

Uma Avaliação do Impacto da Resolução de Dados na Previsão Antecipada de Chuva para Mitigação de Falhas em Redes

Guilherme S. E. Ferreira, Rafael P. S. Gomes, Dianne S. V. Medeiros

Resumo— Chuvas podem interromper a disponibilidade de serviços de telecomunicações ao danificar cabos de fibra ótica e provocar falhas em enlaces de rádio. A recuperação do serviço pode ser lenta e complexa, afetando por longos períodos residências, empresas e prestadores de serviços essenciais. A previsão de eventos climáticos permite antecipar medidas preventivas para evitar as interrupções. As redes neurais têm se mostrado promissoras para prever esses eventos, mas o custo de treinamento tende a ser elevado. Este artigo avalia o desempenho de uma Rede Neural Recorrente (*Recurrent Neural Network - RNN*) para prever o volume de chuva a partir de dados em diversas resoluções temporais usados para treinar o modelo. Avalia-se o impacto das resoluções na eficiência do modelo a partir do erro médio absoluto e da raiz do erro quadrático médio. Os resultados mostram que resoluções menores são mais eficientes. A resolução de 8 dias se destaca com baixo tempo de treinamento, baixo erro e melhor adaptação aos pontos discrepantes que representam chuvas fortes, além de permitir o planejamento de ações para mitigar os efeitos nocivos do evento climático na rede.

Palavras-Chave— Análise de desempenho, RNN, previsão de chuva.

Abstract— Rain can disrupt the availability of telecommunications services by damaging fiber optic cables and causing failures in radio links. Service recovery can be slow and complex, affecting residences, businesses, and essential service providers for extended periods. Forecasting of weather events allows for the anticipation of preventive measures to avoid interruptions. Neural networks have been shown to be promising in predicting these events, but the training cost tends to be high. This paper evaluates the performance of a Recurrent Neural Network (RNN) to predict rainfall volume based on data in various temporal resolutions used to train the model. The impact of the resolutions on model efficiency is assessed using the Mean Absolute Error (MAE) and Root Mean Squared Error (RMSE). The results show that lower resolutions are more efficient. The 8-day resolution stands out with low training time, low error, and better adaptation to outliers that represent heavy rainfall, allowing for the planning of actions to mitigate the harmful effects of the weather event on the network.

Keywords— Performance Analysis, RNN, Rainfall Prediction.

I. INTRODUÇÃO

As fortes chuvas causam avarias na infraestrutura de rede, trazendo prejuízos à vida e à nação. No Rio Grande do Sul, por exemplo, as fortes chuvas ocorridas em Abril de 2024

Guilherme Ferreira e Dianne Medeiros, Departamento de Engenharia de Telecomunicações. Rafael Gomes, Departamento de Engenharia Agrícola e Meio Ambiente. Universidade Federal Fluminense, Niterói-RJ, e-mail: {guilhermesef,diannescherly,rafaelporto}@id.uff.br. Este trabalho é parcialmente financiado por CNPq, CAPES, FAPERJ, Prefeitura de Niterói/FEC/UFF (Edital PDPA 2020) e RNP.

interromperam a conectividade em 220 dos 497 municípios, prejudicando a busca por feridos e a reorganização do estado. As consequências dessas chuvas poderiam ser mitigadas caso houvesse um sistema de alerta antecipado. No entanto, esses sistemas são complexos porque eventos extremos que provocam catástrofes naturais, como tempestades que inundam cidades, têm uma natureza caótica [1].

A previsão numérica de tempo é o método tradicional para prever chuvas fortes. Os modelos matemáticos simulam a atmosfera e preveem o estado futuro do clima utilizando séries históricas e supercomputadores. Esse método, no entanto, pode não ser apropriado para previsão regional em futuro próximo devido à baixa resolução temporal e espacial [2]. Sistemas de alerta antecipado são dependentes de conhecer a previsão para o futuro próximo para que os alertas sejam gerados. Dessa forma, uma abordagem alternativa é necessária para complementar as previsões numéricas em uma escala temporal e espacial menor. Esse complemento pode ser feito por classificadores que preveem a ocorrência de chuva e regressores que preveem o volume de chuva [3].

