



Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Previsão de Focos de Calor na Região Metropolitana de Maceió Utilizando Rede Neural Artificial

Iwldson Guilherme da Silva Santos¹, José Francisco de Oliveira Júnior², Francisco de Assis Salviano de Sousa³, Isnaldo Isaac Barbosa⁴

¹ Doutorando em Meteorologia na Unidade Acadêmica de Ciências Atmosféricas (UACA) e Centro de Tecnologia e Recursos Naturais (CTRN) da Universidade Federal de Campina Grande (UFCG), Campina Grande, Paraíba – Brasil. E-mail: iwldson@gmail.com; ² Prof. Dr. do Laboratório de Meteorologia Aplicada e Meio Ambiente – LAMMA, Instituto de Ciências Atmosféricas (ICAT), Universidade Federal de Alagoas (UFAL), Maceió, Alagoas - Brasil. E-mail: jose.junior@icat.ufal.br; ³ Prof. Dr. de Meteorologia da Universidade Federal de Campina Grande (UFCG). E-mail: fsouza2011@gmail.com; ⁴ Prof. Dr. de Matemática da Universidade Federal de Alagoas (UFAL). E-mail: isnaldo@pos.mat.ufal.br

Artigo recebido em 17/05/2022 e aceito em 20/07/2022

RESUMO

O objetivo deste estudo é o de analisar a previsão de focos de calor (FC) na Região Metropolitana de Maceió (RMM) utilizando Rede Neural Artificial (RNA). Foram usados neste estudo os dados de focos de calor no período de 1999 a 2019, disponíveis no Banco de Dados de Queimadas (BDQueimadas). A previsão foi feita com base na RNA não linear autorregressiva (NAR) com os FC sendo dados de entrada e alvo. As previsões se basearam na função de ativação Tangente Hiperbólica e Sigmoide, para averiguar qual função se adaptaria melhor ao modelo de previsão de FC na RMM. O desempenho do modelo foi verificado pelo diagrama de espalhamento (1:1), com destaque para Regressão Linear Simples (RLS), os coeficientes de determinação (R^2) e de Pearson (r), seguido dos indicadores de erros (EM - Erro Médio, REQM – Raiz do Erro Quadrático Médio, EPAM – Erro Percentual Absoluto Médio). O EM variou entre -0,47 a 1,49 focos, o REQM (1,16 a 7,02 focos) e o EPAM (14,45 a 24,66%). Os coeficientes r (0,08 a 0,52) e R^2 (1 a 58%). Os modelos com base nas funções de ativação foram similares entre observado e previsto, sendo satisfatória na maioria dos municípios. Os modelos não tiveram sucesso na previsão de FC elevados, principalmente nos anos 2008, 2012, 2015 e 2016, período de seca extrema. Os resultados obtidos indicam que a aplicação de RNA na previsão de FC pode auxiliar nas tomadas de decisões dos gestores públicos e no monitoramento de queimadas e incêndios em áreas urbanas. Palavras-chave: incêndios, inteligência artificial, monitoramento ambiental.

Forecast of Fire Foci in the Metropolitan Region of Maceió Using Artificial Neural Network

ABSTRACT

The aim of this study is to analyze the forecast of fire foci (FF) in the Maceió Metropolitan Region (MMR) using Artificial Neural Network (ANN). It was used in the study fire foci data available in the Burning Database (BDQueimadas) in the period from 1999 to 2019. The forecast was made based on the ANN non-linear autoregressive (NAR) with the FF, being input and target data. The forecast was based Hyperbolic Tangent and Sigmoid activation function, to find out which function would best adapt to the forecast model of FF in the MMR. The model performance was based on the Scatter Diagram (1:1), with emphasis on Simple Linear Regression (SLR), the coefficients of determination (R^2) and Pearson's (r), followed by the error indicators (ME – Mean Error, RMSE – Root Mean Square Error, MAPE – Mean Absolute Percentage Error). The ME ranged from -0.47 to 1.49 foci, RMSE (1.16 to 7.02 foci), MAPE (14.45 to 24.66%). The coefficients r (0.08 to 0.52) and R^2 (1 to 58%). The models based on activation function were similar between observed and predicted, being satisfactory in most municipalities. The models were not successful in forecast high FF, especially in the years 2008, 2012, 2015 and 2016, a period of extreme drought. These results obtained in the study indicate that the application of ANN in the forecast of FF can help in the decision-making of public managers and in the monitoring of burnings and fires in urban areas.

Keywords: Fire foci, Artificial Intelligence, Environmental Monitoring.

Introdução

A queimada é uma prática agropastoril, onde o fogo é utilizado de forma controlada. Vale ressaltar que queimada é regulamentada pelo Governo Federal de acordo com o Código Florestal

no artigo nº 38 da Lei nº 12.651/12, que abrange todas as atividades agrícolas (MMA, 2022). Incêndio florestal é caracterizado pelo fogo incontrolável, natural ou antrópico, que atinge a

vegetação com danos socioambientais e econômicos (Lima et al., 2020; Silva et al., 2020; Oliveira-Júnior et al., 2022).

O desmatamento e a agropecuária são fatores que têm elevado o registro de queimadas e incêndios no Brasil, principalmente em áreas rurais, urbanas e em biomas do território brasileiro (Correia-Filho et al., 2019; Carneiro e Albuquerque (2019); Oliveira-Júnior et al., 2020; Oliveira et al., 2021).

Os incêndios e as queimadas, principalmente próximos de regiões urbanas ou de forma remota, intensificam a poluição atmosférica, seguido da piora da qualidade do ar, e por fim no aumento significativo das internações por doenças respiratórias (Silva et al., 2020; Oliveira et al., 2020; Araújo e Rosário, 2020; Oliveira et al., 2021).

