



PREVISÃO DOS ÍNDICES DE CHUVA ACUMULADOS NA CIDADE DE UBERLÂNDIA UTILIZANDO REDES NEURAS ARTIFICIAIS LSTM

Heitor Eugênio Gonçalves*¹, Alexandre Coutinho Mateus¹ e Luciano Xavier Medeiros¹

¹FEELT - Universidade Federal de Uberlândia

Resumo - A previsão dos índices de chuva necessita da análise de numerosos fatores climáticos que nem sempre estão disponíveis. Sendo assim, neste trabalho foi desenvolvido uma Rede Neural Artificial Recorrente do tipo LSTM capaz de prever a tendência de chuva acumulada no dia seguinte na cidade de Uberlândia. Outrossim, este trabalho permite a compreensão do funcionamento de uma rede LSTM, bem como o entendimento dos parâmetros usados na Rede Neural Artificial.

Palavras-Chave- chuvas em Uberlândia, estimativa de chuva, LSTM, predição, Rede Neural Artificial Recorrente.

FORECAST OF ACCUMULATED RAINFALL IN THE CITY OF UBERLÂNDIA USING LSTM ARTIFICIAL NEURAL NETWORKS

Abstract - The forecast of rainfall indexes requires analysis numerous climatic factors that are not always available. Therefore, in this work was developed a Recurring Artificial Neural Network of type LSTM capable of predicting the trend of rainfall accumulated the next day in the city of Uberlândia. Furthermore, this work allows understanding of the operation of an LSTM network, as well as the understanding of the parameters used in the Artificial Neural Network.

Keywords - LSTM, predication, rainfall estimation, Recurrent Artificial Neural Network, Uberlândia rainfall.

I. INTRODUÇÃO

As Redes Neurais Artificiais (RNAs) são técnicas computacionais fundamentadas no funcionamento do sistema nervoso humano. As RNAs são utilizadas na aprendizagem de máquinas, em que um sistema determina a resposta atual baseado em seu treinamento com dados anteriormente fornecidos [1]. Desse modo, estes artifícios possuem diversas aplicabilidades, como a construção de carros autônomos, identificação de tumores em imagens, mineração de *Big Data*, entre outras.

Existem numerosas arquiteturas de RNA que variam de acordo com a aplicação. Por exemplo, caso o objetivo seja

o reconhecimento de imagens, as Redes Neurais Convolucionais (RNCs) obtém os melhores resultados [2]. Porém, se o interesse for modelar dados em uma sequência temporal, as Redes Neurais Recorrentes (RNRs) são as mais eficientes [3].

Salienta-se que as redes neurais são amplamente empregadas na previsão do tempo. Por exemplo, no trabalho de Abhisheka et al. [4] estimou-se a temperatura máxima ao longo de um ano a partir de RNAs cujas as entradas são os dados meteorológicos de Ontário, Canadá, entre os anos de 1999 e 2009. Ademais, as redes desenvolvidas em [4] variaram em relação a função de ativação, números de neurônios e camadas ocultas. Assim, os autores conseguiram desenvolver eficientes previsões.

Li e outros [5] desenvolveram uma inteligência artificial para a previsão de tempo espacial, onde foi criada uma rede neural convolucional profunda para prever explosões solares. Para isso, é feito o treinamento da rede com amostras de regiões solares ativas coletadas entre maio de 2010 e setembro de 2018. Ao analisar os resultados, percebe-se que essa RNC mostrou-se ser um modelo eficaz para o tema em questão.

Em Beritelli et al. [6], uma RNA é elaborada para classificar a intensidade de chuva em 4 níveis a partir de características do sinal 4G/LTE recebido. O modelo obteve excelentes resultados, alcançando uma taxa de 96,7% de classificação correta.

No trabalho de Ahuna et al. [7] é desenvolvida uma RNA que prevê a taxa de chuva por meio de três valores anteriores em um intervalo de 30 segundos. Para a elaboração da rede, são usados dados históricos de precipitação na cidade de Durban, África do Sul. Esse método apresenta baixos valores de erros entre as taxas previstas e as medidas.

Neste trabalho, uma Rede Neural Recorrente com células de memória longa de curto prazo, em inglês Long Short-Term Memory (LSTM), é usada para prever a quantidade de chuva acumulada ao longo de 24 horas na cidade de Uberlândia, localizada em Minas Gerais, Brasil. Ressalta-se que na Subseção C há uma introdução sobre o funcionamento das LSTM.

