

UNIVERSIDADE ESTADUAL DE GOIÁS
CÂMPUS CENTRAL SEDE ANÁPOLIS - CET
PROGRAMA DE PÓS-GRADUAÇÃO *STRICTO SENSU* EM ENGENHARIA AGRÍCOLA
FRANK FREIRE CAPUCHINHO

**DEEP LEARNING PARA ESTIMATIVA NA ESCALA MENSAL DAS
TEMPERATURAS DO AR PARA A REGIÃO CENTRO-OESTE DO BRASIL**

ANÁPOLIS - GO
2021

FRANK FREIRE CAPUCHINHO

**DEEP LEARNING PARA ESTIMATIVA NA ESCALA MENSAL DAS
TEMPERATURAS DO AR PARA A REGIÃO CENTRO-OESTE DO BRASIL**

Dissertação apresentada à Universidade Estadual de Goiás - UEG, Câmpus Central Sede Anápolis – CET, como parte das exigências do Programa de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola, para obtenção do título de Mestre em Engenharia Agrícola.

Área de concentração CNPQ: Agrometeorologia
Orientador: Prof. Dr. Francisco Ramos de Melo

ANÁPOLIS - GO
2021



TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DE TESES E DISSERTAÇÕES NA BIBLIOTECA DIGITAL (BDTD)

Na qualidade de titular dos direitos de autor, autorizo a Universidade Estadual de Goiás a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UEG), regulamentada pela Resolução, **CsA n.1087/2019** sem ressarcimento dos direitos autorais, de acordo com a Lei nº 9610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira, a partir desta data.

Dados do autor (a)

Nome Completo: Frank Freire Capuchinho
E-mail: frankfreirec@gmail.com

Dados do trabalho

Título: Deep learning para estimativa na escala mensal das temperaturas do ar para a região Centro-oeste do Brasil

Tipo

() Tese (X) Dissertação

Curso/Programa: Mestrado em Engenharia Agrícola

Concorda com a liberação documento [X] SIM [] NÃO¹

Anápolis, 12/02/2022

Local Data

Assinatura do autor (a)

Assinatura do orientador (a)

¹ Casos de impedimento:

- Período de embargo é de um ano a partir da data de defesa
- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da Dissertação/Tese em livro.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UEG
com os dados fornecidos pelo(a) autor(a).

FF866 Freire Capuchinho, Frank
d DEEP LEARNING PARA ESTIMATIVA NA ESCALA MENSAL DAS
TEMPERATURAS DO AR PARA A REGIÃO CENTRO-OESTE DO BRASIL
/ Frank Freire Capuchinho; orientador Francisco Ramos
de Melo. -- Anápolis, 2021.
91 p.

Dissertação (Mestrado - Programa de Pós-Graduação
Mestrado Acadêmico em Engenharia Agrícola) -- Câmpus
Central - Sede: Anápolis - CET, Universidade Estadual
de Goiás, 2021.

1. Agroclimatologia. 2. Inteligência Artificial. 3.
Séries Históricas. I. Ramos de Melo, Francisco, orient.
II. Título.

FRANK FREIRE CAPUCHINHO

**DEEP LEARNING PARA ESTIMATIVA NA ESCALA MENSAL DAS
TEMPERATURAS DO AR PARA A REGIÃO CENTRO-OESTE DO BRASIL**

Dissertação defendida ao Programa de Pós-Graduação
Stricto Sensu em Engenharia Agrícola, Campus Central
Sede Anápolis – CET, Universidade Estadual de Goiás,
para obtenção do título de mestre.

Aprovado (a): 16 de dezembro de 2021.

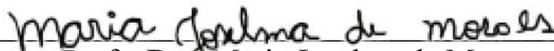
Banca examinadora



Prof. Dr. Francisco Ramos de Melo
Universidade Estadual de Goiás - UEG



Prof. Dr. Sirlon Diniz de Carvalho
Instituto Federal de Educação, Ciência e Tecnologia de Goiás - IFG



Profa. Dra. Maria Joselma de Moraes
Universidade Estadual de Goiás - UEG

ANÁPOLIS –GO
2021

AGRADECIMENTOS

À Deus, pela fé renovada todos os dias, por estar sempre comigo, me guiando, me proporcionando força, determinação, paciência, resiliência e pelas pessoas que tive a oportunidade de conhecer.

À minha mãe, Marylene Freire da Silva, uma mulher incrível, meu exemplo de determinação e resiliência, que sempre incentivou meus estudos, acreditou em mim e nunca mediu esforços para que eu alcançasse meus objetivos.

Ao meu estimado orientador Professor Dr. Francisco Ramos de Melo, pela paciência, dedicação e amizade no decorrer do mestrado, que sempre me incentivou e me desafiou a oferecer o meu melhor, o qual tenho imensa admiração como profissional e pessoa e que sempre vou lembrar com carinho.

Aos meus amigos, Luciana Gabriela Moreira dos Santos, Sâmella Jordana Alves da Costa, Amanda Caroliny de Lima Silva, Samuel Alexandre Abreu Dias, Laís Medeiros Cintra e Guilherme Gonçalves Costa, pelos momentos felizes, pelo apoio e por estarem na minha vida. Em especial a Kedinna Dias de Sousa, pelas horas de conversas, pela amizade e por acreditar em mim, mesmo quando eu duvidei dos meus passos.

À Gabriella Andrezza Meireles Campos, a qual tenho carinho e pude conhecer melhor durante o mestrado e que esteve comigo nos momentos mais complicados, tornando-os mais leves e divertidos.

Aos meus colegas Luan Leite Leão e Jefferson de Souza e Silva pelo companheirismo e ajuda no desenvolvimento deste trabalho.

À Universidade Estadual de Goiás – UEG – Campus Central – Sede: Anápolis e ao Programa de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola por todo o apoio durante o mestrado.

Aos Professores do Mestrado em Engenharia Agrícola da Universidade Estadual de Goiás, por toda a contribuição para o meu crescimento pessoal e profissional. Em especial, as Professoras Dra. Roberta Passini e Dra. Maria Joselma de Moraes e aos Professores Dr. Ivano Alessandro Devilla, Dr. André José de Campos e Dr. Elton Fialho dos Reis. Muito obrigado.

Ao Instituto Nacional de Meteorologia – INMET, ao Instituto Brasileiro de Geografia e Estatística – IBGE e ao Serviço Geológico dos Estados Unidos pela disponibilidade dos dados para desenvolver este trabalho.

À Coordenação de Aperfeiçoamento de Nível Superior (CAPES) pela concessão do auxílio financeiro para a realização desta pesquisa.

RESUMO

Dentre os elementos climáticos que exercem influência na produção agropecuária, tem-se a temperatura do ar e que por sua vez, depende de outros fatores e elementos. Neste sentido, o estudo do clima para as estimativas dos valores mínimos, médios e máximos da temperatura do ar é importante, especialmente em regiões que não apresentam uma densidade de estações meteorológicas aceitável, dados faltantes ou valores inconsistentes, como é o caso da região Centro-Oeste do Brasil. Este trabalho foi conduzido com o objetivo de estudar o emprego de Redes Neurais Artificiais Deep Learning, capazes de estimar as temperaturas máximas (Tmax), mínimas (Tmin) e médias (Tmed) do ar, na escala mensal, para o Centro-Oeste do Brasil. Foram obtidos dados de 1990 a 2020, de 81 estações meteorológicas disponíveis nos Estados que compreendem a região Centro-Oeste brasileira. Os dados foram subdivididos em parcelas de treino, validação e teste. As variáveis independentes de altitude, latitude, longitude, umidade relativa do ar e velocidade do vento foram combinadas em nove cenários (C1 a C9) para estudar a melhor combinação e quantidade de neurônios para estruturação das camadas das RNAs. Foram selecionadas e analisadas três configurações de camadas ocultas e neurônios em cada camada. Em relação a camada de saída é composta por três neurônios que dizem respeito as temperaturas do ar (máxima, média e mínima) na escala mensal. Dessa maneira, foram geradas RNAs Deep Learning para cada um dos nove cenários, configuração de camadas intermediárias, para cada mês do ano (janeiro a dezembro) e temperaturas do ar. Os ajustes das RNAs foram avaliados para a parcela dos dados de teste e por meio de índices estatísticos de Raiz Quadrática do Erro Médio (RQEM), Erro Médio Absoluto (EMA), coeficiente de correlação de Pearson (r), coeficiente de determinação (R²), índice de concordância (d) e índice de performance (IP). Os melhores cenários na combinação de variáveis independentes, para a maioria dos meses foram C1, C2, C3, C4 e C6, que apresentaram R² ≥ 70%. As RNAs desenvolvidas nas configurações de camadas ocultas M3, M2 e M1, nesta ordem, obtiveram os melhores índices estatísticos de r ≥ 70%; RQEM e EMA ≤ 1,0 °C; índice (d) ≥ 0,8 e IP classificados como ótimos. Utilizar um grande volume de dados vinculados a aplicação do Deep Learning apresentou ser possível estimar as médias mensais das temperaturas do ar Tmax, Tmed e Tmin, com aceitável grau de acurácia, para a região Centro-Oeste do Brasil.

Palavras-chave: Agroclimatologia. Inteligência Artificial. Séries históricas.

ABSTRACT

Among the climatic elements that influence agricultural production, there is the air temperature, which in turn depends on other factors and elements. In this sense, the study of the climate for the estimates of the minimum, average and maximum values of air temperature is important, especially in regions that do not have an acceptable density of meteorological stations, missing data or inconsistent values, as is the case of the Midwest region of Brazil. This work was carried out with the objective of studying the use of Deep Learning Artificial Neural Networks, capable of estimating the maximum (Tmax), minimum (Tmin) and average (Tmed) air temperatures, on a monthly scale, for the Midwest of Brazil. Data were obtained from 1990 to 2020, from 81 meteorological stations available in the states that comprise the Brazilian Midwest region. The data were subdivided into training, validation and test plots. The independent variables of altitude, latitude, longitude, relative humidity and wind speed were combined in nine scenarios (S1 to S9) to study the best combination and number of neurons for structuring the ANN layers. Three configurations of hidden layers and neurons in each layer were selected and analyzed. Regarding the output layer, it is composed of three neurons that relate to air temperatures (maximum, average and minimum) on the monthly scale. In this way, Deep Learning ANNs were generated for each of the nine scenarios, configuration of intermediate layers, for each month of the year (January to December) and air temperatures. The adjustments of the ANNs were evaluated for the portion of the test data and through statistical indices of Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Pearson's correlation coefficient (r), coefficient of determination (R^2), agreement index (d) and performance index (PI). The best scenarios in the combination of independent variables for most months were S1, S2, S3, S4 and S6, which presented $R^2 \geq 70\%$. The ANNs developed in the configurations of hidden layers M3, M2 and M1, in that order, obtained the best statistical indices of $r \geq 70\%$; RMSE and MAE ≤ 1.0 °C; index (d) ≥ 0.8 and PI classified as excellent. Using a large volume of data linked to the application of Deep Learning, it was possible to estimate the monthly averages of air temperatures Tmax, Tmed and Tmin, with an acceptable degree of accuracy, for the Midwest region of Brazil.

Keywords: Agroclimatology. Artificial Intelligence. Historical series.

SUMÁRIO

1	INTRODUÇÃO	11
2	REVISÃO BIBLIOGRÁFICA	15
2.1	Temperatura do ar atmosférico e variáveis meteorológicas	15
2.1.1	Radiação Solar	15
2.1.2	Correlação da temperatura do ar com variáveis climáticas e geográficas.....	15
2.1.3	Temperatura do ar no meio rural.....	17
2.2	Séries temporais	20
2.3	Redes Neurais Artificiais	21
2.3.1	Unidades de Processamento ou Neurônios Artificiais.....	22
2.3.2	Conexões Sinápticas	23
2.3.3	Processamento Neural.....	24
2.3.3.1	Treinamento.....	24
2.3.3.2	Execução: Validação e Teste.....	26
2.3.4	Topologia de Redes Neurais Artificiais.....	26
2.3.5	Redes Neurais Artificiais Múltiplas Camadas.....	27
2.4	Deep Learning	28
2.5	Literaturas correlatadas de RNAs e Agricultura	29
3	MATERIAL E MÉTODOS	31
3.1	Local e Área de estudo	31
3.2	Séries históricas e variáveis climáticas	32
3.3	Redes Neurais Artificiais (RNAs)	34
3.4	Estrutura das Redes Neurais Artificiais (RNAs) em Deep Learning	35
3.5	Validação das Redes Neurais Artificiais (RNAs)	39
3.6	Interpretação dos índices estatísticos	41
4	RESULTADOS E DISCUSSÃO	42
4.1	Análise de pertinência das variáveis de entrada	42
4.2	Estrutura de camadas intermediárias	43
4.2.1	Estrutura de camadas intermediárias para a temperatura máxima do ar.....	43
4.2.2	Estrutura de camadas intermediárias para a temperatura média do ar.....	47
4.2.3	Estrutura de camadas intermediárias para a temperatura mínima do ar.....	50
4.3	Distribuição espacial da temperatura média do ar anual para o Centro-Oeste do Brasil	56

4.4	Distribuição espacial da temperatura média do ar mensal para o Centro-Oeste do Brasil.....	57
5	CONSIDERAÇÕES FINAIS.....	60
	REFERÊNCIAS BIBLIOGRÁFICAS.....	62
	APÊNDICES	82

1 INTRODUÇÃO

Conforme informações do Ministério da Agricultura, Pecuária e Abastecimento (MAPA, 2021), o valor bruto da produção (VBP) de 2021 no Brasil está estimado em R\$ 1,119 trilhões, um acréscimo de 9,9% comparado ao ano anterior. Dessa maneira, houve um acréscimo nas lavouras de 11% e na pecuária de 6,2% em relação ao ano de 2020, sendo uma representatividade de 68% e 32% de lavouras e da pecuária, respectivamente (MAPA, 2021).

Em relação ao total do Brasil, conforme levantamento para o mês de outubro de 2021, o estado do Mato Grosso corresponde a um VBP de 17,43%, seguido dos estados de Goiás com 8,49% e Mato Grosso do Sul com 6,60%. A produção na região em sua maior parcela é de soja, milho, algodão, cana de açúcar bem como a criação de bovinos e frangos (MAPA, 2021).

Nesse contexto, as atividades agrícolas são influenciadas pelas condições climáticas sendo o clima um determinante para o desenvolvimento das culturas e na produção animal, que é compatibilizado com o tipo de oferta climática e variável no tempo e no espaço (ELY e DUBREUIL, 2017).

Dentre os elementos e fatores meteorológicos que influenciam o clima de uma região, podem ser citados a latitude, a longitude, a altitude, temperatura do ar, a umidade relativa do ar, a velocidade de ventos etc. Especificamente quanto a temperatura do ar, este elemento meteorológico está diretamente relacionado a diversos eventos e processos, como nas espécies vegetais atuando na quebra de dormência, crescimento embrionário, germinação e modificação da estrutura das moléculas, sobre o vapor d'água da atmosfera influenciando a evapotranspiração (SOUZA e MARTINS, 2014; KERBAUY, 2008; MOURA *et al.*, 2013).

Em relação aos animais, dentre os elementos climáticos, a temperatura do ar é de suma importância, pois o conhecimento das normais dessa variável possibilita projetar instalações com características construtivas capazes de minimizar os efeitos do clima sobre os animais, além de influenciar sobre parâmetros fisiológicos e hematológicos na criação de suínos em crescimento (WALTZ *et al.*, 2014), na avaliação comportamental de frangos de corte submetidos a diferentes ambientes térmicos (SCHIASSI *et al.*, 2015) e no desempenho produtivo de codornas no semiárido paraibano (GUIMARÃES *et al.*, 2014).

Normalmente, o acompanhamento e registro de elementos climáticos é realizado em estações meteorológicas convencionais ou automáticas por meio de medições diárias. Todavia, de acordo com Baba *et al.* (2014), a escassez de dados meteorológicos é um problema comum na maioria das regiões brasileiras, particularmente para aquelas nas quais a densidade da rede de estações meteorológicas é menor.

Nos locais onde há postos meteorológicos, são diversos fatores que podem provocar a falta ou erro no registro dos dados, dentre eles podem ser destacadas as paradas nos sensores, a

falta de calibração dos equipamentos, as falhas nas transmissões dos dados (telemetria) e a interferência de agentes externos (BABA *et al.*, 2014). Nesse contexto, a ausência ou inconstância desses dados podem constituir problemas, incertezas ou imprecisão nas análises.

Dentre os métodos mais comumente utilizados para solucionar problemas como a indisponibilidade de dados, podem ser citados aqueles que se baseiam na geoestatística e no desenvolvimento de modelos matemáticos lineares ou não lineares (FERNANDES *et al.*, 2018; CHAVES *et al.*, 2018; MONTANHER e MINAKI, 2018; YAGUCHI *et al.*, 2016). Dessa forma, a não existência de um método padrão para estimativa de informações meteorológicas de forma exata, impulsiona a busca de metodologias que possam aprimorar o processo de previsões consideravelmente próximas dos valores reais (CARVALHO e DELGADO, 2019; CARVALHO e DELGADO, 2020).

Neste contexto, tem-se as Redes Neurais Artificiais (RNA's), que são sistemas computacionais constituídos por unidades de processamento simples, também denominadas neurônios artificiais ou nodos, conectadas entre si de maneira específica para desempenhar determinada tarefa (BINOTI *et al.*, 2013; HAYKIN, 1999). Os neurônios artificiais são modelos matemáticos, simplificados dos neurônios biológicos e processam as informações recebidas e ponderadas por pesos sinápticos (BINOTI *et al.*, 2013).

As RNAs apresentam as vantagens de aprender por meio de um conjunto reduzido de exemplos, conseguem extrair a relação entre variáveis independentes e dependentes mesmo que os eventos físicos não estejam explicitamente envolvidos no processo (ULIANA *et al.*, 2018). Assim, o uso de RNAs podem ser aplicadas na solução de problemas complexos, como é o caso da variação espacial e temporal das temperaturas do ar, que dependem de diversos fatores como: a presença de vegetação, uso de solo, massas de ar polar, correntes marítimas, formas de relevo, compostos químicos atmosféricos, umidade do solo, dentre outros (SOUZA e MARTINS, 2014; SILVA *et al.*, 2019; AQUINO *et al.*, 2016).

As RNA's podem ser estruturadas com várias camadas, podendo ter em cada camada vários neurônios, sendo este tipo de rede denominada de rede *Multilayer Perceptron* (MLP) ou Múltiplas Camadas (FLECK *et al.*, 2016). As RNAs do tipo MLP apresentam uma arquitetura contendo a camada de entrada, uma ou mais camadas intermediárias e a camada de saída, no qual os sinais de entrada são propagados camada por camada, até que o vetor saída seja obtido na última camada, possibilitando solucionar problemas não linearmente separáveis (HAYKIN, 1999).

Dessa maneira, as RNAs - MLP têm sido aplicadas na solução de diversos problemas relacionados ao campo, a exemplo: na previsão das vazões diárias na bacia do rio Piracicaba (ULIANA *et al.*, 2018); no preenchimento de falhas da precipitação mensal na região serrana

do Espírito Santo (CORREIA *et al.*, 2016); predição da temperatura do ar e umidade relativa no interior de construções de regiões úmidas (MBA *et al.*, 2016); estimativa da pluviosidade no sistema de abastecimento Cantareira (OLIVEIRA *et al.*, 2018); e predição da evapotranspiração de referência (CARVALHO e DELGADO, 2019), predição da necessidade de calagem em área de pivô central (BARBOSA, 2020), Estimativa do índice de área foliar para cultura irrigada (ROCHA, 2019) e estimativa das propriedades físicas e químicas do solo (BITTAR *et al.*, 2018).

Dentre os métodos de aprendizagem de uma RNA-MLP, o mais utilizado é o backpropagation (ou retropropagação), o qual consiste em subtrair a resposta obtida pela resposta desejada. Esta subtração produzirá um sinal de erro e este sinal é retropropagado ao longo da rede neural artificial no sentido da saída para a entrada, de forma a ajustar os pesos sinápticos. Este processo possibilita que a resposta real da rede (valor estimado) se aproxime da resposta desejada (valor observado) (BORSATO *et al.*, 2009; COUTINHO *et al.*, 2016; COUTINHO *et al.*, 2018).

Em contrapartida, para se alcançar a resolução de um problema que necessita de um grande volume de dados (*Big Data*) como é o caso do estudo de séries temporais climáticas, é necessário realizar a aplicação de uma abordagem mais específica e que possibilite uma análise mais adequada (HAO *et al.*, 2016; FERLIN e REZENDE, 2019). Para este tipo de problema, tem-se a abordagem *Deep Learning*, que é uma evolução das RNAs, o qual consiste na sua topologia apresentar diversas camadas intermediárias compostas por alterações lineares e não lineares.

Assim, o *Deep Learning* possibilita que o processo de aprendizagem durante a etapa de treinamento ocorra por meio da identificação dos padrões nas camadas de processamento em vários níveis. Essa abordagem é capaz de proporcionar um aumento no desempenho para a resolução de problemas, especialmente aqueles que envolvem um considerável volume de dados. Além do mais é possível aplicar o *Deep Learning* em diferentes quantidades de neurônios na camada de entrada para selecionar a melhor combinação das variáveis explicativas, bem como analisar diferentes quantidades de camadas intermediárias e neurônios em cada camada (ALSINA *et al.*, 2016; YADAV *et al.*, 2014; JALLAL *et al.*, 2020)

Em termos de aplicações, o *Deep Learning* tem sido implementado em estudos que envolvem reconhecimento de fala (YANG *et al.*, 2018; ZHAO *et al.*, 2018); no uso de imagens digitais voltados a solucionar problemas na área da saúde (BENZ *et al.*, 2020; FRANCK *et al.*, 2021); estimativa da idade e reconhecimento de expressões faciais (ZHAO *et al.*, 2015; LIU *et al.*, 2016). Para a agricultura é possível verificar estudos voltados a contagem de folhas (GIUFFRIDA *et al.*, 2018; UBBENS *et al.*, 2018), reconhecimento de doenças em plantas

(SLADOJEVIC *et al.*, 2016; ZHANG *et al.*, 2018), classificação no uso de terras (LU *et al.*, 2017; XU *et al.*, 2017), estimativa na produção de grãos (YANG *et al.*, 2019; JIANG *et al.*, 2020), na identificação e classificação do comportamento animal (LI *et al.*, 2019; DITRIA *et al.*, 2020), dentre outras aplicações.

Portanto, estudar a empregabilidade do Deep Learning nas estimativas das médias das temperaturas do ar mensal, máxima, média e mínima com precisão satisfatória, bem como selecionar a melhor combinação de variáveis explicativas para a região Centro-oeste do Brasil, é importante pois possibilita que os produtores rurais e os órgãos governamentais possam planejar as atividades agropecuárias de maneira otimizada, definir espécies vegetais e animais mais adaptadas às condições climáticas do local de produção (REIS *et al.*, 2017; SOUZA e MARTINS, 2014; MARTINS *et al.*, 2012).

2 REVISÃO BIBLIOGRÁFICA

2.1 Temperatura do ar atmosférico e variáveis meteorológicas

2.1.1 Radiação Solar

A radiação solar é uma das variáveis meteorológicas de maior importância para a agricultura, além de exercer influência sobre outras variáveis meteorológicas, também influencia nos diversos processos das atividades agropecuárias (SOUZA *et al.*, 2019; SOUZA e ESCOBEDO, 2013). A radiação solar ocorre de duas maneiras, direta e indireta. A radiação direta é a energia que não sofre alteração em sua direção, entretanto, quando a radiação solar interage com partículas de gases da atmosfera, ocorre o processo de difusão, processo conhecido conhecida como radiação indireta (FUNARI *et al.*, 2017).

Essa variável exerce influência sobre outras variáveis meteorológicas, como a velocidade dos ventos, umidade relativa do ar, precipitação, evapotranspiração, temperatura do solo e temperatura do ar. Em relação a temperatura do solo, a mesma é influenciada pela radiação solar de forma em que parte dessa energia é utilizada para aquecer o solo e que, por sua vez, aquece a camada de ar em contato com essa superfície e é denominado de calor sensível.

Nesse contexto, este processo ocorre de duas formas: por meio de condução molecular e por meio de difusão turbulenta. O primeiro está relacionado com a troca de calor entre o contato de moléculas de ar e o segundo ocorre quando as parcelas das massas de ar aquecidas entram em movimento convectivo desordenado, transportando calor, vapor d'água, partículas de poeira, propágulos, entre outras propriedades (PEREIRA *et al.*, 2002).

Na camada de ar em contato com o solo, as temperaturas máximas do solo e do ar ocorrem simultaneamente, quando a radiação solar incide de forma direta sobre a superfície da Terra. No entanto, à medida que se afasta da superfície, o instante de ocorrência da máxima temperatura do ar é retardado em relação ao instante de ocorrência da máxima temperatura do solo (PEREIRA *et al.*, 2002). De acordo com Antonini *et al.* (2009), o solo tem a capacidade de absorver a radiação solar ao longo do dia, e quando chega o período noturno, o mesmo sofre resfriamento contínuo provocado pela interrupção da radiação solar e pelo constante processo da irradiação do solo (a radiação solar absorvida é irradiada para atmosfera em forma de ondas de comprimento longo), chegando à condição de inversão do fluxo de calor, ou seja, o solo que se encontra mais aquecido passa a transferir calor para a atmosfera.

2.1.2 Correlação da temperatura do ar com variáveis climáticas e geográficas

O efeito da altitude sobre a temperatura do ar está relacionado a pressão atmosférica no local, pois quanto menor pressão e maior a altitude, mais rarefeito é o ar a interação entre as

moléculas gasosas no processo da troca de calor ocorre com menor intensidade, o que conduz a menores temperaturas na massa de ar.

Em relação a latitude, os locais que estão situados próximos a linha do equador recebem mais energia solar com incidência menos inclinada relacionando em temperaturas mais elevadas. De maneira contrária, quanto mais distante determinado local estiver mais distante da latitude 0°, a energia solar incide de maneira tangencial, o que implica em menor energia por unidade de área e temperaturas mais amenas.

Quanto ao efeito da longitude na temperatura do ar está relacionado a diferentes taxas de aquecimento e esfriamento da terra e do mar, sob efeitos de continentalidade e maritimidade. Estes efeitos são observados conforme a distância relativa de determinado ponto na terra em relação a grandes corpos hídricos, como mares e oceanos (ARAÚJO, 2010).

Entretanto, não somente a altitude, latitude e longitude interferem na temperatura do ar de um local. Outros fatores como os maciços montanhosos, a topografia e a cobertura vegetal, a presença de ventos e a umidade relativa do ar são capazes de influenciar nos processos de troca de calor de uma região (SILVA e JARDIM, 2017).

A ocorrência dos ventos está relacionada com a interação constante entre atmosfera e superfície, por meio do deslocamento de ar dos centros de alta pressão com baixas temperaturas, em direção aos centros de baixa pressão e com elevadas temperaturas (ALVARENGA *et al.*, 2015). Esta movimentação ocorre tanto no sentido horizontal, quanto no sentido vertical, sendo as principais grandezas relacionadas são a velocidade, direção e força (SOARES e BATISTA, 2004).

Portanto, em locais situados em partes mais altas, o vento tende a ser mais veloz e mais forte, de modo em que quanto mais próximo ao solo, a velocidade tende a ser reduzida em função da fricção ou pelo atrito do vento com obstáculos da superfície (a exemplo da vegetação, construções, montanhas, solos expostos etc.).

A interação de vários fatores como a umidade do ar, diferenças latitudinais, o relevo, continentalidade, irradiância, correntes oceânicas, gradientes de pressão, são capazes de influenciar no vento de dada localidade (ALVARENGA *et al.*, 2015).

A variável de velocidade de vento se relaciona com a temperatura do ar sobre a sensação térmica e no processo de evaporação e evapotranspiração. Dessa maneira, a movimentação do ar é capaz de remover o vapor d'água da atmosfera e modificar a intensidade na troca de calor, gerando o efeito de resfriamento durante períodos de temperaturas elevadas, retirando umidade do ar e aumentando a evaporação da água (JUSTINO *et al.*, 2015).

O vento e temperatura desempenham um papel fundamental no ecossistema e no hidrológico, uma vez que os processos de convecção, evaporação e evapotranspiração está

relaciona a esta variável. Desta maneira, quando uma camada de ar saturada se move, o vento substitui por um camada de ar mais seca e que pode absorver o vapor de água (LIUZZO *et al.*, 2016).

A umidade relativa do ar diz respeito a quantidade de vapor d'água existente na atmosfera no qual a evaporação é o principal processo que gera esta variável e esse relaciona diretamente com a temperatura do ar e com os fatores geográficos de altitude, latitude, a continentalidade e maritimidade (CARNEVSKIS e LOURENÇO, 2018).

Locais situados próximos a grandes corpos hídricos e oceanos, tendem a apresentar maior umidade na massa de ar em função do efeito da maritimidade. Já em locais distantes do litoral, a umidade tende a ser reduzida quando comparado a locais próximos ao litoral. Em relação a latitude, a umidade é maior nos trópicos e a medida em que a latitude aumenta, a umidade tende a reduzir.

Assim, a umidade relativa do ar se relaciona com a temperatura de modo com que quanto maior for a altitude, menor será a pressão, o volume de vapor de água presente no ar também será menor, de modo a reduzir a temperatura do ar. De forma contrária, ocorre que quanto menor for a altitude, maior será a presença de vapor d'água no ar e maior será a temperatura do ar (TORRES e MACHADO, 2011). Entretanto, outros fatores como: temperatura do ar, cobertura vegetal, quantidade de edificações e a presença de corpos d'água, também são capazes de influenciar na variação da umidade relativa do ar (SILVA e JARDIM, 2017; CARNEVSKIS e LOURENÇO, 2018).

2.1.3 Temperatura do ar no meio rural

A influência da temperatura do ar, sobre a fisiologia vegetal, está relacionada com indução, quebra da dormência, germinação e modificação da estrutura das moléculas das sementes, bem como em todos os estádios de desenvolvimento da cultura. Isso porque cada cultura necessita de uma faixa ideal de temperatura mínima e máxima o qual ocorre o melhor desenvolvimento da planta (SOUZA e MARTINS, 2014; KERBAUY, 2004; CESARINO *et al.*, 2007). Dessa maneira, analisar os dados de temperaturas do ar é importante para entender os processos fisiológicos das plantas, bem como suas características produtivas.

Resende *et al.* (2019) avaliaram a produtividade de cultivares de melancia sob cultivo em temperaturas amenas (inverno) e mais elevadas (verão), nas condições do Submédio do Vale do São Francisco, obtendo resultados de características produtivas, as cultivares de melancia Frevo, Red Heaven, Explorer e Ranger são as mais recomendadas para plantio sob condições de temperaturas mais amenas (inverno). Sob condições de temperaturas mais elevadas (verão) as cultivares de melancia Opara F1, Ranger, Combat, Explorer, Conquista, Frevo e Red Heaven

apresentam-se como as mais produtivas e ideais para cultivo no Submédio do Vale do São Francisco (RESENDE E YURI, 2019).

Monteiro *et al.* (2017), estudaram a Emissão de CO₂ em culturas de soja e arroz irrigado no estado d Rio Grande do Sul, safra 2013/2014, notaram uma maior correlação entre a emissão de CO₂ no cultivo de arroz em relação às variações de temperatura do ar, principalmente nos tratamentos T2 (arroz irrigado colhido no barro) e T3 (arroz irrigado colhido na água), pois quando a temperatura do ar atingia 27°C, a emissão chegava a atingir valores bastantes expressivos (6,0 μmol CO₂ m⁻²s⁻¹). Isso porque a ocorrência no aumento da emissão de CO₂ associado ao aumento da temperatura do ar, pode prejudicar no desenvolvimento das culturas e reduzir a produtividade, em função no aumento da respiração do tecido vegetal, relacionando em uma redução no ciclo da cultura (STRECK, 2005; WALTER *et al.*, 2010).

Já Souza *et al.* (2018) estudaram o Zoneamento agroclimático da palma forrageira (*Opuntia sp.*) para o Estado de Sergipe, verificaram que as faixas ideais para aptidão plena são de temperatura média entre 16,1 e 25,4°C, temperatura máxima entre 28,5 e 31,5°C, temperatura mínima 8,6 e 20,4°C, em que valores fora destas faixas, a aptidão para a forrageira é considerado com restrição. Os autores verificaram que 0,03% da área é classificada como plenamente apta, 17,35% classificada como apta e com restrição, e 82,62% classificada como inapta para o plantio da palma forrageira no Estado de Sergipe.

Buriol *et al.* (2015), estudaram a variação da temperatura do ar na área da bacia hidrográfica do rio Vacacaí/RS, e apontam que as diferenças de altitude condicionam importantes variações de temperatura do ar entre as distintas localidades na área da bacia hidrográfica do rio Vacacai/RS, principalmente nos meses mais quentes do ano. Desta forma, os valores médios mensais mais elevados ocorrem na Depressão Central e os menores na Serra do Sudeste e no Rebordo do Planalto. Os autores explicam que estas condições para o crescimento vegetal são mais favoráveis, a demanda evaporativa é mais elevada e o desconforto térmico para os humanos e os animais é mais intenso do que nas áreas de maior altitude, como na Serra do Sudeste e no Rebordo do Planalto (BURIOL *et al.*, 2015).

Jesus *et al.* (2017) estudaram o impacto do aumento da concentração atmosférica de CO₂ no balanço hídrico climatológico do Cerrado, concluíram que a deficiência hídrica da simulação com CO₂ elevado é superior à da simulação controle em 24%. Isto acontece devido ao aumento de temperatura do ar durante o período seco no cenário de CO₂ elevado. A maior temperatura aumenta a evapotranspiração desse período, e como a precipitação não aumenta durante a estação seca, a deficiência hídrica é maior nesse cenário. Portanto, os autores ainda dizem que, o acréscimo de concentração de CO₂ na atmosfera pode aumentar a temperatura média anual do Cerrado em 0,2 °C com um efeito mais pronunciado nos meses de inverno. O

aumento da temperatura do ar se deve ao fato da intensificação do efeito estufa gerado pelo aumento de concentração atmosférica de CO₂.

Em ambiência animal, a temperatura é de suma importância e quando associada a umidade relativa do ar, ventilação e radiação solar, são capazes de causar desconforto nos animais (PADILHA *et al.*, 2017). Quando a temperatura do ar permanece acima da máxima suportada pela espécie, os mecanismos de termorregulação são iniciados visando à dissipação do calor. Se não houver diminuição da temperatura do ambiente os mecanismos de termorregulação são intensificados ocasionando maior gasto energético, resultando em prejuízos produtivos (GUIMARÃES *et al.*, 2020; PADILHA *et al.*, 2017).

