

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
ESCOLA POLITÉCNICA E DE ARTES
ENGENHARIA DE CONTROLE E AUTOMAÇÃO
Trabalho Final de Curso II

Gabriela de Matos César
Silvio Vidal de Miranda Junior

ANÁLISE PREDITIVA COM REDES NEURAIS ARTIFICIAIS PARA A
PRECIFICAÇÃO DE GRÃOS NO MERCADO DE *COMMODITIES*

Trabalho Final de Curso II como parte dos requisitos para
obtenção do título de bacharel em Engenharia de
Controle e Automação, apresentado à Pontifícia
Universidade Católica de Goiás.

BANCA EXAMINADORA:

Prof. Dr. Marcos Antônio de Sousa – Orientador. POLI-PUC Goiás.
Prof. Dr. Antônio Marcos de Melo Medeiros – POLI-PUC Goiás.
Prof. Dr. Bruno Quirino de Oliveira – POLI-PUC Goiás.

Goiânia, 13 de junho de 2023

Análise Preditiva com Redes Neurais Artificiais para Precificação de Grãos no Mercado de *Commodities*

GABRIELA DE MATOS CÉZAR, SILVIO VIDAL DE MIRANDA JUNIOR, MARCOS ANTÔNIO SOUSA

Abstract - This paper describes the development of an Artificial Neural Network (ANN) with the objective of forecasting the prices of three agricultural commodities: rice, corn, and soybeans, based on historical data. Scenarios using time series containing price data of the commodities between the years 2004 and 2023 were analyzed and discussed. The developed system allows the automated analysis of future values, using recurrent neural networks and Long Short-Term Memory (LSTM) techniques. The effectiveness of the developed system was evaluated using datasets obtained from public repositories. The results obtained are presented and discussed in detail. The preliminary results of training and prediction demonstrated the effectiveness of the developed computational tool, highlighting the accuracy of the implemented prediction model.

Translated with www.DeepL.com/Translator (free version)

Keywords – Artificial neural network, artificial intelligence, prediction, agriculture, LSTM, data analysis, rice, corn, soya.

Resumo – Este trabalho descreve o desenvolvimento de uma Rede Neural Artificial (RNA) com o objetivo de realizar previsões dos preços de três *commodities* agrícolas: arroz, milho e soja, com base em dados históricos. Foram analisados e discutidos cenários que utilizam séries temporais contendo dados de preços das *commodities* entre os anos de 2004 e 2023. O sistema desenvolvido permite a análise automatizada de valores futuros, utilizando técnicas de redes neurais recorrentes e *Long Short-Term Memory* (LSTM). A eficácia do sistema desenvolvido foi avaliada utilizando conjuntos de dados obtidos a partir de repositórios públicos. Os resultados obtidos são apresentados e discutidos de forma detalhada. Os resultados preliminares do treinamento e da previsão demonstraram a eficácia da ferramenta computacional desenvolvida, destacando a acurácia do modelo de previsão implementado.

Palavras-chave – Rede neural artificial, inteligência artificial, previsão, agricultura, LSTM, análise de dados, arroz, milho, soja.

I. INTRODUÇÃO

Desde os primórdios do tempo, o ser humano tem tentado prever o ambiente ao seu redor. A previsão do preço de *commodities* também faz parte dessa busca, pois ajuda os produtores a determinarem a melhor época para iniciar a produção, identificar o momento certo para vender e ter uma ideia do preço esperado para aquela *commodity*.

A previsão automatizada se tornou possível graças aos avanços computacionais, que permitiram o

desenvolvimento de sistemas de apoio à decisão, incluindo a Inteligência Artificial (IA). Entre as técnicas de IA, destaca-se a rede neural artificial (RNA), baseada nos estudos da anatomia dos neurônios humanos.

As RNAs evoluíram ao longo do tempo e deram origem a uma variação chamada rede neural recorrente (RNN). A principal diferença da RNN em relação às RNAs convencionais é que os dados inseridos no sistema são reinseridos no processo. Essa característica torna o processo adaptativo, pois à medida que os valores são processados, eles alteram as previsões, permitindo um maior grau de assertividade na tomada de decisões.

Os valores das *commodities* são definidos por meio de séries temporais, que são observações dos valores ao longo do tempo. Essas séries temporais revelam tendências nos valores de venda das *commodities*.

Uma técnica de aprendizado de máquina adequada para prever conjuntos de valores em séries temporais é a rede neural recorrente LSTM (*Long short-term memory* - memória de curto prazo longa). Nessa configuração, os neurônios da rede neural recorrente podem ser treinados para armazenar, substituir e descartar informações de forma autônoma.

Esse trabalho descreve a criação de uma RNN LSTM em *Python* para prever os preços das *commodities* agrícolas: arroz, soja e milho. A RNN LSTM foi desenvolvida utilizando uma base de dados com cerca de 5.000 registros de preços para cada *commodity*. Dos dados disponíveis, 70% foram utilizados para treinar a RNN LSTM, enquanto os 30% restantes foram reservados para testes e validação, a fim de avaliar a precisão e os resultados da aplicação.

A seção II descreve as redes neurais recorrentes LSTM, as *commodities* e as séries temporais utilizadas neste trabalho. Na seção III, são descritos os materiais e métodos utilizados no processo de coleta e tratamento de dados, com destaque para os processos de configuração, treinamento e validação do modelo RNN LSTM desenvolvido. Na seção IV, apresentam-se os resultados obtidos com a aplicação do modelo treinado, com a análise de métricas de desempenho e a avaliação do modelo em diferentes cenários. Por fim, na seção V, são apresentadas as conclusões obtidas a partir dos resultados obtidos e indicativos de continuação para o aprimoramento do modelo e sua aplicação em outros contextos.

II. FUNDAMENTAÇÃO TEÓRICA

Inteligência artificial de acordo com Rich e Knight [1] é “o estudo de como fazer os computadores realizarem coisas que, no momento, as pessoas fazem melhor”. As IAs (Inteligência Artificial) são entidades criadas de forma que são capazes de receber dados e com base em modelos

matemáticos e estatísticos, podem obter respostas para os mais diversos problemas.

