÁFICO 7 – Gráfico do 2º treinamento e teste do preço de fechamento da PETR4.	48
GRÁFICO 8 – Gráfico de comparação do valor real x previsto do 2º experimento da PETR4	49
GRÁFICO 9 – Gráfico do 1º treinamento e teste do preço de fechamento da VALE3.	50
GRÁFICO 10 – Gráfico de comparação do valor real x previsto do 1º experimento da VALE3.....	50
GRÁFICO 11 – Gráfico do 2º treinamento e teste do preço de fechamento da VALE3.....	51
GRÁFICO 12 – de comparação do valor real x previsto do 2º experimento da VALE3	52
GRÁFICO 13 – Gráfico do 1º treinamento e teste do preço de fechamento do HGLG11.....	52
GRÁFICO 14 - Gráfico de comparação do valor real x previsto do 1º experimento do HGLG11	53
GRÁFICO 15 – Gráfico do 2º treinamento e teste do preço de fechamento do HGLG11.....	53
GRÁFICO 16 – Gráfico de comparação do valor real x previsto do 2º experimento do HGLG11	54

GRÁFICO 17 – Gráfico do 1º treinamento e teste do preço de fechamento do VISC11.....	54
GRÁFICO 18 – Gráfico de comparação do valor real x previsto do 1º experimento do VISC11.....	55
GRÁFICO 19 – Gráfico do 2º treinamento e teste do preço de fechamento do VISC11.....	55
GRÁFICO 20 – Gráfico de comparação do valor real x previsto do 2º experimento do VISC11.....	56

LISTA DE QUADROS

QUADRO 1 – Primeira configuração da LTSM da SQIA3	39
QUADRO 2 – Primeira configuração das camadas de LTSM da SQIA3.....	39
QUADRO 3 – Segunda configuração da LTSM da SQIA3	39
QUADRO 4 – Segunda configuração das camadas de LTSM da SQIA3.....	39
QUADRO 5 – Primeira configuração da LTSM da PETR4	39
QUADRO 6 – Primeira configuração das camadas de LTSM da PETR4.....	39
QUADRO 7 – Segunda configuração da LTSM da PETR4	40
QUADRO 8 – Segunda configuração das camadas de LTSM da PETR4.....	40
QUADRO 9 – Primeira configuração da LTSM da VALE3	40
QUADRO 10 – Primeira configuração das camadas de LTSM da VALE3	40
QUADRO 11 – Segunda configuração da LTSM da VALE3	40
QUADRO 12 – Segunda configuração das camadas de LTSM da VALE3	40
QUADRO 13 – Primeira configuração da LTSM do HGLG11	41
QUADRO 14 – Primeira configuração das camadas de LTSM do HGLG11	41
QUADRO 15 – Segunda configuração da LTSM do HGLG11	41
QUADRO 16 – Segunda configuração das camadas de LTSM do HGLG11	41
QUADRO 17 – Primeira configuração da LTSM do VISC11	41
QUADRO 18 – Primeira configuração das camadas de LTSM do VISC11	41
QUADRO 19 – Segunda configuração da LTSM do VISC11	41
QUADRO 20 – Segunda configuração das camadas de LTSM do VISC11	42

LISTA DE TABELAS

TABELA 1 – Função de ativação X fórmula	28
TABELA 2 – Lista de aplicativos instalados e configurados	36

LISTA DE ABREVIATURAS OU SIGLAS

MLP	- Multi Layer Perceptron
LSTM	- Long Short-Term Memory
GRUs	- Gated Recurrent Units
NA	- Neurônio Artificial
RNA	- Rede Neural Artificial
RNN	- Recurrent Neural Network
IA	- Inteligência Artificial
JVM	- Java Virtual Machine
UML	- Unified Modeling Language

LISTA DE SÍMBOLOS

SUMÁRIO

1 INTRODUÇÃO	16
1.1 JUSTIFICATIVA	17
1.2 OBJETIVOS	17
1.2.1 Objetivo geral	17
1.2.2 Objetivos específicos.....	18
1.3 ORGANIZAÇÃO DO TRABALHO	18
2 REVISÃO DE LITERATURA	19
2.1 FUNDAMENTAÇÃO TEÓRICA DO NEGÓCIO.....	19
2.1.1 Conceito e principais apontamentos a respeito da Bolsa de Valores.....	19
2.1.2 Vantagens de aplicação na bolsa de valores	20
2.1.3 Funcionalidade	20
2.2 FUNDAMENTAÇÃO TEÓRICA DAS TECNOLOGIAS.....	21
2.2.1 Inteligência Artificial.....	21
2.2.2 Deep Learning	22
2.2.3 Redes Neurais Artificiais	25
2.2.4 Rede Neural Recorrente (RNN)	28
2.2.5 Long Short-Term Memory (LSTM)	29
2.2.6 UML.....	31
2.3 FERRAMENTAS	32
2.3.1 Java.....	32
2.3.2 DeepLearning4j.....	33
2.3.3 Scrum	33
3 MATERIAL E MÉTODOS	35
3.1.1 Planejamento	35
3.2 FERRAMENTAS E VERSÕES.....	36
3.3 DADOS.....	36
3.4 DESENVOLVIMENTO DO PROJETO	37
3.4.1 Sprint 0 – Montagem de ambiente	37
3.4.2 Sprint 1 – Pesquisa de fonte de dados.....	38
3.4.3 Sprint 2 – Desenvolvimento da rotina de carga de dados	38
3.4.4 Sprint 3 – Treinamento profundo de máquina	38
3.4.5 Sprint 4 – Desenvolvimento do programa de monitoramento.....	42

3.4.6 Sprint 5 - Análise de resultado	42
4 APRESENTAÇÃO DOS RESULTADOS	43
4.1 ARQUITETURA DO SISTEMA.....	43
4.2 IMPORTAÇÃO DE DADOS.....	43
4.3 O TREINAMENTO E A PREDIÇÃO	44
4.3.1 Experimentos com o ativo da empresa SINQIA (SQIA3).	44
4.3.2 Experimentos com o ativo da empresa Petrobras (PETR4).	47
4.3.3 Experimento com o ativo da empresa Vale do Rio Doce (VALE3).	50
4.3.4 Experimento com o ativo do fundo de investimento CSHG Logística (HGLG11).	
52	
4.3.5 Experimento com o ativo do fundo de investimento VINCI Shopping Centers (VISC11).....	54
4.4 O MONITORAMENTO	57
5 CONSIDERAÇÕES FINAIS	61
5.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS	61
REFERÊNCIAS.....	63
UC001 USE CASE DE IMPORTAÇÃO DE DADOS.....	66
APÊNDICE 3 – DIAGRAMA DE CLASSE DA BIBLIOTECA DO PROJETO SMART- STOCK-IA-ENTITY	72
APÊNDICE 4 – DIAGRAMA DE CLASSE DA BIBLIOTECA DO PROJETO SMART- STOCK-IA-SERVICE	73
APÊNDICE 5 – REPOSITÓRIO DO CÓDIGO FONTE	74
APÊNDICE 6 – DIAGRAMA DE ENTIDADE RELACIONAMENTO.....	75

1 INTRODUÇÃO

A bolsa de valores funciona como um mercado comum de perecíveis, em que suas mercadorias podem ser comparadas a pequenas fatias dos patrimônios de várias empresas, conhecidas como papéis de ação. Quando alguém investe comprando uma ou mais fatias, ele se torna um sócio anônimo das companhias originárias dos papéis que adquiriu e, conforme o resultado financeiro delas, pode ganhar ou perder dinheiro (NIGRO, 2018).

As transações de compras e vendas de ações são realizadas de forma eletrônica, através de uma corretora ou pelo próprio investidor. Os preços das ações são determinados pela lei de oferta e procura, pela situação política do país, por acontecimentos mundiais, decisões corporativas e ainda, diante de alguns fatores emocionais de seus investidores, que também podem influenciar no mercado. A principal entidade de compra e venda de ações no Brasil é a B3, pois além de ser a maior da América Latina é a única do país que mantém todas as atividades originárias de uma bolsa de valores. (NIGRO, 2018)

O fator primordial que faz as empresas comercializarem suas ações é obtenção de recursos financeiros para expansão de suas operações, abatimento de suas dívidas, melhoria de sua saúde financeira, dentre outras (NIGRO, 2018). O mercado de ações é considerado um investimento de alto risco, pois os preços dos papéis oscilam a todo tempo, podendo proporcionar ganhos ou perdas, por esse motivo é essencial que o investidor avalie o contexto econômico, histórico da empresa e o desempenho dela na bolsa de valores. Ainda assim o investidor pode ser surpreendido com perda de dinheiro caso as ações de sua carteira desvalorizem (CASTRO, 2020).

De maneira a minimizar perdas e garantir uma escolha mais adequada pelo investidor no momento de compra e venda de suas ações é que presente trabalho foi desenvolvido. Através dele percebe-se como a tecnologia, através da inteligência artificial, pode auxiliar os investidores em rentabilizar suas carteiras de investimentos, prevendo comportamentos dos valores futuros dos papéis das ações.

1.1 JUSTIFICATIVA

Os investidores utilizam de notícias e de alguns dados relativos as empresas listadas na bolsa para decidir se compram ou vendem ações. Ocorre que, devido a uma enorme quantidade e rapidez de informações difundidas em diversos canais de comunicação em um ambiente mundial, é difícil para um investidor receber, processar e verificar se algumas dessas informações poderão impactar nos preços das ações de sua carteira e tomar alguma atitude de compra ou venda antes dos demais investidores.

O mercado de ações da bolsa de valores tem como sua principal característica ser um mercado especulativo, trabalha basicamente em cima de informações e notícias divulgadas, fazendo com que os preços dos papéis valorizem ou desvalorizem. Se os investidores comprarem ou venderem os papéis no início da curva da variação dos preços das ações, eles se anteciparão ao mercado sem mesmo ter conhecimento da causa que resultou na valorização ou desvalorização da ação e obter ganhos ou evitar perdas.

Acredita-se que através do presente estudo é possível realizar uma predição da tendência monetária, identificando aumentos e quedas nos valores de ações, ainda que não de maneira total, haja vista a oscilação advinda de especulações dada a sua imprevisibilidade, e com isso auxiliar nas negociações do investidor, de modo a reduzir suas perdas e garantir maior êxito em suas atividades.

1.2 OBJETIVOS

Neste tópico serão abordados os principais objetivos e os limites de sua abrangência.

1.2.1 Objetivo geral

Desenvolver uma ferramenta que analisasse os preços das ações por um determinado período de tempo, predissesse a tendência monetária desses papéis e, caso o sistema identificasse que a ação não está seguindo o que foi predito, seria emitido um alerta para que fosse tomada uma atitude pelo investidor de compra ou venda.

1.2.2 Objetivos específicos

Selecionar papéis de 5 empresas de áreas distintas de atuação e comparar se a ferramenta desenvolvida apresenta dados relevantes, capazes de auxiliar efetivamente nas tomadas de decisões de compras ou vendas de ações.

As ações escolhidas foram: PETR4(Petrobras), VALE3 (Vale do Rio Doce), VISC11 (Fundo de Investimento VINCI Shopping Centers), HGLG11 (Fundo de Investimento CSHG Logística) e SQIA3 (Sinqia).

As principais funcionalidades são:

- Importar os dados diários das ações;
- Treinar modelos com os dados importados;
- Fazer a predição do comportamento das ações;
- Monitorar a volatilidade dos preços das ações;
- Avisar quando o preço da ação saiu do previsto.

1.3 ORGANIZAÇÃO DO TRABALHO

O presente estudo está dividido em cinco capítulos. No capítulo 1 há a introdução deste trabalho, sua justificativa, seus objetivos e as principais funcionalidades do sistema.

No capítulo 2, apresenta-se a revisão de literatura, com a fundamentação teórica negocial e a fundamentação teórica tecnológica, bem como as ferramentas e as metodologias utilizadas.

O capítulo 3 descreve como os materiais e métodos foram utilizados no trabalho.

O capítulo 4 indica a arquitetura da solução, a forma do funcionamento do sistema e os resultados obtidos pelos experimentos.

Por fim, no capítulo 5 são apresentadas as considerações finais e recomendações para trabalhos futuros.

2 REVISÃO DE LITERATURA

Poderá ser utilizado por investidores da bolsa de valores e/ou principalmente por *Traders*, o sistema utiliza o conceito de *Deep Learning*, desenvolvida na linguagem de programação *Java* e utilizando o framework chamado *DeepLearning4j*, da qual a aplicação será treinada diariamente com os dados dos preços de valor de abertura, valor de fechamento, maior valor, menor valor e volume de negociações das ações.

A seguir serão apresentados os conceitos utilizados para o desenvolvimento da aplicação, as suas bibliotecas e ferramentas.

2.1 FUNDAMENTAÇÃO TEÓRICA DO NEGÓCIO

Este tópico esclarece a que se destina a Bolsa de valores, seu funcionamento, bem como as vantagens em sua aplicação.

2.1.1 Conceito e principais apontamentos a respeito da Bolsa de Valores

Segundo o Nigro (2018) a Bolsa de Valores é o ambiente mais importante de negociação das ações das empresas de capital aberto, ou seja, empresas do tipo S.A (Sociedade Anônima). Em uma empresa de capital aberto, ações, que correspondem a um percentual de seu patrimônio, são colocadas a venda e, quando adquiridas, o comprador torna-se, automaticamente, sócio/acionista dessa companhia, o que dá ao mesmo algumas vantagens, como o voto em assembléias, o recebimento de dividendos ou mesmo o aumento de seu patrimônio com a venda futura dessas ações.

Todas as transações desta natureza ficam sob a tutela da instituição financeira chamada de Bolsa de Valores e as negociações de compra e venda são feitas de forma digital, através do chamado Home Broker, que é uma espécie de painel eletrônico disponibilizado pelas corretoras.

As ações são disponibilizadas de duas formas: Mercado primário, também conhecido como Initial Public Offering (IPO), em que o investidor compra as ações diretamente da empresa e o mercado secundário, onde a venda e compra são realizadas entre os próprios investidores. Nesse ambiente todo o conhecimento

econômico será fundamental para a obtenção de bons resultados financeiros, pois é um mercado de alto risco e muita volatilidade (NIGRO, 2018).

2.1.2 Vantagens de aplicação na bolsa de valores

Nigro (2018) diz que o mercado acionário é uma boa opção de entrada de capital para empresas que estão expandindo seus negócios e acelerando seus planos de investimentos. Isso porque esse tipo de captação de dinheiro seria mais atrativo para as companhias do que recorrer a empréstimos bancários, onde se endividariam e teriam que pagar juros.

De modo geral, a entrada da empresa na bolsa traz uma maior liquidez patrimonial e gera uma reserva financeira sem que para isso precise contrair uma dívida cara, já que está trocando ações por dinheiro.

Outro aspecto importante destacado por Nigro (2018) é que a abertura de capital padroniza as empresas, uma vez que se veem obrigadas a cumprir uma série de regras impostas pelas autoridades legais e pela própria Bolsa de valores, como a publicação de balanços e fatos relevantes, condição que além de tornar as companhias de certa maneira homogêneas, também trás maior transparência aos negócios e protege os investidores.

2.1.3 Funcionalidade

A Bolsa de Valores é um ambiente de negociação de compra e venda de ativos que estão listados na bolsa. No Brasil a instituição que representa a Bolsa de Valores é chamada de B3. A B3 tem a responsabilidade de oferecer um ambiente seguro e único. A B3 está ligada a uma empresa chamada CBLC, que é a responsável por todas as transações realizadas. Todas as operações de compra e venda via Home Broker, isto é, de forma digital, assim como seus participantes, são fiscalizados e regulados pela Comissão de Valores Mobiliários (CVM). Para transações de compra e venda, o investidor estará obrigado a realiza-las fazer através de uma corretora. (NIGRO, 2018)

Vários fatores influenciam o mercado financeiro e com isso, o preço das ações. E maneira resumida pode-se dizer que, quanto mais os acionistas se interessam em comprar um ativo, mais esse papel, essa ação, se valoriza e, por

outro lado, quanto menos interessados em sua compra, mais o valor se deprecia. Outro fator que influencia a precificação dos ativos é a principal característica da bolsa, a especulação de mercado, onde qualquer notícia que acredite-se ter o poder de influenciar na alta ou baixa de preços, pode fazer com que os investidores se antecipem, comprando ou vendendo as ações, tudo visando a obtenção de lucro ou a extinção de prejuízo (BTG PACTUAL DIGITAL, 2018).