Para se obter informações em tempo real e localizar os incêndios florestais em escala continental, o Instituto Nacional de Pesquisas Espaciais (INPE) acompanha, por meio de satélites ambientais, a ocorrência de focos de calor (FC) nos biomas, nas Unidades de Conservação (UC) e nas Áreas de Preservação Ambiental (APAs) - (Oliveira-Júnior et al., 2020). O monitoramento de FC objetiva o controle de áreas vulneráveis aos incêndios florestais no Brasil e América do Sul (AS). Essa identificação de incêndios é armazenada no Banco de Dados de Queimadas (BDQueimadas) - (CPTEC, 2022).

As técnicas de Inteligência Artificial (IA) são reconhecidas como ferramentas apropriadas para o gerenciamento florestal (Viganó et al.,

2017). Os primeiros sistemas inteligentes com aplicações em incêndios florestais foi a partir da década de 1980. A IA destaca-se na avaliação de risco de incêndio, detecção de incêndio e mapeamento de áreas queimadas, simulação e previsão de incêndio, avaliação de danos entre outras áreas (Abid, 2021).

A Rede Neural Artificial (RNA) é um algoritmo matemático composto por camadas: camada de entrada, camada intermediária e camada de saída (Samet et al., 2019). Segundo Viganó et al. (2017), as principais vantagens das RNAs na previsão de FC são: i) não requer conhecimento dos processos físicos causadores do fenômeno; ii) pode ser aplicada em sistemas sem soluções específicas; iii) possibilita o treinamento contínuo da rede; iv) não amplifica os erros de medição; v) permite a otimização no processo de previsão que envolva séries temporais de entrada e saída.

Este estudo utiliza uma ferramenta para previsões de focos de calor, com baixo custo computacional e poderá melhorar a qualidade das previsões de FC em Alagoas e no Nordeste brasileiro (NEB). Até o presente momento, não há nenhum estudo que trate do uso de RNAs aplicados aos incêndios e as queimadas que ocorrem na Região Metropolitana de Maceió (RMM) via dados de FC. Os objetivos do estudo são: i) avaliar a previsão de FC na RMM baseado na RNA não linear autorregressiva (NAR) a partir das funções de ativação Tangente Hiperbólica ou Sigmoidal e ii) qual(is) função(ões) melhor(es) é (são) indicada(s) para modelo de previsão.

Material e métodos

Área de Estudo

A Figura 1 exibe a área de estudo, a RMM que é constituída por 13 municípios. Estima-se que a população da RMM é de 1.330.291 habitantes (FNEM, 2017; IBGE, 2020a). De acordo com a Figura 1, a RMM encontra-se na mesorregião Leste Alagoano e possui uma área de 3.250 km², que se estende entre as latitudes 9° 7' 48" a 9° 51' 36" S, longitudes 35° 28' 12" a 36° 13' 12" O. A altitude varia entre 0 e 148 m acima do nível médio do mar (NMM). A RMM é situada no bioma da Mata Atlântica (Oliveira-Júnior et al., 2020; Souza et al., 2020; Zanini et al., 2020; Silva et al., 2020).

Sistemas Meteorológicos

Na RMM ocorrem diversos sistemas meteorológicos de multiescala que caracterizam a distribuição espaço-temporal de chuva, por exemplo, Alta Subtropical do Atlântico Sul (ASAS), circulação de brisas, convecção local,

Distúrbios Ondulatórios de Leste (DOL), Perturbação Ondulatória dos Alísios (POA) e os Vórtices Ciclônicos de Altos Níveis (VCAN) (Correia-Filho et al., 2019; Oliveira-Júnior et al., 2020; Souza et al., 2020). A fisiografia, tais como, maritimidade, continentalidade, relevo, vegetação, dentre outras, interferem no regime de chuva (Lima et al., 2020; Batista et al., 2021).

Série temporal dos FC

No estudo serão usados os resultados obtidos de Silva et al., (2020) via análise de agrupamento (AA), sendo identificado três grupos homogêneos de FC: grupo 1 (G1) - (Rio Largo e Murici); grupo 2 (G2) - (Pilar, Barra de Santo Antônio, Messias, Barra de São Miguel, Satuba, Paripueira, Coqueiro Seco e Santa Luzia do Norte); grupo 3 (G3) - (Marechal Deodoro e Maceió (Capital)); e um município que não se agrupou (NA) - (Atalaia) – (Figura 1).

O BDQueimadas é um portal desenvolvido pelo Centro de Previsão do Tempo e Estudos

Climáticos (CPTEC) e que disponibiliza dados de FC obtidos a partir de satélites ambientais (CPTEC, 2022). Os dados de FC foram obtidos do BDQueimadas, no seguinte endereço eletrônico: <http://queimadas.dgi.inpe.br/queimadas/bdqueimadas/>. O período de estudo compreende os anos de

1999 a 2019. No estudo foram usados os satélites referências NOAA-12 e AQUA no período de 1999 a 2002 e 2002 a 2019, respectivamente (INPE, 2022; Silva et al., 2020).




Figura 1 – Localização da área de estudo, com destaque aos grupos homogêneos de focos de calor (G1, G2, G3 e NA) identificados anteriormente no estudo realizado por Silva et al. (2020)

Previsão via Rede Neural Artificial

A previsão do FC foi realizada por meio do uso de RNA-NAR. A metodologia foi aplicada as séries temporais de FC nos 13 municípios pertencentes à RMM. As RNAs-NAR são redes recorrentes ou realimentadas, ou seja, os valores de saída de uma camada neural podem realimentar a camada de entrada (Samet et al., 2019). O funcionamento inicial desta RNA é do tipo *Feedforward* (alimentação à frente), onde sua informação na camada de entrada segue sempre na direção da camada de saída (Santos et al., 2020). Esta RNA se caracteriza pela variável Z que é o atraso temporal. O fator Z funciona como uma memória que proporciona valores de entrada atuais e valores anteriores (Santos e Lyra, 2020).

