



TREINAMENTO DE MODELO PARA PREVISÃO DO COMPORTAMENTO DA TEMPERATURA AMBIENTE ATRAVÉS DE REDES NEURAS ARTIFICIAIS ¹

João Paulo Carau de Oliveira² Olívia Sobreira Gomes³ Manuel Osório Binelo⁴ Márcia de Fátima Brondani Binelo⁵

¹ Trabalho final submetido à disciplina Modelagem Matemática.

² Estudante do Programa de Pós-Graduação em Modelagem Matemática e Computacional, UNIJUÍ .

³ Estudante do Programa de Pós-Graduação em Modelagem Matemática e Computacional, UNIJUÍ .

⁴ Professor do Programa de Pós-Graduação em Modelagem Matemática e Computacional, UNIJUÍ .

⁵ Professor do Programa de Pós-Graduação em Modelagem Matemática e Computacional, UNIJUÍ .

RESUMO

A necessidade de um armazenamento eficiente é um dos principais pilares na produção de grãos. Sendo o uso de novas tecnologias, tanto para hardware (sensores e equipamentos) atrelados a métodos e algoritmos já bem estabelecidos, podem ter um impacto positivo quando aplicados aos sistemas de controle de aeração de grãos. O presente trabalho tem como objetivo treinar um modelo baseado em Redes Neurais Artificiais que realize a previsão do comportamento da temperatura ambiente, que em um contexto de aeração de grãos melhore os sistemas de monitoramento. Para isto foi utilizado uma biblioteca de redes neurais chamada neurolab implementada na linguagem python. O dados usados para o treinamento foram obtidos do site do INMET de um sensor localizado na cidade de Santa Maria – RS, que registrou a temperatura do ar durante todo o ano de 2023. A rede implementada apresentou um erro de treinamento igual a 0,004479. Também foi calculado o Mean Absolute Error (MAE) para o treino e para o teste, onde ficou verificado que o erro de treino foi de 0,364276 e erro de teste foi de 0,489469. Logo, foi possível observar que a temperatura prevista por essa rede pode apresentar um erro absoluto de 0,489469 °C acima ou abaixo da temperatura real.

Palavras-chave: Comportamento. Temperatura. Predição. Redes Neurais Artificiais.

ABSTRACT

The need for efficient storage is one of the main pillars in grain production. The use of new technologies, both for hardware (sensors and equipment) linked to already well-established methods and algorithms, can have a positive impact when applied to grain aeration control systems. The present work aims to train a model based on Artificial Neural Networks that predicts the behavior of ambient temperature, which in a context of grain aeration improves monitoring systems. For this, a neural network library called neurolab implemented in the Python language was used. The data we used for training were obtained from the INMET website from a sensor located in the city of Santa Maria – RS, which recorded the air temperature throughout the year 2023. The implemented network presented a training error equal to 0.004479 . The Mean Absolute Error (MAE) was also calculated for training and testing, where it was found that the training error was 0.364276 and the testing error was 0.489469. Therefore, it was possible to observe that the temperature predicted by this network may present an absolute error of 0.489469 °C above or below the actual temperature.

Keywords: Behavior. Temperature. Prediction. Artificial neural networks.



INTRODUÇÃO

A humanidade passou por três grandes revoluções responsáveis pela sociedade moderna como é conhecida hoje, são elas: revolução cognitiva, revolução agrícola e revolução industrial (HARARI, 2011). Entre elas, em algum momento da revolução agrícola, a produção de mantimentos adquiriu proporções superavitárias, e pela primeira vez a humanidade teria sobra de alimentos. Tal fato mudou o paradigma acerca de como o ser humano lidava com os alimentos, antes havia pouca preocupação em armazenagem de alimentos, com esse superávit, os seres humanos passaram a se preocupar com outras questões envolvendo os alimentos produzidos por meio da agricultura. Com isso, culturas relacionadas a produção de grãos teriam de lidar com a produção, o transporte, o beneficiamento, a armazenagem, a comercialização e o consumo desses grãos, e estão envolvidos numa cadeia de atividades vitais às pessoas, às famílias e às nações, motivo pelo qual a armazenagem agrícola é uma atividade das mais antigas e importantes (Faoro apud Weber, 2018).