Segundo Russel e Norvig [2] Inteligências artificiais têm sido aplicadas desde 1943 por Warren McCulloch e Walter Pitts, e na teoria inicial foi baseada em 3 pilares: na teoria da computação de Alan Turing, a lógica proposta por Russell e Whitehead, e por último o conhecimento do cérebro humano, mais especificamente dos neurônios.

Uma técnica bastante poderosa, com grande velocidade de processamento e alto desempenho é a rede neural artificial, “redes neurais são modelos estáticos adaptativos baseados em uma analogia com a estrutura do cérebro” [3], tomando como base a estrutura dos neurônios biológicos. Essa técnica é adequada para a resolução de problemas que possuam ampla base de dados, não tenham solução fácil por métodos mais simples, que exijam processamento rápido de novas entradas de dados e que o processamento deva ser resistente a pequenos ruídos de entrada [4].

O cérebro humano tem uma infinidade de neurônios que com a sua estrutura podem processar informações. De acordo com Bishop [4], os dendritos fornecem um conjunto de entradas para o neurônio, enquanto o axônio atua como uma saída e a comunicação entre a entrada e saída é feito pelas sinapses.

A Figura 1 mostra a estrutura dos neurônios e de acordo com Moreira [5], os dendritos são responsáveis por receber estímulos do ambiente por meio de células sensoriais, o axônio que envia o sinal recebido pelos dendritos em forma de impulso elétrico até a terminação do axônio que encontra os dendritos outro neurônio, quando o impulso passa de um neurônio para o outro acontece a sinapse.

DENDRITOS

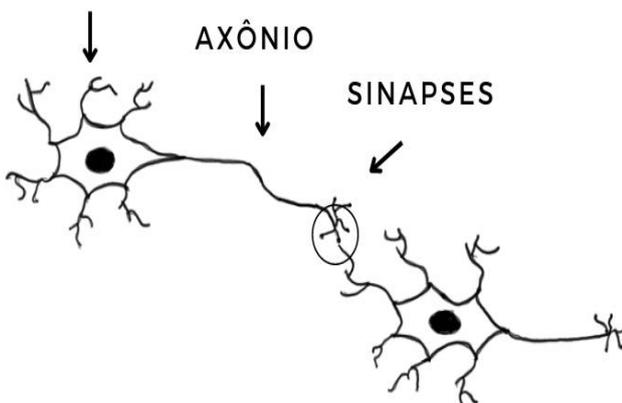


Fig. 1 - Anatomia de um neurônio (adaptada de [4]).

A. Redes Neurais Artificiais (RNA)

Com base nos estudos da anatomia do neurônio, foi desenvolvida a rede neural artificial, onde os dendritos são os neurônios de entrada que recebem a informação, as sinapses correspondem às camadas intermediárias, que tratam os dados de entrada aplicando pesos e os axônios são os neurônios de saída. A Figura 2 apresenta o modelo de uma RNA *multi-perceptron*.

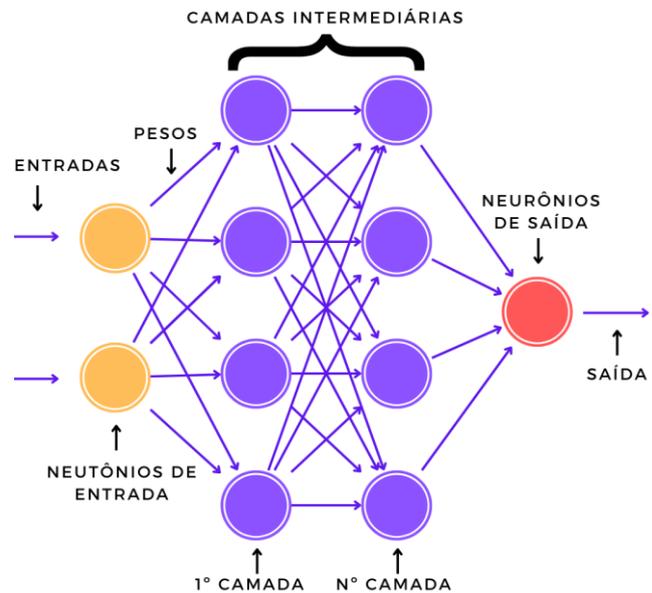


Fig. 2 - Modelo de uma rede neural artificial (adaptada de [6]).

A RNA (rede neural artificial) recebe uma informação pelo neurônio de entrada, este sinal é multiplicado por um peso e inserido em um neurônio da camada intermediária, ao passar por todas as camadas intermediárias, o sinal é enviado para os neurônios de saída obtendo assim o resultado esperado.

A rede neural é criada em etapas e de acordo com Silva [7] deve ser definida a forma que um neurônio está organizado em relação ao outro, isso é chamado de arquitetura de redes neurais. A composição estrutural de uma rede neural é chamada de topologia e é a parte responsável por escolher quantos neurônios serão escolhidos para essa RNA.

Silva [7] ainda define que após escolher como os neurônios vão ser colocados e quantos neurônios vão existir na rede neural, é feito o processo de treinamento, nesse processo a rede neural ajusta os pesos e os limites dos neurônios. O treinamento é feito com valores conhecidos de entrada e saída, e com base nisso, quando um novo valor é inserido na entrada, a RNA prevê o valor de saída.

B. Redes Neurais Recorrentes (RNN)

As RNNs (*Recurrent Neural Networks* - Redes Neurais Recorrentes) são modelos de aprendizagem profunda, elas se diferem das redes neurais artificiais, pois os dados são inseridos novamente no processo. Essa diferença entre os dois modelos impacta no resultado final, tendo em vista que as RNNs produzem modelos adaptativos, ou seja, que mudam durante o processo, dependendo dos dados que são inseridos. A Figura 3 descreve a topologia de uma RNN.