Diversos trabalhos focam na previsão de chuvas utilizando algoritmos de aprendizado profundo, obtendo modelos assertivos com variadas estruturas e tipos de redes neurais [4]. Normalmente, redes neurais apresentam melhor desempenho quando são usadas para prever o nível de precipitação anual [5]. Outros trabalhos utilizam algoritmos de aprendizado de máquina, como a regressão linear, para realizar a previsão [6]. Nesse contexto, este artigo avalia o desempenho de uma Rede Neural Recorrente treinada em um conjunto de dados com 5 anos de registros de informações meteorológicas¹ para prever o volume de precipitação, a fim de permitir as operadores anteciparem medidas para mitigar os efeitos da chuva nos sistemas de telecomunicações. Para isso, são avaliadas resoluções de dados distintas, a fim de identificar a resolução que resulta em baixo erro, com baixa sobrecarga de treinamento e com antecipação suficiente para elaboração e implantação das contramedidas. Os erros utilizados para avaliar o desempenho dos modelos obtidos são a Raiz do Erro Quadrático Médio (*Root Mean Squared Error - RMSE*) e o Erro Médio Absoluto (*Mean Absolute Error - MAE*). São avaliadas resoluções de 2, 4, 8 e 16 horas, 1, 2, 4, 8 e 16 dias, e 1 mês. Os resultados mostram que o agrupamento dos dados em resoluções mais baixas, isto é, janelas de tempo maiores,

¹Subconjunto de 5 anos obtidos a partir do conjunto de dados público disponível em <https://portal.inmet.gov.br/dadoshistoricos>

leva a erros menores e reduz o tempo de treinamento, visto que a quantidade de dados de entrada também é reduzida. Contudo, em resoluções intermediárias, como 8 dias, a sobrecarga de treinamento é muito baixa e o RMSE diminui em 87%. Além disso, a diferença entre o RMSE e o MAE é insignificante, indicando que o modelo obtido se adapta melhor aos pontos discrepantes existentes no conjunto de dados, sendo, portanto, mais confiável para identificar chuvas fortes. A antecipação de pelo menos 8 dias já permite programar ações para mitigar possíveis falhas na rede de telecomunicações.

II. TRABALHOS RELACIONADOS

Tendo em vista a importância da previsão de variáveis ambientais como a precipitação em determinados cenários, especialmente quando existem risco à vida e vulnerabilidades de infraestruturas, a otimização e eficácia dos modelos de previsão se torna um campo de estudo necessário. Cramer et al. [7] comparam o desempenho de um algoritmo de estado-da-arte, a Cadeia de Markov estendida para predição de chuva, com o desempenho de seis algoritmos de inteligência artificial, incluindo aprendizado profundo. Os algoritmos de inteligência artificial superam o desempenho da cadeia de Markov estendida, indicando que os sistemas de predição de chuva podem se beneficiar desses algoritmos.

Considerando a relevância dos modelos de aprendizado profundo, Barrera-Animas et al. [8] comparam diversos modelos utilizando esse tipo de aprendizado. O estudo apresenta modelos baseados em *Long Short-Term Memory* (LSTM), tanto com camadas empilhadas como bidirecionais. Além disso, modelos de regressão também são utilizados, como vetor de suporte linear e *gradient boosting*. O estudo utiliza 20 anos de dados coletados em cinco cidades do Reino Unido, tendo como objetivo a previsão de chuva com 8 horas de antecedência, atualizando o modelo com 1 hora de intervalo de dados coletados para cada previsão. Os desempenhos são avaliados pelas métricas de erro RMSE, Erro Médio Quadrático (*Mean Squared Error* - MSE) e a Raiz do Erro Quadrático Médio Logarítmico (*Root Mean Squared Logarithmic Error* - RMSLE). Os resultados do estudo apontam para a eficácia tanto do LSTM de camadas empilhadas como do LSTM bidirecional na previsão de chuva no intervalo determinado.

Ferreira et al. [9] comparam 10 algoritmos de regressão para predição de volume de chuva nas cidades de São Paulo, Belém, Curitiba, Goiânia e Salvador utilizando um espaço temporal de 13 anos. Os modelos são avaliados pelas métricas RMSE e coeficiente de determinação, R^2 . Os resultados mostram que os algoritmos Floresta Aleatória e Polinomial de grau 3 apresentam os melhores resultados.

