

# Previsão do Volume Mensal de Precipitações em Manaus, Amazonas com Redes Neurais Artificiais

Nicoli Pinheiro de Araújo, Elloá B. Guedes,  
Maria Betânia Leal de Oliveira, Rita Valéria Andreoli Souza

<sup>1</sup> Escola Superior de Tecnologia  
Universidade do Estado do Amazonas  
Av. Darcy Vargas, 1200 – Manaus – Amazonas

{npda.eng,ebgcosta,mloliveira,rasouza}@uea.edu.br

**Abstract.** *This work addresses the adoption of artificial neural networks to predict the monthly precipitation volume in the city of Manaus. For that, we considered data from 1950 to 2015 and climatic indexes of sea surface temperature that influence precipitation in the region of interest. Different neural networks were proposed, trained and tested for the problem considered and, for each month of the year, the network with the best accuracy was selected. The results obtained show the adequacy of the proposed models, with accuracy higher than 92%, emphasizing the advantages in using Machine Learning in this scenario.*

**Resumo.** *Este trabalho endereça a utilização de redes neurais artificiais para previsão do volume de precipitações mensal na cidade de Manaus. Para tanto, foram considerados dados de 1950 a 2015 e índices climáticos de temperatura da superfície do mar que influenciam a precipitação na região de interesse. Foram propostas, treinadas e testadas diferentes redes neurais para o problema em questão e, para cada mês do ano, foi selecionada a rede com melhor acurácia. Os resultados obtidos mostram a adequação dos modelos propostos, com taxa de acerto superior a 92%, enfatizando a utilização da Aprendizagem de Máquina no cenário em questão.*

## 1. Introdução

No âmbito da Meteorologia, entende-se por *precipitação* o fenômeno que consiste no depósito de água na superfície terrestre. A água é oriunda da condensação atmosférica e sua precipitação pode acontecer sob a forma chuva, granizo, neblina, neve, orvalho ou geada [Torres and de Oliveira Machado 2012]. Considerando a *chuva*, fenômeno de precipitação mais comum no Brasil, sua ocorrência possui um papel importantíssimo em diversos setores, incluindo Agricultura, Pecuária, geração de energia elétrica, dentre diversos outros. Dada a importância econômica e social, prever a ocorrência de chuva pode ter impactos positivos em diversos setores, razão pela qual esta previsão é explorada e almejada desde os primórdios da humanidade. Apesar disso, a previsão não pode ser considerada uma tarefa fácil, pois há a instabilidade atmosférica, interações não-lineares entre diferentes escalas espaciais e até mesmo a interferência humana [Darji et al. 2015].

Na cidade de Manaus, em particular, a chuva influencia em aspectos econômicos e sociais de famílias que praticam a agricultura de subsistência, fortemente dependente do regime de precipitações [Adams et al. 2005]. Além disso, pode-se mencionar também aspectos relacionados ao conforto térmico da população, dada as características quentes

e úmidas típicas desta região equatorial [da Silva 2012, Sioli 1991]. Considerando os desafios de prever chuvas nesta cidade, que encontra-se sob a influência de sete sistemas de precipitação distintos [da Silva 2012], trabalhos anteriores consideraram a ocorrência ou não de precipitações um dia à frente [de Lima 2016, Guedes et al. 2016, de Lima and Guedes 2015b, de Lima and Guedes 2015a]. Para tanto, utilizaram redes neurais *multilayer perceptron* e dados observacionais de 40 anos. Embora tenham conseguido resultados satisfatórios, alcançando acurácia de 99.71% no período de um ano reservado para testes, estes resultados não forneceram o volume destas precipitações, sendo uma limitação para o planejamento de tarefas fortemente dependentes do regime de chuvas, por exemplo.