Acentua-se que a previsão de precipitações é de grande importância para vários setores, como o da agricultura, aviação, telecomunicações, entre outros. Menciona-se, como exemplo, a utilização da taxa de precipitação em modelos para calcular a atenuação causada pela chuva durante a transmissão de sinais [8]. Portanto, nota-se que a criação de modelos para prever

*heitor.goncalves@ufu.br

taxas de chuva é imensamente importante.

II. FUNDAMENTAÇÃO TEÓRICA

A. Índice pluviométrico

De acordo com o Sistema Internacional de Medidas, a quantidade de chuva, chamada de pluviosidade, é medida em milímetro (mm). Isto significa que se o seu valor for de 1 mm, tem-se que a água da chuva ocupa uma altura de 1 mm em um paralelepípedo reto cuja a área base é de 1 m², ou seja, abrange um volume de 1 L [9].

O índice pluviométrico é a quantidade de chuva em um dado horário. Geralmente, estes valores são medidos pelas estações meteorológicas a cada uma hora. No caso deste trabalho, é utilizado a quantidade de precipitação acumulada ao longo de um dia.

B. Funcionamento das Redes Neurais Artificiais


As Redes Neurais Artificiais são compostas por camadas constituídas por neurônios. Essas camadas são interligadas por meio de um conjunto de pesos e *bias* que são os responsáveis pelo ganho de experiência da RNA. Isso porque, durante o treinamento, os valores dos pesos e *bias* são ajustados de modo a obter o menor valor para a função de custo, que abrange os erros na saída da rede [10].

As saídas dos neurônios são determinadas por meio de funções de ativação. Estas são aplicadas sobre a soma de *bias* com os valores de entrada multiplicados pelos seus respectivos pesos, ou seja,

$$y = f \left(\sum_{i=1}^n x_i \cdot w_i + b \right), \quad (1)$$

em que f é a função de ativação, y é a saída do neurônio, b é o *bias*, x_i a entrada e w_i o peso para $i = 1, 2, \dots, n$. A Figura 1 mostra de forma gráfica como ocorre a entrada e saída de dados de um neurônio.

Figura 1: Funcionamento de um neurônio.




A quantidade de vezes que os dados de treinamento passam pela rede é chamada de época. Desse modo, quando há poucas épocas, a RNA tem dificuldade para aprender com os dados. Por outro lado, caso haja muitas passagens, a rede pode acostumar-se exageradamente com os dados de treinamento, tendo resultados ruins para novos valores. Este fenômeno é conhecido como *overfitting*.

C. Redes Neurais Recorrentes LSTM

Em uma RNA não Recorrente, apenas os dados da iteração atual são utilizados. No entanto, as Redes Neurais Recorrentes utilizam informações de iterações passadas para obter os valores no presente. Em outras palavras, as RNR são redes que usam suas memórias. A Figura 2 apresenta o modo de operação de uma RNR.

Figura 2: Processamento de dados em um RNR.



Em uma RNA, os ajustes dos pesos podem ser feitos por meio do processo de *backpropagation*. Esta técnica consiste em propagar o erro da camada de saída para as antecessoras a partir do negativo do gradiente da função de custo. A Figura 2 exemplifica esse processo ao mostrar a transferência de informações entre os neurônios h_1, h_2, \dots, h_t .

Quando a quantidade de informações de tempos passados é muito grande, tem-se um fenômeno conhecido como *desaparecimento do gradiente*, em que este tem seu valor bastante reduzido quando chega nas primeiras camadas, não conseguindo corrigir os pesos de forma efetiva. Neste contexto, a LSTM é usada para evitar que esse problema ocorra.

A LSTM, proposta inicialmente por Hochreiter e Schmidhuber [11], permite o esquecimento de informações, o que possibilita que a rede armazene apenas o que for relevante para o modelo. Desse modo, dados de longo prazo podem ser guardados sem que o gradiente desapareça.