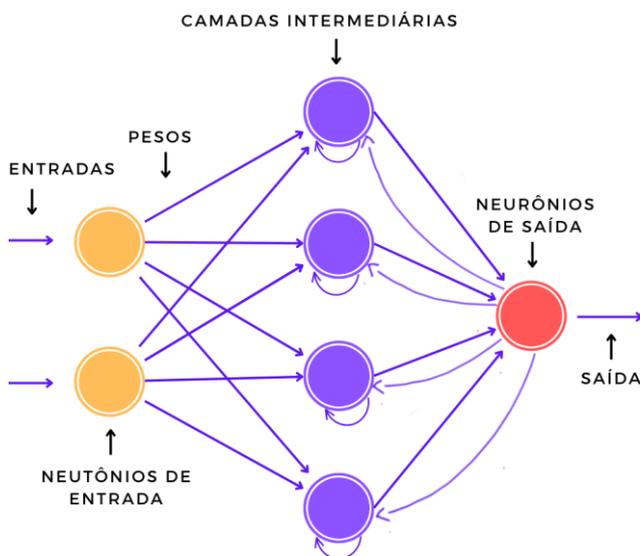


Fig. 3 - Modelo de uma rede neural recorrente (adaptada de [8]).

C. Commodities

Segundo o Serasa [9], *commodities* podem ser definidas como “produtos elaborados ou produzidos em larga escala com características uniformes, que não apresentam diferença sobre quem ou onde foram produzidos”. As *commodities* são matérias primas, que podem ter origem agrícola, mineral ou vegetal.

As *commodities* possuem grande importância para a economia mundial e nacional. No Brasil, no ano de 2021 foram exportados US\$ 280,8 bilhões em *commodities* [10] e US\$ 120,6 bilhões apenas em mercadorias agrícolas [11].

Tipos de *Commodities*

De acordo com o Serasa [9] os principais tipos de *commodities* são três:

- Minerais: recursos naturais como gás natural, petróleo, ouro, carvão e minério de ferro.
- Financeiras: consiste em moedas, como reais e euros, e títulos públicos.
- Agrícolas: alimentos como carnes, grãos, frutas, açúcar e fibras como algodão e lã são exemplos de *commodities* agrícolas. Dentre todos os tipos este é o que possui maior complexidade em sua venda, pois tratam-se em boa parte de produtos perecíveis e que facilmente perdem sua qualidade seja por tempo de armazenamento, umidade ou pragas, como insetos e fungos.

Além das dificuldades já apontadas, estes produtos possuem uma sazonalidade bastante relevante, assim o preço flutua ao longo dos meses influenciado pela produção.

Neste estudo serão analisadas *commodities* agrícolas, mais especificamente arroz, soja e milho, três grãos que representam uma grande parcela de toda a exportação brasileira, somando em 2021 aproximadamente US\$52,56 bilhões [12][13][14].

D. A Rede Neural Recorrente LSTM

A rede LSTM (*Long short-term memory* - memória de curto prazo longa) representa um tipo de Rede Neural

Recorrente (RNN) que surgiu em meados de 1990, e que possibilita realizar tarefas de predição em base de dados que possuem uma dimensão temporal [5]. Portanto, a LSTM é um tipo de RNN adequada para avaliar problemas que lidam com séries temporais.

De acordo com Hochreiter e Schmidhuber [16] definem que:

As redes recorrentes podem, em princípio, utilizar as suas ligações de *feedback* para armazenar representações de eventos recentes sob a forma de ativações (memória a curto prazo”, em oposição a “memória a longo prazo” encarnada pela mudança lenta de pesos).

A realimentação ou feedback que acontece no modelo LSTM permite que a rede neural mantenha informações, o que torna possível que a rede neural aprenda por mais tempo. Além disso, no modelo LSTM os neurônios são programados para a tomada de decisões, de forma a escolherem quais informações serão armazenadas, podendo também ler, excluir e substituir os dados armazenados [17].

A Figura 4 descreve esse processo através do que é chamado de “célula de memória”. Na arquitetura das células de uma rede neural LSTM de acordo com DSA [17] o portão de esquecimento é responsável por remover as informações que não são mais úteis para a célula, o portão de entrada adiciona novos valores à célula e o portão de saída é responsável por extrair as informações que a aplicação necessitar.

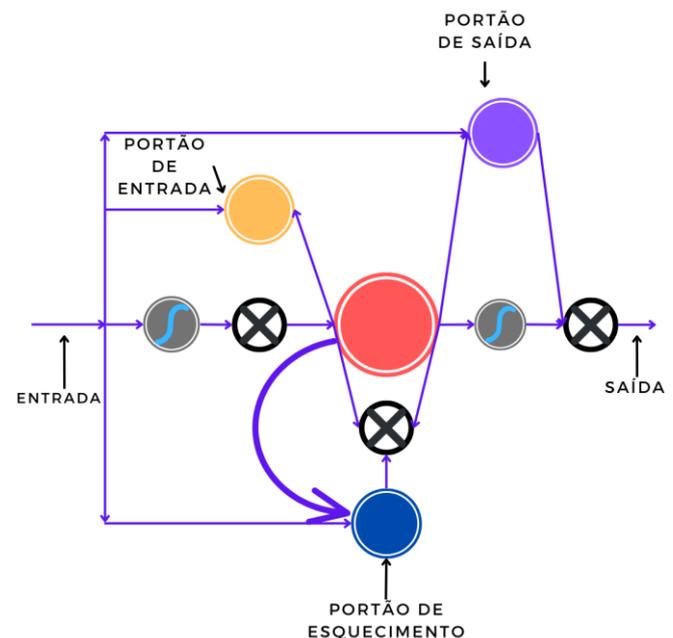


Figura 4 - Diagrama da célula de memória de uma LSTM (adaptada de [17]).

As redes neurais LSTM são a evolução dos modelos convencionais. O grande aditivo que as memórias trazem para o sistema é a capacidade de correlacionar os eventos que já aconteceram com os que vão acontecer. Sendo assim, a DSA [15] define as LSTMs como “múltiplas cópias da mesma rede”. Esse processo está descrito na Figura 5.

