

## PREVISÃO DE PRECIPITAÇÃO MENSAL NO MUNICÍPIO DE BARRA MANSA/RJ USANDO TÉCNICAS DE *DEEP LEARNING TIME SERIES*

V. A. SILVA\*, M. P. OLIVEIRA, F. L. SANTOS  
Universidade do Estado do Rio de Janeiro\*  
ORCID ID: <https://orcid.org/0009-0009-9008-4095>\*  
[vinicius.silva@profagua.uerj.br](mailto:vinicius.silva@profagua.uerj.br)\*

Submitted June 5, 2023 - Accepted December 1, 2023

DOI: 10.15628/holos.2023.16340

## MONTHLY RAINFALL FORECAST IN THE MUNICIPALITY OF BARRA MANSA/RJ USING DEEP LEARNING TIME SERIES TECHNIQUES

### ABSTRACT

Precipitation forecasting is essential for sectors such as water resources management and urban planning. In this study, a deep learning model was developed to predict rainfall in Brazilian cities, focusing on the municipality of Barra Mansa, Rio de Janeiro. Four neural network architectures were tested: FCN, Resnet, ResCNN and InceptionTime. Among them, FCN stood out significantly, presenting the lowest error rates and the best overall

adjustment. The study highlights the ability of deep learning, especially through the FCN (Fully Convolutional Network - Segmented) architecture, to make accurate predictions and uncover hidden rainfall patterns. Such discoveries have great potential to improve rainfall forecasting systems and assist in decision-making in areas that require accurate climate information.

**KEYWORDS:** Forecasting, precipitation, rainfall, deep learning, neural networks

## PREVISÃO DE PRECIPITAÇÃO MENSAL NO MUNICÍPIO DE BARRA MANSA/RJ USANDO TÉCNICAS DE *DEEP LEARNING TIME SERIES*

### RESUMO

A previsão de precipitações é essencial para setores como gestão de recursos hídricos e planejamento urbano. Neste estudo, foi desenvolvido um modelo de aprendizagem profunda (*deep learning*) para prever chuvas em cidades brasileiras, com foco no município de Barra Mansa, Rio de Janeiro. Foram testadas quatro arquiteturas de redes neurais: FCN, Resnet, ResCNN e InceptionTime. Dentre elas, a FCN se destacou significativamente, apresentando os menores índices de

erro e o melhor ajuste global. O estudo evidencia a capacidade da aprendizagem profunda, especialmente através da arquitetura FCN, em fazer previsões precisas e desvendar padrões ocultos das chuvas. Tais descobertas possuem grande potencial para aprimorar sistemas de previsão de chuvas e auxiliar na tomada de decisões em áreas que necessitam de informações climáticas acuradas.

**Palavras chave:** Previsão, precipitação, chuvas, aprendizagem profunda, redes neurais.

## 1 INTRODUÇÃO

A previsão precisa e confiável das condições meteorológicas é essencial para diversos setores, desde agricultura e energia até gestão de recursos hídricos e prevenção de desastres naturais. Um dos aspectos fundamentais nesse processo é a previsão de precipitações, que desempenha um papel crucial na compreensão dos padrões climáticos e na tomada de decisões informadas (BABA et al., 2014).

Neste contexto, a compreensão aprofundada do regime pluviométrico de uma região é essencial para a tomada de decisões estratégicas, especialmente em ambientes urbanos. Em particular, a capacidade de antecipar precipitações intensas e inundações torna-se uma ferramenta vital para a sociedade, permitindo a implementação de medidas preventivas e a redução significativa dos impactos negativos associados a eventos climáticos extremos (TAVARES DINIZ, 2013). Com o avanço das tecnologias de inteligência artificial, a aplicação de algoritmos de Aprendizagem de Máquina (Machine Learning) e Aprendizagem Profunda (Deep Learning) tem se mostrado uma abordagem promissora para melhorar a precisão das previsões de precipitações.

As estações pluviométricas, responsáveis por medir e registrar a quantidade de chuvas em determinadas regiões, fornecem dados históricos valiosos para análises climáticas (INMET, 2011). No entanto, a interpretação desses registros pode ser um desafio complexo devido à natureza variável e não linear dos fenômenos meteorológicos (SILVA, et al., 2010). É neste cenário que a Aprendizagem Profunda se destaca, permitindo o desenvolvimento de modelos capazes de capturar padrões ocultos nos dados históricos e fornecer previsões mais precisas e confiáveis.

As arquiteturas escolhidas para integrar os experimentos de aprendizado profundo são normalmente utilizadas para detecção de objetos e processamento de imagens. No entanto, elas apresentaram resultados notáveis ao serem aplicadas ao processamento de séries temporais, pois são classificadas como redes neurais convolucionais (CNN). Essa categoria é amplamente empregada no campo da classificação de séries temporais, muito possivelmente devido à sua robustez e ao baixo tempo de treinamento computacional em comparação com outras arquiteturas mais complexas (ISMAIL et al., 2019).

A aprendizagem profunda, uma subárea da Aprendizagem de Máquina, envolve o uso de redes neurais artificiais profundas para aprender representações complexas dos dados. As redes neurais profundas, como redes neurais convolucionais (CNNs) e redes neurais recorrentes (RNNs), têm se mostrado particularmente eficazes na modelagem de sequências de dados temporais, como os registros históricos de estações pluviométricas. Essas redes são capazes de aprender padrões de longo prazo, capturando dependências temporais e espaciais nos dados, o que contribui para uma previsão mais precisa das precipitações (GU et al., 2019; SOUSA et al., 2017).