Diante disso, a infraestrutura e os recursos que existem nessas cidades vão se tornando insuficientes para acomodar o crescimento dessa população. No Brasil, a armazenagem de grãos é realizada em unidades mantidas por cooperativas de agricultores ou em empresas especializadas nesse negócio. O déficit de capacidade de armazenagem no Brasil é um problema antigo, e para compensar essa deficiência são construídos e explorados grandes armazéns graneleiros horizontais de alta capacidade. O armazenamento é feito através do depósito dos grãos em silos verticais ou horizontais. Uma vez armazenado, os grãos se acumulam e tornam-se o que na literatura é chamada de uma massa de grãos, sendo que o controle de temperatura desses grãos é realizado através de enormes aerogeradores, esses equipamentos consomem muita energia elétrica.

A otimização e gerenciamento de recursos tem um papel importante na estratégia ASG do Brasil para o século XXI, logo tornar cidades mais inteligentes, gerenciando e otimizando seus recursos de forma sustentável irá promover uma melhor qualidade de vida para sua população (Caragliu et al. 2011; Dameri 2013). As tecnologias de informação e comunicação (TIC) terão papel fundamental em auxiliar nesse processo possibilitando a coleta e análise de grandes volumes de informações geradas das mais diversas fontes de dados da própria cidade como os sistemas de trânsito, redes de sensores e dispositivos utilizados por seus habitantes



(Harrison et al. 2010; Washbourn et al. 2009). No entanto, o manejo desses dados de maneira eficiente será um trabalho complexo.

Uma das dificuldades na implementação de uma cidade inteligente, é que os sistemas adotados são utilizados para a resolver uma demanda específica com pouca reutilização de software e falta de comunicação entres os demais sistemas. Tem a Internet das Coisas (*Internet of Things* ou IoT) como uma das principais tecnologias que solucionam esse problema de integração e auxilia na construção da infraestrutura de uma cidade inteligente. A IoT possibilita também a conexão de diversos dispositivos presentes na cidade, como sistemas de iluminação pública, sistemas de controle de trânsito, câmeras de segurança, sensores de qualidade etc., à rede Internet (Coetzze and Eksteen 2011). O termo “Coisas” pode ser definido como participantes ativos de uma rede que interagem e comunicam-se com outros componentes da rede e com o ambiente (Sundmaeker et al. 2010). A Internet das Coisas interliga o mundo digital ao físico incrementando soluções e inteligência para a internet eliminando a intervenção direta do fator humano.

No ramo da agricultura, os sistemas de IoT também apresentam aplicações relevantes, sendo crucial na superação do desafio da produção de alimentos no século 21. Além disso, mudanças climáticas causadas pelo homem podem causar condições nas quais o desenvolvimento de novas culturas não seja possível, bem como o processo de urbanização diminui a mão de obra nas áreas envolvidas na produção de alimentos, aumenta os custos e diminui a capacidade produtiva do setor (Satterthwaite, 2009). Sendo assim, A Agricultura Inteligente (Smart Farming) é uma nova vertente da gestão agrícola, cujo papel é empregar novas técnicas e tecnologias nas várias etapas da produção agrícola, como monitoramento de plantações, manejo de solo, controle de pragas, controle de entregas (Bhagat et al. 2019), possibilitando solucionar os desafios da crescente demanda por produção de alimentos (Walter et al. 2017).

A Agricultura Inteligente pode usar diversos tipos de dispositivos interconectados (IoT) para coletar dados (temperatura, luminosidade, umidade, pressão, etc) e estabelecer redes de comunicação para encaminhar e receber informações (Pivoto et al. 2018). O uso dos dados recebidos ajuda a impulsionar a produtividade e minimizar as perdas, contribuindo para que as ações cabíveis sejam realizadas no momento, quantidade e local exatos (Leonard, 2016). Do ponto de vista sustentável, espera-se que fazendas inteligentes (Smart farm) sejam capazes de



otimizar a produção de alimentos, promovendo uma melhor aplicação de nutrientes ao solo, reduzindo a quantidade de agrotóxicos e o consumo de água nos processos de irrigação (Kite-Powell, 2018).

Dessa forma, a implementação de uma Agricultura Inteligente vai ao encontro aos interesses estabelecidos na Agenda 2030, uma iniciativa da Organização das Nações Unidas (ONU), ratificada em 2015 por 193 países, que propõe um pacto global em prol do desenvolvimento sustentável (ONU, 2015). Essa agenda é composta por 17 Objetivos do Desenvolvimento Sustentável (ODS), dos quais o ODS 2 (Fome Zero e Agricultura Sustentável) e o ODS 12 (Consumo e Produção Responsáveis) têm relação direta com o que foi discutido até aqui. A Agenda tem como intuito principal promover o desenvolvimento humano e o atendimento às necessidades básicas do cidadão através de um processo econômico, político e social que respeite o ambiente e a sustentabilidade (ONU, 2015).