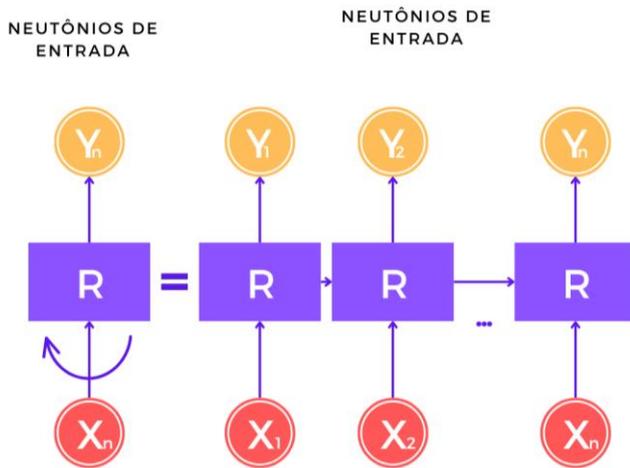


Figura 5 - Modelo equivalente de uma rede neural LSTM (adaptada de [17]).

O aprendizado utilizado para a LSTM pode ser definido como Aprendizado profundo, ou do inglês, *deep learning*, que é um tipo de aprendizado de máquinas.

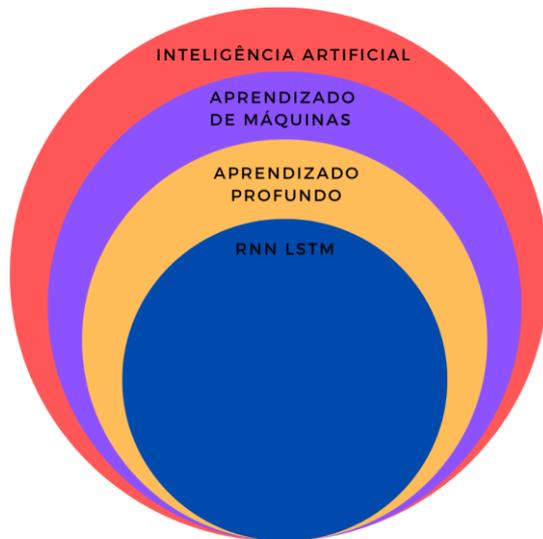


Figura 6 – Classificação da RNN LSTM no universo da IA (adaptada de [18]).

De acordo com Shah e Shinde [19], o aprendizado profundo é a estrutura das unidades de processamento, de forma a organizá-las em cascata de múltiplas camadas para que seja possível a extração de informações. Com a arquitetura da *deep learning* as camadas mais próximas à entrada aprendem processos mais simples, já as camadas mais profundas, aprendem processos mais complexos.

E. Séries temporais.

As redes LSTMs fazem a predição com base em uma série de valores temporais. Essas séries temporais são definidas por Ehlers [20] como “uma coleção de observações feitas sequencialmente ao longo do tempo”. Os dados são colhidos e armazenados à medida que são obtidos, pois no caso de séries temporais o comportamento muda caso um valor seja inserido em um ponto errado no tempo.

No caso da análise de séries temporais, os valores são obtidos, discretizados, registrados e agrupados em intervalos de tempo. Os dados de custo de mercado de *commodities*, assim como muitos outros, podem ser modelados por séries temporais. Nesse trabalho é utilizado redes neurais LSTMs para fazer predição em séries temporais de *commodities* agrícolas.

III. MATERIAIS E MÉTODOS

Visando a resolução de casos de maneira automatizada, ou seja, sem a intervenção humana, mas sem a perda de qualidade e em tempo razoável, este estudo visa aplicar técnicas de IA, mais especificamente através de redes neurais recorrentes.

A aplicabilidade de redes neurais artificiais é muito ampla, uma vez que sua arquitetura é bastante versátil. Assim, dados como a quantidade de camadas, número de elementos por camada, taxa de aprendizado e, também, os critérios de parada do treinamento devem ser planejados de maneira customizada, para cada aplicação e resultado esperado. Portanto, um ajuste adequado da estrutura de uma rede neural é parte essencial de seu desenvolvimento.

O projeto consiste em escolher a técnica mais adequada, escolher um caso no qual a inteligência artificial poderá atuar como sistema de apoio à decisão e desenvolver uma aplicação que implementa a ferramenta escolhida.

A rede deve ser capaz de prever o preço de *commodities* de grãos, utilizando como base os preços de anos anteriores, com granularidade diária.

O sistema inteligente de apoio à decisão desenvolvido nesse trabalho, utilizando RNN LSTM, possibilita o tratamento e a análise de base de dados de *commodities*. O estudo dessas bases de dados gera subsídios para compreender o comportamento de séries temporais e, conseqüentemente, realizar a predição da precificação da *commodity* no mercado.

A. Base de Dados

Para que seja possível atingir bons resultados na aplicação é preciso uma ampla base de dados. Dessa forma, a base de dados utilizada contempla dados diários a partir do ano de 2005 sobre o preço das *commodities* a serem analisadas: soja, milho e arroz. A base de dados recolhida para o presente trabalho foi retirada do site do CEPEA (Centro de Estudos Avançados em Economia Aplicada) que recolhe os dados dos índices da BM&FBOVESPA [21]. Esse índice mede o desempenho de ações e mercadorias e recolhe o valor diário das *commodities* por saca de 60kg no caso do milho e da soja e no caso do arroz para as sacas de 50kg.

Etapa de Inicialização

Para a aplicação da RNN LSTM é necessária uma base de dados para a etapa de treinamento. A plataforma utilizada foi o software *Python*, na versão 3.9.13, com o ambiente de desenvolvimento integrado “Anaconda”. A comunicação entre o sistema desenvolvido e a base de dados utilizada nas aplicações é realizada através da biblioteca “Pandas”.

Para a aplicação da RNN LSTM é necessária uma base de dados para a etapa de treinamento. Para isso foi implementado na linguagem *python*, na versão 3.9.13, e o

ambiente de desenvolvimento integrado, conhecido também como *IDE*, utilizada para essa aplicação foi o *anaconda spyder*.

Os dados presentes no site são disponibilizados em uma planilha com dados desde 2005 até o dia 28/02/2023. Os dados são recolhidos apenas nos dias úteis, logo, não se tem valor das *commodities* nos fins de semana e em feriados.