Aswin et al. [10] apresentam os resultados de previsão para modelos de aprendizado profundo, especificamente LSTM e Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNNs). A avaliação dos resultados é realizada utilizando o RMSE. Os dados utilizados são provenientes do Projeto de Climatologia de Precipitação Global (GPCP), que cobre uma área global do período de 1979 até 2018, contendo estimativas com base em dados de satélite e pluviômetros em campo. Para o estudo, o parâmetro considerado para previsão

é a média mensal global de chuva, em milímetros. O resultado aponta para uma maior eficácia do modelo CNN, que apresenta um RMSE de 2,44 mm com apenas 100 épocas de treinamento, enquanto que o LSTM apresenta 2,55 com 1000 épocas. Os autores destacam ainda que a eficácia desses modelos pode ser ainda superior com a implementação de mais camadas ocultas, permitindo um ajuste fino do modelo.

Ainda ressaltando o potencial desses modelos, Hussain et al. [11] apresenta uma análise comparativa de diversos estudos que aplicam modelos de aprendizado profundo para previsão de chuva. Dos 45 estudos analisados, 26 usaram parâmetros meteorológicos para a previsão, 13 usaram imagens de radar, e 6 usaram imagens de satélite para treino e teste dos modelos. A resolução dos dados meteorológicos usados nos estudos varia entre 10 minutos, 15 minutos, 1 hora, 3 horas, 6 horas, resolução diária, mensal, e finalmente anual. Os modelos usados são: LSTM, CNN, Rede Neural Profunda (*Deep Neural Network* - DNN), dentre outros. Através dessa análise, Hussain et al. destaca que não apenas os modelos de aprendizado profundo são eficazes na previsão de chuvas, como também são superiores a métodos de aprendizado de máquina tradicionais e redes neurais de poucas camadas.

A resolução dos dados é uma escolha que influencia diretamente na eficácia dos algoritmos e na interpretação dos resultados. Por exemplo, Yonekura et al. [12] buscam uma previsão de curto prazo de 10 minutos, fazendo uma comparação de desempenho entre um modelo DNN com Máquina de Vetor Suporte (*Support Vector Machine* - SVM), XGBoost, Floresta Aleatória (*Random Forest* - RF) e Previsão Aleatória (*Random Prediction* - RP). Os resultados mostram que o modelo DNN apresenta maior assertividade na previsão de chuva. A utilização de imagens de radar permite alcançar resoluções muito altas, chegando a 2 minutos, como apresentam Agrawal et al. [13]. Os autores utilizam a arquitetura U-Net para CNN com resolução espacial de 1 x 1 km, e avaliam a precisão e o *recall*. O modelo proposto supera os modelos Multi-Radar/Multi-Sensor System persistence e fluxo ótico High-Resolution Rapid Refresh, utilizado pela *National Oceanic and Atmospheric Administration* (NOAA) nos Estados Unidos. Por outro lado, Manoj S. et al. [14] utilizam resoluções notavelmente menores para dados meteorológicos. Os autores organizam os conjuntos de dados em resoluções mensais, trimestrais, e anuais, comparando os métodos Convolutional Long Short-Term Memory (ConvLSTM), Cyclic Learning Rate (CLR), Multi-Layer Perceptron (MLP) e Deep Spatial-Temporal Model for Imbalanced Anomalies (DSMIA) com o método proposto ConvLSTM ajustado com gradiente S-SGD (Stochastic Gradient Descent). O desempenho do modelo proposto no trabalho supera os demais ao considerar as métricas Peak-Relative Difference (PRD) e MSE.

Este trabalho segue a mesma linha de avaliação de resoluções distintas para treinar os modelos de predição. Diferentemente, além de avaliar diversas resoluções de dados, busca encontrar o melhor custo-benefício em termos de assertividade e sobrecarga de treinamento, avaliando também o tempo de treinamento, com o objetivo de identificar uma resolução que permita um treinamento rápido com baixo erro e antecedência suficiente para mitigar impactos na rede.