Nesse sentido, a temperatura do ar, associada com a umidade relativa são variáveis utilizadas para determinar Índice de Temperatura e Umidade, que é utilizado para verificar se as condições ambientais adequadas em que os animais estão submetidos, sendo estes um dos principais parâmetros para identificar estresse térmico na produção e criação de animais (JUSTA *et al.*, 2019).

Desta maneira, Coelho *et al.* (2019) avaliaram o ambiente térmico de aviário com fechamento em alvenaria na fase inicial para frangos de corte, obtiveram resultados para a temperatura média do ar na primeira semana de vida, variando de 21.4 a 30.9 °C, sendo considerado bem abaixo de valores recomendados na literatura e bem abaixo dos sugeridos no manual da linhagem dos frangos de corte, indicando que as aves estão sobre estresse por frio na fase de crescimento.

Ao estudar as variáveis fisiológicas e de desempenho produtivo como indicadores de estresse térmico em caprinos mestiços Boer em câmara climática, Miranda *et al.* (2018) verificaram que as variáveis fisiológicas apresentaram efeito diretamente proporcional à temperatura do ambiente, e quanto maior foi a temperatura do ar, os animais consumiram menos alimento e obtiveram menos peso, reduziram a eficiência de conversão dos alimentos em tecido corporal e gordura, reforçando o estado de desconforto térmico com a elevação da temperatura ambiente.

Já Silva *et al.* (2020), estudaram a influência da temperatura e umidade relativa do ar no consumo alimentar de suínos no semiárido brasileiro, no qual foi possível inferir que temperaturas do ar em torno de 24 e 25°C (meses de junho e agosto) proporcionaram um ambiente ideal para o desempenho produtivo de suínos e aumento no consumo alimentar. Entretanto, os autores salientam que na maior parte do ano os suínos sofrem estresse devido à elevada temperatura, influenciando negativamente no ganho de peso e eficiência de utilização do alimento.

Santos *et al.* (2020), avaliaram a influência do ambiente em diferentes períodos do dia sobre os parâmetros fisiológicos de frangos caipira da linhagem *Label Rouge* em diferentes fases de criação (inicial, crescimento e terminação) na Amazônia Ocidental. Os resultados indicaram a partir da quinta semana de criação (com temperatura do ar em torno de 28,5°C) os animais já se encontravam fora da zona de termoneutralidade estabelecidas, e explicam que as altas temperaturas associadas à alta umidade no período da tarde aumentaram os índices bioclimáticos (ITU e ITGU), bem como o aumento no desconforto dos animais, promovendo alteração nas temperaturas superficiais e frequência respiratória.

Santos *et al.* (2018) estudaram o impacto do microclima sobre a fisiologia, pelame e produção de leite de vacas lactantes em diferentes estações do ano, verificando que as variáveis ambientais nas duas estações do ano não promoveram grandes alterações nas respostas fisiológicas e produtivas dos animais, indicando adaptação destes às condições climáticas do ambiente de criação. Entretanto, os autores ressaltam que houve diferenças entre épocas para a maioria dos parâmetros fisiológicos estudados, sendo estes mais elevados na primavera (com temperatura variando de 15,9 a 27,8°C) e no horário da tarde.

Castro *et al.* (2017) avaliaram o comportamento de codornas japonesas submetidas a diferentes temperaturas, verificando que o intervalo de conforto térmico, obtido com base na análise comportamental de codornas japonesas em fase de postura, foi de 22°C a 24°C, e concluíram que as codornas japonesas apresentaram reações condizentes com o estresse térmico quando foram submetidas à temperatura ambiente igual a 20°C.

2.2 Séries Temporais

Séries temporais são conjuntos de observações ordenadas no tempo, refletem o comportamento de sistemas físicos ou fenômenos a partir de dados coletados periodicamente, podendo uma série temporal ser representada matematicamente (SOARES, 2017; MORETTIN e TOLOI, 2006).

Neste sentido, estudos foram desenvolvidos baseando-se em séries temporais em diferentes áreas do conhecimento, a exemplo do mercado financeiro (KEIEL e BENDER, 2018; SILVEIRA *et al.*, 2017), da saúde (CASCAES *et al.*, 2018; PARENTE *et al.*, 2020; SANTOS *et al.*, 2020). Em relação a agricultura, é possível verificar na literatura estudos voltados para comparação de algoritmos de filtragem em séries temporais de NDVI/MODIS (VICENS e FURTADO, 2018), Viabilidade econômica da produção de biogás em granjas de suínos, por meio da análise de séries temporais (ROCKENBACH *et al.*, 2016).

Alguns estudos com enfoque em séries temporais de variáveis meteorológicas, podem ser citados para a resolução de problemas relacionados à caracterização de mudanças climáticas

na cidade do Recife (ROCHA e SANTOS, 2017); na análise de índices de extremos climáticos na Região MATOPIBA do Brasil (REIS *et al.*, 2020); variabilidade e tendências da precipitação pluvial (JUNGES *et al.*, 2019); na estimativa da evapotranspiração de referência (CARVALHO e DELGADO, 2019); previsão de velocidade do vento em termos de médias mensais e horárias (CAMELO *et al.*, 2017), são alguns exemplos.

Portanto, estudar e analisar séries temporais possibilita compreender os mecanismos que gera os valores da série, de forma a explicar tal comportamento em relação a um determinado intervalo no tempo (BOX *et al.*, 2015; SOARES, 2017). Desta maneira, uma abordagem que pode ser utilizada para solucionar problemas como a indisponibilidade de dados é o emprego de Redes Neurais Artificiais, como é o caso de estimativas de elementos meteorológicos, que são problemas complexos, que são influenciados por diversos fatores e elementos e que variam no tempo e no espaço (PAPANTONIOU e KOLOKTSA, 2016; KIRBAS e KEREM, 2016; LIU *et al.*, 2019).

2.3 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são sistemas computacionais baseados na atividade de redes de neurônios biológicos os quais são constituídos por unidades de processamento simples, também denominadas neurônios artificiais ou nodos, conectadas entre si de maneira específica para desempenhar determinada tarefa (PACHECO e PEREIRA, 2018; BINOTI *et al.*, 2013; HAYKIN, 1999).

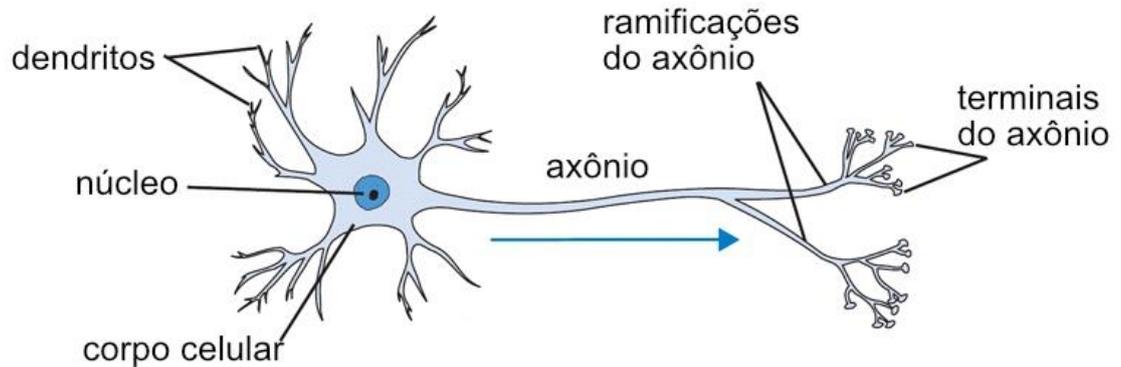
Neste sentido, as RNAs são utilizadas na resolução de problemas complexos, nos quais o comportamento das variáveis não é rigorosamente conhecido. Uma de suas principais vantagens está relacionada a capacidade de aprender por meio de exemplos e de generalizar a informação aprendida de modo a gerar um modelo não linear e de aplicação eficiente (SPÖRL *et al.*, 2011). Outras vantagens da RNA estão relacionadas à não-linearidade, adaptabilidade, resposta a evidências, informação contextual, tolerância a falhas e análise neurobiológica (FLECK *et al.*, 2016).

Entretanto e assim como outros métodos preditivos, as RNAs também apresentam algumas limitações quanto ao desempenho e aplicabilidade, a exemplo: tempo de treinamento demorado, conclusões contrárias às teorias aceitas e fatores relacionados aos dados como a preparação prévia e a necessidade de um grande volume de conjuntos amostrais (AMBRÓSIO, 2002; FLECK *et al.*, 2016). Este último fator, no entanto, se adequa à proposta deste trabalho, pois as séries históricas de variáveis meteorológicas consideram observações superiores a trinta anos.

2.3.1 Unidades de Processamento ou Neurônios Artificiais

O neurônio biológico é uma célula responsável por produzir e conduzir um impulso nervoso, que nada mais é que um impulso elétrico, caracterizado como unidade básica anátomo-funcionais tanto do cérebro quanto do sistema nervoso, sendo que um ser humano chega a possuir cerca de 100 bilhões de neurônios (GUYTON e HALL, 2006; FABRINI, 2019).

Figura 1 – Representação dos componentes de um neurônio biológico.



Fonte: Rodrigues (2020).

Um neurônio é constituído pelas seguintes partes: os dendritos, o corpo celular ou núcleo, o axônio e a sinapse (FERNDA, 2006; FABRINI, 2019). Estes constituintes são capazes de desempenhar funções específicas e complementares, de forma que os dendritos realizam a coleta dos impulsos nervosos advindos de outros neurônios, enquanto o corpo celular apresenta a função de processar os sinais recebidos pelos dendritos (PACHECO e PEREIRA, 2018; BIANCHINI, 2001).

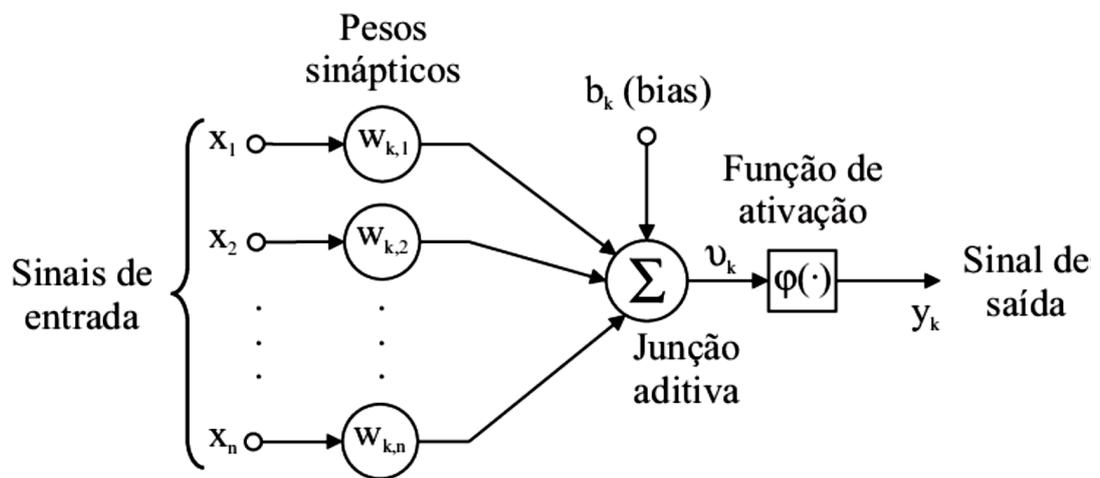
Em relação ao axônio, este é caracterizado como sendo um prolongamento do corpo celular e é responsável pela transmissão dos impulsos nervosos captados pelos dendritos. Já a sinapse pode ser interpretada como pontos de conexão entre o axônio de um neurônio com o dendrito de outro neurônio e tem a funcionalidade de transmitir os impulsos elétricos (FABRINI, 2019).

As RNAs são capazes de aprender por meio de um conjunto reduzido de exemplos, conseguem extrair a relação entre variáveis independentes e dependentes, mesmo que os eventos físicos não estejam explicitamente envolvidos no processo (ULIANA *et al.*, 2018). Assim, o uso de RNAs podem ser aplicadas na solução de problemas complexos, como é o caso da variação espacial e temporal da temperatura do ar, que dependem de diversos fatores como: a presença de vegetação, uso de solo, massas de ar polar, correntes marítimas, formas de relevo,

compostos químicos atmosféricos, umidade do solo, dentre outros (SOUZA e MARTINS, 2014; SILVA *et al.*, 2019; AQUINO *et al.*, 2016).

Em relação aos neurônios artificiais, eles são modelos matemáticos simplificados dos neurônios biológicos que processam as informações recebidas e ponderadas por pesos sinápticos (BINOTI *et al.*, 2013). Na Figura 2 é apresentado um modelo de um neurônio artificial, do tipo Perceptron e seus respectivos componentes (sinais de entrada, pesos sinápticos, junção aditiva, função de ativação e sinal de saída).

Figura 2 – Representação do neurônio artificial Perceptron e seus componentes (sinais de entrada, pesos sinápticos, junção aditiva, função de ativação e sinal de saída).



Fonte: Bianchini (2001)

Conforme exemplificado na Figura 2, um neurônio artificial conta com sinais de entradas, sendo estes equivalentes aos dendritos do neurônio biológico (Figura 1). Os pesos sinápticos realizam a ligação entre os neurônios, de modo em que cada sinal de entrada será multiplicado pelo peso sináptico associado a ele. Já a função aditiva, também conhecida como função soma, é responsável por realizar a soma dos sinais de entrada ponderados pelo respectivo valor de peso, de forma a se obter um novo valor. Por último, a função de ativação possibilita a emissão da amplitude do sinal de saída do neurônio, conforme a estrutura da função empregada (NARANJO, 2014; PACHECO e PEREIRA, 2018).

2.3.2 Conexões Sinápticas

Conforme citado anteriormente, as conexões sinápticas realizam a junção entre os dendritos e o axônio dos neurônios biológicos, sendo que cada conexão terá a ela associado um peso sináptico. Este peso sináptico está relacionado ao nível de influência do dado de entrada para a classificação do problema (NARANJO, 2014). O modelo de cada unidade da rede pode

incluir uma não-linearidade em sua saída, no qual a função de ativação tem como principais objetivos identificar qual ou quais neurônios serão ativados bem como determinar a relevância das informações que serão recebidas pelos neurônios subsequentes (FLECK *et al.*, 2016; LIN e SHEN, 2018).

Normalmente o estado de ativação dos neurônios pode assumir valores binários (0 e 1), valores bipolares (-1 e 1) e por fim, valores analógicos (0 a 1 ou -1 a 1), dependendo da função de ativação utilizada. Desta maneira, a escolha da função de ativação ocorre em função da necessidade do problema no que a rede está trabalhando, sendo as principais funções de ativação utilizadas em redes neurais artificiais: a limiar e limiar por partes (FLECK *et al.*, 2016); função degrau e tangente sigmoide (NARANJO, 2014); função logarítmica, seno e sigmoide (BINOTI *et al.*, 2014); Softmax (AGARWALL *et al.*, 2018; ARUNKUMAR *et al.*, 2020); Tangente Hiperbólica e Logística (COUTINHO *et al.*, 2016; COUTINHO *et al.*, 2018) e a Unidade Linear Retificada (PETROSYAN *et al.*, 2020; ECKLE *et al.*, 2019).

Quanto à função de Unidade Linear Retificada, conhecida como ReLU (*Rectified Linear Unit*) é uma das funções mais comuns aplicadas às RNAs e em especial, na abordagem Deep Learning (LIN e SHEN, 2018). As principais vantagens da função ReLU é a sua simplicidade de ser calculada e implementada, além de proporcionar uma maior rapidez na convergência para o resultado ótimo (YU *et al.*, 2020). Essas vantagens possibilitam explorar e estudar diferentes arquiteturas para otimizar o desempenho das RNAs de forma satisfatória, mesmo em hardwares que apresentam baixo desempenho.

2.3.3 Processamento Neural

2.3.3.1 Treinamento

O processamento de uma Rede Neural Artificial pode ser dividido em duas etapas: a execução e treinamento. Na etapa de treinamento, são utilizados algoritmos de aprendizagem com o objetivo de realizar a atualização dos pesos sinápticos das conexões existentes entre neurônios das camadas, de modo que a RNA se adapte e alcance o objetivo desejado (HAYKIN, 2001; MONTEIRO *et al.*, 2016).

O método de aprendizado de máquina envolve a criação de uma função de treinamento para um conjunto de dados, fazendo o uso de um mecanismo de inferência lógica (SANTOS *et al.*, 2019). Neste sentido e em termos de processo de aprendizado (treinamento), o mesmo pode ocorrer por meio de aprendizagem supervisionada e não-supervisionada (HAYKIN, 2001).

O aprendizado não supervisionado, apresenta a característica de não haver o conhecimento prévio de classes, bem como o de não haver um supervisor acompanhando o processo de aprendizagem. A rede aprende baseando-se em padrões a partir dos dados de

entrada (RUSSEL & NORVIG, 2013). Desta forma, no aprendizado não-supervisionado, a rede tende a procurar algum tipo de redundância ou correlação buscando a formação de agrupamentos em amostras que apresentam semelhanças entre si (FLECK *et al.*, 2016; SANTOS *et al.*, 2019).

Já no aprendizado supervisionado, há a presença de um supervisor que conhece a relação dos dados com a classe para conduzir o processo de aprendizado, este tipo de método de treinamento consiste em apresentar à rede um padrão de entrada bem como suas respectivas saídas (HAYKIN, 2001), sendo o algoritmo backpropagation o mais comumente utilizado no treinamento por aprendizado supervisionado. O treinamento backpropagation consiste em duas etapas: o processamento direto (forward) e o processamento reverso (backward).

No processamento direto, uma entrada é aplicada à rede neural e seu efeito é propagado pela rede, camada a camada, os quais os pesos da rede não são alterados (COUTINHO *et al.*, 2016). Quanto ao processamento reverso, é calculada a diferença entre valor observado e estimado pela RNA, obtendo-se assim um erro na saída da rede, o qual é propagado no sentido reverso camada a camada e durante este processo, os pesos são ajustados de acordo com uma regra de correção de erro (BORSATO *et al.*, 2009; COUTINHO *et al.*, 2016; COUTINHO *et al.*, 2018). Nesta etapa de aprendizagem, os pesos sinápticos são modificados a cada iteração de forma que a saída calculada pela rede neural se aproxime da saída. Desta forma, a minimização do erro ocorre de maneira incremental, pois a cada resposta gerada pela rede, são efetuados pequenos ajustes nos pesos das conexões (FLECK *et al.*, 2016).

Portanto, o treinamento pode ser considerado como concluído a partir de um dado número máximo de iterações previamente definido ou então, quando o erro é menor que um determinado limiar (CAJO *et al.*, 2020; PEREIRA e CENTENO, 2017).

Um aspecto importante diz respeito a repartição do conjunto de dados que são utilizados na etapa de treino. Isto porque é importante que as parcelas amostrais sejam em quantidade suficiente para que a rede possa aprender de modo a representar adequadamente o problema estudado (PEREIRA e CENTENO, 2017). Normalmente, a divisão ocorre de 70-80% para treinamento e 30-20% do conjunto dos dados utilizados para a etapa de validação e se faz necessária para realizar uma avaliação dos resultados de treinamento em contraposição aos de teste (CARVALHO e DELGADO, 2019; COUTINHO *et al.*, 2016; AQUINO *et al.*, 2016). Desta maneira, é possível realizar uma inferência independente sobre o desempenho do sistema para que o mesmo possa ser utilizado de maneira confiável em futuras análises (MONARD e BARANAUSKAS, 2003).

2.3.3.2 Execução: Validação e Teste

A fase de validação é o processo de cálculo da saída da RNA em função dos vetores de entrada. Nesta etapa, os pesos sinápticos não são modificados e é esperado que a rede produza uma saída muito próxima daquela que seria gerada pelo sistema na fase de treinamento (NARANJO, 2014).

A etapa de validação diz respeito a avaliar a capacidade de generalização da rede para qualquer dado no domínio do problema, ou seja, a sua capacidade de aprendizagem. Desta forma, esta etapa consiste em apresentar à RNA entradas que não estavam presentes no conjunto amostral utilizados durante a fase de treinamento e objetivando que a rede possa produzir saídas adequadas para estes dados (BINOTI *et al.*, 2015). Assim, é possível verificar se a rede está conseguindo generalizar a solução de um determinado problema ao comparar a parcela treinada em contraposição à parcela de teste (ERICHSON *et al.*, 2020).

Entretanto, ao realizar a etapa de validação, a RNA pode não apresentar uma boa capacidade de generalização, surgindo assim, alguns problemas conhecidos como superajuste (*overfitting*) e subajuste (*underfitting*) do sistema. Conforme explicado por Monard e Baranauskas (2003), o *overfitting* ocorre quando o modelo se adaptou em excesso ao conjunto de treinamento utilizado, apresentando um melhor desempenho nesta etapa, mas não generaliza bem para novos dados. Nesta situação, diz-se que o modelo se especializou no conjunto de dados de treino, mas não aprendeu de fato o que diferencia aqueles dados para quando ser aplicado ao universo do problema.

Em relação ao *underfitting*, este tipo de problema ocorre quando existem poucos exemplares ou quando estes não são suficientemente representativos, de modo que o modelo não se adaptará aos dados com os quais foi treinado. Além do mais, quando o número de neurônios ou conexões da rede não suficientes, isto poderá resultar em um desempenho muito pequeno tanto no conjunto de treinamento, quanto no conjunto de teste (MONARD e BARANAUSKAS, 2003).

2.3.4 Topologia de Redes Neurais Artificiais

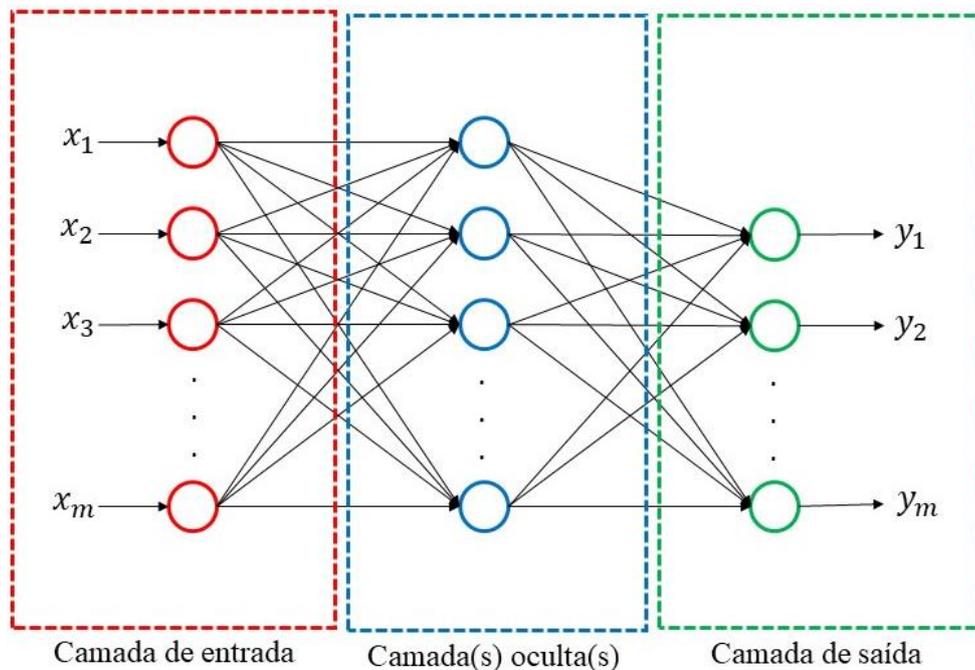
Para que a rede possua uma boa capacidade de generalização e que possa contornar os problemas de *overfitting* e *underfitting*, é necessário o estudo e a definição cuidadosa de todos os seus parâmetros (FLECK *et al.*, 2016). Desta forma, os principais fatores que devem ser considerados na arquitetura de uma RNA são: o número de nós na camada de entrada, o número de camadas escondidas bem como o número de neurônios contidos nestas camadas, a função de ativação dos neurônios e o número de neurônios na camada de saída (SANTOS *et al.*, 2005; GEORGENS *et al.*, 2014).

O número de nós na camada de entrada corresponde ao número de variáveis predictoras, normalmente aquelas de maior importância para o problema de estudo e, no caso da camada de saída, estas dizem respeito às variáveis resultantes, ou seja, as variáveis estimadas. Quanto ao número de camadas ocultas assim como o número de neurônios que devem constar nesta camada, podem ser definidos por meio de metodologias disponíveis na literatura (HIROSE *et al.*, 1991; ARAI, 1993; FUJITA, 1998). Entretanto é mais comum serem definidos de forma empírica baseando-se na experiência do pesquisador e levando em consideração o tipo do problema a ser solucionado (BINOTI *et al.*, 2014).

2.3.5 Redes Neurais Artificiais Múltiplas Camadas

As RNAs de maneira geral são dispostas em camadas, podendo ter em cada camada ‘N’ quantidade de neurônios, sendo este tipo de rede denominada de rede *Multilayer Perceptron* (MLP) ou Múltiplas Camadas (FLECK *et al.*, 2016). As RNAs do tipo MLP apresentam uma arquitetura contendo a camada de entrada, a camada intermediária e a camada de saída (Figura 3). Os sinais de entrada (também denominadas de variáveis de entrada) são propagados camada por camada, até que o vetor saída seja obtido na última camada, possibilitando solucionar problemas não linearmente separáveis (HAYKIN, 1999).

Figura 3 – Arquitetura de uma Rede Neural Artificial de Múltiplas Camadas



Fonte: Elaborado pelo autor.

Neste sentido, as RNAs MLP têm sido aplicadas na solução de diversos problemas relacionados ao campo, a exemplo: na previsão das vazões diárias na bacia do rio Piracicaba

(ULIANA *et al.*, 2018); no preenchimento de falhas da precipitação mensal na região serrana do Espírito Santo (CORREIA *et al.*, 2016); previsão da temperatura do ar e umidade relativa no interior de construções de regiões úmidas (MBA *et al.*, 2016); estimativa da pluviosidade no sistema de abastecimento Cantareira (OLIVEIRA *et al.*, 2018); e previsão da evapotranspiração de referência (CARVALHO e DELGADO, 2019).

Em síntese, a compreensão das exigências térmicas de vegetais e animais e a aplicação de dados meteorológicos de boa qualidade é de fundamental importância para elaboração de estratégias de manejo, aumentar a produção, contribuir em programas de seleção e melhoramento genético, estabelecer as espécies ou cultivares mais adaptadas às condições climáticas do local de produção (SOUZA e MARTINS, 2014; MARTINS *et al.*, 2012).

2.4 Deep Learning

O Machine Learning (Aprendizado de Máquina) é um subdomínio no campo de Inteligência Artificial, o qual possibilita o computador a habilidade de aprender sem a necessidade de ser explicitamente programado para tal atividade (SHRESTHA *et al.*, 2021).

Dessa maneira o Machine Learning pode ser entendido como uma maneira capaz de adquirir conhecimento por meio de uma base de dados (também entendido como uma base de exemplos) em que cada exemplar está relacionado a um alvo, ou seja, a resposta desejada. Assim, o aprendizado da máquina pode ser de forma supervisionada, não supervisionada e aprendizado por reforço, conforme abordado no tópico de redes multicamadas (SHRESTHA *et al.*, 2021).

Deep Learning pode ser entendido como um subdomínio do Aprendizado de Máquina, porém, com um maior aprofundamento na etapa de aprendizagem e a possibilidade de se desenvolver modelos mais complexos (SCHMIDHUBER, 2015; LECUN e BENGIO, 1995). A topologia base de redes com abordagem Deep Learning, consideram várias camadas intermediárias, diversos neurônios em cada camada e diferentes funções de ativação entre camadas.

Neste sentido a utilização do Deep Learning, tem como fundamento que esse incremento de camadas intermediárias e a aplicação de várias funções de transformação, são capazes de representar os dados de uma forma hierárquica por meio de vários níveis de abstração (SCHMIDHUBER, 2015; LECUN e BENGIO, 1995). Este tipo de organização, possibilita às redes um pré-treinamento em camadas, de modo a superar os problemas relacionados à etapa de treinamento e apresentar uma melhor aprendizagem para as redes (HAO *et al.*, 2016).

Portanto, a utilização de redes neurais artificiais multicamadas associadas ao Deep Learning são capazes de resolver problemas mais complexos pelo fato de também utilizarem

modelos mais complexos. Esse incremento na complexidade dos modelos permite uma maior capacidade de aprendizagem e, portanto, um possível incremento do desempenho e da precisão das redes. Assim, os problemas relacionados a classificação normalmente apresentam uma maior precisão classificatória e no caso de problemas de regressão, o erro de simulação é reduzido (KAMILARIS e PRENAFETA-BOLDÚ, 2018).

Por se tratar de um método adaptativo e flexível, o Deep Learning tem sido aplicado em uma variedade de problemas complexos de diversas áreas, como exemplos o para reconhecimento de fala (YANG *et al.*, 2018; ZHAO *et al.*, 2018); no uso de imagens digitais voltados a solucionar problemas na área da saúde (BENZ *et al.*, 2020; FRANCK *et al.*, 2021).

Particularmente para a área da agricultura, é possível verificar estudos aplicando Deep Learning para solucionar problemas de monitoramento espacial e temporal da temperatura e umidade do solo (GENG e DONG, 2017; SONG *et al.*, 2016); para a contagem de frutos de tomates a partir de imagens digitais (RAHNEMOONFAR e SHEPPARD, 2017); também tem sido aplicado na detecção de obstáculos e anomalias em lavouras (CHRISTIANSEN *et al.*, 2016), dentre outros.

Portanto, é possível verificar na literatura trabalhos que aplicaram às Redes Neurais Artificiais a abordagem Deep Learning, baseados em diferentes quantidades e tipos de dados, tanto para estimativas quanto para classificações, com diferentes métricas de avaliação, comparação de métodos e junção entre técnicas abordadas. Isso indica uma boa flexibilidade e adaptabilidade da técnica de Deep Learning para a resolução de diversos problemas relacionados à agricultura.

2.5 Literaturas correlatas de RNAs e Agricultura

Autores como Esteves *et al.* (2019) utilizaram redes neurais artificiais multicamadas para estimar a precipitação em diferentes localidades e estações climáticas do Brasil, no qual obtiveram precisão médias das redes de 78% na estação de verão, 71% na estação de inverno, 62% na estação de primavera e 56% na estação de outono. Os autores explicam que os efeitos da continentalidade, altitude e do volume de precipitação impactaram diretamente na precisão das redes em estações bem definidas e que as redes neurais artificiais podem ser utilizadas para indicar a eminência da precipitação.

Ao prever a radiação solar utilizando redes neurais artificiais baseadas em interpolação para o Sudeste da China, Zou *et al.* (2016) verificaram melhor acurácia quando comparado a modelos empíricos, com valores de Raiz Quadrática de Erro Médio, Erro Médio do bias e coeficiente de determinação de 1.34MJm^{-2} , 0.11MJm^{-2} e 0.91, respectivamente, concluindo

que as redes propostas apresentaram boa performance na estimativa da radiação solar de modo a auxiliar na compreensão das variações desta variável meteorológica no Sudeste da China.

Em estudos da velocidade do vento a curto prazo para a cidade de Burdur na Turquia, os autores Kirbas e Kerem (2016) obtiveram como resultados 99% de precisão na estimativa da velocidade dos ventos ao utilizarem redes neurais artificiais multicamadas. Resultados semelhantes, foram encontrados por Lee *et al* (2019) que obtiveram um coeficiente de correlação no valor de 0,90 entre valores medidos e estimados por redes neurais artificiais ao estudar o máximo acumulado de neve para região Sudeste da Coreia do Sul, no qual os autores explicam que utilizar as redes reduziu de forma significativa as altas incertezas das estimativas causadas pela alta variabilidade espacial.

Papantoniou e Koloktsa (2016) utilizaram redes neurais artificiais para prever a temperatura do ar externa para quatro cidades europeias (Ancona – Itália, Chania – Grécia, Granada – Espanha e Mollet – Espanha), obtendo valores de coeficiente de correlação superiores a 0,9 e de Raiz Quadrática do Erro Médio inferior a 2°C para todas as localidades estudadas, confirmando a acurácia das redes neurais artificiais para previsão da temperatura do ar nas localidades estudadas.

Liu *et al.* (2019) verificaram que a aplicação de Redes Neurais Artificiais para estimativa da temperatura do ar na estação de verão para a China no qual obtiveram coeficiente de correção, Raiz Quadrática do Erro Médio e Bias nos valores de 0.97, 1.72°C, e 0.04°C, respectivamente, quando comparado com a regressão linear que obteve 0.89, 3.28°C, e 0.07°C para o coeficiente de correção, Raiz Quadrática do Erro Médio e Bias, para respectivamente, indicando que as redes neurais artificiais apresentam melhor acurácia nas estimativas.

Entretanto, na literatura disponível verifica-se certa limitação de trabalhos correlatados que aplicaram redes neurais artificiais múltiplas camadas e Deep Learning nas estimativas das temperaturas do ar, máxima, média e mínima, a nível mensal para a região Centro-Oeste do Brasil.