Essa sensibilidade nos preços das ações, pode causar grande crescimento as empresas detentoras das ações ou sua completa ruína, chegando a falência se for mal gerida e não entregar os resultados esperados, pois os investimentos captados na bolsa podem diminuir drasticamente, fazendo com que a empresa perca sua rentabilidade (BTG PACTUAL DIGITAL, 2018).

2.2 FUNDAMENTAÇÃO TEÓRICA DAS TECNOLOGIAS

Nesse item são apresentados os conceitos e fundamentos das tecnologias usadas nesse estudo.

2.2.1 Inteligência Artificial

Russell e Norvig (2013) comentam que a Inteligência Artificial (IA), não somente tenta compreender o funcionamento do cérebro humano no que tange ao pensamento, raciocínio e comportamento, conforme o ambiente e a situação, mas também construir agentes inteligentes capazes de tomar decisões para executar determinada tarefa de forma autônoma, baseada em um conhecimento adquirido. Segundo os autores, tal conhecimento é aprendido através de um treinamento prévio e contínuo, denominado *Aprendizado de Máquina*, ou em inglês, *Machine Learning*.

O *Aprendizado de Máquina* é um sistema que através de uma base de conhecimentos é programado para aprender sobre um determinado tema por indução, empregando o princípio de inferência, onde se obtêm conclusões genéricas, através de um conjunto de exemplos. Com esses exemplos, a máquina aprende a induzir uma função ou hipótese capaz de resolver um problema. Segue uma lista de alguns problemas reais que a máquina conseguiu resolver via *Machine Learning* (FACELI, et al. , 2011).

- Reconhecimento de palavras faladas;
- Predição de taxas de cura de pacientes com diferentes doenças;
- Detecção do uso fraudulento de cartões de crédito;
- Condução de automóveis de forma autônoma em rodovias;
- Ferramentas que jogam gamão e xadrez de forma semelhante aos de campeões;
- Diagnóstico de câncer por meio da análise de dados de expressão gênica.

A Inteligência Artificial nasceu em meados dos anos 1950, período em que foram colecionados diversos projetos fracassados, porém através deles e de vários outros estudos, tem-se evoluído muito no tema, assim como em outras áreas da tecnologia da informação (DE MEDEIROS, 2018).

Segundo De Medeiros (2018), a Inteligência Artificial é, sem dúvida, entre todas as tecnologias ou ferramentas inventadas pelo homem, a mais emblemática, pois ela executa algumas tarefas que só o ser humano é capaz de fazer, realizada outras melhores que os homens e ainda, é capaz de fazer coisas de forma tão rápida e eficiente que ultrapassam a capacidade humana. Dentre as tarefas é possível destacar ações como dirigir um automóvel de forma autônoma, controlar uma indústria, empreender em uma busca na internet, controlar um eletrodoméstico, entre outras.

Para a realização de tarefas, estão envolvidos diversos algoritmos e dispositivos, os quais simulam as funções cognitivas, estímulos do cérebro e ações humanas.

A invenção da IA proporcionou o desenvolvimento de diversos processos inteligentes que auxiliam no reconhecimento de padrões, execução de tarefas repetitivas e tomadas de decisões (DE MEDEIROS, 2018).

2.2.2 Deep Learning

Deep Learning (DL) ou *Aprendizado Profundo* é um dos temas que mais tem centros de pesquisas no mundo por sua multiplicidade de aplicação e por resultados

extremamente satisfatórios. Empresas de grande porte em tecnologia como Google e Facebook, por exemplo, analisam grandes volumes de dados utilizando *Deep Learning* em várias de suas aplicações, como reconhecimento de fala, imagem e tradução.

Deep Learning é um estilo de aprendizagem de máquina que utiliza rede neural profunda, onde executa diversos algoritmos em uma série de camadas, assemelhando-se ao funcionamento do cérebro humano, em que um neurônio processa uma pequena parte da informação fazendo com que a máquina seja capaz de gerar conteúdo por assimilação, utilizando o aprendizado realizado anteriormente (PACHECO e PEREIRA, 2015).

Segundo Beysolow II (2017) com o avanço teórico significativo e a melhora tecnológica da capacidade de processamento das máquinas atuais, o *Deep Learning* é o campo da ciência que mais tem crescido atualmente. Essa tecnologia vem sendo bastante usada em carros autônomos, reconhecimento de imagens em mídias sociais e tradução de textos. O *Deep Learning* é um campo da IA voltada a construir algoritmos que explicam e aprendem com um conjunto de dados não alcançados pelos algoritmos de *Machine Learning*.

Machine Learning é a ciência de criação e estudo de algoritmos que, através da estatística e da matemática, deu origem a *Inteligência Artificial*, porém com algumas limitações de desempenho no treinamento de máquina e com resultados em suas predições não tão satisfatórios em comparação ao *Deep Learning*, principalmente quando se fala em visão computacional, onde os resultados de seus algoritmos deixam a desejar.


Beysolow II (2017) também comenta que os modelos de *Deep Learning* são frequentemente inspirados em várias áreas do conhecimento como: neurociência e teorias de game. Muitos modelos seguem as estruturas do sistema nervoso humano.

Embora originalmente o *Deep Learning* tenha começado com o foco inicial similar ao de *Machine Learning*, que tem em sua característica restringir a satisfação em vários graus de complexidade, o *Deep Learning* evoluiu para abranger uma definição mais ampla de seus algoritmos que não somente são capazes de prever e classificar, mas também podem aprender em diferentes níveis de complexidade. Para exemplificar, podemos usar o reconhecimento de imagem usando *Deep Learning*, onde a rede neural está baseada no reconhecimento de cílios, rostos, pessoas e assim por diante, esse nível de complexidade é necessário para criar um

software inteligente. É possível identificar esse processo na funcionalidade de autocorreção, em que se sugerem correções e alterações no texto, conforme os padrões de fala e escrita, observando uma determinada pessoa.

A FIGURA 1 mostra a estrutura dos modelos de *Deep Learning* que frequentemente tem camadas não lineares, unidades de processamentos (neurônios) com múltiplas camadas de diferentes níveis de abstração dos dados.

FIGURA 1 – Arquitetura Deep Learning



FONTE: Ponti e Costa (2017).

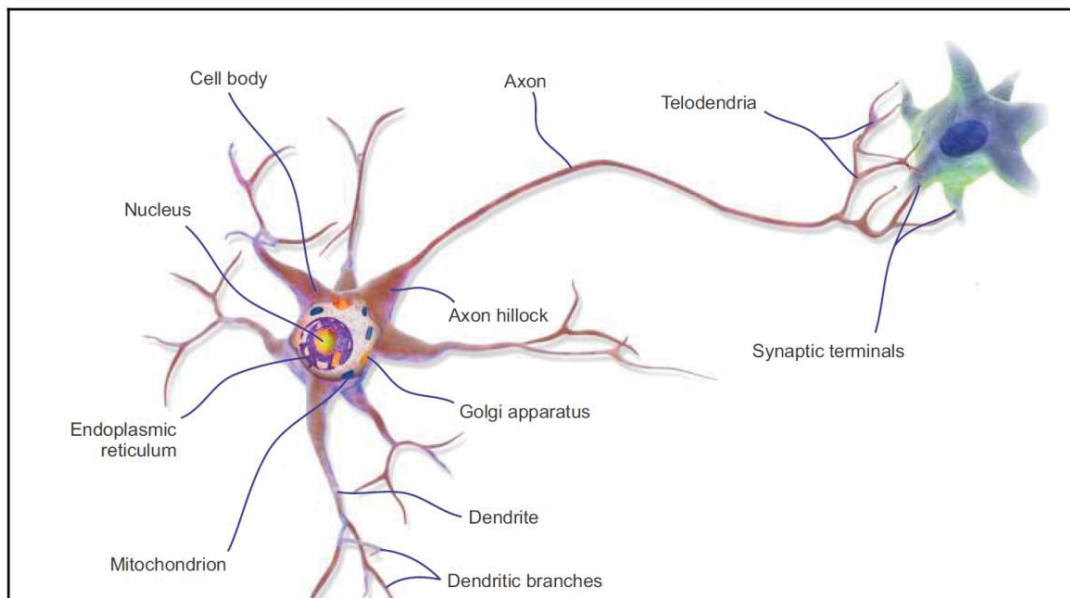
Beysolow II (2017) diz que possuir várias camadas permite que o modelo processe os dados de forma a construir entendimento de aspectos simples a construções maiores. O objetivo desses modelos é realizar tarefas sem o mesmo grau de instrução explícita, que muitos algoritmos de aprendizado de máquina precisam. Um dos principais benefícios na utilização destes modelos é a aplicação à problemas de aprendizagem não supervisionados, como o reconhecimento de imagem, especialmente depois que um modelo foi treinado em um determinado conjunto de dados. Ao inserir, por exemplo, a imagem de um cachorro para que o sistema o identifique, sem informar ao modelo do que a imagem se trata, a rede neural começará reconhecendo os cílios, depois o focinho, em seguida o formato da cabeça, e assim por diante, até classificar a imagem como de um cachorro. As

ferramentas baseadas em *Deep Learning* conseguem chegar a altos índices de acertos nas tarefas em que elas são aplicadas.

2.2.3 Redes Neurais Artificiais

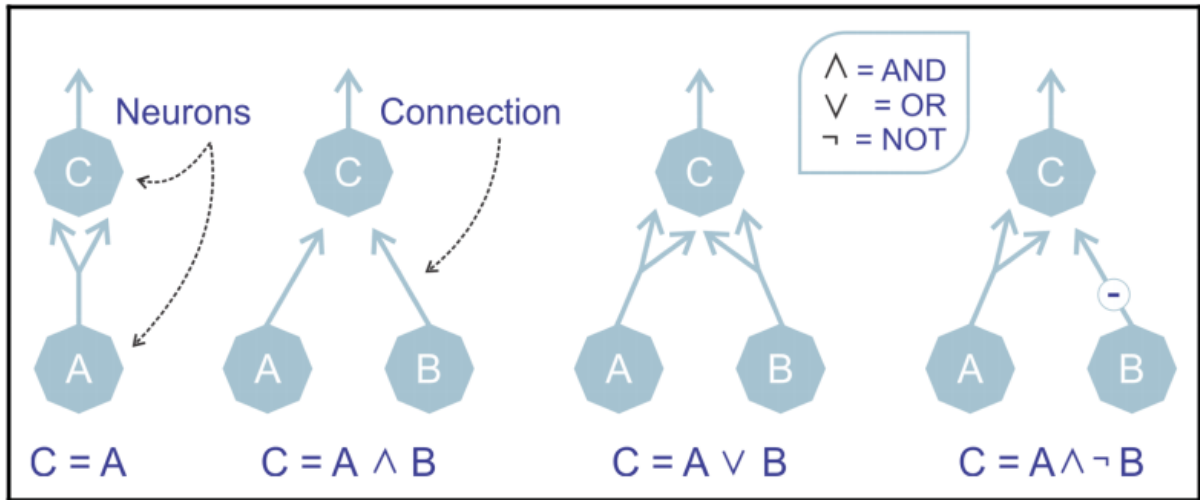
Inspirado no funcionamento do sistema nervoso biológico, conforme FIGURA 2, receptadores nervosos recebem estímulos do mundo exterior e os encaminham para serem processados por diversos neurônios que se comunicam entre si. Em 1943, Warren McCulloch e Walter Pitts propuseram o primeiro modelo computacional de neurônio artificial (NA), que tinha uma ou várias entradas binárias de *liga* e *desliga* e uma única saída, como mostra na FIGURA 3 (KARIM, 2018).

FIGURA 2 – Sistema nervoso biológico



FONTE: Karim (2018).

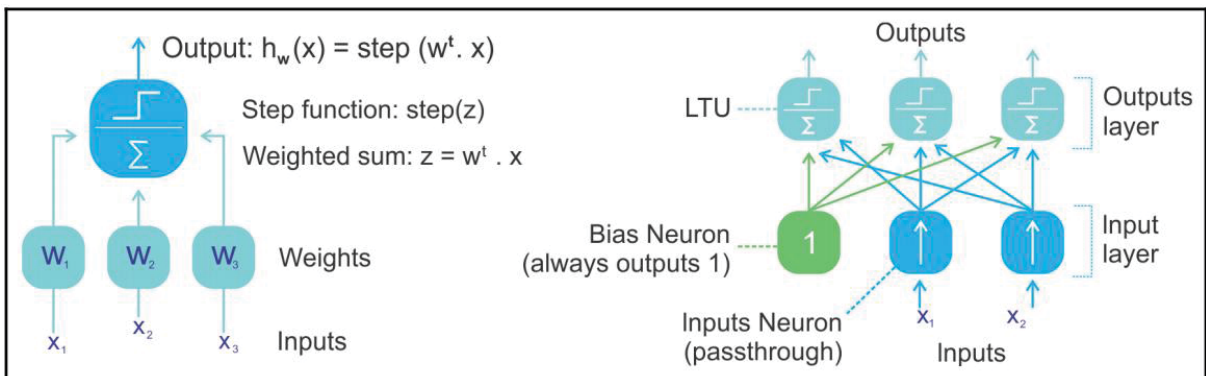
FIGURA 3 – Modelo de Neurônio Artificial



FONTE: Karim (2018).

Posteriormente em 1957, o modelo de NA serviu de base para que fosse criado um novo modelo mais complexo, chamado de Rede de Neural Artificial (RNA), esse modelo foi desenvolvido por John Von Neumann, Marvin Minsky, Frank Rosenblatt e outros, e foi batizado de Perceptron Back. Nesse novo modelo, a principal diferença, a chamada Unidade de Limiar Linear (LTU), apresentou entradas e saídas como números ao invés dos binários *liga* e *desliga*. Nele, cada entrada está associada a um peso, onde o LTU calcula uma soma ponderada nas entradas, aplica uma função e produz um resultado. A FIGURA 4 demonstra esse processo (KARIM, 2018).

FIGURA 4 – Modelo de Rede Neural Artificial Perceptron



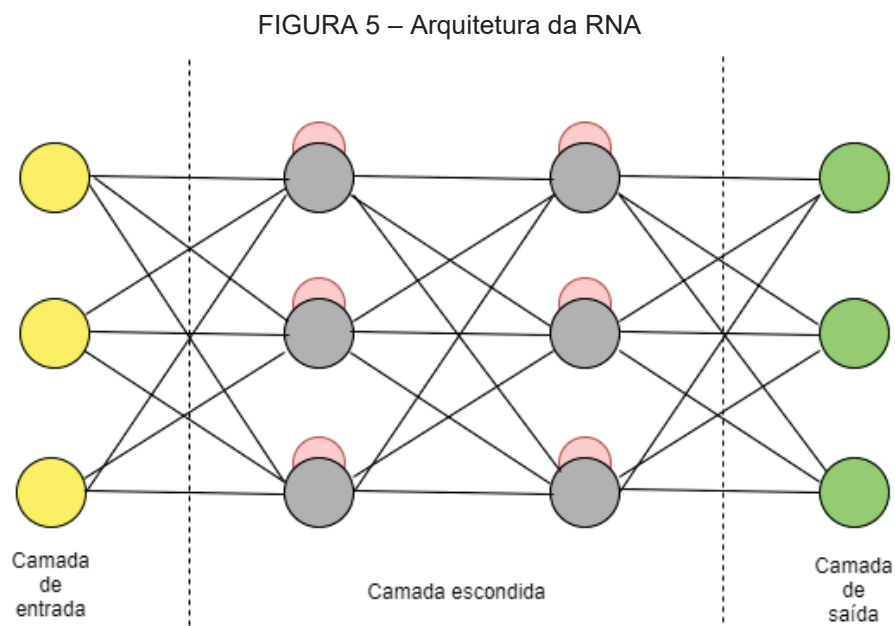
FONTE: Karim (2018).

A Rede Neural Artificial, um dos campos de pesquisa da IA, tem como foco o reconhecimento de padrões, previsões e tomada de decisões mediante o uso de redes de unidades conectadas e treinadas por algoritmos e usa como base amostras do mundo real, possibilitando o aprendizado, a identificação e classificação de padrões (DE MEDEIROS, 2018).