III. METODOLOGIA

Utiliza-se a biblioteca *TensorFlow* do Python para criar os modelos e a biblioteca *Sci-kit Learn* para treinar e testar utilizando o algoritmo *GridSearchCV* para otimização de parâmetros. O computador utilizado possui um processador Ryzen 5 5600, 32 GB de RAM e Windows 11 como sistema operacional. Seleciona-se a cidade de Belém como conjunto de dados, por apresentar chuva praticamente diária, facilitando o aprendizado do modelo. São utilizadas 10 resoluções temporais de dados para gerar e treinar os modelos individualmente. O conjunto de dados sempre é dividido em uma proporção de dados de treino/teste de 70%/30%. O conjunto de dados utilizado engloba 5 anos de registros com resolução horária e são utilizadas resoluções mais baixas para agrupar esses dados. Assim, os registros são resumidos pela média em resoluções de [2, 4, 6, 8, 16] horas, [1, 2, 4, 8, 16] dias e 1 mês. As variáveis independentes usadas para prever o volume de Precipitação Total (PCT) são Pressão Atmosférica ao Nível da Estação (PAE), Pressão Atmosférica Reduzida ao Nível do Mar (PARM), Pressão Atmosférica Máxima na Hora Anterior (PAMA), Pressão Atmosférica Mínima na Janela Anterior (PAMI), Temperatura do Ar de Bulbo Seco (TABS), Temperatura do Ponto de Orvalho (TPO), Temperatura Máxima na Janela Anterior (TMA), Temperatura Mínima na Janela Anterior (TMI), Temperatura de Orvalho Máxima na Janela Anterior (TOMA), Temperatura de Orvalho Mínimo na Janela Anterior (TOMI), Umidade Relativa Máxima na Janela Anterior (URMA), Umidade Relativa Mínima na Janela Anterior (URMI), Umidade Relativa do Ar (URA), Direção do Vento (DV), Vento em Rajada Máxima (VRM) e Velocidade do Vento (VV). O pré-processamento realizado consiste em verificar a duplicidade, a ausência de dados e a existência de dados errados. Os registros com dados incompletos e com valores incoerentes, como -9999, que representam erro de medição, são preenchidos através de interpolação linear. Não há dados duplicados.

O desempenho de cada modelo é avaliado por meio da análise do RMSE e do MAE obtidos para o conjunto de teste. Utiliza-se o RMSE por prover informações sobre o desempenho a curto prazo de um modelo, possibilitando uma comparação entre o valor real e o previsto. Ademais, erros grandes na predição do volume de chuva podem ser graves e o RMSE se caracteriza por penalizar mais esses erros. Por outro lado, o MAE considera cada erro de forma linear, ou seja, os pontos discrepantes não influenciam fortemente a avaliação, de forma que todos os erros são penalizados de forma aproximadamente igual.

O algoritmo *GridSearchCV* é utilizado sobre o conjunto de dados de treinamento para encontrar os melhores hiperparâmetros para cada modelo. A Tabela I mostra o espaço de busca utilizado. A fim de diminuir o sobreajuste, a busca pelos melhores parâmetros é combinada com a técnica de validação cruzada (*Cross Validation - CV*), que divide a base de dados aleatoriamente em K subconjuntos, e em cada iteração $K-1$ subconjuntos são utilizados para treino e o restante para teste, garantindo que todos os conjuntos sejam alguma vez utilizados para teste e treino. O valor $K = 5$ é usado neste trabalho.

TABELA I: Espaço de busca de hiperparâmetros para o *GridSearchCV*.

Hiperparâmetro	Valores
Camadas	(64, 32), (32, 64), (128, 64, 32), (64, 128, 32), (32, 64, 128)
Função de ativação	relu, swish
Taxa de abandono	0.1, 0.2, 0.3
Tamanho do lote	256, 512, 1024
Épocas	500, 1000
Taxa de aprendizado	0.001, 0.01, 0.1

