

## **Redes neurais artificiais aplicadas na estimativa do índice de área foliar utilizando imagens de sensoriamento remoto**

### **Artificial neural networks applied to estimating the leaf area index using remote sensing images**

DOI:10.34117/bjdv8n5-247

Recebimento dos originais: 21/03/2022

Aceitação para publicação: 29/04/2022

#### **Ivandro José de Freitas Rocha**

Mestre

Instituição: Faculdade Evangélica de Goianésia - FACEG

Endereço: Av. Brasil, Nº 1000, Bairro Covoá, Goianésia-GO CEP: 76.385-608

E-mail: ivandro.rocha@evangelicagoianesia.edu.br

#### **Guiliano Rangel Alves**

Mestre

Instituição: Universidade Estadual de Goiás - UEG

Endereço: Universidade Estadual de Goiás, Campus Central Anápolis, BR 153, KM 99

Zona Rural, Anápolis-GO, CEP: 75.132-903

E-mail: guiliano@gmail.com

#### **Carlos Eduardo Bento Barbosa**

Mestre

Instituição: Faculdade Anhanguera de Anápolis e Faculdade Metropolitana de Anápolis

Endereço: Residencial: Rua Morumbi quadra 8a lote 4, Jardim São Paulo- Anápolis

Goiás

E-mail: carloskun.ce@gmail.com

#### **Sueli Martins de Freitas Alves**

Doutora

Instituição: Universidade Estadual de Goiás - UEG

Endereço: Universidade Estadual de Goiás, Campus Central Anápolis, BR 153, KM 99

Zona Rural, Anápolis-GO, CEP: 75.132-903

E-mail: suelifreitas@ueg.br

#### **Francisco Ramos de Melo**

Doutor (PhD)

Instituição: Universidade Estadual de Goiás (UEG)

Endereço: Universidade Estadual de Goiás, Campus Central Anápolis, BR 153, KM 99

Zona Rural, Anápolis-GO, CEP: 75.132-903

E-mail: francisco.melo@ueg.br

#### **RESUMO**

Objetivou-se com esse estudo, obter o Índice de Área Foliar (IAF) por meio de Redes Neurais Artificiais (RNAs) tendo como dados de entrada o Índice de Vegetação por Diferença Normalizada (NDVI) obtido por meio de imagens de sensoriamento remoto. O estudo foi realizado em área comercial de 35 ha de tomate industrial, irrigado por pivô

central, no município de Vila Propício, Goiás. Os dados utilizados para o treinamento da RNA foram obtidos in loco e por sensoriamento remoto utilizando imagens dos sensores OLI/Landsat 8 e MSI/Sentinel-2 (A e B). Para universalizar a utilização da RNA escolhida, as coordenadas utilizadas no treinamento ou na entrada da rede foram obtidas pela diferença das coordenadas X e Y, e altitude de cada ponto em relação ao centro do pivô, respectivamente. Após o treinamento, foi feita a validação externa das RNAs, metodologia na qual se apresenta dados novos para a rede. A melhor RNA treinada teve o coeficiente de determinação ( $R^2$ ) geral de 0,74 e o EQM geral menor que 4%. Com base no  $R^2$  obtido entre o IAF estimado e o aferido, o emprego de sistemas computacionais inteligentes na estimativa do IAF é viável.

**Palavras-chave:** imagens orbitais, ndvi, irrigação, pivô central.

### ABSTRACT

The objective of this study was to obtain the Leaf Area Index (LAI) through Artificial Neural Networks (ANNs) having as input data the Normalized Difference Vegetation Index (NDVI) obtained through remote sensing images. . The study was carried out in a commercial area of 35 ha of industrial tomato, irrigated by central pivot, in the municipality of Vila Propício, Goiás. The data used for ANN training were obtained in loco and by remote sensing using images from the OLI/Landsat sensors. 8 and MSI/Sentinel-2 (A and B). To universalize the use of the chosen ANN, the coordinates used in the training or in the network entry were obtained by the difference of the X and Y coordinates, and the altitude of each point in relation to the center of the pivot, respectively. After training, the ANNs were externally validated, a methodology in which new data is presented to the network. The best trained ANN had an overall coefficient of determination ( $R^2$ ) of 0.74 and an overall NDE of less than 4%. Based on the  $R^2$  obtained between the estimated and measured LAI, the use of intelligent computer systems to estimate the LAI is feasible.