Em um estudo, foi conduzida uma avaliação da simulação do comportamento hidrológico na bacia hidrográfica do Alto Canoas, localizada em Santa Catarina, utilizando redes neurais artificiais do tipo *Multi Layer Perceptron* (MLP). Foram explorados doze conjuntos de tratamentos que consistiam em diferentes combinações de variáveis, como precipitação, evapotranspiração e vazão, com o objetivo de determinar as variáveis mais adequadas para modelar a vazão. A MLP foi submetida a treinamento, utilizando uma parte dos dados de vazão observados. Além disso, as vazões foram simuladas em modo aberto e fechado durante o período de teste. O tratamento que

apresentou melhor desempenho utilizou a precipitação diária registrada em quatro estações pluviométricas, considerando um tempo de resposta de -2 dias, juntamente com a vazão simulada do dia anterior. Embora o valor do erro médio quadrático tenha sido baixo, observou-se uma tendência de superestimação na vazão modelada pela MLP (DEBASTIANI; SILVA; NETO, 2016).

Outra pesquisa mostrou que os resultados alcançados com a aplicação do modelo Recurrent Neural Network (RNN) com a arquitetura LSTM (Long Short Term Memory) validam diversos estudos encontrados na literatura, os quais serviram como base para a pesquisa. Desse modo, os resultados demonstram que a rede neural foi capaz de capturar os padrões presentes na série temporal dos dados da estação meteorológica, apresentando um desempenho satisfatório em termos de previsão de verdadeiros positivos. Uma investigação focada na ampliação do intervalo de tempo da previsão pode ser benéfica para obter resultados ainda melhores com esse método (DONINELLI; GRZYBOWSKI; SILVA, 2020).

Neste artigo, são exploradas as aplicações da Aprendizagem Profunda para a utilização de um modelo computacional que atua na previsão de precipitações (mm de chuvas) com base em registros históricos de estações pluviométricas no Brasil. O aperfeiçoamento desta técnica tem potencial para aprimorar a capacidade de previsão de chuvas e contribuir para uma gestão mais eficiente dos recursos hídricos.

## 2 ARQUITETURAS DE APRENDIZADO PROFUNDO PARA SÉRIES TEMPORAIS

As Redes Neurais Artificiais (RNA) consistem em ferramentas valiosas no processo de tomada de decisão. Elas são apontadas como instrumentos fundamentais para otimizar o aproveitamento dos recursos e dados disponíveis, podendo ser empregadas em problemas de regressão, classificação e compactação de dados. O processamento de informações realizado por essas redes assemelha-se ao funcionamento do cérebro humano, utilizando o princípio de organização de neurônios. Logo, as redes neurais artificiais são apresentadas como aliadas promissoras na abordagem de desafios complexos em situações práticas, destacando sua importância e versatilidade em diferentes contextos (PINHEIRO; AZEVEDO DOS SANTOS; PASA, 2020).

Diferentemente das redes neurais convolucionais (CNNs) usuais, que são projetadas para tarefas de categorização, as FCNs são capazes de gerar uma saída ponto a ponto que aloca etiquetas a cada ponto de uma figura de entrada. Isso implica que as FCNs são apropriadas para tarefas de divisão semântica, onde o objetivo é alocar etiquetas de classe a cada ponto da figura, destacando as áreas de interesse. A arquitetura FCN emprega camadas convolucionais para aprender representações hierárquicas de uma figura, seguidas por camadas de convolução transposta (também conhecidas como "desconvolução" ou "ampliação") para aumentar a resolução da saída e criar um mapa de divisão com a mesma resolução que a figura de entrada (ZHOU et al., 2016).

A arquitetura Resnet, também conhecida como Rede Residual, tem como objetivo solucionar o desafio do enfraquecimento dos gradientes em redes neurais profundas. Quando aplicada à previsão de chuvas, a Resnet tem a capacidade de aprender representações mais profundas e intrincadas das séries temporais de precipitação, o que possibilita uma modelagem mais precisa dos padrões climáticos. A utilização de conexões residuais na Resnet permite que

informações relevantes fluam de maneira mais fluente ao longo da rede, ajudando a capturar dependências temporais e aprimorar o desempenho das previsões (HE et al., 2016).

A estrutura ResCNN, também conhecida como Rede Neural Convolutacional Residual, une os princípios de redes residuais com convoluções tradicionais. Essa arquitetura possibilita a propagação de informações residuais por meio das camadas convolucionais, aprimorando o fluxo de dados e evitando questões de atenuação de gradientes. No contexto do prognóstico de chuvas, a ResCNN é capaz de aprender a representação das séries temporais de precipitação com maior eficácia e apreender características pertinentes relacionadas aos padrões pluviométricos, resultando em previsões mais acuradas (LONG; YAN; LIANG, 2019).

O modelo InceptionTime se fundamenta na ideia de blocos Inception, os quais viabilizam a extração de informações em múltiplas escalas temporais. Tal abordagem mostra-se especialmente vantajosa na predição de chuvas, visto que permite que a rede neural aprenda características presentes em diferentes períodos, abarcando desde padrões de curta duração até tendências de longo prazo. A arquitetura InceptionTime é capaz de capturar conexões intrincadas nas séries temporais de precipitação, proporcionando uma representação abundante e eficiente para a previsão pluviométrica (SZEGEDY et al., 2015).

A previsão meteorológica desponta como um campo amplamente explorado para a aplicação da análise de sequências temporais. Diversas abordagens são empregadas na resolução de problemas desse tipo, abarcando tanto métodos estatísticos tradicionais, como a família de modelos ARIMA (autoregressive integrated moving average ou média móvel integrada autorregressiva), quanto técnicas de aprendizado de máquina e aprendizado profundo. No contexto do modelo de séries temporais adotado pelo ArcGIS Learn, são utilizados backbones de redes neurais convolucionais de última geração especialmente adaptados a conjuntos de dados temporais. Entre eles, destacam-se InceptionTime, ResCNN, Resnet e FCN. O que confere singularidade à modelagem de sequências temporais é que, na metodologia clássica do ARIMA, diversos hiperparâmetros necessitam ser finamente ajustados antes da adequação do modelo, ao passo que, com a abordagem de aprendizado profundo atual, a maioria dos parâmetros é aprendida pelo modelo em si, a partir dos dados disponíveis.