Na sequência, foram inseridas três bibliotecas:

- a primeira é a biblioteca *TensorFlow*, fornece uma API chamada *Keras*, que facilita a criação e treinamento da rede neural;
- a segunda é a biblioteca *pandas*, que torna fácil a manipulação de dados, desde a coleta até a filtragem de dados que são úteis para a RNN LSTM;
- a terceira biblioteca a ser implementada foi a *numpy*, que torna mais fácil manipular um grande conjunto de dados numéricos;
- a quarta biblioteca foi a *matplotlib*, que fornece ferramentas para a criação de gráficos.
- a quinta biblioteca foi a *datetime*, que permite trabalhar com datas mais facilmente.

Padronização dos Dados

Uma vez que a base de dados já esteja integrada com a aplicação é preciso realizar alguns pequenos ajustes. O *python* não compreende a vírgula como um sinal que divide um número inteiro de sua parte fracionária e sim o ponto. Para isso os valores devem passar por um tratamento onde a vírgula deve ser substituída por ponto, como por exemplo:

- Valor em Real da saca de 60kg da soja no site do CEPEA no dia 13/03/2006 R\$27,66.
- Valor em Real da saca de 60kg carregado no python - R\$2766.

Isso acontece, pois, a vírgula, em inglês, é utilizada apenas para separar expressões linguísticas, o que separa a unidade de um décimo é o ponto, por isso ele compreende o R\$27,66 como R\$2766. Quando o valor é carregado no python, deve passar por uma padronização, sendo adicionado no valor o ponto onde deveria ser a vírgula e após isso o valor deve ser apresentado como R\$27.66. A partir daí é possível utilizá-lo para avaliar os dados, treinar a LSTM e verificar o desempenho do sistema desenvolvido.

Configuração da RNN LSTM

O desenvolvimento da rede neural foi feito com base no entendimento sobre a ferramenta *Keras* desenvolvido a arquitetura da RNN LSTM.

A aplicação necessita apenas de uma entrada, para isso foi configurado apenas um neurônio de entrada para receber a requisição da predição do preço das *commodities*. Para as camadas intermediárias foi construído dez camadas com oito neurônios em cada camada. Esses ajustes nos hiper parâmetros da LSTM foram realizados com base no estudo da API *Keras* e execução de alguns testes de treinamento e validação, com o objetivo de obter melhor qualidade no resultado da predição.

Para a camada de saída foi necessário apenas um neurônio, com a responsabilidade de informar o resultado da predição após toda a execução da aplicação.

Além da configuração da quantidade de neurônios por camada, também foram configuradas: a memória dos neurônios e a realimentação da informação para os neurônios, configurando, assim, a RNN como uma LSTM.

Treinamento da RNN LSTM

A etapa de treinamento é a parte da aplicação em que a LSTM “aprende” como deve responder aos dados, para então prever o valor futuro das *commodities*. A rede neural utiliza uma parte dos dados para um treinamento supervisionado, em que a base de dados é constituída por valores de entrada e de saída já conhecidos. Nesse processo a aplicação é treinada, ajustando os pesos das bias da LSTM, para que ela seja capaz de lidar com valores futuros.

A outra parte da base de dados é destinada a testes e validação, com o objetivo de averiguar o desempenho do treinamento realizado. Caso a variação seja aceitável, a rede neural começa a predição de valores futuros. Por outro lado, caso o erro de predição não seja adequado, a aplicação volta para a etapa de treinamento, para corrigir novamente os pesos das bias, diminuindo assim o erro do valor de saída.

Para avaliar se o erro de predição é aceitável ou não, é utilizada a métrica de desempenho MSE (*mean squared error* - erro quadrático médio), conforme Equação 1.

$$M = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (1)$$

M - Erro quadrático médio

n - Número de dados

Y_i - Valores observados

\hat{Y}_i - Valores previstos

O algoritmo Adam (*Adaptive Moment Estimation*) foi o escolhido para a realização do treinamento da RNN LSTM.

Alguns ajustes de hiper parâmetros se tornam necessários:

- O número de épocas, que é a quantidade de vezes que o treinamento analisará os dados. Neste trabalho, em todos os cenários de aplicação, esse hiper parâmetro foi ajustado em 150.
- O tamanho do lote, que é o número de treinamentos que são feitos antes de se atualizar os pesos das bias, foi configurado com o valor 16.
- A taxa de aprendizado foi ajustada em 0,05. Essa taxa específica o quanto os pesos das bias devem ser incrementados em cada etapa do treinamento.

IV. CENÁRIO DE APLICAÇÃO

O objetivo dessa aplicação é desenvolver um sistema de predição para o preço de *commodities* agrícolas, focando em três tipos de grãos, arroz, milho e soja para apoio de tomada de decisões focado na escolha do momento de venda otimizando os lucros. Sem um sistema preditivo automático a estimativa de preço futuro seria realizada por uma pessoa, seja por experiência prática, análise econômica e social ou por análise de gráficos de preço. A predição da aplicação deve estimar o preço em conjunto com um especialista, visando tornar a decisão mais precisa e acertada e não substituir a opinião especializada.

Os cenários avaliados para as três *commodities* são modelados por séries temporais oriundas de uma base de dados composta por mais de 4.000 amostras cada. Cada amostra representa o preço vigente da *commodity* naquele dia da série temporal.

Tradicionalmente, a base de dados é particionada em 70% para treinamento e 30% para teste e validação. Porém, devido à especificidade das séries temporais avaliadas neste

estudo, em que se tem um período com dados atípicos devido ao período da pandemia de COVID-19, esse processo de partição da base de dados foi adaptado. A solução proposta foi ordenar os dados em lotes de 10 amostras cada, e dentro de cada um desses lotes são selecionadas sete amostras aleatoriamente para treinamento, deixando o restante para validação. Esse processo de preparação dos dados para treinamento e validação é realizado respeitando a cronologia dos eventos na série temporal.