A RNA-NAR realizou a previsão do FC com base no sinal de entrada e alvo ao mesmo tempo. A arquitetura dessa rede foi configurada para fornecer a previsão de FC no período de estudo. A configuração dos parâmetros utilizados foi baseada nos estudos (Viganó et al., 2017; Santos et al., 2020; Santos e Lyra, 2020).

Um parâmetro importante presente no algoritmo deste tipo de RNA é a função de ativação

Sigmoide (Eq. (1)) e Tangente Hiperbólica (Eq. (2)). A função de ativação Tangente Hiperbólica é geralmente a escolha mais adequada, mais o uso desta função pode propagar valores negativos, e nesse estudo isso não pode ocorrer, pois não há registros negativos de FC. As funções de ativação têm uma característica em que x pode assumir qualquer valor, seja ele infinitamente positivo ou negativo, mas $f(x)$ sempre estará dentro do intervalo aberto entre 0 e +1 (Sigmoide) e entre -1 a +1 (Tangente Hiperbólica). As duas funções de ativação são continuamente diferenciáveis e não linear com formato de S, estas funções servem de entrada para a camada seguinte, elas reduzem o efeito de valores extremos de entrada, proporcionando um melhor funcionamento da RNA (Santos et al., 2020). A Figura 2 exibe as duas funções de ativação no plano cartesiano x e $f(x)$.

A Tabela 1 mostra a configuração final da fase de treinamento da RNA-NAR. Na fase de previsão o FC observado funciona como sinal de entrada e destino $y(t)$. A camada escondida (*Hidden*) é composta por 10 neurônios e pela função de ativação Tangente Hiperbólica (*Tansing*) ou Sigmoide (*Logsig*). A camada de saída (*Output*)

é composta por 1 neurônio e função de ativação Linear (*Purelin*). Por fim, é gerado um sinal de saída $y(t+1)$ que representa a previsão dos FC na RMM.

Análise estatística

A avaliação dos FCs na RMM foi baseada na estatística descritiva (ED). Na ED utilizou-se a média (M), mediana (MD), mínimo (Min), máximo (Max), amplitude total (AT), desvio padrão (DP) e coeficiente de variação (CV) aplicada aos FCs observado e previsto no período de estudo. Na estatística bivariada (EB) os indicadores estatísticos usados na validação da RNA-NAR foram: (Eq. (3)) Erro Médio (EM); (Eq. (4)) Raiz do Erro Quadrático Médio (REQM); (Eq. (5)) Erro Percentual Absoluto Médio (EPAM); (Eq. (6)) Coeficiente de Correlação de Pearson (r); (Eq. (7)) Coeficiente de Determinação (R^2); (Eq. (8)) Regressão Linear Simples (RLS). Todas as equações seguem listadas a seguir.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

$$EM = \frac{1}{N} \cdot \sum_{i=1}^N (RNA_i - OBS_i) \quad (3)$$

$$REQM = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (RNA_i - OBS_i)^2} \quad (4)$$

$$EPAM = \frac{1}{N} \cdot \sum_{i=1}^N \left| \frac{RNA_i - OBS_i}{OBS_i} \right| \cdot 100 \quad (5)$$

$$r = \frac{\sum_{i=1}^N (RNA_i - \overline{RNA}) \cdot (OBS_i - \overline{OBS})}{\sqrt{\sum_{i=1}^N (RNA_i - \overline{RNA})^2} \cdot \sqrt{\sum_{i=1}^N (OBS_i - \overline{OBS})^2}} \quad (6)$$

$$R^2 = \left(\frac{\sum_{i=1}^N (RNA_i - \overline{RNA}) \cdot (OBS_i - \overline{OBS})}{\sqrt{\sum_{i=1}^N (RNA_i - \overline{RNA})^2} \cdot \sqrt{\sum_{i=1}^N (OBS_i - \overline{OBS})^2}} \right)^2 \quad (7)$$

$$RNA = a \cdot OBS + b \quad (8)$$

Em que, o número total de valores (N) é igual a 21, o índice (i) varia de 1 a N , RNA_i e OBS_i são os valores previstos e observados com seus respectivos índices, $\overline{RNA}$ e $\overline{OBS}$ são os valores previstos e observados médios, respectivamente.

Foi realizado o diagrama de espalhamento (1:1) entre os FCs observado e previsto. Esse tipo de gráfico possui informações importantes, tal como: As equações das retas ($y = a \cdot x + b$) geradas a partir da RLS; Coeficiente de determinação; Coeficiente de correlação de Pearson.

Os valores do coeficiente r foram classificados segundo a metodologia de Hopkins (2009) – (Tabela 2). Por fim, foram realizadas duas previsões do FC via RNA trocando a função de ativação Tangente Hiperbólica pela Sigmoide, a análise estatística descritiva e bivariada, os gráficos de comparação entre os FC observados e previstos e o diagrama de espalhamento (1:1) foram realizados no software computacional Matlab® (versão R2013a).




Figura 2 – Funções de ativação Sigmoide e Tangente Hiperbólica.

Tabela 1 – Parâmetros utilizados na fase de treinamento da RNA-NAR.

Parâmetros	Dados/valores
Sinais de entrada/alvo	FC
Sinais na camada de entrada	21
Número de previsões	21
Algoritmo de treinamento	Levenberg-Marquardt
Algoritmo de desempenho	Erro médio quadrático
Épocas	1000
Verificação	10
Gradiente	0,00001
Treinamento, Teste e Validação	70%, 15% e 15%
Camada escondida	1
Atraso de entrada	1:2
Neurônios na camada escondida	10
Função de ativação	Tangente Hiperbólica ou Sigmoide
Camada de saída	1
Função de ativação	Linear
Neurônios na camada de saída	1

Tabela 2 – Coeficiente de correlação de Pearson (r) e sua respectiva classificação (Hopkins, 2009).