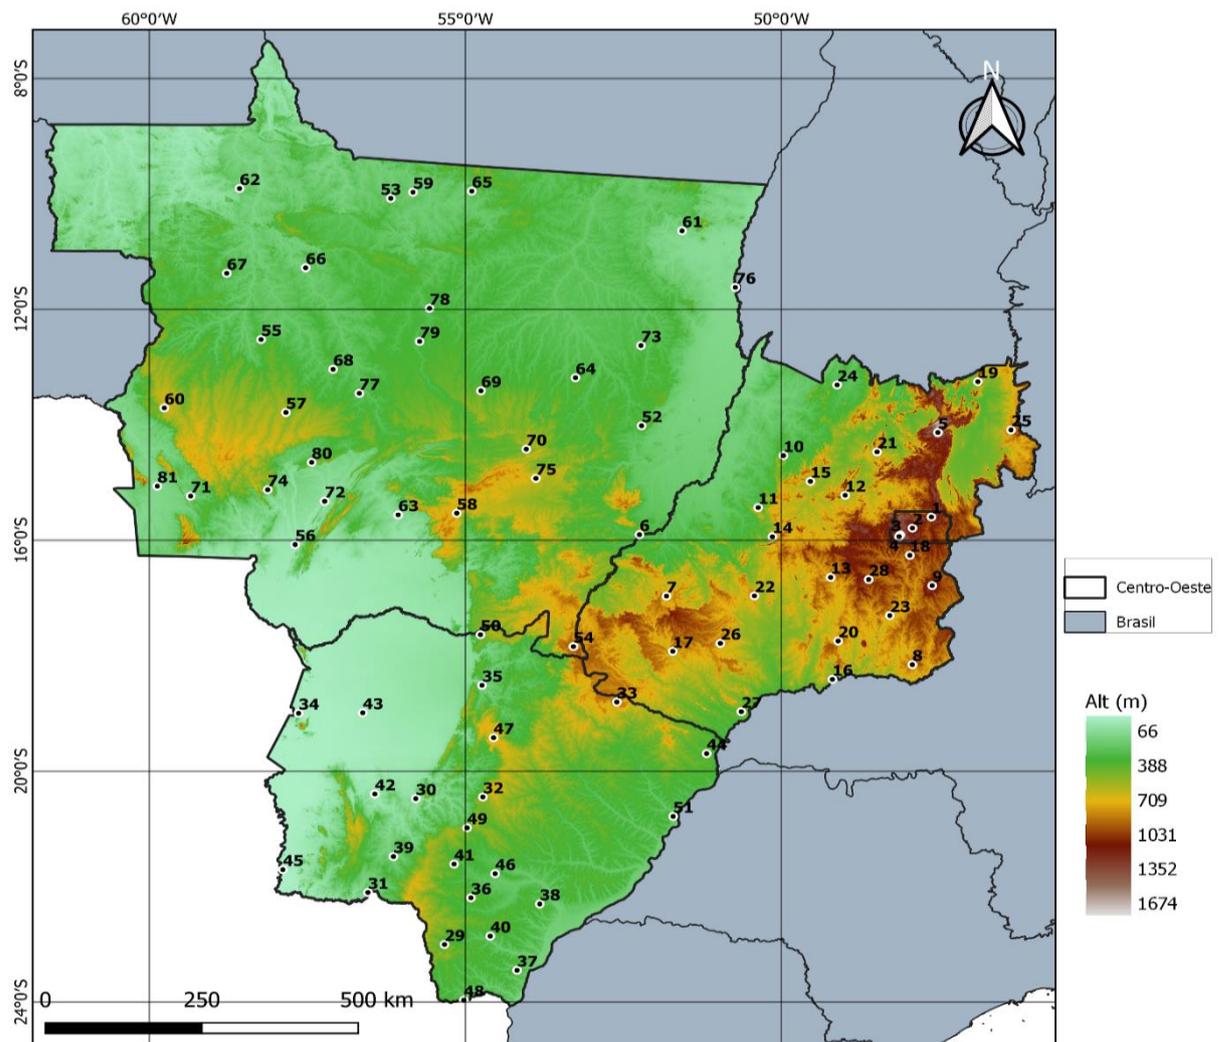
3 MATERIAL E MÉTODOS

3.1 Local e Área de estudo

O trabalho foi desenvolvido no Laboratório de Engenharia Agrícola da Universidade Estadual de Goiás, Campus Central – CET, sede Anápolis/GO. O estudo foi realizado para a região Centro-Oeste do Brasil, nos estados de Goiás, Mato Grosso, Mato Grosso do Sul e Distrito Federal. Conforme Informações do IBGE (2020a) o Estado de Goiás apresenta uma extensão territorial de aproximadamente 340.242 Km², o Distrito Federal de 5.760 Km², Mato Grosso com 903.207 Km² e o Mato Grosso do Sul de 357.148 Km². Dessa forma, a região Centro-Oeste do Brasil totaliza aproximadamente 1.606.358 Km² de território (IBGE. 2020a).

A Figura 4 e Apêndice A apresentam os valores de altitude (metros), latitude (em graus decimais) e longitude (graus decimais) e o código de identificação da estação na Organização Meteorológica Mundial (OMM), das 81 estações meteorológicas que foram utilizadas neste trabalho.

Figura 4 – Mapa de elevação e distribuição espacial de 81 estações meteorológicas localizadas nos estados que compreendem a região Centro-Oeste do Brasil.



Fonte: Instituto Nacional de Meteorologia (2020). Instituto Brasileiro de Geografia e Estatística (2020b). *United States Geological Survey* (2021).

O mapa (Figura 4) foi gerado utilizando o *software* QGIS versão 3.16.1, com dados de coordenadas geográficas das estações meteorológicas obtidas pelo Instituto Nacional de Meteorologia (INMET, 2020). Os arquivos de delimitações estaduais foram obtidos pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2020b) e as imagens de topografia obtidas por meio do *United States Geological Survey*, o Serviço Geológico dos Estados Unidos (USGS, 2020).

Conforme classificação de Köppen, o Estado de Goiás e o Distrito Federal apresentam clima Aw, definido como tropical de savana com duas estações distintas, a estação seca no inverno e a estação chuvosa no verão (CARDOSO *et al.*, 2014). Já o Estado do Mato Grosso apresenta dois tipos de classificação Am e Aw. O clima Am é definido como tropical de monção, sendo caracterizado por apresentar temperatura média no mês mais frio superior a 18°C e estação seca de pequena duração (TRES *et al.*, 2016). No caso do estado do Mato Grosso do Sul, este apresenta quatro tipos de classificação: Am, Aw, Cfa e Af. O clima Cfa é definido como temperado subtropical com verões quentes, geadas pouco frequentes, chuvas mais concentradas no verão, porém, sem estação seca definida. Já o clima Af é caracterizado por também não apresentar estação seca definida (IVASKO JÚNIOR *et al.*, 2020; EMBRAPA, 2016).

3.2 Séries históricas e variáveis climáticas

A Organização Meteorológica Mundial preconiza que na análise de séries históricas de dados climáticos, sejam utilizados dados de pelo menos 30 anos de observação (MARTIN *et al.*, 2008). As séries históricas de dados oficiais de temperatura do ar, disponíveis na região Centro-Oeste, com densidade aceitável, não atingem este número de anos de observações. Porém, resultados satisfatórios têm sido obtidos em séries históricas, com o número de anos de observações abaixo do preconizado (ANTONINI *et al.*, 2009; PEZZOPANE *et al.*, 2004; GOMES *et al.*, 2005).

Foram utilizados dados diários da temperatura máxima, mínima e média, velocidade do vento e umidade relativa do ar de estações automáticas obtidos na plataforma online do Instituto Nacional de Meteorologia (2020). Dessa forma, foram selecionadas 24 estações meteorológicas de municípios compreendidos no estado de Goiás, 04 estações meteorológica do Distrito Federal, 23 estações localizadas no estado do Mato Grosso do Sul e 30 no estado do Mato Grosso, totalizando 81 pontos amostrais, referentes ao período com disponibilidade de dados entre 2000 e 2020 (INMET, 2020).

Para completar o período de 30 anos estipulado pela OMM e preencher possíveis falhas nos registros das estações automáticas, foi utilizado banco de dados desenvolvido por Xavier

et al. (2015) para o Brasil no *software* R versão 3.6.1, de resolução espacial horizontal em Grid de 0,25° de latitude e 0,25° de longitude.

A verificação da consistência entre os valores medidos pelos equipamentos das estações meteorológicas e os dados interpolados Xavier *et al.* (2015) foi realizada a análise de correlação de Pearson (r) para as variáveis de Tmax, Tmed, Tmin, UR e VV. O valor admitido como critério foi de $r \geq 0,5$ no qual é considerada uma correlação alta (COHEN, 2013; ESTEVES *et al.*, 2019). Este critério foi adotado para garantir uma maior quantidade de estações meteorológicas no estudo já que cada local obteve um valor diferente para este parâmetro. Após esta análise, os dados observados faltantes nas estações meteorológicas foram preenchidos com os dados interpolados pelo inverso da distância de modo a completar a série estipulada de 30 anos (entre 1990 e 2020) e garantir a consistência das análises posteriores.

Em cada município foram determinadas as médias aritméticas dos dados diários das temperaturas do ar máxima (Tmax, em °C), mínima (Tmin, em °C) e média (Tmed, em °C), umidade relativa (UR, em %) e velocidade do vento (VV, em m.s⁻¹), para serem obtidos seus respectivos valores a nível mensal (de janeiro a dezembro), de modo a completar os 12 meses do ano. Este processo foi realizado para os outros 29 anos estudados e, assim, obter as médias mensais destas variáveis por um período de 30 anos, os quais podem ser verificados na Tabela 1 as medidas estatísticas de posição para cada variável.

Tabela 1 – Resultados dos parâmetros estatísticos para altitude (Alt), em metros, latitude (Lat) em graus decimais, longitude (Long) em graus decimais, umidade relativa do ar (UR), em %, velocidade do vento (VV), em m.s⁻¹ e temperaturas máxima (Tmax), média (Tmed) e mínima (Tmin) do ar em °C, de 81 estações meteorológicas localizadas na região Centro-Oeste do Brasil.

Medidas	Alt	Lat	Long	UR	VV	Tmax	Tmed	Tmin
Mínimo	78,56	-23,97	-59,87	26,08	0,00	19,72	14,60	8,00
1°Quartil	300,83	-18,97	-56,14	64,19	0,93	29,57	23,29	17,26
Mediana	426,20	-15,91	-54,18	73,00	1,21	31,20	25,05	19,68
Média	497,44	-16,44	-53,32	70,59	1,34	30,97	24,68	19,10
3°Quartil	667,01	-14,02	-50,14	79,15	1,62	32,57	26,38	21,31
Máximo	1.264,70	-9,91	-46,37	93,83	4,86	39,37	33,62	29,78

Fonte: Elaborado pelo autor com dados do Instituto Nacional de Meteorologia (2021).

Dessa maneira, as estações meteorológicas (Tabela 1) apresentam uma variação altimétrica entre 78,56 e 1.264,70 m, uma oscilação latitudinal entre -23,97 a -9,91 graus Sul e, variação longitudinal entre -59,87 e -46,37 graus Oeste. Já a variabilidade entre valores mínimos e máximos relacionados ao elemento climático de UR, apresenta uma variação de 26,08 a 93,83% e para a VV entre 0,00 e 4,86 m.s⁻¹. Quanto a variabilidade das temperaturas do ar, a Tmax apresenta oscilação na faixa de 19,72 a 39,37 °C, a Tmed entre 14,60 e 33,62 °C

enquanto as estações meteorológicas utilizadas no estudo apresentam valores mínimos e máximos de 8,0 e 29,78 °C para a Tmin.

3.3 Redes Neurais Artificiais (RNAs)

Para as estimativas das temperaturas do ar, foram utilizadas as redes neurais Perceptron de Múltiplas Camadas (MLP), conforme descrito pelas Equações 1 e 2, baseado no algoritmo de treinamento backpropagation (SOARES *et al.*, 2014; LIMA *et al.*, 2019; HAYKIN, 2001).

$$u_k = \sum_{j=1}^k W_{kj}X_j \quad (1)$$

$$Y_k = \varphi(U_k + b_k) \quad (2)$$

Em que: u_k é o combinador linear; W_{kj} é o peso sináptico do neurônio k, X_j é o sinal de entrada do neurônio, y_k é o sinal de saída do neurônio; φ é a função de ativação e b_k é o bias.

Em relação ao algoritmo de treinamento backpropagation (retropropagação), pode ser representado conforme a equação 3 (LIMA *et al.*, 2019; HAYKIN, 2001):

$$e_j(n) = d_j(n) - y_i(n) \quad (3)$$

Onde: $e_j(n)$ é o sinal de erro de um neurônio de saída j ; n é o instante de tempo discreto, $d(n)$ é a resposta desejada para o neurônio j ; e $y_i(n)$ é o sinal de saída do neurônio j .

A Equação 4, exemplifica a configuração de uma Rede Neural Artificial do tipo MLP, contendo a camada de entrada, uma camada oculta e a camada de saída.

$$y_1 = S_1 \left(\sum_{j=1}^{Nj} w_j S_2 \left(\sum_{i=1}^{Ni} w_i x_i \right) \right) \quad (4)$$

Em que:

y_1 é a saída da rede; x_i é a matriz de entrada da rede; w_i são os pesos conectados entre os dados e a camada de entrada; w_j são os pesos conectados entre a camada oculta e a camada de saída; S_1 é a função de ativação da camada de entrada para a camada oculta; S_2 é a função de ativação da camada de oculta para a camada de saída.

Previamente ao treinamento das Redes Neurais Artificiais, os dados foram normalizados de modo a melhorar o aprendizado e aumentar o desempenho da máquina, conforme a Equação 5.

$$Z_i^p = \frac{x_i^p - l_i}{\sigma} \quad (5)$$

Em que:

Z_i^p é o valor transformado; l_i é a média; σ é o desvio padrão e, x_i^p é o valor atual observado.

3.4 Estrutura das Redes Neurais Artificiais (RNAs) em Deep Learning

São apresentados na Tabela 2 os parâmetros estatísticos das variáveis altitude, latitude, longitude, umidade relativa do ar e velocidade do vento que foram utilizadas para o treinamento das Redes Neurais Artificiais, com dados de 1990 a 2020.

Tabela 2 – Parâmetros estatísticos das médias das variáveis meteorológicas de estações automáticas localizadas na região Centro-Oeste do Brasil, utilizadas para o treinamento e validação das Redes Neurais Artificiais, com dados de 1990 a 2020.

Classificação das variáveis	Variáveis	Unidade de medida	Mín	Méd	Máx	Var
Variáveis de entrada	Alt: altitude	m	78,56	479,92	1.264,70	73.236,20
	Lat: latitude	graus decimais	-23,97	-16,43	-9,91	12,72
	Long: longitude	graus decimais	-59,87	-53,70	-46,37	13,76
	UR: umidade relativa do ar	%	26,08	70,89	93,83	127,83
	VV: velocidade do vento	m.s ⁻¹	0,00	1,32	4,39	0,34
Variáveis de Saída	Tmax: temperatura máxima do ar	°C	19,72	31,04	39,37	6,03
	Tmed: temperatura média do ar	°C	14,60	24,74	33,62	5,43
	Tmin: temperatura mínima do ar	°C	8,00	19,17	29,78	7,87

Fonte: Instituto Nacional de Meteorologia (2021). Mínimo (Mín); Média (Méd); Máximo (Máx); Variância (Var).

Para a seleção dos dados, foi utilizada uma amostragem em que 60% (quarenta e nove estações meteorológicas) foram utilizados para a etapa de treinamento da rede, 20% (dezesseis estações meteorológicas) para a etapa de validação e 20% para a etapa de teste (dezesseis estações meteorológicas) (SOARES *et al.*, 2014; COUTINHO *et al.*, 2018), com 2000 ciclos de treinamento. As etapas de treinamento, validação e teste das redes foram realizadas

utilizando o software R versão 4.0.3. Para evitar que ocorra o superaprendizado das redes durante a etapa de treinamento, foi utilizada uma amostragem de 32 lotes a cada ciclo.

Na Tabela 3 são apresentadas o número da estação (Figura 4), a altitude, as coordenadas geográficas e código de identificação na Organização Meteorológica Mundial (OMM), de 16 estações meteorológicas localizadas na região Centro-Oeste do Brasil e que foram utilizadas para a etapa de teste das Redes Neurais Artificiais.

Tabela 3 – Coordenadas geográficas e código de identificação na Organização Meteorológica Mundial (OMM), de 16 estações meteorológicas localizadas na região Centro-Oeste do Brasil e utilizadas para os testes das Redes Neurais Artificiais.

Num	Código OMM	Estação Meteorológica	Estado	Altitude (m)	Latitude (°Sul)	Longitude (°Oeste)
29	A008	Faculdade da Terra de Brasília	DF	1.144	-15,91	-48,12
25	A036	Cristalina	GO	1.211	-16,78	-47,61
36	A015	Itapaci	GO	551,16	-14,98	-49,54
49	A003	Morrinhos	GO	751,09	-17,75	-49,10
51	A004	Niquelândia	GO	663,53	-14,47	-48,49
64	A025	Rio Verde	GO	780,11	-17,79	-50,96
7	A719	Aquidauana	MS	151,35	-20,48	-55,78
14	A702	Campo Grande	MS	528,47	-20,45	-54,72
44	A749	Juti	MS	375,18	-22,86	-54,61
54	A710	Paranaíba	MS	408,06	-19,70	-51,18
68	A732	São Gabriel do Oeste	MS	646,00	-19,42	-54,55
3	A924	Alta Floresta	MT	291,85	-10,08	-56,18
32	A930	Gaúcha do Norte	MT	375,87	-13,18	-53,26
58	A937	Pontes e Lacerda	MT	272,53	-15,23	-59,35
66	A931	Santo Antônio do Leste	MT	664,21	-14,93	-53,88
69	A903	São José do Rio Claro	MT	339,59	-13,45	-56,68

Fonte: Instituto Nacional de Meteorologia (2021).

Os municípios foram escolhidos aleatoriamente, mas mantendo-se o critério de conter a mesma quantidade (cinco cidades) de municípios para cada Estado. Neste sentido, para o Estado de Goiás foram selecionadas as cidades de Cristalina, Itapaci, Morrinhos, Niquelândia e Rio Verde. Já para o Estado do Mato Grosso do Sul foram as estações dos municípios de Aquidauana, Campo Grande, Juti, Paranaíba e São Gabriel do Oeste. Enquanto no Estado do Mato Grosso as estações meteorológicas estão situadas em Alta Floresta, Gaúcha do Norte, Pontes e Lacerda, Santo Antônio do Leste e São José do Rio Claro. No caso do Distrito Federal, foi selecionada apenas uma estação meteorológica (Faculdade da Terra de Brasília), já que o DF está localizado no estado de Goiás além de não apresentar uma extensão territorial elevada.

Na Tabela 4 é possível verificar que os municípios utilizados na etapa de teste, as variáveis de entrada apresentam oscilação altimétrica entre 151,35 e 1.211,08 m. Em relação às

coordenadas geográficas, as estações meteorológicas estão situadas em latitudes entre -22,86 e -10,08 graus Sul e longitudes entre -56,18 e -47,61 graus Oeste Já a umidade relativa do ar apresenta valores mínimos e máximos entre 28,31 e 93,32 %, enquanto a VV entre 0,00 e 4,86 m.s⁻¹. Em relação as variáveis de saída para os locais utilizados na etapa de teste (Tabela 4), a temperatura máxima do ar Tmax apresenta oscilação entre 19,94 e 38,53 °C, a Tmed entre 15,05 e 30,45 °C e a Tmin entre 9,02 e 24,40 °C.

Tabela 4 – Parâmetros estatísticos das médias das variáveis meteorológicas de 16 estações automáticas localizadas na região Centro-Oeste do Brasil, utilizadas para o teste das Redes Neurais Artificiais, com dados de 1990 a 2020.

Classificação das variáveis	Variáveis	Unidade de medida	Mín	Méd	Máx	Var
Variáveis de entrada	Alt: altitude	m	151,35	568,72	1211,08	85842,83
	Lat: latitude	graus decimais	-22,86	-16,48	-10,08	11,85
	Long: longitude	graus decimais	-56,18	-51,75	-47,61	8,08
	UR: umidade relativa do ar	%	28,31	69,38	93,32	131,66
	VV: velocidade do vento	m.s ⁻¹	0,00	1,41	4,86	0,48
Variáveis de Saída	Tmax: temperatura máxima do ar	°C	19,94	30,72	38,53	6,02
	Tmed: temperatura média do ar	°C	15,05	24,43	30,45	5,27
	Tmin: temperatura mínima do ar	°C	9,02	18,83	24,40	7,34

Fonte: Instituto Nacional de Meteorologia (2021). Mínimo (Mín); Média (Méd); Máximo (Máx); Variância (Var).

A Tabela 5 apresenta as configurações de estruturas das camadas ocultas e a função de ativação entre camadas para três diferentes modelos (M1, M2 e M3) para as etapas de treinamento e validação das Redes Neurais Artificiais.

Tabela 5 – Estruturas das camadas ocultas e função de ativação entre camadas para três diferentes modelos (M1, M2 e M3) utilizados nas etapas de treinamento e validação das Redes Neurais Artificiais.

Modelo	Estrutura das camadas ocultas	Função de ativação das camadas ocultas
M1	16 – 7 – 3	ReLU
M2	14 – 3	ReLU
M3	17 – 3	ReLU

Fonte: Elaborado pelo Autor (2021).

Foram estudadas três diferentes estruturas de camadas ocultas nas de redes (M1, M2 e M3) (JALALL *et al.*, 2020). Conforme apresentado na Tabela 5, o Modelo 1 (M1) apresenta

03 camadas ocultas com 16 neurônios na primeira camada, 07 neurônios na segunda camada e 03 neurônios na terceira camada. O segundo modelo (M2) apresenta a configuração com 02 camadas ocultas, no qual a primeira camada contém 14 neurônios e a segunda camada 03 neurônios. O terceiro modelo (M3) contém também 02 camadas ocultas, em que primeira camada contém 17 neurônios e a segunda camada 03 neurônios.

A função de ativação utilizada entre as camadas intermediárias das RNAs, foi a função de Unidade Linear Retificada (*Rectified Linear Unit*) também denominada como ReLU. Entre a última camada oculta e a camada de saída, a função aplicada foi a linear. Também foram estudadas diferentes combinações entre variáveis explicativas, denominadas de cenários (Ci), com o objetivo de estudar as melhores combinações e a quantidade ideal de neurônios na camada de entrada para a estimativa das médias das temperaturas do ar (Tmax, Tmed e Tmin) na escala mensal, para a região Centro-Oeste do Brasil (Tabela 6). Dessa forma, foram estudados e analisados nove diferentes cenários de combinações de variáveis de entrada bem como a quantidade de neurônios na camada de entrada.

Tabela 6 – Combinações de variáveis explicativas considerando diferentes cenários (C1 a C9) de entrada para as Redes Neurais Artificiais, nas estimativas das temperaturas do ar Tmax, Tmed e Tmin, na escala mensal, para a região Centro-Oeste do Brasil.

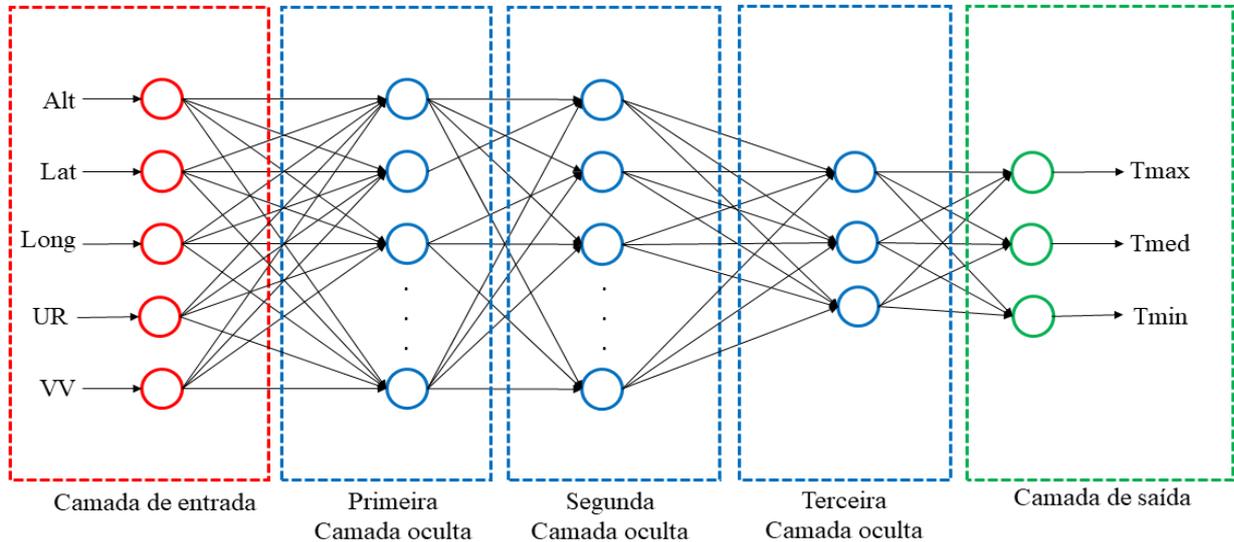
Variáveis de entrada	C1	C2	C3	C4	C5	C6	C7	C8	C9
Alt	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde	Verde
Lat	Verde	Verde	Verde	Verde	Vermelho	Verde	Vermelho	Vermelho	Vermelho
Long	Verde	Verde	Verde	Verde	Verde	Vermelho	Verde	Vermelho	Vermelho
UR	Verde	Verde	Vermelho	Vermelho	Vermelho	Vermelho	Vermelho	Verde	Vermelho
VV	Verde	Vermelho	Vermelho	Verde	Verde	Vermelho	Vermelho	Vermelho	Verde

Fonte: Elaborado pelo Autor (2021).

Os cenários que apresentam a cor verde para as variáveis independentes (Tabela 6), indicam que elas foram consideradas como sinais de entrada na etapa de treinamento, validação e teste das RNAs. As variáveis marcadas com a coloração vermelha indicam que elas não foram consideradas naqueles cenários das RNAs. Neste contexto por exemplo, o cenário C1 apresenta todas as variáveis independentes como entradas para a rede (Alt, Lat, Long, UR e VV) e no caso do cenário C2, consta todas as variáveis, exceto a velocidade do vento (VV). É possível verificar na Figura 5 a topologia da rede no cenário C1 apresentando todas as variáveis de entrada, utilizando a configuração de camadas ocultas M1, com três camadas intermediária,

paras as estimativas da Tmax, Tmed e Tmin, na escala mensal para a região Centro-Oeste do Brasil.

Figura 5 – Exemplo de da arquitetura da Rede Neural Artificial para o modelo M1 no cenário C1, contendo todas as variáveis de entrada (Alt, Lat, Long, UR e VV), com três camadas ocultas e, a camada de saída com as variáveis respostas (Tmax, Tmed e Tmin) para a região Centro-oeste do Brasil, na escala mensal.



Fonte: Elaborado pelo Autor (2021).

Dessa maneira, foram estudadas quais as melhores combinações de cenários (C1 a C9) de variáveis de entrada, bem como a configuração de quantidade de camadas ocultas e quantidade no número de neurônios em cada camada intermediária (M1, M2 e M3). A finalidade foi a de avaliar nestas circunstâncias, os menores índices estatísticos de erro e os maiores índices de acurácia, para três saídas: as temperaturas do ar (mínima, média e máxima) na escala mensal, para os locais situados nos estados da região Centro-Oeste do Brasil.

3.5 Validação das Redes Neurais Artificiais (RNAs)

Os resultados das RNAs foram desnormalizados para se obter os índices estatísticos dos modelos. A finalidade da validação das redes propostas foi a de analisar o ajuste dos valores estimados pelas RNA's em relação aos valores observados nas estações meteorológicas.

Para tal, foram calculados os índices estatísticos da Raiz Quadrática de Erro Médio (RQEM), do Erro Médio Absoluto (EMA), Erro Quadrático Médio (EQM), o índice de concordância ou exatidão "d", o coeficiente de correlação de Pearson (r) e o índice de performance "IP". Estes índices serão obtidos para as parcelas (20%) que não foram utilizadas na etapa de treino e em todos os meses do ano, para as temperaturas do ar mínima, média e máxima. Todos os índices estatísticos foram calculados conforme as Equações (6 a 11) no programa MSOffice Excel.

$$RQEM = \sqrt{\frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)^2}{n}} \quad (6)$$

$$EMA = \frac{1}{n} \sum_{i=1}^n |\hat{Y}_i - Y_i| \quad (7)$$

$$EQM = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (8)$$

$$d = \begin{cases} 1 - \frac{\sum |\hat{Y}_i - Y_i|}{\sum |Y_i - \bar{Y}|}, & \text{quando } \sum |\hat{Y}_i - Y_i| \leq c \sum |Y_i - \bar{Y}| \\ \frac{c \sum |\hat{Y}_i - \bar{Y}|}{\sum |\hat{Y}_i - Y_i|} - 1, & \text{quando } \sum |\hat{Y}_i - Y_i| > c \sum |Y_i - \bar{Y}| \end{cases} \quad (9)$$

$$r = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{\hat{Y}})(Y_i - \bar{Y})}{\sqrt{\frac{\sum_{i=1}^n (\hat{Y}_i - \bar{\hat{Y}})^2}{n}} * \sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n}}} \quad (10)$$

$$IP = d.r \quad (11)$$

Em que: Y_i = temperatura do ar observada, em °C; \hat{Y}_i = temperatura do ar estimada, em °C; \bar{Y} = média da temperatura do ar observada, em °C; n = é o número de dados utilizados; RQEM = Raíz Quadrática do Erro Médio, em °C; EMA = Erro Médio Absoluto, em %; EQM = Erro Quadrático Médio; d = índice de concordância ou exatidão de Willmott *et al.* (2012); R^2 = Coeficiente de determinação; r = Coeficiente de correlação linear de Pearson; IP = Índice de Performance, com $c = 2$.

As classificações dos critérios para os índices de Performance (Equação 8), são apresentados na Tabela 7.

Tabela 7 – Intervalo de valores do índice de performance (IP) e suas respectivas classificações.

Índice de performance (IP)	Classificação
>0,75	Ótimo
0,60 – 0,75	Muito bom
0,45 – 0,60	Bom
0,30 – 0,45	Tolerável
0,15 – 0,30	Pobre
0 – 0,15	Ruim
< 0	Muito Ruim

Fonte: Alvares *et al.* (2013).

3.6 Interpretação dos índices estatísticos

Os índices estatísticos utilizados auxiliam na explicação da qualidade das estimativas em cada cenário, mês, temperatura do ar e modelo testado. Os índices dizem respeito a variação, precisão, acurácia e performance. Dessa maneira, o índice erro médio absoluto (EMA) e raiz quadrática do erro médio (RQEM) indicam o quão próximos os valores observados estão dos estimados, mensurando a acurácia dos modelos (CELESTE e CHAVES, 2014; SANTOS *et al.*, 2017).

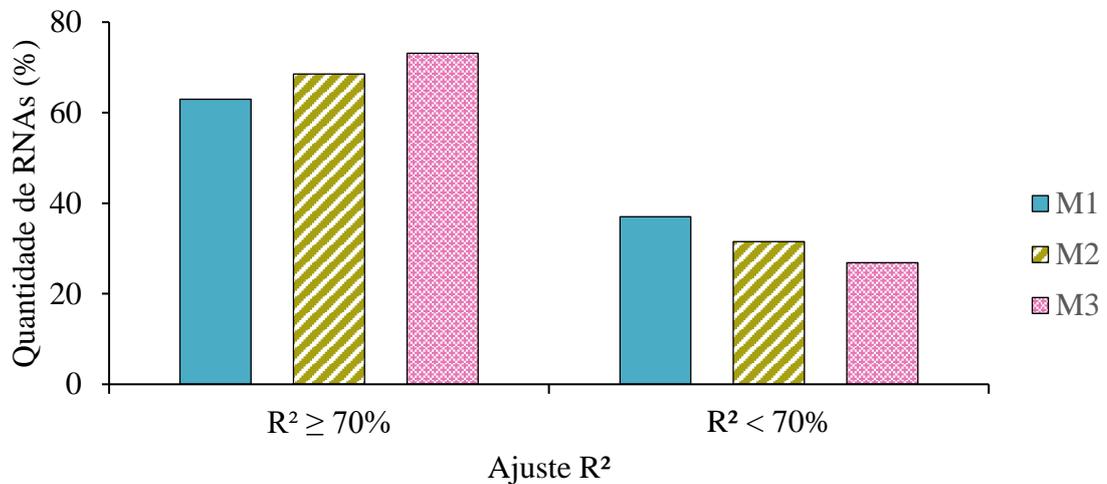
Já a percentagem da variação nas estimativas entre a variável resposta e explicada pelas variáveis independentes, pode ser analisado pelo coeficiente de determinação (R^2) no qual os melhores modelos devem produzir R^2 próximos a 100. A precisão dos modelos indica o grau de dispersão dos dados obtidos em termos da média, explicados pelo coeficiente de correlação de Pearson (r). Este índice oscila na faixa de -1 a +1 (ou -100 a +100), indicando o sentido e o grau da correlação entre valores reais e simulados. A acurácia também pode ser quantificada pelo índice de desempenho ou concordância de Willmott (d) e pelo índice de Performance (IP), de forma em que valores mais próximos a 1 indicam ótimos desempenhos e performances (CELESTE e CHAVES, 2014; SANTOS *et al.*, 2017).

4 RESULTADOS E DISCUSSÃO

4.1 Análise de pertinência das variáveis de entrada

São apresentados os resultados da quantidade de redes neurais artificiais que apresentaram valores de coeficiente de determinação superiores e inferiores a 70%, em cada modelo analisado (M1, M2 e M3) para as estimativas das temperaturas máximas (Figura 5), médias (Figura 7) e mínimas do ar (Figura 8) na escala mensal, para a região Centro-Oeste do Brasil, com dados de 16 estações meteorológicas, para o período analisado de 1990 a 2020.

Figura 5 – Quantidade de redes neurais artificiais (RNAs, em %) que obtiveram valores de coeficiente de determinação (R^2) superiores e inferiores a 70%, em cada modelo analisado (M1, M2 e M3) para as estimativas da temperatura máxima do ar (T_{max}), na escala mensal para a região Centro-Oeste do Brasil, com dados de 16 estações meteorológicas, para o período analisado de 1990 a 2020.