Diante da limitação observada, este trabalho teve como objetivo prever o volume mensal de precipitações na cidade de Manaus, Amazonas. Para tanto, considerou dados coletados entre os anos de 1950 e 2015, e também outras variáveis meteorológicas, como os índices de temperatura na superfície do mar coletadas no Oceano Pacífico. Estas medições possuem relação com os fenômenos El Niño e La Niña, que influenciam na ocorrência de precipitações na região de interesse. Os parâmetros em questão serviram de entrada para redes neurais artificiais, que foram treinadas para o problema em questão.

De acordo com os resultados observados, foi possível constatar que as redes neurais artificiais endereçam adequadamente o problema em questão, prevendo o volume de precipitações mensal em relação à média histórica com acurácia média em torno de 92%. Para cada mês do ano foram construídas diferentes redes neurais e a rede com melhor acurácia foi identificada, garantindo assim a construção de modelos de previsão adequados às características particulares de cada mês.

As seções a seguir apresentam os resultados obtidos decorrentes da realização deste trabalho. Inicialmente, uma análise dos trabalhos relacionados pode ser vista na Seção 2. Uma visão geral do conjunto de dados utilizado neste trabalho encontra-se apresentada na Seção 3. A metodologia utilizada para proposição das arquiteturas de diferentes redes neurais, descrição dos procedimentos de treinamento e teste encontra-se na Seção 4. Os resultados obtidos e a discussão encontram-se apresentados na Seção 5. Por fim, as considerações finais e os trabalhos futuros são mostrados na Seção 6.

## **2. Trabalhos Relacionados**

Por meio de revisões bibliográficas, foi possível identificar quatro trabalhos que se propõem a abordar o problema de previsão de precipitações em Manaus com a utilização de redes neurais artificiais [de Lima 2016, Guedes et al. 2016, de Lima and Guedes 2015b, de Lima and Guedes 2015a]. Observando a cronologia destas publicações, também é possível observar uma crescente melhoria nas métricas de desempenho obtidas pelos autores.

O problema considerado nestes trabalhos relacionados foi a previsão de precipitações em Manaus um dia à frente. Em mais detalhes, os autores utilizaram como entrada uma janela de tempo de variáveis meteorológicas coletadas de uma estação meteorológica automática para prever a ocorrência ou não de precipitações nas 24h seguintes, independentemente do volume associado. Neste contexto, a tarefa de aprendizagem considerada foi de classificação.

No tocante às redes neurais utilizadas, os autores adotaram o modelo *time delay neural networks*, uma variante das redes *multilayer perceptron* em que dados defasados

das variáveis preditoras são apresentadas às redes tendo em vista a captura de características temporais nos dados. Este tipo de rede se mostrou adequada ao domínio do problema porque este defasamento permitiu introduzir diferentes janelas de tempo das variáveis preditoras. Os autores utilizaram uma metodologia para estimar o número de redes adequadas ao problema, resultando em 38 redes neurais a serem treinadas e testadas.

Os dados para treinamento e testes destas redes neurais foram obtidos de uma estação meteorológica automática mantida em Manaus pelo Instituto Nacional de Meteorologia [INMET 2017], coletados diariamente entre os anos de 1970 e 2010. Cada medição diária disponível neste conjunto de dados contempla uma das seguintes variáveis meteorológicas: temperatura máxima, temperatura mínima, umidade relativa, velocidade média do vento e precipitação. Após um pré-processamento dos dados, que visou excluir medições incompletas, o conjunto de dados contemplou 11719 dias de observações.

Os autores identificaram que a melhor rede para o problema possuía 15 neurônios na camada de entrada, uma única camada oculta com 7 neurônios e que utilizava dados de 3 dias anteriores para defasamento, obtendo acurácia de 99.7%. Embora considerem apenas a sua ocorrência ou não de precipitações, alguns aspectos utilizados nestes trabalhos colaboram para os resultados obtidos e serão considerados no escopo deste trabalho para previsão do volume mensal de precipitações, a citar: (i) utilização de dados advindos de estações meteorológicas, (ii) utilização de dados defasados das variáveis meteorológicas e (iii) adoção das *time delay neural networks*.