Coeficiente de correlação (r)	Classificação
0 – 0,1	Muito baixa
0,1 – 0,3	Baixa
0,3 – 0,5	Moderada
0,5 – 0,7	Alta
0,7 – 0,9	Muito alta
0,9 – 1,0	Quase perfeita

Resultados e discussão

Variabilidade Anual do FC Observado versus as Previsões da RNA-NAR na RMM

A Tabela 3 é exibida a ED dos FC observados e previstos na RMM. O FC observado registrou um total de 951 focos, enquanto as previsões 1 (P1) - (1055,14 focos) e 2 (P2) - (1083,73 focos). O grupo G1 apresentou o maior número de ocorrências de FC com 291 registros (30,60%). Destaque para o grupo NA que registrou 250 focos (26,29%). Os grupos G2 e G3 com 228 registros (23,97%) e 182 focos (19,14%), respectivamente. As P1 e P2 apresentaram os maiores registros de FC para o grupo G1 com 353,61 focos (33,51%) e 311,78 focos (28,77%), seguido do grupo G2 com 257,24 focos (24,36%) e 285,47 focos (26,34%).

O grupo NA apresentou a maior média (11,90 focos) seguido do grupo G1 (6,93 focos). De forma análoga as P1 e P2 apresentaram as maiores médias para os grupos NA com 11,44 e 11,87 focos, e para o grupo G1 com 8,42 e 7,42 focos (Tabela 3). O FC máximo foi de 67,45 focos para a P1 do grupo G1, que não condiz com a realidade. Os grupos NA (34 focos) e G1 (30 focos) apresentaram FC máximo elevados, assim como as P1 e P2 do grupo NA (30,02 e 30,41 focos). Os maiores valores de DP e CV foram nos grupos NA e G1, que por sua vez indicam alta variabilidade dos FC na RMM, similar as P1 e P2 com os maiores DP e CV. Os resultados resumidos na Tabela 3 foram similares aos estudos de Clemente et al., 2017, Rio de Janeiro; Oliveira-Júnior et al., 2020, Alagoas; e Silva et al., 2020, RMM.

Na Figura 3 é exibida a distribuição temporal do FC observado versus as previsões da RNA-NAR. Os padrões entre o FC observado e as previsões apresentaram similaridade no período de estudo. No entanto, ocorreram exceções, principalmente nos anos 2008, 2012, 2015 e 2016, com os maiores registros de FC na RMM. Os maiores registros de FC estão diretamente relacionados aos períodos de seca extremas ocorridas no NEB (Marengo et al., 2017a; Carvalho et al., 2018; Oliveira-Júnior et al., 2020; Silva et al., 2020).

Na Figura 3A, correspondente ao município de Atalaia (NA), mostra-se que os primeiros anos de análise os FCs observados versus as previsões foram similares, assim como os anos de 2007, 2008, 2018 e 2019. Nos anos restantes da série temporal, ambas as previsões divergiram. Destaque para os anos de 2006 e de 2009 a 2017, onde as previsões oscilaram, ora com superestimativa e ora com subestimativa de FC.

O município de Atalaia foi o único que não formou grupo, isso se deve a produção de cana-de-açúcar, intensa atividade de queima de biomassa, sendo identificado anteriormente nos estudos realizados por Oliveira-Júnior et al., (2020), para o Estado de Alagoas e Silva et al., (2020) para a RMM. Ambos os estudos comprovam que este elevado registro de FC em Atalaia é devido a sua produção sucroalcooleira.

Na Figura 3B exibe os FCs observados e suas previsões no grupo G1. O município de Rio Largo apresentou uma quantidade de registro de FC significativo, visto que há usinas de produção de açúcar e etanol, por exemplo, Central Leão e

Santa Clotilde - (Silva et al., 2020). Destaque para o ano de 2015, com 20 focos, a exceção foi 2004 sem ocorrência de FC. As previsões foram similares aos FC observados, por exemplo, nos anos de 1999, 2002, 2005, 2009, 2012 e 2019, porém nos anos de 2006, 2011, 2013, 2015 e 2016 as previsões foram muito abaixo dos valores observados, resultando em subestimação de valores.

O município de Murici também apresentou altos registros de FC, novamente destaque para os anos de 2015 que apresentou (30 focos) e 2016 (22 focos). A P2 também obteve FC máximo em 2015 (22,42 focos), ao contrário em 2016 (0,92). A P1, em 2017 (67,64 focos), obteve valor muito superior à média. O município de Murici não possui usina ou destilaria instalada na sua região, mas sua área é arrendada para o cultivo de cana-de-açúcar e, assim faz parte do complexo de indústrias de produção sucroalcooleira das cidades vizinhas (Silva et al., 2020).

O grupo G1 apresentou os maiores registros de FC (291 focos), sendo atribuída a queima da cana-de-açúcar, limpeza de pasto e queima do bioma Mata Atlântica para o plantio de cultivo agrícola (Neves et al., 2018; Oliveira-Júnior et al., 2020).

As Figuras 3C e 3D correspondem aos oito municípios do grupo G2 junto com as previsões. O grupo G2 se caracterizou pela maior quantidade de municípios e pelos menores registros de FC

Tabela 3 – Resultados da ED aplicada aos grupos homogêneos de FC observado e previsto no período estudado 1999 a 2019. As siglas correspondentes aos termos: ATFC – Acumulado Total de Focos de Calor, PATFC – Percentual Acumulado Total de FC, M – Média, MD – Mediana, Min – Mínima, Max – Máxima, AT – Amplitude Total, DP – Desvio Padrão, CV – Coeficiente de Variação.