O Objetivo deste trabalho concentra-se em realizar uma previsão do comportamento da temperatura ambiente levando em consideração que os sistemas de monitoramento são passíveis de falhas. Para isto, foi utilizado um banco de dados disponibilizado pelo Instituto Nacional de Meteorologia (INMET), com dados de temperatura para a cidade de Santa Maria-RS durante todo o ano de 2023. As medições da temperatura do ar foram feitas em 2023, com intervalos de 60 minutos durante todo o ano. A partir do banco de dados foi implementado um modelo baseado em Redes Neurais Artificiais (RNAs) em linguagem Python através do serviço de nuvem Google Colab (*Google Colaboratory*).

REDES NEURAIAS ARTIFICIAIS

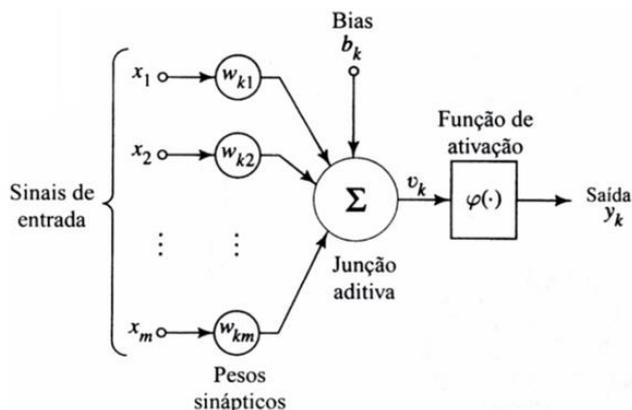
As Redes Neurais Artificiais são modelos computacionais baseados no funcionamento do cérebro humano, capazes de “aprender” e correlacionar grandes volumes de dados através de experimentos e simulações (Asteris; Mokos, 2020). De um modo geral, o objetivo é introduzir dados que representam entradas e saídas, fazendo com que a rede aprenda as relações existentes entre os dois. Esse processo é chamado de treinamento ou aprendizado e faz com que as RNAs proporcionem tratamento adequado para solucionar problemas complexos (Silva, 2015).

De acordo com Haykin (2001), um neurônio artificial configura uma unidade de processamento de informações essencial para execução de uma rede neural, que por sua vez é



constituída por três elementos fundamentais: um conjunto pesos sinápticos, um somador (também chamado de junção aditiva) e uma função de ativação. Esses elementos podem ser vistos no modelo de neurônio artificial apresentado na Figura 1.

Figura 1 - Modelo de Neurônio artificial.



Fonte: Haykin (2001).

Os sinais de entradas são valores numéricos que são multiplicados pelos pesos sinápticos e somados na junção aditiva, que pode ser influenciada por um sinal fixo responsável em melhorar a capacidade de processamento do neurônio (Bias). A soma resultante passa pela função de ativação que determinará o sinal de saída do neurônio, gerando estímulo para o neurônio seguinte. O modelo acima é descrito matematicamente da seguinte forma (Haykin, 2001):

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \quad (1)$$

$$y_k = \varphi(u_k + b_k). \quad (2)$$

Onde: x_1, x_2, \dots, x_m são as entradas, $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos, u_k é a saída do combinador linear, b_k é o Bias, $\varphi(.)$ é função de ativação e por fim, y_k é a saída do neurônio. A entrada da função de ativação pode aumentar ou diminuir de acordo com o Bias, sendo assim é aplicado uma transformação na saída u_k chamada de potencial de ativação v_k :

$$v_k = u_k + b_k. \quad (3)$$

Normalmente, uma rede neural contém uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (SHIH et al., 2015). A camada de entrada recebe as informações do ambiente externo. As camadas ocultas são formadas por neurônios cuja função é extrair características presentes nos dados fornecidos. A camada de saída, também é composta por neurônios e tem como função gerar os resultados da rede. Vale salientar que essa saída é



proveniente do processamento realizado pelos neurônios das camadas anteriores (Silva; Spatti; Flauzino, 2010). Dessa forma, as camadas são interligadas aos neurônios que juntos formam um sistema de processamento, onde cada um deles corresponde a uma unidade desse sistema capaz de gerar saídas a partir das entradas, baseado em uma função de ativação (Shih et al., 2015).

