



IV-260 - AVALIAÇÃO DE DESEMPENHO DE REDES NEURAIS ARTIFICIAIS NA PREVISÃO SAZONAL DE PRECIPITAÇÃO NA REGIÃO HIDROGRÁFICA DOS SERTÕES DE CRATEÚS

Francisco Igor Siqueira Evangelista

Engenheiro Civil pela Universidade Federal do Ceará, Campus Crateús (2019).

Alan Michell Barros Alexandre ⁽¹⁾

Engenheiro Civil pela Universidade de Fortaleza (2002), mestre e doutor em Engenharia Civil (Recursos Hídricos) pela Universidade Federal do Ceará (2005 e 2012). Professor Adjunto da Universidade Federal do Ceará, Campus de Crateús.

José Kerlly Soares de Araújo

Engenheiro Civil pela Universidade Federal do Ceará, Campus Crateús (2024). Mestrando em Engenharia Civil (Recursos Hídricos), POSDEHA/UFC.

Endereço ⁽¹⁾: Avenida Professora Machadinha Lima, S/N, Príncipe Imperial, Crateús-CE, CEP 63708-825. Fone: +55 (88) 3691-9700 - e-mail: alanmichell@crateus.ufc.br.

RESUMO

O clima do Nordeste Brasileiro (NEB) é marcado por características predominantemente semiáridas, onde a distribuição da precipitação varia significativamente tanto em escala temporal quanto espacial. Nessa região a variabilidade interanual da precipitação e os baixos índices pluviométricos anuais, são fatores preponderantes para a ocorrência de secas. Dessa forma, a complexidade e a variabilidade climática da região, tornam a previsão do regime de precipitações sazonais um grande desafio. O presente trabalho tem o objetivo avaliar a previsibilidade do regime pluviométrico da Região Hidrográfica dos Sertões de Crateús, a partir da variabilidade da Temperatura de Superfície do Mar (TSM) do oceano Pacífico equatorial e Atlântico tropical, utilizando técnicas de redes neurais artificiais (RNA). Para tanto, foram analisados quatro períodos preditivos, semestre chuvoso - dezembro a maio (DJFMAM), quadra chuvosa - fevereiro a maio (FMAM), primeiro trimestre chuvoso - dezembro a fevereiro (DJF), e segundo trimestre chuvoso - março a maio (MAM). As variáveis preditivas são compostas por 12 índices climáticos de TSM, formados pelas médias de três meses de anomalias de TSM em 12 regiões, para quatro períodos imediatamente anteriores a cada período preditivo, a saber, os trimestres de dezembro a fevereiro (DJF), setembro a novembro (SON), junho a agosto (JJA), março a maio (MAM). Os modelos tiveram sua acurácia medida pelo coeficiente de correlação de Pearson (R) e a medida de eficiência proposta em Nash e Sutcliffe (1970) (NASH). O modelo com maior capacidade preditiva foi o M9 para o trimestre chuvoso MAM e os índices TSM de DJF apresentando $R = 0,823$ e $NASH = 0,663$.

PALAVRAS-CHAVE: Previsão climática, Temperatura da Superfície do Mar (TSM), Multilayer Perceptron.

INTRODUÇÃO

O clima do Nordeste Brasileiro (NEB) é marcado por características predominantemente semiáridas, onde a distribuição da precipitação varia significativamente tanto em escala temporal quanto espacial. Os prolongados períodos de escassez hídrica e episódios de chuvas intensas trazem graves desafios sociais e econômicos, agravados pela frequência desses eventos (Nobre, 2012).

Os baixos índices pluviométricos anuais característicos da climatologia do semiárido nordestino, associada a concentração do período chuvoso em cerca de três a quatro meses e a alta variabilidade interanual da precipitação, são fatores preponderantes para a ocorrência de secas na região. De forma geral o regime pluviométrico no NEB está relacionado a variações de padrões de Temperatura da Superfície do Mar (TSM) sobre os oceanos tropicais, os quais alteram a posição e a intensidade da Zona de Convergência Intertropical (ZCIT) sobre o oceano Atlântico, reconhecidamente o maior sistema gerador de precipitações na zona setentrional do NEB (Repelli; Alves, 1996; Ferreira; Mello, 2005).

A complexidade e alta variabilidade climática da região tornam a previsão do regime de precipitações sazonais um grande desafio técnico. Neste aspecto, as redes neurais artificiais (RNA) emergem como uma alternativa promissora, devido à sua capacidade avançada de aprendizagem, que reproduz o funcionamento do cérebro humano. Essas ferramentas se mostram eficazes na modelagem de fenômenos complexos e multivariados, como a interação entre variáveis hidrológicas e dados climáticos (Araújo *et al.*, 2015).

As redes *Multilayer Perceptron* (MLP) apresentam possibilidades de aplicações na solução de diversos tipos de problemas, em uma grande gama de áreas do conhecimento, portanto, considerada uma arquitetura extremamente versátil. As áreas com maior potencial de aplicação são: aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais e otimização de sistemas (Silva; Spatti; Flauzino, 2010).