Segundo De Medeiros (2018), os aspectos que definem inteligência humana de forma bem sucinta são:

- Capacidade de resolução de problemas;
- Aprendizado com o ambiente;
- Desenvolvimento de estruturas cognitivas;
- Orientação e metas.

A IA busca se aproximar do funcionamento da mente humana, fazendo com que um software inteligente envolva as tomadas de decisões baseadas em um conhecimento adquirido e executando tarefas a partir desse raciocínio lógico.



FONTE: O autor 2021

Segundo Karim (2018), o processamento em cada neurônio se dá pela chamada função de ativação, que é a transformação não linear nos dados de entrada e saída de cada neurônio. As principais funções são Tanh, ReLU, Softmax, e Sigmoid. Na TABELA 1 mostra as fórmulas das funções utilizadas nesse estudo:

TABELA 1 – Função de ativação X fórmula

Função de ativação	Fórmula
Sigmoid	$\text{Out}_i = \frac{1}{(1 + e^{-x})}$
Tanh	$\tanh(x) = 2\sigma(2x) - 1$
ReLU	$f(x) = \max(0, x)$
Softmax	$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad \text{for } j = 1, \dots, K.$
Identity	$f(X) = X$


FONTE: O autor (2021).

2.2.4 Rede Neural Recorrente (RNN)

A Inteligência Artificial possui alguns tipos de redes neurais, nesse trabalho foi abordada a Rede Neural Recorrente, na sigla em inglês é RNN. Sua aplicação é indicada para reconhecer padrões de sequência de dados, como falas, textos, séries numéricas e temporais. As suas conexões entre as unidades formam um ciclo direcionado.

A arquitetura da RNN foi originalmente projetada por Hochreiter e Schmidhuber, em 1997, é como padrão um Perceptron de Multicamada (MLP) com um aditivo de repetição, se caracterizando como rede neural com mais de uma camada oculta, com quantidade de neurônios indeterminados e com camadas de entrada e saída. A RNN pode explorar a poderosa capacidade de mapeamento não linear de um MLP utilizando memória (KARIM, 2018).

FIGURA 6 – Arquitetura da RNN



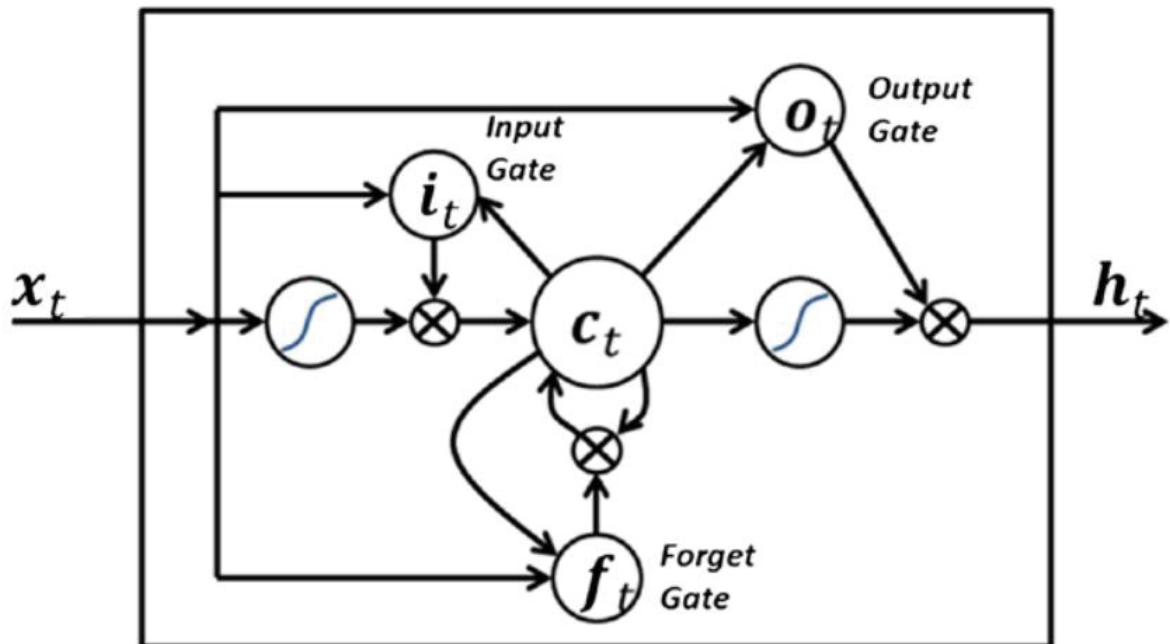
FONTE: O autor 2021

A FIGURA 6 mostra uma básica camada de entrada representada por X , uma camada recorrente representada por A e uma camada de saída representada por H . Entretanto este modelo sofre de problema de desaparecimento e explosão de gradiente e não consegue modelar a dependência a longo prazo, apesar das arquiteturas mais avançadas serem desenhadas para utilizar a informação sequencial de dados de entrada com conexões cíclicas entre os Perceptrons. Os principais tipos de Rede Neural Recorrente são: *Long-Short-Term Memory (LSTM)*, *Gated Recurrent Units (GRUs)* e *Bidirectional-LSTM* (KARIM, 2018).

2.2.5 Long Short-Term Memory (LSTM)

LSTM é um modelo que consegue obter excelentes resultados, mesmo com as lacunas de tamanhos desconhecidos entre sinais no ruído dos dados. Ele pode ser aplicado de forma tão universal, que quando a unidade de rede está presente e com uma matriz de peso devidamente calibrada, qualquer coisa que um computador processar, poderá ser replicado nas redes LSTM (BEYSOLOW II, 2017).

FIGURA 7 – Arquitetura da RNN



FONTE: BEYSOLOW II 2017

As redes LSTM tem um alto índice de uso em robótica, previsão de séries temporais, reconhecimento de voz, entre outras. Diferentemente de outras RNNs, a arquitetura das redes LSTM contém blocos e conta com capacidade de memorizar um valor por longos períodos de tempo. Os objetos GATE, dentro de um modelo, determinarão vários atributos de sequência de entrada que poderão ser mantidos ou removidos. Uma unidade sigmoid padrão LSTM possui a equação $y = s(\sum_{i=1}^N w_i x_i)$, onde S é uma função de esmagamento (em alguns casos sendo uma função de logística) (BEYSOLOW II,2017).

Na FIGURA 7, à esquerda, verifica-se a unidade sigmoid alimentando a entrada para a "memória" do bloco LSTM. A partir desse ponto, outras unidades da figura servem como portas, que permitiram ou negaram o acesso a essa "memória". A unidade intitulada i funciona como porta de entrada do diagrama, descrita como INPUT GATE, ela bloqueará a entrada de todos os valores pequenos na "memória" (próximos de zero).

O FORGET GATE da unidade na parte inferior da FIGURA 7 descartará qualquer valor que estiver na "memória". A unidade no canto superior direito da FIGURA 7 é a porta de saída, chamada de OUTPUT GATE, que determina se o valor armazenado na memória do LSTM deve ser ou não enviado. As unidades

descritas pelos símbolos: π ou Σ são retornadas ao LSTM para facilitar a lembrança do mesmo valor ao longo dos intervalos de tempo. Normalmente, este valor também é inserido nas três unidades de porta para melhorar os processos de tomada de decisões. O produto *Haramard*, ou produto básico de matrizes usado em LSTM, é dado pela seguinte notação de índice: $(A \circ B)_{i,j} = A_{i,j} \times B_{i,j}$. As equações abaixo mostram as camadas e suas equações de uma rede LSTM tradicional, onde x = vetor de entrada, h_t = vetor de saída, c_t = estado da célula, (W, U, b) = matrizes de parâmetros e vetores, $(f_t, i_t, e o_t)$ = informação lembrada, informação adquirida e informação de saída, respectivamente, σ_g = função sigmoid, σ_c = tangente hiperbólica original, σ_h = original tangente hiperbólica (BEYSOLOW II, 2017).

$$\begin{aligned} f_t &= \sigma_g(W_f x_t + U_f h_{t-1} + b_f), \\ i_t &= \sigma_g(W_i x_t + U_i h_{t-1} + b_i), \\ o_t &= \sigma_g(W_o x_t + U_o h_{t-1} + b_o), \\ c_t &= f_t \circ c_{t-1} + i_t \circ \sigma_c(W_c x_t + U_c h_{t-1} + b_c), \\ h_t &= o_t \circ \sigma_h(c_t). \end{aligned}$$

Os gradientes de desaparecimento em LSTMs são tratados especificamente como carrossel de erros. Redes LSTM "lembram" os seus erros retropropagados, que são realimentados para cada um dos pesos, com isso, a retropropagação regular é eficaz em treinar um bloco LSTM, para lembrar os valores por períodos de tempo muito longos (BEYSOLOW II, 2017).

2.2.6 UML

A UML é uma linguagem visual vastamente usada no mundo pela indústria de engenharia de software na modelagem de sistemas baseados em orientação a objetos. O significado da sigla é Unified Modeling Language, cuja tradução é Linguagem de Modelagem Unificada (GUEDES, 2018).

O objetivo da linguagem é modelar e auxiliar nas definições das características, requisitos funcionais, requisitos não funcionais, processos e o comportamento do software antes do desenvolvimento. Modelar um software antes de iniciar o desenvolvimento traz um melhor entendimento do negócio, planejamento

de custos, definições de prazos, definição de prioridades, tamanho do time, identificação de itens mais complexos e mapeamento dos itens que ainda precisam ser amadurecidos. Criar modelos de software captura uma visão de um sistema físico (GUEDES, 2018).

A linguagem possui alguns diagramas e modelos que quando especificados no projeto, proporcionam a equipe diversas visões, sob diferentes perspectivas do sistema. Os principais itens são prototipação de telas, Diagrama de Casos de Uso, Diagrama de Classes, Diagrama de Objetos, Diagrama de Pacotes, Diagrama de Sequência, Diagrama de Comunicação, Diagrama de Máquina de Estados, Diagrama de Atividade, Diagrama de Visão Geral de Interação, Diagrama de Componentes, Diagrama de Implantação, Diagrama de Implantação, Diagrama de Estrutura Composta, Diagrama de Tempo e Diagrama de Perfil. Os diagramas são divididos em comportamentais, estruturais e de interação. Um fator importante é que a UML não é um processo de desenvolvimento de um software, nem possui uma forma exclusiva de uso, podendo ser utilizada da forma que a equipe de desenvolvimento achar mais adequada (GUEDES, 2018).

2.3 FERRAMENTAS

Nessa seção são listadas as ferramentas usadas no desenvolvimento desse trabalho.

2.3.1 Java

A linguagem Java foi criada pela empresa Sun Microsystems em 1995, que logo foi comprada pela Oracle em 2010 (DEITEL e DEITEL, 2016).

Segundo Claro e Sobral (2008), *Java* é uma linguagem baseada em programação orientada a objetos, em que cada componente ou uma classe é considerada um objeto. Muito importante por aproximar o universo de programação do mundo real, a linguagem *Java* se destaca por ser multiplataforma, em que é possível desenvolver tanto para sistemas desktop como sistemas web, desde aplicações simples até as mais complexas e robustas de forma independente.

Ela também é a linguagem-chave para desenvolvimento de aplicativos em dispositivos móveis, como tablets e celulares que usem o sistema operacional Android (DEITEL e DEITEL, 2016).

Apesar de ser parecido com a linguagem C++, *Java* eliminou a complexidade de desenvolvimento, como por exemplo, o controle dos ponteiros de memória pelo programador e a herança múltipla (CLARO e SOBRAL, 2008).

2.3.2 DeepLearning4j

O *DeepLearning4j* (DL4j) é uma biblioteca de código aberto de *Deep Learning*, que agrega Inteligência Artificial em aplicações usadas em JVM (Java Virtual Machine), como Java, Scala, Clojure ou Kotlin. Essa ferramenta já é integrada com Hadoop e Apache Spark e pode ser utilizada em ambientes de GPUs e CPUs. O DL4j oferece suporte a todas as necessidades que uma aplicação de IA baseada em JVM precisa, além de ser uma API de alto nível, estão inclusas as bibliotecas ND4J (álgebra linear), SameDiff (diferenciação automática baseada em gráfico), DataVec (ETL), Arbiter (Pesquisa de hiperparâmetros), e a C++ LibND4J (que sustenta todos os itens citados). LibND4J que chama as bibliotecas padrões para suporte de CPU e GPU, como OpenBLAS, OneDNN (MKL-DNN), cuDNN, e cuBLAS (HELLER, 2020).

Segundo Heller (2020), o objetivo do DeepLearning4j é prover componentes para construir aplicações que incorporem Inteligência Artificial, tratando as tarefas de carregamento de dados nos algoritmos de treinamentos em um processo aparte e treinando os modelos com tensores.

2.3.3 Scrum

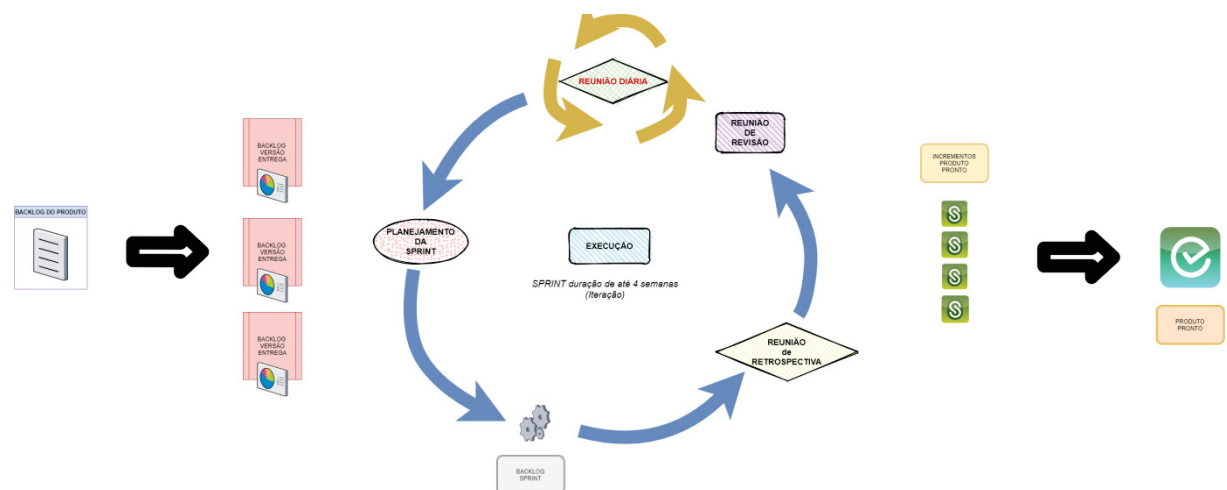
O Scrum é um framework de gerenciamento de projetos voltado ao desenvolvimento e manutenção de produtos complexos. Apesar de ser muito usado em projetos de desenvolvimento de sistemas, é perfeitamente possível usar o Scrum em iniciativas de outras áreas. Sua principal característica é ser incremental e iterativo, tendo como foco realizar pequenas entregas no menor tempo possível e priorizar as construções ou implementações das funcionalidades ou componentes que agreguem mais valor no negócio do cliente (CRUZ, 2018).

Para usar o Scrum em um projeto, deve-se dividi-lo em vários ciclos curtos, chamados de Sprints, com no máximo 4 semanas cada, e repetitivos. As Sprints possibilitam modificações e correções de desvios mais rapidamente do que outros métodos de gerenciamento de projetos, diminuindo assim o impacto de perda de tempo e dinheiro no projeto. Cada membro de um time Scrum possui um papel, sendo eles Scrum Master, Product Owner e o Time de Desenvolvimento (CRUZ, 2018).

Segundo Cruz (2018) é necessário desmembrar o produto ou a aplicação idealizada em várias partes e a partir dessas partes, criar diversas tarefas, das quais se retirem alguns itens, como: funcionalidades, componentes e/ou requisitos. Essa lista de tarefas é chamada de Backlog. O Backlog é dividido em 3 tipos: Backlog do produto, que terá todos os itens do produto e o que mais sofrerá modificações durante todo o projeto, o Backlog da versão de entrega, que contempla os itens que serão entregues na versão corrente e o Backlog da Sprint, onde constaram os itens que serão entregues no final de cada Sprint.