	ATFC	PATFC	M	MD	Min	Max	AT	DP	CV
	Focos.Ano ⁻¹	%	Focos.Ano ⁻¹						%
NA	250	26,29	11,90	8	2	34	32	8,14	68,39
G1	291	30,60	6,93	6	0	30	30	5,84	34,12
G2	228	23,97	1,36	1	0	8	8	1,72	2,97
G3	182	19,14	4,33	4,50	0	14	14	3,09	9,54
Total	951	100	24,52	19,5	-	-	-	-	-
NA-Prev1	240,17	22,76	11,44	9,69	1,06	30,02	28,95	8,13	66,13
G1-Prev1	353,61	33,51	8,42	6,16	0,19	67,64	67,45	10,27	105,57


G2-Prev1	257,24	24,36	1,53	1,24	0	10,07	10,07	1,71	2,93
G3-Prev1	204,12	19,35	4,86	4,99	0	10,21	10,21	2,21	4,88
Total	1055,14	100	26,25	22,08	-	-	-	-	-
NA- Prev2	249,32	23,01	11,87	8,12	2,02	30,41	28,39	8,30	68,88
G1- Prev2	311,78	28,77	7,42	7,55	0,74	22,42	21,68	4,40	19,40
G2- Prev2	285,47	26,34	1,70	1,16	0	6,66	6,66	1,66	2,75
G3- Prev2	237,16	21,88	5,65	5,11	0,97	23,86	22,89	3,84	14,74
Total	1083,73	100	26,64	21,94	-	-	-	-	-

O município de Pilar obteve 8 focos em 2005 e 2012, a exceção foi em 2001, sem ocorrência de FC. No município de Barra de Santo Antônio ambas as previsões apresentaram um comportamento inversamente proporcional aos FC observados, principalmente nos anos 2000, 2001, 2010, 2011, 2012, 2014, 2015 e 2016. Destaque nos valores extremos com atraso de um ano de diferença pelas previsões. No município de Messias as previsões P1 e P2 foram distintas. A P2 apresentou mais casos de superestimativa de valores, exceto em 2018. A P1 se assemelhou aos FC observados, as exceções foram os anos de 2014 e 2018. No município de Barra de São Miguel as previsões reproduziram satisfatoriamente a variabilidade dos FC. Vale ressaltar que metade dos anos analisados não ocorreram FC (Oliveira-Júnior et al., 2020; Silva et al., 2020).

Na Figura 3D o município de Satuba apresentou o maior número de FC nos anos de 2016 (5 focos) e 2008 (4 focos), sendo oito anos sem ocorrência de FC. As previsões reproduziram satisfatoriamente a variabilidade da série observada, porém não reproduziu os FC máximos. O FC máximo da P1 (2,71 focos) e P2 (2,33 focos) se repetiram em vários anos, por exemplo, 2002, 2004, 2007, 2011 e 2015. No município de Paripueira a detecção de FC máximo nos anos 2007 e 2010 foram de três focos e em nove anos não ocorreram FC. As previsões divergiram, mas se mantiveram dentro do intervalo de FC entre 0 e 3

focos. Os municípios de Coqueiro Seco e Santa Luzia do Norte obtiveram a menor detecção de FC, apenas dois registros. As ocorrências de FC para Coqueiro Seco foram em 2001 e 2013, Santa Luzia do Norte ocorreram em 2018 e 2019. As previsões também apresentaram comportamento constante coincidindo com o FC observado e reproduziram satisfatoriamente a variabilidade do FC. Os resultados foram similares aos estudos realizados anteriormente por Oliveira-Júnior et al., (2020) e Silva et al., (2020).

A Figura 3E correspondente ao grupo G3 com os municípios de Marechal Deodoro e Maceió e suas previsões. A maior detecção de FC do município de Marechal Deodoro ocorreu no ano de 2016 (9 focos), as exceções foram nos anos de 2000, 2001 e 2013 sem nenhum registro de FC. No município de Maceió as maiores detecções de FC ocorreram em 2008 (14 focos) e 2016 (10 focos), o ano de 2013 foi o único que não registrou FC. As previsões foram similares e conseguiram reproduzir os FC observados satisfatoriamente. A maior diferença de FC ocorreu em 2017, onde a P2 apresentou uma superestimativa de FC. Tal variabilidade identificada no grupo G3 se deve aos municípios de Maceió e Marechal Deodoro possuírem um polo industrial, seguido de plantação urbana de cana-de-açúcar, além da ocorrência de incêndios urbanos, devido ao uso do fogo para limpeza de terrenos, e assim contribui para o aumento de FC (Correia-Filho et al., 2019; Oliveira-Júnior et al., 2020; Silva et al., 2020; Batista et al., 2021).






Figura 3 – Distribuição anual de FC na RMM dos grupos homogêneos de FC (grupos G1, G2 e G3) e não agrupados (NA) no período de estudo 1999 a 2019. A linha azul corresponde a Previsão 1 (Tangente Hiperbólica), linha vermelha Previsão 2 (Sigmoide) e a linha preta FC observados.

Validação do Modelo RNA-NAR

A Figura 4 mostra o diagrama de espalhamento (1:1) entre os dados observados de FC e as previsões P1 e P2 na RMM.


A Figura 4A corresponde a P1 e a Figura 4B corresponde a P2 do município de Atalaia. O coeficiente R^2 variou entre 9 e 12%, sendo baixas as previsões explicadas pela RNA-NAR. Áreas próximas às usinas e destilarias concentram os maiores FC, Atalaia faz parte da região matriz sucroenergética de Alagoas (Sindaúcar-AL, 2019; Neves et al., 2018; Oliveira-Júnior et al., 2020; Silva et al., 2020) e portanto contribuiu para alta dispersão dos dados. O coeficiente r variou entre 0,30 e 0,34 categorizados como moderado, segundo a Tabela 2. As P1 e P2 foram similares, sendo devido a variabilidade e dispersão de dados, e assim houve subestimativa e superestimativa.

A Figura 4C corresponde a P1 e 4D corresponde P2 do grupo G1. O coeficiente R^2 variou entre 1 e 5%, sendo insuficientes para que a variável preditiva seja explicada pelo modelo RNA-NAR. O coeficiente r variou entre 0,08 e 0,21, sendo categorizados entre muito baixo e baixo, conforme a Tabela 2. Apesar do grupo G1 apresentar FC elevados, o modelo não respondeu satisfatoriamente. As previsões em ambas as Figuras apresentaram superestimativas.