Pesquisas recentes realçam os excelentes resultados obtidos com o uso de RNA na área de recursos hídricos e hidrologia, especialmente na simulação, previsão e classificação de dados (Jain *et al.*, 2004; Bowden *et al.*, 2005; Jain; Kumar, 2007; Oliveira *et al.*, 2013). Entre os diversos tipos de RNA, a MLP se destaca, sendo amplamente empregado em estudos relacionados a recursos hídricos, como demonstrado nos trabalhos de Figueiredo *et al.* (2007), Gomes *et al.* (2010), Cruz *et al.* (2010), Rocha *et al.* (2013), Telles *et al.* (2013), Araújo *et al.* (2015), Debastiani *et al.* (2016), Charles (2017), Araújo Júnior *et al.* (2019) e Carvalho *et al.* (2021).

Dessa forma, este estudo tem o objetivo geral avaliar a previsibilidade do regime pluviométrico sazonal da Região Hidrográfica dos Sertões de Crateús (RHSC) a partir da variabilidade da temperatura superfície do mar (TSM), utilizando técnicas de RNA. Especificamente, pretende-se: i) Determinar modelos de previsão de precipitação a partir da associação dos diferentes índices TSM por ordem de influência; ii) Avaliar o desempenho dos diferentes modelos de previsão sazonal de precipitação a partir das métricas de avaliação selecionadas; e iii) Apresentar os modelos preditores com melhores desempenhos para os diferentes períodos preditivos adotados.

MATERIAIS E MÉTODOS

A Região Hidrográfica dos Sertões de Crateús (RHSC) tem como rio principal o Poti, que nasce no Ceará e possui a foz no rio Parnaíba (PI). A RHSC conta com uma capacidade de acumulação de 446,69 hm³, divididos em 10 reservatórios estratégicos. Na Figura 1 é apresentada a localização da área de estudo em relação as demais regiões hidrográficas de planejamento do estado do Ceará.



Figura 1 - Regiões hidrográficas do Estado do Ceará. Fonte: SRH-CE (2013).

Levantamento dos Dados

As anomalias de Temperatura da Superfície do Mar (TSM) utilizadas nas análises realizadas nesse estudo foram obtidas a partir do sítio do *Earth System Research Laboratory* (ESRL) do *National Oceanic and Atmospheric Administration* (NOAA) em <http://www.esrl.noaa.gov/psd/data/climateindices/list>. Os índices TSM foram selecionados a partir do estudo de Evangelista *et al.* (2024), onde foram determinadas a ordem de importância dos índices TSM em explicar a variabilidade de precipitações sazonais da RHSC, com diferentes períodos de antecedência. Os índices utilizados como variáveis explicativas são apresentados na Tabela 1.

Tabela 1 - Índices TSM utilizados como variáveis explicativas

Sigla	Índice (em inglês)	Índice (em português)
TAD	<i>Tropical Atlantic Dipole</i>	Dipolo do Atlântico Tropical
TNA	<i>Tropical Northern Atlantic</i>	Atlântico Tropical Norte
TSA	<i>Tropical Southern Atlantic</i>	Atlântico Tropical Sul
NINO1.2	<i>Niño 1 + 2</i>	Niño 1 + 2
NINO3.4	<i>Niño 3.4</i>	Niño 3.4
NINO3	<i>Niño 3</i>	Niño 3
NINO4	<i>Niño 4</i>	Niño 4
NAO	<i>North Atlantic Oscillation</i>	Oscilação do Atlântico Norte
MEI	<i>Multivariate ENSO Index</i>	ENSO multivariado
PDO	<i>Pacific Decadal Oscillation</i>	Oscilação Decadal do Pacífico
AMO	<i>Atlantic Multidecadal Oscillation</i>	Oscilação Multidecadal do Atlântico
ONI	<i>Oceanic Niño Index</i>	Niño Oceânico

A série temporal da precipitação sobre a RHSC foi obtida na plataforma Hidroweb da Agência Nacional de Águas e Saneamento Básico (ANA) em: <http://www.snirh.gov.br/hidroweb>, onde foram selecionadas as estações pluviométricas com área de influência na região, e seguida a média ponderada foi calculada através do método de Thiessen.

Desse modo, a série histórica de precipitação calculada compreende os anos de 1911 a 2018, porém como NOAA disponibiliza seus dados para alguns índices apenas a partir de 1950, foi necessário restringir a série histórica para o período de 1950 a 2017.

Estratégia Metodológica

A estratégia metodológica implementada para a previsão da precipitação sazonal pode ser observada na Figura 2. A abordagem é estruturada em quatro períodos preditivos, a saber: DJFMAM - semestre chuvoso, de dezembro a maio, englobando a chuvas de pré-estação e quadra chuvosa; FMAM - quadra chuvosa, de fevereiro a maio; DJF - primeiro trimestre chuvoso, de dezembro a fevereiro; MAM - segundo trimestre chuvoso, de março a maio. Para cada um desses períodos, os índices TSM avaliados como variáveis explicativas foram definidos como a média das anomalias de temperatura para os quatro trimestres preditores: dezembro a fevereiro (DJF), setembro a novembro (SON), julho a agosto (JJA), e março a maio (MAM).