Cruz (2018) comenta que as Sprints possuem suas próprias cerimônias, sendo elas: planejamento da Sprint, reunião diária, revisão e retrospectiva e isso pode ser vislumbrado através da FIGURA 8.

FIGURA 8 – Ciclo da Interação do Scrum




FONTE: O autor (2021).

3 MATERIAL E MÉTODOS

O presente tópico apresenta a forma como foi desenvolvido esse estudo.

3.1.1 Planejamento

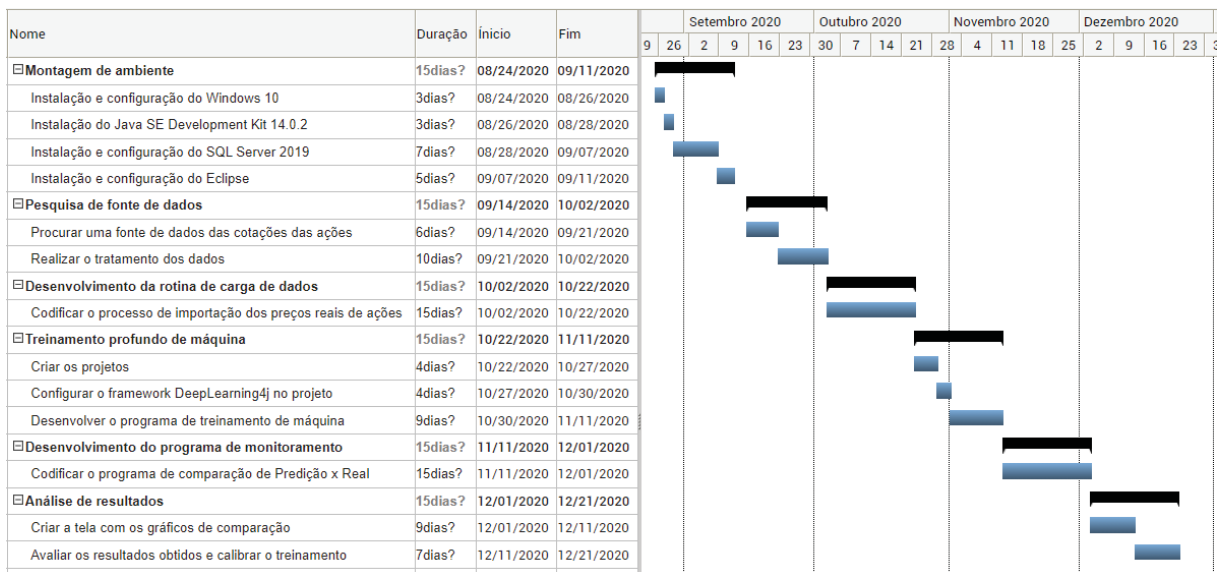
A FIGURA 9 mostra um planejamento macro do desenvolvimento de um produto mínimo, porém conforme dita à metodologia Scrum, os itens do backlog podem sofrer algum tipo de repriorização durante o desenvolvimento.



FONTE: O autor (2020)

A FIGURA 10 mostra o cronograma Gantt da implementação e codificação do projeto.

FIGURA 10 – Cronograma Gantt



FONTE: O autor (2020)

3.2 FERRAMENTAS E VERSÕES

TABELA 2 – Lista de aplicativos instalados e configurados

Programa	Descrição
Java SE Development Kit 14.0.2	compilar e executar o sistema
SQL Server 2019	banco de dados
DeepLearning4j 1.0.0-beta7	bibliotecas de Deep-Learning
Eclipse	IDE de desenvolvimento
Windows 10	Sistema Operacional

FONTE: O autor (2021).

3.3 DADOS

As bolsas de valores disponibilizam os dados de cotação de várias formas, os quais podem ser acessados via página web, via mídia escrita, via mídia falada e também através de integrações sistêmicas, para que sejam disponibilizadas em outro canal. Nesse trabalho a informação foi buscada manualmente, através de uma ferramenta chamada GOOGLFINANCE, que é disponibilizada pela empresa Google. Para usar essa ferramenta bastou abrir uma planilha eletrônica do GOOGLDOCS, e em uma célula incluir a funcionalidade do GOOGLFINANCE indicando a faixa de datas desejada, então a planilha foi preenchida automaticamente com os valores das ações no intervalo dos períodos informados. Após esse passo, bastou importar esse arquivo no sistema que foi desenvolvido nesse trabalho. Segue a sintaxe do GOOGLFINANCE que foi incluída na planilha do GOOGLDOCS:

=GOOGLFINANCE({endereço da célula atual} ,{campos desejados},{data início},{data fim})

A FIGURA 11 demonstra a planilha preenchida usando a fórmula **=GOOGLFINANCE(A1,"all",TODAY()-500,TODAY())**, bem como todos os dados apurados e utilizados no desenvolvimento da pesquisa.

FIGURA 11 – Planilha eletrônica do GoogleDocs com os valores das ações

1	PETR4						VALE3						VISC11
2	Date	Open	High	Low	Close	Volume	Date	Open	High	Low	Close	Volume	Date
3	7/13/2020 16:56:00	22.61	22.65	22.16	22.16	55425500	7/13/2020 16:56:00	57.73	59.22	57.65	57.65	28780200	7/13/2020 16:56:00
4	7/14/2020 16:56:00	22.13	22.96	21.86	22.9	89380500	7/14/2020 16:56:00	57.92	61.97	57.9	61.7	52234500	7/14/2020 16:56:00
5	7/15/2020 16:56:00	23.2	23.43	22.85	23.34	58390600	7/15/2020 16:56:00	62.3	62.93	60.39	61.79	29833100	7/15/2020 16:56:00
6	7/16/2020 16:56:00	23.16	23.28	22.52	22.72	69698700	7/16/2020 16:56:00	61.3	61.69	59.85	60.12	22788400	7/16/2020 16:56:00
7	7/17/2020 16:56:00	22.83	23.03	22.58	22.74	49927600	7/17/2020 16:56:00	60.5	61.25	60.32	61.04	18896400	7/17/2020 16:56:00
8	7/20/2020 16:56:00	22.7	22.91	22.52	22.74	48679800	7/20/2020 16:56:00	61.12	61.49	60.35	60.8	16491500	7/20/2020 16:56:00
9	7/21/2020 16:56:00	23.15	23.6	23.14	23.37	101769600	7/21/2020 16:56:00	60.44	60.48	59.27	59.7	29043600	7/21/2020 16:56:00
10	7/22/2020 16:56:00	23.3	23.41	23.01	23.05	43085500	7/22/2020 16:56:00	59.93	60.25	58.8	59.24	19644700	7/22/2020 16:56:00
11	7/23/2020 16:56:00	23.16	23.23	22.54	22.67	64072100	7/23/2020 16:56:00	59.9	60.16	58.64	58.85	17291900	7/23/2020 16:56:00
12	7/24/2020 16:56:00	22.54	23.06	22.42	22.73	43380300	7/24/2020 16:56:00	58.57	58.85	57.82	58.6	22544100	7/24/2020 16:56:00
13	7/27/2020 16:56:00	22.87	23.25	22.45	23.2	56539600	7/27/2020 16:56:00	59.1	61.63	58.98	61.37	35124800	7/27/2020 16:56:00
14	7/28/2020 16:56:00	23.04	23.32	22.8	22.8	48353000	7/28/2020 16:56:00	60.7	61.16	60.2	60.34	21707500	7/28/2020 16:56:00
15	7/29/2020 16:56:00	23.03	23.25	22.92	23.17	44011500	7/29/2020 16:56:00	61.21	62.95	60.85	62.95	29486600	7/29/2020 16:56:00
16	7/30/2020 16:56:00	22.92	22.92	22.5	22.82	57859000	7/30/2020 16:56:00	62.3	62.37	60.85	61.27	32210700	7/30/2020 16:56:00
17	7/31/2020 16:56:00	22.92	23.14	22.16	22.2	75397300	7/31/2020 16:56:00	61.1	62.21	60.5	60.71	26318800	7/31/2020 16:56:00
18	8/3/2020 16:56:00	22.54	22.55	21.72	21.8	63598500	8/3/2020 16:56:00	61.86	62.67	60.26	60.26	35910500	8/3/2020 16:56:00
19	8/4/2020 16:56:00	21.46	22.05	21.25	21.78	63011900	8/4/2020 16:56:00	60.26	60.84	59.36	60.7	182535800	8/4/2020 16:56:00
20	8/5/2020 16:56:00	22.23	23.28	22.23	23.18	137214700	8/5/2020 16:56:00	61.9	62.9	61.85	62.19	36999600	8/5/2020 16:56:00
21	8/6/2020 16:56:00	23.28	23.53	23.01	23.22	56375100	8/6/2020 16:56:00	62.62	62.88	61.28	61.83	22468400	8/6/2020 16:56:00
22	8/7/2020 16:56:00	22.86	22.91	22.55	22.79	56040200	8/7/2020 16:56:00	61.39	61.39	59.78	60.45	28427400	8/7/2020 16:56:00
23	8/10/2020 16:56:00	22.9	23.45	22.64	23.45	52390100	8/10/2020 16:56:00	60.7	62.2	60.41	62.2	29341400	8/10/2020 16:56:00
24	8/11/2020 16:56:00	23.71	23.88	23.06	23.08	66342300	8/11/2020 16:56:00	62.79	62.82	60.16	60.28	23822800	8/11/2020 16:56:00
25	8/12/2020 16:56:00	23.36	23.68	23.08	23.48	67008500	8/12/2020 16:56:00	60.88	62.29	60.58	61.5	29627900	8/12/2020 16:56:00
26	8/13/2020 16:56:00	23.45	23.58	22.71	22.64	44588200	8/13/2020 16:56:00	61.4	62.16	60.11	60.35	24906200	8/13/2020 16:56:00
27	8/14/2020 16:56:00	22.77	22.98	22.53	22.67	38422000	8/14/2020 16:56:00	60.35	61.43	60.3	61.35	17848800	8/14/2020 16:56:00
28	8/17/2020 16:56:00	22.88	22.84	22.15	22.6	52084300	8/17/2020 16:56:00	61.78	62.6	61.15	62.23	42786400	8/17/2020 16:56:00
29	8/18/2020 16:56:00	22.93	23.24	22.77	23.02	49361300	8/18/2020 16:56:00	63.3	63.7	62.85	63.06	32205700	8/18/2020 16:56:00
30	8/19/2020 16:56:00	22.95	23.32	22.75	22.89	51982100	8/19/2020 16:56:00	63.41	63.88	62.33	62.39	23537900	8/19/2020 16:56:00
31	8/20/2020 16:56:00	22.52	22.87	22.35	22.73	55251700	8/20/2020 16:56:00	61.82	63.5	61.67	62.95	25866600	8/20/2020 16:56:00
32	8/21/2020 16:56:00	22.54	22.63	22.35	22.56	38668300	8/21/2020 16:56:00	62.41	62.79	61.51	62.2	27242700	8/21/2020 16:56:00
33	8/24/2020 16:56:00	22.86	23.13	22.8	22.97	51841900	8/24/2020 16:56:00	62.94	63.13	62.24	62.96	17944700	8/24/2020 16:56:00
34	8/25/2020 16:56:00	23.09	23.15	22.69	22.87	37981400	8/25/2020 16:56:00	62.8	62.84	61.05	61.62	23543000	8/25/2020 16:56:00
35	8/26/2020 16:56:00	22.78	22.9	22.04	22.22	69925300	8/26/2020 16:56:00	61.86	62.35	61.24	61.75	23924400	8/26/2020 16:56:00
36	8/27/2020 16:56:00	22.32	22.47	22.04	22.15	35489800	8/27/2020 16:56:00	61.69	62.18	60.33	60.79	18201900	8/27/2020 16:56:00
37	8/28/2020 16:56:00	22.25	22.54	22.06	22.54	31071000	8/28/2020 16:56:00	61.18	61.7	60.63	61.1	15040300	8/28/2020 16:56:00

FONTE: O autor (2020)

3.4 DESENVOLVIMENTO DO PROJETO

Nesse item estão descritos todos os Sprints do projeto.

3.4.1 Sprint 0 – Montagem de ambiente

Nessa etapa foi instalado e configurado um ambiente para o desenvolvimento da aplicação, na TABELA 2 estão listados os softwares e as ferramentas que foram utilizadas, quais sejam, Java SE Development Kit 14.0.2, SQL Server 2019, DeepLearning4j 1.0.0-beta7 e Eclipse.

3.4.2 Sprint 1 – Pesquisa de fonte de dados

Nessa etapa foi pesquisada uma fonte oficial ou uma fonte com informações confiáveis, que possibilitassem obter os dados diários das cotações das ações da bolsa de valores de forma on-line.

3.4.3 Sprint 2 – Desenvolvimento da rotina de carga de dados

Aqui foi necessário criar um programa que permitisse realizar importações diárias dos preços das ações por um arquivo gerado através do GOOGLFINANCE. A partir dele, se estabeleceu uma rotina de tratamentos das informações, com limpeza, formatações, transformações e salvamento no banco de dados. No APÊNDICE 4 se descreve o diagrama de classe do microsserviço, que armazena no banco de dados as informações reais das cotações dos papéis de ação via importação.

3.4.4 Sprint 3 – Treinamento profundo de máquina

Após concluídas as etapas anteriores, iniciou-se o treinamento profundo de máquina, utilizando o framework DeepLearning4j, com a rede neural recorrente, RNN, do tipo LSTM. As definições das estruturas de classes do programa estão descritas no APÊNDICE 2, onde se demonstra o diagrama de classe do aplicativo que realiza as previsões.

Foram realizados dois experimentos para cada uma das ações SQIA3, PETR4, VALE3, VISC11 e HGLG11. A cada ciclo de treinamento foi reservado 80% dos dados para treinamento e 20% para validação do modelo da massa total de dados. Durante os experimentos foram ajustados os hiperparâmetros **quantidade de entrada** e **quantidade de saída**, e também o **epochs**, **loss function**, **optimization algorithm**, **activation function** e as **quantidades de camadas**. Após os experimentos de cada uma das ações, foi possível comparar a assertividade de cada um deles e prever diariamente as tendências de valores dos principais atributos das ações, como: preço de abertura, preço de fechamento, maior e menor preço do dia e volume da quantidade de negociações realizadas.

As configurações usadas no primeiro experimento da ação SQIA3 foram:

QUADRO 1 – Primeira configuração da LSTM da SQIA3

Ephocs	Loss function	Optimization Algorithm
120	ADAM = 0,001	Stochastic Gradient Descent

QUADRO 2 – Primeira configuração das camadas de LSTM da SQIA3

Camada	Activation function	Quantidade de entradas	Quantidade de saídas
Camada 1	Tanh	5	128
Camada 2	Tanh	128	128
Camada 3	Tanh	128	128
Camada 4	Tanh	128	128
Camada 5	Relu	128	32
Camada 6	Relu	32	32
Camada 7	Relu	32	32
Camada 8	Identity	32	1

FONTE: O autor (2021).

As configurações usadas no segundo experimento da ação SQIA3 foram:

QUADRO 3 – Segunda configuração da LSTM da SQIA3

Ephocs	Loss function	Optimization Algorithm
150	ADAM = 0,1	Stochastic Gradient Descent

QUADRO 4 – Segunda configuração das camadas de LSTM da SQIA3

Camada	Activation function	Quantidade de entradas	Quantidade de saídas
Camada 1	Tanh	5	500
Camada 2	Tanh	500	320
Camada 3	Identity	320	1

FONTE: O autor (2021).

As configurações usadas no primeiro experimento da ação PETR4 foram:

QUADRO 5 – Primeira configuração da LSTM da PETR4

Ephocs	Loss function	Optimization Algorithm
80	ADAM = 0,001	Stochastic Gradient Descent

QUADRO 6 – Primeira configuração das camadas de LSTM da PETR4

Camada	Activation function	Quantidade de entradas	Quantidade de saídas
Camada 1	Relu	5	128
Camada 2	Relu	128	128
Camada 3	Relu	128	32
Camada 4	Relu	32	32
Camada 5	Identity	32	1

FONTE: O autor (2021).

