

PREVISÕES HORÁRIAS DE TEMPERATURA MÁXIMA VIA LSTM: UMA COMPARAÇÃO EM QUATRO CENÁRIOS SAZONAIS

MILENA DIAS DE OLIVEIRA¹; FABRÍCIO PEREIRA HARTER²

¹Universidade Federal de Pelotas – dmilena729@gmail.com

²Universidade Federal de Pelotas – fpharter@gmail.com

1. INTRODUÇÃO

A previsão de temperatura é um tema que vem ganhando cada vez mais destaque global, pois é de suma importância para o desenvolvimento sustentável, na dinâmica de interação solo-atmosfera, proteção dos ecossistemas, gerenciamento de recursos hídricos e na emissão de alertas de desastres climáticos (HOU et al., 2022). Para gerar essas previsões faz-se uso de modelos coerentes com os fatores que descrevem a temperatura, como os modelos numéricos baseados na física, cujos cálculos são feitos por computadores, se integrando assim, na área da modelagem matemática e computacional.

Nos últimos anos, um dos métodos que tem recebido destaque nas previsões de variáveis meteorológicas por ter capacidade de processar grandes volumes de dados com baixa complexidade computacional, são os modelos de *Deep Learning* (aprendizado profundo), que fazem uso de camadas de Redes Neurais Artificiais (RNAs) (NETO et al., 2020). Dentre as RNAs, destacam-se as com arquitetura recorrente, como a LSTM (*Long Short-Term Memory*), proposta por HOCHREITER e SCHMIDHUBER (1997) como solução para o problema conhecido como o *desaparecimento do gradiente*, que acontece quando este tende a zero, ocasionando a perda de dados durante o treino da rede.

Pesquisas como a de SCHIZAS et al. (1991), KAUR e SINGH (2011), CHOLLET (2021), HAQUE et al. (2021), HOU et al. (2022), BI et al. (2023) e DÍAZ-RAMÍRE (2024), mostram que modelos baseados em redes neurais artificiais tem potencial significativo para complementar e até superar as técnicas clássicas nas previsões de variáveis meteorológicas, como a temperatura.

Nesse contexto, e considerando a importância das previsões de temperatura para as atividades humanas e o monitoramento climático, esta pesquisa teve como objetivo realizar previsões horárias de temperatura máxima em diferentes horizontes temporais, considerando quatro cenários sazonais diferentes, usando um modelo baseado na rede neural recorrente LSTM. A proposta é avaliar o desempenho preditivo desse modelo, para esses horizontes, ao longo de um período específico de cada estação do ano (verão, outono, inverno e primavera).

2. METODOLOGIA

Com o objetivo de desenvolver um modelo de *deep learning* usando redes neurais do tipo LSTM para realizar previsões de temperatura máxima horária, esta pesquisa tomou como referência o trabalho de CHOLLET (2021). O modelo utilizou como variável de entrada apenas dados históricos de temperatura máxima horária, no período de 2001 a 2024, obtidos do site do Instituto Nacional de Meteorologia (INMET). Esses dados correspondem à estação meteorológica localizada no bairro Jardim Botânico em Porto Alegre, cujas coordenadas são: (-30.05, -51.17).

No pré-processamento, foi feita a concatenação de todos os valores no período

analisado (2001-2024) em um único arquivo no formato CSV, contendo apenas duas colunas: uma com a data e hora, e a outra com os valores de temperatura máxima. Os dados foram divididos em 50% para treinamento do modelo, 25% para validação e 25% para teste.

Os horizontes de previsão escolhidos foram de 24h, 48h, 72h, 7 dias, 15 dias e 30 dias. Essas simulações foram realizadas ao longo dos meses de março, junho, setembro e dezembro no ano de 2024, que foram os quatro cenários sazonais distintos selecionados. O motivo da escolha desses meses se deu pelo fato de coincidirem com a transição entre as estações do ano, períodos em que há variações significativas na temperatura do ar. Tais períodos são essenciais para avaliar o desempenho de um modelo de previsão.

O modelo foi desenvolvido na linguagem de programação Python. Sua Arquitetura é composta por duas camadas LSTM e utiliza o otimizador Adam para ajustar os pesos. Ele lê o arquivo CSV contendo os dados de entrada, remove valores ausentes e os normaliza entre 0 e 1. É treinado por 10 épocas com um *batch_size* de 64 amostras, e *look back* de 72 horas. As previsões são realizadas utilizando os dados de teste e os valores resultantes são desnormalizados retornando a escala original.