Desenvolvimento dos Modelos de Previsão

O cálculo da precipitação sazonal foi efetuado a partir de modelos utilizando a rede neural *Multilayer Perceptron* (MLP). Na análise de previsibilidade foram desenvolvidos 12 modelos distintos, cada um integrando um conjunto de índices TSM, escolhidos em ordem de importância com base em Evangelista *et al.* (2024), as variáveis preditoras são inseridas progressivamente. Ou seja, o primeiro modelo (M1) emprega a variável preditora mais significativa. O segundo modelo (M2) inclui as duas variáveis mais importantes, e este padrão continua sequencialmente, ou seja, o Modelo M12 é calculado com as 12 variáveis mais importantes, como é exposto na camada de entrada da Figura 3.

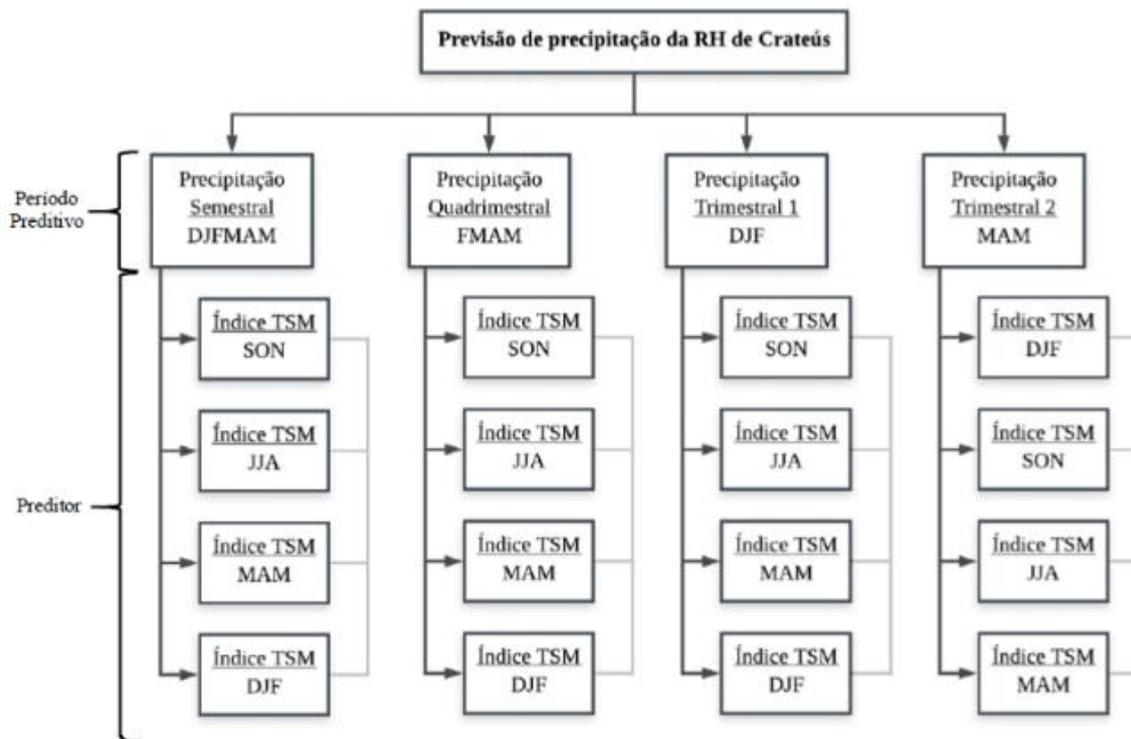


Figura 2 - Estratégia metodológica utilizada para determinação da precipitação na RHSC

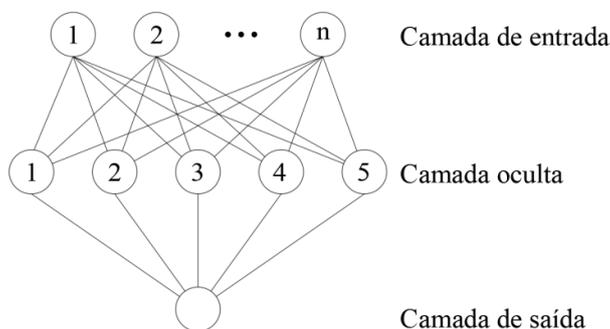


Figura 3 - Estrutura do modelo de previsão de precipitação da RHSC

No desenvolvimento da rede neural MLP foi necessária a normalização de todos os dados utilizados seja das variáveis de entrada, anomalias de TSM, ou dados de saída, série de dados de precipitação. Assim, os valores dos dados de entrada e saída foram definidos como valores que variam entre 0 e 1. A Equação 1 apresenta a formulação utilizada, onde o vetor x consiste nos dados que se pretende normalizar.

$$x_j^* = 2 \left(\frac{x_j - x_j^{min}}{x_j - x_j^{max}} \right) - 1 \tag{equação (1)}$$

Os dados utilizados na modelagem foram separados aleatoriamente, nas proporções de 80% para o treinamento e 20% para a etapa de validação, portanto formando uma série com 53 anos para o treinamento e 14 anos para a validação. Vale ressaltar que a etapa de treinamento consiste no processo de aprendizagem da rede neural, enquanto o processo de validação serve para analisar se a rede apresenta resultados satisfatórios ao modelar o fenômeno estudado.