A figura 1 apresenta diagramas explicativos que descrevem de maneira didática, as quatro arquiteturas de redes neurais contempladas neste trabalho.

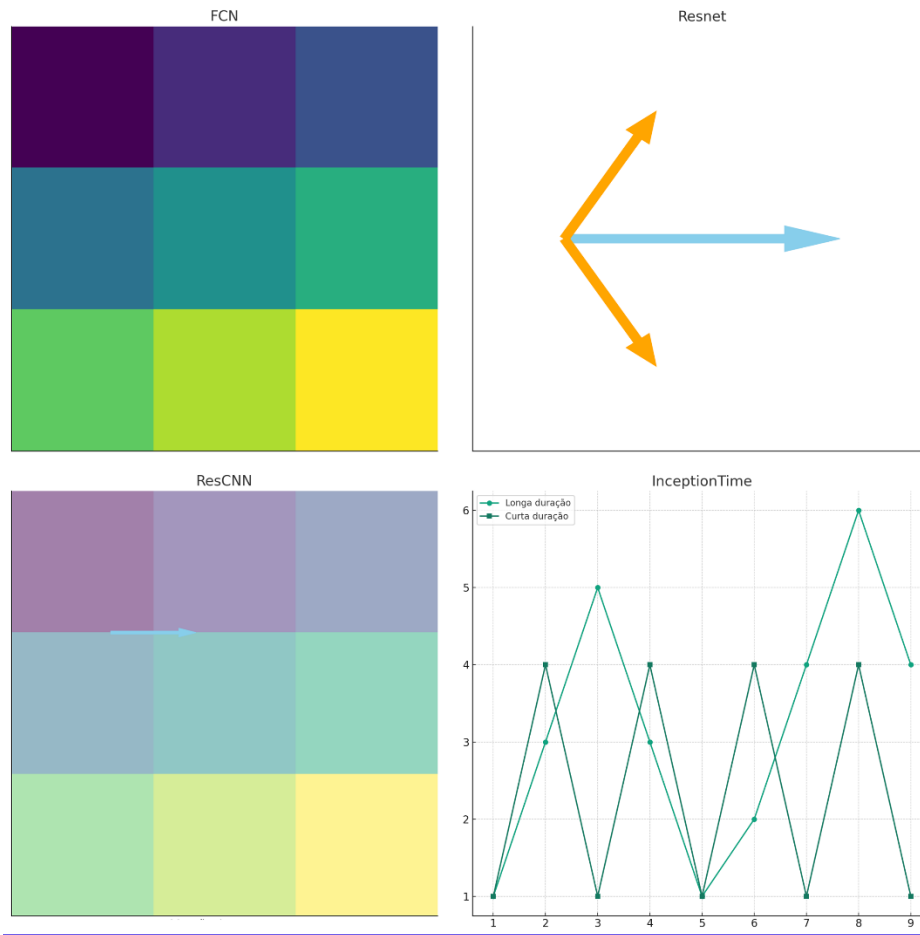


Figure 1: Diagramas explicativos do princípio de aprendizagem de cada arquitetura de rede utilizada no estudo. FCN: identifica cada pixel de uma imagem; Resnet: memória especial para lembrar informações; ResCNN: combinação de FCN e Resnet; InceptionTime: analisa o clima por diferentes ângulos.

### 3 METODOLOGIA

O banco de dados denominado como biblioteca HydroBR foi criado para facilitar o acesso às informações hidrometeorológicas das estações de monitoramento distribuídas por todo o país, gerenciadas e de responsabilidade da Agência Nacional de Águas e Saneamento Básico (ANA) e do Instituto Nacional de Meteorologia (INMET). A aquisição dos dados se dá de maneira que os downloads dos mesmos, inclusive os agrupados em séries históricas, são realizados automaticamente (CARVALHO, 2021).

O programa utilizado tem a função de importar dados de precipitação de séries históricas de qualquer cidade brasileira que contenha estações de monitoramento pluviométrico. É fundamental destacar que a entrada de dados pelo usuário consiste somente no nome da cidade pretendida, sendo necessário inserir os mesmos caracteres cadastrados junto ao sistema HIDROWEB (ANA). Além disso, o modelo ainda identifica outras informações relativas a cada estação levantada, tais como o órgão responsável, as coordenadas geográficas e as datas de início e fim das medições de séries históricas.

Ao usuário selecionar o município e os postos pluviométricos serem levantados, o programa reúne as precipitações máximas médias mensais (soma das chuvas diárias) dos respectivos postos e as correlaciona para identificar e aprender os padrões existentes e executar

a previsão das chuvas nos anos posteriores. O aprendizado profundo foi empregado nas séries históricas compreendidas entre 1940 e 2023 (variáveis explanatórias). Após, foram avaliadas as previsões dos eventos de precipitação ocorridos em três anos subsequentes, ou seja, os 36 meses contidos entre julho/2020 e junho/2023.

Para avaliar a eficiência de diferentes modelos computacionais na previsão dos eventos de precipitação, foram testados quatro arquiteturas de Deep Learning responsáveis pelo aprendizado profundo do comportamento das séries temporais, sendo elas: FCN, Resnet, ResCNN e InceptionTime.

Neste artigo, foi selecionado o município de Barra Mansa (Rio de Janeiro) para avaliação das séries históricas de precipitação de todas as estações de monitoramento pluviométrico disponíveis no sistema HIDROWEB.