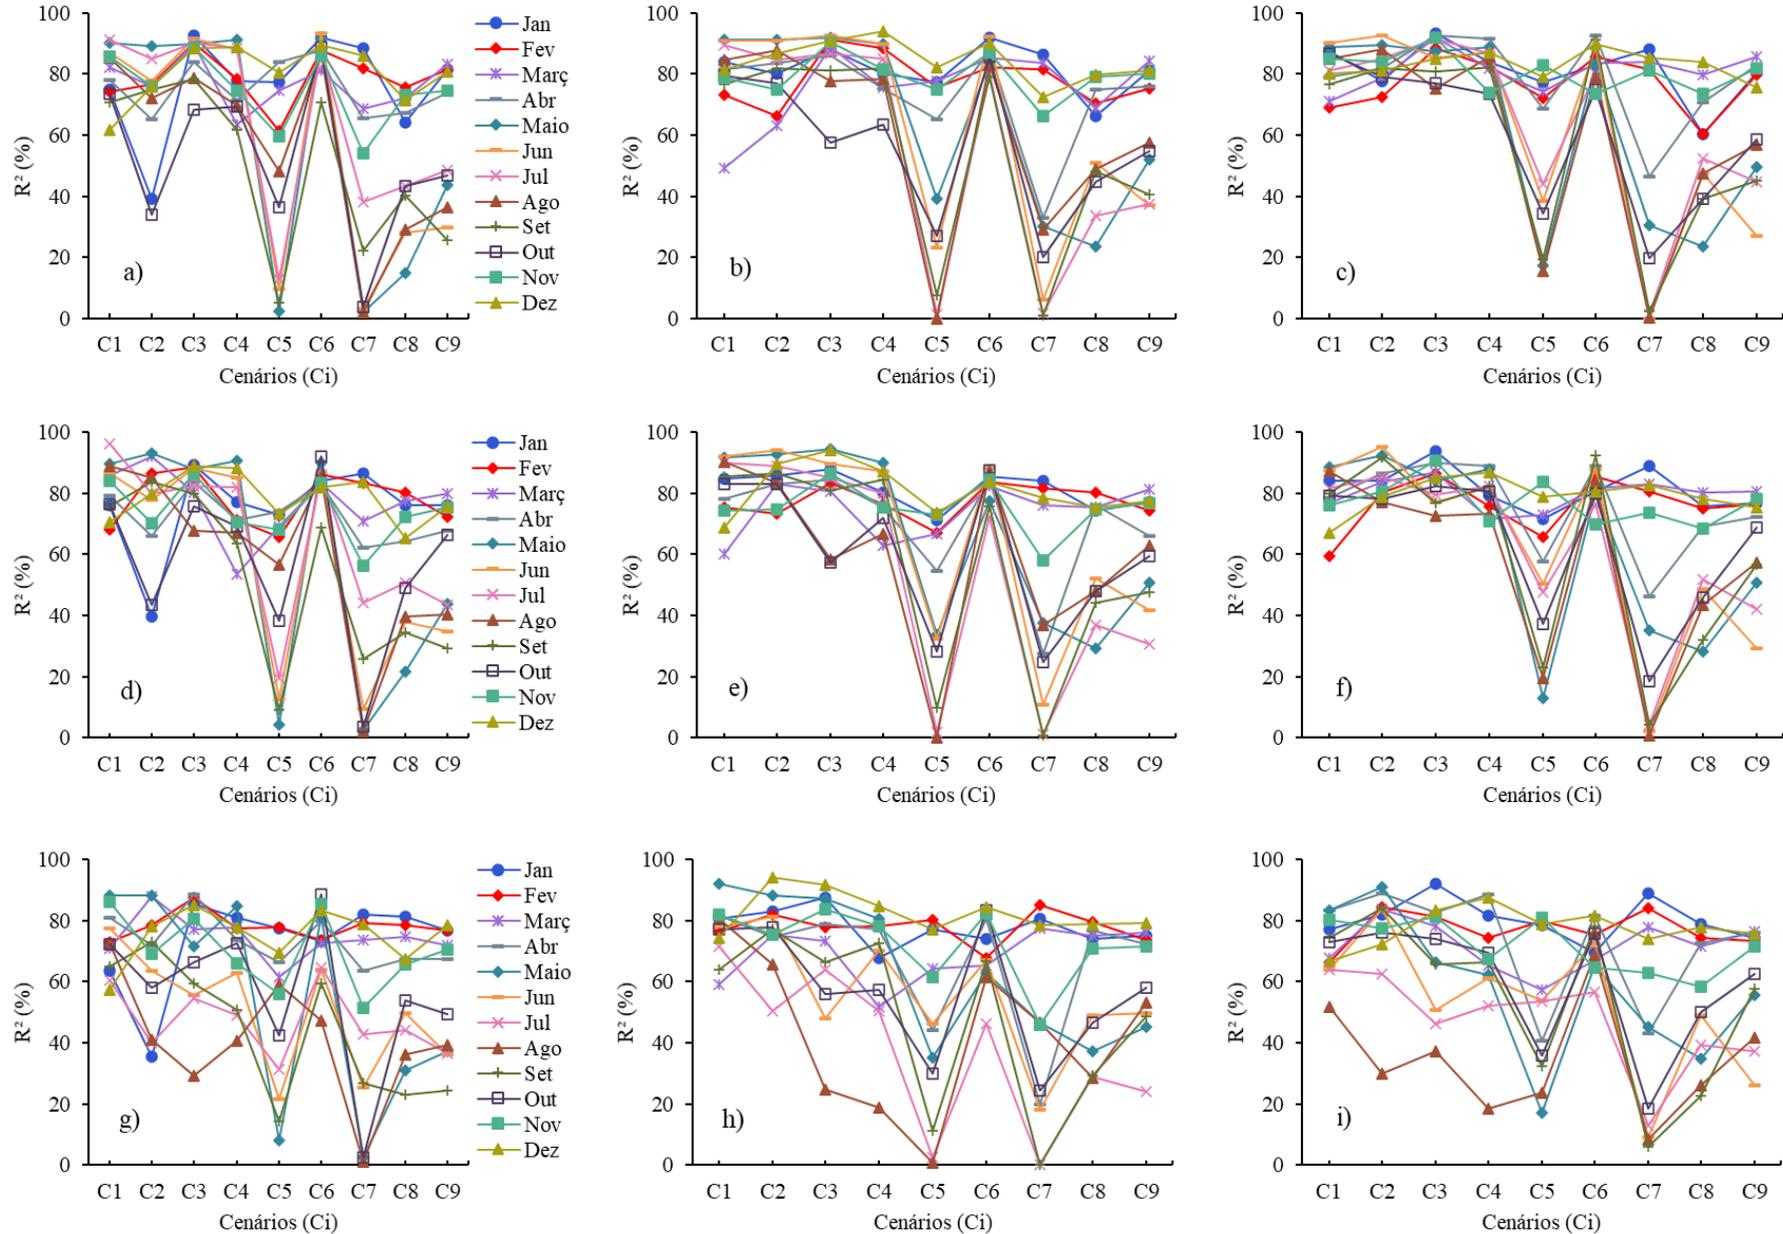
Fonte: Elaborado pelo Autor (2021).

De maneira geral (Figura 5), os maiores valores de R^2 foram obtidos para o modelo M3, no qual 73% das redes (79 redes) obtiveram valores superiores a 70%, seguido da configuração M2 que resultou em 69% (74 redes) e da configuração M1 com 63% (68 redes). Os valores absolutos de R^2 nas estimativas da T_{max} oscilaram de 0,05 (M2 e M3) a 94% observado ao utilizar a configuração M3 (Figura 6).

A Figura 6 apresenta os resultados de coeficiente de determinação (R^2), para as temperaturas do ar, na escala mensal: máxima (T_{max}) no modelo M1 (Figura 6.a), M2 (Figura 6.b) e M3 (Figura 6.c); média (T_{med}) no modelo M1 (Figura 6.d), M2 (Figura 6.e) e M3 (Figura 6.f) e, mínima (T_{min}) no modelo M1 (Figura 6.g), M2 (Figura 6.h) e M3 (Figura 6.i).

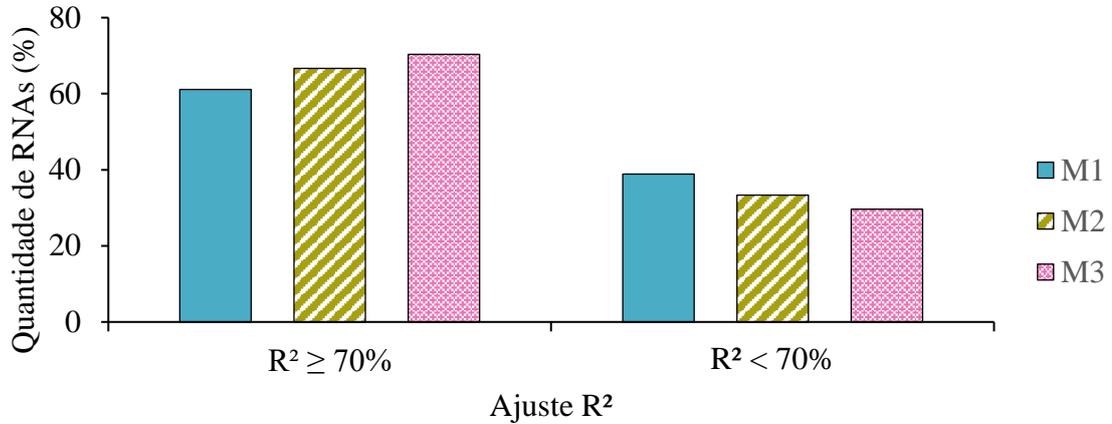
Os modelos M2 (Figura 6.e) e M3 (Figura 6.f) foram os que apresentaram maior estabilidade (T_{med}) para os cenários C1, C2, C3, C4 e C6. Os cenários que apresentaram maior variabilidade de R^2 , foram os cenários C5, C7 e em alguns meses (maio a outubro) dos cenários C8 e C9. Isso foi obtido para o modelo M1 (Figura 6.d), com exceção do cenário C2 que apresentou menores R^2 em dois meses (maio e outubro).

Figura 6 – Coeficiente de determinação (R^2) em %, para as temperaturas do ar máxima na arquitetura da rede M1 (a), M2 (b) e M3 (c); temperatura média M1 (d), M2 (e) e M3 (f) e, temperatura mínima M1 (g), M2 (h) e M3 (i), na escala mensal para a região Centro-Oeste do Brasil, com dados de 16 estações meteorológicas, para o período analisado de 1990 a 2020.



Fonte: Elaborado pelo Autor (2021).

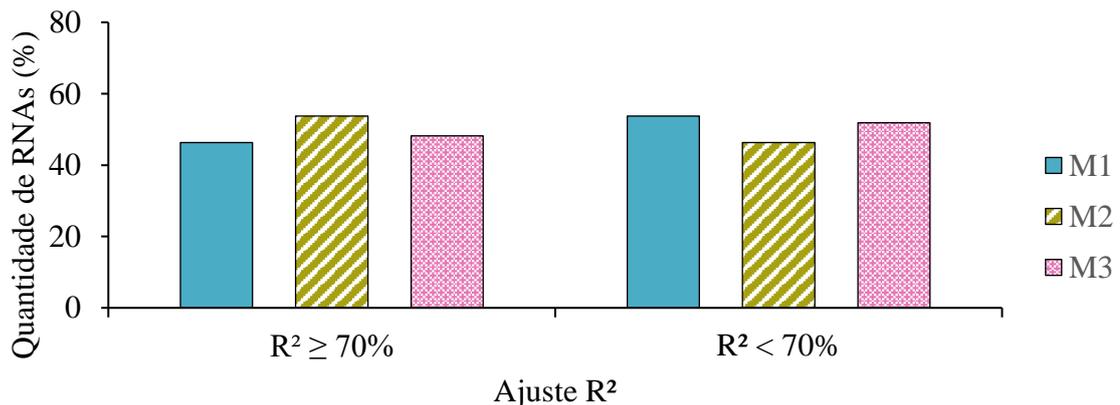
Figura 7 – Quantidade de redes neurais artificiais (RNAs, em %) que obtiveram valores de coeficiente de determinação (R^2) superiores e inferiores a 70%, em cada modelo analisado (M1, M2 e M3) para as estimativas da temperatura média do ar (T_{med}), na escala mensal para a região Centro-Oeste do Brasil, com dados de 16 estações meteorológicas, para o período analisado de 1990 a 2020.



Fonte: Elaborado pelo Autor (2021).

A configuração de camadas observadas nas camadas ocultas do modelo M3 (Figura 7) foi a que obteve uma maior quantidade proporcional de redes, no qual 76 RNAs (70%) apresentaram valores de R^2 superiores a 70%. Já a segunda maior quantidade, foi obtido ao utilizar o modelo M2 com 67% (72 redes), seguido do modelo M1 com 66 redes (67% do total) com R^2 superior a 70%.

Figura 8 – Quantidade de redes neurais artificiais (RNAs, em %) que obtiveram valores de coeficiente de determinação (R^2) superiores e inferiores a 70%, em cada modelo analisado (M1, M2 e M3) para as estimativas da temperatura mínima do ar (T_{min}), na escala mensal para a região Centro-Oeste do Brasil, com dados de 16 estações meteorológicas, para o período analisado de 1990 a 2020.



Fonte: Elaborado pelo Autor (2021).

Quando comparado as temperaturas do ar T_{max} e T_{med} , as estimativas da T_{min} (Figura 6.g, Figura 6.h e Figura 6.i) apresentaram valores simulados pelas RNAs com uma variação mais acentuada em todos os modelos, cenários e meses. Além do mais, a quantidade de RNAs que obteve $R^2 \geq 70\%$, foi menor quando comparado aos resultados obtidos para T_{max} e T_{med} , respectivamente (Figura 8).

Dessa maneira, a partir da Figura 8 o modelo M2 resultou ($R^2 \geq 70\%$) em 58 redes (equivalente a 54% do total), seguido do modelo M3 com 52 redes (48% do total) e por fim, o modelo M1 obteve 50 redes (46% do total), com resultados de $R^2 \geq 70\%$. Portanto, proporcionalmente, apenas o modelo M2 apresentou mais da metade de redes com precisão satisfatória.

Ao utilizar a regressão linear simples, os valores de R^2 obtidos por Silva Júnior *et al.* (2020) variaram entre 16% (em janeiro) e aproximadamente 55% (em maio), no qual o maior valor foi de 61% para as estimativas da temperatura máxima na escala anual para Recife-PE. No caso da temperatura média do ar, os autores obtiveram menor R^2 para o mês de junho ($R^2 = 26\%$) e o maior R^2 foi observado no mês de novembro com $R^2 = 59,1$. Comparado as temperaturas máximas e médias, foram obtidos menores valores para a temperatura mínima, os quais variaram de 2,3% (junho) a aproximadamente 46% (novembro).

Estudando a eficiência de diferentes métodos nas estimativas das temperaturas do ar máxima e mínima, Yaguchi *et al.* (2016) obtiveram que os melhores resultados para ambas as temperaturas foram obtidos ao utilizar o método de Steurer Modificado (SRMOD) com R^2 de 0,92 para a Tmax e 0,93 para a Tmin, seguido do método de regressão linear múltipla (RLM) com R^2 de 0,92 para Tmax e Tmin, nas estimativas para o estado de Santa Catarina. Neste contexto, Fernandes *et al.* (2018) utilizou modelo digital de elevação com o método interpolativo espacial de krigagem na predição da temperatura máxima do ar no município de Piranhas, Alagoas. Os autores obtiveram resultados satisfatórios de R^2 que variaram entre 89% (dezembro) a 95% (março e abril) e concluíram que a combinação de MDE e o método interpolativo apresentou resultados satisfatórios na estimativa da Tmax.

Já Alonso e Renard (2019) combinou informações obtidas por satélites e modelos de regressão linear múltipla (RLM) para as estimativas da temperatura média do ar, em diferentes usos de terra. As faixas de valores mínimos e máximos toda a área de estudo de R^2 66 a 92%). Em áreas modificadas artificialmente com R^2 entre 68 e 83%, enquanto que áreas utilizadas para produção agrícola os o R^2 variaram de 63 a 87%. Já para ambientes considerados como seminaturais, os valores de R^2 oscilaram entre 81 e 99%. Os autores concluíram que a combinação de índices espectrais e RLM proporcionaram aumento na qualidade das predições.

Os resultados obtidos para as estimativas da temperatura mínima do ar obtidos por Bardin *et al.* (2010) apresentaram R^2 variando entre 85% (junho e julho) e 97% (janeiro, fevereiro, outubro, novembro e dezembro) com três variáveis de entrada (Alt, Lat e Long). Ao retirar a variável Long, os modelos obtiveram resultados de R^2 variando entre 69% (junho) e 94% (dezembro). Correa *et al.* (2017) explicam que a dinâmica atmosférica e a associação de fatores, a exemplo do relevo e sistemas frontais de massa polar atlântica, proporcionam

reduções acentuadas na temperatura do ar, ocasionando uma maior variabilidade desse elemento climático. Este fenômeno é perceptível em épocas do ano em que tanto a presença de nuvens quanto a umidade relativa do ar do ar é baixa. Dessa maneira, a inversão térmica ocorre de forma mais acentuada, especialmente durante a noite, resultando em uma redução brusca na temperatura, principalmente nas estações de inverno, outono e primavera (SILVEIRA *et al.*, 2019).

Alsina *et al.* (2016) estudaram 13 variáveis de entrada, com nove possibilidades de combinações, no qual obtiveram que a melhor combinação foi a de sete variáveis de entrada. Os autores ainda verificaram que os extremos em termos de quantidade de variáveis de entrada com 13 e com 1 variável, não obtiveram resultados satisfatórios. Yadav *et al.* (2014) analisaram redes neurais artificiais com sete, cinco e quatro variáveis de entrada para estimar a radiação solar em diferentes cidades da Índia. A rede com 5 variáveis de entrada resultou em um acréscimo de 13,23% na precisão quando comparada as redes que continham 7 e 4 neurônios na camada de entrada. De maneira contrária aos estudos citados, Jallal *et al.* (2020) verificaram que ao reduzir o número de variáveis de entrada também foi reduzida a performance dos modelos analisados. Resultados satisfatórios foram obtidos ao utilizar todas as 5 variáveis independentes estudadas.

Os baixos valores de R^2 nestes cenários (C7 e C5) ajudam a explicar que a combinação adequada das variáveis de entrada pode ser mais relevante do que a quantidade em si. Isso porque, por exemplo, o cenário C6 com duas variáveis de entrada (Alt e Lat) obtiveram maiores coeficientes de determinação quando comparado ao cenário C5, com três variáveis de entrada (Alt, Long e VV). Além do mais, os melhores resultados inerentes ao cenário C6 foram obtidos na maioria dos meses e modelos para as estimativas das temperaturas Tmax e Tmed, enquanto apenas no modelo M3 para a Tmin, esta combinação de variáveis (Alt e Lat), obteve menores oscilações de R^2 .

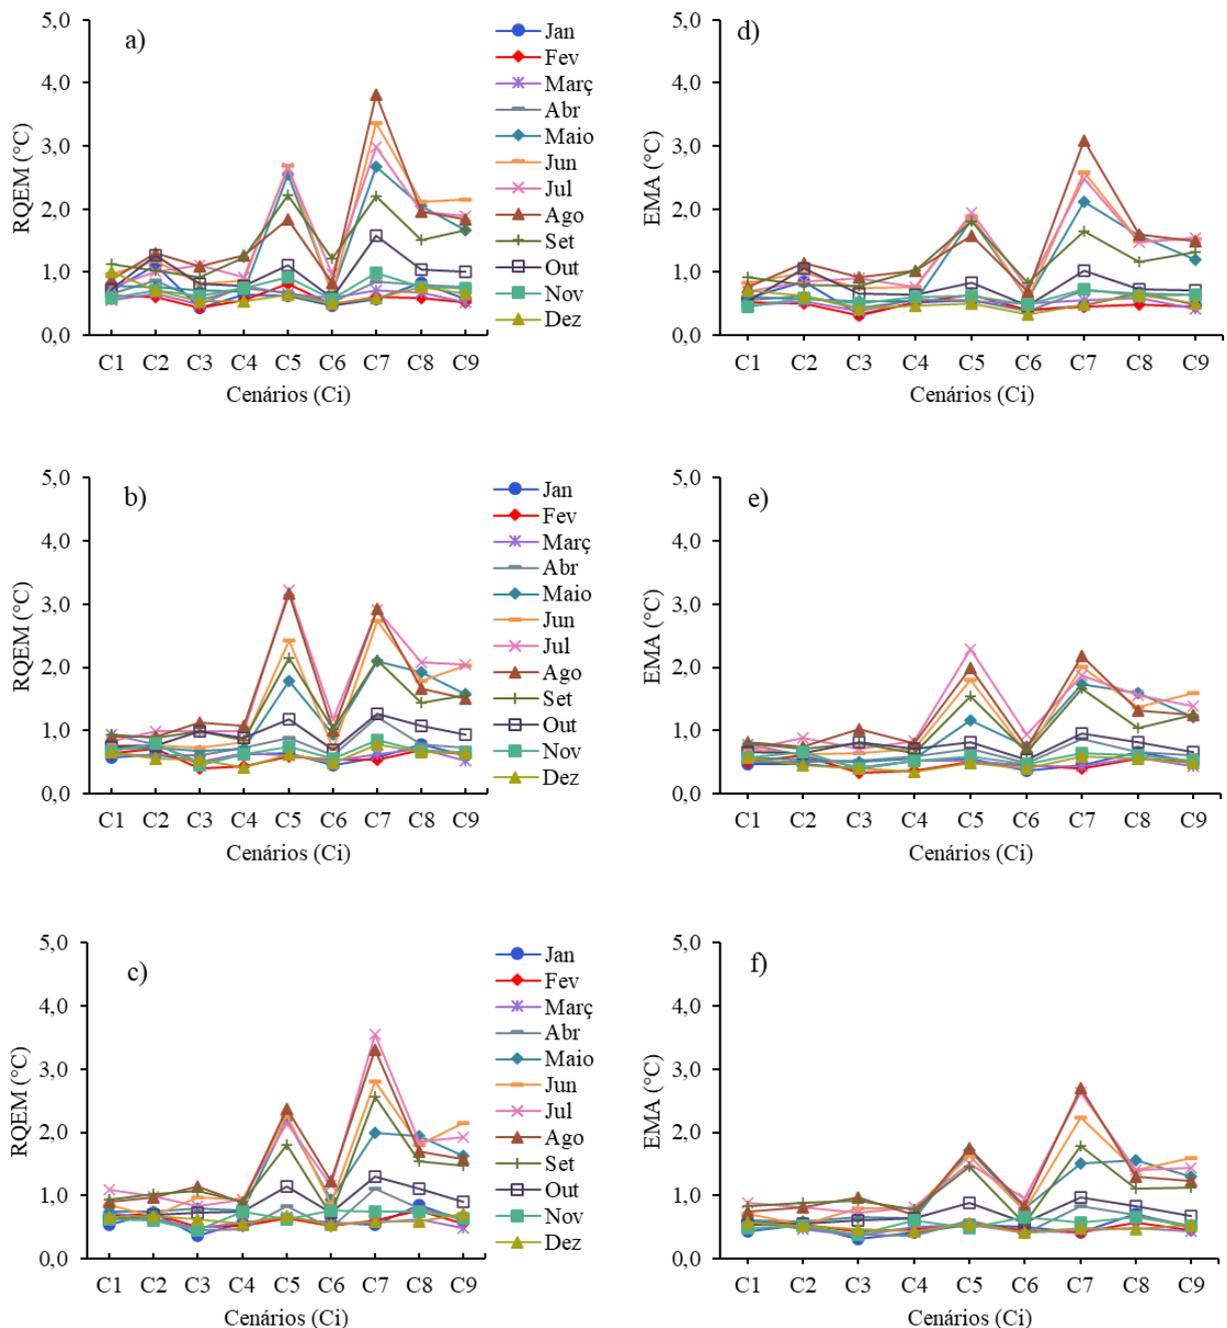
Os resultados obtidos neste estudo indicaram que as RNAs de forma geral, não foram capazes de convergir durante a etapa de treinamento em alguns meses dos cenários C5, C7, C8 e C9. Desse modo, ao realizar os testes para as estimativas da Tmax, Tmed e Tmin, as RNAs não obtiveram resultados satisfatórios para os cenários citados. Sobre o treinamento das RNAs, May *et al.* (2011) explicam que o aprendizado nesta etapa se torna mais complexo quando as variáveis de entrada ou a combinação entre elas é redundante ou inconclusiva. Dessa forma, é importante tentar minimizar a redundância dessas variáveis para tornar o treinamento mais eficiente, aumentar a performance das redes na etapa de teste, e possibilitar uma interpretação mais simplificada dos resultados (MAY *et al.*, 2011; LIMA, 2021; RANZAN, 2021).

4.2 Estrutura de camadas intermediárias

4.2.1 Estrutura de camadas intermediárias para a temperatura máxima do ar

A Figura 9 apresenta os índices estatísticos de Raiz Quadrática de Erro Médio (RQEM) e Erro Médio Absoluto (EMA), ambos em °C, para as estimativas da temperatura máxima do ar, na escala mensal, em diferentes cenários e modelos para o Centro-Oeste do Brasil., com dados de 1990 a 2020.

Figura 9 – Raiz Quadrática de Erro Médio (RQEM, em °C) e Erro Médio Absoluto (EMA, em °C) para as estimativas da temperatura máxima do ar, na escala mensal, em diferentes cenários (C1-C9) e modelos (M1-M3) para o Centro-Oeste do Brasil., com dados de 1990 a 2020.



Fonte: Elaborado pelo Autor (2021).

Os valores obtidos ao utilizar o modelo M1(Figura 9.a) para estimar a média mensal da Tmax, para a região Centro-Oeste do Brasil, apresentaram índices estatísticos de RQEM oscilando entre 0,43°C (C3 em janeiro) a 3,81°C (C7 em agosto). Em relação aos modelos M2 (Figura 9.b) e M3 (Figura 9.c), o menor índice de RQEM foi de 0,39°C e 0,37°C, respectivamente. Entretanto, o modelo M2 obteve o valor máximo de 3,17°C enquanto o modelo M3 obteve um índice máximo de RQEM de 2,40°C.

Em média (Apêndice B), para a Tmax o modelo M1 obteve 0,84°C, o modelo M2 e M3 obtiveram médias de 0,78°C e 0,79°C, respectivamente do índice de erro EMA entre valores observados e estimados da Tmax. De maneira geral para as estimativas das temperaturas máximas do ar (Tmax), no qual os cenários C7 e C5 foram os que apresentaram os maiores valores de EMA em todos os modelos analisados, conforme as Figuras 9(d – e). Resultados satisfatórios de RQEM e EMA foram obtidos nos melhores cenários C1, C2, C3, C4 e C6, pois houve pouca variabilidade dos erros e (Figura 9.d, Figura 9.e e Figura 9.f) entre a maior parcela dos meses (RQEM e EMA $\leq 1^\circ\text{C}$).

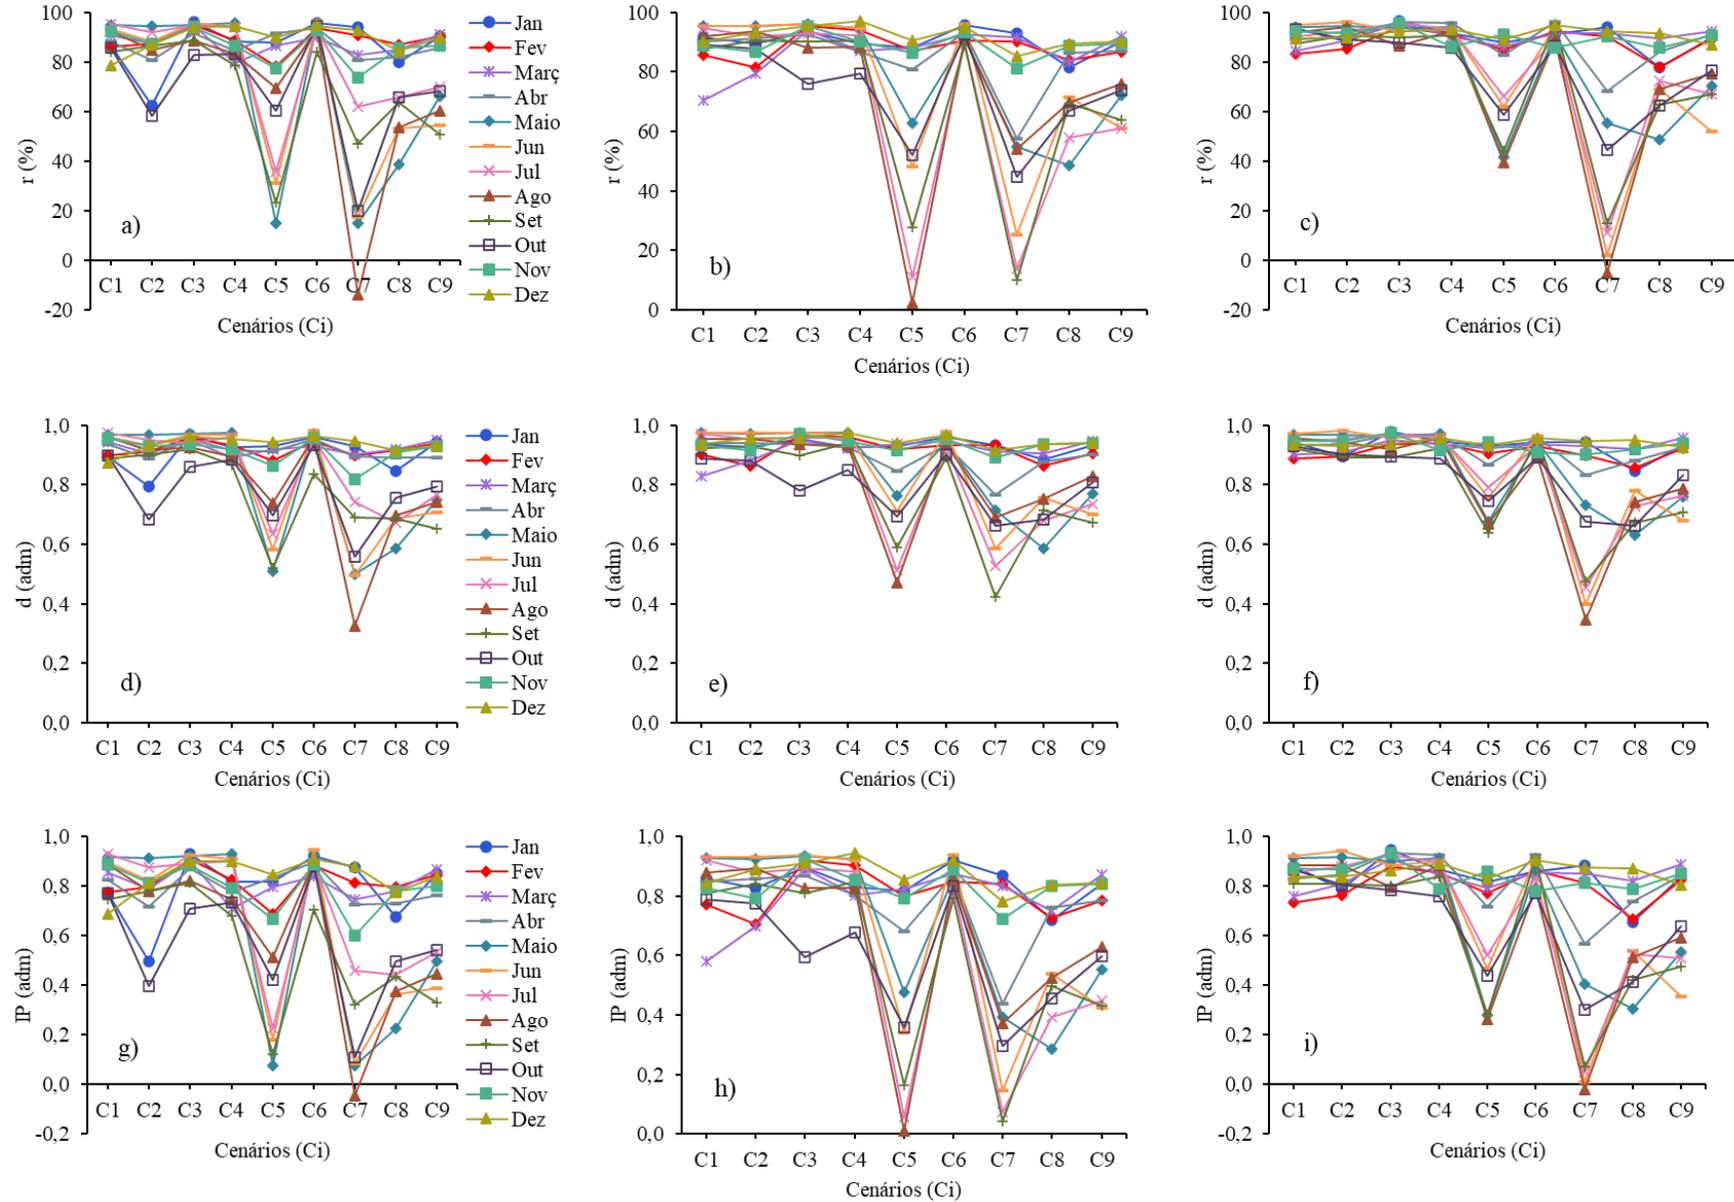
Valores superiores de RQEM e EMA foram verificados em diferentes abordagens e locais do Globo Terrestre (TRAN *et al.*, 2020; ZHU *et al.*, 2013; SHEN *et al.*, 2020). Ao utilizar abordagens de aprendizado de máquina como *Artificial Neural Network* (ANN), *Recurrent Neural Network* (RNN) e *Long Short-Term Memory* (LSTM), na estimativa da temperatura máxima do ar para a cidade de Cheongju, Coreia do Sul, Tran *et al.* (2020) obteve os maiores valores de RQEM para todas as abordagens, na estação de primavera (3,59 a 3,64 °C.). Já a menor variação foi na estação do verão.

Nas estimativas da temperatura máxima do ar na bacia do rio Xiangride, parte Norte do planalto tibetano, Zhu *et al.* (2013) verificaram que aplicar modelo sinusoidal e informações do satélite MODIS (Terra e Aqua) apresentaram índices de RQEM de 7,45°C e EMA de 6,21°C para o produto MODIS Terra. Entretanto, para o produto MODIS Aqua estes índices foram superiores, sendo eles de 9,45°C para RQEM e 8,12°C para EMA.

Shen *et al.* (2020) analisou diferentes abordagens na estimativa da temperatura máxima do ar combinando informações de sensoriamento remoto, dados de estações meteorológicas e dados socioeconômicos, estudando diferentes abordagens, obteve que a Deep Belief Network (DBN) resultou em RQEM de 1,99°C e EMA de 1,54°C.

Na Figura 10 são apresentados os índices de coeficiente de correlação (r); índice de performance 'IP' e índice de desempenho 'd', para os diferentes cenários e modelos (M1, M2 e M3) na escala mensal para as estimativas da Tmax na região Centro-Oeste do Brasil.

Figura 10 – Coeficiente de correlação (r) dos modelos de rede M1 (a), M2 (b) e M3 (c); índice de desempenho ‘d’ M1 (d), M2 (e) e M3 (f) e, índice de performance ‘IP’ M1 (g), M2 (h) e M3 (i), na escala mensal para as estimativas da Tmax na região Centro-Oeste do Brasil, com dados de 16 estações meteorológicas, para o período analisado de 1990 a 2020.



Fonte: Elaborado pelo Autor (2021).

Os valores obtidos ao utilizar o modelo M1 para estimar a média mensal da Tmax, para a região Centro-Oeste do Brasil, foram obtidos coeficiente de correlação de Pearson entre 96,95% (C6 em junho) a -13,88% (C7 em agosto). O valor máximo obtido de 'r' foi notado ao utilizar o modelo M2 (98,11%) e o menor valor em aproximadamente de -15,36%. O modelo M3 apresentou valor máximo de correlação entre valores observados e estimados de 94,19% e valor mínimo de -11,24%.

