

15º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2024

Modelo de predição da precipitação na cidade de São Paulo por meio de redes neurais recorrentes

VICTOR GOMOR DE OLIVEIRA ELOY¹, REGIVALDO SOUSA FERREIRA², ADRIANO JOSÉ FERRUZZI³

¹ Estudante do Curso Técnico em Redes de Computadores Integrado ao Ensino Médio, IFSP, Câmpus Pirituba, gomor.victor@aluno.ifsp.edu.br.

² Orientador, Docente. IFSP, Campus São Paulo Pirituba, adrianoferruzzi@ifsp.edu.br.

³ Professor de arquitetura de computadores e redes, IFSP, Campus Pirituba, regivaldo.ferreira@ifsp.edu.br.

Área de conhecimento (Tabela CNPq): 1.02.02.08-0 Análise de Dados

RESUMO: A cidade de São Paulo sofre com os impactos das fortes chuvas e inundações que causam prejuízos humanos e econômicos. Este trabalho propõe a criação de um modelo de previsão de precipitação utilizando redes neurais recorrentes (RNN), treinadas com dados históricos do INMET (Instituto Nacional de Meteorologia). A RNN é capaz de aprender padrões complexos em séries temporais, permitindo previsões precisas. O objetivo do trabalho é desenvolver um modelo de previsão de precipitação que pode servir como base para tomada de decisões em casos de chuvas e tempestades, possibilitando a implementação de medidas preventivas. Espera-se que o modelo contribua para a gestão de riscos, podendo se tornar mais uma ferramenta de previsão de precipitação para a população paulistana.

PALAVRAS-CHAVE: redes neurais; inteligência artificial; modelo computacional; precipitação

Precipitation Prediction Model in the State of São Paulo Using Recurrent Neural Networks

ABSTRACT: The city of São Paulo suffers from the impacts of heavy rains and floods, which cause human and economic losses. This work proposes the creation of a precipitation forecasting model using recurrent neural networks (RNN), trained with historical data from INMET (National Institute of Meteorology). The Recurrent Neural Network (RNN) demonstrates the capability to learn complex temporal patterns in time series, thus enabling accurate forecasting. The aim of this study is to develop a precipitation forecasting model that can inform decision-making processes related to rain and storm events, thereby supporting the implementation of preventive measures. It is anticipated that the model will contribute to risk management efforts, potentially serving as an additional forecasting tool for precipitation events for the population of São Paulo.

KEYWORDS: KEYWORDS: neural networks; artificial intelligence; computational model; precipitation.

INTRODUÇÃO

A cidade de São Paulo enfrenta precipitações intensas que acarretam significativos danos humanos, econômicos e disrupções nas atividades cotidianas, comprometendo a qualidade de vida dos cidadãos (Genovez & Zuffo, 2000). Por isso, foram criados modelos matemáticos que possibilitam prever as precipitações intensas e, dessa forma, empenhar-se em mitigar os problemas causados por elas (Abreu, 2018). Neste contexto, o presente estudo concentra-se no desenvolvimento de um modelo de previsão de chuvas utilizando RNN (Russel; Norvig, 2016). O modelo criado com RNN utiliza a arquitetura LSTM (*Long Short-Term Memory*) (Junior, 2019). O objetivo é aprimorar a capacidade de antecipar eventos extremos. A RNN do tipo LSTM foi escolhida devido à sua capacidade de apreender representações latentes complexas em dados sequenciais, como as séries temporais de precipitação (Estébanez et al., 2018) O modelo desenvolvido pode contribuir para previsão de eventos extremos na cidade de São Paulo. A partir deste ponto, os administradores públicos podem utilizar essa previsão para tentar mitigar os danos, otimizar a gestão de recursos e fortalecer a resiliência da cidade de São Paulo frente a condições climáticas adversas (Doninelli; Silva; Grzybowski, 2020)