É preciso ressaltar também que cada uma das *commodities* avaliadas neste trabalho possui conjunto de dados com início em anos distintos:

- para o milho, a coleta de dados se inicia em 2004;
- para o arroz, o início se dá no ano de 2005;
- e para a soja em 2006.

A Figura 7 descreve o funcionamento sequencial da aplicação desenvolvida.

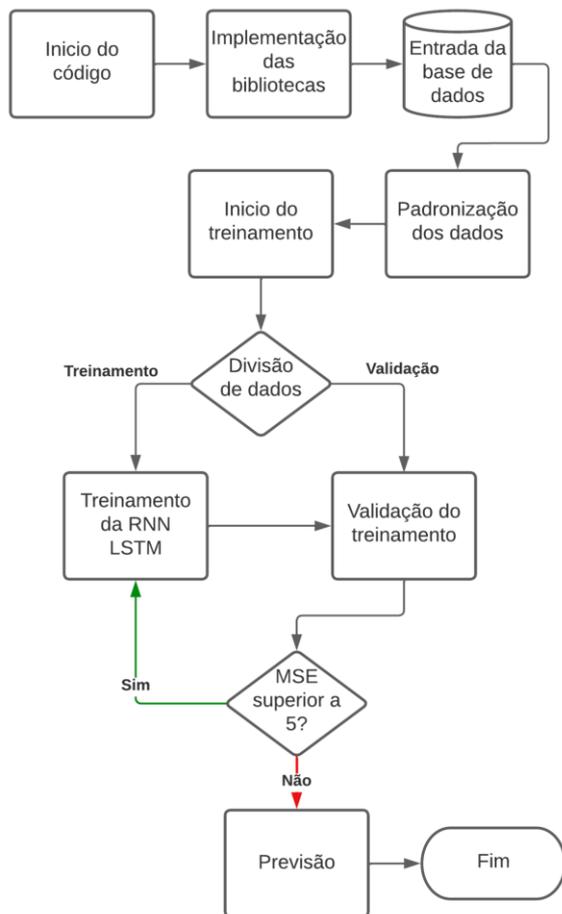


Fig. 7 - Fluxograma da aplicação (elaborada pelos autores).

Ao iniciar o programa desenvolvido para a aplicação, ele primeiro carrega as bibliotecas que auxiliam no desenvolvimento das tarefas da aplicação. Após isso é carregado os dados para o treinamento da rede neural, esses dados antes de serem utilizados no treinamento são padronizados.

Em seguida, a rede neural é devidamente treinada e a aplicação começa a prever valores. É avaliado o erro médio quadrático (MSE) e caso seja superior a cinco, a aplicação é treinada novamente. Se o erro médio quadrático (MSE) for

inferior a cinco, a aplicação fornece os valores previstos e é encerrada.

V. RESULTADOS E DISCUSSÕES

O estudo das *commodities* deve começar pela compreensão do comportamento do seu preço no mercado de acordo com a série temporal que a representa. O processo de predição da precificação de grãos no mercado de *commodities* deve ser precedido de uma análise exploratória da base de dados para o arroz, milho e soja.

Ainda analisando os dados das *commodities*, foi possível perceber que os preços apresentam tendência de crescimento a cada ano. No entanto, a partir da metade do ano de 2020 os preços começam a subir vertiginosamente. Este crescimento rápido muito provavelmente se deve a pandemia de Covid-19.

Outro fator relevante para a análise de custo no mercado de *commodities* é a variação cambial, principalmente com a mudança do dólar, que em momentos de subida é possível perceber o aumento do preço das três *commodities*.

Com os dados de entrada apresentados, pode ser realizada a predição assistida, que trata de utilizar dados de entrada dos quais se sabe o valor final e analisar o resultado e a assertividade da predição realizada pela rede neural LSTM, ajustada conforme cenário da seção anterior. Os melhores resultados do processo de predição para as três *commodities* podem ser conferidos nas Figuras 8, 9 e 10.

Com base na predição assistida das três *commodities*, é evidente que os valores previstos estão em consonância com os valores reais. A acurácia das predições pode ser avaliada por meio dos erros médios quadráticos (MSE) obtidos: 0,027 para o arroz, 0,038 para o milho e 0,094 para a soja. Tais resultados indicam que os ajustes realizados na rede LSTM resultaram em um desempenho superior para a *commodity* arroz.

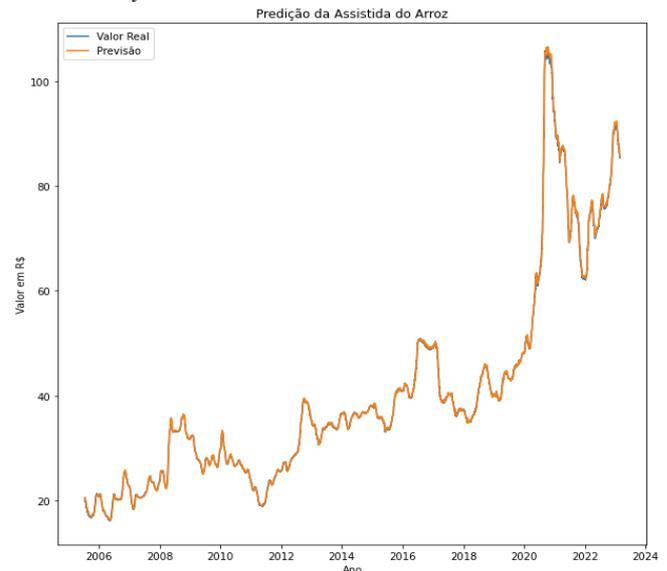


Fig. 8 – Predição assistida do arroz (elaborada pelos autores).