A métrica de avaliação utilizada foi a Raiz do Erro Quadrático Médio (RMSE), pois é uma das métricas mais utilizadas em modelos de regressão estatística (HYNDMAN e KOEHLER, 2006), por realizar uma avaliação criteriosa. Seus valores não têm limite superior e quanto mais próximo do zero melhor o desempenho do modelo e a precisão das previsões (BINOTI et al, 2015). Para a previsão de temperatura, valores entre 0 e 1 °C, garantem um resultado excelente.

3. RESULTADOS E DISCUSSÃO

O modelo neural baseado na LSTM desenvolvido nesse trabalho gerou as previsões horárias de temperatura para os horizontes de 24h, 48h, 72h, 7 dias, 15 dias e 30 dias ao longo dos meses de março, junho, setembro e dezembro, que foram os quatro cenários sazonais distintos escolhidos.

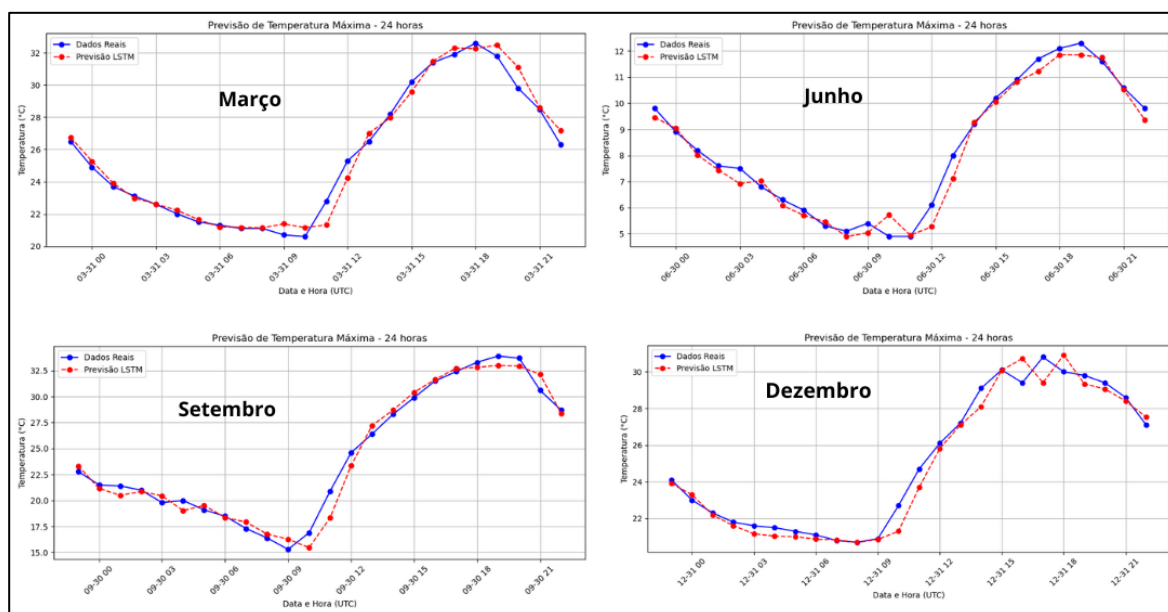


Figura 1. Previsões horárias de temperatura máxima no período de 24 horas, referentes aos meses de março, junho, setembro e dezembro do ano de 2024. Fonte: Autores

Na Figura 1, a fim de ilustração, são apresentados os gráficos das previsões no período de 24 horas referentes às últimas horas de cada um dos quatro meses referentes. O gráfico na cor azul representa os valores reais ou observados e o gráfico na cor vermelha os valores previstos (verdade terrestre). Foram igualmente gerados gráficos correspondentes aos demais horizontes de previsão.

Ao analisar esses gráficos (Figura 1) é possível notar que o modelo neural reproduz o ciclo diurno de temperatura, ou seja, que os valores previstos seguem a tendência dos valores observados. Há apenas algumas divergências nos valores previstos, que são aceitáveis considerando a boa sequência das previsões. O mesmo ocorreu nas previsões realizadas nos períodos de 48h, 72h, 7 dias, 15 dias e 30 dias. Os valores de RMSE obtidos em cada previsão, nos respectivos períodos e para os meses selecionados, estão ilustradas na Figura 2.