MATERIAIS E MÉTODOS

Este estudo está pautado em pesquisas teóricas e práticas, feitas por meio de revisão de literatura de natureza qualitativa. Ele tem como base os artigos publicados nos últimos 5 anos e utiliza as bases de dados encontradas nos periódicos Capes e Google Acadêmico. A seleção dos artigos considera as seguintes palavras-chave em ambos os portais: LSTM, precipitação, neural networks. Sobre os critérios de inclusão, são utilizados artigos nos idiomas de português e inglês relacionados ao tema, compreendidos na faixa temporal estipulada e que tiverem proximidade com o contexto deste estudo. O modelo de previsão de precipitação foi criado utilizando um algoritmo de RNN com arquitetura LSTM com base nos dados gerados pelo INMET, destes foram coletadas as leituras desde dia um de Janeiro de 2023 a trinta e um de Dezembro do mesmo ano com as seguintes variáveis: evaporação do piche diária em (milímetros), insolação total diária em (horas), temperatura máxima diária em °C, temperatura média compensada diária em °C, temperatura mínima diária em °C, umidade relativa do ar média diária em (%), umidade relativa do ar mínima diária em (%), vento com velocidade média diária em (metros/segundo); com o fito de aprimorar o modelo e comparar as previsões realizadas no presente estudo com os acontecimentos climático já ocorridos anteriormente.

O modelo possui portas de entrada, portas de saída, portas de esquecimento e células de memória. Além de permitir que a rede governe as células de memória, essas portas regulam o fluxo de informações. Os portões permitem que o LSTM controle o fluxo de informações e escolha quais dados produzir, esquecer ou armazenar. A rede pode identificar parâmetros em curto prazo porque as células de memória armazenam informações por um longo tempo na rede LSTM, os dados utilizados, os pré-processamentos realizados e as métricas de avaliação (Paixão et al. , 2022)

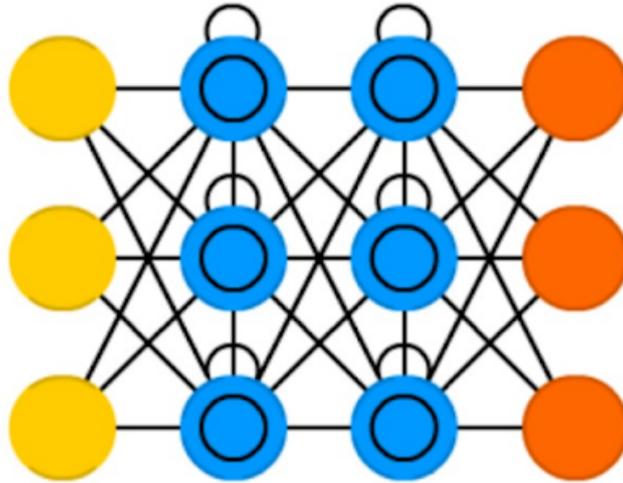


Figura 1: Memória de Longo E Curto Prazo (LSTM).

Os círculos amarelos representam o portão de entrada a qual controla quais novas informações serão adicionadas na célula de memória. Ele combina a entrada atual e a saída anterior, passando por uma função sigmoide que decide quais valores serão atualizados. Um vetor de possíveis novos valores candidatos também é gerado através de uma função tangente hiperbólica, sendo multiplicado pelos valores do portão de entrada.

Os círculos azuis com contornos representam a célula de memória responsável por armazenar informações ao longo do tempo em uma sequência. Ela permite que os dados importantes sejam mantidos por longos períodos, controlando o que lembrar ou esquecer através de três portões: **portão de esquecimento** (decide o que descartar), **portão de entrada** (adiciona novas informações relevantes) e **portão de saída** (determina quais informações serão usadas na saída). Isso permite que a LSTM capture longo prazo, essencial em tarefas de séries temporais ou processamento de sequências.

Os círculos laranja representam a célula de **saída** em uma LSTM essas células controlam quais informações do estado da célula serão usadas como saída. O **portão de saída** decide, com uma função sigmoide, quanto das informações da célula será liberado. Essas informações passam por uma função **tangente hiperbólica** para serem ajustadas entre -1 e 1, e o resultado final é multiplicado pelo valor do portão de saída, determinando a **saída final** da LSTM naquela etapa.