TABELA II: Melhores hiperparâmetros encontrados

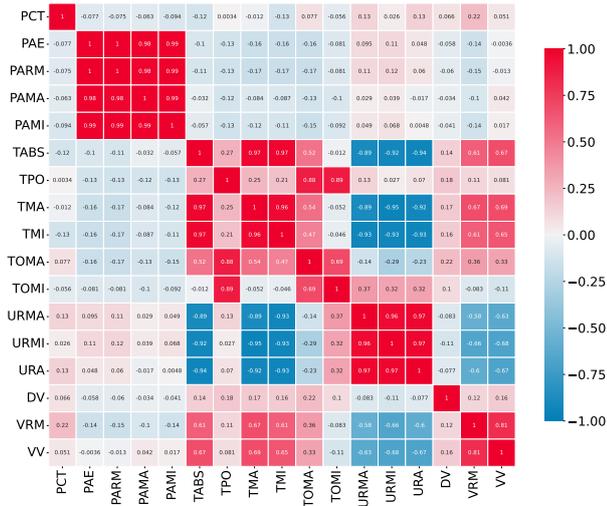
	2H	4H	8H	16H	1D
Tamanho do lote	1024	256	256	256	256
Épocas	1000	1000	1000	500	500
Função de ativação	swish	relu	swish	relu	swish
Taxa de abandono	0.1	0.1	0.1	0.1	0.2
Camadas	(128,64,32)	(64,32)	(64,32)	(64,32)	(64,32)
Taxa de aprendizado	0.001	0.001	0.001	0.001	0.001

	2D	4D	8D	16D	1M
Tamanho do lote	512	1024	256	1024	256
Épocas	1000	1000	1000	1000	1000
Função de ativação	swish	swish	swish	swish	relu
Taxa de abandono	0.1	0.1	0.1	0.1	0.1
Camadas	(128,64,32)	(128,64,32)	(128,64,32)	(128,64,32)	(64, 128, 32)
Taxa de aprendizado	0.001	0.001	0.001	0.001	0.001

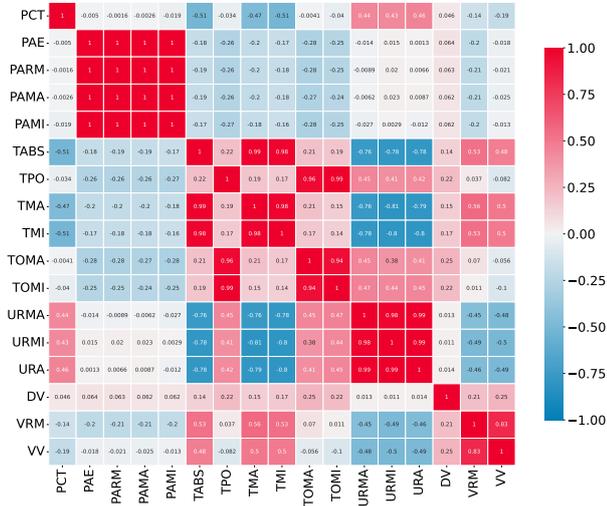
A Tabela II mostra os hiperparâmetros encontrados para o melhor modelo usando o *GridSearchCV*. Percebe-se que o método de ativação *swish*, a taxa de abandono de 0,1, o número de épocas de 1.000, as camadas com (128,64,32) neurônios e a taxa de aprendizado de 0,001 são predominantes, sendo escolhidos para a maioria das resoluções utilizadas. O custo computacional de cada modelo pode ser medido em FLOPs (*Floating Point Operations*), que indica a quantidade de operações de ponto flutuante necessárias em uma passagem para frente (*forward*), independentemente do tempo que o modelo precisa para executá-las. Destaca-se que essa medida não é afetada pela quantidade de dados de entrada, mas sim pela complexidade do modelo construído. A quantidade de FLOPs necessárias para cada modelo é 1.581.312 para as resoluções de 4H e 16H, 1.630.464 para 8H e 1D, 6.414.592 para 2H, 2D, 4D, 8D e 16D, e 6.856.960 para 1M.