**Keywords:** orbital images, ndvi, irrigation, center pivot.

## 1 INTRODUÇÃO

As Redes Neurais Artificiais (RNAs) são uma representação matemática da arquitetura neural do cérebro humano, transparecendo as habilidades de aprendizagem e generalização, por isso estão classificadas no âmbito da ciência que estuda Inteligência Artificial (IA). As RNAs são bastante empregadas em pesquisas, devido às suas habilidades em modelar sistemas altamente não-lineares onde a relação entre as variáveis não é conhecida ou são muito complexas (Alves et al., 2018; Bittar et al., 2018).

Vários são os campos de estudo em que se utilizam as RNAs: na zootecnia, com o objetivo de avaliar a produção de leite (Sharma et. al., 2007), na área de produção vegetal, em que as RNAs foram utilizadas para calcular a produtividade de algumas culturas como a do milho (Kaul et. al., 2005), do trigo (Safa et. al., 2015), das bananas (Soares et. al., 2013) da soja (Alves et al., 2018). Na engenharia agrícola, as RNAs foram

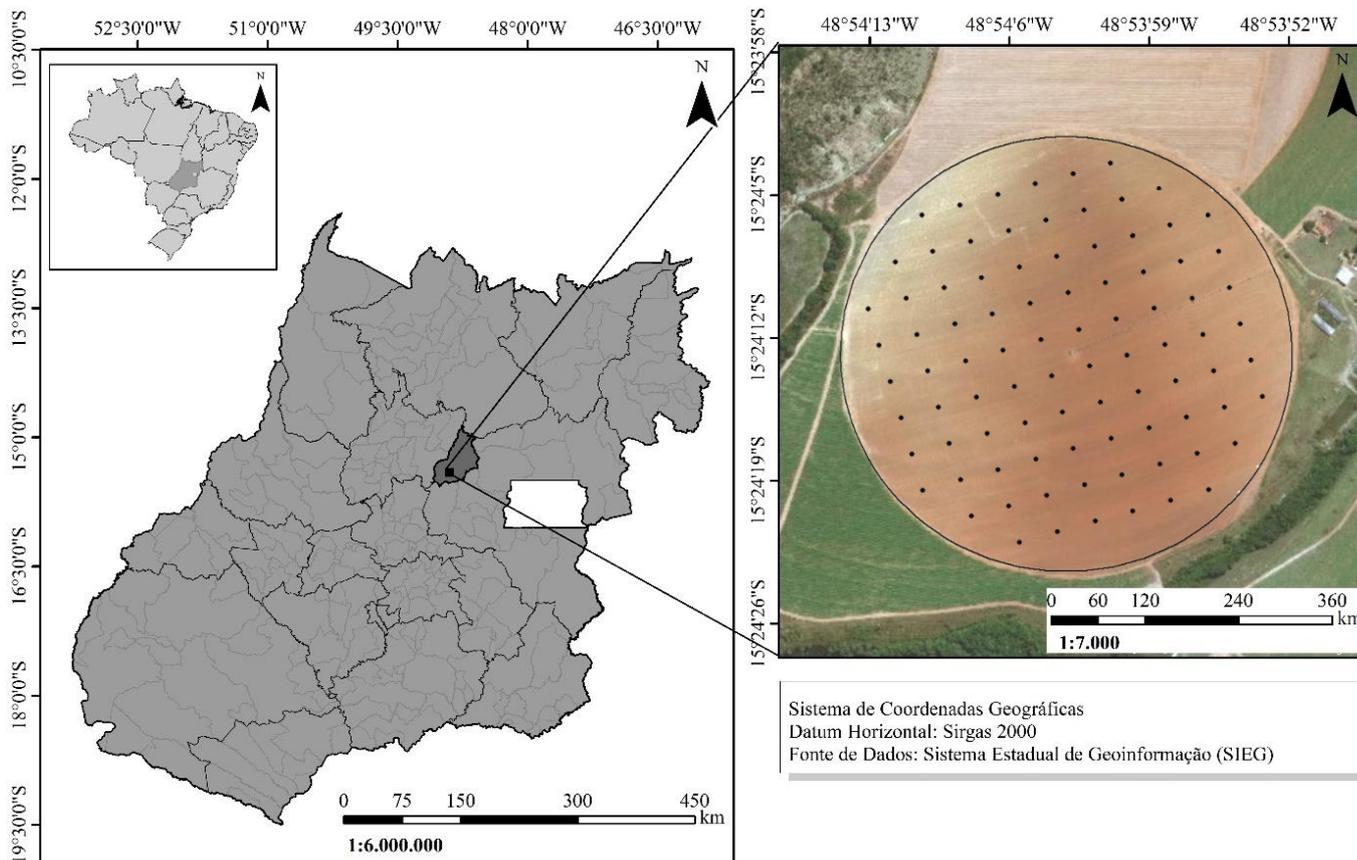
empregas com muito êxito para determinar a resistividade elétrica e térmica, classificação do solo e grau de saturação (Bittar et al., 2018).