Para análise de séries históricas no contexto do aprendizado profundo de redes neurais artificiais, como as associadas a registros históricos de chuvas, foram utilizados os parâmetros RMSE (Root Mean Square Error), MAE (Mean Absolute Error) e R-Square ( $R^2$ ), os quais são definidos como métricas amplamente empregadas para avaliar a performance e a precisão dos modelos. Esses parâmetros são fundamentais para avaliar a performance e a eficácia dos modelos de aprendizado profundo na previsão de séries históricas. Eles permitem a comparação entre diferentes arquiteturas de redes neurais e auxiliam na identificação daquelas que melhor se adaptam aos dados analisados.

O RMSE (raiz do erro quadrático médio) representa uma medida do desvio-padrão dos resíduos entre os valores reais e as previsões do modelo. Ele corresponde à raiz quadrada da média dos quadrados dos erros, proporcionando uma estimativa do quão bem o modelo se ajusta aos dados. Quanto menor o valor do RMSE, maior será o ajuste do modelo em relação aos valores reais. Essa métrica é particularmente sensível a erros de grande magnitude, sendo adequada para identificar discrepâncias significativas entre os valores reais e as previsões.

O MAE (erro absoluto médio), por sua vez, é uma métrica que calcula a média do valor absoluto dos erros entre os valores reais e as previsões do modelo. Ela mensura a magnitude média dos erros, independentemente de sua direção. O MAE oferece uma estimativa da proximidade entre as previsões do modelo e os valores reais. Da mesma forma que o RMSE, quanto menor o valor do MAE, maior será a precisão do modelo.

O R-Square ( $R^2$  ou R-quadrado), também conhecido como coeficiente de determinação, é uma medida estatística que indica a proporção da variabilidade dos valores reais explicada pelo modelo. Ele varia de 0 a 1, sendo 0 quando o modelo não explica nenhuma variabilidade e 1 quando o modelo explica toda a variabilidade dos dados. O R-Square é uma medida global de ajuste do modelo, e valores mais próximos de 1 indicam um ajuste superior.

A figura 2 apresenta um fluxograma das etapas do trabalho.

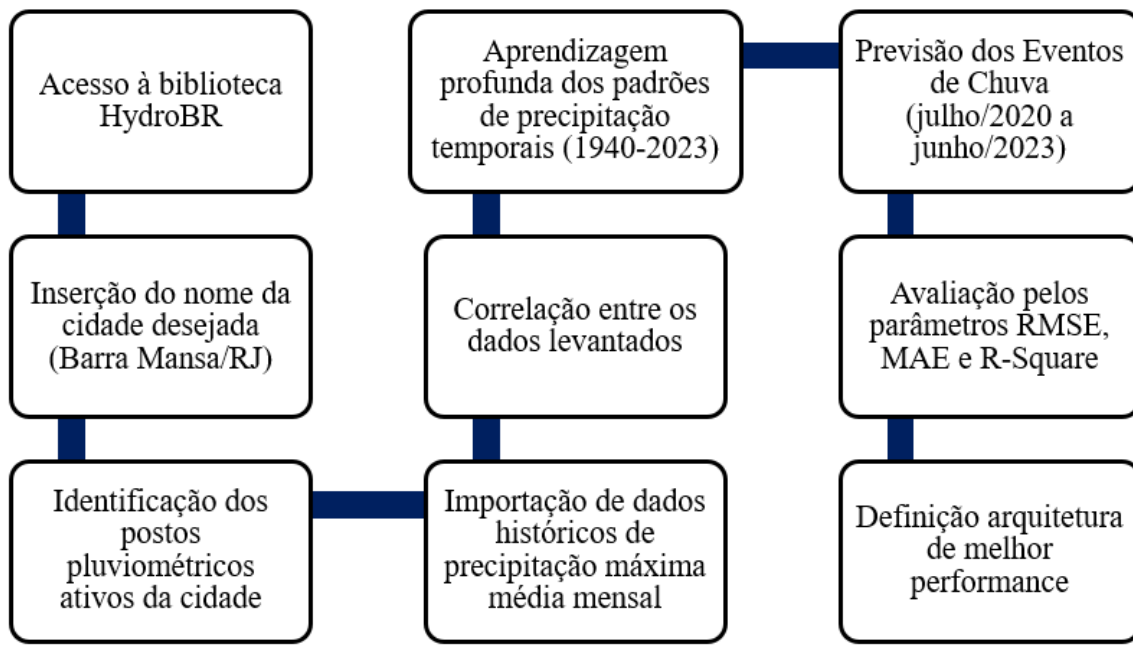


Figure 2: Fluxograma explicativo das etapas cumpridas para executar o programa. As etapas do programa foram submetidas a quatro arquiteturas de redes neurais: FCN, Resnet, ResCNN e InceptionTime.

## 4 RESULTADOS E DISCUSSÕES

A partir da inserção do nome da cidade na primeira etapa de processamento do programa (“BARRA MANSA”), o modelo é capaz de identificar automaticamente a quantidade de postos de monitoramento pluviométrico associados ao município digitado e suas respectivas informações básicas, como é possível visualizar na Figura 3. No município de Barra Mansa/RJ, existem 10 (dez) estações pluviométricas com dados de precipitação disponíveis, os quais variam entre o ano de 1940 e 2023, isto é, um intervalo de 80 anos de monitoramento em pontos distribuídos pela cidade.