### 3. Visão Geral do Conjunto de Dados


Para treinar e testar redes neurais para o problema considerado, primeiramente fez-se necessário consolidar um conjunto de dados. No escopo deste trabalho, foram considerados os volumes de precipitação mensal na cidade de Manaus ao longo de 65 anos, de 1950 a 2015, fornecidos pelo Departamento de Meteorologia da Universidade do Estado do Amazonas. Uma estatística descritiva dessas informações encontra-se apresentada na Tabela 1. O gráfico de *boxplot* ilustrado na Figura 1 fornece uma representação visual da distribuição desses dados.

**Tabela 1: Média, mediana e desvio padrão do volume de precipitação por mês do ano em Manaus.**

Meses	1	2	3	4	5	6	7	8	9	10	11	12
<b>Média</b>	284.5	281.4	321.6	318.3	240.3	113.7	70.9	54.6	71	113.3	178	224.6
<b>Mediana</b>	286	261.6	302.9	300.8	241.8	108.6	64.4	46.7	63.6	105.6	170.4	207.4
<b>Desvio Padrão</b>	87.5	109.8	98.7	96.1	100.7	49.8	46.2	43.5	49.7	63	83	84.9

Tomando os volumes mensais de precipitação no período observado, é possível constatar diferentes padrões nos meses do ano, alguns dos quais com ampla dispersão, distribuições oblíquas e *outliers*. Estas características dos atributos a serem previstos no escopo deste trabalho reforçam os desafios inerentes à concepção de modelos de previsão de precipitação.

Alguns índices climáticos também foram considerados. Os índices Niño 1+2, 3, 3.4 e 4 da temperatura na superfície do mar no Oceano Pacífico são os indicadores primários para o monitoramento do El Niño, que influencia a variabilidade da chuva na bacia amazônica [Fisch et al. 1998]. Além destes, o índice Atlântico Tropical Sul (TSA)



**Figura 1: Boxplot do volume de precipitação mensal em Manaus.**


também foi considerado, por ter um papel importante na variabilidade da precipitação ao influenciar o transporte de umidade para a bacia amazônica [Limberger and Silva 2016]. Os gráficos de *boxplot* que ilustram a distribuição destes índices encontram-se ilustrados na Figura 2.

Os volumes de precipitação de Manaus e os índices climáticos Niño 1+2, 3, 3.4, 4 e TSA anteriormente apresentados foram organizados sistematicamente em um *dataset* composto de 65 exemplos anuais. A metodologia de utilização destes dados para treinar e testar as redes neurais artificiais será detalhada na seção a seguir.


#### 4. Materiais e Métodos

A tarefa de aprendizagem de máquina considerada neste trabalho é uma tarefa de classificação um mês à frente do volume de precipitação mensal em relação à média histórica. Os resultados desta tarefa visam prever se em um determinado mês haverá volume de precipitações inferior ou superior ao volume mensal médio nos últimos anos, a chamada média histórica. Por exemplo, a média histórica do volume de precipitações em Manaus para o mês de janeiro é de 284 mm. Caso se deseje prever se o próximo mês de janeiro terá um volume de precipitações abaixo ou acima deste valor, esta previsão, de acordo com a abordagem considerada neste trabalho, poderá ser feita em dezembro (isto é, com um mês de antecedência). A previsão em relação à média histórica, tal como considerado neste trabalho, permite estimar se o regime de chuvas em um determinado mês será maior ou inferior ao habitual.