A figura 4E corresponde a P1 e a Figura 4F corresponde a P2 do grupo G2. O coeficiente R^2 variou entre 14 e 58% das previsões são explicadas.

O coeficiente r variou entre 0,38 e 0,52 classificada como moderada e alta, respectivamente de acordo com a Tabela 2. Vale ressaltar que a P2 foi superior a P1, ou seja, a função de ativação Sigmoide se destacou em relação a Tangente Hiperbólica. Destaque que os coeficientes da P2 foram os melhores resultados do estudo. O grupo G2 obteve os menores registros de FC, consequentemente as variabilidades dos dados foram menores, e portanto, diminui o grau de dispersão da série observada e previstas.

A Figura 4G corresponde a P1 e a Figura 4H corresponde a P2 do grupo G3. O coeficiente R^2 variou entre 1 e 2%, sendo caracterizados como insuficientes para os FC previstos sejam explicados. O coeficiente r variou entre 0,11 e 0,13 categorizado como baixa (Tabela 2). Neste grupo as P1 e P2 foram similares, novamente houve superestimativa. O grupo G3 apresentou elevados FC, devido à proximidade das unidades industriais e usinas, queimadas de canaviais na capital, seguido da prática de limpeza de áreas vegetadas para uso e ocupação do solo (Correia-Filho et al., 2019, Oliveira-Júnior et al., 2020, Silva et al., 2020; Santos et al., 2021). Outro motivo que eleva o FC no grupo G3 é a expansão urbana no Leste Alagoano, ações antropogênicas, sendo identificados anteriormente pelos estudos (Oliveira-Júnior et al., 2020; Souza et al., 2020; Silva et al., 2020; Batista et al., 2021).






Figura 4. Diagramas de espalhamento (1:1) dos FCs observados versus as previsões no período de 1999 a 2019 dos grupos homogêneos (G1, G2 e G3) e o não agrupado (NA).

A Tabela 4 exibe o resumo da análise estatística aplicada no estudo (EM, REQM, EPAM, r , R^2 e RLS) e a avaliação de desempenho do modelo de previsão por RNA-NAR.

Com base nos resultados obtidos na Tabela 4, o menor EM foi o da P2 do NA (-0,03 focos) em comparação aos demais grupos homogêneos avaliados. O maior EM foi o da P2 do G1 (1,49 focos), em virtude do erro ocorrido no ano de 2017 que causou superestimativa de FC. Outro EM que se destacou foi o da P2 do G3 (1,31 focos), novamente o ano de 2017 influenciou o modelo RNA-NAR.

A REQM de todos os resultados variou entre 1,16 focos (P2 do G2) a 7,02 focos (P2 do NA). O indicador estatístico apontou que quanto maior a concentração de FC, maiores serão a variabilidade e o grau de dispersão dos dados, e assim aumenta significativamente o erro das previsões (Viganó et al., 2017). Destaque positivo para os melhores resultados obtidos para o grupo G2, onde ambas as previsões apresentaram os menores erros. Destaque negativo foi para o grupo NA em que as P1 e P2 apresentaram os maiores erros, devido a elevados registros de FC (Correia-Filho et al., 2019; Oliveira-Júnior et al., 2020; Silva et al., 2020).

O EPAM informa o percentual de erros das previsões pelo modelo RNA-NAR. Os resultados variaram entre 14,45% (P2 do G2) a 24,66% (P2 do G3). Novamente, o grupo G2 em ambas as

previsões apresentaram os menores erros em termos de porcentagem (Viganó et al., 2017).

Os coeficientes r variaram de 0,08 (P1 do G1) a 0,52 (P2 do G2). Deste modo, verifica-se que as previsões de todos os grupos apresentaram comportamento diretamente proporcional, e o grupo G2 em ambas as previsões apresentaram as melhores correlações, entre moderada e alta, de acordo com a Tabela 2.

Os coeficientes R^2 variaram 0,01 (grupos G1 e G3 ambos da P1) a 0,58 (P2 do G2). Novamente, a P2 do grupo G2 apresentou o maior valor para este indicador estatístico. Vale ressaltar os valores de R^2 baixos, sendo considerado insatisfatório na maioria das previsões em seus respectivos grupos. Portanto, com base na análise estatística e avaliação do desempenho do modelo RNA-NAR Tabela 4, a previsão 2 do grupo G2 obteve os melhores resultados.

Comparando os resultados deste estudo com estudos similares verificamos que a maioria dos valores da Tabela 4 está em concordância com resultados obtidos por Viganó et al. (2017). Os autores realizaram a previsão do número de focos de incêndios e a área queimada (em Km^2), com base em oito modelos de previsão com RNA Perceptron de Múltiplas Camadas (PMC), nos meses de julho a novembro, para série histórica de 2005 a 2015, na região do Pantanal brasileiro. Os dois modelos de previsão em que usa apenas as variáveis previstas (focos de incêndios e área

queimada) apresentaram os resultados satisfatórios e os menores erros, similar ao nosso modelo.

Tabela 4 - Resultados da estatística bivariada entre os FCs observados e previstos no período estudado de 1999 a 2019. As siglas correspondentes aos termos: EM – Erro Médio (focos), REQM – Raiz do Erro Quadrático Médio (focos), EPAM – Erro Percentual Absoluto Médio (%), RLS – Regressão Linear Simples.