A função de ativação de uma RNA faz a ligação entre os pesos de um neurônio às entradas, e sua escolha pode trazer influências significativas no desempenho e complexidade da rede (Asteris et al., 2016). Geralmente é realizada a normalização dos dados de entrada de modo que os valores fiquem dentro dos limites da função de ativação. Segundo Silva et al., 2017 a normalização proporciona uma melhor precisão numérica diante das operações que serão realizadas durante o processamento da rede.

Haykin (2001) descreve a função de ativação como uma função restritiva, uma vez que ela limita o intervalo de amplitude do sinal de saída a um valor finito. Uma vez normalizado, esse intervalo em descrito como unitário e fechado variando entre $[0, 1]$ ou $[-1, 1]$. Vale ressaltar que, uma função matemática pode ser utilizada como função de ativação desde que ela seja contínua, ou seja, cujas derivadas de primeira existam e que sejam conhecidas em todos os pontos do seu domínio. As quatro funções principais são: sigmóide logística, tangente, hiperbólica e linear (Da Silva; Spatti; Flauzino, 2016; Haykin, 2001).

A forma como os neurônios se conecta entre si recebe o nome de arquitetura da rede (Fausett, 1994). As arquiteturas fundamentais de rede são subdivididas em: feedforward de 1 camada, feedforward multicamadas e recorrentes ou realimentadas (Furtado, 2019).

Em termos gerais, a rede neural *feedforward* de 1 camada é a forma mais simples dentre as arquiteturas, pois uma única camada de entrada é projetada diretamente a uma única camada saída, mas não vice-versa. Geralmente utilizada para resolver problemas lineares e classificar padrões (Haykin, 2001). Já a rede *feedforward* multicamadas, apresenta uma ou mais camadas ocultas em sua estrutura e recebe esse nome pois corresponde a uma parte do sistema neural que não é visualizado na entrada ou na saída da RNA (Haykin, 2001). É fortemente utilizada para resolver problemas relacionados a processamento de informações, previsões do tempo, processamento de imagens, dentre outros (Shah & Ghazali, 2018).

E por fim, existem as redes do tipo recorrentes. Um modelo mais recente e sua principal particularidade é a retroalimentação, ou seja, em cada etapa de processamento vai gerando



cópias de si mesma. Pode consistir em uma única camada, onde cada neurônio retorna ao seu sinal de saída em relação às entradas de todos os outros neurônios. Característica essa que a coloca como a rede mais propícia para resolver problemas variantes no tempo, como por exemplo séries temporais (Haykin, 2001).

METODOLOGIA

O presente trabalho partiu de um levantamento bibliográfico acerca dos temas Cidades Inteligentes e IoT, Smart Farming, influências da mudança climática nos processos de armazenagem de grãos e modelos baseados em Redes Neurais Artificiais. Dentre as plataformas de busca utilizadas pode-se citar a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), National Center for Biotechnology Information (NCBI), Researchgate, Biblioteca SciELO e Google Academy. Ao longo da revisão foram selecionados os trabalhos que apresentaram mais relevância para a fundamentação desse estudo.

Para a próxima etapa foi obtido os dados de temperatura do ar de uma estação de meteorologia localizada na cidade de Santa Maria RS e retirados do site do Instituto Nacional de Meteorologia (INMET), com dados de temperatura do ano de 2023. As medições foram feitas a cada 60 minutos ao longo de trezentos e sessenta e cinco dias, onde foi apresentado a temperatura média, máxima e mínima coletada dentro de cada intervalo de medição.

Antes de chegar na etapa de implementação, foi realizada a seguinte contextualização: supondo que o sensor da estação meteorológica tenha sofrido uma pane e ficado inoperante, qual será a próxima temperatura levando em consideração as 24 temperaturas medidas anteriormente? Ou seja, levando em consideração as últimas 2 horas de medição, qual será a temperatura daqui a 5 minutos? Como as medições são feitas em intervalo de 5 minutos, teremos 12 medições em 1 hora (60 minutos), totalizando assim 24 dados em 2 horas.

Na próxima etapa foi realizado o tratamento na planilha de dados. Os dados recebidos estavam organizados em uma planilha de Excel que apresentavam informações textuais bem como outros dados além das medições de temperatura do ar, como por exemplo: horário, umidade relativa, temperatura do solo, vento, pressão atmosférica, precipitação e temperatura do sensor. Após o tratamento, foram considerados apenas os dados relativos aos dias, horários e temperatura média do ar de cada medição.