A arquitetura da rede neural MLP foi implementada usando o pacote “RSNNS” no *software* Rstudio, onde os quatro principais parâmetros são “hidden”, “inputsTest”, “targetTest” e “learnFunc”. O parâmetro “hidden” está relacionado ao número de neurônios, sendo adotado o valor de 5 para as situações analisadas, como é apresentado na camada oculta da Figura 3. O “inputsTest” está relacionado a matriz com as variáveis de entrada para o treinamento e “targetTest” corresponde a entrada dos dados de validação (Bergmeir; Benítez, 2012).

O “learnFunc” é a função que define como o aprendizado ocorre na rede, sendo utilizado o “Std_Backpropagation”, que possui dois parâmetros, a taxa de aprendizado e a diferença máxima de saída. A taxa de aprendizado geralmente é um valor entre 0,1 e 1, especificando a largura da etapa de descida do gradiente. A diferença máxima define qual diferença entre a saída e o valor de destino é tratada como erro zero e não é retropropagada, sendo utilizado para evitar o excesso de treinamento (Zell *et al.*, 1993).

Além disso, foi estabelecido um limite máximo de 1000 iterações para a compilação do modelo. A função sigmoide foi escolhida como função de ativação, conforme descrito na Equação 2.

$$\varphi = (v) = \frac{1}{1 + e^{(-x)}} \quad \text{equação (2)}$$

Abordagem Estatística

Para a análise da performance dos modelos utilizou-se o coeficiente de Correlação de Pearson (R), que é a medida da associação linear entre as observações e previsões, definido na Equação 3. Este índice é adimensional, podendo variar de 1 a -1, sendo os valores extremos correspondentes a uma previsão perfeita, piorando o desempenho ao se aproximar do zero (Guarnieri, 2006).

$$R = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{(P_i - \bar{P})}{S_p} \right) \left(\frac{(O_i - \bar{O})}{S_o} \right) \quad \text{equação (3)}$$

Em que: O e P são os valores observados e os da previsão, S é o desvio padrão, \bar{P} e \bar{O} são as médias das previsões e observações e N o número de observações. Conforme Dancey e Reidy (2005), valores de 0,10 a 0,30 indicam correlações fracas, enquanto valores de 0,40 a 0,60 indicam correlações moderadas, e valores de 0,70 a 1,00 indicam correlações fortes.

A performance do modelo RNA também foi mensurada a partir do coeficiente de eficiência proposto por Nash; Sutcliffe (1970), ou apenas NASH, sendo exposto na Equação 4.

$$NASH = 1 - \frac{\sum (P_{cal}^t + P_{obs}^t)^2}{\sum (P_{obs}^t + \bar{P}_{obs})^2} \quad \text{equação (4)}$$

Em que: P_{obs}^t é a precipitação observada, P_{cal}^t é a precipitação calculado pelo RNA e t é referente a precipitação no tempo t, \bar{P}_{obs} é a média da precipitação observada.

Este índice pode variar de -∞ a 1, em que o valor 1 para o NASH corresponde a uma combinação perfeita entre a precipitação observada e a precipitação calculada. Em casos de eficiência igual a zero, indica que a precipitação obtida pelo modelo é tão precisa quanto a média observada. Em casos de NASH negativo, tem-se que a média da precipitação observada é um melhor preditor do que a saídas do modelo (Moriassi *et al.*, 2007). Além disso, o NASH adotado prioriza precipitações altas (Estácio; Souza Filho; Rocha, 2019).

De acordo com Moriassi *et al.*, (2007), valores de Nash superiores a 0,75 são considerados muito bons, entre 0,65 e 0,75 são bons, entre 0,50 e 0,65 são satisfatórios, e valores iguais ou inferiores a 0,50 são considerados insatisfatórios.

RESULTADOS

Previsão da precipitação para o semestre de dezembro a maio

Os resultados obtidos semestre chuvoso DJFMAM na Região Hidrográfica dos Sertões de Crateús (RHSC) são detalhados na Tabela 2, representados pelos três modelos que alcançaram os melhores desempenhos conforme as métricas de avaliação, coeficiente de correlação de Pearson (R) e coeficiente de eficiência NASH, para a fase de treinamento e validação.

Tabela 2 – Melhores modelos da precipitação para DJFMAM

Preditor	Treinamento						Validação					
	1°		2°		3°		1°		2°		3°	
	R	M	R	M	R	M	R	M	R	M	R	M
SON	0,606	12	0,600	11	0,600	10	0,738	3	0,667	4	0,643	9
JJA	0,559	12	0,558	10	0,557	11	0,630	7	0,608	3	0,606	4
MAM	0,618	12	0,616	11	0,569	10	0,204	1	0,195	3	0,186	11
DJF	0,556	12	0,525	11	0,523	9	0,208	3	0,185	5	0,162	4

Preditor	Treinamento						Validação					
	1°		2°		3°		1°		2°		3°	
	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M
SON	0,362	12	0,359	10	0,358	9	0,364	4	0,351	8	0,345	12
JJA	0,310	10	0,305	11	0,294	12	0,261	12	0,254	3	0,252	7
MAM	0,377	11	0,375	12	0,322	10	-0,244	8	-0,208	10	-0,204	6
DJF	0,300	12	0,274	11	0,266	7	-0,355	12	-0,336	11	0,330	8

De acordo com a Tabela 2, a correlação (R) entre a precipitação observada e a prevista pelas Redes Neurais Artificiais (RNA) foi mais significativa ao utilizar os preditores do trimestre SON, tanto na etapa de validação quanto no treinamento. Em contraste, os resultados do NASH mostraram que, na etapa de validação, os preditores com menor antecedência SON e JJA foram mais eficientes, enquanto os preditores de longo prazo MAM e DJF apresentaram majoritariamente baixas correlações e valores negativos de NASH.

