

Predição de Temperatura Ambiente por meio de Rede Neural Artificial Aplicada à Sistemas de Aeração de Grãos

Olívia S. Gomes¹, Manuel O. Binelo², Márcia F. B. Binelo³, João P. C. Oliveira⁴
UNIJUI, Ijuí, RS

Resumo. Um sistema de aeração eficaz é um fator determinante para um armazenamento de grãos seguro e duradouro. Neste trabalho, buscou-se realizar a predição da temperatura ambiente de modo melhorar a eficiência de sistemas de aeração. Com base em dados reais de temperatura, foi utilizado um modelo de rede feedforward multicamadas e um modelo de rede recorrente LSTM para prever a temperatura ambiente, considerando predições sucessivas para até duas horas. Considerando as arquiteturas de redes testadas, o modelo feedforward multicamadas obteve melhor desempenho, apresentando um erro médio de 0,94 °C, sendo o que melhor se adequa para compor um sistema preditivo que auxilie na tomada de decisão quanto ao uso da aeração em grãos armazenados.

Palavras-chave. Sistema de Aeração, Previsão de temperatura, Redes Neurais Artificiais, Sistema Preditivo.

1 Introdução

A aeração é a principal técnica empregada para conservar os grãos armazenados [2]. Consiste em promover a passagem do ar por meio de ventiladores através da massa granular, que após os processos de limpeza e secagem, são mantidos em armazéns até sua comercialização. Um sistema de aeração ineficiente pode causar problemas como migração de umidade, superaquecimento devido à atividade biológica dos grãos e proliferação de fungos e insetos [4].

O processo de aeração pode ser afetado por fatores internos ao silo, como profundidade, porosidade e umidade dos grãos, e externos, como variações de temperatura ambiente e umidade relativa do ar [7]. Segundo [5], a condição de temperatura no interior do silo de grãos com aeração depende, dentre outros fatores, da temperatura ambiente. A exposição à radiação solar na superfície externa do silo, associada à não uniformidade de distribuição do ar de ventilação, promove a presença de impurezas na massa de grãos.

A previsão e controle de temperatura e umidade de grãos armazenados tem sido objeto de estudo em muitas pesquisas. Em [3] é visto como a inteligência artificial capacita modelos de previsão eficientes a extrair características não lineares de dados de temperatura dos grãos. Nos trabalhos de [12], [13] e [9] a previsão de temperatura e umidade dos grãos foram estudadas na perspectiva de aprendizado de máquina, e em [10], [6], [11] e [14] esse tópico é abordado numa perspectiva de aprendizado profundo. Em [10], é proposto um modelo baseado em redes neurais recorrentes (RNN), capaz de prever com precisão a temperatura dos grãos. As características extraídas são alimentadas em Redes de Memória de Longo Prazo (LSTM), para realizar as previsões de temperatura dos grãos no futuro.

¹olivia.gomes@souunijui.edu.br

²manuel.binelo@unijui.edu.br

³marcia.brondani@unijui.edu.br

⁴joao.carau@sou.unijui.edu.br

Sistemas de aeração usam ventiladores de alta potência que precisam ficar ligados por várias horas. Ligar e desligar os ventiladores em intervalos curtos torna o processo ineficiente devido à energia necessária para a partida dos motores e para vencer a inércia inicial do fluxo de ar em meio poroso. Sistemas de controle de aeração geralmente usam o método de extrapolação constante, ou seja, tomam a decisão de ligar os ventiladores com base no valor de temperatura ambiente atual, considerando que ela permanece constante por alguns minutos. Caso a temperatura ambiente fique desfavorável em poucos minutos, esses sistemas podem tomar a decisão de desligar em pouco tempo, realizando aeração ineficiente, ou tomar a decisão de manter a aeração ligada por um período mínimo, mesmo em condições menos favoráveis.

Predizer a evolução da temperatura ambiente tem o potencial de melhorar o desempenho de sistemas de controle de aeração, podendo evitar situações em que o sistema de aeração seria ligado por um curto período devido à mudança da temperatura ambiente. Um sistema preditivo da temperatura do ar também pode possibilitar estimativas mais precisas da condição dos grãos após um determinado período de aeração. Considerando isso, esse trabalho analisa dois modelos de predição de temperatura ambiente baseados em aprendizado de máquina. Um dos modelos utiliza uma rede neural recorrente do tipo LSTM, e outro utiliza uma rede neural tipo feedforward (FNN). Para verificar o desempenho dos modelos propostos, eles são comparados à extrapolação constante.