Estes resultados de correlação negativa entre valores observados e simulados indicam uma correlação inversa. Isso significa que a medida em que os valores medidos pelas estações meteorológicas tendem a aumentar, os valores estimados pelas RNAs tendem a para a direção oposta, dessa maneira, a reduzir. Entretanto e de maneira generalizada, os cenários C1, C2, C3, C4, C6 e nos meses iniciais e finais do ano (janeiro, fevereiro, março, abril, novembro e dezembro) dos cenários C5, C7, C8 e C9 todos os modelos apresentaram ótimos ajustes ($r \cong 100\%$).

Cargnelutti Filho *et al.* (2008) utilizando a regressão múltipla na estimativa da temperatura máxima do ar para o estado do Rio Grande do Sul, apresentou coeficientes de correlação que variaram entre 86% (1º decêndio de março) a 97% (3º decêndio de novembro; 1º e 3º decêndio de dezembro) indicando correlações adequadas para estimativa da Tmax.

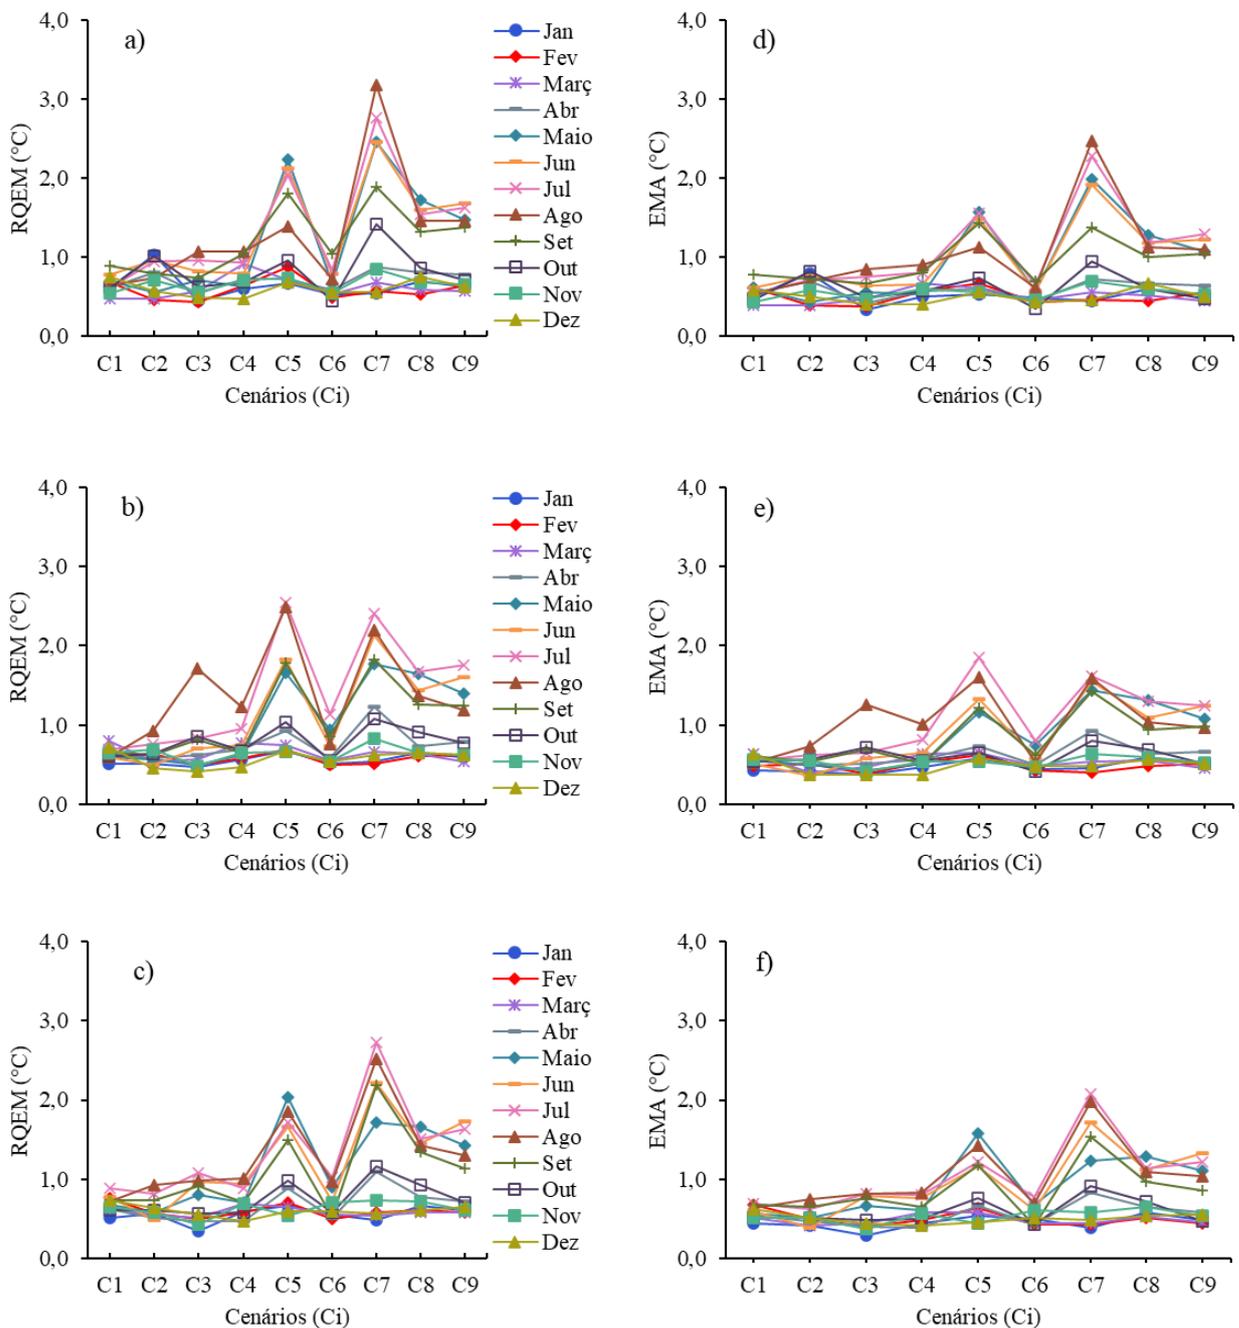
Já Afzali *et al.* (2012) obteve 'r' de 0,96 ao utilizar redes neurais forward e recorrentes, na escala diária. Entretanto, menores valores foram obtidos para a escala mensal para essas duas abordagens de aproximadamente 0,80 para a estimativa da temperatura máxima do ar, na escala diária e mensal, para a cidade de Kerman, Irã. Na estimativa da temperatura máxima do ar por meio de informações do satélite MODIS, Zhu *et al.* (2013) obteve para o produto Terra coeficiente de correlação de 0,83 e para o produto MODIS Aqua o coeficiente de correlação foi de 0,82.

Em relação ao índice 'd', ele apresentou menor valor na configuração M1 (0,33) e valores máximos de 0,98 para as três configurações utilizadas (M1, M2 e M3), indicando ótimos desempenhos ($d \cong 1$). Para o índice de performance, e independentemente das configurações, a maioria das redes obtiveram classificações consideradas como ótimas ($IP \geq 0,75$). Dessa maneira, a maior quantidade de RNAs (Apêndice C) com esta classificação foi obtida no modelo M1, com 72% (78 redes). A penas 1% (uma rede) com classificação muito ruim ($IP < 0$) para M3. Ao utilizar a configuração M2, 69% das redes (74) apresentaram ótimas estimativas da Tmax e nenhuma rede obteve classificação considera como muito ruim. Já o modelo M1, foi o que na terceira maior quantidade de redes 61% (66 redes) que obteve classificação considerada como ótima e, assim como o modelo M2, apenas uma rede com classificação muito ruim.

4.2.2 Estrutura de camadas intermediárias para a temperatura média do ar

A Figura 11 apresenta para os três modelos (M1, M2 e M3), em diferentes cenários de combinações de variáveis explicativas (Ci) os índices estatísticos de Raiz Quadrática de Erro Médio (RQEM, em °C) e Erro Médio Absoluto (EMA, em °C), na escala mensal para as estimativas da temperatura média do ar para o Centro-Oeste do Brasil., com dados de 1990 a 2020.

Figura 11 – Raiz Quadrática de Erro Médio (RQEM, em °C) e Erro Médio Absoluto (EMA, em °C) para as estimativas da temperatura média do ar, na escala mensal, em diferentes cenários (C1-C9) e modelos (M1-M3) para o Centro-Oeste do Brasil., com dados de 1990 a 2020.



Fonte: Elaborado pelo Autor (2021).

Resultados satisfatórios e semelhantes aos obtidos para a T_{max} , foram observados nas estimativas da T_{med} , pois apresentaram pouca variação para RQEM e EMA, nos três modelos analisados e nos cenários C1, C2, C3, C4 e C6. Estes resultados podem ser verificados na Figuras: 11(a – c) para o índice de RQEM e nas Figuras 11(d – f) para o índice de EMA. Os valores destes índices e nestas avaliações foram inferiores a 1°C (exceto no mês de agosto, no C3 para o M2), indicando baixos índices de erro e a eficiência dos modelos na estimativa da T_{med} .

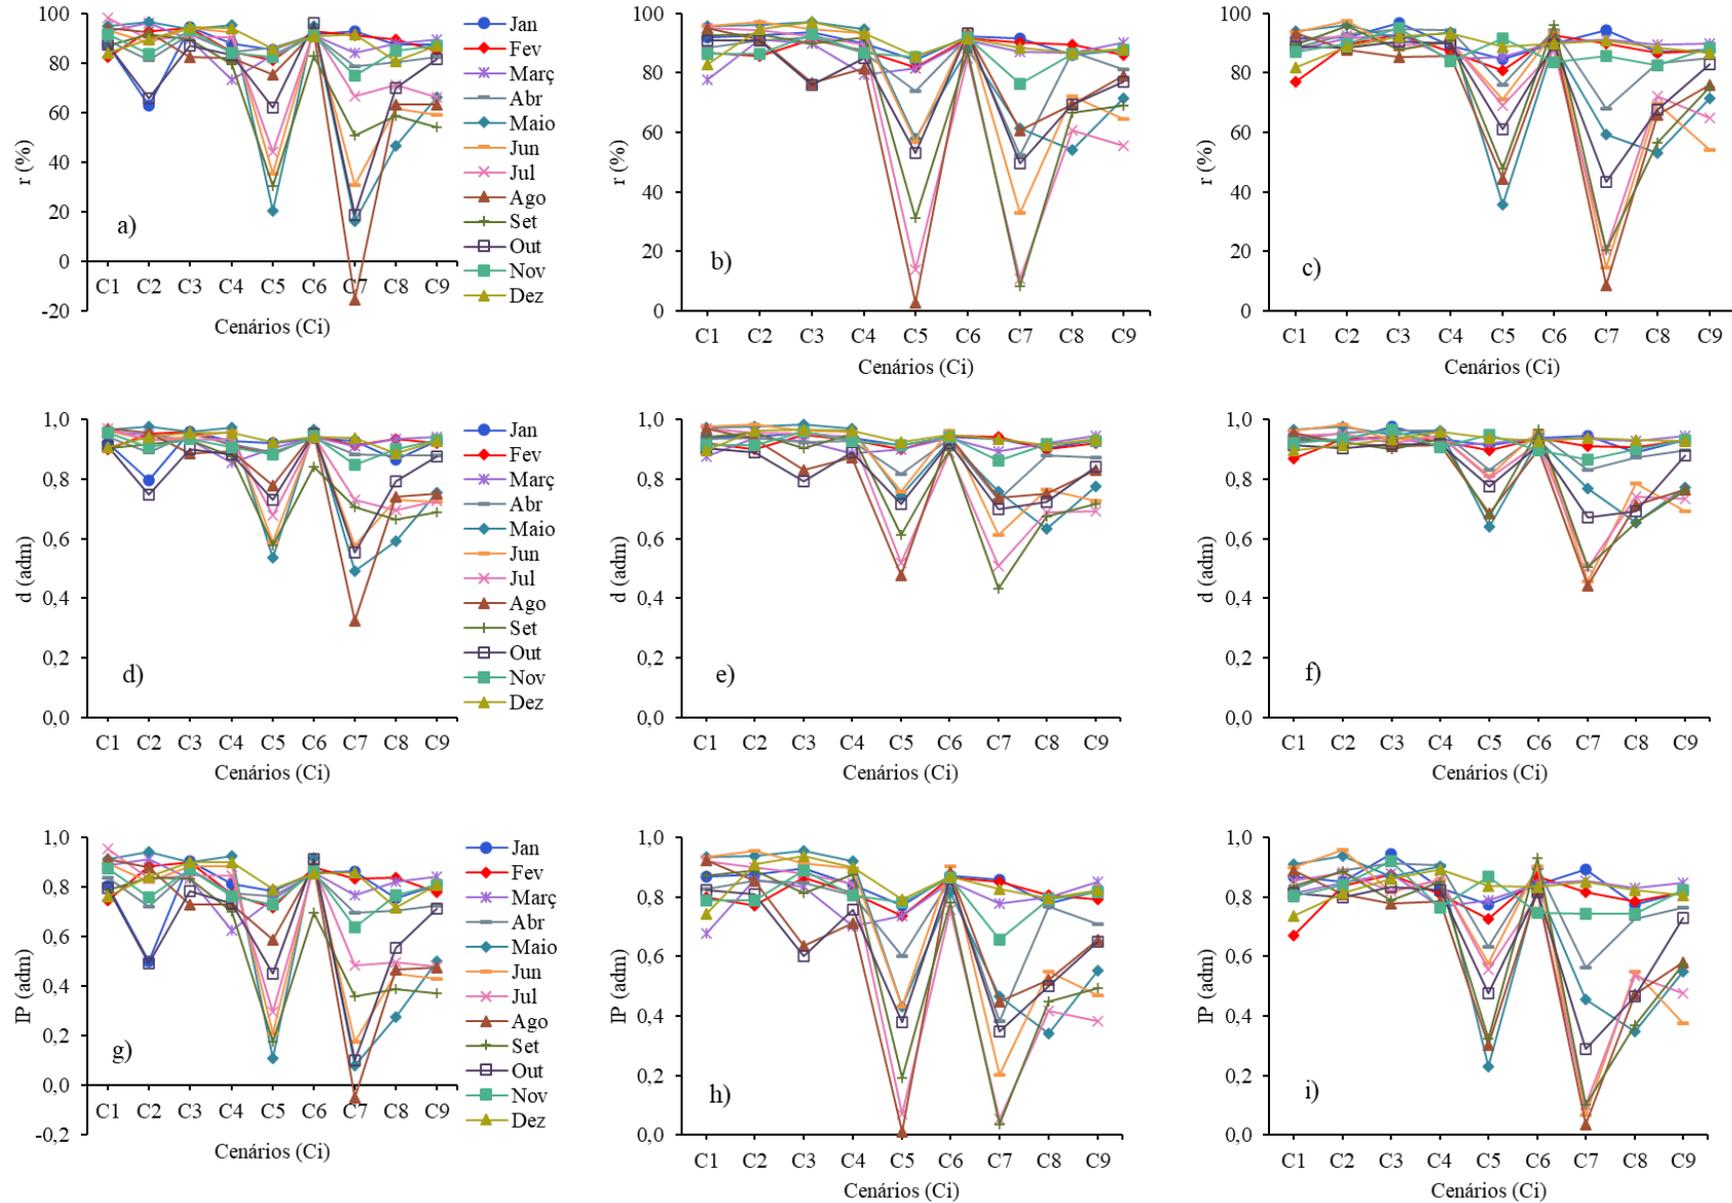
Os cenários C5, C7, C8 e C9 apresentaram maiores valores de RQEM. O menor valor deste índice foi de $0,34^{\circ}\text{C}$ e o maior de $2,7^{\circ}\text{C}$, sendo esse valor, ambos para a configuração do modelo M3 (Figura 11.c). Já o modelo M2 obteve o segundo menor índice de RQEM (Figura 11.b), no qual variaram de $0,42$ a $2,5^{\circ}\text{C}$, enquanto o modelo M1 resultou em RQEM (Figura 11.a) entre $0,43$ e $3,2^{\circ}\text{C}$.

As configurações de camadas ocultas dos modelos M2 e M3, apresentaram médias no índice EMA no valor de $0,70^{\circ}\text{C}$, enquanto a aplicação do modelo M1 resultou em $0,73^{\circ}\text{C}$ (Apêndice B). Semelhante aos resultados obtidos para a T_{max} , também podem ser constatados para a T_{med} , em termos de pouca variabilidade entre os meses, modelos e melhores cenários explicitados anteriormente nas Figuras 11: (d), (e) e (f). Entretanto, a utilização da configuração do modelo M2 e cenário C3 apresentou EMA ligeiramente superior para mês de agosto, ainda assim este resultado é aceitável.

Ao combinar a regressão linear e a série trigonométrica de Fourier incompleta para as estimativas da temperatura média diária do ar no estado de Goiás, Antonini *et al.* (2009) obtiveram resultados de RQEM variando de $0,22^{\circ}\text{C}$ ao valor máximo de $1,27^{\circ}\text{C}$ para locais de altitude elevada. Nas estimativas da temperatura média do ar pela regressão linear múltipla, Alonso e Renard (2019) obteve oscilação do índice de RQEM para áreas artificiais RQEM ($0,73 - 1,66^{\circ}\text{C}$); para áreas de produção agrícola os índices de RQEM ($0,78 - 1,14^{\circ}\text{C}$) e para ambientes considerados como seminaturais, com RQEM ($0,06 - 1,94^{\circ}\text{C}$).

Azad *et al.* (2020) utilizou modelos Fuzzy em diferentes locais com características climáticas e geográficas específicas, no qual o local próximo a colinas, obteve RQEM (entre $1,29$ e $1,44^{\circ}\text{C}$) e EMA (entre $2,09$ e $2,97^{\circ}\text{C}$). Para o local de clima árido foi obtido RQEM (entre $0,84$ e $0,98^{\circ}\text{C}$) e EMA (entre $0,95$ e $1,19^{\circ}\text{C}$), enquanto a região de climas quentes e húmidos com RQEM (entre $0,69$ e $0,75^{\circ}\text{C}$) e EMA (entre $0,54$ e $0,73^{\circ}\text{C}$). Já em climas frios, o RQEM oscilou entre $0,76$ e $0,88^{\circ}\text{C}$ e EMA entre $0,77$ e $0,95^{\circ}\text{C}$. São apresentados na Figura 12 os índices estatísticos do coeficiente de correlação, índices de desempenho e performance, para os diferentes cenários (C_i), modelos (M1, M2 e M3) e para todos os meses do ano, nas estimativas da T_{med} para a região Centro-Oeste do Brasil.

Figura 12 – Coeficiente de correlação (r) dos modelos de rede M1 (a), M2 (b) e M3 (c); índice de desempenho ‘d’ M1 (d), M2 (e) e M3 (f) e, índice de performance ‘IP’ M1 (g), M2 (h) e M3 (i), na escala mensal para as estimativas da Tmed na região Centro-Oeste do Brasil, com dados de 16 estações meteorológicas, para o período analisado de 1990 a 2020.



Fonte: Elaborado pelo Autor (2021).

Os melhores ajustes dos modelos considerando o coeficiente de correlação de Pearson nas estimativas da Tmed foram obtidos ao utilizar os três modelos nos cenários C1, C2, C3, C4 e C6. Os cenários C5, C7, C8 e C9 apresentaram menores correlações 'r', especialmente nos meses de maio a setembro. Os valores de 'r' variaram entre 8,5 e 97% para M3 (Figura 12.c). Já o modelo M2 obteve 'r' oscilando de 2,9 a 97% (Figura 12.b), enquanto o modelo M1 resultou no menor valor de -15,4% e o maior de 98% (Figura 12.a).

Os coeficientes de correlação obtidos por Antonini *et al.* (2009) nas estimativas da temperatura média do ar, foram interpretados como moderados e fortes, no qual o maior valor do coeficiente de correlação foi de 87% (média altitude) e o menor de 77% (baixa altitude), enquanto os locais de elevada altitude obtiveram 'r' de 79%. Os coeficientes de correlação obtidos por Cargnelutti Filho *et al.* (2008) oscilaram entre 92% (3º decêndio de junho) a 99% (1º e 2º decêndio de março) na estimativa da temperatura média do ar no estado do Rio Grande do Sul utilizando a regressão linear múltipla, comprovando a adequabilidade dos modelos.

Para a comparação entre valores observados e estimados para a Tmed, os menores índices de desempenho 'd' foram nos valores 0,32 para o modelo M1 observado na Figura 12.d; de 0,43 para o modelo M2 (Figura 12.e) e de 0,44 para o modelo M3 (Figura 12.f). Entretanto, não houve diferença entre os modelos para o valor máximo obtido de 0,98 para as três configurações analisadas. De maneira geral para os cenários C1, C2, C3, C4 e C6, e em todos os meses, apresentaram baixa variabilidade no índice de desempenho 'd', indicando um ótimo desempenho dos modelos nestas situações e que se aproximam de $d = 1$.

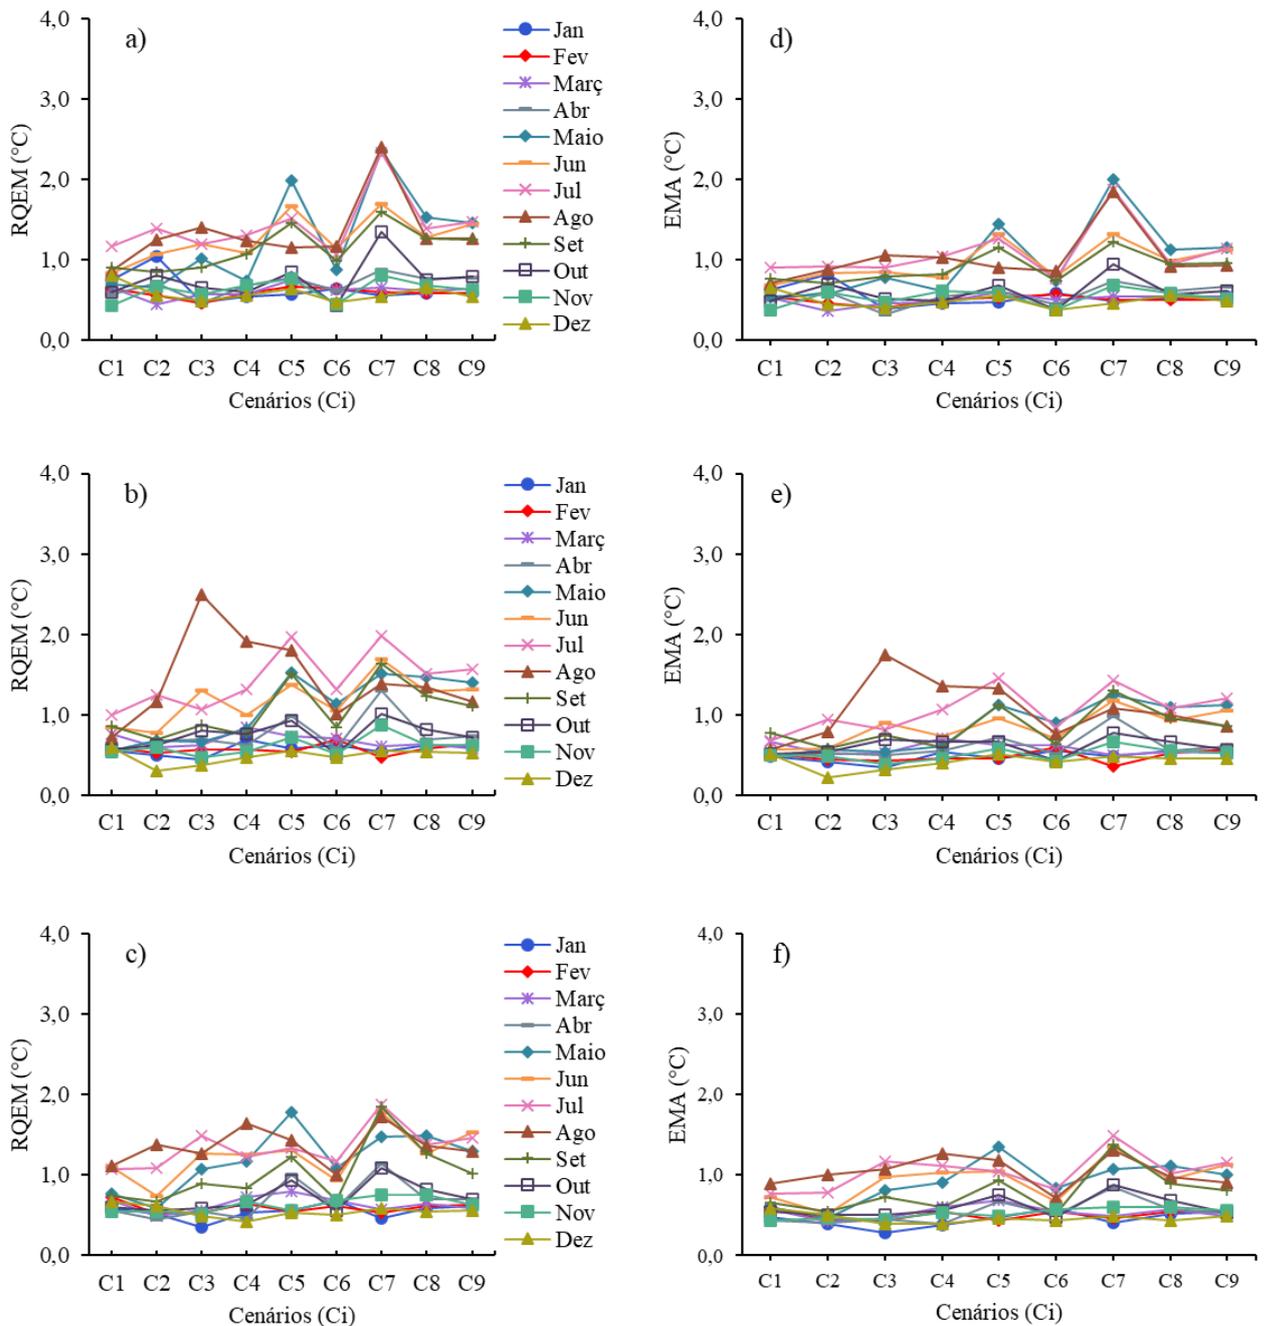
A maioria das RNAs para as estimativas da temperatura média do ar (Tmed) e para os três modelos estudados (Figura 12.g, Figura 12.h e Figura 12.i) obtiveram índices de performances (IP) com pouca variação em todos os meses do ano e cenários mais promissores (C1, C2, C3, C4 e C6). A maior parcela de RNAs apresentaram classificações consideradas como ótimas ($IP \geq 0,75$), seguida das classificações de muito bom (0,60 – 0,75) e bom (0,45 – 0,60), indicando a precisão nas estimativas da Tmed.

A sequência dos modelos que apresentaram classificações de IP considerados como ótimos ($IP \geq 0,75$) foi observado para as configurações dos modelos M3, M2 e M1, respectivamente (Apêndice D). Dessa maneira, 69% das RNAs (75 redes) do M3 apresentaram ótimas performances, seguido do modelo M2 com 67% (72 redes) e do modelo M1 com 62% (67 redes). Em relação a pior situação de IP, classificado como muito ruim ($IP < 0$), apenas uma rede do modelo M1 que obteve essa classificação (Apêndice D).

4.2.3 Estrutura de camadas intermediárias para a temperatura mínima do ar

São apresentados na Figura 13 para as estimativas da temperatura média do ar, na escala mensal, em diferentes cenários (C1-C9) e modelos (M1-M3) para o Centro-Oeste do Brasil, com dados de 1990 a 2020, os índices estatísticos da Raiz Quadrática de Erro Médio (RQEM) e Erro Médio Absoluto (EMA), ambos em °C.

Figura 13 – Raiz Quadrática de Erro Médio (RQEM, em °C) e Erro Médio Absoluto (EMA, em °C) para as estimativas da temperatura mínima do ar, na escala mensal, em diferentes cenários (C1-C9) e modelos (M1-M3) para o Centro-Oeste do Brasil., com dados de 1990 a 2020.



Fonte: Elaborado pelo Autor (2021).

Em relação aos três modelos, os resultados de RQEM observados nas Figuras 13 (a – c) para a estimativa da T_{min}, apresentaram maiores variações entre os meses centrais (junho, julho

e agosto) até mesmo nos cenários considerados promissores (C1, C2, C3, C4 e C6), quando comprado aos obtidos para Tmax e Tmed. Porém, essas variações não foram tão acentuadas podendo, portanto, considerar como uma oscilação aceitável pois a maioria das RNAs, resultaram em RQEM $\leq 2,0^{\circ}\text{C}$. Os valores de RQEM variaram entre 0,4 a $2,4^{\circ}\text{C}$ para o modelo M1 (Figura 13.a) e para o modelo M2 foram obtidos valores de 0,3 a $2,5^{\circ}\text{C}$ (Figura 13.b), sendo este valor máximo observado no C3 no mês de agosto. Já o modelo M3 é possível verificar (Figura 13.c) resultados na faixa de 0,35 a $1,9^{\circ}\text{C}$.

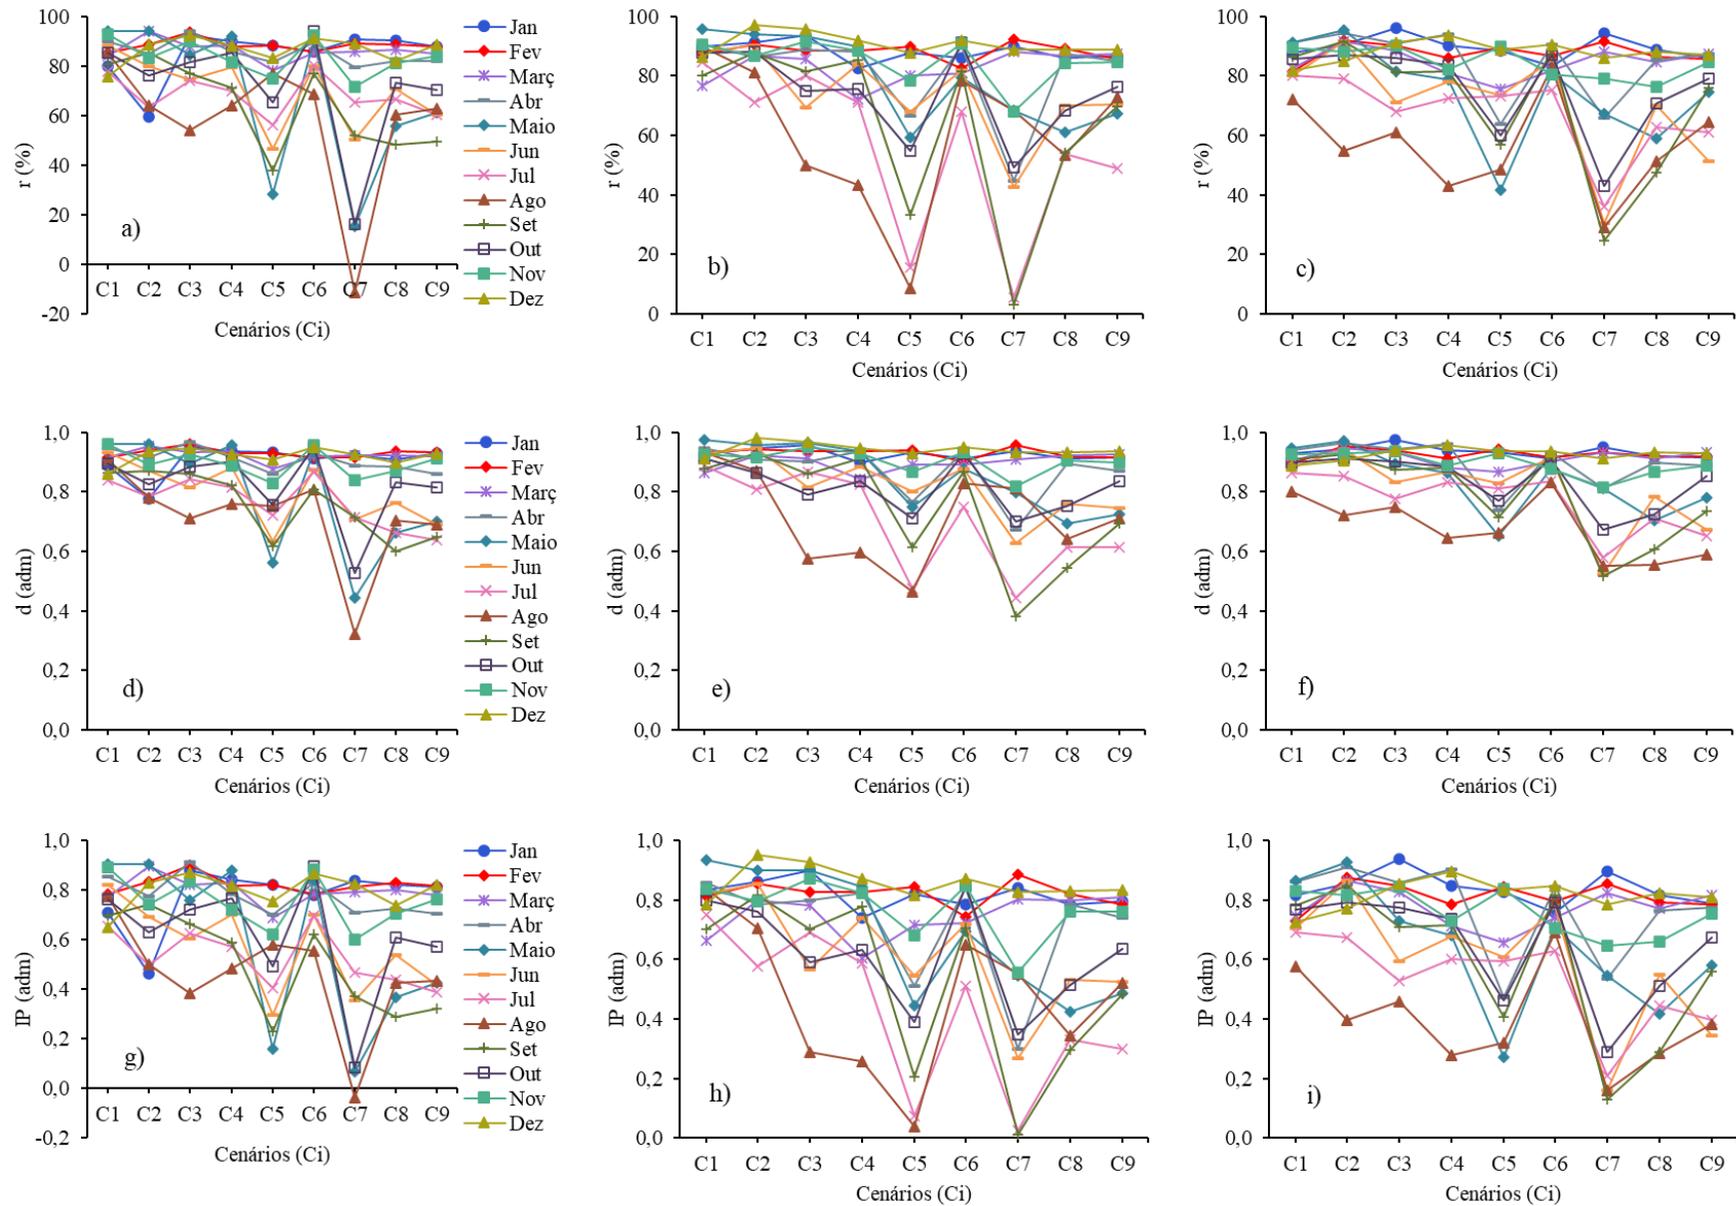
Quanto a Tmin o modelo M1 (Apêndice B) resultou em média EMA no valor de $0,72^{\circ}\text{C}$, o modelo M2 e M3 de $0,70^{\circ}\text{C}$ e $0,69^{\circ}\text{C}$, respectivamente. Em termos absolutos, os valores de EMA observados nas Figuras 13 (d – f) apresentaram uma menor variação entre os meses e cenários quando comparado ao índice EMA obtido para a Tmax e Tmed. Além do mais, a maioria das RNAs apresentaram ótimos resultados (EMA $\leq 1^{\circ}\text{C}$), no qual o maior valor foi de aproximadamente 2°C (em maio e agosto para M1 e cenário C7). Especificamente as estimativas da Tmin no mês de agosto, ao analisar o cenário C3 e utilizar o modelo M2, apresentou uma variação quando comparado aos outros cenários, mas ainda assim, pode ser considerado aceitável.