Previsão da precipitação para a quadra chuvosa

De forma similar, os resultados obtidos para quadra chuvosa FMAM, são apresentados na Tabela 3 os três modelos que alcançaram os melhores desempenhos conforme as métricas de avaliação para a fase de treinamento e validação.

Tabela 3 – Melhores modelos da precipitação para FMAM (continua)

Preditor	Treinamento						Validação					
	1°		2°		3°		1°		2°		3°	
	R	M	R	M	R	M	R	M	R	M	R	M
SON	0,603	10	0,603	12	0,599	9	0,627	4	0,620	3	0,609	10
JJA	0,558	12	0,554	11	0,532	10	0,724	2	0,689	3	0,679	4
MAM	0,631	12	0,605	11	0,586	10	0,227	11	0,191	9	0,186	10
DJF	0,447	12	0,463	11	0,441	10	0,261	8	0,250	9	0,243	2

Tabela 3 – Melhores modelos da precipitação para FMAM

Preditor	Treinamento						Validação					
	1°		2°		3°		1°		2°		3°	
	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M
SON	0,361	10	0,358	9	0,354	11	0,300	10	0,291	12	0,279	11
JJA	0,302	11	0,283	12	0,281	10	0,240	12	0,239	10	0,239	3
MAM	0,393	12	0,363	11	0,340	10	0,297	7	0,297	5	0,293	6
DJF	0,224	12	0,211	11	0,193	10	-0,218	12	-0,136	11	-0,074	10

Para a quadra chuvosa FMAM (Tabela 3), os dados de treinamento demonstraram que a correlação (R) e o NASH foram mais elevados usando o preditor do terceiro trimestre anterior MAM. Na etapa de validação, os maiores valores de R ocorreram com o preditor JJA. Nos resultados do NASH, a etapa de treinamento superou a de validação, sendo mais notável com o preditor MAM. Além disso, os melhores resultados de treinamento foram alcançados nos três últimos modelos, M11, M12 e M10, caracterizados por uma maior quantidade de índices agregados, enquanto a validação mostrou maior variabilidade nos modelos de melhor desempenho.

Previsão da precipitação para o trimestre de dezembro a fevereiro

Os resultados obtidos para o período preditor trimestral DJF são detalhados na Tabela 4, representados pelos três modelos que alcançaram os melhores desempenhos conforme as métricas de avaliação para a fase de treinamento e validação.

Tabela 4 – Melhores modelos da precipitação para DJF

Preditor	Treinamento						Validação					
	1°		2°		3°		1°		2°		3°	
	R	M	R	M	R	M	R	M	R	M	R	M
SON	0,561	11	0,559	12	0,548	10	0,642	1	0,636	2	0,611	11
JJA	0,448	12	0,428	10	0,427	11	0,692	5	0,686	6	0,685	7
MAM	0,341	12	0,316	11	0,315	10	0,652	2	0,647	3	0,645	4
DJF	0,419	11	0,412	12	0,404	10	0,367	2	0,363	3	0,361	4

Preditor	Treinamento						Validação					
	1°		2°		3°		1°		2°		3°	
	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M
SON	0,312	11	0,312	12	0,299	10	0,360	1	0,336	10	0,334	12
JJA	0,200	12	0,182	10	0,181	11	0,420	5	0,411	7	0,409	6
MAM	0,115	12	0,100	11	0,099	10	0,245	3	0,239	2	0,231	4
DJF	0,175	11	0,166	12	0,163	10	0,126	2	0,123	3	0,123	5

Especificamente para o trimestre DJF, a etapa de treinamento revelou que tanto a correlação (R) quanto o NASH foram mais altos com o preditor do trimestre imediatamente anterior SON (Tabela 4). Para este período preditivo o NASH não registrou valores negativos em nenhum dos quatro períodos preditores. Na etapa de validação, os maiores valores de R e NASH foram obtidos com o trimestre JJA como preditor. Somente no último preditor o treinamento superou a validação. Adicionalmente, a etapa de treinamento apresentou os melhores resultados nos três modelos últimos modelos (M10, M11 e M12), enquanto a validação exibiu maior variação entre os modelos que obtiveram maiores resultados.

Previsão da precipitação para o trimestre de março a maio

A Tabela 5 apresenta para o segundo trimestre chuvoso, MAM, os três modelos que alcançaram os melhores desempenhos conforme as métricas de avaliação para a fase de treinamento e validação.