2 Material e métodos

2.1 Conjunto de Dados

Os dados foram disponibilizados pelo Laboratório de Climatologia e Biogeografia da Universidade de São Paulo (USP), advindos da Estação Meteorológica Experimental. O conjunto corresponde a dados meteorológicos coletados durante o ano de 2018, com frequência de medição a cada 5 minutos. Neste trabalho, dois fatores são utilizados para fazer a previsão da temperatura, os horários de medição e a temperatura média nesses horários. Os dados foram normalizados para acelerar a fase de aprendizado. Foram utilizados dados dos três primeiros meses do ano de 2018, divididos em 67% para treinamento e 33% para teste.

Em aprendizado de máquina, é importante uma ampla base de dados para o treinamento. Esse artigo mostra resultados iniciais a partir dos três meses de dados utilizados, mas em trabalhos futuros, a base será expandida para considerar mais anos.

2.2 Modelos de Machine Learning

O trabalho utiliza dois tipos de redes neurais para prever a temperatura ambiente dos próximos 5 minutos com base nos dados disponíveis. Por meio de previsões sucessivas, as redes foram utilizadas para prever a temperatura ambiente das próximas 2 horas. RNNs são uma família de redes neurais usadas principalmente para lidar com dados sequenciais [8]. Com essas redes é possível traçar um caminho de uma unidade até ela mesma, de modo que seu estado interno mantenha um "vetor de estado" que guarda de forma implícita um histórico de informações de todos os elementos passados da sequência [8]. Entretanto, as RNNs geralmente apresentam dificuldade de otimização conhecida como Fuga do Gradiente [1] que é amenizada por uma arquitetura recorrente mais robusta chamada LSTM (Memória de Longo e Curto Prazo). FNNs são redes que apresentam 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 rede neural.

Os modelos foram implementados usando a biblioteca Tensorflow em Linguagem Python e suas configurações estão apresentadas na figura abaixo.

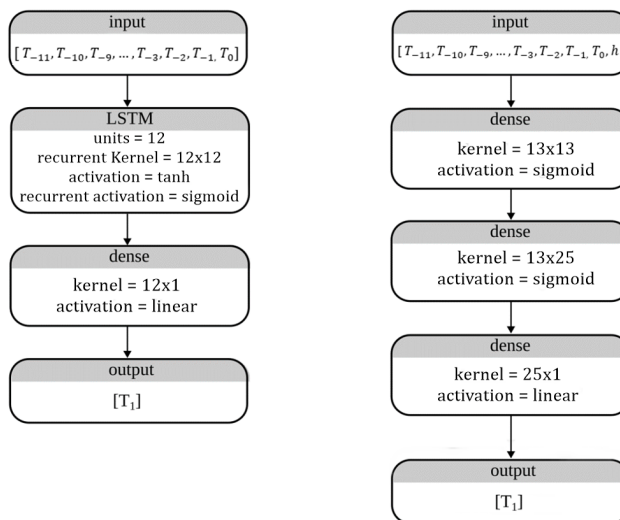


Figura 1: Esquema da RNA LSTM (à esquerda) e da RNA FF (à direita). Fonte: Autoria própria.

A RNN possui como entrada as 12 últimas temperaturas, considerando o intervalo de 5 minutos, representando a última hora, e a saída é a temperatura estimada para 5 minutos no futuro. A FNN possui 13 entradas, as 12 últimas temperaturas e também o horário da última temperatura registrada, a saída é também a temperatura estimada para 5 minutos no futuro.

Para validar os modelos propostos foram realizadas 24 previsões sucessivas a partir de um ponto inicial escolhido aleatoriamente dentro dos dados de aprendizado e teste, resultando assim em 2 horas de predição. Esse processo foi repetido 100 vezes nos dados de treinamento e 100 vezes nos dados de teste, sendo calculada a média do erro absoluto ao longo das 2 horas de predição.