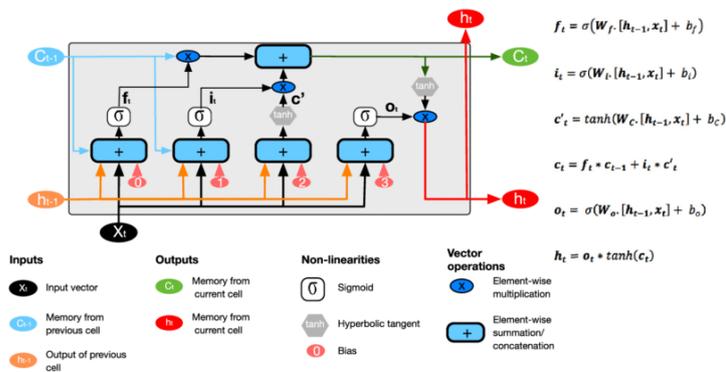


Figura 2: Representação Esquemática de uma Célula LSTM.

A imagem acima representa a arquitetura de uma célula de memória LSTM (Long Short-Term Memory), mostrando as portas de controle e as operações internas, essas operações são reguladas por funções de ativação sigmoide e tangente hiperbólica, permitindo que a LSTM mantenha e atualize

informações ao longo de sequências temporais de forma eficiente, evitando problemas de gradientes explosivos.

A função tangente hiperbólica nas LSTMs é essencial para controlar a amplitude dos dados, garantir que os novos valores candidatos e as saídas ocultas estejam em uma faixa estável, e facilitar o treinamento da rede, minimizando problemas de saturação e explosão de gradientes (Lyu et al. , 2015).

As células LSTM foram propostas para resolver o problema das redes neurais comuns com *vanishing gradient* (Gradiente de Desaparecimento), onde os gradientes se tornam muito pequenos durante o treinamento, dificultando o aprendizado da rede neural (Lecun; Bengio; Hinton , 2015). Portanto, as LSTM's com células de memória e mecanismos de controle na arquitetura permitem à rede decidir quais informações devem ser lembradas ou esquecidas, tornando-as mais eficazes em capturar os dados e retornar respostas com ajuda de suas células de memórias (Hochreiter & Schmidhuber, 1997).

As configurações da máquina para treinar o modelo foram de um processador de dois núcleos Intel(R) Xeon(R) CPU @ 2.0GHz, memória RAM 12GB, placa de vídeo Nvidia Tesla T4 15GB RAM, CUDA 12.2 (plataforma criada pela NVIDIA), fornece capacidades de computação paralela permitindo que programas utilizem a GPU (unidade de processamento gráfico) do computador para realizar diversos cálculos, resultando em uma redução do tempo necessário para as computações. Por essa razão, é utilizada em muitas aplicações que demandam alta capacidade computacional, como aprendizado de máquina. (Weninger; Bergmann; Schuller, 2015). O Google Colab foi utilizado como ambiente virtual, oferecendo suporte para o uso das configurações mencionadas e facilitando o acesso à GPU Nvidia Tesla T4, otimizando o processo de treinamento. O código foi desenvolvido sob a linguagem python em sua versão: Python 3.10.12, acompanhado das seguintes bibliotecas e suas respectivas versões: pandas 2.1.4, keras 3.4.1, matplotlib 3.7.1, numpy 1.26.4, sklearn 1.3.2.