O processo que uma rede LSTM usa para decidir os dados que serão armazenados pode ser dividido em a porta de esquecimento, de entrada e de saída para a célula de memória C_t , como representado na Figura 3. As equações desses segmentos são descritas pelas Eqs. (2) [12, 13].

$$f_t = \sigma(W_f \cdot x_t + U_f \cdot h_{t-1} + b_f), \quad (2a)$$

$$i_t = \sigma(W_i \cdot x_t + U_i \cdot h_{t-1} + b_i), \quad (2b)$$

$$o_t = \sigma(W_o \cdot x_t + U_o \cdot h_{t-1} + b_o), \quad (2c)$$

$$\tilde{C}_t = \tanh(W_c \cdot x_t + U_c \cdot h_{t-1} + b_c), \quad (2d)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tilde{C}_t, \quad (2e)$$

$$h_t = o_t \circ \tanh(C_t), \quad (2f)$$

onde:

σ – Função sigmóide.

\tanh – Função tangente hiperbólica.

W – Vetor de pesos que interliga a camada oculta anterior a atual.

U – Vetor de pesos que conecta a entrada com a camada oculta.

f_t, i_t, o_t – Vetores de ativação das portas de esquecimento, entrada e saída.


\tilde{C}_t – Vetor de ativação da célula de entrada.

C_t – Vetor da célula de memória.

b – Vetor dos bias.

h_t – Vetor de estado da camada oculta.

Figura 3: Rede Neural Artificial Recorrente LSTM.




Pontua-se que os símbolos \otimes e \oplus na Figura 3 indicam, respectivamente, a exclusão e adição de informação. Esses processos são realizados baseados nas saídas das funções σ e \tanh que variam no intervalo de 0 a 1. Desse modo, quando esses valores são próximos de zero, eles são descartados pela rede (\otimes), caso contrário, são adicionados (\oplus) à memória.

D. Função Linear

A função linear é caracterizada por uma reta que passa na origem do plano de coordenadas, como apresentado na Figura 4.

Figura 4: Rede LSTM.



Uma função linear $f : \mathfrak{R} \rightarrow \mathfrak{R}$ é definida como

$$f(x) = m \cdot x, \quad (3)$$

onde m é o coeficiente angular da reta [14].

III. METODOLOGIA

A RNA construída neste trabalho foi treinada com os dados de precipitação dos anos de 2014 a 2018 divulgados pelo o

Instituto Nacional de Meteorologia (INMET) [15] a partir da coleta realizada pelo Laboratório de Climatologia e Recursos Hídricos (LCRH) do Instituto de Geografia da Universidade Federal de Uberlândia. Para isso, foi utilizada a Estação Meteorológica de Observação de Superfície Automática localizada no Campus Santa Mônica da Universidade.

Para a realização de testes, isto é, análise da eficiência do método em prever precipitações, utilizou-se os índices de chuva dos anos de 2019 e 2020 também publicados pelo INMET. Dessa forma, percebe-se que 71,43% do banco de dados foi destinado ao treinamento e 28,57% aos testes.

Com o objetivo de prever a quantidade de chuva acumulada em 24 horas na cidade de Uberlândia, foi criada neste artigo uma RNR do tipo LSTM. Esta rede é constituída por 2 camadas intermediárias recorrentes, uma de 120 e outra de 60 células de memória, e uma densa com 31 neurônios. Os parâmetros empregados na rede são descritos a seguir.

A. Número de épocas

Para a LSTM desenvolvida neste trabalho, escolheu-se um número de épocas igual a 100. Em testes com valores maiores, como 200 épocas, a rede teve péssimos resultados para dados diferente dos de treinamento, o que caracteriza o *overfitting*. Além disso, para valores muito menores que 100, a rede não conseguiu realizar o aprendizado.

B. Função de Ativação

Nas camadas recorrentes, empregou-se as funções de ativação descritas na Subseção II-C. Entretanto, para a camada densa, foi usada a função linear.

C. Otimizador

O método utilizado para corrigir os pesos é chamado de *otimizador*. Nesse sentido, a RNA proposta utiliza o algoritmo de Adam (Adaptive Moment Estimation) como otimizador [16]. Para a aplicação da técnica os parâmetros foram definidos como $\beta_1 = 0,9$, $\beta_2 = 0,999$ e $\epsilon = 10^{-7}$. Estes valores são os recomendados por Kingma e Ba em [16].

O método de Adam usa o *Gradiente de Descida Estocástica*, que é definido pelo uso de apenas parte dos dados disponíveis por iteração para calcular a função custo. Outrossim, o algoritmo é composto por dois coeficientes conhecidos como momentos, dados por

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (4a)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (4b)$$

em que:

β_1 e β_2 – Coeficientes de decaimento.

g_t – Gradiente da função custo em t .