3 Resultados e Discussão

Após 30 épocas, o processo de treinamento estabilizou em uma perda MSE de $1,536e-05$ para a RNN, e em uma perda MSE de $1,941e-05$ para a FNN. A métrica de MSE considera apenas a predição da próxima temperatura, que acontece durante a execução do algoritmos de treinamento. O erro médio absoluto em $^{\circ}\text{C}$ é apresentado nas Figuras 2, 3, 4 e 5, e considera a predição em sequência para até 120 minutos, que é como acontece a aplicação prática dos modelos. Portanto, o erro médio absoluto representa melhor o desempenho dos modelos.

Nas Figuras 2 e 3, é apresentada a média da evolução do erro médio absoluto das previsões ao longo tempo para os conjuntos de treinamento e teste respectivamente, considerando os dois modelos de predição comparados à extrapolação constante. Como esperado, quanto mais o tempo passa, mais distante dos dados reais fica a predição.

Para os dados de treinamento (Figura 2), ambos modelos de predição apresentam um resultado melhor do que extrapolação constante. Um aspecto importante a se considerar é que a RNN apresenta resultados mais instáveis, enquanto que a FNN apresenta um comportamento mais linear da evolução do erro médio. Para os dados de teste (Figura 3), a FNN mantém o mesmo bom desempenho, enquanto que a RNN apresenta resultados ainda mais instáveis e com desempenho pior que a extrapolação constante. Uma possível provável razão para essa diferença é o fato da FNN possuir uma informação a mais de entrada, que é o horário do dia. No entanto, é importante

a realização de mais testes, para identificar de forma mais segura, quais os fatores responsáveis por essa diferença nos resultados.

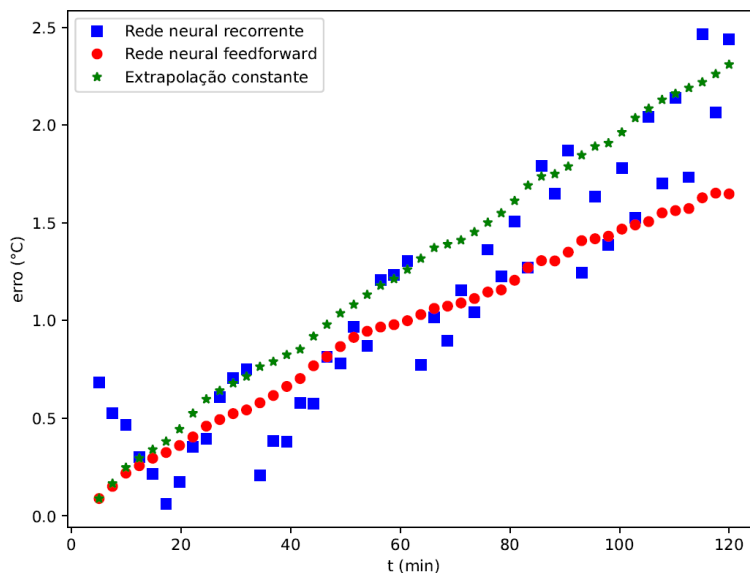


Figura 2: Erro médio de predição ao longo de 120 min, considerando como pontos iniciais 100 pontos aleatórios dos dados de treinamento. Fonte: Autoria própria.

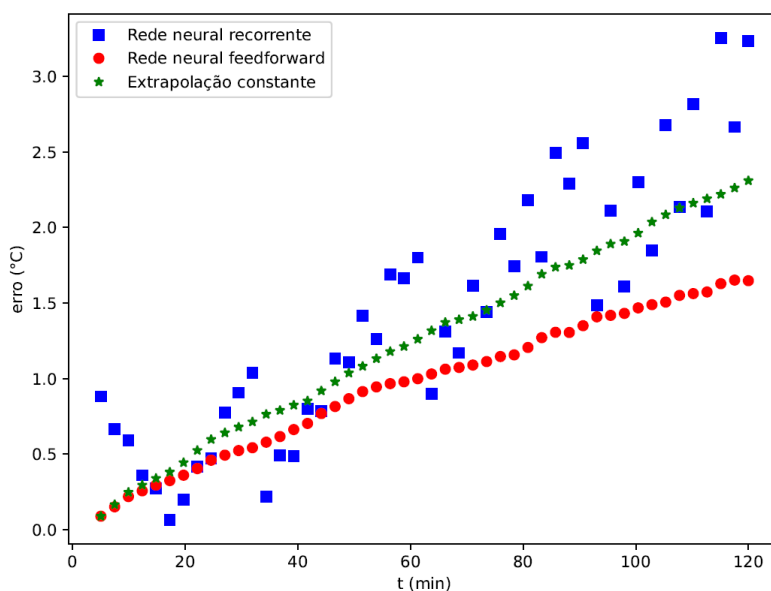


Figura 3: Erro médio de predição ao longo de 120 min, considerando como pontos iniciais 100 pontos aleatórios dos dados de teste. Fonte: Autoria própria.