RESULTADOS E DISCUSSÃO

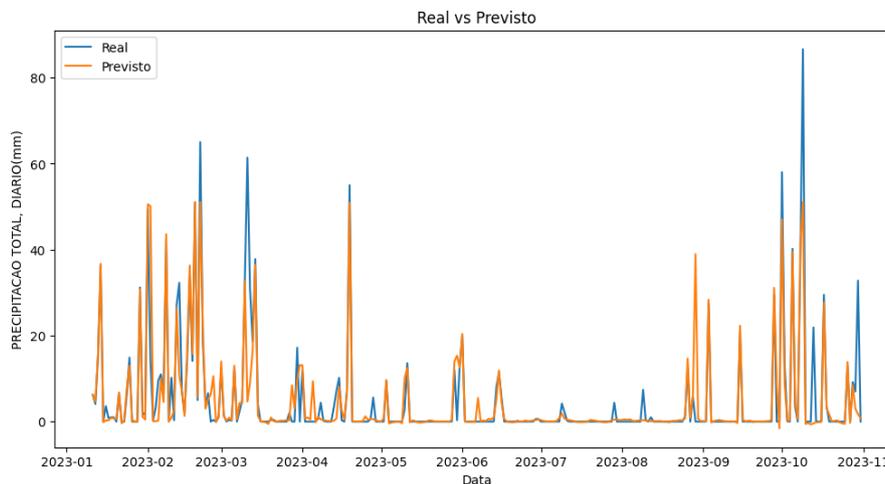


Figura 3: Comparativo entre previsões e os reais acontecimentos climáticos.

O gráfico retrata a relação entre os valores gerados pelo modelo matemático e os de fato ocorridos para analisar a qualidade da rede em questão, foi observado que a rede se comporta muito bem prevendo lapsos menores entre um e três dias, tendo uma queda a partir do terceiro dia, sendo assim se fez assertiva no total entre 80 e 92% em previsões dentro o período de três dias.

Foram obtidas previsões semelhantes aos reais acontecimentos de precipitações, mostrando o po-

tencial de assertividade deste modelo matemático sob o viés de sua viabilidade de execução.

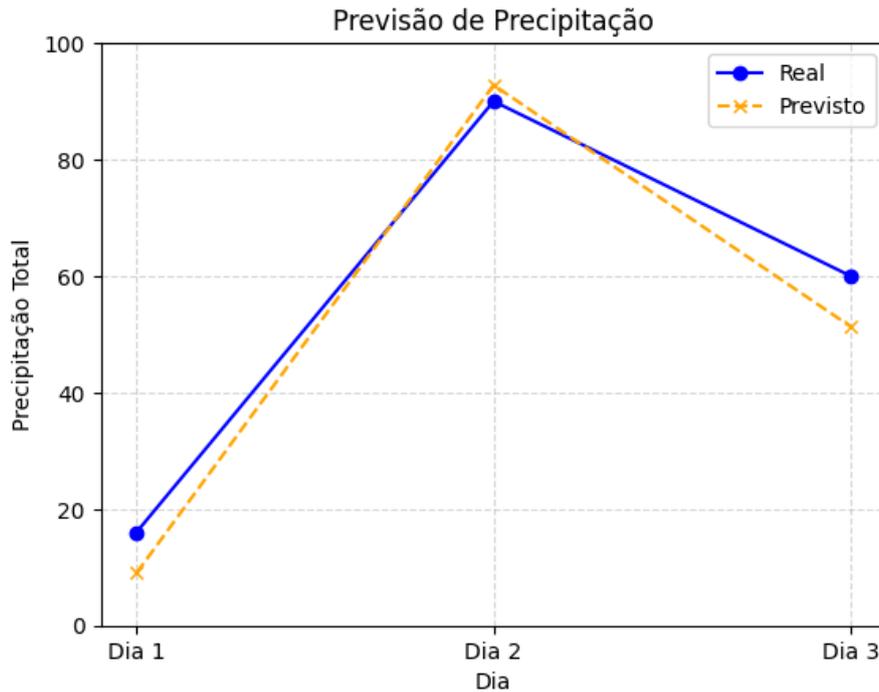


Figura 4: Relação de Acurácia da Rede Neural Em Um Período De 03 Dias.

O gráfico ilustra a capacidade preditiva da rede neural em relação a precipitação na cidade de São Paulo.