Para capturar a relação temporal existentes nos dados, serão consideradas as *time delay neural networks*. Resultados da literatura mostram uma boa avaliação deste modelo de redes neurais na captura das características dinâmicas da precipitação [Htike and Khalifa 2010], superando até mesmo outras abordagens [Adya and Collopy 1998]. Neste trabalho, serão considerados parâmetros de entrada defasados em uma janela de tempo de 6 meses, isto é, cada rede neural será alimentada com os 6 últimos volumes de precipitação mensal e os 6 últimos meses de cada um dos índices climáticos. Com este defasamento, cada rede neural responsável pela previsão do volume de precipitações em




(a) Niño 1+2




(b) Niño 3



(c) Niño 3.4



(d) Niño 4



(e) TSA

**Figura 2: Distribuição dos índices considerados no escopo deste trabalho ao longo dos meses do ano.**

um determinado mês irá possuir 37 neurônios em sua camada de entrada.

Dadas as diferentes características mensais do volume de precipitações em Manaus, conforme detalhado na seção anterior, a proposição de uma única rede neural capaz de generalizar características tão diversas poderia vir a culminar em muitas previsões errôneas. Para contornar este problema, decidiu-se então propor redes neurais para cada mês do ano, modelando mais adequadamente as características próprias de cada mês.

O passo seguinte consistiu em dimensionar diferentes redes neurais para o problema em questão. Seguindo algumas sugestões existentes na literatura para *time delay neural networks* [Palit and Popovic 2005], decidiu-se adotar a regra da pirâmide geométrica, que estabelece que o número de neurônios nas camadas ocultas  $N_h$  deve ser igual a:

$$N_h = \alpha \sqrt{N_i \cdot N_o}, \quad (1)$$

em que  $N_i = 37$  é o número de neurônios na camada de entrada,  $N_o = 1$  é o número de neurônios na camada de saída e  $\alpha$  é um valor no intervalo de  $0.5 \leq \alpha \leq 2$ . Desta forma, o número de neurônios na camada oculta  $N_h$  deve ficar entre 3 e 12.

Distribuindo o neurônios obtidos em duas camadas ocultas, as arquiteturas de redes neurais consideradas foram: (37-3-1), (37-4-1), (37-5-1), (37-6-1), (37-7-1), (37-8-1), (37-9-1), (37-10-1), (37-11-1), (37-12-1), (37-3-9-1), (37-4-8-1), (37-5-7-1), (37-6-6-1), (37-7-5-1), (37-8-4-1), (37-9-3-1). Além destas arquiteturas, considerou-se o treinamento das redes com as funções de ativação sigmoideal ou tangente hiperbólica, taxa de aprendizado adaptativa igual a 0.001 ou 0.003, com fração de decréscimo igual 0.0001 ou 0.01. Como resultado, para cada mês do ano foram propostas 136 redes neurais.

Para a implementação, treino e teste destas redes neurais propostas, treino e testes, foi utilizado o ferramental da linguagem de programação Python, nos quais o *framework* `sci-kit learn`<sup>1</sup> e a biblioteca `pandas`<sup>2</sup> possuíram papel central.

Para o treinamento das redes neurais, em particular, consideraram-se os dados no período de 1950 a 2000, correspondentes a uma partição de 76% do conjunto de dados. O ajustes de peso em cada rede estava sujeito a um limite máximo de 200 épocas e os atributores previsoires deveriam ser normalizados antes da apresentação às redes. As redes foram treinadas com o algoritmo de *backpropagation* na versão otimizada do método de Levenberg-Marquadt. Para permitir a comparação entre as diferentes redes nesta tarefa de aprendizagem, optou-se pela utilização da acurácia no conjunto de testes (2001 a 2015) como métrica de desempenho.

## 5. Resultados e Discussão

Após a realização do treinamento e teste das redes neurais propostas, conforme detalhado na seção anterior, partiu-se para uma análise minuciosa dos resultados a fim de identificar os modelos com melhores resultados para o problema considerado.