As configurações usadas no segundo experimento da ação PETR4 foram:

QUADRO 7 – Segunda configuração da LSTM da PETR4

Ephocs	Loss function	Optimization Algorithm
90	ADAM = 0,001	Stochastic Gradient Descent

QUADRO 8 – Segunda configuração das camadas de LSTM da PETR4

Camada	Activation function	Quantidade de entradas	Quantidade de saídas
Camada 1	Tanh	5	300
Camada 2	Tanh	300	300
Camada 3	Relu	300	220
Camada 4	Relu	220	220
Camada 5	Identity	220	1

FONTE: O autor (2021).

As configurações usadas no primeiro experimento da ação VALE3 foram:

QUADRO 9 – Primeira configuração da LSTM da VALE3

Ephocs	Loss function	Optimization Algorithm
90	ADAM = 0,001	Stochastic Gradient Descent

QUADRO 10 – Primeira configuração das camadas de LSTM da VALE3

Camada	Activation function	Quantidade de entradas	Quantidade de saídas
Camada 1	Tanh	5	530
Camada 2	Tanh	530	32
Camada 3	Relu	32	32
Camada 4	Identity	32	1

FONTE: O autor (2021).

As configurações usadas no segundo experimento da ação VALE3 foram:

QUADRO 11 – Segunda configuração da LSTM da VALE3

Ephocs	Loss function	Optimization Algorithm
40	ADAM = 0,01	Stochastic Gradient Descent

QUADRO 12 – Segunda configuração das camadas de LSTM da VALE3

Camada	Activation function	Quantidade de entradas	Quantidade de saídas
Camada 1	Tanh	5	100
Camada 2	Relu	100	120
Camada 3	Identity	120	1

FONTE: O autor (2021).

As configurações usadas no primeiro experimento da ação HGLG11 foram:

QUADRO 13 – Primeira configuração da LTSM do HGLG11

Ephocs	Loss function	Optimization Algorithm
100	ADAM = 0,001	Stochastic Gradient Descent

QUADRO 14 – Primeira configuração das camadas de LTSM do HGLG11

Camada	Activation function	Quantidade de entradas	Quantidade de saídas
Camada 1	Tanh	5	200
Camada 4	Relu	200	32
Camada 5	Identity	32	1

FONTE: O autor (2021).

As configurações usadas no segundo experimento da ação HGLG11 foram:

QUADRO 15 – Segunda configuração da LTSM do HGLG11

Ephocs	Loss function	Optimization Algorithm
50	ADAM = 0,01	Stochastic Gradient Descent

QUADRO 16 – Segunda configuração das camadas de LTSM do HGLG11

Camada	Activation function	Quantidade de entradas	Quantidade de saídas
Camada 1	Tanh	5	100
Camada 2	Tanh	100	320
Camada 3	Identity	320	1

FONTE: O autor (2021).

As configurações usadas no primeiro experimento da ação VISC11 foram:

QUADRO 17 – Primeira configuração da LTSM do VISC11

Ephocs	Loss function	Optimization Algorithm
100	ADAM = 0,001	Stochastic Gradient Descent

QUADRO 18 – Primeira configuração das camadas de LTSM do VISC11

Camada	Activation function	Quantidade de entradas	Quantidade de saídas
Camada 1	Tanh	5	300
Camada 2	Relu	300	32
Camada 3	Relu	32	32
Camada 4	Relu	32	32
Camada 5	Identity	32	1

FONTE: O autor (2021).

As configurações usadas no segundo experimento da ação VISC11 foram:

QUADRO 19 – Segunda configuração da LTSM do VISC11

Ephocs	Loss function	Optimization Algorithm
---------------	----------------------	-------------------------------

Ephocs	Loss function	Optimization Algorithm
120	ADAM = 0,001	Stochastic Gradient Descent

QUADRO 20 – Segunda configuração das camadas de LTSM do VISC11

Camada	Activation function	Quantidade de entradas	Quantidade de saídas
Camada 1	Tanh	5	420
Camada 2	Relu	420	128
Camada 3	Relu	128	3200
Camada 4	Identity	32	1

FONTE: O autor (2021).

3.4.5 Sprint 4 – Desenvolvimento do programa de monitoramento

Nesta etapa, foi desenvolvida uma funcionalidade que lê as previsões das ações do dia e realiza monitoria nelas. Caso alguma das ações selecionadas oscilem, para cima ou para baixo, mudando sua tendência predita pelo sistema, um alarme de compra ou venda é acionado.

3.4.6 Sprint 5 - Análise de resultado

Na última etapa foram avaliados os resultados obtidos e verificado se foi possível melhorar as performances das carteiras de ações, perdendo menos e ganhando mais.

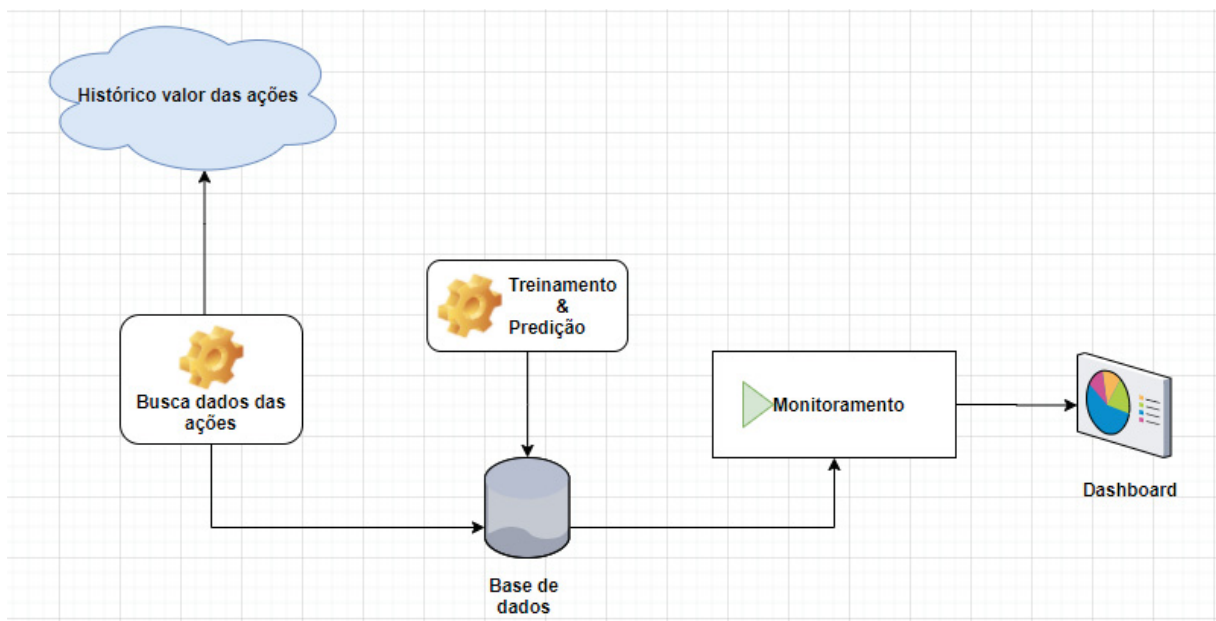
4 APRESENTAÇÃO DOS RESULTADOS

Nessa seção são demonstrados o sistema e os resultados obtidos.

4.1 ARQUITETURA DO SISTEMA

O desenho da FIGURA 12 descreve o ciclo completo da solução.

FIGURA 12 – Desenho da solução



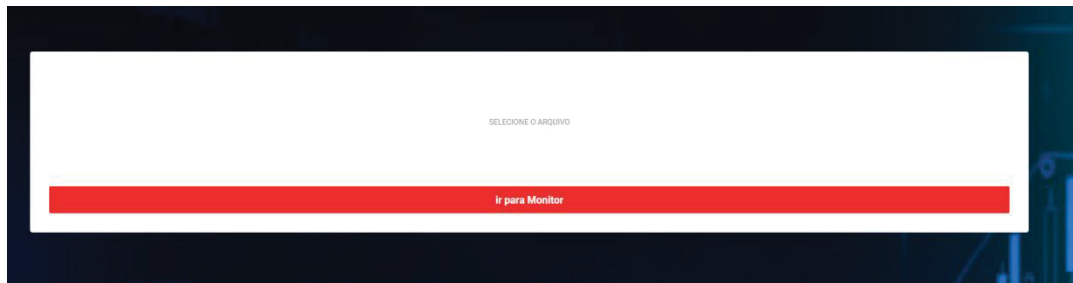
FONTE: O autor (2021).

4.2 IMPORTAÇÃO DE DADOS

Diariamente é executada uma carga dentro do sistema com os principais dados financeiros, como valor de abertura, maior valor do dia, menor valor do dia, valor do fechamento e o volume das negociações realizadas de cada uma das ações selecionadas, as ações são: SQIA3, PETR4, VALE3, VISC11 e HGLG11.

As FIGURAS 13 e 14 mostram as telas de importação de dados que foram construídas e que são utilizadas diariamente, com as importações dos valores das ações obtidas no GOOGLFINANCE.

FIGURA 13 – Tela de importação dos dados das ações do sistema



FONTE: O autor (2021).

FIGURA 14 – Tela de importação dos dados em andamento




FONTE: O autor (2021).

4.3 O TREINAMENTO E A PREDIÇÃO

O GRÁFICO 1 demonstra a saída gerada pelo sistema construído de treinamento e predição. Após o treinamento de máquina, o sistema criou modelos e fez a predição do dia seguinte para cada uma das ações usando o framework DeepLearning4J com os algoritmos LTSM, uma implementação de algoritmo de serie linear.

4.3.1 Experimentos com o ativo da empresa SINQIA (SQIA3).


GRÁFICO 1 – Gráfico do 1º treinamento e teste do preço de fechamento da ação da SQIA3.



FONTE: O autor (2021).

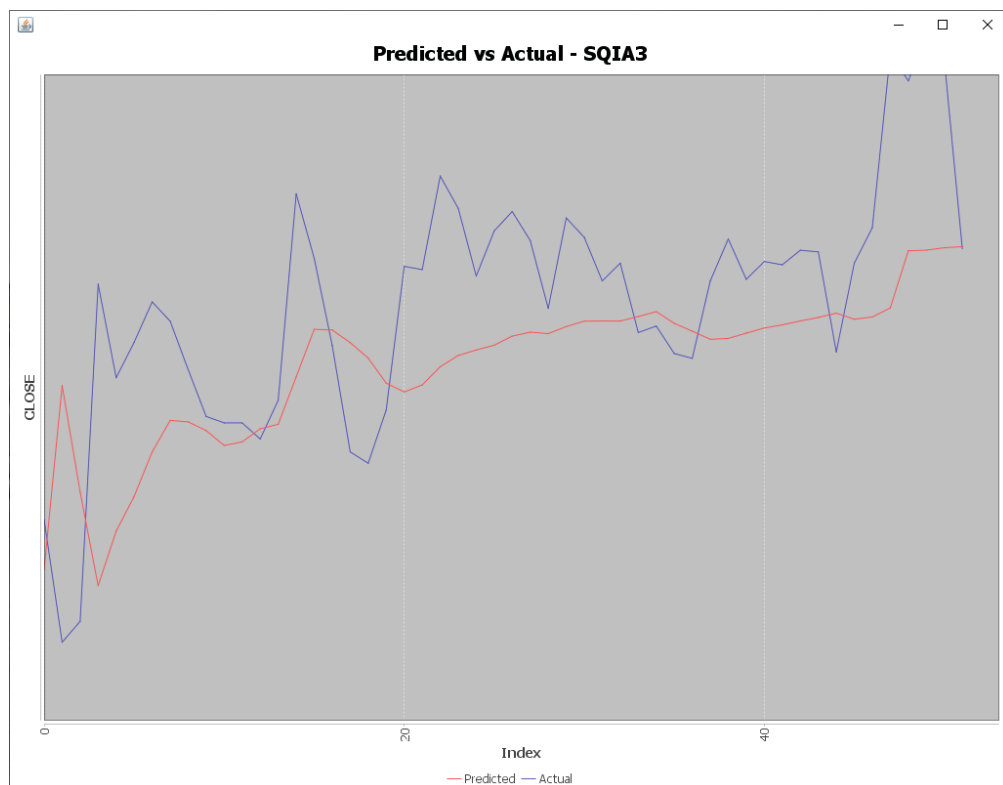
O GRÁFICO 1 demonstra que no treinamento do modelo a linha de valor real ficou um pouco acima da linha de valor predito e os valores se mantiveram próximos durante a flutuação dos preços. O modelo gerado foi utilizado para realizar as previsões da ação, da qual obteve os resultados descritos no GRÁFICO 2, que indicam o preço de fechamento diário real em comparação ao preço predito pelo sistema da ação SQIA3. Pode-se observar dos dados que apesar dos valores preditos estarem um pouco acima do valor real em todos os dias, a assertividade na previsão que o sistema fez com a queda de preço entre os dias 26/04/2021 e 28/04/2021 e sua valorização no dia 30/04/2021, demonstra que a previsão antecipou de forma satisfatória o comportamento de valorização e desvalorização do ativo.

GRÁFICO 2 – Gráfico de comparação do valor real x previsto do 1º experimento da SQIA3



FONTE: O autor (2021).

GRÁFICO 3 – Gráfico do 2º treinamento e teste do preço de fechamento da ação da SQIA3.




FONTE: O autor (2021).

O GRÁFICO 3 mostra que o treinamento do modelo buscou seguir a curva de valorização do ativo, porém a linha do valor real nesse período oscilou bastante fazendo com que a linha de predição não conseguisse acompanhar de forma tão fiel os dados reais, em que pese isso, a linha dos valores preditos acabou praticamente no meio da variação.

O modelo gerado foi utilizado para realizar a predição da ação no sistema, que obteve os resultados descritos no GRÁFICO 4, onde se demonstrou o preço de

fechamento diário real em comparação ao preço predito pelo sistema da ação SQIA3, que o sistema conseguiu prever uma leve queda dos valores no dia 12/05/2021 ao dia 13/05/2021 e ainda, a alta no dia 14/04/2021.

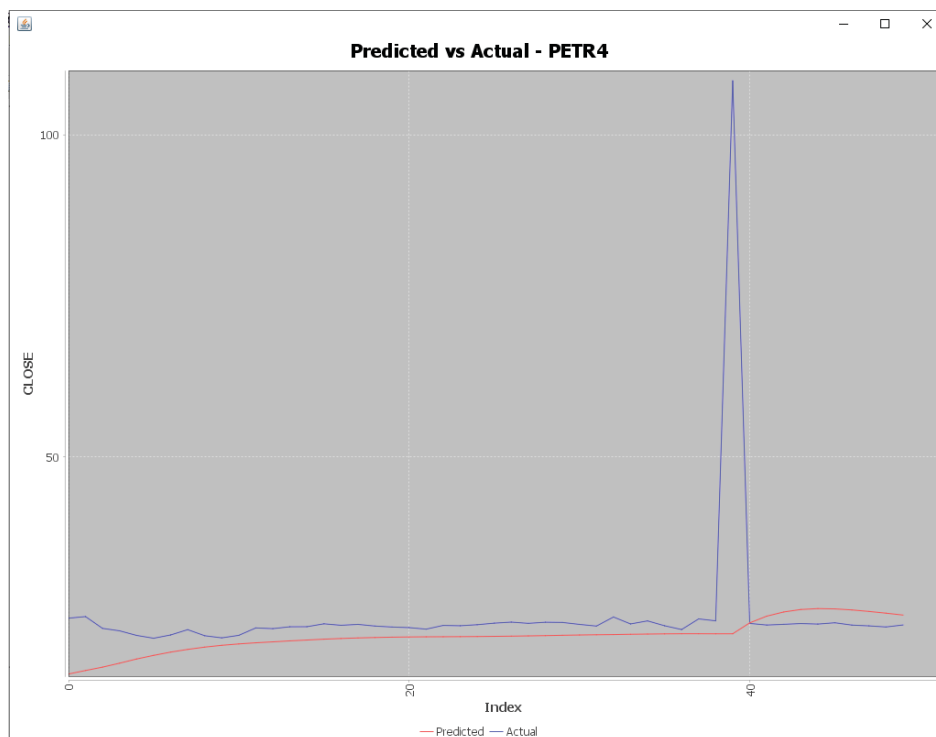
GRÁFICO 4 – Gráfico de comparação do valor real x previsto do 2º experimento da SQIA3



FONTE: O autor (2021).