O passo inicial para o desenvolvimento da RNA foi a importação do conjunto de dados para a área de trabalho (Workspace) do Google Colab. Os dados foram importados através da biblioteca Pandas, criada para a linguagem Python para manipulação e análise de dados. O uso do Pandas permitiu que os dados fossem filtrados de modo que apenas o horário e a temperatura média da planilha fossem considerados. Em seguida, os dados foram convertidos em uma matriz (8760 x 2), através da biblioteca Numpy, com a primeira coluna contendo os horários e a segunda coluna contendo as temperaturas médias. Por defeito no sensor ou outro motivo, alguns horários não tiveram temperatura registrada, então utilizamos interpolação linear através de função interpolate da biblioteca Scipy do python. Em seguida os dados foram normalizados para valores entre 0 e 1.

Dado que o objetivo é treinar uma rede que seja capaz de prever com confiabilidade a temperatura dos próximos 5 minutos, definiu-se como entradas da rede o horário que representa o momento em que o sensor fica inoperante, vale ressaltar que esse horário é selecionado aleatoriamente, bem como as 24 temperaturas anteriores a ele, e como saída a temperatura do horário que se pretende prever. Os horários das 24 temperaturas anteriores foram desconsiderados pois ao fornecê-los como entradas, eles seriam informações redundantes para a rede uma vez que são correlacionados diretamente com o horário a ser sorteado. Dessa maneira, a rede terá 25 entradas que podem ser generalizadas de acordo com a tabela abaixo.

Tabela 1- Generalização do número de entradas da RNA

| Intervalo para previsão | Medições por hora | Saída | Total de Entradas |
|-------------------------|-------------------|-------|-------------------|
| 1h | 12 | 1 | 13 |
| 2h | 24 | 1 | 25 |
| 3h | 36 | 1 | 37 |
| ⋮ | ⋮ | ⋮ | ⋮ |
| n | 12 x n | 1 | 12n + 1 |

Fonte: Autoria própria.

Definidas as entradas da rede, partiu-se para a separação dos dados para o treinamento e para o teste. Foram separados trezentos dados para treino e 20 dados para teste. Todavia, para fins de explicação, esses trezentos dados não correspondem às trezentas linhas da matriz, mas à trezentos pontos onde serão selecionadas as temperaturas para trás.



Finalizado todo pré-processamento dos dados, seguiu-se para a criação da RNA propriamente dita. Para isto, foi utilizada a biblioteca de algoritmos básicos de RNAs para Python, Neurolab. A arquitetura da rede selecionada foi do tipo *Feed Forward Multilayer Perceptron*, cujo algoritmo de treinamento usa a função (newff) e apresenta uma ou mais camadas. Para este trabalho optou-se por duas camadas - uma camada oculta (*Hidden Layer*) e uma camada de saída (*Output Layer*). O número de camadas não foi alterado.

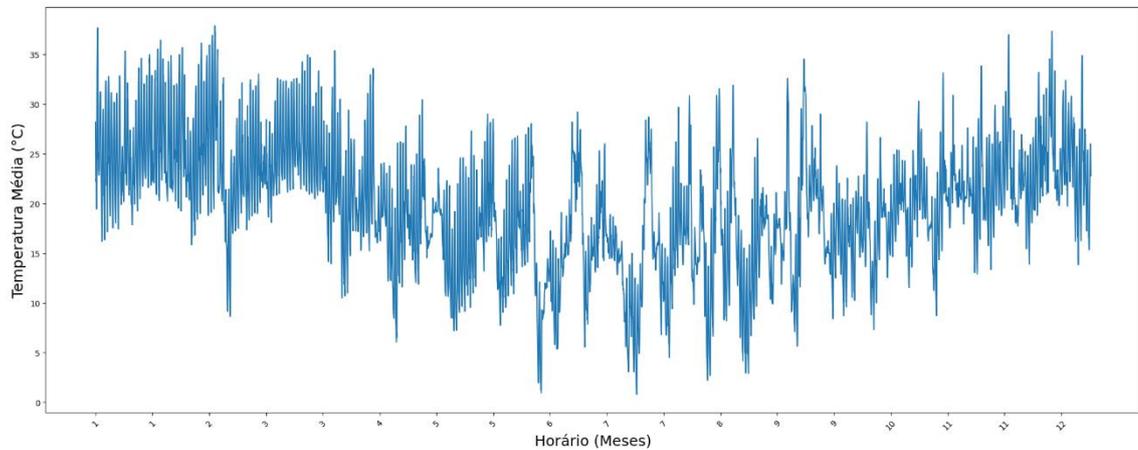
Após todos os parâmetros ajustados e a rede já treinada, os dados foram desnormalizados retornando a sua escala original e dessa forma o erro dar-se-á em graus celsius. Por fim, seguiu-se para a análise de desempenho usando Soma de Quadrados do Erro (Sum Squared Error - SSE) e Erro Médio Absoluto (Mean Absolute Error - MAE) tanto para o treinamento quanto para o teste. Onde a Soma de Quadrados do Erro mede a variabilidade do erro. Quanto mais baixo os valores, melhores são os resultados. E o Erro Médio Absoluto mede a média da diferença entre o valor real e o valor predito. Quanto mais baixo os valores, mais o valor predito aproxima-se do valor real.