Em termo de acurácia, métrica de desempenho adotada, observou-se que diferentes redes treinadas e testadas com os mesmos parâmetros obtiveram resultados significativamente diferentes, conforme ilustrado na Figura 3. Este resultado tão heterogêneo

---

<sup>1</sup><http://scikit-learn.org/>

<sup>2</sup><http://pandas.pydata.org/>

ressalta as dificuldades inerentes ao domínio do problema e a não-trivialidade na identificação de redes neurais que capturem adequadamente os padrões existentes.



**Figura 3: Gráfico de *boxplot* para a média das acurácias obtidas para as redes testadas para cada mês do ano.**

Considerando a maior acurácia, foi possível elencar uma arquitetura de rede neural com melhor desempenho no conjunto de testes de cada mês. Estas redes e a acurácia obtida são mostradas na Tabela 2. É possível observar que, em quase 70% dos meses do ano, as melhores redes neurais para previsão de precipitação possuem apenas uma camada oculta. Este aspecto evidencia a simplicidade estrutural na maioria dos modelos identificados.

**Tabela 2: Redes neurais com maior acurácia para previsão do volume de precipitações em Manaus nos diferentes meses do ano.**

Mês	Arquitetura	Função de Ativação	Taxa de Aprendizado	Taxa de Decréscimo	Acurácia
1	(37, 9, 1)	Tangente Hiperbólica	0.0001	0.003	0.93
2	(37, 7, 1)	Sigmoidal	0.0001	0.003	0.93
3	(37, 8, 4, 1)	Tangente Hiperbólica	0.0001	0.001	1.00
4	(37, 4, 1)	Tangente Hiperbólica	0.0001	0.001	0.87
5	(37, 8, 1)	Tangente Hiperbólica	0.0100	0.001	0.93
6	(37, 5, 1)	Tangente Hiperbólica	0.0100	0.003	0.87
7	(37, 8, 1)	Tangente Hiperbólica	0.0100	0.003	0.93
8	(37, 6, 6, 1)	Sigmoidal	0.0001	0.003	0.93
9	(37, 8, 4, 1)	Tangente Hiperbólica	0.0001	0.003	1.00
10	(37, 8, 1)	Tangente Hiperbólica	0.0001	0.003	0.87
11	(37, 8, 1)	Tangente Hiperbólica	0.0001	0.001	0.93
12	(37, 9, 3, 1)	Tangente Hiperbólica	0.0100	0.003	0.87

A abordagem de elaborar uma rede específica para capturar os padrões do volume de precipitação de cada mês do ano resultaram em uma acurácia média de 92.16%. Este resultado é comparável ao estado da arte [de Lima 2016], que prevê a ocorrência de precipitações com grande acurácia (99.7%), mas que não prevê o volume associado às mesmas. Um outro constraste com resultados existentes diz respeito à elaboração de

múltiplas redes neurais, em que cada uma é capaz de descrever o volume de precipitações específico de cada um dos meses do ano, ao invés de propor um único modelo para todo o ano, pouco especializado em capturar as características tão diversas da precipitação ao longo dos meses.

## 6. Considerações Finais

Este trabalho teve por objetivo abordar o problema da previsão do volume de precipitações mensais na cidade de Manaus, Amazonas. Para tanto, considerou a utilização de redes neurais e a extração de padrões do volume de precipitação dos seis meses anteriores e de índices climáticos que influenciam o regime de precipitações na região considerada. Como resultado, foi identificada uma arquitetura de rede neural adequada para cada mês do ano, a qual obteve melhor acurácia no conjunto de testes. No geral, as redes propostas obtiveram acurácia média de 92.16% para o cenário considerado.

Os resultados obtidos neste trabalho colaboram para o entendimento do volume de precipitações na cidade de Manaus e os modelos propostos podem ser utilizados por órgãos governamentais para auxiliar no planejamento estratégico de atividades dependentes do regime de chuvas, especialmente a Agricultura. Além destes aspectos, pôde-se observar a adequação das rede neurais para o domínio do problema e a importância dos dados oriundos de estações meteorológicas.