É comum utilizar os coeficientes \hat{m}_t e \hat{v}_t , para que os momentos não tendam a zero caso sejam inicializados como zero. Portanto, tem-se

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \quad (5a)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}, \quad (5b)$$

Logo, a atualização de Adam é feita pela equação

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \varepsilon} \hat{m}_t, \quad (6)$$

onde o $\varepsilon \ll 1$ impede o valor zero no denominador.

D. Função de Erro

Para calcular o erro realizou-se a média quadrática entre o valor esperado \hat{Y}_i e a previsão Y_i feito pela RNR LSTM. Dessa maneira, tem-se

$$E_q = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}, \quad (7)$$

em que n é o número de amostras.

IV. RESULTADOS

O método desenvolvido neste trabalho foi implementado em Python 3.7 e a criação da RNA foi por intermédio das bibliotecas *TensorFlow* e *keras*. O código foi implementado no IDE (*Integrated Development Environment*) Spyder 5.0.0, que foi executado no sistema operacional Linux Mint Debbie 4, em um computador com 4 GB de memória RAM e processador Intel Core i3-6006U.

Os índices pluviométricos usados nos testes são referentes aos anos de 2014 a 2018 e estão armazenados em arquivos no formato CSV, onde a leitura desses arquivos é feita por meio da biblioteca *Pandas*. Como a simulação utiliza índices de uma em uma hora, estão disponíveis 8759 valores por ano e no caso de 2016 (ano bissexto), são 8783 amostras. Porém, notou-se que, ao longo de cada ano, uma pequena quantidade de horários não foram preenchidos e desse modo, os seus valores foram descartados diminuindo o número de índices de chuva.

A Tabela 1 mostra a quantidade de dados que não foram fornecidos em cada ano.

Tabela 1: Quantidade de índices de chuva por ano

Ano	Valores preenchidos	Valores não preenchidos
2014	8757	2
2015	8758	1
2016	8757	26
2017	8759	0
2018	8758	1

Identifica-se que o ano de 2016 apresenta o maior número de dados não preenchidos. Porém, isso permite que a variação da quantidade de dados entre os anos seja pequena, no máximo de 2 valores.

A precipitação acumulada foi obtida somando-se os índices pluviométricos de uma em uma hora ao longo do dia. Portanto, após realizar esse procedimento, o número total de dados de entrada mudou-se para 1824.

Durante o treinamento da rede, rede e de forma aleatória, 30% dos dados de entrada de cada camada são atribuídos ao

valor numérico zero. Esse processo é denominado *Dropout* e foi realizado para evitar o fenômeno de *overfitting*.

Após a realização do treinamento, a rede LSTM foi empregada para prever o índice de chuva acumulado em 24 horas nos anos de 2019 e 2020. Essa previsão necessita de dados de 7 dias anteriores ao que se deseja obter a precipitação. O período de uma semana foi determinado depois de realizar e analisar testes com valores maiores e menores que este.

Determinar o valor exato da precipitação acumulada em um dia, dependeria de diversos fatores além dos índices de dias anteriores, como pressão atmosférica, temperatura, análise do vento, umidade relativa do ar, identificação dos fenômenos El Niño e La Niña, entre diversos outros. Contudo, é possível estimar, com dados de precipitação, a tendência de chuva, isto é, se ela aumentará, diminuirá ou se ela manter-se-á constante no próximo dia.

Figura 5: Previsão da tendência de chuva acumulada em cada dia do ano de 2019 feita pela RNA em comparação com a precipitação real.


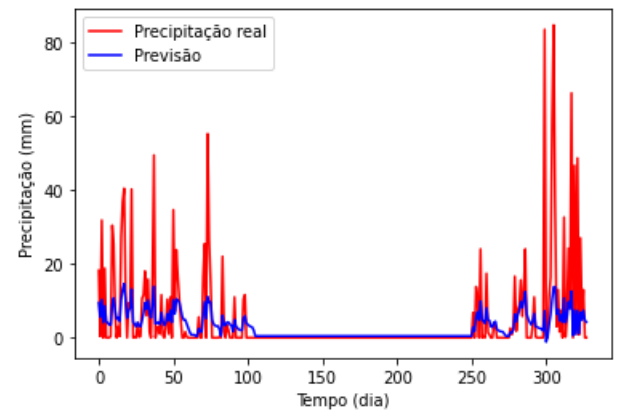


Figura 6: Previsão da tendência de chuva acumulada em cada dia do ano de 2020 feita pela RNA em comparação com a precipitação real.