	Name	Code	Type	SubBasin	City	State	Responsible	Latitude	Longitude	StartDate	EndDate	NYD	MD	N_YWOMD	YWMD
8185	RIBEIRÃO DE SÃO JOAQUIM	02244034	2	58	BARRA MANSA	RIO DE JANEIRO	ANA	-22.3036	-44.1869	1942/02/01	2019/10/31	78	0.5	71	9.0
8193	UHE FUNIL JUSANTE 2	02244042	2	58	BARRA MANSA	RIO DE JANEIRO	FURNAS	-22.5375	-44.1758	1940/04/19	2016/02/29	77	1.5	62	19.5
8194	RIALTO	02244043	2	58	BARRA MANSA	RIO DE JANEIRO	ANA	-22.5814	-44.2681	1951/07/01	2019/09/30	69	19.7	50	27.5
8195	GLICÉRIO	02244044	2	58	BARRA MANSA	RIO DE JANEIRO	ANA	-22.4742	-44.2289	1967/09/01	2019/10/31	53	2.5	41	22.6
8196	NOSSA SENHORA DO AMPARO	02244045	2	58	BARRA MANSA	RIO DE JANEIRO	ANA	-22.3856	-44.1075	1968/01/01	2019/10/31	52	1.0	49	5.8
8200	QUATIS	02244049	2	58	BARRA MANSA	RIO DE JANEIRO	ANA	-22.3881	-44.1683	2002/04/16	2019/09/30	18	0.5	13	27.8
8243	BARRA MANSA (SE)	02244106	2	58	BARRA MANSA	RIO DE JANEIRO	LIGHT	-22.5414	-44.1781	1951/01/01	2004/02/17	54	0.9	36	33.3
8246	QUATIS	02244109	2	58	BARRA MANSA	RIO DE JANEIRO	LIGHT	-22.4114	-44.2725	1951/08/01	2012/12/31	62	69.6	11	82.3
8254	NOSSA SENHORA DO AMPARO	02244118	2	58	BARRA MANSA	RIO DE JANEIRO	LIGHT	-22.3806	-44.1142	1951/04/13	1964/03/07	14	2.0	10	28.6
8255	RIALTO	02244119	2	58	BARRA MANSA	RIO DE JANEIRO	LIGHT	-22.5825	-44.2667	1951/07/01	1958/06/30	8	0.1	5	37.5

Figure 3: Resultado do levantamento de postos pluviométricos situados no município de Barra Mansa/RJ.

A coleta dos dados de precipitação máxima mensal permitiu que o programa elaborasse a série histórica geral dos valores máximos registrados para as chuvas do município de Barra Mansa/RJ. Os registros históricos máximos de chuvas, levantados a partir da lista de postos exibida na Figura 3, podem ser visualizados no gráfico contido na Figura 4.






Figure 4: Série temporal criada pelo modelo computacional, formada pelos valores máximos mensais de precipitação do município de Barra Mansa/RJ, entre os anos de 1940 e 2023.

É possível exibir os resultados do treinamento utilizando o comando `show_results()`, que consiste em uma maneira de avaliar a qualidade do modelo treinado e calcular as métricas correspondentes. No caso de modelos de séries temporais, o comando `show_results` normalmente apresentará dois gráficos adjacentes. Nos gráficos à esquerda, são plotados os valores reais do terreno, enquanto nos gráficos à direita são exibidas as previsões realizadas pelo modelo após a aplicação do conjunto de dados de validação. Ao comparar as previsões com os valores reais ou a verdade absoluta, é possível obter uma indicação do desempenho do modelo treinado. Por exemplo, o comando `model.show_results(rows=5)` fornece uma comparação entre cinco valores alvo e suas respectivas previsões, conforme demonstrado na Figura 5.

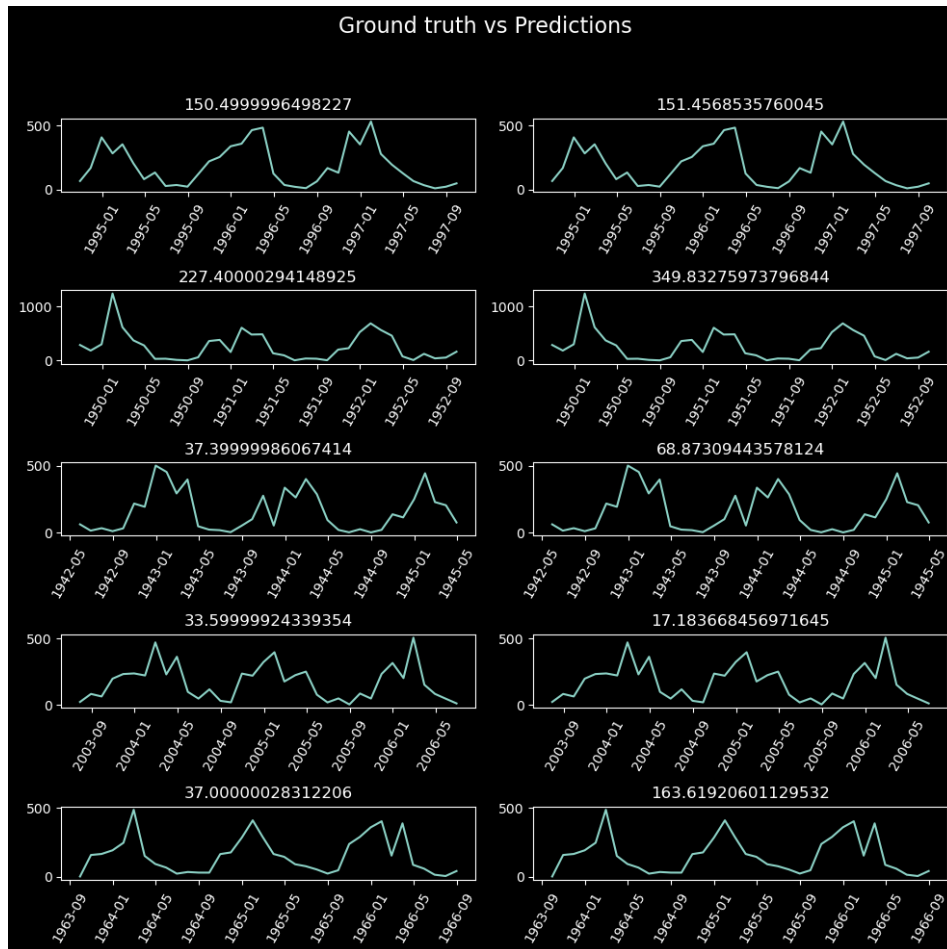


Figure 5: Valores de destino x valores de previsão, para os modelos de Deep Learning.