Tabela 5 – Melhores modelos da precipitação para MAM

Preditor	Treinamento						Validação					
	1°		2°		3°		1°		2°		3°	
	R	M	R	M	R	M	R	M	R	M	R	M
DJF	0,740	12	0,739	11	0,737	8	0,823	9	0,815	10	0,814	11
SON	0,567	10	0,567	12	0,563	11	0,695	4	0,663	10	0,654	9
JJA	0,527	11	0,523	12	0,509	10	0,567	4	0,542	7	0,539	6
MAM	0,609	11	0,608	12	0,554	9	-0,059	10	-0,051	9	-0,037	4

Preditor	Treinamento						Validação					
	1°		2°		3°		1°		2°		3°	
	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M	NASH	M
DJF	0,545	12	0,543	10	0,540	8	0,663	9	0,656	10	0,654	11
SON	0,319	10	0,314	11	0,314	12	0,310	10	0,292	4	0,286	9
JJA	0,273	11	0,261	12	0,259	10	0,150	10	0,150	8	0,141	7
MAM	0,368	11	0,367	12	0,303	10	-0,424	10	-0,423	9	-0,401	11

Para o trimestre MAM, tanto no treinamento quanto na validação, a correlação (R) e o NASH foram mais elevados utilizando o preditor de um trimestre anterior DJF (Tabela 5). Essa tendência se manteve, exceto para o último preditor do NASH, onde os valores negativos foram classificados entre os melhores resultados. Na validação, os maiores valores de R e NASH foram observados, com exceção do último preditor, onde o treinamento teve desempenho superior. No caso do período preditor JJA, o treinamento mostrou-se mais eficaz segundo o NASH.

Análise Geral

Para uma análise geral, na Tabela 6 é possível observar os maiores valores de correlação (R) e NASH, com seu respectivo preditor, para cada período preditivo que foi analisado e o indicador do modelo (M).

Tabela 6 – Melhores modelos da precipitação para MAM

Período Preditivo	Correlação (R)			NASH		
	Preditor	Valor	Modelo	Preditor	Valor	Modelo
DJFMAM	SON	0,738	M3	SON	0,364	M4
FMAM	JJA	0,724	M2	SON	0,300	M10
DJF	JJA	0,692	M5	JJA	0,420	M5
MAM	DJF	0,823	M9	DJF	0,663	M9

Para todas as análises realizadas observa-se que o modelo com maior capacidade preditiva foi o M9 para o trimestre chuvoso MAM a partir dos índices TSM de DJF apresentando R = 0,823 e NASH = 0,663. De modo a melhor verificar o comportamento desse modelo, são apresentadas nas Figuras 4 e 5 a comparação entre a precipitação real e a prevista durante as etapas de treinamento (R = 0,740 e NASH = 0,545) e validação, respectivamente. Durante o treinamento, a precipitação real tende a ser maior do que a prevista na maioria dos casos. Na validação, há uma correlação satisfatória entre os valores previstos e desejados, com apenas alguns valores discrepantes.

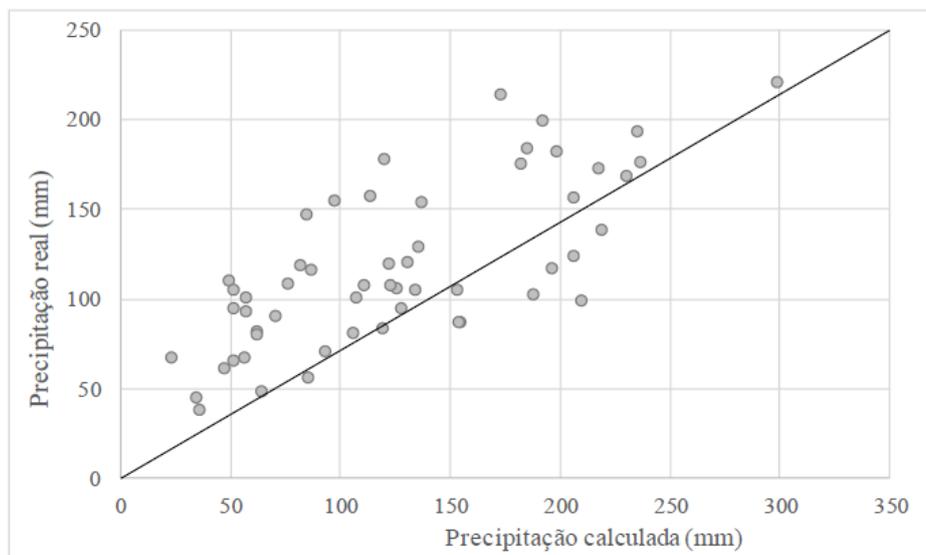


Figura 4 – Relação entre valores calculados e observados para precipitação RHSC (MAM) e índice TSM (DJF) na fase de treinamento com $R=0,740$ e $NASH=0,545$