RESULTADOS E DISCUSSÃO

O banco de dados utilizado para o desenvolvimento da RNA é extenso, dessa forma optou-se pela sua visualização gráfica apresentada na Figura 1. As temperaturas médias observadas por 1 ano variam entre 1,1 °C a 39 °C, e no mesmo dia variam vários graus para cima e para baixo. Em todos os dias nota-se que nas primeiras medições a temperatura média não sofrem oscilações expressivas seguindo relativamente estabilizada nas primeiras horas do dia. Ao longo dos meses, após um certo horário variando conforme o período do ano, a temperatura média começa a subir atingindo sua máxima por volta entre 13 e 16 horas. A partir desse horário a temperatura média começa a cair, quando então por volta das 20 até as 22 horas ela novamente segue relativamente estabilizada, sendo que das 0 horas do dia seguinte em diante a temperatura segue em queda até o final das medições. Diante disso, pode-se dizer que as maiores variações de temperatura do ar ocorreram das 0 horas da manhã até as 17 horas da tarde, e logo em seguida começando a cair novamente e recomeçando o ciclo novamente. Também foi observado que nos meses do meio do ano é onde ocorrem as menores temperaturas entre todas as medições.



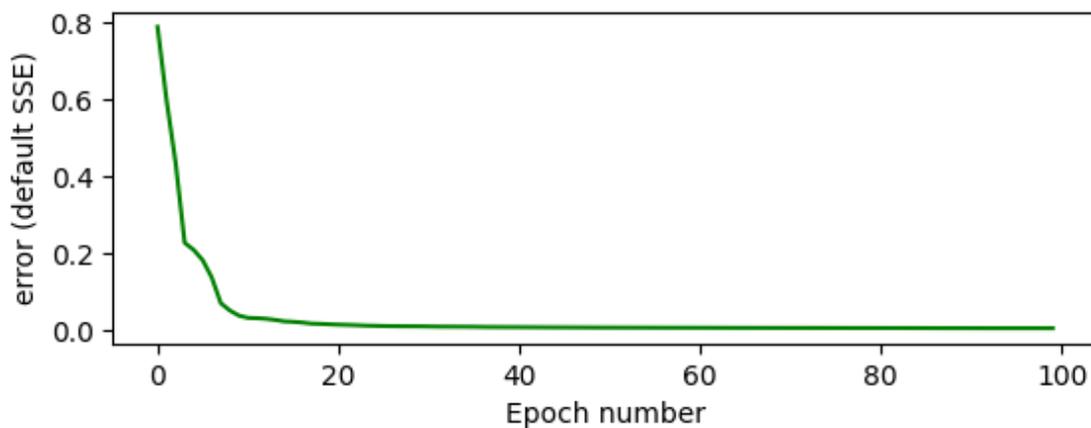
Figura 1 - Gráfico do comportamento da temperatura média ao longo de 30 dias



Fonte: Autoria própria

A partir do banco de dados a rede foi treinada com o número de neurônios na camada escondida igual ao tamanho da entrada (25 neurônios), 1000 épocas de treinamento e objetivo igual a 0,0001, esses valores não foram alterados. A Figura 2 mostra o gráfico do desempenho da rede, cujo Erro observado foi igual a 0.004479 (SSE = 0,004479).

Figura 2 - Desempenho da Rede Neural



Fonte: Autoria própria.

É possível observar que o erro de treinamento da RNA converge rapidamente seguindo com estabilidade próxima de zero até a execução completa do número de épocas estabelecidas.