Já Zhu *et al.* (2013) verificaram que para a estimativa da temperatura mínima do ar por meio de informações do satélite MODIS Terra apresentaram índices de RQEM de $2,97^{\circ}\text{C}$ e EMA de $2,37^{\circ}\text{C}$. Para o produto MODIS Aqua estes índices foram de $4,41^{\circ}\text{C}$ para RQEM e de $3,39^{\circ}\text{C}$ para EMA. Os resultados obtidos por Viggiano *et al.* (2019) apresentaram que a RQEM é menor $1,86^{\circ}\text{C}$ nas estimativas da temperatura mínima do ar $1,86^{\circ}\text{C}$ e que não houve uma alta variação especial pois os valores de RQEM foram aproximadamente os mesmos para o MAE.

Azad *et al.* (2020) obteve valores superiores para diferentes cidades do Iran, em que a cidade de Zahedan apresentou índices de erros de RQEM (entre $1,22$ e $1,39^{\circ}\text{C}$) e EMA (entre $2,06$ e $3,02^{\circ}\text{C}$). No caso de Mashhad foram obtidos RQEM entre $1,21$ e $1,69^{\circ}\text{C}$ e EMA entre $1,85$ e $2,99^{\circ}\text{C}$. Wang *et al.* (2021) Combinou informações obtidas do Satélite MODIS, modelo de elevação digital, *Land Surface Temperature* (LST) dos produtos Terra (MOD11A1) e Aqua (MYD11A1) combinadas a regressão simples para a estimativa da temperatura mínima do ar de seis províncias na região do rio Yangtze, China. Os resultados satisfatórios foram obtidos para o produto MYD11A1 com RQEM de $2,15^{\circ}\text{C}$ e EMA de $1,66^{\circ}\text{C}$, no qual os resultados destes índices foram considerados adequados para as estimativas.

A Figura 14 contém os índices estatísticos do coeficiente de correlação (r), em %; índice de desempenho ‘d’ e índice de performance (IP), para os diferentes cenários (C1 a C9) modelos (M1, M2 e M3) na escala mensal para as estimativas da Tmin na região Centro-Oeste do Brasil.

Figura 14 – Coeficiente de correlação (r) dos modelos de rede M1 (a), M2 (b) e M3 (c); índice de desempenho ‘d’ M1 (d), M2 (e) e M3 (f) e, índice de performance ‘IP’ M1 (g), M2 (h) e M3 (i), na escala mensal para as estimativas da T_{min} na região Centro-Oeste do Brasil, com dados de 16 estações meteorológicas, para o período analisado de 1990 a 2020.



Fonte: Elaborado pelo Autor (2021).

Os valores do coeficiente de correlação ‘r’ variaram entre -11 a 94% para o modelo M1 (Figura 14.a). Em relação ao modelo M2 (Figura 14.b) foram obtidos valores de ‘r’ entre de 3,0 a 97%. Já o modelo M3 (Figura 14.c) resultou aproximadamente de ‘r’ mínimo e máximo de 25 e 96%, respectivamente.

As estimativas da T_{min} no mês de agosto, também apresentou redução no coeficiente de correlação, nos três modelos: M1 (C2, C3, C4); M2 (C3, C4, C5 e C8) e M3 (C2, C3, C4, C5, C7, C8 e C9). Cargnelutti Filho *et al.* (2006) obteve coeficientes de correlação (r) entre valores observados e estimados oscilando de 83% (2º decêndio de junho) a 97% (1º e 3º decêndio em janeiro) ao utilizar a regressão linear múltipla na estimativa da temperatura mínima do ar decendial, para o estado do Rio Grande do Sul, no qual concluíram que os modelos obtidos podem ser utilizados na estimativa da T_{min}.

Já Zhu *et al.* (2013) verificaram que para a estimativa da temperatura mínima do ar por meio de informações do satélite MODIS Terra apresentaram correlações 0,94. Para o produto MODIS Aqua a correlação foi de 0,91. Afzali *et al.* (2012), utilizou redes perceptron múltiplas camadas (MLP) e redes neurais recorrentes (RNR) para estimar as temperaturas máximas, médias e mínimas do ar, na escala diária e mensal, para a cidade de Kerman, região Sudeste do Irã. Os melhores resultados de ‘r’ para as estimativas da T_{min}, foram obtidas para a escala diária de 0,93 para MLP e 0,94 para RNR. Para a escala mensal, as estimativas da T_{min} foram de 0,71 para o método MLP e de 0,73 para o método RNR, indicando que em ambas as escalas (diária e mensal), os coeficientes de correlação apresentaram bom ajustes entre valores observados e estimados.

Ao analisar o índice ‘d’, este foi o que apresentou de maneira geral maior estabilidade, para os cenários C1, C2, C3, C4 e C6. Os valores do índice de desempenho (d) variaram entre 0,32 e 0,97 para o modelo M1 (Figura 14.d); entre 0,38 e 0,98 para o modelo M2 (Figura 14.e) e, na faixa de 0,52 a 0,98 ao utilizar o modelo M3 (Figura 14.f) para as estimativas da T_{min} mensal.

Apesar da maior variação no índice de IP (Apêndice E), os três modelos analisados (M1, M2 e M3) apresentaram maior proporção de RNAs para classificação de ótima performance. Assim, a sequência de melhores performances foi para os modelos M2 com 52% (52 redes), M3 com 49% (53 redes) e modelo M1 com 46% (50 redes). Tanto o modelo M1 e M3, apresentaram a mesma proporção de 25% (27 redes) com classificação considerada como performance muito boa ($0,6 \leq IP \leq 0,75$).

De forma geral, em todos os modelos, temperaturas do ar (T_{max}, T_{med} e T_{min}) para os cenários C5, C7 e em alguns meses dos cenários C8 e C9, os índices estatísticos de Raiz Quadrática do Erro Médio (RQEM), de Erro Médio Absoluto (EMA) apresentaram valores

superiores que os outros cenários (C1, C2, C3, C4 e C6). Já os índices que medem a acurácia e ajustes dos modelos, como o coeficiente de determinação (R^2), coeficiente de correlação de Pearson (r), índice de concordância 'd' e índice de performance (IP), apresentaram baixos valores.

Estes resultados indicam que não houve a convergência das RNAs durante o treinamento de forma que, quando submetidas a etapa de teste, as redes não apresentaram resultados satisfatórios nestas circunstâncias citadas. Isso pode ser explicado em função da falta de redundância na combinação entre as variáveis de entrada e até mesmo sobre a complexidade da relação física entre os fatores e elementos a nível macro e microclimáticos e sazonalidade. A variabilidade dos elementos climatológicos está relacionada não somente a mudanças climáticas a nível global, mas as próprias alterações do local, como supressão e áreas vegetadas e a expansão do adensamento urbano, presença de corpos hídricos, evaporação, uso de terra etc. (SILVA JÚNIOR *et al.*, 2020).

Portanto, a ordem dos melhores cenários de variáveis de entrada para estimativas das temperaturas do ar máxima, média e mínima, na escala mensal, para a região Centro-Oeste do Brasil, são os cenários: C1, C2, C3, C4 e C6, respectivamente. Os cenários C5 e C7, C8 e C9, por resultarem de maneira geral em menores coeficientes de determinação (R^2), não são indicados para as estimativas dos meses de maio, junho, julho, agosto e setembro e outubro.

Em relação às redes neurais artificiais, outra possível causa para os reduzidos valores de R^2 , r , d , IP e elevados valores de RQEM e EMA, diz respeito ao número de camadas e neurônios em cada camada, funções de transferências, sorteio inicial dos pesos, métodos de normalização, algoritmos de treinamento, subdivisão adequada parcelas de treino, validação e teste, a própria presença de ruídos nos dados.

O problema do não aprendizado dos modelos de Deep Learning é comum, especialmente na etapa de treinamento das redes. Xiao *et al.* (2021) explicam que as amostras que contêm excesso de ruídos, são ajustadas durante o processo de treinamento, ignorando parte dos dados sem ruídos, então os ajustes são satisfatórios nesta etapa, resultando em pequenos desvios entre valores observados e estimados. Mas quando as redes são submetidas a etapa de teste, os desvios são elevados e as RNAs não são capazes de generalizar o domínio do problema de forma representativa e satisfatória redes (XIAO *et al.*, 2021).

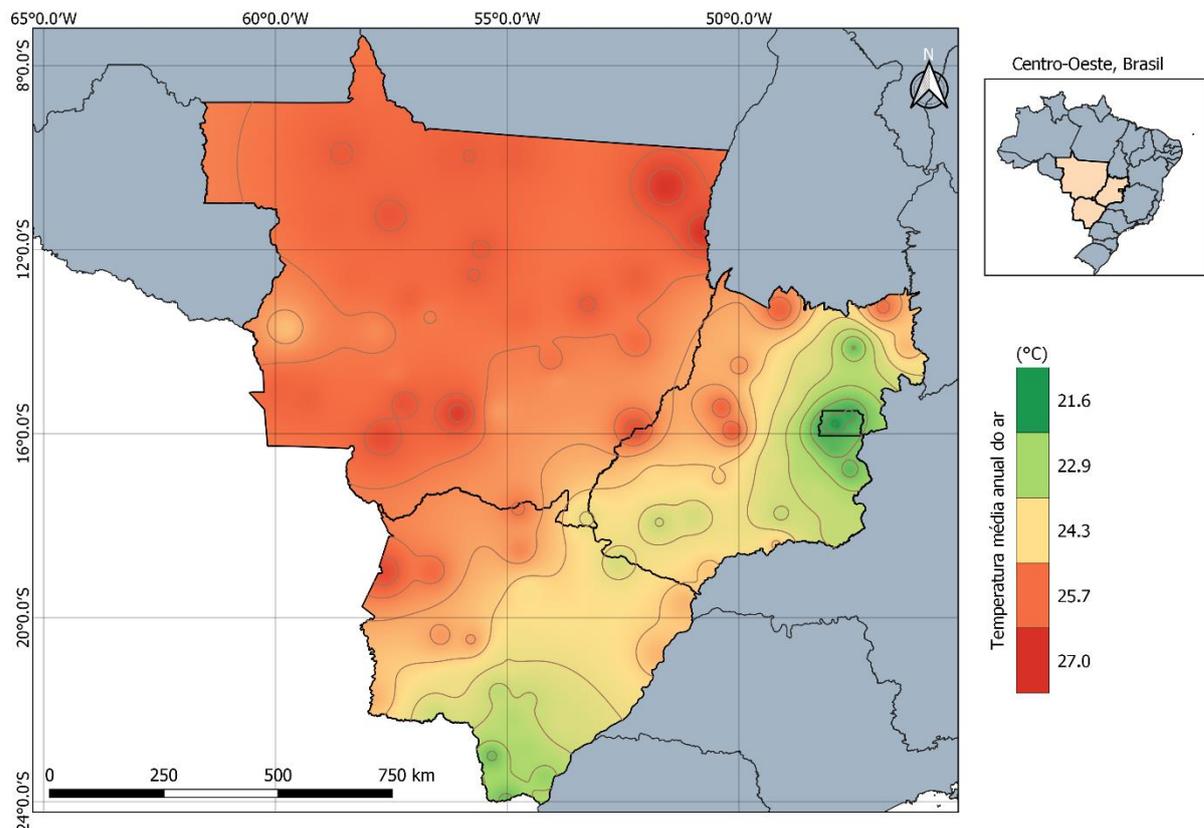
Além do mais, redes neurais artificiais do tipo Deep Learning apresentam uma maior complexidade, pois a medida em que se aumenta a quantidade de dados, neurônios e camadas, os parâmetros ajustáveis também se tornam maiores. Neste contexto, as RNAs são submetidas ao aprendizado contínuo de novas tarefas e informações, resultando em uma subscrição do conhecimento adquirido previamente (XIE *et al.*, 2021).

Assim, nenhum método pré-determina a melhor combinação na quantidade de camadas ocultas e de neurônios em cada camada, pois isso pode variar da especificidade do modelo, dos processos físicos que ocorrem na iteração entre as variáveis, assim como do conjunto de treinamento (ALISINA *et al.*, 2016). Dessa forma, os artigos relatados que estudaram a aplicação do Deep Learning apresentam vantagens, especificidades e certas limitações, abrindo precedentes para expansão dos estudos (XIAO *et al.*, 2021).

4.3 Distribuição espacial da temperatura média do ar anual para o Centro-Oeste do Brasil

A Figura 15 apresenta a temperatura média do ar anual para a região Centro-Oeste do Brasil, com dados de 1990-2020. Por meio desta figura, é possível verificar que as maiores temperaturas médias, na escala anual, estão situadas quase que em todo o território do Estado do Mato Grosso e altitude inferior a 388 m. Entretanto a divisa entre a mesorregião Norte com a mesorregião Sudoeste e, no extremo da mesorregião sudeste (divisa entre os estados de GO e MS) do Mato Grosso, são regiões com características altimétricas superiores a 709 m, apresentando menores temperaturas entre 22,9 e 24,3 °C.

Figura 15 – Mapa de regionalização da temperatura média do ar, na escala anual para os estados da região Centro-Oeste do Brasil, com dados de 81 estações meteorológicas, para o período analisado de 1990 a 2020.



Fonte: Elaborado pelo Autor com dados Instituto Nacional de Meteorologia (2020).

Os Estados de Goiás e Mato Grosso do Sul são os que apresentaram maior variabilidade de temperaturas médias do ar anual (Figura 15). Especificamente no Estado do MS, a mesorregião Pantanal é a que apresenta temperaturas do ar superiores a 25,7 °C (e altitude em torno de 66 m). As mesorregiões Centro Norte, Leste e Sudoeste do MS apresentam temperaturas médias anuais variando de 21,6 a 25,7 °C, no qual a menor temperatura do ar é observada no extremo da mesorregião do Sudoeste e com valor em torno de 21,6°C.

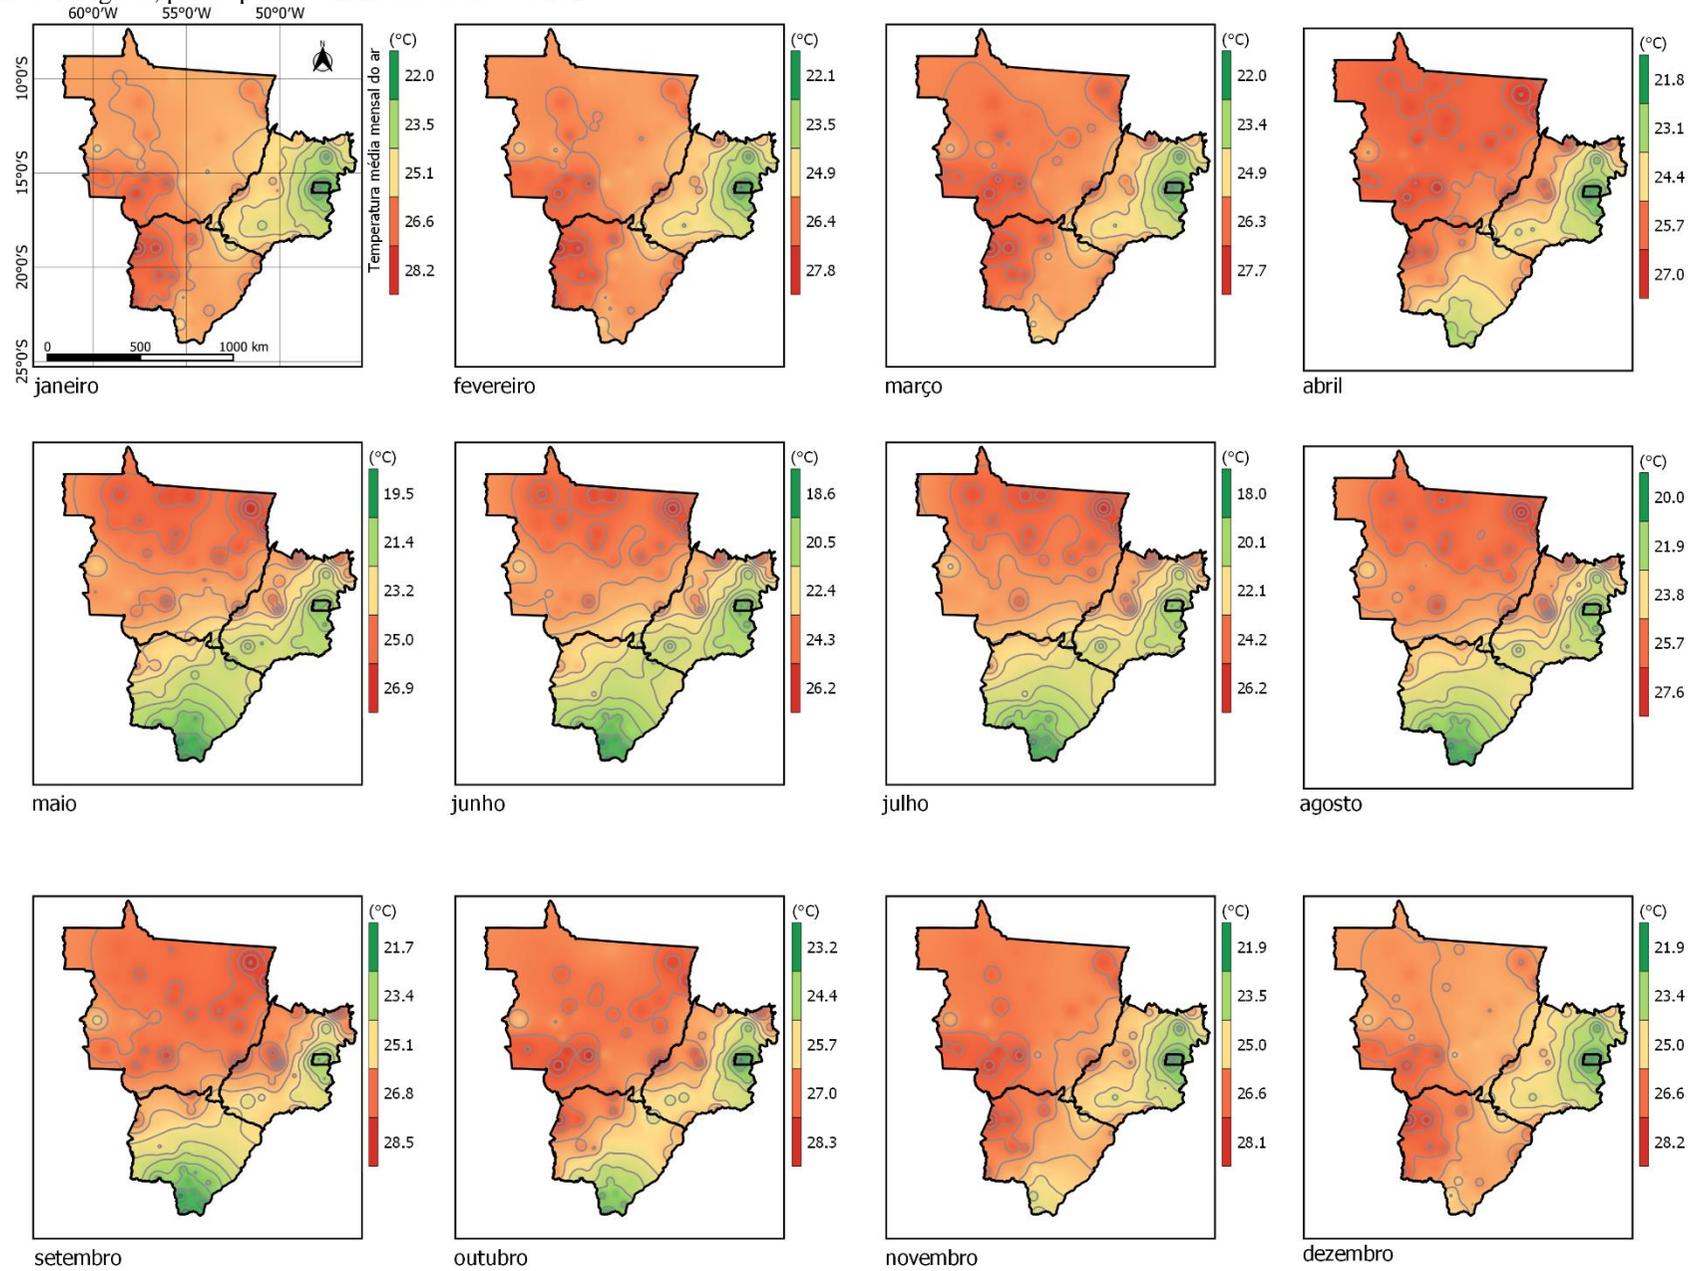
No Distrito Federal bem como o seu entorno (mesorregião Leste Goiana), parte das mesorregiões Norte, Centro e Sul goiano apresentam os menores valores (inferiores a 22,9°C) de temperaturas médias do ar anual, com altitudes entre 709 a 1674 m. Já a mesorregião Noroeste de Goiás (e divisa com MT) e no extremo Norte goiano (divisa com o estado do Tocantins) são os locais apresentam as maiores temperaturas médias anuais, com valores superiores a 25,7°C e altitudes abaixo de 388 m.

4.4 Distribuição espacial da temperatura média do ar mensal para o Centro-Oeste do Brasil

A Figura 16 apresenta distribuição das temperaturas médias mensais para a região Centro-Oeste do Brasil. Na estação de outono, o mês de março foi observado valor mínimo de 22,0 °C e máximo de 27,7 °C, com amplitude térmica de 5,7 °C. Já a menor amplitude térmica observada nesta estação do ano foi para o mês de abril (5,2 °C), com valor mínimo para temperatura média do ar de 21,8 °C e máximo de 27 °C. Maio foi o mês que apresentou a segunda maior amplitude térmica na estação do outono (7,4 °C) com temperaturas médias variando de 19,5 (mínima) a 26,9 °C (máxima). Já o mês de junho (mês de transição entre outono-inverno) foi o que apresentou a maior amplitude térmica (7,6 °C) em relação aos outros meses do que compreendem a estação do outono, com valor máximo chegando a 26,2 °C e mínimo de 18,6 °C, no qual este foi a menor temperatura média do ar observada na estação analisada.

Em relação a estação de inverno (parte do mês de junho, julho, agosto e setembro), pode ser observado pela Figura 6 que em julho foi o mês em que ocorreu a maior amplitude térmica em relação a todos os meses do ano (8,2 °C). Neste mês o valor máximo foi de 27,6 °C e o menor valor para temperatura média do ar foi de 18,0 °C, o menor valor para temperatura média do ar mensal quando comparado aos outros meses do ano. Agosto apresentou valor mínimo de 20,0 °C e máximo 27,6 °C, com amplitude térmica de 7,6 °C. Enquanto o mês de setembro (transição do inverno-primavera) indicou amplitude térmica de 6,8 °C, com valores mínimos e máximos observados de 21,7 °C e 28,5 °C, respectivamente. Neste mês foi observado o maior valor de da temperatura média do ar em comparação aos outros meses do ano.

Figura 16 – Mapa de regionalização da temperatura média do ar, na escala anual para os estados da região Centro-Oeste do Brasil, com dados de 81 estações meteorológicas, para o período analisado de 1990 a 2020.



Fonte: Instituto Nacional de Meteorologia (2020).

Para a estação de primavera, foi observado no mês de outubro a menor amplitude térmica (5,1 °C) em relação a todos os meses do ano, com valores mínimos de 23,2 °C e máximos de 28,3 °C. Novembro apresentou valores que variaram entre 21,9 °C a 28,1 °C e amplitude térmica de 6,9 °C. Em relação a dezembro (transição entre primavera-verão), para este mês foi observado mínimas de 21,9 °C e máximas na escala de 28,2 °C, com amplitude térmica em torno de 6,3 °C.

Por fim, a estação de verão apresentou no mês janeiro amplitude térmica de 6,2 °C e mínimas e máximas de 22,0 °C e 28,2 °C, respectivamente. Foi observado para o mês de fevereiro a menor amplitude térmica para esta estação do ano (5,2 °C), com mínimos em torno de 22,1 °C e máximas de 27,8 °C.

5 CONSIDERAÇÕES FINAIS

Este trabalho teve por objetivo apresentar a viabilidade das Redes Neurais Artificiais nas estimativas das temperaturas do ar mensais, máxima, média e mínima para o Centro-Oeste do Brasil, bem como estudar a combinação adequada entre variáveis explicativas para as estimativas.

Para isto, foram utilizadas Redes Neurais Artificiais do tipo Deep Learning no qual a parametrização das RNAs ocorreu utilizando dados de altitude, coordenadas geográficas e elementos climáticos de 81 estações meteorológicas, distribuídas na região Centro-Oeste do Brasil, no período compreendido de 1990 a 2020. Foram estudadas diferentes combinações de variáveis de entrada, assim como três diferentes configurações de camadas intermediárias, com a finalidade de identificar quais destes cenários e modelos proporcionam estimativas adequadas para as temperaturas do ar, na escala mensal, para o Centro-Oeste brasileiro.

A aplicabilidade do Deep Learning considerando diversas camadas intermediárias e neurônios em cada camada, possibilitou uma melhor capacidade de abstração para se determinar a solução ótima no domínio do problema. Além do mais, a contribuição no estudo das melhores combinações de variáveis independentes, em cada modelo e mês do ano, é de suma relevância, pois permite uma melhor acurácia nas estimativas.

As melhores combinações de variáveis de entrada obtidas neste estudo, foram os cenários com 05 neurônios: C1 (Alt, Lat, Long, UR e VV); com 04 neurônios: C2 (Alt, Lat, Long e UR) e C4 (Alt, Lat, Long e VV); com 03 neurônios: C3 (Alt, Lat e Long) e; com 02 neurônios na camada de entrada: C6 (Alt e Lat).

Para este estudo, a quantidade de neurônios na camada de entrada não foi necessariamente fator determinante para melhores acurácias, mas sim a combinação adequada entre os fatores e elementos explicativos.

Para as estimativas das temperaturas do ar máxima e média, a sequência das melhores configurações dos modelos de camadas intermediárias foram, com duas: M3 (17 - 3) e M2 (14 - 3) e com três camadas ocultas M1 (16 - 7 - 3). Em relação a temperatura mínima do ar, as melhores configurações de camadas ocultas foram os modelos M2, M3 e M1.

Para os melhores cenários e modelos nas estimativas das temperaturas do ar, máxima, média e mínima, a utilização de Deep Learning promoveu para a maioria das RNAs estudadas, R^2 e $r \geq 70\%$; $RQEM$ e $EMA \leq 1^\circ C$; $d \geq 0,8$ e IP com classificações dos ajustes dos modelos como ótimos, muito bom e bom.

Diante do exposto, é possível verificar a viabilidade da aplicação do Deep Learning nas estimativas das temperaturas, podendo ser útil para locais que necessitam conhecer as variações

térmicas com precisão satisfatória, tanto para aqueles que apresentam falhas ou valores inconsistentes destas variáveis, quanto para os locais que não possuam uma rede de estações meteorológicas e que se deseja conhecer estes valores.

Desta forma, este trabalho apresenta indícios da viabilidade do emprego de Redes Neurais Artificiais – especificamente o Deep Learning – com aceitável grau de acurácia, nas estimativas das temperaturas mensais máximas, médias e mínimas, na região Centro-Oeste do Brasil, podendo a metodologia ser modificada e/ou estendida para outras regiões com a parametrização da rede com os dados relativos às mesmas.

REFERÊNCIAS BIBLIOGRÁFICAS

AFFAM, A.C.; CHAUDHURI, M.; WONG, C.C.; WONG, C.S. Artificial neural network (ANN) modeling for prediction of pesticide wastewater degradation by FeGAC/H₂O₂ process. **ICCEE**, Malaysia, v. 65, p.1-14, 2018.

AFZALI, M; AFZALI, A.; ZAHEDI, G. The potential of artificial neural network technique in daily and monthly ambient air temperature prediction. **International Journal of Environmental Science and Development**, Singapura, v.3, n.1, p.33-38, 2012.

AGARWAL, N.; BALASUBRAMANIAN, V.N.; JAWAHAR, C.V. Improving multiclass classification by deep networks using DAGSVM and Triplet Loss. **Pattern Recognition Letters**, New York, v. 112, p. 184-190, 2018.

ALONSO, L.; RENARD, F. Integrating Satellite-Derived data as spatial predictors in multiple regression models to enhance the knowledge of air temperature patterns. **Urban Science**, Basel, v.3, n.4, p.1-22, 2019.

ALSINA, E.F.; BORTOLINI, M.; GAMBERI, M.; REGATTIERI, A. Artificial neural network optimization for monthly average daily global solar radiation prediction. **Energy Conversion and Management**, Amsterdã, v.120, p.320-329, 2016.

ALVARENGA, A.A.; AZEVEDO, L.L.C.; MORAES, M. E. De O. **Agrometeorologia - Princípios, Funcionalidades e Instrumentos de Medição**. 1.ed. Viçosa: Editora Érica. 2015. 120p.

ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; GONÇALVES, J.L.M. Modeling monthly mean air temperature for Brazil. **Theoretical and Applied Climatology**, Berlim, v.113, n.3-4, p.407-427, 2013.

ALVES, C.P.; EUGÊNIO, D.S.; SOUZA, L.F.; SANTOS, J.P.A.S. Influência da temperatura e umidade relativa do ar no consumo alimentar de suínos no semiárido brasileiro. **Brazilian Journal of Development**, Curitiba, v.3, n.4, p.4263-4269, 2020.

AMBRÓSIO, P. E. **Redes neurais artificiais no apoio ao diagnóstico diferencial de lesões intersticiais pulmonares**. 2002. 82f. Dissertação (Mestrado em Ciências), Faculdade de Filosofia, Ciências e Letras, Universidade de São Paulo, Ribeirão Preto, 2002.

AMBRÓSIO, P.E. **Redes neurais artificiais no apoio ao diagnóstico diferencial de lesões intersticiais pulmonares**. 2002. 85 f. (Mestrado em Ciências) – Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto, Universidade de São Paulo, Ribeirão Preto, 2002.

ANTONINI, J.C.A.; SILVA, E.M.; OLIVEIRA, L.F.C.; SANO, E.E. Modelo matemático para estimativa da temperatura média diária do ar no Estado de Goiás. **Pesquisa Agropecuária Brasileira**, Brasília, v.44, n.1, p.331–338, 2009.

ANTONINI, J.C.A.; SILVA, E.M.; OLIVEIRA, L.F.C.; SANO, E.E. Modelo matemático para estimativa da temperatura média diária do ar no estado de Goiás. **Pesquisa Agropecuária Brasileira**, Brasília, v.44, n.4, p.331-338, 2009.

AQUINO, P.S.R.; RODRIGUES, M.S.; CASTRO, R.V.O.; NAPPO, M.E. Uso de redes neurais artificiais na análise de variáveis ambientais associadas à deposição de serapilheira. **Revista Comunicata Scientiae**, Bom Jesus, v.7, n.3, p.394-405, 2016.

ARAI, M. Bounds on the number of hidden units in binary-valued three-layer neural networks. **Neural Networks**, Omaha, v.6, p.855-860, 1993.

ARAÚJO, F.F.S. **Distribuição da temperatura do ar mensal e anual no Estado do Rio de Janeiro baseada em modelos lineares**. 2010. 36p Monografia (Graduação em Engenharia Florestal), Universidade Federal Rural do Rio de Janeiro, Seropédica, 2010.

ARUNKUMAR, K.R.; BHASKAR, M. Heart rate estimation from wrist-type photoplethysmography signals during physical exercise. **Biomedical Signal Processing and Control**, Amsterdã, v.57, p.1-9, 2020.

AZAD, A.; KASHI, H.; FARZIN, S.; SINGH, V.P.; KISI, O.; KARAMI, H.; SANIKHANI, H. Novel approaches for air temperature prediction: A comparison of four hybrid evolutionary fuzzy models. **Meteorological Applications**, Hoboken, v.27, n.1, p.1-12, 2020.

BABA, R.K.; VAZ, M.S.M.G.; COSTA, J. Agrometeorological data correction using statistical methods. **Revista Brasileira de Meteorologia**, São José dos Campos, v.29, n.4, p.515-526, 2014.

BARBOSA, C.E.B. **Desenvolvimento de rede neural artificial para a predição da necessidade de calagem em área de pivô central**. 2020. 62f. Dissertação (Mestrado em Engenharia Agrícola), Universidade Estadual de Goiás, Anápolis, 2020.

BARDIN, L.; PEDRO JÚNIOR, M.J.; MORAES, J.F. Estimativa das temperaturas máximas e mínimas do ar para a região do circuito das frutas, SP. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.14, n.6, p.618-624, 2010.