A Figura 5 mostra a previsão do índice pluviométrico acumulado em cada dia do ano 2019. Nota-se que os valores previstos pela RNA não se aproximam do valor real, porém a RNA consegue determinar a tendência da chuva no dia seguinte. Essa funcionalidade pode ser muito útil, pois, após verificar os dados dos últimos 7 dias, é possível prever se chuva estará mais intensa ou se a tendência é que ela diminua no dia

seguinte sem que haja a análise de fatores como temperatura, velocidade do evento, entre outros.

Figura 7: Previsão da tendência de chuva em cada hora do ano de 2019.

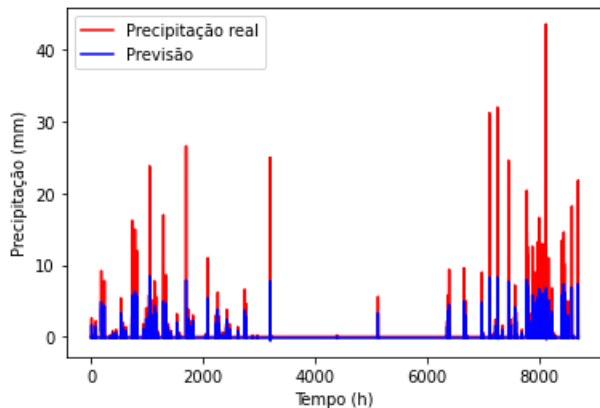
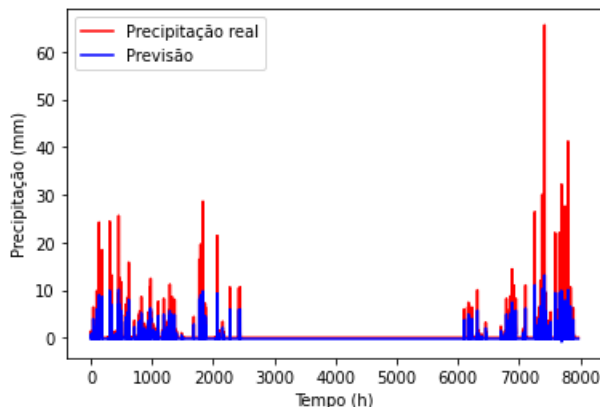


Figura 8: Previsão da tendência de chuva em cada hora do ano de 2020.



Na Figura 6 são exibidos as previsões dos índices de chuva acumulada para o ano de 2020. Ao analisar esse gráfico, verifica-se que os valores previstos são uma ótima tendência para descobrir como a chuva variará nas próximas 24 horas. Afinal, a curva de previsão pela RNA acompanhou o crescimento e decréscimo da precipitação real na grande maioria dos pontos.

Ao atribuir o valor 1 para crescimento, -1 para decréscimo e 0 para manutenção da chuva, percebe-se que, para o ano de 2019, em 73,46% dos casos, a previsão determinou corretamente se nos próximos dias terá aumento, diminuição ou inalteração da chuva acumulada. Enquanto isso, para o ano de 2020, esse acerto foi de 83,84%.

Treinou-se a LSTM para prever também o índice de chuva na próxima 1 hora. Isso foi feito com o intuito de comparar a previsão para precipitação acumulada em 1 hora e 24 horas.

Para executar o treinamento para cada hora, utilizou-se apenas os dados do ano de 2018. Isso porque, apenas este ano já tem um total de 8758 dados, o que já é o suficiente para treinar a rede e proporcionar bons resultados. A determinação de cada hora foi feita a partir das 72 horas anteriores.

A Figura 7 apresenta o gráfico dos índices de chuva em cada hora nos anos de 2019. Percebe-se que a curva de previsão acompanhou o crescimento e decréscimo das taxas de chuva.

Neste ano, em 89,33% dos casos, a previsão determinou acertadamente se nos próximos dias terá crescimento, decréscimo ou inalteração da taxa de chuva acumulada.