Para avaliar a quantidade de perdas em relação aos treinamentos realizados pelo programa, em função das bateladas processadas, obteve-se o gráfico mostrado na Figura 6.

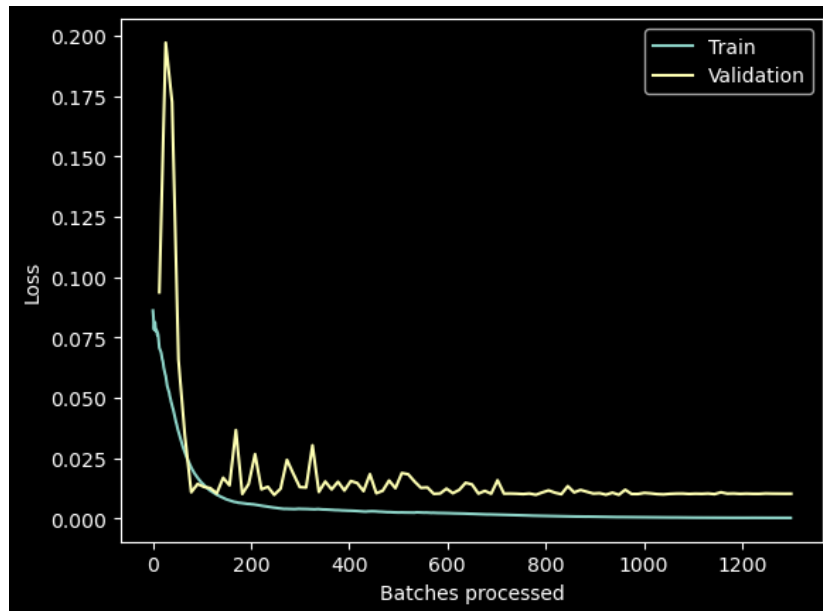


Figure 6: Quantidade de bateladas processadas na relação entre o treinamento e a validação dos dados analisados.

A partir da execução do programa desenvolvido, foram testadas quatro arquiteturas de aprendizado profundo (InceptionTime, Resnet, FCN e ResCNN), todas adequadas para o processamento de séries históricas de dados. O objetivo foi identificar a correlação entre essas arquiteturas e elaborar um gráfico comparativo. Os principais resultados obtidos estão apresentados na figura 7.

As métricas utilizadas para avaliar o desempenho das correlações nas arquiteturas testadas foram os seguintes: RMSE, MAE e R-Square (R-Quadrado). Os coeficientes RMSE e MAE são responsáveis por mensurar os erros decorrentes da comparação entre as variáveis reais e previstas. Em outras palavras, quanto menores forem esses valores, maior será a capacidade do modelo em explicar a realidade de forma eficiente. O coeficiente RMSE é particularmente útil em situações em que erros de grande magnitude são indesejáveis, diferentemente do MAE. A Figura 7 mostra os resultados da aplicação das quatro arquiteturas de aprendizagem profunda na previsão dos eventos de precipitação de Barra Mansa/RJ, entre os anos de 2020 e 2023 (ULIANA et al., 2018).

No que diz respeito ao coeficiente R-quadrado ( $R^2$ ), trata-se de uma métrica utilizada para avaliar a distribuição dos dados em gráficos, com valores variando entre 0 e 1. Em outras palavras, quanto mais próximo o  $R^2$  estiver de 1, melhor será o ajuste do modelo/arquitetura testada aos dados coletados. Em casos em que a distribuição dos pontos difere significativamente de uma linha horizontal, o  $R^2$  pode assumir um valor negativo, sem violar os princípios matemáticos (ULIANA et al., 2018).

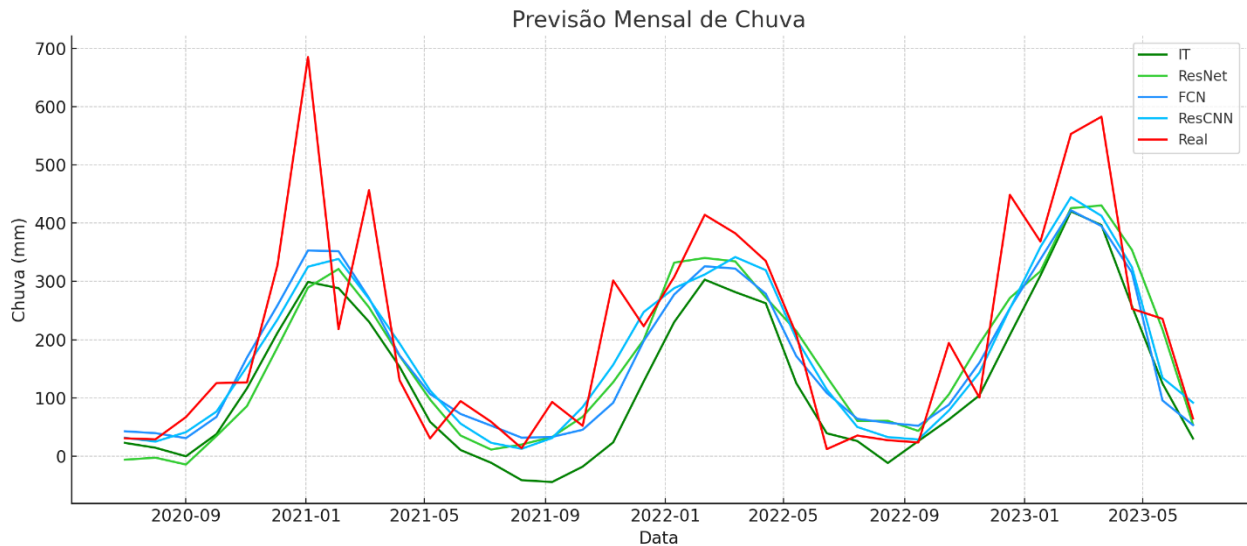


Figure 7: Distribuição temporal das precipitações reais e previstas entre julho/2020 e junho/2023.