BENALI, A.; CARVALHO, A.C.; NUNES, J.P.; CARVALHAIS, N.; SANTOS, A. Estimating air surface temperature in Portugal using MODIS LST data. **Remote Sensing of Environment**, Amsterdã, v.124, p.108-121, 2012.

BENZ, DOMINIK C.; BENETOS, G.; RAMPIDIS, G.; FELTON, E.V.; BAKULA, A.; SUSTAR, A.; KUDURA, K.; MESSERLI, M.; FUCHS, T. A.; GEBHARD, C.; PAZHENKOTTIL, A.P.; KAUFMANN, P.A.; BUECHEL, R.R. Validation of deep-learning image reconstruction for coronary computed tomography angiography: Impact on noise, image quality and diagnostic accuracy. **Journal of Cardiovascular Computed Tomography**, Charlottesville, v. 14, p.444-451, 2020.

BEZERRA, P. E. S.; MORAES, E. T. I.; SOARES, I. R. C. Análise da temperatura de superfície e do índice de vegetação no município de Belém na identificação das ilhas de calor. **Revista Brasileira de Cartografia**, Uberlândia, v.70, n.3, p.803-818, 2018.

BIANCHINI, Â. R. **Arquitetura de redes neurais para o reconhecimento facial baseado no neocognitron**. 2001. 142f. Dissertação (Mestrado em Ciência da Computação), Universidade Federal de São Carlos, São Carlos, 2004.

BINOTI, D.H.B.; BINOTI, M.L.M.S.; LEITE, H.G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira**, v.5, n.1, p.58-67, 2014.

BINOTI, M.L.M. DA S.; BINOTI, D.H.B.; LEITE, H.G. Aplicação de Redes Neurais Artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, Viçosa, v.37, n.4, p.639–645, 2013.

BINOTI, M.L.M.S.; LEITE, H.G.; BINOTI, D.H.B.; GLERIANI, J.M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Revista Cerne**, Lavras, v.21, n.1, p.97-105, 2015.

BORSATO, D.; MOREIRA, I.; NOBREGA, M.M.; MOREIRA, M.B.; DIAS, G.H. Aplicação de Redes Neurais Artificiais na identificação de gasolinas adulteradas comercializadas na região de Londrina - Paraná. **Química Nova**, São Paulo, v.32, n.9, p.2328–2332, 2009.

BOX, G.E.P.; JENKINS, G.M.; REINSEL, G.C.; LJUNG, G.M. **Time series Analysis: Forecasting and control**. 5. ed. Hoboken: Wiley & Sons, 2015. 712p.

BURIOL, G.A.; ESTEFANEL, V.; TODESCHINI, R.; SILVA, R.L.L. Variação espacial da temperatura do ar na área da bacia hidrográfica do Rio Vacacaí, RS. **Revista Brasileira de Climatologia**, Curitiba, v.17, ano. 11, p.272-281, 2015.

BITTAR, R.D.; ALVES, S.M. DE F.; F.R. DE MELO. Estimation of physical and chemical soil properties by artificial neural networks. **Revista Caatinga**, Mossoró, v.31, n.3, p.704-712, 2018.

CAJO, I.M.H.; PUCUNA, S.Y.; CAJO, B.G.H.; CAJO, D.P.H.; BENALCÁZAR, N.B.L. Estudio comparativo de los algoritmos backpropagation (BP) y múltiple linear regression (MLR) a través del análisis estadístico de datos aplicados a redes neurales artificiales. **Revista Boletín Redipe**, Cali, v.9, n.3, p.144-152, 2020.

CAMELO, H.N.; LUCIO, P.S.; LEAL JÚNIOR, J.B.V. Previsão de velocidade do vento em termos de médias mensais e horárias a partir da combinação dos modelos Holt-Winters e Redes Neurais Artificiais. **Revista Brasileira de Geografia Física**, Recife, v.10, n.5, p.1391-1405, 2017.

CARDOSO, M.R.D.; MARCUZZO, F.F.N.; BARROS, J.R. Classificação climática de Köppen-Geiger para o estado de Goiás e o Distrito Federal. **ACTA Geográfica**, Boa vista, v.8, n.16, p.40-55, 2014.

CARGNELUTTI FILHO, A.; MALUF, J.R.T.; MATZENAUER, R. Coordenadas geográficas na estimativa das temperaturas máxima e média decendiais do ar no Estado do Rio Grande do Sul. **Ciência Rural**, Santa Maria, v.38, n.9, p.2448-2456, 2008.

CARGNELUTTI FILHO, A.; MALUF, J.R.T.; MATZENAUER, R.; STOLZ, A.P. Altitude e coordenadas geográficas na estimativa da temperatura mínima média decendial do ar no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, Brasília, v.41, n.6, p.893-901, 2006.

CARMAGO, A.P.; SENTELHAS, P.C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.5, n.1, p.89-97, 1997.

CARNEVSKIS, E.L.; LOURENÇO, L.F. **Agrometeorologia e Climatologia**. 1.ed. Porto Alegre: Editora Grupo A. 2018. 228p.

CARVALHO, R.L.S.; DELGADO, A.R.S. Estimativas das modelagens por redes neurais artificiais tipo GMDH e Box-Jenkins para as séries de temperaturas máximas e mínimas do município de Ariquemes (RO). **Revista Brasileira de Climatologia**, Curitiba. v.26, ano. 16, p.326-344, 2020.

CARVALHO, R.L.S.; DELGADO, A.R.S. Estimates of reference evapotranspiration in the municipality of Ariquemes (RO) using neural networks GMDH-type. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.23, n.5, p.324-329, 2019.

CASCAES, A.M.; DOTTO, L.; BOMFIM, R.A. Tendências da força de trabalho de cirurgiões-dentistas no Brasil, no período de 2007 a 2014: estudo de séries temporais com dados do Cadastro Nacional de Estabelecimentos de Saúde. **Revista Epidemiologia e Serviços de Saúde**, Brasília, v.27, n.1, p.1-10, 2018.

CASTRO, J.O.; YANANGI JÚNIOR, T.; FERRAZ, P.F.P.; FASSANI, E.J. Comportamento de codornas japonesas submetidas a diferentes temperaturas. **Revista Energia na Agricultura**, Botucatu, v.32, n.2, p.141-147, 2017.

CELESTE, A.B.; CHAVES, V.S. Avaliação de algoritmos de otimização e funções objetivo para calibração automática do modelo chuva-vazão Tank Model. **Ciência e Natura**, Santa Maria, v.36, n.3, p.527-537, 2014.

CHAVES, M.E.D.; CONCEIÇÃO, K.V.; GUERRERO, J.V.R. Geoestatística no monitoramento da temperatura no Estado da Bahia. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, Pombal, v.13, n.5, p.652-660, 2018.

- CHOUAIBI, M.; RIGANE, K.; FERRARI, G. Extraction of *Citrullus colocynthis* L. seed oil by supercritical carbon dioxide process using response surface methodology (RSM) and artificial neural network (ANN) approaches. **Industrial Crops & Products**, Amsterdam, v.158, p.1-15, 2020.
- CHRISTIANSEN, P.; NIELSEN, L.N.; STEEN, K.A.; JORGENSEN, R.N.; KARSTOFT, H. Deep Anomaly: combining background subtraction and deep learning for detecting obstacles and anomalies in an agricultural field. **Sensors**, Basel, p. 1-21, 2016.
- COELHO, D.J.R.; TINÔCO, I.F.F.; SOUZA, C.F.; BAPTISTA, F.J.F.; BARBARI, M.; OLIVEIRA, K.P. Thermal environment of masonry-walled poultry house in the initial life stage of broilers. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 23, n.3, p.203-208, 2019.
- COHEN, J. **Statistical power analysis for the behavioral sciences**. 1.ed. Cambridge: Academic Press. 2013. 474p.
- CORREA, M.G.; TERASSI, P.M.B.; GALVANI, E. Aplicação da metodologia de estimativas da temperatura média do ar para a bacia hidrográfica do rio Piquiri-PR. **Ciência e Natura**, Santa Maria, v.39, Ed. Esp., p.99-109, 2017.
- CORREIA, T.P.; DOHLER, R.E.; DAMBROZ, C.S.; BINOTI, H.B. Aplicação de Redes Neurais Artificiais no preenchimento de falhas de precipitação mensal na região serrana do Espírito Santo. **Geociências**, São Paulo, v.35, n.4, p.560–567, 2016.
- COUTINHO, E.R.; SILVA, R.M.; DELGADO, A.R.S. Utilização de inteligência computacional na previsão de dados meteorológicos. **Revista Brasileira de Meteorologia**, São José dos Campos, v.31, n.1, p.24-36, 2016.
- COUTINHO, E.R.; SILVA, R.M.; MADEIRA, J.G.F.; COUTINHO, P.R.O.S.; BOLOY, R.A.M.; DELGADO, A.R.S. Application of artificial neural networks (ANNs) in the gap filling of meteorological time series. **Revista Brasileira de Meteorologia**, São José dos Campos, v.33, n.2, p.317-328, 2018.
- CRUZ, C.D. GENES – a software package for analysis in experimental statistics and quantitative genetics. **Acta Scientiarum Agronomy**, Maringá, v.35, n.3, p.271-276, 2013.
- DANCEY, C.P.; REIDY, J. **Estatística sem matemática**: para psicologia usando SPSS para Windows. 3.ed. Porto Alegre: Artmed, 2006. 608p.
- DITRIA, E.M.; LOPEZ-MARCANO, S.; SIEVERS, M.; JINKS, E.L. BROWN, C.J.; CONNOLLY, R.M. Automating the analysis fish abundance using object detection: optimizing animal ecology with Deep Learning. **Frontier in Marine Science**, Lausanne, v.7, p. 1-9, 2020.
- ECKLE, K.; SCHMIDT-HIEBER, J. A comparison of deep networks with ReLU activation function and linear spline-type methods. **Neural Networks**, Omaha, v.110, p.232-242, 2019.

ELY, D.F.; DUBREUIL, V. Análise das tendências espaço-temporais das precipitações anuais para o Estado do Paraná - Brasil. **Revista Brasileira de Climatologia**, Curitiba, v.21, n.13, p.553–569, 2017.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Espécies Arbóreas Brasileiras - EMBRAPA**, 2016. Disponível em: <
<https://www.cnpf.embrapa.br/pesquisa/efb/clima.htm> >. Acesso em: 20 de nov. de 2021.

ERICHSON, N.B.; MATHELIN, L.; YAO, Z.; BRUNTON, S.L.; MAHONEY, M.W.; KUTZ, J.N. Shallow neural networks for fluid flow reconstruction with limited sensors. **Proceedings of The Royal Society**, London, v.476, n.2238, p.1-25, 2020.

ESPÓSITO, D.P.; PETERNELLI, L.A.; PAULA, T.O.M.; BARBOSA, M.H.P. Análise de trilha usando valores fenotípicos e genotípicos para componentes do rendimento na seleção de famílias de cana-de-açúcar. **Ciência Rural**, Santa Maria, v.42, n.1, p.38–44, 2012.

ESTEVES, J.T.; ROLIM, G. de S.; FERRAUDO, A.S. Rainfall prediction methodology with binary multilayer perceptron neural networks. **Climate Dynamics**, Berlim, v.52, p.2319-2331, 2019.

FABRINI, F. **Projeto de um sistema de registro de sinais de neurônios em matriz de microelétrodos com ressonância estocástica**. 2019. 236f. Tese (Doutorado em Ciência da Computação), Universidade Federal de São Carlos, São Carlos, 2019.

FARIA, L.A.; PELÚZIO, J.M.; AFFÉRI, F.S.; CARVALHO, E.V.; DOTTO, M.A.; FARIA, E.A. Análise de trilha para crescimento e rendimento de genótipos de milho sob diferentes doses nitrogenadas. **Journal of Bioenergy and Food Science**, Macapá, v.2, n.1, p.1-11, 2015.

FERLIN, E.P.; REZENDE, D.A. *Big Data* aplicado à cidade digital estratégica: estudo sobre o volume de dados das aplicações *smart city*. **Revista Gestão & Tecnologia**, Pedro Leopoldo, v. 19, n. 2, p. 175-194, 2019.

FERNANDES, P.J.F.; VICENS, R.S.; FURTADO, L.F.A. Comparação de algoritmos de filtragem em séries temporais de NDVI/MODIS. **Revista Brasileira de Cartografia**, Uberlândia, v. 70, n.3, p.867-905, 2018.

FERNANDES, R.C.; WANDERLEY, H.S.; CARVALHO, A.L. Modelagem geoestatística para predição da temperatura máxima do ar utilizando modelo digital de elevação para o município de Piranhas, Alagoas. **Revista Brasileira de Geografia Física**, Recife, v.11, n.5, p.1642-1650, 2018.

FERNANDES, R.C.; WANDERLEY, H.S.; CARVALHO, A.L. Modelagem geoestatística da temperatura máxima do ar utilizando modelo digital de elevação para o município de Piranhas, Alagoas. **Revista Brasileira de Geografia Física**, Recife, v.11, n.5, p.1642-1650, 2018.

FERNEDA, E. Redes Neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**, Brasília, v.35, n.1, p.25-30, 2006.

FLECK, L.; TAVARES, M.H.F.; EYNG, E.; HELMANN, A.C.; ANDRADE, M.A.M. Redes neurais artificiais: princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, Medianeira, v.1, n.13, p.47-57, 2016.

FRANCK, C.; ZHANG, G.; DEAK, P.; ZANCA, F. Preserving image texture while reducing radiation dose with deep learning image reconstruction algorithm in chest CT: A phantom study. **Physica Medica**, Amsterdam, v.81, p.86-93, 2021.

FREITAS, T.G.G.; SILVA, P.S.L.; DOVALE, J.C.; SILVA, I.N.; SILVA, E.M. Grain yield and path analysis in the evaluation of cowpea landraces. **Revista Caatinga**, Mossoró, v.32, n.2, p.302-311, 2019.

FUJITA, O. Statistical estimation of the number of hidden units for feedforward neural networks. **Neural Networks**, Omaha, v.11, p.851-859, 1998.

FUNARI, F.L.; TARIFA, J.R. Sunshine, global radiation and net radiation in Brazil. **Revista do Instituto Geológico**, São Paulo, v.38, n.2, p.49-83, 2017.

GENG, L.; DONG, T. AN agricultural monitoring system based on wireless sensor and depth learning algorithm. **iJOE**, Kassel, v. 13, n. 12, p.127-137, 2017.

GEORGENS, E.B.; LEITE, H.G.; GLERIANI, J.M.; SOARES, C.P.B.; CEOLIN, A. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. **Revista Árvore**, Viçosa, v.38, n.2, p.289-295, 2014.

GIUFFRIDA, M.V.; DOEMES, P.; TSAFTARIS, S.A. Pheno-DEEEP Counter: a unified and versatile deep learning architecture for leaf counting. **The Plant Journal**, Hoboken, v.96, p.880-890, 2018.

GOMES, A.A.N.; ANDRADE JÚNIOR, A.S.; MEDEIROS, R.M. Evapotranspiração de referência mensal para o Estado do Piauí. **Engenharia Agrícola e Ambiental**, Campina Grande, v.9, n.4, p.560-564, 2005.

GONÇALVES, D.L.; BARELLI, M.A.A.; OLIVEIRA, T.C.; SANTOS, P.R.J.; SILVA, C.R.; POLENTINE, J.P.; NEVES, L.G. Genetic correlation and path analysis of common bean collected from Caceres Mato Grosso State, Brazil. **Ciência Rural**, Santa Maria, v.47, n.8, p.1-7, 2017.

GOSUKONDA, R.; MAHAPATRA, A.K.; EKEFRE, D.; LATIMORE JÚNIOR, M. Prediction of thermal properties of sweet sorghum bagasse as a function of moisture content using artificial neural networks and regression models. **Acta Technologica Agriculturae**, Warsaw, v.2, p.29-35, 2017.

- GUILHERME, A.P.; MOTA, A.B.S.; MOTA, D.S.; MACHADO, N.G.; BIUDES, M.S. Uso de índice de vegetação para caracterizar a mudança no uso do solo em Coari-AM. **Revista Sociedade e Natureza**, Uberlândia, v.28, n.2, p.301–310, 2016.
- GUIMARÃES, K.L.; SARMENTO, P.L.C.; MANNO, M.C.; CARVALHAL, M.V.L. Zoneamento bioclimático para produção de bovinos de leite na região sudeste da Amazônia Legal. **Publicações em Medicina Veterinária e Zootecnia**, Maringá, v.14, n.12, p.1-10, 2020.
- GUIMARÃES, M.C.C.; FURTADO, D.A.; NASCIMENTO, J.W.B.; TOTA, L.C.A.; SILVA, C.M.; LOPES, K.B. Efeito da estação do ano sobre o desempenho produtivo de codornas no semiárido paraibano. **Engenharia Agrícola e Ambiental**, Campina Grande, v.18, n.2, p.231–237, 2014.
- GUYTON, A. C.; HALL, J. E. **Tratado de fisiologia médica**. 11. ed. Rio de Janeiro: Elsevier Editora, 2006.
- HAO, X.; ZHANG, G.; MA, S. Deep Learning, **International Journal of Semantic Computing**, Singapore, v.10, n.3, p.417-439, 2016.
- HAYKIN, S. **Neural Networks and Learning Machines**. 3.ed. New Jersey: Pearson Education, 1999. 906p.
- HAYKIN, S. **Redes neurais: princípios e prática**. 2.ed. Porto Alegre: Bookman, 2001. 900p.
- HENG, L.; XIAO, F.; CHAO, L.; LONG-GUO, L.; YU-XIN, H.; NAI-WEN, L. cultivated land information extraction in UAV imagery based on deep convolutional neural network and transfer learning. **Journal of Mountain Science**, Sichuan, v.14, n.4, p.731-741, 2017.
- HIROSE, Y.; YAMASHITA, K.; HIJITA, S. Back-propagation algorithm which varies the number of hidden units. **Neural Networks**, Omaha, v.4, p.61-66, 1991.
- IIZUMI, T.; RAMANKUTTY, N. How do weather and climate influence cropping area and intensity?. **Global Food Security**, Hoboken, v.4, p.46-50, 2015.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Áreas Territoriais - IBGE**, 2020a. Disponível em: < <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura-territorial/15761-areas-dos-municipios.html?=&t=sobre> >. Acesso em: 22 de nov. de 2021.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Geociências - IBGE**, 2020b. Disponível em: < <https://www.ibge.gov.br/geociencias/downloads-geociencias.html> >. Acesso em: 20 de nov. de 2020.
- INSTITUTO NACIONAL DE METEOROLOGIA. **Banco de dados meteorológicos para ensino e pesquisa - INMET**, 2020. Disponível em: < <https://www.inmet.gov.br/> >. Acesso em: 20 de nov. de 2020.

- IVASKO JÚNIOR, S.; MASTELLA, A.D.F.; TRES, A.; TETTO, A.F.; WENDLING, W.T.; SOARES, R.V. Classificação do estado de Mato Grosso do Sul segundo sistema de zonas de vida de Holdridge. **Revista Brasileira de Climatologia**, Curitiba, v.16, ano.16, p.629-645, 2020.
- JALLAL, M.A.; GONZÁLEZ-VIDAL, A.; SKARMETA, A.F.; CHABBA, S.; ZEROUAL, A. A hybrid neuro-fuzzy inference system-based algorithm for time series forecasting Applied to energy consumption prediction. **Applied Energy**, v.268, p.1-19, 2020.
- JANATIAN, N.; SADEGHI, M.; SANAEINEJAD, S.H.; BAKSHIAN, E.; FARID, A.; HASHEMINIA, S.M.; GHAZANFARI, S. A statistical framework for estimating air temperature using MODIS land surface temperature data. **International Journal of Climatology**, Chichester, v.37, n.3, p.1181–1194, 2016.
- JAPA, R.S.L.; ORTEGA, J.L.M.; URGILÉS, W.R.C. Predicción de emisiones de CO y HC em motores otto mediante redes neurales. **Ingenius**, Cuenca, n.23, p.30-39, 2020.
- JESUS, T.C.L.; SENNA, M.C.A.; CATALDI, M.; PAIVA, C.M.; FRANZ, B. impacto do aumento da concentração atmosférica de CO₂ no balanço hídrico climatológico do Cerrado. **Revista Brasileira de Climatologia**, Curitiba, v.21, ano.13, p.313-326, 2017.
- JIANG, H.; HU, H.; ZHONG, R.; XU, J.; XU, J.; HUANG, J.; WANG, S.; YING, Y.; LIN, T. A deep learning approach to conflating heterogeneous geospatial data for corn yield estimation: A case of the US Corn Belt at the county level. **Global change Biology**, Hoboken, v.26, p.1754-1766, 2020.
- JUNGES, A.H.; BREMM, C.; FONTANA, D.C. Rainfall, climatology, variability, and trends in Veranópolis, Rio Grande do Sul, Brazil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.23, n.3, p.160-166, 2019.
- JUSTA, J.S.; SALLES, M.G.F.; PINTO, C.M.; RODRIGUES, I.C.S.; VIANA NETO, A.M. Influência do clima semiárido de Itapiúna nos parâmetros fisiológicos e produtivos de vacas mestiças. **Enciclopédia Bioesfera**, Goiânia, v.16, n.29, p.1522-1532, 2019.
- JUSTINO, E.; NÄÄS, I.A.; CARVALHO, T.M.R.; SALGADO, D.A. Efeito do resfriamento evaporativo e do balanço eletrolítico sobre lactação de porcas em condições de verão tropical. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, Belo Horizonte, v.67, n.2, p.455-464, 2015.
- KAMILARIS, A.; PRENAFETA-BOLDÚ, F. Deep Learning in agriculture: A survey. **Computers and Electronics in Agriculture**, Amsterdam, v.147, p.70-90, 2018.
- KEIEL, G.; BENDER, F.A. Modelagem de séries temporais financeiras: uma abordagem estatística para a identificação de modelos de média condicional. **Scientia Cum Industria**, Caxias do Sul, v.6, n.1, p.22-28, 2018.
- KERBAUY, G. B. **Fisiologia Vegetal**. 2 ed. São Paulo: Guanabara Koogan, 2008. 452p.

KIRBAS, I.; KEREM, A. Short-term wind speed prediction based on artificial neural network models. **Measurement and Control**, v.49, n.6, p.183-190, 2016.

KLOOG, I.; NORDIO, F.; COULL, B.A.; SCWARTZ, J. Predicting spatiotemporal mean air temperature using MODIS satellite surface temperature measurements across the Northeastern USA. **Remote Sensing of Environment**, Amsterdam, v.150, p.132–139, 2014.

KUMARI, S.; TIYYAGURA, H.R.; DOUGLAS, T.E.L.; MOHAMMED, E.A.A.; ADRIENS, A.; FUCHS-GODEC, E.; MOHAN, M.K.; SKIRTACH, A.G. ANN prediction of corrosion behaviour of uncoated and biopolymers coated cp-Titanium substrates. **Materials and Design**, Amsterdam, v.157, p.35-51, 2018.

LECUN, Y.; BENGIO, Y. Convolutional networks for images, speech, and time series. **The handbook of brain theory and neural networks**, London, v. 3361, n. 10, p.1-14, 1995.

LEE, G.; KIM, D.; KNOW, H.H.; CHOI, E. Estimation of maximum daily fresh snow accumulation using artificial neural network model. **Advances in Meteorology**, London, v.2019, p.1-11, 2019.

LI, J.; DUAN, L.; NIU, L. Method for automatic identification and classification of animal behavior based on deep learning. **Revista Científica**, Maracaibo, v.29, n.5, p.1198-1210, 2019.

LIMA, J.M.M. **Extração de características representativas para o desenvolvimento de sensores virtuais industriais: uma abordagem baseada em aprendizado profundo**. 2021. 95f. Tese (Doutorado em Ciências), Universidade Federal do Rio Grande do Norte, Natal, 2021.

LIMA, L. M.M.; VIANNA, R.P.T.; MORAES, R.M. Identificação das anomalias congênitas baseado em um modelo de decisão a partir de redes neurais artificiais. **Journal of Health Informatics**, São Paulo, v.11, n.1, p.8-12, 2019.

LIMA, L.M.M. de.; VIANNA, R.P.T.; MORAES, R.M. de. Identificação das anomalias congênitas baseado em um modelo de decisão a partir de reses neurais artificiais. **Journal of Health Informatics**, São Paulo, v.11, n.1, p.8-12, 2019.

LIN, G.; SHEN, W. Research on convolutional neural network based on improved Relu piecewise activation function. **Procedia Computer Science**, Amsterdam, v.131, p.977-984, 2018.

LIU, H.; LU, J.; FENG, J.; ZHOU, J. Group-aware deep feature learning for facial age estimation. **Pattern Recognition**, London, v.66, p.82-94, 2017.

LIU, H.; ZHOU, Q.; ZHANG, S.; DENG, X. Estimation of summer air temperature over China using Himawari-8 AHI and numerical weather prediction data. **Advances in Meteorology**, London, v.2019, p.1-11, 2019.

LIUZZO, L.; VIOLA, F.; NOTO, L.V. Wind speed and temperature trends impacts on reference evapotranspiration in Southern Italy. **Theoretical and Applied Climatology**, Berlin, v.123, n.1-2, p.43-62, 2016.

LU, H.; FU, X.; LIU, C.; LI, L.G.; HE, Y.X.; LI, N.W. Cultivated land information extraction in UAV imagery based on deep convolutional neural network and transfer learning. **Journal of Mountain Science**, Sichuan, v.14, n.4, p.731-741, 2017.

MARTIN, T.N.; DOURADO NETO, D.; STORCK, L.; BURAUUEL, P.; SANTOS, E.A. Regiões homogêneas e tamanho de amostra para atributos do clima no Estado de São Paulo, Brasil. **Ciência Rural**, Santa Maria, v.38, n.3, p.690–697, 2008.

MARTINS, F.B.; REIS, D.F.; PINHEIRO, M.V.M. Temperatura base e filocrono em duas cultivares de oliveira. **Ciência Rural**, Santa Maria, v.42, n.11, p.1975–1981, 2012.

MAY, R.; DANDY, G.; MAIER, H. **Review of Input Variable Selection Methods for Artificial Neural Networks, Artificial Neural Networks - Methodological Advances and Biomedical Applications**, Prof. Kenji Suzuki (Ed.). Shanghai: InTech, 2011.

MBA, L.; MEUKAM, P.; KEMAJOU, A. Application of artificial neural network for predicting hourly indoor air temperature and relative humidity in modern building in humid region. **Energy & Buildings**, Amsterdã, v.121, p.32–42, 2016.

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. **Agricultura e Pecuária - MAPA**, 2021. Disponível em: < <https://www.gov.br/agricultura/pt-br/assuntos/noticias/valor-bruto-da-producao-de-2021-e-o-maior-em-32-anos> >. Acesso em: 20 de nov. de 2021.

MIRANDA, J.R.; SILVA, V.C.; LOPES NETO, J.P.; NASCIMENTO, W.B.; ARAÚJO, T.G.P. Variáveis fisiológicas e desempenho produtivo como indicadores de estresse térmico em caprinos mestiços Boer em câmara climática. **Revista Energia na Agricultura**, Botucatu, v.33, n.3, p.201-206, 2018.

MONARD, M.C., BARANAUSKAS, J. A. Conceitos Sobre Aprendizado de Máquina. **Sistemas Inteligentes Fundamentos e Aplicações**. 1 ed. Barueri: Manole Ltda, 2003. 114p.

MONTANHER, O.C.; MINAKI, C. Condicionantes geográficos da temperatura do ar no Estado do Paraná. **Revista RA'EGA**, Curitiba, v.45, n.1, p.250-267, 2018.

MONTEIRO, G.C.; FISHER, G.R.; AGUIAR, L.J.G.; SCIVITTARO, W.B.; CONCEIÇÃO, L.F.C. Emissão de CO₂ em culturas de soja e arroz irrigado – Safra 2013/2014 – RS. **Revista Brasileira de Geografia Física**, Recife, v.10, n.4, p.1071-1078, 2017.

MONTEIRO, R.V.A.; CASTILLO, M.R.; GUIMARÃES, G.C.; MOURA, F.A.M.; TAMASHIRO, M.A. Avaliação de algoritmos de treinamento para redes neurais artificiais para previsão temporal de geração fotovoltaica. **Aplicaciones Industriales**, v.37, n.3, p.218-228, 2016.

- MOREIRA, A.; FONTANA, D.C.; KUPLICH, T.M.; CARDOSO, M.A. Dados meteorológicos estimados em condições de clima subtropical e a relação com índices de vegetação. **Revista Brasileira de Cartografia**, Rio de Janeiro, v.70, n.4, p.1409-1436, 2018.
- MOURA, A.R.C.; MONTENEGRO, G.L.; ANTONINO, A.C.D.; AZEVEDO, J.R.G.; SILVA, B.B.; OLIVEIRA, L.M.M. Evapotranspiração de referência baseada em métodos empíricos em bacia experimental no Estado de Pernambuco - Brasil. **Revista Brasileira de Meteorologia**, Curitiba, v.28, n.2, p.181–191, 2013.
- NARANJO, J.F.L. **Inteligência computacional aplicada na geração de respostas impulsivas bi-auriculares e em aurilização de salas**. 2014. 130f. Tese (Doutorado em Modelagem Computacional), Universidade do Estado do Rio de Janeiro, Nova Friburgo, 2014.
- NASH, J.E.; SUTCLIFFE, J.V. River flow forecasting through conceptual models part I - A discussion of principles. **Journal of Hydrology**, Amsterdã, v.10, n.3, p.282–290, 1970.
- NOGUEIRA, A.P.O.; SEDIYAMA, T.; SOUSA, L. B.; HAMAWAKI, O.T.; CRUZ, C.D.; PEREIRA, D.G.; MATSUO, E. Análise de trilha e correlações entre caracteres em soja cultivada em duas épocas de semeadura. **Bioscience Journal**, Uberlândia, v.28, n.6, p.877–888, 2012.
- NOGUEIRA, A.P.O.; SEDIYAMA, T.; SOUSA, L.B.; HAMAWAKI, O.T.; CRUZ, C.D.; PEREIRA, D.G.; MATSUO, E. Análise de trilha e correlações entre caracteres em soja cultivada em duas épocas de semeadura. **Bioscience Journal**, Uberlândia, v.28, n.6, p.877-888, 2012.
- OLAWOYIN, R. Application of backpropagation artificial neural network prediction model for the PAH bioremediation of polluted soil. **Chemosphere**, London, v.161, p.145-150, 2016.
- OLIVEIRA, B.A.S.; NAMETALA, M.S.; CASTORIAL, B.R.; CATALANO, M.D.; NAMETALA, C.A.L. Avaliação de uma Rede Neural Artificial como estimador temporal pluviométrico no sistema de abastecimento cantareira. **Revista de Informática Aplicada**, São Caetano do Sul, v.14, n.1, p.17–25, 2018.
- PACHECO, C.A.R.; PEREIRA, N.S. Deep Learning conceitos e utilização nas diversas áreas do conhecimento. **Revista Ada Lovelace**, Anápolis, v.2, p.34-49, 2018.
- PADILHA, J.B.; GROFF, P.M.; TAKAHASHI, S.E.; EINSFELD, S.; ROSA, E.O.; ANDRADE, M.; BAGATINI, A.; GERHARDS JÚNIOR, S. Importância Do ambiente térmico em produção de suínos na fase de creche. **Revista Electrónica de Veterinaria**, v. 18, n.2, p.1-11, 2017.
- PALOMARES-SALAS, J.C.; AGÜERA-PÉREZ, A.; DE LA ROSA, J.J.G.; MORENO-MUÑOZ, A. A novel neural network method for wind speed forecasting using exogenous measurements from agriculture stations. **Measurement**, Amsterdam, v.55, p.295-304, 2014.

PAPANTONIOU, S.; KOLOKOTSA, D.D. Prediction of outdoor air temperature using neural networks: Application in 4 European cities. **Energy and Buildings**, Amsterdam, v.114, p.72-79, 2016.

PARENTE, A.S.; SANTANA, A.S.R.; DINIZ, G.T.N.; OLIVEIRA, S.R.A. Indicadores de desempenho do Sistema único de Saúde: uma análise de tendência. **Revista Brasileira em Promoção da Saúde**, Fortaleza, v.33, p.1-12, 2020.

PEREIRA, A.B.; VRISMAN, A.L.; GALVANI, E. Estimativa da radiação solar global diária em função do potencial de energia solar na superfície do solo. **Scientia Agricola**, Piracicaba, v.59, n.2, p.211-216, 2002.

PEREIRA, G.H.A.; CENTENO, J.A.S. Avaliação do tamanho de amostras de treinamento para redes neurais artificiais na classificação supervisionada de imagens utilizando dados espectrais e laser scanner. **Boletim de Ciências Geodésicas**, Curitiba, v.23, n.2, p.268-283, 2017.

PETROSYAN, A.; DEREVENTSOV, A.; WEBSTER, C.G. Neural network integral representations with the ReLU activation function. **Proceedings of Machine Learning Research**, v.107, p.1-16, 2020.

PEZZOPANE, J.E.M.; SANTOS, E.A.; ELEUTÉRIO, M.M. Espacialização da temperatura do ar no Estado do Espírito Santo. **Revista Brasileira de Agrometeorologia**, Santa Maria, v.12, n.1, p.151–158, 2004.

PINHEIRO, L.S.; SILVA, R.C.; VIEIRA, R.C.; AGUIAR, R.O.; NASCIMENTO, M.R.; VIEIRA, M.M.; SOUSA, R.F.; OLIVEIRA, J.T.; SILVA, J.N.; SILVA FILHO, V.A.; SILVA, P.A. Análise de trilha dos atributos físicos de milho (*Zea mays* L.) em sistema de cultivo convencional. **Research, Society and Development**, Vargem Grande Paulista, v.10, n.1, p.1-10, 2021.

QGIS GEOGRAPHIC INFORMATION SYSTEM. **Baixar o QGIS - QGIS**, 2020. Disponível em: < https://qgis.org/pt_BR/site/forusers/download.html >. Acesso em: 25 de nov. de 2020.

RAHNEMOONFAR, m.; SHEPPARD, C. Deep count: Fruit counting based on deep simulated learning. **Sensors**, Basel, v.17, p.1-12, 2017.

RAMOS, M.F. **Estudo da variação temporal do índice de vegetação por diferença normalizada em Juiz de Fora a partir de imagens de satélite**. 2016. 39f. (Graduação em Engenharia Sanitária e Ambiental) – Faculdade de Engenharia, Universidade Federal de Juiz de Fora, Juiz de Fora, 2016.

RANZAN, L. **Metodologias para seleção de variáveis explicativas e detecção de inconformidades de predição aplicadas à espectroscopia por fluorescência**. Tese (Doutorado em Engenharia Química), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2021.