Grupos - Previsão	EM	REQM	EPAM	r	R ²	RLS
NA - P1	-0,47	6,76	19,89	0,34	0,12	$y=0,3411x+7,3764$
NA - P2	-0,03	7,02	20,65	0,30	0,09	$y=0,3038x-8,2551$
G1 - P1	1,49	5,38	17,95	0,08	0,01	$y=0,1343x+7,4889$
G1 - P2	0,49	5,23	17,42	0,21	0,05	$y=0,1597x+6,3172$
G2 - P1	0,17	1,29	16,16	0,38	0,14	$y=0,3733x+1,0246$
G2 - P2	0,34	1,16	14,45	0,52	0,58	$Y=0,4959x+1,0262$
G3 - P1	0,53	2,76	19,71	0,11	0,01	$Y=0,0789x+4,5181$
G3 - P2	1,31	3,45	24,66	0,13	0,02	$y=0,1607x+4,9505$

Na ED comprovou-se que quanto maior a quantidade de FC maior é a variabilidade dos dados, isto ocorreu com os grupos G1 e NA, as previsões P1 e P2 apresentaram as maiores variabilidades para ambos os grupos e a maior ocorrência de FC para o G1. As previsões também apresentaram os maiores valores médios dos grupos NA e G1. As métricas estatísticas de erros indicaram que as previsões reproduziram satisfatoriamente os FC do grupo G2, sendo a P2 melhor que a P1.

A discussão e a comparação com estudos similares comprovaram que os elevados registros de FC estão relacionados aos períodos de seca extremas ocorridas no NEB, a produção sucroalcooleira das usinas existentes na região, a queima da cana-de-açúcar, queima do bioma Mata Atlântica para o plantio de cultivo agrícola, além da ocorrência de incêndios urbanos, para limpeza de terrenos.

Considerações Finais

Os modelos de previsão são satisfatórios, pois consegue reproduzir a variabilidade do FC na maioria dos municípios da RMM, com destaque para o grupo G2, com maior quantidade de

municípios da RMM, e, portanto, perfeitamente aplicável.

Vale destacar que a previsão 2 (função de ativação Sigmoide) do grupo G2, com os melhores indicadores estatísticos em comparação com a previsão 1 (função de ativação Tangente Hiperbólica) e juntamente com os demais grupos. O grupo G2 com o menor número de FC, seguido da menor variabilidade, a previsão 2 reproduz essas características melhor que a previsão 1 via modelo RNA-NAR.

Foram apontados quais são os fatores que elevam os registros de FC na RMM, principalmente no G1 e NA. Apesar da alta variabilidade dos dados influenciar no baixo coeficiente de determinação, ambas as previsões identificaram e reproduziram os maiores registros e a maior variabilidade de FC do grupo G1.

A maior limitação dos modelos usados no estudo é em relação a reproduzir os elevados registros de FC, principalmente nos anos de ocorrência de seca. Apesar disso, os resultados obtidos mostram que a utilização de RNA-NAR é uma solução viável e acessível para a previsão de focos de calor em Regiões Metropolitanas do Brasil e, assim contribui para tomadas de decisões dos gestores públicos em relação ao controle de queimadas e monitoramento de incêndios urbanos.

Agradecimentos

Os autores agradecem ao Programa de Pós-Graduação em Meteorologia (PPGMET), a Unidade Acadêmica de Ciências Atmosféricas (UACA), ao Centro de Tecnologia e Recursos Naturais (CTRN), a Universidade Federal de Campina Grande (UFCG), ao Instituto de Ciência Atmosférica (ICAT), a Universidade Federal de Alagoas (UFAL) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro concedido ao primeiro autor durante o curso de mestrado (2017-2019) e doutorado (2020-Atual). O segundo autor agradece ao CNPq pela bolsa de Produtividade Nível 2 sob o número de processo 309681/2019-7.

Referências

- Abid, F., 2021. A survey of machine learning algorithms based forest fires prediction and detection system. *Fire Technology*, 57, 559-590.
- Araújo, J.M., Rosário, N.M.E., 2020. Poluição atmosférica associada ao material particulado no estado de São Paulo: análise baseada em dados de satélite. *Revista Brasileira de Ciências Ambientais*, 55, 32-47.
- Batista, B.A., Correia-Filho, W.L.F., Oliveira-Júnior, J.F., Santiago, D.B., Santos, C.T., 2021. Avaliação da expansão urbana na cidade de Maceió, Alagoas – Nordeste do Brasil. *Research, Society and Development*, 10, 1-14.
- Carneiro, K.F.S., Albuquerque, E.L.S., 2019. Análise multitemporal dos focos de queimadas em Teresina, estado do Piauí. *Revista de Geociências do Nordeste*, 5, 31-40.
- Carvalho, A.L., Magalhães, I.D., Lyra, G.B., Santiago, D.B., Souza, J.S., Teodoro, I., Fernandes, R.C., Lyra, G., Lopes-Júnior, J.M., 2018. Avaliação climatológica das ocorrências de períodos secos e chuvosos no estado de Alagoas. *Caderno de Pesquisa, Ciências e Inovação*, 1, 40-50.
- Clemente, S.S., Oliveira-Júnior, J.F., Louzada, M.A.P., 2017. Focos de calor na Mata Atlântica do Estado do Rio de Janeiro. *Revista Brasileira de Meteorologia*, 32, 1-9.
- Correia-Filho, W.L.F., Santiago, D.B., Oliveira-Júnior, J.F., Silva-Júnior, C.A., 2019. Impact of urban decadal advance on land use and land cover and surface temperature in the city of Maceió, Brazil. *Land Use Policy*, 1, 1-11.
- CPTEC - Centro de Previsão do Tempo e Estudos Climáticos. Monitoramento de focos. Disponível: <http://queimadas.dgi.inpe.br/queimadas/bdqueimadas/>. Acesso: 21 mar. 2022.
- FNEM. Fórum Nacional de Entidade Metropolitanas. 2017. Disponível: <http://fnembrasil.org/regiao-metropolitanade-maceio-al/>. Acesso: 21 mar. 2022.
- Hopkins, W.G., A new view of statistics: Correlation Coefficient. New York: Internet Society for Sport Science, 2009. Disponível: <http://www.sportsci.org/resource/stats/correl.html>. Acesso: 23 jun. 2022.
- IBGE – Instituto Brasileiro de Geografia e Estatística. Censo Demográfico 2010 – Área Territorial Brasileira. Rio de Janeiro: IBGE, 2020a.
- INPE – Instituto Nacional de Pesquisas Espaciais. Banco de Dados de Queimadas. Disponível: <https://queimadas.dgi.inpe.br/queimadas/bdqueimadas>. Acesso: 01 abr. 2022.
- Lima, M., Vale, J.C.E., Costa, G.M., Santos, R.C., Correia-Filho, W.L.F., Gois, G., Oliveira-Júnior, J.F., Teodoro, P.E., Rossi, F.S., Silva-Júnior, C.A., 2020. The Forests in the Indigenous Lands in Brazil in Peril. *Land Use Policy*, 90, 1-3.
- Marengo, J.A., Torres, R.R., Alves, L.M., 2017a. Drought in Northeast Brazil – past, present and future. *Theoretical and Applied Climatology*, 129, 1189-1200.
- MMA - Ministério do Meio Ambiente. Unidades de Conservação: O Que São? Disponível: <https://www.mma.gov.br/areas-protegidas/unidades-de-conservacao/o-quesao.html>, acesso em 12 de abr. 2022.
- Neves, J.A., Santos, C.C., Amaral, A.F.C., Sant'Anna, S.A.C., Silva, P.A., Ivo Mello, W.P., 2018. Emissões de gases de efeito estufa em áreas de cana-de-açúcar colhida crua e queimada. *Anais 8 Seminário de Iniciação Científica e Pós-Graduação da Embrapa Tabuleiros Costeiros*.
- Oliveira, J.G.I., Paiva, R.F.P.S., Reis, M.M., Gois, G., 2020. Poluição do ar e interações por doenças respiratórias em Volta Redonda, RJ. *Revista Brasileira de Ciências Ambientais*, 55, 72-88.
- Oliveira, U.C., Lima, E.C., Figueiredo, T.W.X., Claudino-Sales, V., Feitosa, C.E.L., 2021. Environmental risk in Northeast Brazil: estimation of burning áreas in Coreaú River Basin, Ceará, Brazil. *Environmental Monitoring and Assessment*, 193, 1-12.
- Oliveira-Júnior, J.F., Correia-Filho, W.L.F., Alves, L.E.R., Lyra, G.B., Gois, G., Silva-Júnior, C.A., Santos, P.J., Sobral, B.S., 2020. Fire foci dynamics and their relationship with socioenvironmental factors and meteorological