IV. RESULTADOS E DISCUSSÃO

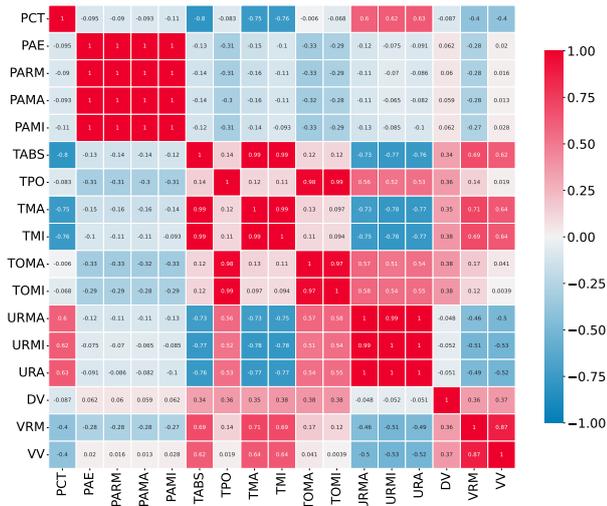
A Figura 1 apresenta a matriz de correlação para resoluções de 2 horas, 1 dia e 1 mês. Utiliza-se o coeficiente de Pearson, r , para o qual $r = 1$ sugere correlação positiva perfeita, $0.5 \leq r < 1$ sugere forte correlação positiva, $0.3 \leq r < 0.5$ sugere correlação moderada positiva, $0 < r < 0.3$ sugere fraca correlação positiva e $r = 0$ sugere não haver correlação entre as variáveis. De forma análoga, valores negativos implicam correlações negativas fracas/moderadas/fortes. Percebe-se um aumento da correlação da precipitação total, PCT, com as outras variáveis quando diminui-se a resolução dos dados. Isso ocorre porque com o aumento da janela, isto é, a redução da resolução, agrupando os dados pela média, diminui-se a quantidade de pontos discrepantes, suavizando-se a curva. Dessa forma, o comportamento da precipitação torna-se mais linear, aumentando a correlação linear entre as variáveis. As Figuras 2(a) e 2(b) mostram os dados agrupados pela média com uma resolução de 2 horas e de 1 mês, respectivamente. A precipitação é diretamente correlacionada à URMA, à URMI



(a) Resolução de 2 horas.



(b) Resolução de 1 dia.

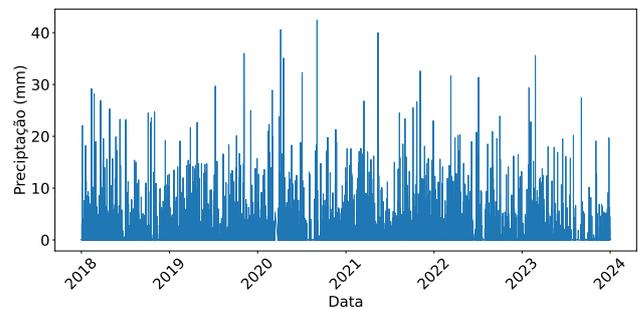


(c) Resolução de 1 mês.

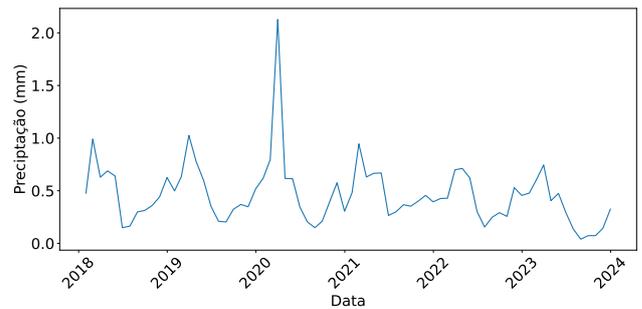
Fig. 1: Correlação de Pearson entre as variáveis para diferentes resoluções de dados.

e à URA, começando em uma fraca correlação para resolução de 2 horas, aumentando para moderada em uma resolução de 1 dia e alcançando uma correlação forte para 1 mês. Ao mesmo tempo, a precipitação é inversamente correlacionada à TABS e à TMI, também aumentando a intensidade da correlação quando a resolução diminui. Destaca-se que para uma resolução de 2 horas, praticamente não ha correlação entre a precipitação e a TMA, mas à medida que a resolução diminui, a correlação com essa variável passa a ser forte. Nota-se também que a correlação com as variáveis referentes à pressão atmosférica é praticamente nula, enquanto a velocidade do vento, VV, apresenta correlação moderada para a resolução de 1 mês, e a velocidade da rajada máxima do vento, VRM, está fracamente correlacionada apenas ao analisar a resolução de 2 horas. Esse comportamento pode ser explicado pelo clima tropical úmido da região de Belém, no qual predominam altas temperaturas que aumentam a evaporação dos corpos d'água, resultando em alta umidade relativa, que é a medida da quantidade de vapor d'água no ar. A chuva, por sua vez, ocorre devido à condensação desse vapor que acontece quando a temperatura do ar cai abaixo da temperatura de orvalho. O vento pode afetar afastando as nuvens carregadas e afetando o sistema de evaporação e condensação da água. As outras variáveis estão fracamente correlacionadas ou praticamente decorrelacionadas com a precipitação. Dado que somente na menor resolução há uma correlação forte entre as variáveis e a precipitação, pode haver dificuldade dos modelos em encontrar padrões para resoluções maiores.