A Figura 8 mostra o gráfico dos índices de chuva em cada hora nos anos de 2020. Neste ano, as chuvas foram menos espaçadas no tempo em comparação com 2019, porém, apesar disso, a curva de previsão conseguiu apontar a tendência de precipitação com uma precisão de 87,95%.

V. CONCLUSÃO

Este trabalho permite a modelagem matemática da tendência de precipitação na cidade de Uberlândia por meio de Redes Neurais Artificiais Recorrentes do tipo LSTM. Esta rede utiliza dados em suas memórias para prever valores, o que é muito útil para predição de séries temporais.

A RNA foi treinada com os dados de precipitação dos anos de 2014 a 2018 da cidade de Uberlândia disponibilizados pelo INMET. Para fins de teste de eficiência, essa rede foi usada para prever os índices de chuva de 2019 e 2020.

A partir dos gráficos gerados em cada ano, percebeu-se que a rede LSTM desenvolvida apresentou bons resultados na previsão das chuvas em cada dia dos anos testados. Isso ocorreu independente do espaçamento entre as chuvas e de suas intensidades.

Com o intuito de mostrar que a porcentagem de acerto aumenta com a diminuição do tempo de previsão, o ano de 2018 foi usado para treinar uma rede com os valores de precipitação a cada 1 hora. Assim, foi possível estimar com mais acerto a tendência dos índices de chuva dos anos de 2019 e 2020. Porém, a previsão da próxima 1 hora pode, dependendo da aplicação, não ser tão útil quanto a estimativa para as próximas 24 horas.

REFERÊNCIAS

- [1] J. E. Dayhoff, *Neural network architectures: an introduction*. Van Nostrand Reinhold Co., 1990.
- [2] S. Soffer, A. Ben-Cohen, O. Shimon, M. M. Amitai, H. Greenspan, and E. Klang, "Convolutional neural networks for radiologic images: a radiologist's guide," *Radiology*, vol. 290, no. 3, pp. 590–606, 2019.
- [3] M. Hüsken and P. Stagge, "Recurrent neural networks for time series classification," *Neurocomputing*, vol. 50, pp. 223–235, 2003.
- [4] K. Abhishek, M. Singh, S. Ghosh, and A. Anand, "Weather forecasting model using artificial neural network," *Procedia Technology*, vol. 4, pp. 311–318, 2012.
- [5] X. Li, Y. Zheng, X. Wang, and L. Wang, "Predicting solar flares using a novel deep convolutional neural network," *The Astrophysical Journal*, vol. 891, no. 1, p. 10, 2020.
- [6] F. Beritelli, G. Capizzi, G. L. Sciuto, C. Napoli, and F. Scaglione, "Rainfall estimation based on the intensity of the received signal in a lte/4g mobile terminal

- by using a probabilistic neural network,” *IEEE Access*, vol. 6, pp. 30865–30873, 2018.
- [7] M. N. Ahuna, T. J. Afullo, and A. A. Alonge, “Rainfall rate prediction based on artificial neural networks for rain fade mitigation over earth-satellite link,” in *2017 IEEE AFRICON*, pp. 579–584, IEEE, 2017.
- [8] L. J. Ippolito Jr, *Satellite communications systems engineering: atmospheric effects, satellite link design and system performance*. John Wiley & Sons, 2017.
- [9] R. Y. Ynoue, M. S. Reboita, T. Ambrizzi, and G. A. da Silva, *Meteorologia: noções básicas*. Oficina de Textos, 2017.
- [10] S. Haykin, *Redes neurais: princípios e prática*. Bookman Editora, 2007.
- [11] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [12] C. Olah, “Understanding lstm networks,” 2015. Disponível em <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- [13] Y. Yu, X. Si, C. Hu, and J. Zhang, “A review of recurrent neural networks: Lstm cells and network architectures,” *Neural computation*, vol. 31, no. 7, pp. 1235–1270, 2019.
- [14] P. BOULOS and I. CAMARGO, *Geometria Analítica-Um tratamento vetorial*. São Paulo: Ed. Prentice Hall Brasil, 2005.
- [15] INMET, “Dados históricos de precipitação,” Disponível em <https://bdmep.inmet.gov.br/>. Acessado em 18/07/2021.
- [16] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” *arXiv preprint arXiv:1412.6980*, 2014.