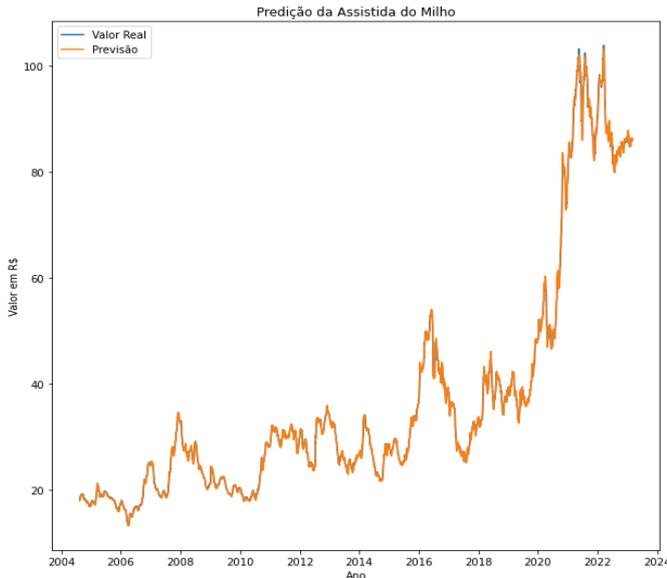


Fig. 9 – Predição assistida do milho (elaborada pelos autores).



Fig. 10 – Predição assistida da soja (elaborada pelos autores).

Além da predição assistida, cada um dos cenários mencionados anteriormente foi testado com a aplicação da rede LSTM para uma predição não assistida. Cada aplicação foi utilizada para prever preços futuros, ou seja, para aqueles dias em que se considera que ainda não há registros nos bancos de dados utilizados. Essas predições foram simuladas para um período de dez dias: de 01/03/2023 a 10/03/2023. Vale ressaltar que a base de dados não apresenta valores para fins de semana e feriados, portanto, não é possível realizar a comparação nos dias 04/03/2023 e 05/03/2023. Os resultados das predições, assim como os preços reais de mercado que foram praticados nesses dias, estão apresentados nas tabelas 1, 2 e 3 para o arroz, o milho e a soja, respectivamente.

Tabela 1 - Predição futura dos preços do arroz

Dia	Valor Real (R\$)	Valor Previsto (R\$)
01/03/23	84,80	85,69
02/03/23	85,10	85,83
03/03/23	85,18	86,02
06/03/23	85,31	86,82
07/03/23	85,20	87,13
08/03/23	85,07	87,46
09/03/23	85,29	87,80
10/03/23	85,53	88,15

Tabela 2 - Predição futura dos preços do milho

Dia	Valor Real (R\$)	Valor Previsto (R\$)
01/03/23	86,11	86,05
02/03/23	86,36	85,97
03/03/23	86,22	85,87
06/03/23	86,15	85,40
07/03/23	85,84	85,21
08/03/23	86,03	85,02
09/03/23	85,47	84,80
10/03/23	85,32	84,59

Tabela 3 - Predição futura dos preços da soja

Dia	Valor Real (R\$)	Valor Previsto (R\$)
01/03/23	168,75	170,24
02/03/23	169,23	169,84
03/03/23	169,72	169,47
06/03/23	169,35	168,40
07/03/23	168,21	168,09
08/03/23	167,76	167,78
09/03/23	167,24	167,47
10/03/23	167,83	167,18

Foi identificada uma variação máxima de R\$2,62 entre o valor real e a predição para a *commodity* arroz no décimo dia de predição. Além disso, foram calculados os erros médios quadráticos (MSE) exclusivamente para as predições listadas nas tabelas 1, 2 e 3, com os seguintes resultados: 3,37 para a predição do arroz; 0,40 para a predição do milho e 0,50 para a predição da soja.

É importante destacar que, embora o MSE ainda seja baixo nas situações de predição futura, os resultados revelam uma tendência de aumento nessa métrica à medida que se busca estimar os preços das três *commodities* para períodos mais distantes.

No caso da predição do preço das três *commodities*, a tendência é o aumento no valor e quanto mais distante o período de predição, maior o erro. Essa é uma característica da própria série temporal, tendo em vista o comportamento dos dados e o fato de que a RNN LSTM usa os dez últimos valores para prever o próximo valor futuro.

Dessa forma, para uma predição de 1 dia à frente serão utilizados como base 10 valores conhecidos, já para a predição 6 dias à frente 5 dos valores utilizados serão conhecidos e os outros 5 serão valores previstos, a partir do décimo primeiro dia, a predição será realizada apenas com valores estipulados pela própria LSTM, assim, o erro se acumula e tende a aumentar.

VI. CONCLUSÃO

Avanços significativos nas técnicas de inteligência artificial e na produção massiva de dados têm permitido o desenvolvimento de sistemas altamente precisos de predição em uma variedade de cenários, incluindo a predição de preços de *commodities*.

No caso específico dos preços de *commodities* agrícolas, diversos fatores influenciam seu valor, tais como índice pluviométrico, temperatura, impostos, custo de frete e condições de mercado.

A acurácia alcançada pelos sistemas de predição desenvolvidos neste trabalho, com MSE inferior a 1 para as três *commodities* avaliadas, é bastante satisfatória estando abaixo do MSE de cinco desejado. Isso confere confiabilidade à RNN LSTM utilizada para avaliar cenários em que as *commodities* são modeladas através de séries temporais.

Uma constatação relevante desse estudo é o comprometimento da acurácia conforme a predição se estende para datas futuras mais distantes. Nos cenários avaliados, esse fenômeno pode ser atribuído, principalmente, à escassez de dados disponíveis após as mudanças atípicas provocadas pela pandemia de Covid-19. O comportamento durante esse período pandêmico exerce uma influência significativa nos resultados futuros.

Com o intuito de aprimorar as predições futuras, uma possível abordagem seria avaliar a relevância de se incluir outras variáveis no processo de tomada de decisão, além de explorar ferramentas que possam auxiliar no tratamento de séries temporais altamente influenciadas por longos períodos com dados atípicos. Vislumbra-se que essa metodologia possa contribuir para uma melhor precisão e confiabilidade das predições de preços de *commodities*.