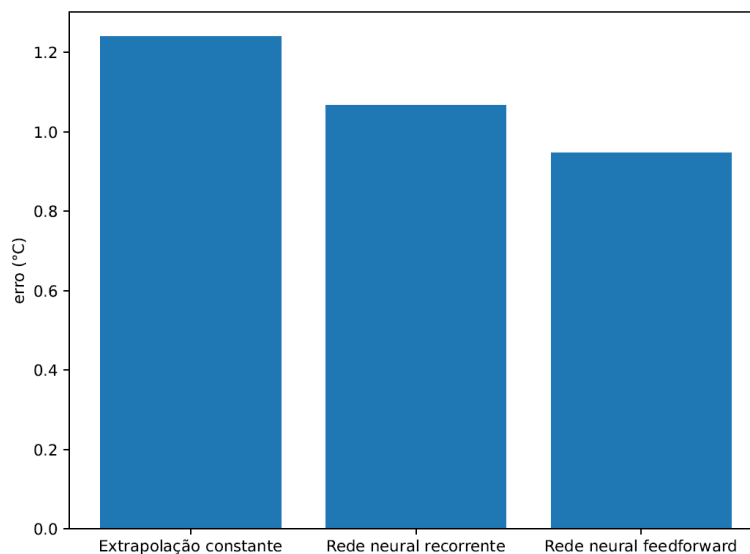


Figura 4: Erro médio geral de predição ao longo de 120 min, considerando como pontos iniciais 100 pontos aleatórios dos dados de treinamento. Fonte: Autoria própria.




Figura 5: Erro médio geral de predição ao longo 120 min, considerando como pontos iniciais 100 pontos aleatórios dos dados de teste. Fonte: Autoria própria.

A média geral do erro ao longo das duas horas é apresentada nas Figuras 4 e 5 para treinamento e teste respectivamente. Aqui fica claro que a FNN apresentou melhores resultados, enquanto que RNN apresentou resultados melhores que a extrapolação constante apenas para os dados de treinamento. Para os dados de treinamento, a extrapolação constante apresentou o erro de 1,24 °C, a RNN apresentou o erro de 1,07 °C e a FNN o erro de 0,94 °C. para os dados de teste, o erro

foi de $1,24\text{ }^{\circ}\text{C}$ para a extrapolação constante, de $1,41\text{ }^{\circ}\text{C}$ para RNN e de $0,94\text{ }^{\circ}\text{C}$ para FNN.




Figura 6: Comparação entre dados experimentais e previsão de 120 min atrás para cada um dos métodos. Fonte: Autoria própria.

A Figura 6 mostra uma comparação entre os dados experimentais e a previsão de 120 minutos para cada um dos métodos durante uma semana, onde é possível notar que os resultados da FNN se ajustam melhor aos dados experimentais.

4 Considerações Finais

Neste estudo apresentou-se o uso de dois modelos de rede neural para prever a temperatura ambiente comparados à extrapolação constante. Os resultados demonstram que o aprendizado de máquina pode ser utilizado para diminuir o erro da previsão de temperatura ambiente, o que pode contribuir para o desenvolvimento de sistemas de controle mais precisos. A rede neural do tipo FNN apresentou os melhores resultados, tanto para os dados de treinamento quanto de teste. Isso se deve possivelmente à inclusão do horário de previsão na entrada da rede, enquanto que redes do tipo RNN trabalham apenas com séries de dados.