A Figura 3 mostra os valores de RMSE e MAE obtidos para os modelos de RNN treinados com as diferentes resoluções de dados. O intervalo de confiança utilizado é de 95%. Nota-



(a) Resolução de 2 horas.



(b) Resolução de 1 mês.

Fig. 2: Volume de precipitação em diferentes resoluções.

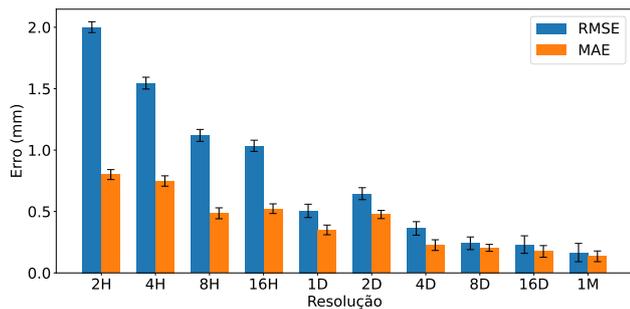


Fig. 3: RMSE e MAE para cada resolução de dados.

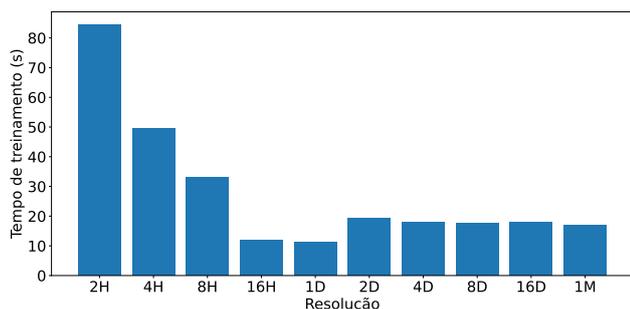


Fig. 4: Tempo necessário para treinamento.

se uma discrepância entre os valores de RMSE e MAE que tende a diminuir com a redução da resolução dos dados. A partir de 8 dias, não há significância estatística na diferença entre esses erros. Uma maior discrepância entre os erros indica que os modelos não são capazes de se ajustarem aos pontos discrepantes. Dessa forma, considera-se que a partir de uma resolução de 8 dias, os modelos obtidos são mais confiáveis, pois, além de apresentar baixo erro, a diferença entre o MAE e o RMSE é insignificante.

A Figura 4 mostra o tempo necessário de treinamento do melhor modelo encontrado para cada janela. Os melhores modelos são treinados com os parâmetros apresentados na Tabela II. Percebe-se uma redução considerável no tempo de treinamento com a redução da resolução, tendendo a permanecer constante para resoluções menores do que 2 dias. Essa redução ocorre principalmente devido à menor quantidade de registros existentes para resoluções maiores, visto que mais dados passam a ser resumidos pela média.

Os resultados provam que o uso de um banco de dados com um resolução menor é extremamente aplicável no cenário de um previsão de chuva no tempo distante de 8 dias a 1 mês. O erro é baixo e o modelo é mais confiável, sendo a informação obtida antecipadamente útil para que a operadora prepare a sua infraestrutura para que, durante o evento climático, não haja interrupção no serviço oferecido. Além disso, a baixa sobrecarga de treinamento influencia no custo de operação, podendo ser utilizadas máquinas mais simples sem levar uma quantidade de tempo relevante.