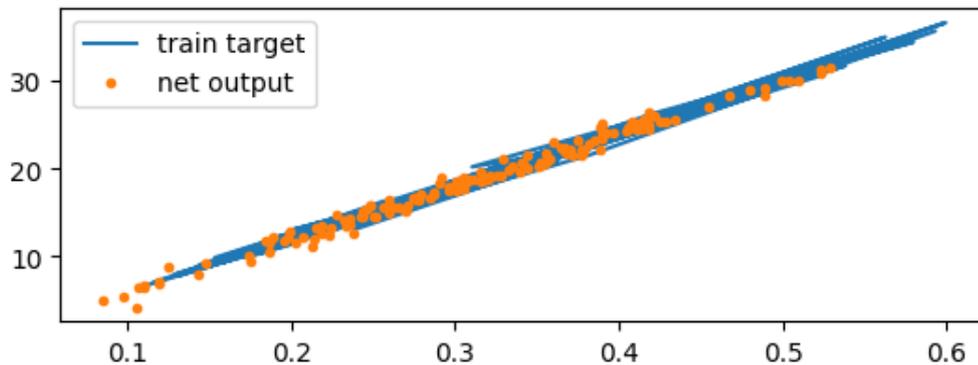
Também analisamos o desempenho a partir do Mean Absolute Error tanto para os dados de treino como para os dados de teste. O Mean Absolute Error do treino foi de 0.36428 (MAE = 0,36428) e do teste foi de 0.48947 (MAE = 0,48947). Portanto os valores próximos indicam



que o resultado obtido no teste se aproxima de forma significativa dos resultados obtidos no treino, dessa forma pode-se afirmar que temperatura dos próximos 60 minutos predita por esta rede terá um erro de 0.48947 °C abaixo ou acima da temperatura real.

A fim de visualizar a performance da rede foi plotado o gráfico (FIGURA 3) que mostra os valores de saída obtidos pela rede (net output) e os valores alvos (target).

Figura 3 - Simulação da Rede Neural



Fonte: Autoria própria.

O comportamento visto no gráfico acima indica que existe uma relação importante de proximidade entre os valores de saída da rede e os alvos.

CONSIDERAÇÕES FINAIS

Levando em consideração o objetivo estabelecido para este trabalho, foi possível treinar uma Rede Neural que fosse capaz de prever com pouca margem de erro (0,48 °C) a temperatura média dos próximos 60 minutos tendo como base as 24 temperaturas anteriores selecionadas a partir do banco de dados utilizado.

Mesmo sendo uma predição aparentemente simples de se realizar, pois as temperaturas médias observadas a cada 60 minutos apresentam variações bem superiores a 0,5° C, caso essa variabilidade não seja ruído nos dados entende-se que é uma variação causada pela ação do vento e por ser um fator caótico não tem como a rede prever.

Portanto como os sistemas de monitoramento são propensos a falhas, buscar alternativas inteligentes que deem continuidade ao trabalho desses sistemas é de grande valia, uma vez que o controle da temperatura em silos é de extrema importância, pois temperaturas acima de 42°C causam a deterioração dos grãos (Silva, 1998), dentre outros problemas.



Para continuidade deste trabalho, pretende-se estabelecer hipóteses mais complexas e modelos mais robustos, os quais serão utilizados para realizar um estudo mais aprofundado acerca do aprimoramento dos sistemas de controle de temperatura em grãos armazenados.

REFERÊNCIAS BIBLIOGRÁFICAS

ASTERIS, P.; MOKOS, V. **Concrete compressive strength using artificial neural networks**. Neural Computing and Applications, 08 2020. Citado nas páginas 18, 37 e 43.

BHAGAT, M., KUMAR, D., KUMAR, D. **Role of Internet of Things (IoT) in Smart Farming: A Brief Survey**; Proceedings of the IEEE 2019 Devices for Integrated Circuit (DevIC); Kalyani, India. 23–24 March 2019; pp. 141–145.

CARAGLIU, A., DEL BO, C., AND NIJKAMP, P. (2011). **Smart cities in europe**. Journal of urban technology, 18(2):65–82.

COETZEE, L., EKSTEEN, J. (2011). **The internet of things – promise for the future? An introduction**. In IST-Africa Conference Proceedings, 2011, pages 1–9.

COLLINS, D.A. **A review on the factors affecting mite growth in stored grain commodities**. Exp App Acarol 56:191–208

DAMERI, R. P. (2013). **Searching for smart city definition: a comprehensive proposal**. International Journal of Computers & Technology, 11(5):2544–2551.