Table 1: Parâmetros matemáticos de avaliação do desempenho da previsão das precipitações em cada arquitetura.

Arquitetura de Rede	Métricas de Avaliação do Desempenho das Correlações		
	RMSE	MAE	R-Square
FCN	102,5278	76,1319	0,69
InceptionTime	107,6426	77,6585	0,66
ResCNN	107,9742	80,7041	0,65
Resnet	136,5354	101,1202	0,45

No contexto analisado, as séries temporais de precipitações médias máximas mensais apresentam um comportamento teoricamente imprevisível, conforme evidenciado pelos gráficos elaborados. Os valores exibidos nesses gráficos revelam padrões altamente irregulares e aleatórios, diferindo significativamente de linhas retas. Como resultado, todos os coeficientes de determinação ( $R^2$ ) são negativos. Devido a essa situação, quanto mais próximo de zero os coeficientes estiverem, melhor sucedida foi a arquitetura na previsão dos dados reais. Dessa forma, a arquitetura FCN também demonstrou o melhor desempenho de previsão, exibindo um  $R^2$  de -0,05.

Através da análise comparativa entre os parâmetros que avaliam a performance da previsão dos eventos de precipitação em cada uma das arquiteturas de aprendizagem profunda aplicadas no modelo computacional, constatou-se que a arquitetura FCN apresentou os menores coeficientes de erro RMSE (102,5278) e MAE (76,1319), assim como o maior coeficiente R-Square (0,69), na análise dos dados de precipitação.

## 5 CONCLUSÃO

O modelo computacional utilizado e sua metodologia de processamento de dados estão em estágio inicial. No entanto, ao longo do tempo, pretende-se demonstrar que as técnicas de Deep Learning associadas à previsão de séries históricas e variáveis hidrometeorológicas têm o potencial para oferecer resultados ainda mais coerentes e satisfatórios na previsão de precipitações.

A RNA (Redes Neurais Artificiais) apresentou resultados promissores na previsão de chuvas no município de Barra Mansa/RJ. No entanto, é válido salientar que os valores extremos de precipitação real, traduzidos pelos picos de chuva contidos na figura 7, não foram previstos pelas arquiteturas avaliadas. Em geral, estes dados mais discrepantes são mais problemáticos na previsão do comportamento de dados, visto que se apresentam distantes dos padrões aprendidos pelo programa. Destaca-se as diferentes arquiteturas de RNA empregadas e as análises estatísticas realizadas para avaliar o desempenho dessas redes. Foram utilizadas diversas arquiteturas de redes neurais artificiais associadas ao Deep Learning, para avaliar as previsões de dados de precipitação ao longo do tempo e determinar sua eficiência. As arquiteturas de Deep Learning incluíram InceptionTime, Resnet, ResCNN e FCN, nas quais o modelo FCN resultou nos melhores coeficientes que representam a performance de precisão na previsão das chuvas, com base nos dados reais e previstos pelo programa.

Essas análises foram aplicadas aos dados pluviométricos de Barra Mansa/RJ, abrangendo o período de 1940 e 2023. Porém, podem ser aplicados em qualquer cidade brasileira contemplada nos registros históricos do HIDROWEB (ANA). Foram considerados três coeficientes de avaliação do desempenho das correlações nas arquiteturas testadas: RMSE, MAE e R-Square.

Devido ao melhor desempenho em termos de previsão de dados, a aplicação da aprendizagem profunda na arquitetura FCN apresentou os menores coeficientes de erro, tanto MAE (76,1319) como RMSE (102,5278). Além disso, foi observado o maior valor de R-Quadrado (0,69) dentre as arquiteturas testadas, indicando um bom desempenho na previsão dos dados reais para os anos de 2020 a 2023.

## 6 REFERENCES

- Baba, R. K., Vaz, M. S. M. G., & Costa, J. (2014). Correção de dados agrometeorológicos utilizando métodos estatísticos. *Revista Brasileira de Meteorologia*, 29(4), 515-526.
- Carvalho, W. (2021, March 21). Utilizando a biblioteca HydroBR – Parte 1: Trabalhando com dados da Agência Nacional de Águas. Medium. <https://wallissoncarvalho.medium.com/utilizando-a-biblioteca-hydrobr-parte-1-fe6026fa1d04>
- Debastiani, A. B., Silva, R. D., & Rafaeli Neto, S. L. (2016). Eficácia da arquitetura MLP em modo closed-loop para simulação de um Sistema Hidrológico. *RBRH*, 21(4), 821–831.
- Dominelli, J. W., Grzybowski, J. M. V., & Silva, R. V. (2020). Previsão pluviométrica por meio da aplicação de redes neurais artificiais recorrentes alimentadas com dados meteorológicos em tempo atual. In *X Jornada de Iniciação Científica e Tecnológica* (Vol. 1, No. 10). <https://portaleventos.uffs.edu.br/index.php/JORNADA/article/view/14161>