- REIS, C.J.; BEIJO, L.A.; AVELAR, F.G. Temperatura mínima esperada para Piracicaba-SP via distribuições de valores extremos. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v.11, n.4, p.1639-1650, 2017.
- REIS, L.C.; SILVA, C.M.S.; BEZERRA, B.G.; MUTTI, P.R.; SPYRIDES, M.H.C.; SILVA, P.E. Analysis of climate extreme indices in the MATOPIBA region, Brazil. **Pure and Applied Geophysics**, Basileia, v.177, p.4457-4478, 2020.
- RESENDE, G.A.; YURI, J.E.; COSTA, N.D.; GOMES, A.S.; MOTA, J.H. Desempenho produtivo de genótipos de alface crespa no Submédio do Vale do São Francisco. **Scientia Plena**, Sergipe, v.13, n.11, p.1-7, 2017.
- RESENDE, G.M.; YURI, J.E. Desempenho produtivo de cultivares de melancia em duas épocas de cultivo no Submédio do Vale do São Francisco. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v.13, n.4, p.3533-3539, 2019.
- RIOS, S.A.; BORÉM, A.; GUIMARÃES, P.E.O.; PAES, M.C.D. Análise de trilha para carotenoides em milho. **Revista Ceres**, Viçosa, v.59, n.3, p.368-373, 2012.
- ROCHA, I.J.F. **Estimativa do índice de área foliar para cultura irrigada por meio de pivô central utilizando imagens de sensoriamento remoto e redes neurais artificiais**. 2019. 126f. Dissertação (Mestrado em Engenharia Agrícola), Universidade Estadual de Goiás, Anápolis, 2019.
- ROCHA, J.V.C.; SANTOS, V.A. caracterização de mudanças climáticas na cidade do Recife utilizando séries temporais. **Revista Brasileira de Climatologia**, Curitiba, v.20, Ano.13, p.148-168, 2017.
- RODRIGUES, L.S. **Reconhecimento de caracteres manuscritos com Redes Neurais Convolucionais**. 2020. 47p Monografia (Graduação em Ciência da Computação), Fundação Educacional do Município de Assis, Assis, 2020.
- RSTUDIO: INTEGRATED DEVELOPMENT FOR R. **Download the RStudio IDE - Software R**, 2020. Disponível em: < <https://www.rstudio.com/products/rstudio/download/> >. Acesso em: 15 de out. de 2020.
- SALAZAR-GÁSCON, R.E.; FERREIRA, C.C.M. Influências do Enos e Amo entre 2003-2014 no clima e regimes de fogo na Gran Sabana, Parque Nacional Canaima, Guiana venezuelana. **Revista Brasileira de Climatologia**, Curitiba, v.22, ano.14, p.55-75, 2018.
- SALLA, V.P.; DANNER, M.A.; CITADIN, I.; SASSO, S.A.Z.; DONAZZOLO, J.; GIL, B.V. Análise de trilha em caracteres de frutos de jabuticabeira. **Pesquisa Agropecuária Brasileira**, Brasília, v.50, n.3, p.218-223, 2015.
- SANTOS, A.M.; SEIXAS, J.M.; PEREIRA, B.B.; MEDRONHO, R.A. Usando redes neurais artificiais e regressão logística na predição da hepatite A. **Revista Brasileira Epidemiol**, São Paulo, v.8, n.2, p.117-126, 2005.

SANTOS, C.V.B.; CARVALHO, H.F.S.; SILVA, M.S.B.M; GALVÍNIO, J.D. Uso de sensoriamento remoto na análise da temperatura da superfície em áreas de floresta tropical sazonalmente seca. **Revista Brasileira de Geografia Física**, Recife, v.13, n.3, p.941-953, 2020.

SANTOS, E.G.O.; BARBOSA, I.R.; SEVERO, A.K.S. Análise espaço-temporal da mortalidade por suicídio no Rio Grande do Norte, Brasil, no período de 2000 a 2015. **Ciência & Saúde Coletiva**, Rio de Janeiro, v.25, n.2, p.633-643, 2020.

SANTOS, J.L.V.; LACERDA JÚNIOR, J.A.C.; SANTOS, E.C.P.; SANTOS, G.B.; SÁ, H.M.; QUEIROZ, E.O. Avaliação dos parâmetros ambientais e fisiológicos para frangos de corte linhagem caipira em diferentes fases de criação na Amazônia Ocidental. **Brazilian Journal of Development**, Curitiba, v.6, n.8, p.61607-61622, 2020.

SANTOS, L.V.; CARVALHO, C.C.S.; RUAS, J.R.M.; DINIZ, T.A.; SILVA, E.A.; MOREIRA, S.J.M. Impacto do microclima sobre a fisiologia, pelame e produção de leite de vacas lactantes em diferentes estações do ano. **Revista de Ciências Agroveterinárias**, Lages, v.17, n.3, p.368-376, 2018.

SANTOS, M.K.; FERREIRA JÚNIOR, J.R.; WADA, D.T.; TENÓRIO, A.P.M.; BARBOSA, M.H.N.; MARQUES, P.M.A. inteligência artificial, aprendizado de máquina, diagnóstico auxiliado por computador e radiômica: avanços da imagem rumo à medicina de precisão. **Revista Radiologia Brasileira**, São Paulo, v.52, n.6, p.387-396, 2019.

SANTOS, P.A.B.; MONTI, C.A.U.; CARVALHO, L.G.; LACERDA, W.S.; SCHERZ, F. Air temperature estimation techniques in Minas Gerais state, Brazil, Cwa and Cwb climate regions according to the Köppen-Geiger climate classification system. **Ciência e Agrotecnologia**, Lavras, v.45, p.1-14, 2021.

SCHIASSI, L.; YANAGI JUNIOR, T.; FERRAZ, P.F.P.; CAMPOS, A.T.; SILVA, G.R.; ABREU, L.H.P. Comportamento de frangos de corte submetidos a diferentes ambientes térmicos. **Engenharia Agrícola**, Jaboticabal, v.35, n.2, p.390-396, 2015.

SCHMIDHUBER, J. Deep Learning in neural networks: An overview. **Neural Networks**, Omaha, v.61, p.85-117, 2015.

SHEN, H.; JIANG, Y.; LI, T.; CHENG, Q.; ZENG, C.; ZHANG, L. Deep learning-based air temperature mapping by fusing remote sensing, station, simulation, and socioeconomic data. **Remote Sensing Environment**, Amsterdam, v.240, p.1-14, 2020.

SHRESTHA, Y.R.; KRISHNA, V.; KROGH, G.V. Augmenting organizational decision-making with deep learning algorithms: Principles, promises, and challenges. **Journal of Business Research**, New York v.123, p.588-603, 2021.

SILVA JÚNIOR, M.A.B.; FONSECA NETO, G.C.; CABRAL, J.J.S.P. Análise estatística para detecção de tendências em séries temporais de temperatura e precipitação no Recife-PE. **Revista de Geografia**, Recife, v.37, n.1, p.222-240, 2020.

SILVA, D.A.P.; CAMPOS, M.C.C.; MONTOVANELLI, B.C.; SANTOS, A.C.; SOARES, M.D.R.; CUNHA, J.M. Variabilidade espacial da emissão de CO₂, temperatura e umidade do solo em área de pastagem na região Amazônica, Brasil. **Revista Ciências Agroveterinárias**, Lages, v.18, n.1, p.119-126, 2019.

SILVA, M.R.; JARDIM, C.H. Influência da topografia e uso da terra na variação dos elementos climáticos em Belo HORIZONTE, Ibirité, Sete Lagoas e Conceição do Mato Dentro – MG: O segmento temporal entre 11 a 23/06/2016. **Revista do Departamento de Geografia**, São Paulo, v. Especial – Eixo 3, p.48-57, 2017.

SILVA, T.N.; MORO, G.V.; MORO, F.V.; SANTOS, D.M.M.; BUZINARO, R. Correlation and path analysis of agronomic and morphological traits in maize. **Revista Ciência Agrônômica**, Fortaleza, v.47, n.2, p.351-357, 2016.

SILVEIRA, C.T.; OKA-FIORI, C.; SANTOS, L.J.C.; SIRTOLI, A.E.; SILVA, C.R.; BOTELHO, M.F. Soil prediction using artificial neural networks and topographic attributes. **Geoderma**, Basileia, v.195-196, p.165-172, 2013.

SILVEIRA, R.B.; ALVES, M.P.A.; BARREIRO, M.; BITENCOURT, D.P. Ondas de calor nas capitais do Sul do Brasil e Montevidéu – Uruguai. **Revista Brasileira de Geografia Física**, Recife, v.12, n.4, p.1259-1276, 2019.

SILVEIRA, V.G.; VIEIRA, K.M.; BENDER FILHO, R.; CORONEL, D.A. Análise fatorial de séries temporais para medidas de liquidez no mercado brasileiro. **RACE**, Joaçaba, v.16, n.3, p.885-910, 2017.

SOARES, E.A. **Sistemas evolutivos baseados em regras para previsões de séries temporais meteorológicas**. 2017. 78f. Dissertação (Mestrado em Engenharia de Sistemas e Automação), Universidade Federal de Lavras, Lavras, 2017.

SOARES, F.C.; ROBAINA, A.D.; PEITER, M.X.; RUSSI, J.L.; VIVAN, G.A. Redes neurais artificiais na estimativa da retenção de água no solo. **Ciência Rural**, Santa Maria, v.44, n.2, p.293-300, 2014.

SOARES, R.V. e BATISTA, A.C. **Meteorologia e Climatologia Florestal**. Curitiba: UFPR. 2004. 195p.

SONG, X.; ZHANG, G.; LIU, F.; LI, D.; ZHAO, Y.; YANG, J. Modeling spatio-temporal distribution of soil moisture by deep learning-based cellular automata model. **Journal of Arid Land**, Beijing, p. 1-15, 2016.

SOUZA, A.P.; CASAVECCHIA, B.H.; ALMEIDA, F.T.; ZOLIN, C.A.; LULU, J.; MAGALHÃES, C.A.S. Estimativas das componentes do balanço de radiação com base no coeficiente de transmissividade atmosférica. **Agrometeoros**, Passo Fundo, v.27, n.1, p.101-122, 2019.

SOUZA, A.P.; ESCOBEDO, J.F. Estimativas da radiação global incidente em superfícies inclinadas com base na razão de insolação. **Agrária**, Recife, v.8, n.3, p.483-491, 2013.

SOUZA, D.C.F.; LIMA, I.S.; SANTANA, J.A.; ALMEIDA, A.Q.; GONZAGA, M.I.S.; SANTANA, J.F. Zoneamento agroclimático da palma forrageira (*Opuntia sp.*) para o estado de Sergipe. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v.12, n.1, p.2338-2347, 2018.

SOUZA, P.J.O.P.; SANTOS, C.D.M.; SOUZA, E.B.; OLIVEIRA, E.C.; SANTOS, J.T.S. Impactos das mudanças climáticas na cultura da soja no Nordeste do estado do Pará. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v.12, n.2, p.2454-2467, 2018.

SOUZA, P.M.B.; MARTINS, F.B. Estimativa da temperatura basal inferior para as cultivares de oliveira Grappolo e Maria da Fé. **Revista Brasileira de Meteorologia**, São José dos Campos, v.29, n.2, p.307-313, 2014.

SPÖRL, C.; CASTRO, E.G.; LUCHIARI, A. Aplicação de redes neurais artificiais na construção de modelos de fragilidade ambiental. **Revista do Departamento de Geografia**, São Paulo, v.21, p.113-135, 2011.

SRDJAN SLADOJEVIC, S.; ARSENOVIC, M.; ANDERLA, A.; CULIBRK, D.; STEFANOVIC, D. Deep neural networks based recognition of plant diseases by leaf image classification. **Computational Intelligence and Neuroscience**, London, p.1-11, 2016.

STRECK, N.A. Climate change and agroecosystems: the effect of elevated atmospheric CO₂ and temperature on crop growth, development, and yield. **Ciência Rural**, Santa Maria, v.35, n.3, p.730-740, 2005.

STRECK, N.A. Climate change and agroecosystems: the effect of elevated atmospheric CO₂ and temperature on crop growth, development, and yield. **Ciência Rural**, Santa Maria, v.35, n.3, p.730-740, 2005.

SUN, S.; BAO, Z.; LI, R.; SUN, D.; GENG, H.; HUANG, X.; LIN, J.; ZHANG, P.; MA, R.; FANG, L.; ZHANG, X.; ZHAO, X. Reduction and prediction of N₂O emission from an Anoxic/Oxic wastewater treatment plant upon DO control and model simulation. **Bioresource Technology**, Amsterdam, v.244, p.800-809, 2017.

TERAMORO, E.H.; BENJUMEA, M.T.; GONÇALVES, R.D.; KIANG, C.H. Séries temporais do índice NDVI na avaliação do comportamento sazonal do Aquífero Rio Claro. **Revista Brasileira de Cartografia**, Uberlândia, v.70, n.3, p.1135-1157, 2018.

TORRES, F.T.P.; MACHADO, P.J. De O. **Introdução a Climatologia**. 1.ed. São Paulo: Cengage Learning. 2011. 256p.

TRAN, T.T.K.; LEE, T.; SHIN, J.Y.; KIM, J.S.; KAMRUZZAMAN, M. Deep learning-based maximum temperature forecasting assisted with meta-learning for hyperparameters optimization. **Atmosphere**, Basileia, v.11, n5, p.1-21, 2020.

TRES, A.; TETTO, A.F.; SOARES, R.V.; WENDLING, W.T.; MENGATTO, A.P.R. Classificação do estado de Mato Grosso segundo sistema de zonas de vida de Holdridge. **Enciclopédia Biosfera**, Goiânia, v.13, n.23, p.329-343, 2016.

UBBENS, J.; CIESLAK, M.; PRUSINKIEWICZ, P.; STAVNESS, I. The use of plant models in deep learning: an application to leaf counting in rosette plants. **Plant Methods**, Basingstoke, v.14, n.6, p.1-10, 2018.

ULIANA, E.M.; SILVA, D.D.; MOREIRA, M.C.; PEREIRA, D.R.; PEREIRA, S.B.; ALMEIDA, F.T. Desenvolvimento de Redes Neurais Artificiais para estimativa das vazões diárias na bacia do Rio Piracicaba. **Irriga**, Botucatu, v.23, n.4, p.756-772, 2018.

USGS - UNITED STATES GEOLOGICAL SURVEY. **Banco de dados de imagens de satélite**, 2019. Disponível em: < <https://www.usgs.gov/> >. Acesso em: 20 de nov. de 2019.

VALENCIA-RAMÍREZ, R.A.; LIGARRETO-MORENO, G.A. Correlación fenotípica y análisis de sendero para el rendimiento de soya (*Glycine max* L. Merrill). **Acta Agronómica**, Palmira, v.61, n.4, p.353-363, 2012.

VELHO, L.P.S.; GEMELI, M.S.; TRAVISANI, N.; PEREIRA, T.C.V.; CERUTTI, P.H.; MELO, R.C.; GUIDOLIN, A.F.; COIMBRA, J.L.M.; CORRÊA, S.C. Phenotypic correlation and direct and indirect effects of aerial part components with root distribution of common bean. **Revista Pesquisa Agropecuária Brasileira**, Brasília, v.52, n.5, p.328-334, 2017.

VIGANÓ, H.H.G.; SOUZA, C.C.; CRISTALDO, M.F.; JESUS, L. Redes neurais artificiais na previsão de queimadas e incêndio no Pantanal. **Revista Brasileira de Geografia Física**, Recife, v.10, n.5, p.1355-1367, 2017.

VIGGIANO, M.; Busetto, L.; CIMINI, D.; PAOLA, F.D.; GERALDI, E.; RANGHETTI, L.; RICCIARDELLI, E.; ROMANO, F. A new spatial modeling and interpolation approach for high-resolution temperature maps combining reanalysis data and ground measurements. **Agricultural and Forest Meteorology**, Amsterdam, v.276-277, p.1-17, 2019.

WALTER, L.C.; STRECK, N.A.; ROSA, H.T.; KRÜGER, C.A.M. Mudanças climáticas e seus efeitos na cultura do arroz. **Ciência Rural**, Santa Maria, v.40, n.11, p.2411-2418, 2010.

WALTZ, X.; BAILLOT, M.; CONNES, P.; BOCAGE, B.; RENAUDEAU, D. Effects of hydration level and heat stress on thermoregulatory responses, hematological and blood rheological properties in growing pigs. **PLOS ONE**, San Francisco, v.9, n.7, p.1-7, 2014.

WANG, P.; MA, Y.; TANG, J.; WU, D.; CHEN, H.; JIN, Z.; HUO, Z. Spring frost damage to tea plants can be identified with daily minimum air temperatures estimated MODIS Land Surface Temperature products. **Remote Sensing**, Basileia, v.13, n.6, p.1-22, 2021.

WILLMOTT, C.J.; ACKLESON, S.G.; DAVIS, R.E.; FEDDEMA, J.J.; KLINK, K.M.; LEGATES, D.R.; ROWE, C.M. Statistics for the evaluation and comparison of model. **Journal of Geophysical Research: Oceans**, Washington, v.90, n.C5, p.8995-9005, 1985.

WILLMOTT, C.J.; ROBESON, S.M.; MATSUURA, K. A refined index of model performance. **International Journal of Climatology**, London, v.32, n.13. p.2088-2094, 2012.

XAVIER, A.C.; KING, C.W.; SCANLON, B.R. Daily gridded meteorological variables in Brazil (1980-2013). **International Journal of Climatology**, Reading, v.36, p.2644-2659, 2015.

XIAO, M.; WU, Y.; ZUO, G.; FAN, S.; YU, H.; SHAIKH, Z.A.; WEN, Z. Addressing overfitting problem in deep learning-based solutions for next generation data-driven networks. **Wireless Communications and Mobile Computing**, London, v.2021, p.1-10, 2021.

XIE, Z.; HE, F.; FU, S.; SATO, I.; TAO, D.; SUGIYAMA, M. Artificial neural variability for deep learning: on overfitting, noise memorization, and catastrophic forgetting. **Neural Computation**, Cambridge, v.33, n.8, p.2163-2192, 2021.

XU, G.; ZHU, X.; FU, D.; DONG, J.; XIAO, X. Automatic land cover classification of geo-tagged field photos by deep learning. **Environmental Modelling & Software**, Amsterdam, v.91, p.127-134, 2017.

YADAV, A.K.; MALIK, H.; CHANDEL, S.S. Selection of most relevant input parameters using WEKA for artificial neural network based solar radiation prediction models. **Renewable and Sustainable Energy Reviews**, Amsterdam, v.31, p.509-519, 2014.

YAGUCHI, S.M.; MASSIGNAM, A. M.; RICCE, W. S.; PANDOLFO, C. Preenchimento de falhas de dados diários de temperatura máxima e mínima do ar. **Ciência e Natura**, Santa Maria, v.38, n.3, p.1419-1425, 2016.

YANG, Q.; SHI, L.; HAN, J.; ZHA, Y.; ZHU, P. Deep convolutional neural networks for rice grain yield estimation at the ripening stage using UAV-based remotely sensed images. **Field Crops Research**, Amsterdam, v. 235, p.142-153, 2019.

YANG, X. K.; QU, D.; ZHANG, W.L.; ZHANG, W.Q. An adapted data selection for deep learning-based audio segmentation in multi-genre broadcast channel. **Digital Signal Processing**, Kidlington, v.81, p.8-15, 2018.

YANG, Y.Z.; CAI, W.H.; YANG, J. Evaluation of MODIS land surface temperature data to estimate near-surface air temperature in Northeast China. **Remote Sensing**, Basileia, v.9, n.410, p.1-19, 2017.

YU, Y.; ADU, K.; TASHI, N.; ANOKYE, P.; WANG, X.; AYIDZOE, M. A. RMFAF: Relu-Memristor-Like activation function for deep learning. **Institute of Electrical and Electronics Engineers**, Piscataway, v.8, p.72727-72741, 2020.

ZANZARINI, F.V.; PISSARRA, T.C.T.; BRANDÃO, F.J.C.; TEIXEIRA, D.D.B. Correlação espacial do índice de vegetação (NDVI) de imagem Landsat / ETM+ com atributos do solo.

Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande, v.17, n.6, p.608–614, 2013.

ZHANG, K.; WU, Q.; LIU, A.; MENG, X. can deep learning identify tomato leaf disease?. **Advances in Multimedia**, London, p.1-10, 2018.

ZHANG, R.; RONG, Y.; TIAN, J.; SU, H.; LI, Z.L.; LIU, S. A remote sensing method for estimating surface air temperature and surface vapor pressure on a regional scale. **Remote Sensing**, Basileia, v.7, n.5, p.6005–6025, 2015.

ZHAO, X.; SHI, X.; ZHANG, S. Facial Expression recognition via deep learning. **IETE Technical Review**, London, v.32, n.5, p. 347-355, 2015.

ZHAO, Y.; WANG, D.; JOHNSON, E.M.; HEALY, E.W. A deep learning based segregation algorithm to increase speech intelligibility for hearing-impaired listeners in reverberant-noisy conditions. **Journal of Acoustical Society of America**, Melville, v.144, n.3, p.1627-1637, 2018.

ZHU, W.; LU, A.; JIA, S. Estimation of daily maximum and minimum air temperature using MODIS land surface temperature products. **Remote Sensing of Environment**, Amsterdam, v.130, p.62-73, 2013.

ZOU, L.; WANG, L.; LIN, A.; ZHU, H.; PENG, Y.; ZHAO, Z. Estimation of global solar radiation using an artificial neural network based on an interpolation technique in Southeast China. **Journal of Atmospheric and Solar-Terrestrial Physics**, Kidlington, v.146, p.110-122, 2016.

ZUFFO, A.M.; ALCÂNTARA NETO, F.; ZOZ, T.; RATKE, R.F.; AGUILERA, J.G.; TEODORO, P.E. Correlations and path analysis in agronomic traits of soybeans under defoliation. **Bioscience Journal**, Uberlândia, v.36, n.5, p.1629-1637, 2020.

APÊNDICES

APÊNDICE A – Coordenadas geográficas e código de identificação na Organização Meteorológica Mundial (OMM), de 81 estações meteorológicas localizadas no estado de Goiás, Distrito Federal, Mato Grosso do Sul e Mato Grosso.

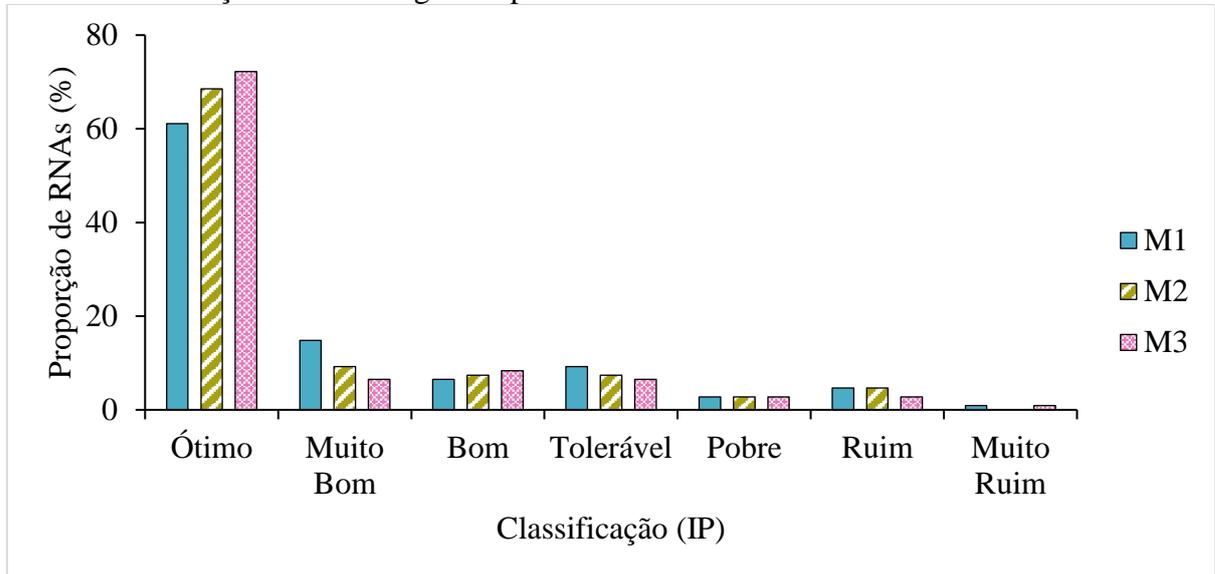
Nº	Código OMM	Cidade	Estado	Altitude (m)	Latitude (°Sul)	Longitude (°Oeste)
1	A045	Águas Emendadas	DF	1030.36	-15.60	-47.63
2	A001	Brasília	DF	1160.96	-15.79	-47.93
3	A008	Faculdade da Terra de Brasília	DF	1144.20	-15.91	-48.12
4	A046	Gama (Ponte Alta)	DF	990.00	-15.94	-48.14
5	A024	Alto Paraíso de Goiás	GO	1264.70	-14.13	-47.52
6	A013	Aragarças	GO	327.35	-15.90	-52.25
7	A023	Caiapônia	GO	740.10	-16.97	-51.82
8	A034	Catalão	GO	900.72	-18.15	-47.93
9	A036	Cristalina	GO	1211.08	-16.78	-47.61
10	A006	Crixás	GO	389.00	-14.53	-49.97
11	A007	Faina	GO	332.00	-15.43	-50.37
12	A022	Goianésia	GO	667.01	-15.22	-48.99
13	A002	Goiânia	GO	727.30	-16.64	-49.22
14	A014	Goiás	GO	512.86	-15.94	-50.14
15	A015	Itapaci	GO	551.16	-14.98	-49.54
16	A035	Itumbiara	GO	491.17	-18.41	-49.19
17	A016	Jataí	GO	670.08	-17.92	-51.72
18	A012	Luziânia	GO	1000.82	-16.26	-47.97
19	A032	Monte Alegre de Goiás	GO	551.33	-13.25	-46.89
20	A003	Morrinhos	GO	751.09	-17.75	-49.10
21	A004	Niquelândia	GO	663.53	-14.47	-48.49
22	A027	Parauna	GO	678.74	-16.96	-50.43
23	A033	Pires do Rio	GO	757.27	-17.30	-48.28
24	A005	Porangatu	GO	365.00	-13.31	-49.12
25	A017	Posse	GO	830.00	-14.09	-46.37
26	A025	Rio Verde	GO	780.11	-17.79	-50.96
27	A011	São Simão	GO	492.45	-18.97	-50.63
28	A037	Silvânia	GO	952.00	-16.68	-48.62
29	A750	Amambai	MS	433.59	-23.00	-55.33
30	A719	Aquidauana	MS	151.35	-20.48	-55.78
31	A757	Bela Vista	MS	206.09	-22.10	-56.54
32	A702	Campo Grande	MS	528.47	-20.45	-54.72
33	A730	Chapadão do Sul	MS	820.82	-18.80	-52.60
34	A724	Corumbá	MS	111.73	-19.00	-57.64
35	A720	Coxim	MS	251.48	-18.51	-54.74
36	A721	Dourados	MS	463.30	-22.19	-54.91
37	A752	Itaquiraí	MS	337.82	-23.45	-54.18
38	A709	Ivinhema	MS	377.36	-22.30	-53.82

39	A758	Jardim	MS	252.47	-21.48	-56.14
40	A749	Juti	MS	375.18	-22.86	-54.61
41	A731	Maracaju	MS	388.94	-21.61	-55.18
42	A722	Miranda	MS	132.49	-20.40	-56.43
43	A717	Nhumirim	MS	102.26	-18.99	-56.62
44	A710	Paranaíba	MS	408.06	-19.70	-51.18
45	A723	Porto Murtinho	MS	78.56	-21.71	-57.89
46	A743	Rio Brilhante	MS	324.31	-21.77	-54.53
47	A732	São Gabriel do Oeste	MS	646.00	-19.42	-54.55
48	A751	Sete Quedas	MS	398.40	-23.97	-55.02
49	A754	Sidrolândia	MS	471.43	-20.98	-54.97
50	A761	Sonora	MS	495.25	-17.64	-54.76
51	A704	Três Lagoas	MS	328.94	-20.78	-51.71
52	A908	Água Boa	MT	440.00	-14.02	-52.21
53	A924	Alta Floresta	MT	291.85	-10.08	-56.18
54	A934	Alto Taquari	MT	862.42	-17.84	-53.29
55	A927	Brasnorte (Novo Mundo)	MT	426.20	-12.52	-58.23
56	A941	Cáceres	MT	123.53	-16.07	-57.69
57	A905	Campo Novo dos Parecis	MT	525.41	-13.79	-57.84
58	A912	Campo Verde	MT	748.27	-15.53	-55.14
59	A926	Carlinda	MT	293.71	-9.97	-55.83
60	A913	Comodoro	MT	576.87	-13.71	-59.76
61	A918	Confresa	MT	233.28	-10.64	-51.57
62	A919	Contriguaçu	MT	265.00	-9.91	-58.57
63	A901	Cuiabá	MT	241.56	-15.56	-56.06
64	A930	Gaúcha do Norte	MT	375.87	-13.18	-53.26
65	A906	Guarantã do Norte	MT	283.58	-9.95	-54.90
66	A914	Juara	MT	263.43	-11.28	-57.53
67	A920	Juína	MT	365.39	-11.38	-58.77
68	A928	Nova Maringá	MT	334.36	-13.04	-57.09
69	A929	Nova Ubiratã	MT	466.48	-13.41	-54.75
70	A915	Paranatinga	MT	476.91	-14.42	-54.04
71	A937	Pontes e Lacerda	MT	272.53	-15.23	-59.35
72	A935	Porto Estrela	MT	147.75	-15.32	-57.23
73	A916	Querência	MT	360.59	-12.63	-52.22
74	A936	Salto do Céu	MT	300.83	-15.12	-58.13
75	A931	Santo Antônio do Leste	MT	664.21	-14.93	-53.88
76	A921	São Feliz do Araguaia	MT	201.37	-11.62	-50.73
77	A903	São José do Rio Claro	MT	339.59	-13.45	-56.68
78	A917	Sinop	MT	366.57	-11.98	-55.57
79	A904	Sorriso	MT	379.31	-12.56	-55.72
80	A902	Tangara da Serra	MT	440.01	-14.65	-57.43
81	A922	Vila Bela da Santíssima Trindade	MT	213.00	-15.06	-59.87

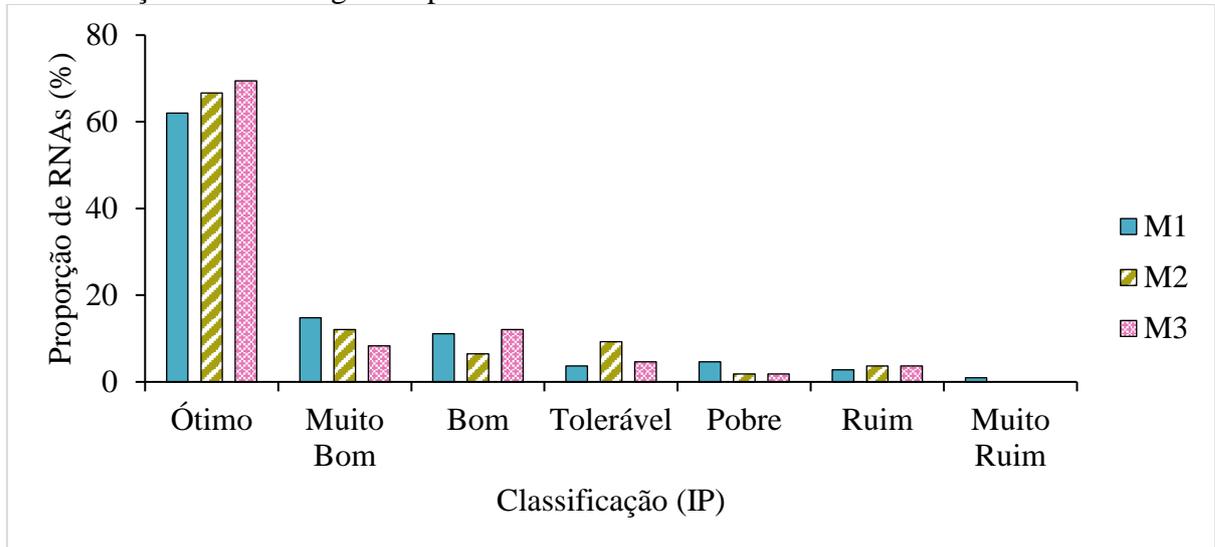
APÊNDICE B – Média do índice de Erro Médio Absoluto (EMA) para os diferentes cenários de parâmetros de entrada das RNAs (C1 – C9), modelos (M1, M2 e M3) e temperaturas médias mensais (Tmax, Tmed e Tmin), para o Centro-Oeste do Brasil com dados de 16 estações meteorológicas e período de 1990-2020.

Cenários	Média EMA (°C)								
	Tmax			Tmed			Tmin		
	M1	M2	M3	M1	M2	M3	M1	M2	M3
C1	0,64	0,63	0,63	0,55	0,55	0,58	0,61	0,56	0,61
C2	0,76	0,62	0,60	0,62	0,50	0,52	0,66	0,55	0,54
C3	0,58	0,58	0,58	0,53	0,57	0,55	0,61	0,66	0,65
C4	0,67	0,59	0,59	0,63	0,59	0,58	0,65	0,68	0,70
C5	1,11	1,08	1,02	0,95	0,96	0,89	0,84	0,83	0,79
C6	0,53	0,57	0,61	0,51	0,54	0,54	0,59	0,62	0,60
C7	1,37	1,15	1,25	1,19	0,99	1,05	1,05	0,87	0,90
C8	0,98	0,94	0,93	0,82	0,81	0,81	0,73	0,74	0,74
C9	0,91	0,87	0,86	0,78	0,76	0,75	0,77	0,74	0,73
Média	0,84	0,78	0,79	0,73	0,70	0,70	0,72	0,70	0,69

APÊNDICE C – Proporção de RNAs e classificação do índice de performance (IP) entre valores observados e estimados da temperatura máxima mensal, para o Centro-Oeste do Brasil com dados de 16 estações meteorológicas e período de 1990-2020.



APÊNDICE D – Proporção de RNAs e classificação do índice de performance (IP) entre valores observados e estimados da temperatura média mensal, para o Centro-Oeste do Brasil com dados de 16 estações meteorológicas e período de 1990-2020.



APÊNDICE E – Proporção de RNAs e classificação do índice de performance (IP) entre valores observados e estimados da temperatura mínima mensal, para o Centro-Oeste do Brasil com dados de 16 estações meteorológicas e período de 1990-2020.