4.3.2 Experimentos com o ativo da empresa Petrobras (PETR4).


GRÁFICO 5 – Gráfico do 1º treinamento e teste do preço de fechamento da PETR4.



FONTE: O autor (2021).


O GRÁFICO 5 apresentou o treinamento do modelo com valores de preditos em uma excelente aproximação da linha dos valores reais, tendo apenas uma alta do valor real, a qual a predição não seguiu. Esse modelo obteve os resultados descritos no GRÁFICO 6, o qual mostra o preço de fechamento diário real em comparação ao preço predito pelo sistema da ação PETR4 próximos e onde verifica-se que o valores reais ficaram um pouco acima do que foi predito, entretanto o comportamento entre eles permaneceram muitos similares.

GRÁFICO 6 – Gráfico de comparação do valor real x previsto do 1º experimento da PETR4



FONTE: O autor (2021).

GRÁFICO 7 – Gráfico do 2º treinamento e teste do preço de fechamento da PETR4.




FONTE: O autor (2021).

O GRÁFICO 7 esboçou ótimos resultados no treinamento, pois a linha dos valores preditos acompanhou a linha dos valores reais da ação durante todo o


processo, excluindo apenas um momento de pico do valor real, mas logo as linhas voltaram a se aproximar. O modelo gerado foi utilizado para realizar as predições no sistema, obtendo o resultado descrito no GRÁFICO 8, que mostrou uma boa proximidade do valor real com o predito, uma vez que o sistema previu a alta do dia 12/05/2021 a 14/05/2021.

GRÁFICO 8 – Gráfico de comparação do valor real x previsto do 2º experimento da PETR4



FONTE: O autor (2021).

GRÁFICO 11 – Gráfico do 2º treinamento e teste do preço de fechamento da VALE3.




FONTE: O autor (2021).

O GRÁFICO 11 projeta que a linha dos valores reais do treinamento ficou um pouco acima da linha dos valores preditos e também apresentou muitas oscilações. Dos dados percebe-se que o valor predito não só ficou abaixo, como também não conseguiu prever essas sequências de oscilações.

Com o modelo gerado realizaram-se as previsões, obtendo o resultado como descrito no GRÁFICO 12, que mostra o preço de fechamento real, seguindo uma tendência de queda e de recuperação. O predito pelo sistema não acompanhou o comportamento acima e manteve os valores abaixo do real.


GRÁFICO 12 – de comparação do valor real x previsto do 2º experimento da VALE3



FONTE: O autor (2021).

4.3.4 Experimento com o ativo do fundo de investimento CSHG Logística (HGLG11).

GRÁFICO 13 – Gráfico do 1º treinamento e teste do preço de fechamento do HGLG11.




FONTE: O autor (2021).

O GRÁFICO 13 demonstra que o treinamento seguiu com a linha dos valores preditos muito próximos a linha dos valores reais. O modelo gerado foi utilizado para realizar as previsões da ação e obteve os resultados descritos no

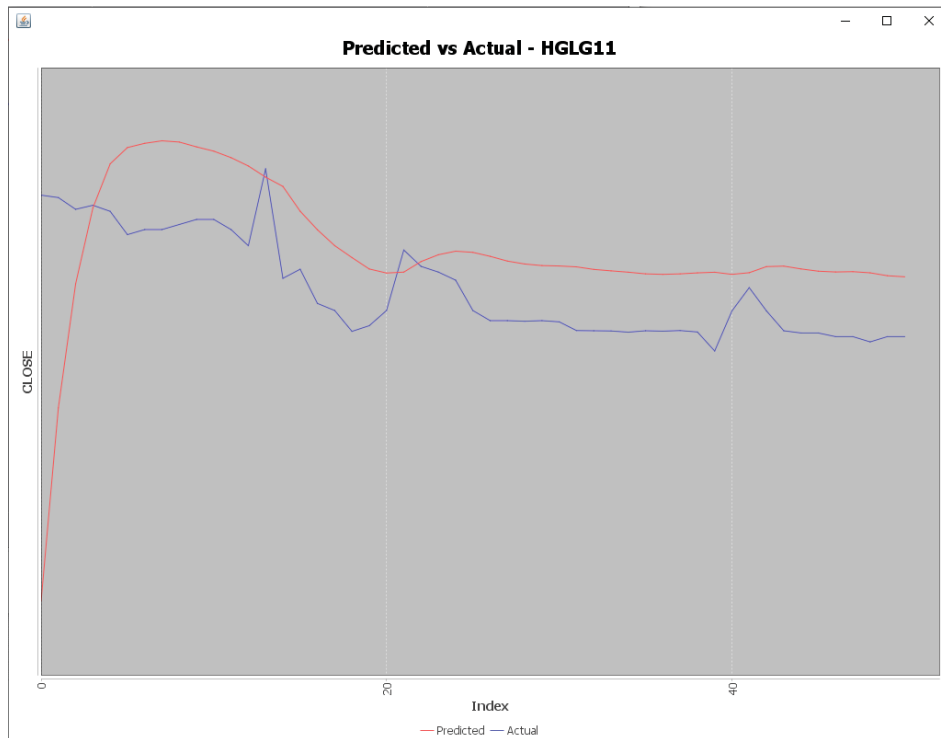
GRÁFICO 14, que demonstrou que o preço predito foi diverso do preço de fechamento diário real e que também não foi possível prever a oscilações do ativo.

GRÁFICO 14 - Gráfico de comparação do valor real x previsto do 1º experimento do HGLG11



FONTE: O autor (2021).

GRÁFICO 15 – Gráfico do 2º treinamento e teste do preço de fechamento do HGLG11.




FONTE: O autor (2021).

No treinamento o GRÁFICO 15 apresentou uma proximidade da linha dos valores reais com a linha dos valores previstos, assim como o comportamento de ambas. Após o modelo gerado, ele foi utilizado para realizar as previsões dos preços das ações obtendo os resultados descritos no GRÁFICO 16, que apesar de apresentarem uma distância entre os valores de predito e real, conseguiu indicar o

comportamento de desvalorização que ocorreu entre dias 13/05/2021 ao dia 17/05/2021.

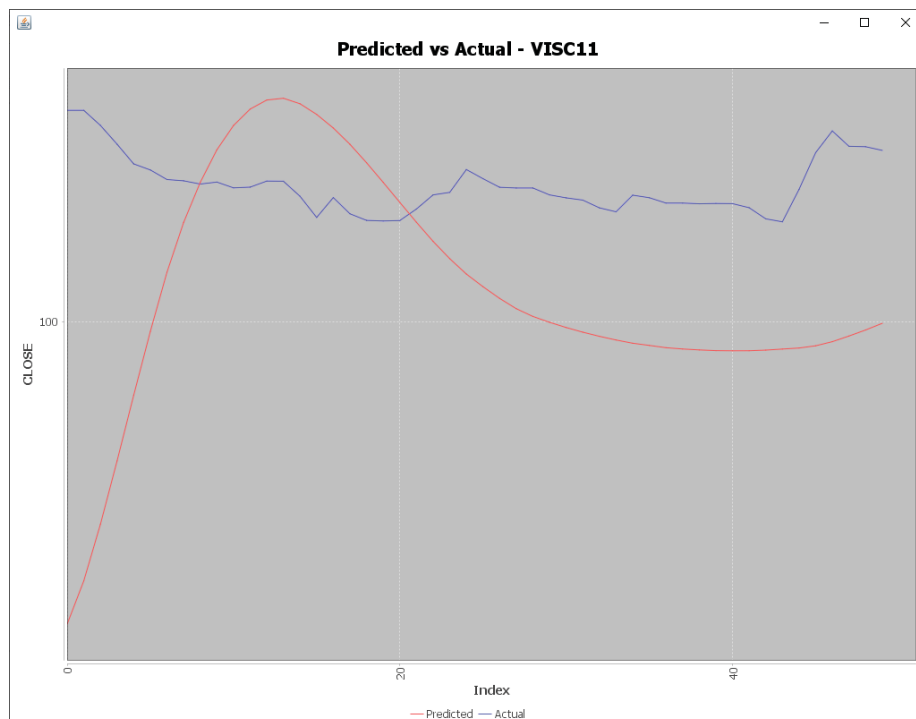
GRÁFICO 16 – Gráfico de comparação do valor real x previsto do 2º experimento do HGLG11



FONTE: O autor (2021).

4.3.5 Experimento com o ativo do fundo de investimento VINCI Shopping Centers (VISC11).


GRÁFICO 17 – Gráfico do 1º treinamento e teste do preço de fechamento do VISC11.



FONTE: O autor (2021).


O GRÁFICO 18 apresenta uma grande discrepância entre a linha dos valores reais e a linha dos valores preditos no treinamento, como também no comportamento de ambas no quesito de valorização e desvalorização das ações. Após a criação do modelo, ele foi utilizado para realizar as previsões no sistema obtendo os resultados descritos no GRÁFICO 19, que demonstra o preço de fechamento diário real em comparação ao preço predito pelo sistema da ação VISC11, onde os valores reais e preditos ficaram próximos e também a sua flutuação.

GRÁFICO 18 – Gráfico de comparação do valor real x previsto do 1º experimento do VISC11



FONTE: O autor (2021).


GRÁFICO 19 – Gráfico do 2º treinamento e teste do preço de fechamento do VISC11.



FONTE: O autor (2021).

Conforme é mostrado no GRÁFICO 19, a linha do valor predito ficou próxima à linha de valor real, e também a linha de valores de predição manteve as oscilações da linha dos valores reais durante o treinamento. Com o modelo gerado foi utilizado para realizar as predições da ação obtendo os resultados como descritos no GRÁFICO 20, onde os valores reais e preditos apresentaram uma boa aproximação e o sistema também foi capaz de prever uma queda ocorrida nos dias 14/05/2021 e 17/05/2021.

GRÁFICO 20 – Gráfico de comparação do valor real x previsto do 2º experimento do VISC11




FONTE: O autor (2021).

4.4 O MONITORAMENTO

A FIGURA 15 mostra a tela de monitoramento do sistema, onde é possível comparar o predito com o valor real. Essa comparação poderá ser feita sempre até o dia anterior.

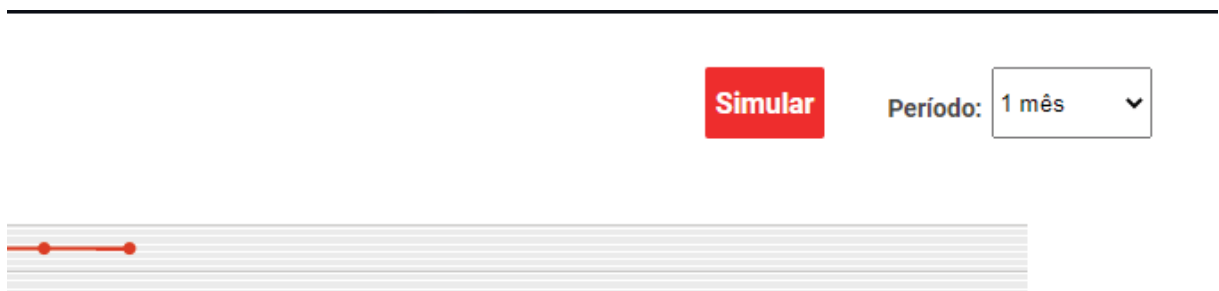
FIGURA 15 – Tela de monitoramento



FONTE: O autor (2021).

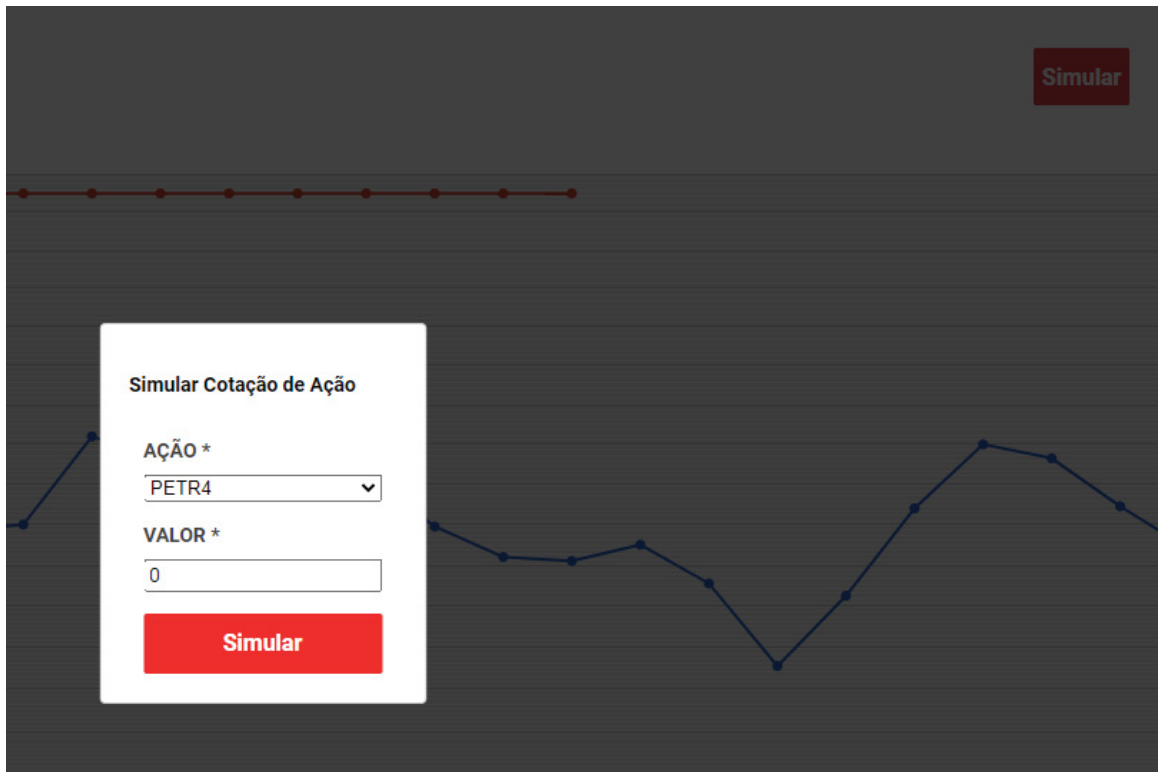
Por não ter sido possível contratar um serviço que busque os preços das ações atualizadas em tempo real, como mostra a FIGURA 15, foi desenvolvida uma tela que simula esse comportamento, para que seja possível ao sistema verificar se o preço está próximo do que foi predito e mostrar a sugestão de compra ou venda do ativo. Para fazer a simulação basta clicar no botão *Simular*, como mostrado na FIGURA 16, então será aberto um *popup* onde é possível selecionar a ação que se deseja simular, conforme é mostrado na FIGURA 17, na sequência, é necessário que se informe o valor e clique no botão *Simular* do *popup*, após essa ação será mostrada na tela de monitoramento com a sugestão do sistema de compra ou venda, como é mostrado na FIGURA 18.

FIGURA 16 – Botão que inicia a simulação da tela de monitoramento




FONTE: O autor (2021).

FIGURA 17 – Tela de simulação de preço de ação



FONTE: O autor (2021).

FIGURA 18 – Tela de monitoramento alertando o comportamento das ações



FONTE: O autor (2021).

A FIGURA 18 mostra a simulação da tela de monitoramento acompanhando o comportamento das ações durante o dia, onde alerta ao usuário quando o preço alcança a fronteira para cima ou para baixo do valor predito, informando ao usuário a necessidade de vender ou comprar.

5 CONSIDERAÇÕES FINAIS

Baseado nos resultados desse trabalho, conclui-se que embora existam acertos nas previsões de valorização e desvalorização através do sistema criado, com grande proximidade entre as predições e os valores reais em determinados períodos, fazer uma prévia dos valores futuros de ações simplesmente levando em conta o seu histórico de preços, não se mostrou muito eficiente, haja vista a característica especulativa do mercado financeiro. Tal condição, que denota grande instabilidade, não permite o acompanhamento de padrões, uma vez que envolve elementos muito subjetivos, como o sentimento humano. No mercado financeiro, qualquer acontecimento ao redor do mundo, a fala de uma autoridade ou uma declaração de um empresário pode fazer com que os acionistas fiquem temerosos ou otimistas com um determinado papel, mudando assim completamente a tendência que os preços estavam seguindo. Um exemplo disso foi o fato ocorrido durante a pandemia do Covid-19, que se iniciou em 2020 e criou uma corrida entre as farmacêuticas no desenvolvimento e vendas de vacinas para o mundo inteiro, cenário em que resultou numa grande valorização das ações referentes a essas companhias, mas que, tempos depois, após uma declaração do presidente dos Estados Unidos da América, Joe Biden, apoiando a suspensão da quebra de patentes das vacinas contra a pandemia, culminou com uma queda vertiginosa dos valores das ações de empresas farmacêuticas como: Moderna(-6,19%), BioNTech(-3,45%), Novavax(-4,94%) quebrando assim o qualquer tipo de previsão ou análise futura (Exame.Invest, 2021).