- Forecasting monthly rainfall in California using Deep Learning Time Series techniques. (n.d.). ArcGIS Developers: ArcGIS API for Python/Samples. <https://developers.arcgis.com/python/samples/forecasting-monthly-rainfall-in-california-using-deeplearning-timeseries-model-from-arcgis-learn/>
- Gu, Q., et al. (2019). Characterizing the spatial variations of the relationship between land use and surface water quality using self-organizing map approach. *Ecological Indicators*, 102, 633-643.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *IEEE conference on computer vision and pattern recognition* (pp. 770–778).
- INMET. (2011). Nota técnica nº 001/2011/SEGER/LAIME/CSC/INMET. Rede de Estações Meteorológicas Automáticas do INMET.
- Ismail, F. H., Forestier, G., Weber, J., et al. (2019). Deep learning for time series classification: a review. *Data Min Knowl Disc*, 33, 917–963. <https://doi-org.ez24.periodicos.capes.gov.br/10.1007/s10618-019-00619-1>
- Long, W., Yan, D., & Liang, G. (2019). A new ensemble residual convolutional neural network for remaining useful life estimation. *Mathematical Biosciences and Engineering*, 16(2), 862-880. doi: 10.3934/mbe.2019040
- Pinheiro, T. C., Azevedo dos Santos, J. A., & Pasa, L. A. (2020). GESTÃO DA PRODUÇÃO DE FRANGOS DE CORTE POR MEIO DE REDES NEURAIS ARTIFICIAIS. *HOLOS*, 2, 1–15. <https://doi.org/10.15628/holos.2020.9043>
- Silva, R. M., et al. (2010). Análise da variabilidade espaço-temporal e identificação do padrão da precipitação na bacia do Rio Tapacurá, Pernambuco. *Sociedade & Natureza*, 22(2), 357–372.
- Sousa, L. M., et al. (2017). Avaliação do Uso e Cobertura da Terra em Paragominas e Ulianópolis-PA, Utilizando Dados do Projeto TERRACLASS. *Revista Brasileira de Cartografia*, 3(69), 421-431. <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44339>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1–9).
- Tavares Diniz, J. M. (2013). VARIABILIDADE DA PRECIPITAÇÃO E DO NÚMERO DE DIAS COM CHUVAS DE DUAS CIDADES DISTINTAS DA PARAÍBA. *HOLOS*, 3, 171–180. <https://doi.org/10.15628/holos.2013.1291>
- Uliana, E. M., Silva, D. D., Moreira, M. C., Pereira, D. R., Pereira, S. B., & Almeida, F. T. (2018). Desenvolvimento de redes neurais artificiais para estimativa das vazões diárias na bacia do rio Piracicaba. *IRRIGA*, 23(4), 756–772. <https://actarborea.fca.unesp.br/index.php/irriga/article/view/2740>
- Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. In *IEEE conference on computer vision and pattern recognition* (pp. 2921–2929).

#### HOW TO CITE THIS ARTICLE:

Silva, V. A., Oliveira, M. P., Santos, F. L. (2023). PREVISÃO DE PRECIPITAÇÃO MENSAL NO MUNICÍPIO DE BARRA MANSA/RJ USANDO TÉCNICAS DE DEEP LEARNING TIME SERIES. *HOLOS*, 5(39). Recuperado de <https://www2.ifrn.edu.br/ojs/index.php/HOLOS/article/view/16340>



**ABOUT THE AUTHORS:****V. A. SILVA**

Graduado em Engenharia Ambiental pelo Centro Universitário de Volta Redonda (UniFOA), campus Oléio Galotti, (2009). Possui especialização em Geoprocessamento pela Pontifícia Universidade Católica de Minas Gerais (PUC Minas) e em Georreferenciamento de Imóveis Rurais pela Faculdade de Engenharia de Minas Gerais (FEAMIG). Mestrado (2023) pelo Pós-Graduação em Rede Nacional em Gestão e Regulação de Recursos Hídricos, Departamento de Tecnologia e Ciências, da Universidade do Estado do Rio de Janeiro.

E-mail: [vinicius.silva@profagua.uerj.br](mailto:vinicius.silva@profagua.uerj.br)

ORCID ID: <https://orcid.org/0009-0009-9008-4095>

**M. P. OLIVEIRA**

Graduado em Engenharia Ambiental pelo Centro Universitário de Volta Redonda (UniFOA), campus Oléio Galotti, (2019). Mestrado (2023) pelo Pós-Graduação em Tecnologia Ambiental, Escola de Engenharia Industrial Metalúrgica de Volta Redonda, da Universidade Federal Fluminense. Atua na área de consultoria ambiental na Azevedo Consultoria Ambiental e Energética.

E-mail: [mateuspo@id.uff.br](mailto:mateuspo@id.uff.br)

ORCID ID: <https://orcid.org/0000-0001-5385-5895>

**F. L. SANTOS**

Graduado em Engenharia Civil pela UNESP - Ilha Solteira (2000) e Engenheiro de Segurança do Trabalho. Possui Mestrado em Engenharia Civil - Recursos Hídricos e Tecnologias Ambientais pela UNESP - Ilha Solteira (2003) e Doutorado em Engenharia Elétrica - Automação - Redes Neurais Artificiais pelo PPGEE - Conceito Capes 6 da UNESP - Ilha Solteira (2013), com Sanduiche no LNEC - Portugal (2013).

E-mail: [franciscollado@unemat.br](mailto:franciscollado@unemat.br)

ORCID ID: <https://orcid.org/0000-0002-7718-8203>

**Editor:** Francinaide de Lima Silva Nascimento

**Ad Hoc Reviewer:** Andre Luis Sotero S. Martim e Giovanni Chaves Penner



Submitted June 5, 2023

Accepted December 1, 2023

Published December 18, 2023