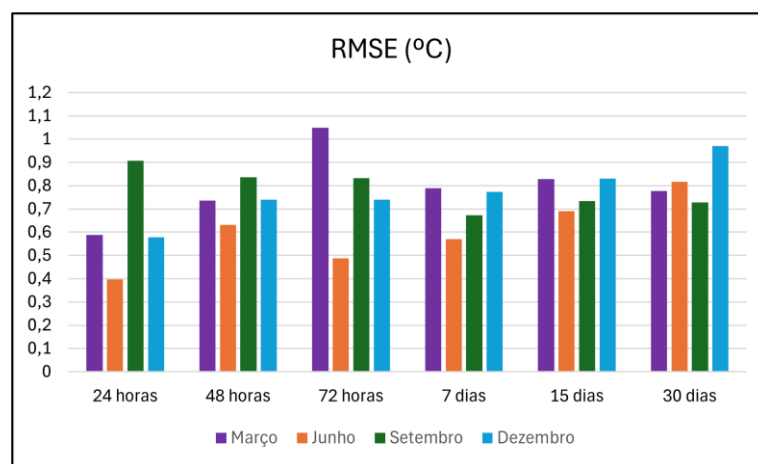


Figura 2. RMSE obtidos nas previsões. Fonte: Autores

De acordo com o gráfico na figura 2, as previsões horárias de 24h e 48h obtiveram os valores de RMSE mais elevados no mês de setembro e mais baixos no mês de junho. Nas previsões de 72h e 7 dias os menores RMSEs foram também do mês de junho, enquanto os maiores ocorreram no mês de março, comportamento que se repetiu para a de 15 dias. No horizonte de 30 dias, o maior valor de RMSE foi no mês de dezembro e o menor no mês de setembro.

Em síntese, os resultados indicam que as previsões com maior precisão, isto é, onde o modelo teve um melhor desempenho foram as geradas no mês de junho, onde se tem a transição do outono para o inverno. Em contrapartida, nas previsões do mês de março, período correspondente ao final do verão e início do outono, foi onde o modelo apresentou o seu pior desempenho. Entretanto, é preciso investigar o porquê de previsões de maior alcance apresentarem erro menor do que previsões e menor alcance.

4. CONCLUSÕES

O modelo neural baseado na rede LSTM desenvolvido nesta pesquisa apresentou, de forma geral, um bom desempenho ao gerar previsões de temperatura máxima horária para os horizontes de 24h, 48h, 72h, 7 dias, 15 dias e 30 dias nos quatro cenários sazonais referentes aos meses de março, junho, setembro e dezembro de 2024. Os valores de RMSE ficaram dentro do intervalo esperado, indicando que esta ferramenta é eficaz para gerar previsões de temperaturas e pode,

com ajustes adequados, ser complementar às previsões tradicionalmente realizadas por modelos numéricos baseados em física.

Essa primeira versão do modelo, no entanto, é relativamente simples e apresenta algumas limitações, como o de utilizar somente dados de temperatura como variável de entrada. Para trabalhos futuros, pretende-se desenvolver uma versão mais complexa, ajustando os parâmetros quando necessário e adicionando como entrada outras variáveis meteorológicas, como dados de pressão atmosférica, temperatura do ponto de orvalho e velocidade do vento, buscando aumentar a precisão das previsões.

5. REFERÊNCIAS BIBLIOGRÁFICAS

BI, K. et al. Accurate medium-range global weather forecasting with 3D neural networks. **Nature**, v. 619, n. 7970, p. 533-538, 2023.

BINOTI, M. L. M. S. et al. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, v. 21, n. 1, p. 97-105, 2015.

CHOLLET, F. **Deep Learning with Python**. Nova York: Manning Publications, 2021. 2v

DÍAZ-RAMÍRE, J. et al. Comparative analysis of machine learning techniques for forecasting weather: a case study. **Interciencia**, v. 49, n. 5, p. 305-313, 2024.

HAQUE, E. TABASSUM, S. HOSSAIN, E. A comparative analysis of deep neural networks for hourly temperature forecasting. **IEEE Access**, v. 9, p. 160646-160660, 2021.

HOCHREITER, S; SCHMIDHUBER, J. Long short-term memory. **Neural computation**, v. 9, n. 8, p. 1735-1780, 1997.

HOU, J. et al. Prediction of hourly air temperature based on CNN–LSTM. **Geomatics, Natural Hazards and Risk**, v. 13, n. 1, p. 1962-1986, 2022.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International journal of forecasting**, v. 22, n. 4, p. 679-688, 2006.

KAUR, A. SINGH, H. Artificial Neural Networks in forecasting minimum temperature. **International Journal of Electronics & Communication Technology**, v. 2, n. 3, p. 101-105, 2011.

NETO, H. L. et al. Aplicação de Redes Neurais Recorrentes em séries temporais de estações meteorológicas para imputação de dados: uma abordagem sobre micro-estações meteorológicas na região Oeste do Pará. In: **Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais (WCAMA)**. SBC, 2020. p. 171-180.

SCHIZAS, C. N. et al. Artificial neural networks in forecasting minimum temperature (weather). In: **1991 second international conference on artificial neural networks**. IET, 1991. p. 112-114.