Reconhecendo as oscilações que cercam o mercado financeiro, entende-se que a ferramenta desenvolvida, embora não seja capaz de prever com exatidão os valores das ações, suas quedas e valorizações, pode, sem dúvidas, haja vista a proximidade dos dados coletados, ser utilizada como mais um instrumento na análise nas decisões de compras ou vendas de ações pelos investidores.

5.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Um ponto interessante a ser implementado, seria a consulta da ação em tempo real, que nesse momento não pode ser implementada diante do custo para a consulta do serviço.

Outro item que melhoraria a assertividade da predição seria criar um mecanismo que buscasse notícias em diversas fontes e envolvendo várias áreas e que, a partir disso, se interpretassem as informações coletadas e adicionassem esses dados nas predições caso esses fatos pudessem influenciar no ânimo do mercado.

REFERÊNCIAS

BEYSOLOW II, Taweh, Introduction to Deep Learning Using R - A Step-by-Step Guide to Learning and Implementing Deep Learning Models Using R. 1.ed. São Francisco - California: Apress Media, 2017.

BTG Pactual Digital, Bolsa de valores: o que é, como funciona e como investir, 2018. Disponível em: https://www.btgpactualdigital.com/como-investir/artigos/investimentos/tudo-sobre-bolsa-de-valores?cmpid=c04:m05:google:10091078072::101087369933&utm_medium=spl&utm_source=google&utm_campaign=10091078072&utm_content=101087369933&creative=436099160595&adposition=&keyword=&matchtype=&targetid=aud-484175182982:dsa-404428417342&device=c&feeditemid=&loc_interest_ms=9041153&loc_physical_ms=1001634&placement=&s_kwcid=AL!9288!3!436099160595!!!g!!&gclid=CjwKCAiA7dKMBhBCEiwAO_crFFhNNKre6rwwOaXSFR0qGTtmjRJkZSktiupPIWgD-wyQAK45LMowURoCn9EQAvD_BwE. Acesso em: 17 de novembro de 2021.

CASTRO, Giovanni, Mercado de Ações: o que é, como funciona, como investir e vantagens, BTG Pactual Digital, 2020. Disponível em: <https://www.btgpactualdigital.com/blog/investimentos/acoes/o-que-e-mercado-de-acoes-como-funciona-como-investir-e-vantagens>. Acesso em: 15 de novembro de 2020.

CLARO D. B. e Sobral J. B. M. PROGRAMAÇÃO EM JAVA. Copyright Pearson Education. Florianópolis, SC, 2008 <https://www.facterj-rio.edu.br/downloads/bbv/0031.pdf>. Acesso em: 07 de Dezembro de 2020.

CRUZ, Fábio, Scrum e Agile em Projetos Guia Completo. 2.ed. Rio de Janeiro-RJ: BRASPORT Livros e Multimídia Ltda, 2018.

DE LOSSO, Rodrigo, Aplicando inteligência artificial e machine learning no mercado financeiro, Valor Invest, 2019. Disponível em: <https://valorinveste.globo.com/blogs/nefin/coluna/aplicando-inteligencia-artificial-e-machine-learning-no-mercado-financeiro.ghtml>. Acesso em: 07 de agosto de 2020.

DE MEDEIROS, Luciano Frontino, Inteligência Artificial Aplicada Uma Abordagem Introdutória. 1.ed. Curitiba-PR: Editora Intersaberes, 2018.

DEITEL, H. M. DEITEL, P. J., Java Como programar. 10.ed. São Paulo: Person Prentice Hall, 2016.

EXAME.INVEST, Ações de farmacêuticas caem após Biden apoiar quebra de patente de vacinas, Exame, 2021. Disponível em: <https://invest.exame.com/me/acoes-de-farmaceuticas-caem-apos-biden-apoiar-quebra-de-patente-de-vacinas>. Acesso em: 08 de Maio de 2021.

FACELI Katti, LORENA A. Carolina, GAMA João, CARVALHO André C. P. L. Ferreira (2011) "Inteligência Artificial : Uma abordagem de aprendizado de máquina". 1.ed. Rio de Janeiro-PR: LTC – Livros Técnicos e Científicos Editora Ltda.

GUEDES, Gilleanes T. A. UML 2 – Uma Abordagem Prática. 3. ed. Novatec Editora Ltda. São Paulo – SP, 2018

HELLER, Martin, Deeplearning4j: Deep learning and ETL for the JVM, InfoWord, 2020. Disponível em: <https://www.infoworld.com/article/3567055/deeplearning4j-deep-learning-and-etl-for-the-jvm.html>. Acesso em: 15 de novembro de 2020.

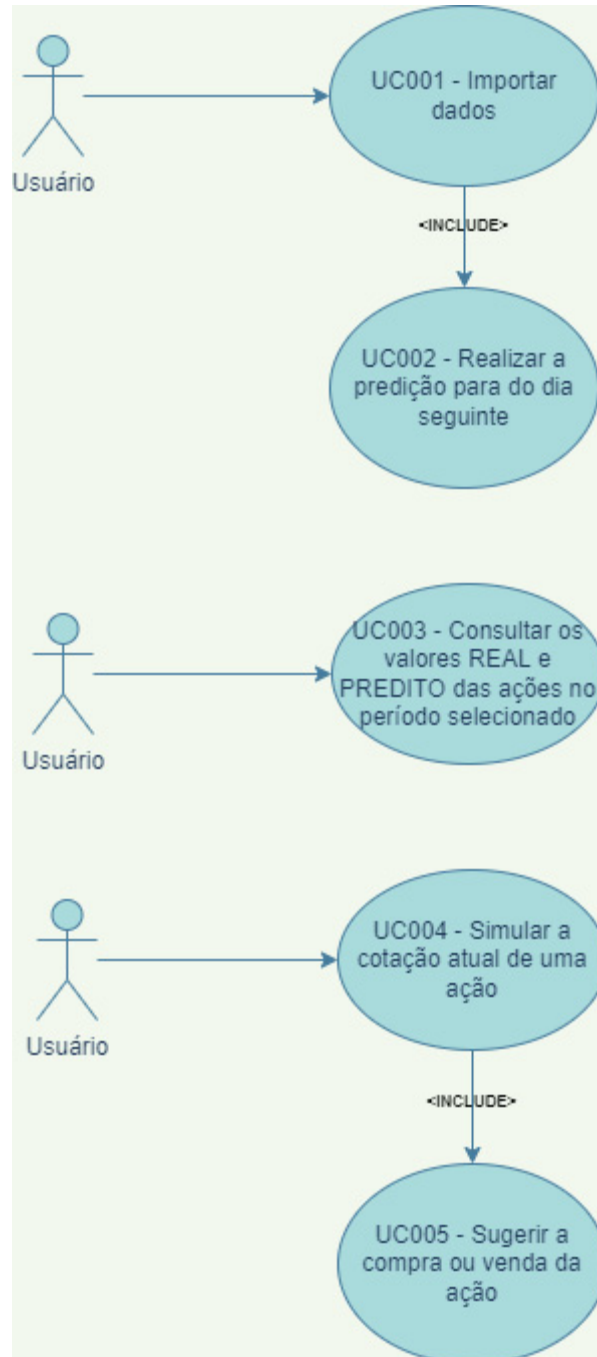
KARIM, Rezaul, Java Deep Learning. 1.ed. Birmingham - UK : Published by Packt Publishing Ltd, 2018.

NIGRO, Thiago Do mil ao milhão : sem cortar o cafezinho / Thiago Nigro. - 1. ed. - Rio de Janeiro : Harper Collins, 2018.

PACHECO, Cesar Augusto Rodrigues; Pereira, Natasha Sophi, Deep Learning Conceitos e Utilização nas Diversas Áreas do Conhecimento, v. 2, Revista Ada Lovelace, 2018. Disponível em: <http://45.4.96.34/index.php/adalovelace/article/view/4132/2770>, Acesso em: 09 de setembro de 2020

PONTI, M. A.; COSTA, G. B. P.. Tópicos em Gerenciamento de Dados e informações. ICMC - Universidade de São Paulo, São Carlos, SP – SBC, 1.ed, 2017. https://sites.icmc.usp.br/moacir/papers/Ponti_Costa_Como-funciona-o-Deep-Learning_2017.pdf

RUSSELL Stuart, NORVIG Peter, Inteligência Artificial. 3.ed. Rio de Janeiro-RJ: Elsevier Editora Ltda, 2013.

APÊNDICE 1 – DIAGRAMA DE CASO DE USO

FONTE: O autor (2021).

UC001 USE CASE DE IMPORTAÇÃO DE DADOS

Atores:

Usuário;

Sistema;

Descrição:

Importar as cotações reais das ações

Fluxo Básico:

1. Usuário baixa os dados das cotações dos dias anteriores em uma planilha eletrônica;
2. Usuário navega para a tela de importação clicando no botão “Ir para Importação de Histórico”;
3. Usuário clica no botão “SELECIONE O ARQUIVO”;
4. O sistema abrirá um popup de seleção de arquivo;
5. O usuário deverá selecionar o arquivo com os dados das cotações;
6. Após a seleção do arquivo o processo de importação será iniciado e os valores serão salvos no banco de dados;
7. O UC002 será executado;

Fluxo Alternativo:

N/A

UC002 USE CASE QUE REALIZA A PREDIÇÃO PARA O DIA SEGUINTE

Atores:

Sistema;

Descrição:

Realiza as previsões do preço das ações do dia seguinte

Fluxo Básico:

1. Após os dados reais terem si salvos no banco através do UC001, o sistema usa esses valores e executa o treinamento de máquina e a previsão do preço da ação para o dia seguinte;
2. Ao concluir a previsão o valor será salvo no banco de dados; **[A1]**

Fluxo Alternativo:

[A1]

1. Caso já tenha um valor predito para esse dia o valor será substituído;

UC003 USE CASE DE CONSULTA VALORES REAL E PREVISTO

Atores:

Usuário;

Descrição:

Tela de consulta que mostra os dados de cotação de real x previsto;

Fluxo Básico:

1. A tela inicial do sistema mostrará os dados de real x predição no período de uma semana; **[A1]**

Fluxo Alternativo:

[A1]

2. O usuário poderá selecionar outro período para comparar o valor real x predito em 1 semana, 2 semanas, 1 mês e 2 meses;

UC004 USE CASE DE SIMULAÇÃO DE COTAÇÃO DE AÇÃO

Atores:

Usuário;

Descrição:

Simulação de alerta conforme a flutuação dos valores de cotações;

Fluxo Básico:

1. Na tela inicial do sistema o usuário clicará no botão “Simular”; **[A1]**
2. Será aberto um popup onde o usuário deverá selecionar a ação e informar o valor da ação e clicar no botão “Simular”;
3. O sistema fechará o popup e simulará o valor informado como se fosse o preço atual da ação e o UC005 será chamado;

Fluxo Alternativo:

[A1]

1. Se o usuário clicar em qualquer lugar fora do popup, o processo de simulação será cancelado e o popup será fechado;

UC005 USE CASE DE SUGESTÃO COMPRA E VENDA

Atores:

Sistema;

Descrição:

O sistema irá sugerir a compra ou venda da ação;

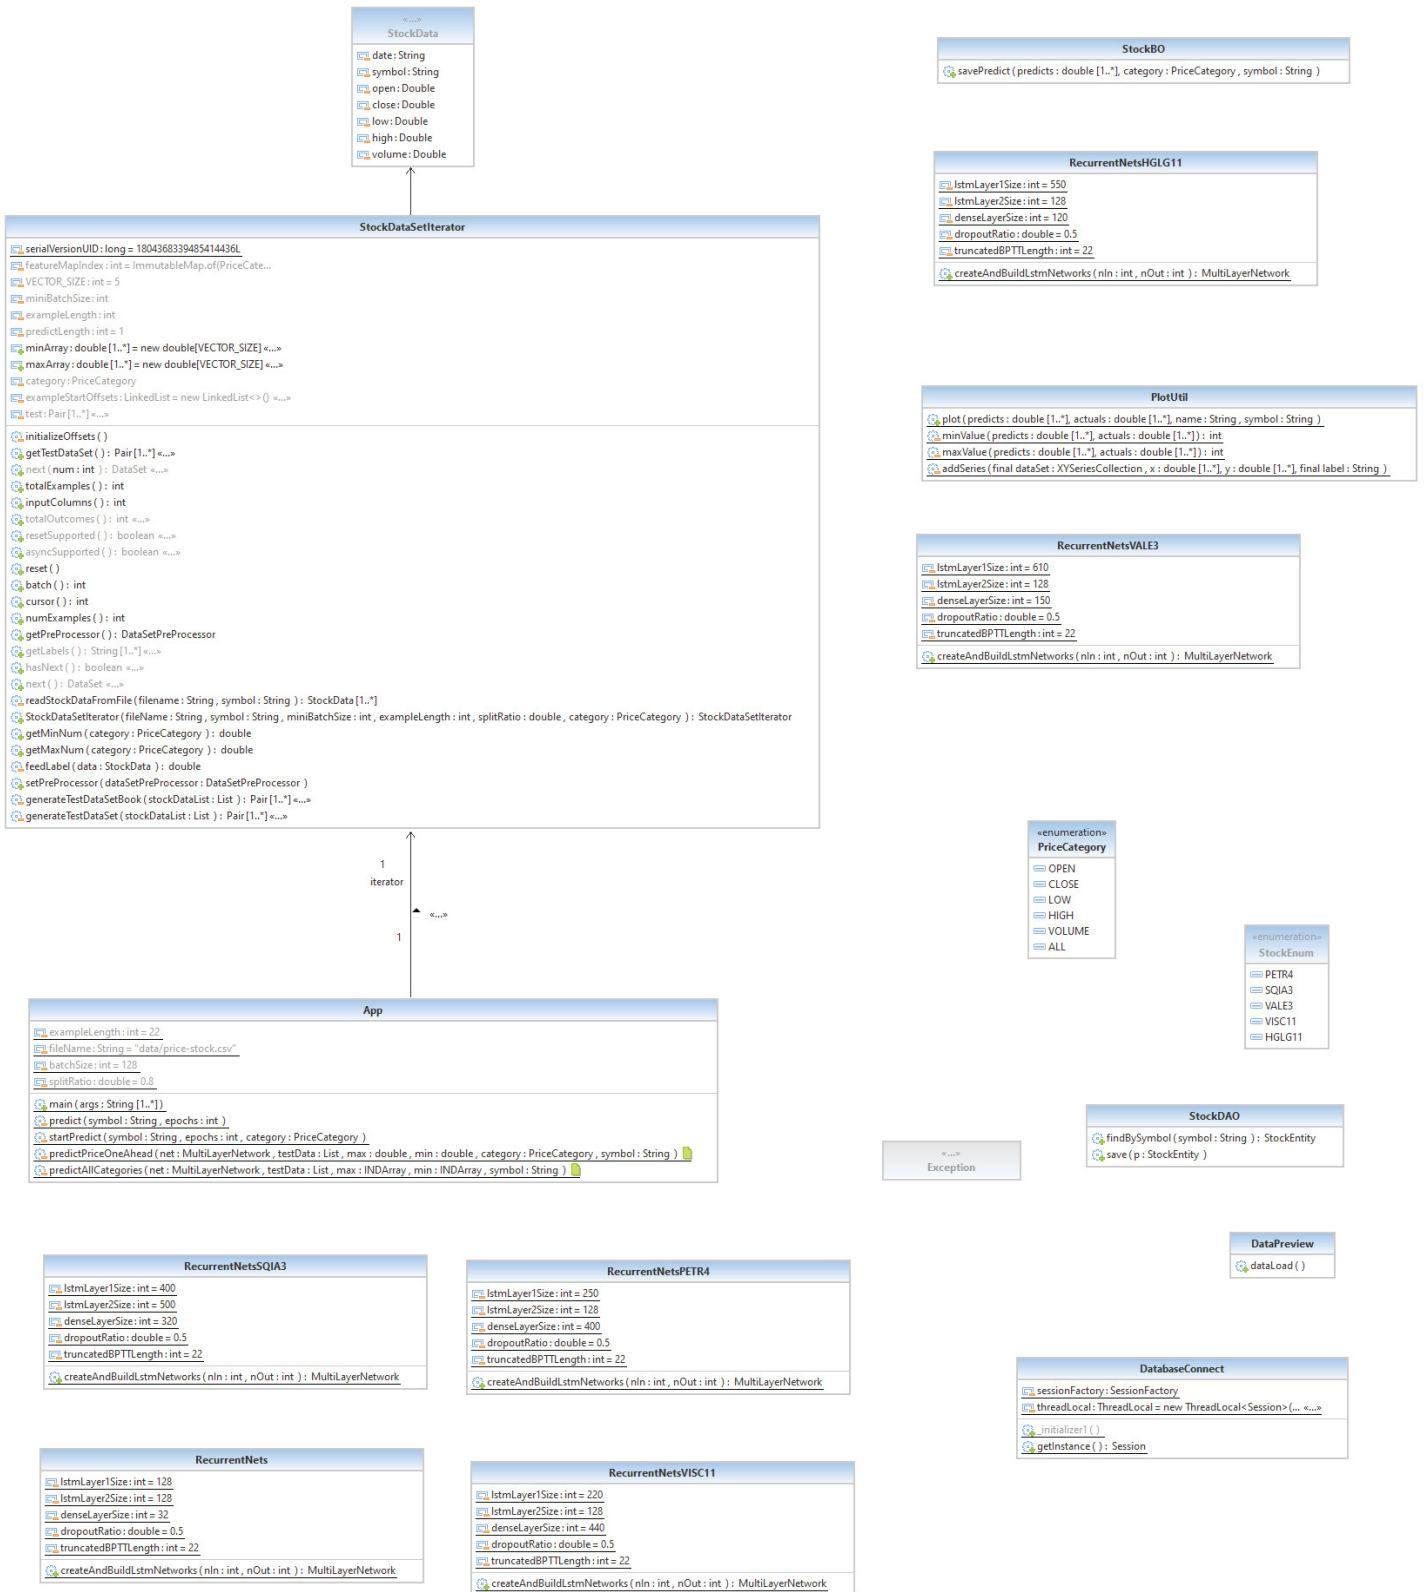
Fluxo Básico:

1. Baseado no treinamento e no valor predito para o dia, o sistema irá sugerir a compra ou venda do ativo conforme o valor imputado na simulação;

Fluxo Alternativo:

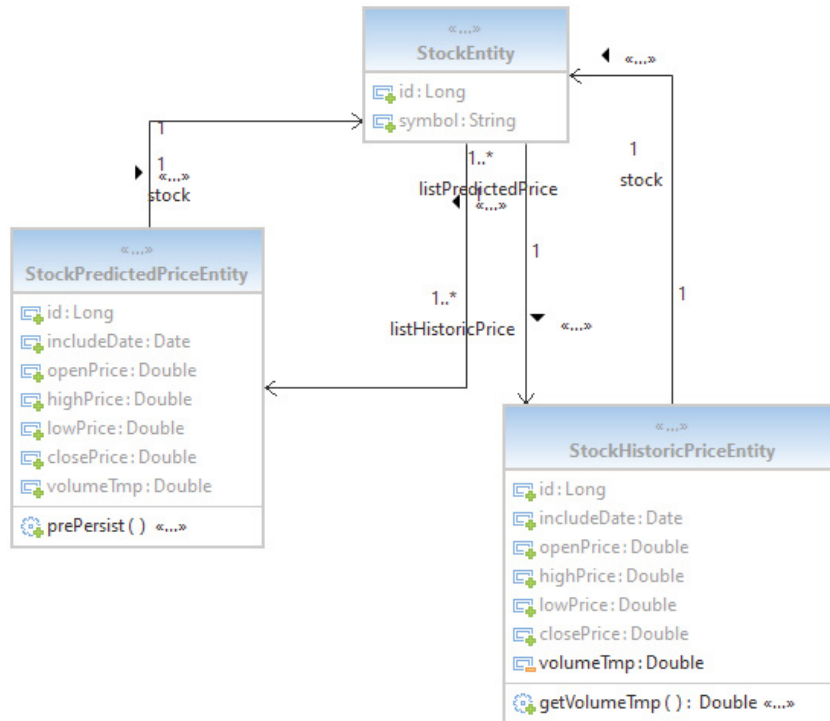
N/A

APÊNDICE 2 – DIAGRAMA DE CLASSE DO PROJETO SMART-STOCK-IA



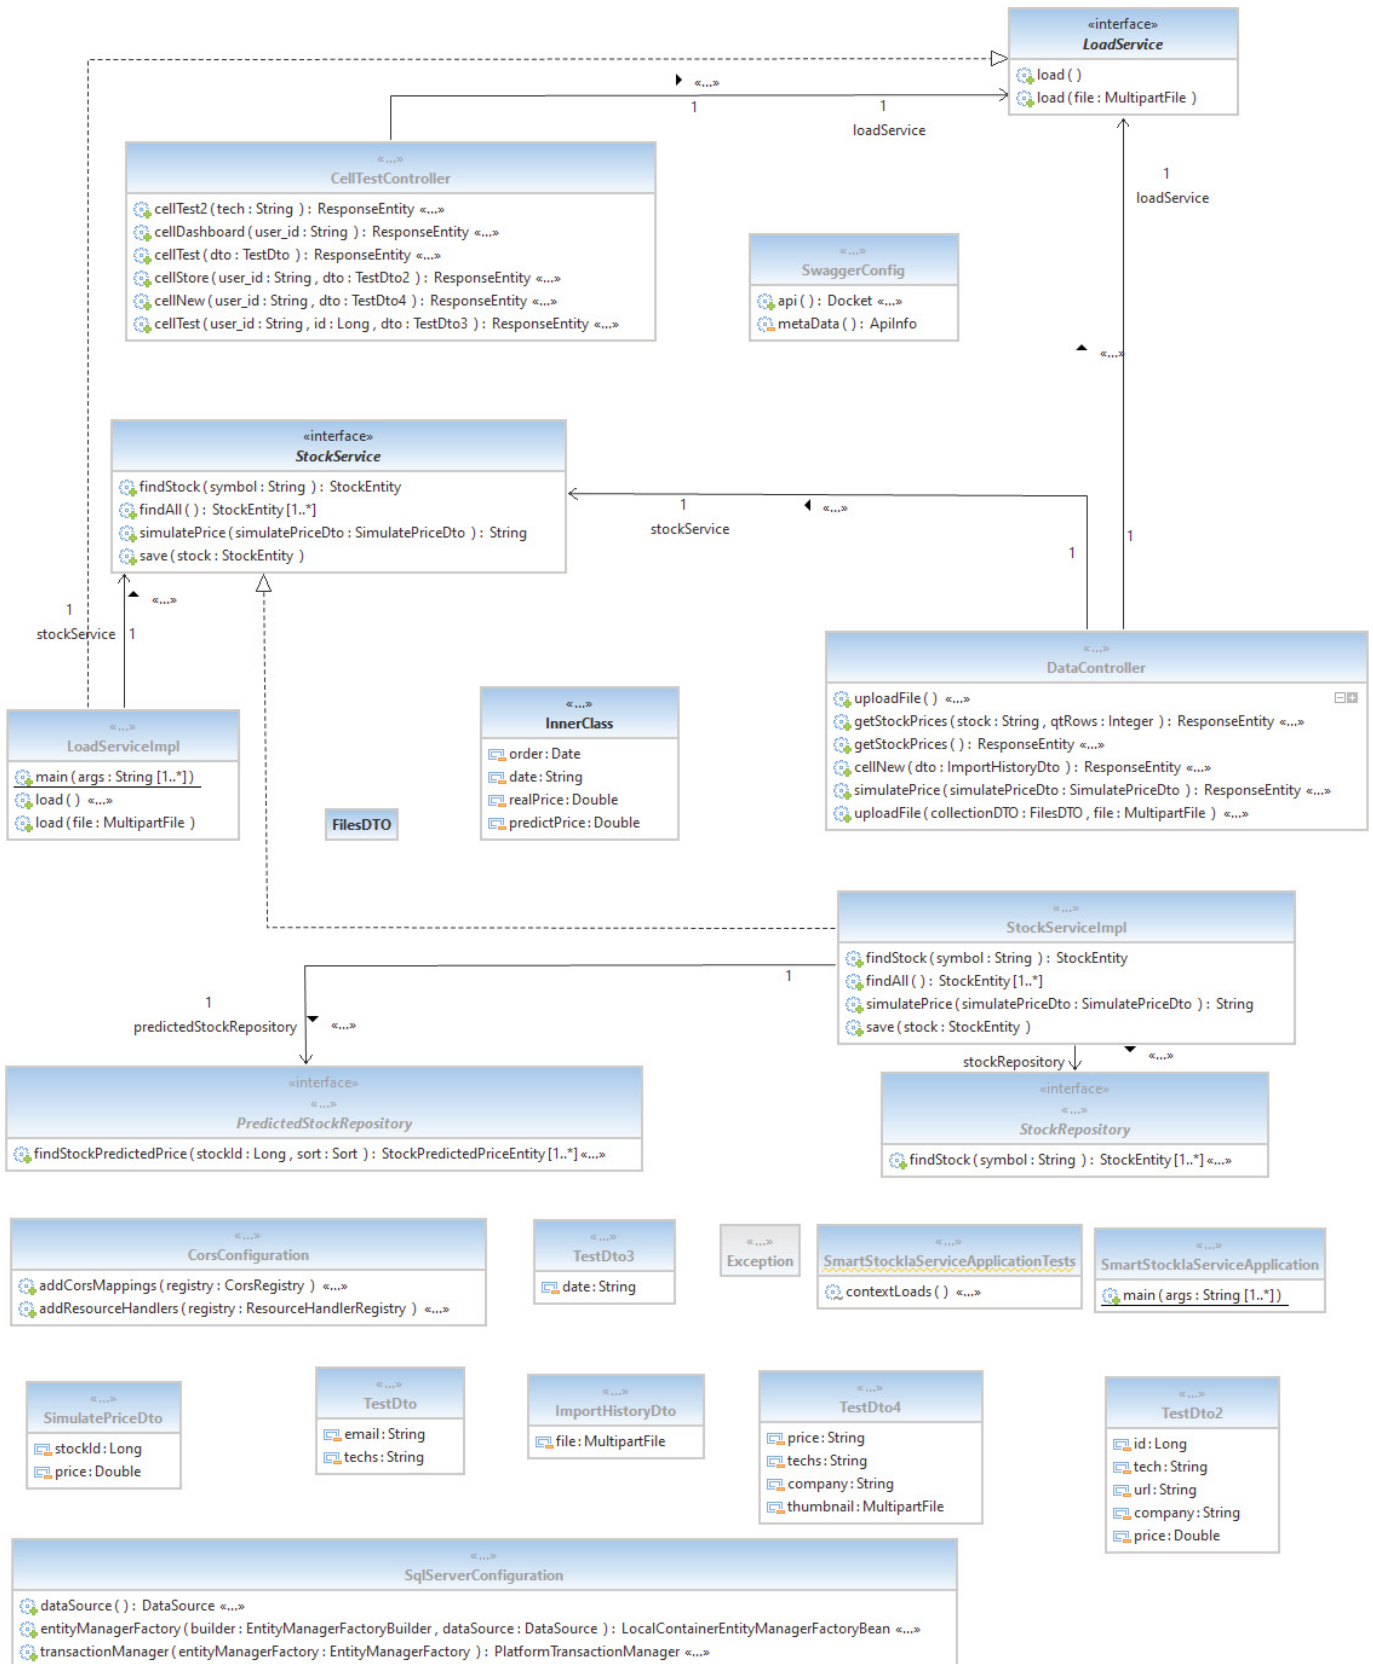
FONTE: O autor (2021).

APÊNDICE 3 – DIAGRAMA DE CLASSE DA BIBLIOTECA DO PROJETO SMART-STOCK-IA-ENTITY



FONTE: O autor (2021).

APÊNDICE 4 – DIAGRAMA DE CLASSE DA BIBLIOTECA DO PROJETO SMART-STOCK-IA-SERVICE



FONTE: O autor (2021).

APÊNDICE 5 – REPOSITÓRIO DO CÓDIGO FONTE

Nos repositórios do Bitbucket abaixo são os códigos fontes de todos os projetos desse estudo e está disponível para trabalhos futuros, evolução ou que seja usado como exemplo para outros projetos.

- Biblioteca com as entidades:

git clone <https://luispastre@bitbucket.org/luispastre/smart-stock-ia-entity.git>

- Projeto que realiza a predição dos preços das ações:

git clone <https://luispastre@bitbucket.org/luispastre/smart-stock-ia.git>

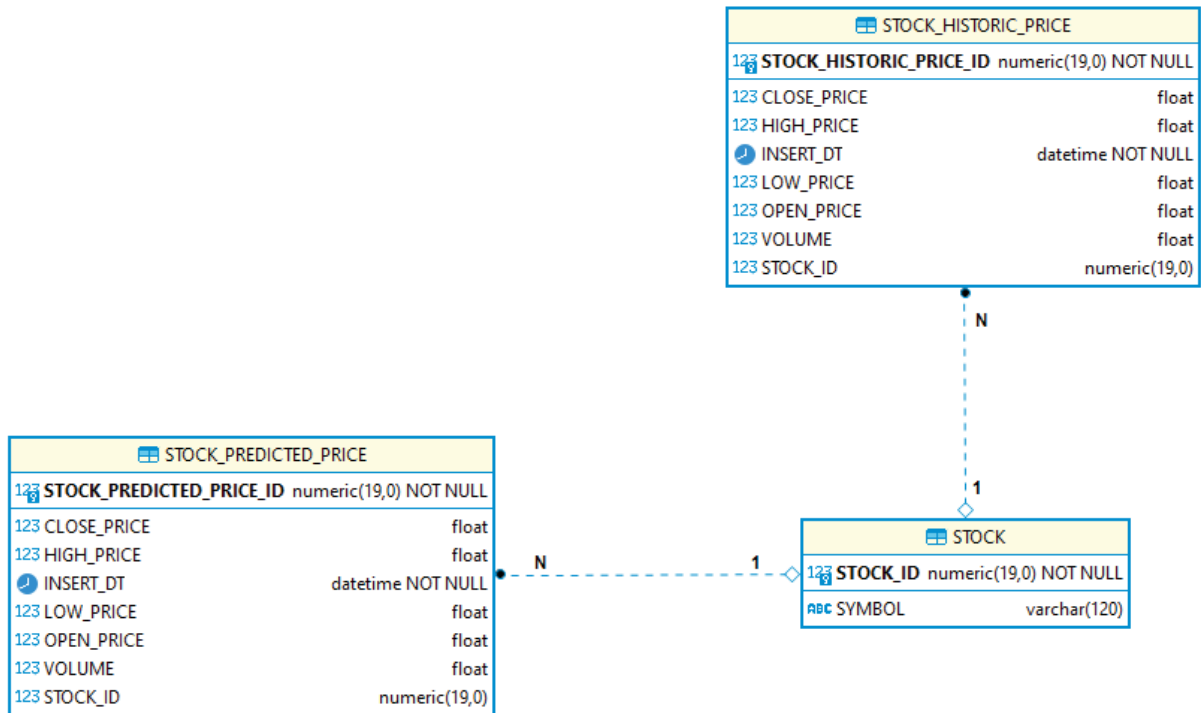
- Projeto microsserviço que realiza a importação e consulta os valores reais das cotações como o que foi predito:

git clone <https://luispastre@bitbucket.org/luispastre/smart-stock-ia-service.git>

- Projeto web que possui a interface com o usuário:

git clone <https://luispastre@bitbucket.org/luispastre/smart-stock-ia-web.git>

APÊNDICE 6 – DIAGRAMA DE ENTIDADE RELACIONAMENTO



FONTE: O autor (2021).