A rede quando posta frente ao desafio de prever os acontecimentos se comporta com assertividade de 88% no primeiro dia, 96% no segundo dia em relação ao de fato ocorrido, e depois uma pequena depressão que normaliza em 82% a taxa de acerto.

CONCLUSÕES

Foram identificados, por meio de pesquisas bibliográficas, os fatores mais relevantes para a análise da precipitação. Para isso, foram coletados e analisados trabalhos que abordam o uso de RNNs na previsão de precipitação, além de dados históricos de precipitação do INMET e de outras fontes relevantes. Em seguida, foi realizada a limpeza e preparação desses dados, tornando-os prontos para o treinamento do modelo. A arquitetura da rede neural foi definida e implementada, incluindo a seleção do número de camadas e neurônios, bem como a configuração dos parâmetros de treinamento. Durante o treinamento da rede, seu desempenho foi monitorado, sempre comparando as previsões com os eventos pluviométricos efetivamente ocorridos nas datas previstas. O desempenho do modelo foi avaliado com base em sua assertividade, e foram identificados pontos de melhoria, como o aumento na precisão e um maior índice de acerto em previsões mais longínquas. Assim, o monitoramento contínuo do desempenho do modelo está em curso, com ajustes sendo realizados conforme necessário.

Uma vez terminado e testado o algoritmo de RNN, ele pode ser treinado com novos dados e expandido para outras cidades, permitindo a criação de modelos especializados para cada local, podendo ajudar nas previsões de precipitação locais.

CONTRIBUIÇÕES DOS AUTORES

V. G. O Desenvolvedor da rede neural; R. S. F Desenvolvedor da aplicabilidade dos dados na rede; A. J. F Correções dos trabalhos e ajustes no código da rede neural.

AGRADECIMENTOS

Os autores agradecem ao Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - Câmpus Pirituba pela possibilidade do desenvolvimento do trabalho.

REFERÊNCIAS

- ABREU, J. Agrometeorologia. aplicação da meteorologia para maximizar a produção agrícola. *Editora Agrobook*, 2018.
- DONINELLI, J. W.; SILVA, R. V. da; GRZYBOWSKI, J. M. V. Previsão pluviométrica por meio da aplicação de redes neurais artificiais recorrentes alimentadas com dados meteorológicos em tempo atual. *JORNADA DE INICIAÇÃO CIENTÍFICA E TECNOLÓGICA*, v. 1, n. 10, 2020.
- ESTÉBANEZ, K. M. B. Previsão de níveis de precipitação usando redes neurais artificiais. Universidade Federal do Rio de Janeiro, 2018.
- GENOVEZ, A. M.; ZUFFO, A. C. Chuvas intensas no estado de são paulo: Estudos existentes e análise comparativa. *Revista Brasileira de Recursos Hídricos*, v. 5, n. 3, p. 45–58, 2000.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, MIT press, v. 9, n. 8, p. 1735–1780, 1997.
- JUNIOR, J. R. F. *Redes neurais recorrentes — LSTM - Jose R F junior*. 2019. Disponível em: <<https://medium.com/@web2ajax/redes-neurais-recorrentes-lstm-b90b720dc3f6>>.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015.
- LYU, Q. et al. Modelling high-dimensional sequences with lstm-rtrbm: Application to polyphonic music generation. In: *Twenty-Fourth International Joint Conference on Artificial Intelligence*. [S.l.: s.n.], 2015.
- PAIXÃO, G. M. d. M. et al. Machine learning na medicina: Revisão e aplicabilidade. *Arquivos brasileiros de cardiologia*, SciELO Brasil, v. 118, p. 95–102, 2022.
- RUSSELL, S. J.; NORVIG, P. *Artificial intelligence: a modern approach*. [S.l.]: Pearson, 2016.
- WENINGER, F.; BERGMANN, J.; SCHULLER, B. Introducing currennt: The munich open-source cuda recurrent neural network toolkit. *Journal of Machine Learning Research*, p. 547–551, 2015.