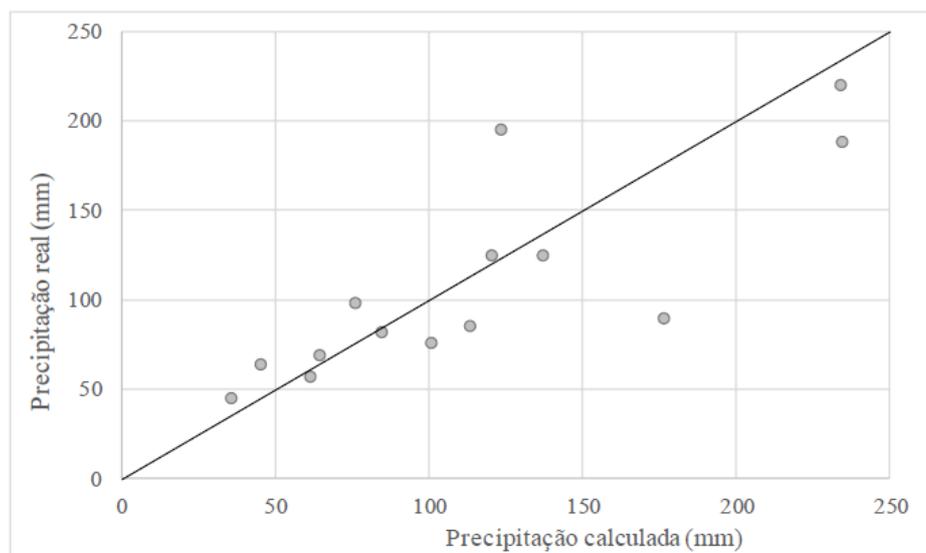


Figura 5 - Relação entre valores calculados e observados para precipitação RHSC (MAM) e índice TSM (DJF) na fase de validação com $R=0,823$ e $NASH=0,663$

CONCLUSÕES

Este estudo teve como objetivo a avaliação da eficácia de modelos baseados em Redes Neurais Artificiais (RNA) para previsão de precipitação sazonal na Região Hidrográfica dos Sertões de Crateús (RHSC) utilizando índices climáticos derivados das anomalias de Temperaturas da Superfície do Mar (TSM), a partir de uma série histórica de 67 anos em dados hidrometeorológicos. Os resultados demonstraram que, no semestre chuvoso, período preditivo DJFMAM, a correlação mais significativa, de 0,738 com o uso de modelo com três variáveis TSM de SON como preditor. Destaca-se também o melhor coeficiente eficiência NASH de 0,364, obtido também a partir das TSM SON, mas agora com um modelo com quatro variáveis.



Durante a quadra chuvosa FMAM, observamos uma correlação máxima de 0,724, com as TSM de JJA como preditor, em modelo de apenas duas variáveis. Já o NASH de 0,300 foi obtido para as TSM de período distinto, SON, mas agora com um modelo de dez variáveis, considerado um modelo com muitas variáveis para um baixo desempenho. A diferença apresentada entre o período preditivo em R e NASH, ocorre porque os dois períodos tiveram comportamento similar.

Para a precipitação do trimestre DJF, observou-se correlação de 0,692 e NASH de 0,420, para o mesmo modelo de variáveis com período preditor JJA, apresentando consistência do modelo na fase de validação. No período preditivo MAM, os valores máximos de correlação e NASH foram de 0,823 e 0,663, respectivamente, com as TSM de DJF atuando como preditores, para o mesmo modelo de nove variáveis, apresentando consistência também para esse período.

Conclui-se que, durante a etapa de validação, modelos com um maior número de índices agregados apresentaram maiores valores de correlação (R) e NASH. A fase de treinamento revelou uma maior variabilidade em termos de modelos eficazes, embora modelos com um menor número de índices agregados tenham mostrado maior recorrência de bons resultados. Considerando o tamanho da série histórica, os resultados obtidos são consideráveis, especialmente no que se refere à correlação, que apresenta valores entre moderados e fortes, conforme a classificação de Dancey e Reidy (2005). Entretanto, é importante destacar que os valores de NASH foram, em geral, relativamente baixos e classificados como insatisfatórios segundo a categorização de Moriasi *et al.* (2007), indicando a necessidade de futuras melhorias e ajustes nos modelos propostos.

REFERÊNCIAS BIBLIOGRÁFICAS

1. ARAÚJO JÚNIOR, L. M. A.; SOUZA FILHO, F. A. S.; BARRETO, G. A. Previsão de vazão: Multi modelos. In: ADAPTA: Gestão adaptativa do risco climático de seca/ organizado por Francisco de Assis de Souza Filho *et al.* Fortaleza: Expressão Gráfica e Editora, 2019.
2. ARAÚJO, C. B. C. de; DANTAS NETO, S. A.; SOUZA FILHO, F. de A. Previsão de vazões para o açude Orós/CE a partir de dados hidrometeorológicos utilizando perceptrons. Revista Brasileira de Meteorologia, Fortaleza, v. 30, n. 1, p. 37-46, 2015.
3. ARAÚJO, C. B. C. *et al.* Previsão de vazões: Utilização de RNA. In: ADAPTA: Gestão adaptativa do risco climático de seca/ organizado por Francisco de Assis de Souza Filho *et al.* Fortaleza: Expressão Gráfica e Editora, 2019.
4. BERGMEIR, C.; BENÍTEZ, J.M. (2012), 'Neural Networks in R Using the Stuttgart Neural Network Simulator: RSNNS', Journal of Statistical Software, 46(7), 1-26.
5. BOWDEN, G.J., DANDY, G.C., MAIER, H.R. Input determination for neural network models in water resources applications: Part I – background and methodology. Journal of Hydrology, 301, 75-92, 2005.
6. CARVALHO, T. M. N.; SOUZA FILHO, F. A.; PORTO, V. C. Urban water demand modeling using machine learning techniques: Fortaleza - Brazil Case Study. Journal of Water Resources Planning and Management, v. 147, p. 1, 2021.
7. CHARLES A. C.; NAMEN, A. A.; RODRIGUES, P. P. G. W. Comparação de modelos de mineração de dados aplicados a uma estação meteorológica de superfície. RBRH - Revista Brasileira de Recursos Hídricos, v. 22, e58, 2017.
8. CRUZ, M. F. M.; RODRIGUES, L. D; VERSIANI, B. R. Previsão de Vazões com a Metodologia DPFT e com Redes Neurais Artificiais. RBRH - Revista Brasileira de Recursos Hídricos, vol. 15, n.1, p. 121-132, 2010.
9. DEBASTIANI, A. B.; SILVA, R. D.; DANTAS NETO, S. L. F. Eficácia da arquitetura MLP em modo closed-loop para simulação de um Sistema Hidrológico. RBRH - Revista Brasileira de Recursos Hídricos, v. 21, n. 4, p. 821-831, 2016.
10. ESTÁCIO, A. B. S; SOUZA FILHO, F. A. S.; ROCHA, R. V. Análise da incerteza de modelo hidrológico com uso de otimização multiobjetivo e impacto na incerteza de oferta hídrica: estudo de caso do reservatório Orós. In: ADAPTA: Gestão adaptativa do risco climático de seca/ organizado por Francisco de Assis de Souza Filho *et al.* Fortaleza: Expressão Gráfica e Editora, 2019.
11. EVANGELISTA, F. I. S. *et al.* Análise da Variabilidade da Temperatura da Superfície do Mar e o Regime Pluviométrico nos Sertões de Crateús. In: 21° Simpósio Luso-Brasileiro de Engenharia Sanitária e Ambiental, Recife. Anais [...]. Recife: ABES, 2024. p. 1-10.