FAORO, VANESSA, Tese: **Modelagem matemática e otimização do fluxo de ar em armazéns graneleiros**. – Ijuí-RN, 2018.

FAUSETT, L. **Fundamentals of Neural Networks - Architectures, Algorithms, and Applications**. [S.l.: s.n.], 1994. v. 1. Citado na página 39.

FURTADO, M. I. V. **Redes neurais artificiais: uma abordagem para sala de aula**. [S.l.]:Atena Editora, 2019. v. 1. Citado nas páginas 39, 40, 41 e 42.

GUBBI, J., BUYYA, R., MARUSIC, S., PALANISWAMI, M. (2013). **Internet of things (iot): A vision, architectural elements, and future directions**. Future Generation Computer Systems, 29(7):1645–1660.

HARARI, YUVAL NOAH, **Sapiens: Uma breve história da humanidade**. – Campina Grande-PB, Companhia das Letras, São Paulo-SP, 2011.

HAYKIN, S. **Redes Neurais Princípios e Prática**. 2. ed. [S.l.]: Bookman, 2001. v. 1. Citado nas páginas 37, 38, 40 e 42.

HARRISON, C. et al. (2010). **Foundations for smarter cities**. IBM Journal of Research and Development, 54(4):1–16.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA . Censo Brasileiro de 2022. Rio de Janeiro: IBGE, 2022



KITE-POWELL J. **Why Precision Agriculture Will Change How Food Is Produced.**

Acessado em jul de 2023. Disponível em:

<https://www.forbes.com/sites/jenniferhicks/2018/04/30/why-precision-agriculture-will-change-how-food-is-produced/#1aa438ec6c65>

LEONARD E.C. **Encyclopedia of Food Grains.** Volume 4. Elsevier; Amsterdam, The Netherlands: 2016. Precision Agriculture; pp. 162–167.

MOSES, J. A, JAVAS, D. S., Alagusundaram, K. **Climate Change and its Implications on Stored Food Grains.** National Academy of Agricultural Sciences, v. 8, p. 480–483, 2015. Citado na página 7, 8 e 9.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS. **Transformando o nosso mundo: a agenda 2030 para o desenvolvimento sustentável.** Resolução A/RES/70/1 [internet]. Nova Iorque: UN; 2015. [acesso em 2023 jul 15]. Disponível em: <https://nacoesunidas.org/wp-content/uploads/2015/10/agenda2030-pt-br.pdf>

PIVOTO, D. et al. **Scientific development of smart farming technologies and their application in Brazil.** Inf. Process. Agric. 2018;5:21–32 doi: 10.1016/j.inpa.2017.12.002.

SATTERTHWAITE, D. **The implications of population growth and urbanization for climate change.** Environ. Urban. 2009;21:545–567. doi: 10.1177/0956247809344361.

SILVA, W. R. 1998. **Seed Performance After Exposure to High Temperatures.** Scientia Agricola, 55, 102-109.

SILVA, I.; SPATTI, D.; FLAUZINO, R.; LIBONI, L. B.; ALVES, S. R. **Artificial neural network architectures and training processes.** In: . [S.l.: s.n.], 2017. p. 21–28. Citado nas páginas 37, 41 e 42.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas.** [S.l.]: Artliber Editora, 2010. v. 1. Citado nas páginas 39, 40 e 41.

SHAH, H., GHAZALI, R., NAWI, N.M. **Global artificial bee colony algorithm for boolean function classification.** In: Asian Conference on Intelligent Information and Database Systems, pp. 12–20. Springer, Berlin, Heidelberg (2013).

SHIH, Y.-F.; WANG, Y.-R.; WEI, S.-S.; CHEN, C.-W. **Improving non-destructive test results using artificial neural networks.** International Journal of Machine Learning and Computing, v. 5, p. 480–483, 12 2015. Citado na página 39.

SUNDMAEKER, H., GUILLEMIN, P., FRIESS, P., AND WOELFFLÉ, S. (2010). **Vision and challenges for realising the internet of things.**

UNITED NATIONS (2009). Urban and rural areas 2009.

WALTER, A., FINGER, R., HUBER, R., BUCHMANN N. **Opinion: Smart farming is key to developing sustainable agriculture.** Proc. Natl. Acad. Sci. USA. 2017;114:6148–6150. doi: 10.1073/pnas.1707462114.