- systems in the state of Alagoas, Northeast Brazil. *Environmental Monitoring and Assessment*, 192, 1–26.
- Oliveira-Júnior, J. F., Shah, M., Abbas, A., Correia-Filho, W.L.F Silva Júnior, C.A., Barros Santiago, D., Teodoro, P. E., Mendes, D., Souza, A., Aviv-Sharon, E., Silveira, V. R., Pimentel, L. C. G., Silva, E. B., Haq, M. A., Khan, I., Mohamed, A., Attia, E-A, 2022. Spatiotemporal Analysis of Fire Foci and Environmental Degradation in the Biomes of Northeastern Brazil. *Sustainability*, 14, 6935.
- Samet, H., Reisi, M., Marzbani, F., 2019. Evaluation of neural network based methodologies for wind speed forecasting. *Computers and Electrical Engineering*, 78, 356-372.
- Santos, I.G.S. Lyra, R.F.F., 2020. Análise do potencial de previsão da velocidade do vento na utilizando rede neural artificial. *Anuário do Instituto de Geociências – UFRJ*, 43, 11-17.
- Santos, I.G.S. Lyra, R.F.F.; Silva-Júnior, R.S., 2020. Comparativo de prognósticos da velocidade do vento utilizando modelo WRF e rede neural artificial. *Revista Brasileira de Meteorologia*, 35, 1017-1027.
- Santos, F.S.; Gomes, H.B.; Barros, G.V.P.; Alves, L.E.R.; Silva, D.F.; Costa, R.L.; Silva, F.D.S.; Oliveira-Júnior, J.F., 2021. Análise sazonal dos parâmetros biofísicos utilizando o sensor MODIS para o Estado de Alagoas. *Revista Brasileira de Meteorologia*, 35, 955-968.
- Silva, C.; Portella, A.C.F.; Giongo, M., 2020. Meta-análise de estudos sobre o efeito do fogo nos biomas florestais em relação aos microrganismos fúngicos. *Advances in Forestry Science*, 7,. 931-938.
- Silva, E.M.S., Correia-Filho, W.L.F., Oliveira-Júnior, J.F., Barros, H.G., Costa, M.S., Gois, G., Falcão, N.A.M., 2020. Espaço-temporalidade dos focos de calor na região metropolitana de Maceió. *Revista Brasileira de Meteorologia*, 35, 1029–1043.
- Sindaçúcar-AL, 2019. Relação das Usinas. Disponível: <http://www.sindacucar-al.com.br/relacao-das-usinas/>. Acesso: 06 maio. 2022
- Souza, E.O., Costa, M.S., Oliveira-Júnior, J.F., Gois, G., Mariano, G.L., Costa, C.E.S., Correia-Filho, W.L.F., Santiago, D.B., 2020. Estimativa e espacialização da erosividade em mesorregiões climáticas no Estado de Alagoas. *Revista Brasileira de Meteorologia*, 35, n769–783.
- Viganó, H.H.G., Souza, C.C., Cristaldo, M.F.; Jesus, L., 2017. Redes neurais artificiais na previsão de queimadas e incêndios no Pantanal. *Revista Brasileira de Geografia Física*, 10, 1355-1367.
- Zanini, A.M., Vendruscolo, G.S., Milesi, S.V., Zanin, E.M., Zakrzewsk, S.B.B., 2020. Percepções de estudantes do Sul do Brasil sobre a biodiversidade da Mata Atlântica. *Interciência*, 45, 15-22.