VIII. REFERÊNCIAS

- [1] E. Rich e K. Knight, Artificial Intelligence, New York, McGraw-Hill, 1994, pp. 3.
- [2] S. Russell e P. Norvig, Inteligência Artificial, Rio de Janeiro: Elsevier, 2013, pp 36.
- [3] H. Abdi, D.Valentin e B.Edelman, “Neural Networks”, Madhya Pradesh: Sage University, 1991.
- [4] C. M. Bishop, “Neural networks and their applications”, Birmingham: Aston University, 1994.
- [5] C. Moreira, Neurônio, Revista Ciência Elementar, V1(01):008, 2013.
- [6] A. C. Carvalho, Redes Neurais Artificiais [Online]. Disponível em: <https://sites.icmc.usp.br/andre/research/neural/>, acessado em: 28/11/2022.
- [7] I. N. Silva. Redes Neurais Artificiais [Powerpoint slides]. Disponível em: https://edisciplinas.usp.br/pluginfile.php/5240268/mod_resource/content/1/RNA_Aula02.pdf, acessado em: 28/11/2022.
- [8] DSA. Deep Learning Book [Online]. Cap. 10.
- [9] Serasa. O que são commodities e quais são os tipos? [Online]. Disponível em: <https://www.serasa.com.br/blog/commodities/>, acessado em 28/11/2022.
- [10] CNN Brasil. (2022). Brasil deve bater novo recorde de exportações com commodities em alta, dizem especialistas [Online]. Disponível em: <https://www.cnnbrasil.com.br/business/brasil-deve-bater-novo-recorde-de-exportacoes-com-commodities-em-alta-dizem-especialistas/>, acessado em 28/11/2022.
- [11] CNA Brasil. (2022). Exportações do agro somam US\$ 9,9 bilhões em dezembro de 2021 [Online]. Disponível em: <https://cnabrasil.org.br/noticias/exportacoes-do-agro-somam-us-9-9-bilhoes-em-dezembro-de-2021>, acessado em 28/11/2022.
- [12] CNN Brasil. (2022). Receita de exportações de soja até agosto supera total de 2021,diz associação [Online]. Disponível em: <https://www.cnnbrasil.com.br/business/receita-de-exportacoes-de-soja-ate-agosto-supera-total-de-2021-diz-associacao/>, acessado em 28/11/2022.
- [13] Canal Rural. (2022). Em recuperação, exportação de milho já supera 2021 [Online]. Disponível em: <https://www.canalrural.com.br/noticias/agricultura/milho/em-recuperacao-exportacao-de-milho-ja-supera-2021/>, acesso em: 28/11/2022.
- [14] Canal do boi. (2022) Brasil: exportações de arroz tem saldo positivo em 2021, diz Abiarroz [Online]. Disponível em: <https://sba1.com/noticias/noticia/17684/Brasil-exportacoes-de-arroz-tem-saldo-positivo-em-2021-diz-Abiarroz>, acesso em: 28/11/2022.
- [15] Pathmind. (2020). A Beginner’s Guide to LSTMs and Recurrent Neural Networks [Online]. Disponível em: <https://wiki.pathmind.com/lstm>, acesso em: 28/11/2022.
- [16] S. Hochreiter e J. Schmidhuber. (1997). Long Short-Term Memory, Massachusetts: MIT Press.
- [17] DSA. Deep Learning Book [Online]. Cap. 51.
- [18] Smart tec organic. Que é Deep Learning o Aprendizaje Profundo? [Online]. Disponível em: <http://ia.smartecorganic.com.co/deep-learning/>, acesso em: 30/11/2022.
- [19] P. P. Shinde e S. Shah, A Review of Machine Learning and Deep Learning Applications, 2018.
- [20] R. S. Ehlers Análise de Séries Temporais, Paraná: Universidade Federal do Paraná, 2003, pp.1.
- [21] CEPEA. (2022). Preços Agropecuários [Online]. Disponível em: <https://www.cepea.esalq.usp.br/br/busca.aspx?busca=Soja>, acesso em 30/11/2022.



PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
GABINETE DO REITOR
Av. Universitária, 1089 • Setor Universitário
Caixa Postal 98 • CEP 74805-010
Goiânia • Goiás • Brasil
Fone: (62) 3244-1000
www.pucgoias.edu.br • reitoria@pucgoias.edu.br

RESOLUÇÃO nº 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O(A) estudante Gabriela de Matos César do Curso de Engenharia de Controle e Automação, matrícula 2019.1.0118.0007-0, telefone: (62)985922348 e-mail gabriela.cezar.meca@gmail.com, na qualidade de titular dos direitos autorais, em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor), autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho de Conclusão de Curso intitulado Análise Preditiva com Redes Neurais Artificiais para Precificação de Grãos no Mercado de Commodities, gratuitamente, sem ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF); Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros, específicos da área; para fins de leitura e/ou impressão pela internet, a título de divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 06 de março de 2023.

Assinatura do autor: *Gabriela de Matos César*

Nome completo do autor: Gabriela de Matos César

Assinatura do professor-orientador: *Marcos A. de Sousa*

Nome completo do professor-orientador: Marcos Antônio de Sousa



PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
GABINETE DO REITOR
Av. Universitária, 1089 • Setor Universitário
Caixa Postal 98 • CEP 74805-010
Goiânia • Goiás • Brasil
Fone: (62) 3244-1000
www.pucgoias.edu.br • reitoria@pucgoias.edu.br

RESOLUÇÃO nº 038/2020 – CEPE

ANEXO I

APÊNDICE ao TCC

Termo de autorização de publicação de produção acadêmica

O(A) estudante SILVIO VIDAL DE MIRANDA JUNIOR do Curso de ENGENHARIA DE CONTROLE E AUTOMAÇÃO, matrícula 2018.1.0118.0069-2, telefone: (62)993987510 e-mail silviovidaleng@gmail.com, na qualidade de titular dos direitos autorais, em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor), autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho de Conclusão de Curso intitulado Análise Preditiva com Redes Neurais Artificiais para Precificação de Grãos no Mercado de Commodities, gratuitamente, sem ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF); Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros, específicos da área; para fins de leitura e/ou impressão pela internet, a título de divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 06 de março de 2023.

Assinatura do autor: *Silvio Vidal de M. Junior*

Nome completo do autor: Silvio Vidal de Miranda Junior

Assinatura do professor-orientador: *Marcos A. de Sousa*

Nome completo do professor-orientador: Marcos Antônio de Sousa