12. FERREIRA, A.G.; MELLO, N.G.S. Principais sistemas atmosféricos atuantes sobre a região Nordeste do Brasil e a influência dos oceanos Pacífico e Atlântico no clima da região. *Revista Brasileira de Climatologia*, v. 01, n. 01, p. 15-28, 2005.
13. FIGUEIREDO, K. *et al.* Modelo de Previsão de Vazão com Informação de Precipitação Utilizando Redes Neurais. *RBRH - Revista Brasileira de Recursos Hídricos*, v. 12, n. 3, p. 69-82, 2007.
14. GOMES, L. F. C.; MONTENEGRO, S. M. G.; VALENÇA, M. J. S. Modelo Baseado na Técnica de Redes Neurais para Previsão de Vazões na Bacia do Rio São Francisco. *RBRH - Revista Brasileira de Recursos Hídricos*, v. 15, n.1, p. 05-15, 2010.
15. GUARNIERI, R. A. Emprego de redes neurais artificiais e regressão linear múltipla no refinamento das previsões de radiação solar do modelo ETA. Dissertação (Mestre) do Curso de Pós-Graduação em Meteorologia. INPE, São José dos Campos, 2006.
16. JAIN, A. *et al.* Identification of physical processes inherent in artificial neural network rainfall runoff models. *Hydrological Processes*, v. 18, n. 3, p. 571-581, 2004.
17. JAIN, A.; KUMAR, A. M. Hybrid neural network models for hydrologic time series forecasting. *Applied Soft Computing*, v. 7, n. 2, p. 585-592, 2007.
18. MORIASI, D. N. *et al.* Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *American Society of Agricultural and Biological Engineers*, v. 50, n. 3, p. 885-900, 2007.
19. NASH, J.E.; SUTCLIFFE, J.V. (1970) River Flow Forecasting through Conceptual Model. Part 1—A Discussion of Principles. *Journal of Hydrology*, 10, 282-290.
20. NOBRE, P. As origens das águas no Nordeste: A questão da água no Nordeste. In: Centro de Gestão e Estudos Estratégicos, Agência Nacional de Águas. – Brasília, DF: CGEE, 2012.
21. OLIVEIRA, G. G. *et al.* Simulações hidrológicas com diferentes proporções de área controlada na bacia hidrográfica. *RBRH: Revista Brasileira de Recursos Hídricos*, v. 18, n.3, 2013.
22. REPELLI, C. A.; ALVES, J. M. B. Uso de Análise de Correlações Canônicas para Prognosticar a Variabilidade Espacial da Precipitação Sazonal Sobre o Nordeste do Brasil. *Revista Brasileira de Meteorologia*, v. 11, n. 1/2, 67-75, 1996.
23. ROCHA, V. A. G. M. *et al.* Análise Comparativa Entre RNA, AG e Migha na Determinação de Rugosidades Através de Calibração de Redes Hidráulicas. *RBRH – Revista Brasileira de Recursos Hídricos*, v. 18, n. 1, p. 125-134, 2013.
24. SECRETARIA DE RECURSOS HÍDRICOS. Comitê de bacias hidrográficas. Fortaleza: SRH, 2013.
25. SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. *Redes Neurais Artificiais Para Engenharia E Ciências Aplicadas: Curso Prático. 1ª Edição.* Editora Artliber, 2010.
26. TELLES, W. R. Simulação de uma Pluma de Contaminantes no Rio Macaé Utilizando Redes Neurais Artificiais. *RBRH – Revista Brasileira de Recursos Hídricos*, v. 18, n. 2, p. 165-174, 2013.
27. ZELL, A. *et al.* (1998), 'SNNS Stuttgart Neural Network Simulator User Manual, Version 4.2', IPVR, University of Stuttgart and WSI, University of Tübingen.