Os resultados mostram um resultado melhor para o modelo do tipo FNN. No entanto, como o artigo usa uma base de dados limitada, para demonstrar de forma segura qual modelo é o mais adequado, é necessário ampliar a base de dados. Em trabalhos futuros, pretende-se ampliar o conjunto de dados, explorando mais anos de dados meteorológicos, além de explorar de forma mais ampla diferentes configurações de redes tipo RNN, FNN, além de outras arquiteturas, para que seja possível determinar de forma mais segura o melhor tipo de rede para esse problema.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil - (CAPES). Os autores também agradecem ao Laboratório de Climatologia

e Biogeografia da Universidade de São Paulo (USP) pelos dados fornecidos.

Referências

- [1] Y. Bengio, P. Simard e P. Frasconi. “Learning long-term dependencies with gradient descent is difficult”. Em: **IEEE Transactions on Neural Networks** 5.2 (1994), pp. 157–166.
- [2] M. O. Binelo, V. Faoro, O. A. Kathatourian e B. Ziganshin. “Airflow simulation and inlet pressure profile optimization of a grain storage bin aeration system”. Em: **Computers and Electronics in Agriculture** 164 (2019), p. 104923. ISSN: 0168-1699.
- [3] A. Kamilaris e F.X. Prenafeta-Bondú. “Deep Learning in agriculture: A survey.” Em: **Computers and electronics in Agriculture** 147 (2018), pp. 70–90.
- [4] O. A. Khatchatourian, M. O. Binelo, V. faoro e N. A. Toniazzo. “Three-dimensional simulation and performance evaluation of air distribution in horizontal storage bins”. Em: **Biosystems Engineering** 142 (2016), pp. 42–52. ISSN: 1537-5110.
- [5] O. A. Khatchatourian, M. O. Binelo, R. Neutzling e V. Faoro. “Models to predict the thermal state of rice stored in aerated vertical silos”. Em: **Biosystems Engineering** 161 (2017), pp. 14–23. ISSN: 1537-5110.
- [6] Y. Li, J. Nie e X. Chao. “Do we really need deep CNN for plant diseases identification?” Em: **Computers and Electronics in Agriculture** 178 (2020), p. 105803. ISSN: 0168-1699.
- [7] D. C. Lopes, J. H. Martins, A. F. Lacerda Filho, E. C. Melo, P. M. B. Monteiro e D. M. De Queiroz. “Aeration strategy for controlling grain storage based on simulation and on real data acquisition”. Em: **Computers and Electronics in Agriculture** 63.2 (2008), pp. 140–146. ISSN: 0168-1699.
- [8] E. A. Nketiah, L. Chenlong, J. Yingchuan e S. A. Aram. “Recurrent neural network modeling of multivariate time series and its application in temperature forecasting”. Em: **PLoS ONE** 5 (2023), p. 18.
- [9] V. Pham, D. C. Weindorf e T. Dang. “Soil profile analysis using interactive visualizations, machine learning, and deep learning”. Em: **Computers and Electronics in Agriculture** 191 (2021), p. 106539. ISSN: 0168-1699.
- [10] D. Shanshan, Y. Weidong, W. Xuyu, M. Shiwen e Z. Yuan. “Temperature Forecasting for Stored Grain: A Deep Spatiotemporal Attention Approach”. Em: **IEEE Internet of Things Journal** 8.23 (2021), pp. 17147–17160.
- [11] G. Sharma, A. Singh e S. Jain. “Hybrid deep learning techniques for estimation of daily crop evapotranspiration using limited climate data”. Em: **Computers and Electronics in Agriculture** 202 (2022), p. 107338. ISSN: 0168-1699.
- [12] Q. Wang, J. Feng, F. Han, W. Wu e S. Gao. “Analysis and prediction os grain temperature from air temperature to ensure the safety os grain storage.” Em: **International Journal of food properties** 23.1 (2020), pp. 1200–1213.
- [13] H. Xue, L. Li, P. Wen e M. Zhang. “A machine learning-based positioning method for poultry in cage environments”. Em: **Computers and Electronics in Agriculture** 208 (2023), p. 107764. ISSN: 0168-1699.
- [14] Q. Zhongke, Y. Zhang, C. Hong, C. Zhang, Z. Dai, Y. Zhao, X. Wu, Y. gao, X Jiang, J. Qian e Z. Gu. “Temperature forecasting of grain in storage: A multi-output and spatiotemporal approach based on deep learning”. Em: **Computers and Electronics in Agriculture** 208 (2023), p. 107785. ISSN: 0168-1699.