Em trabalhos futuros almeja-se investigar o problema de forma mais específica, almejando a obtenção do volume estimado de precipitações mensais e também anuais. A comparação com outros modelos e técnicas da Aprendizagem de Máquina também será efetuada.

## Agradecimentos

A autora Nicoli Pinheiro de Araújo agradece o apoio financeiro do CNPq por meio do Programa de Apoio à Iniciação Científica da Universidade do Estado do Amazonas edição 2016-2017.

## Referências

- [Adams et al. 2005] Adams, C., Murrieta, R. S. S., and Sanches, R. A. (2005). Agricultura e alimentação em populações ribeirinhas das várzeas do Amazonas: novas perspectivas. *Ambiente & Sociedade*, 8(1):1–22.
- [Adya and Collopy 1998] Adya, M. and Collopy, F. (1998). How effective are neural networks at forecasting and prediction? a review and evaluation. *J. Forecasting*, 17:481–495.
- [da Silva 2012] da Silva, D. A. (2012). Função da precipitação no conforto do clima urbano da cidade de Manaus. *Revista Geonorte*, 1(5):22–40.
- [Darji et al. 2015] Darji, M. P., Dabhi, V. K., and Prajapati, H. B. (2015). Rainfall forecasting using neural network: A survey. In *International Conference on Advances in Computer Engineering and Applications*, India. IMS Engineering College.
- [de Lima 2016] de Lima, P. M. (2016). Redes neurais para predição de séries temporais de precipitação em Manaus, Amazonas. Monografia de Engenharia de Computação, Universidade do Estado do Amazonas.



- [de Lima and Guedes 2015a] de Lima, P. M. and Guedes, E. B. (2015a). Rainfall prediction for Manaus, Amazonas with artificial neural networks. In *Latin America Congress on Computational Intelligence*, Curitiba, Paraná.
- [de Lima and Guedes 2015b] de Lima, P. M. and Guedes, E. B. (2015b). Uma abordagem baseada em redes neurais para a previsão de chuva em Manaus, Amazonas. In *Congresso Amazônico de Computação e Sistemas Inteligentes*, pages 149–158, Manaus, Amazonas.
- [Fisch et al. 1998] Fisch, G., Marengo, J. A., and Nobre, C. A. (1998). Uma revisão geral sobre o clima da Amazônia. *Acta Amaz.*, 28(2):101.
- [Guedes et al. 2016] Guedes, E. B., de Lima, P. M., and de Oliveira, M. B. L. (2016). Neural networks for time series rainfall forecasting: A case study in Manaus, Amazonas. In *Encontro Nacional de Inteligência Artificial e Computacional*, pages 337–348, Recife, Pernambuco.
- [Htike and Khalifa 2010] Htike, K. K. and Khalifa, O. O. (2010). Rainfall forecasting models using focused time-delay neural networks. In *2010 International Conference on Computer and Communication Engineering*, pages 1–6, Malásia. IEEE.
- [INMET 2017] INMET (2017). Instituto Nacional de Meteorologia. <http://www.inmet.gov.br>.
- [Limberger and Silva 2016] Limberger, L. and Silva, M. E. S. (2016). Precipitação na bacia amazônica e sua associação à variabilidade da temperatura na superfície dos oceanos Pacífico e Atlântico: uma revisão. *GEOUSP – Espaço e Tempo*, 20(3):657–675.
- [Palit and Popovic 2005] Palit, A. K. and Popovic, D. (2005). *Computational Intelligence in Time Series Forecasting - Theory and Engineering Applications*. Springer, Londres, 1 edition.
- [Sioli 1991] Sioli, H. (1991). *Amazônia: Fundamentos da Ecologia da maior região de florestas tropicais*. Vozes, Manaus.
- [Torres and de Oliveira Machado 2012] Torres, F. T. P. and de Oliveira Machado, P. J. (2012). *Introdução à Climatologia*. Cengage Learning.