V. CONCLUSÕES

Este artigo avaliou o impacto da resolução dos dados climáticos no desempenho de um modelo de previsão de

chuva treinado com uma RNN, a fim de fornecer informações antecipadas sobre eventos climáticos que podem prejudicar o funcionamento de sistemas de telecomunicações. O modelo ótimo foi obtido a partir dos melhores hiperparâmetros encontrados por uma busca em grade. Além de avaliar o desempenho dos modelos, também foi estudada a correlação entre as variáveis independentes e o volume de precipitação. Os resultados mostraram que em resoluções menores a correlação entre as variáveis se torna mais forte. Isso levou à obtenção de modelos melhores, com erros mais baixos, e a uma sobrecarga de treinamento significativamente menor. No contexto estudado, as RNNs se mostram promissoras para previsão em futuro próximo, com baixo custo computacional. Como trabalhos futuros, pretende-se refinar os modelos para prever chuvas moderadas a fortes que têm grande potencial de provocar falhas nas redes de telecomunicações. Ademais, pretende-se avaliar outras cidades que apresentam um comportamento de chuvas mais errático comparado à cidade de Belém.

REFERÊNCIAS

- [1] S.-H. Moon, Y.-H. Kim, Y. H. Lee, and B.-R. Moon, "Application of machine learning to an early warning system for very short-term heavy rainfall," *Journal of Hydrology*, vol. 568, pp. 1042–1054, 2019.
- [2] A. Kumar, T. Islam, Y. Sekimoto, C. Mattmann, and B. Wilson, "Convcast: An embedded convolutional LSTM based architecture for precipitation nowcasting using satellite data," *PLoS ONE*, vol. 15, no. 3, pp. 1–18, 03 2020. [Online]. Available: <https://doi.org/10.1371/journal.pone.0230114>
- [3] J. A. Weyn, D. R. Durran, and R. Caruana, "Can machines learn to predict weather? using deep learning to predict gridded 500-hpa geopotential height from historical weather data," *Journal of Advances in Modeling Earth Systems*, vol. 11, no. 8, pp. 2680–2693, 2019.
- [4] S. Aswin, P. Geetha, and R. Vinayakumar, "Deep learning models for the prediction of rainfall," in *International Conference on Communication and Signal Processing (ICCSP)*, 2018, pp. 0657–0661.
- [5] M. P. Darji, V. K. Dabhi, and H. B. Prajapati, "Rainfall forecasting using neural network: A survey," in *International Conference on Advances in Computer Engineering and Applications*, 2015, pp. 706–713.
- [6] S. K. Mohapatra, A. Upadhyay, and C. Gola, "Rainfall prediction based on 100 years of meteorological data," in *Int. Conf. on Comp. and Comm. Tech. for Smart Nation (IC3TSN)*, 2017, pp. 162–166.
- [7] S. Cramer, M. Kampouridis, A. A. Freitas, and A. K. Alexandridis, "An extensive evaluation of seven machine learning methods for rainfall prediction in weather derivatives," *Expert Systems with Applications*, vol. 85, pp. 169–181, 2017.
- [8] A. Y. Barrera-Animas, L. O. Oyedele, M. Bilal, T. D. Akinosho, J. M. D. Delgado, and L. A. Akanbi, "Rainfall prediction: A comparative analysis of modern machine learning algorithms for time-series forecasting," *Machine Learning with Applications*, vol. 7, p. 100204, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S266682702100102X>
- [9] G. S. E. Ferreira and D. S. V. Medeiros, "Uma avaliação de algoritmos de regressão para previsão de volume de chuva," in *Anais do Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*, 2022.
- [10] S. Aswin, P. Geetha, and R. Vinayakumar, "Deep learning models for the prediction of rainfall," in *International Conference on Communication and Signal Processing (ICCSP)*, 2018, pp. 0657–0661.
- [11] J. Hussain and C. Zoremsanga, "A survey of rainfall prediction using deep learning," in *3rd International Conference on Electrical, Control and Instrumentation Engineering (ICECIE)*, 2021, pp. 1–10.
- [12] K. Yonekura, H. Hattori, and T. Suzuki, "Short-term local weather forecast using dense weather station by deep neural network," in *IEEE International Conference on Big Data (Big Data)*. IEEE, Dec. 2018.
- [13] S. Agrawal, L. Barrington, C. Bromberg, J. Burge, C. Gazen, and J. Hickey, "Machine learning for precipitation nowcasting from radar images," *arXiv preprint arXiv:1912.12132*, 2019.
- [14] O. M. S and A. J P, "Mapreduce and optimized deep network for rainfall prediction in agriculture," *The Computer Journal*, vol. 63, no. 1, pp. 900–912, 2020.