Objetivou-se com este trabalho obter estimativas do IAF por meio de RNA. Os dados de entrada da rede foram obtidos a partir de imagens de sensoriamento remoto, bem como definir o melhor satélite para obtenção das imagens.

## 2 MATERIAL E MÉTODOS

O estudo foi realizado em uma área de 35 ha de tomate comercial irrigado por sistema de pivô central, na Vila Propício, Goiás, Brasil, localizado a  $15^{\circ} 24' 12''$  S e  $48^{\circ} 53' 59,69''$  W com altitude média de 686 m (Figura 1). O clima da região segundo o sistema de classificação climática de Köppen é AW com duas estações bem definidas: verão chuvoso e inverno seco (Referência). A temperatura média anual é de  $22,5^{\circ}$  C e a precipitação média anual é de 1.370 mm (Cardoso et al., 2014). Com base nos experimentos de Scavacini et al. (2015) e Soares et al. (2019), foi adotada uma malha amostral de 60 x 60 m, totalizando 88 pontos. A grade de amostra usou as linhas de plantio de tomate como referência.

FIGURA 1. Mapa de localização do município de Vila Propício-GO, área experimental e grade amostral.



Os solos são do tipo Cambissolo Haplic distrófico com textura argilosa. O transplante teve início em 24 de abril de 2018, em área não cultivada e coberta com palha, 30 dias após a germinação da muda. As plantas foram espaçadas de 0,30 m entre cada planta e 1,0 m entre linhas com densidade de 30 mil plantas ha. O híbrido comercial de tomate plantado foi o N901, que tem uma produção estimada de 50 frutos por planta.

Aos 76 Dias Após o Transplante (DAT), em 9 de julho de 2018, data escolhida para coincidir com a passagem do satélite e a fase de pós-floração, período de maior valor de IAF e início de decréscimo. O Número de Plantas (NP), Área Foliar (AF) e Índice de Área Foliar (IAF) foram avaliados em cada ponto da grade amostral. Uma moldura quadrada de 1,0 m<sup>2</sup> foi usada para determinar o número de plantas. Duas plantas dentro do quadro foram separadas aleatoriamente, tomando cuidado para não danificar as plantas. O Número de Folhas (NL) da primeira haste principal e hastes laterais dos ramos individuais foram contados separadamente. Dez folhas foram tiradas e fotografadas individualmente com a função de câmera em um telefone celular com resolução de 8,0 megapixels (Figura 2).

FIGURA 2. Fotografia de uma folha, retirada de um ponto amostral, usada para calcular a área foliar. A linha no canto inferior direito, medindo 2 cm de comprimento, é usada para calibração de software ImageJ.



Os dados do IAF foram obtidos por meio da razão do AF sobre a superfície do solo ocupada pela planta, representando o AF total por unidade de área (Equação 1).

$$IAF = \frac{(AF * NP)}{TA} \quad (1)$$

no qual:

IAF - índice de área foliar, m<sup>2</sup> m<sup>-2</sup>;

AF - área foliar média de duas plantas, m<sup>2</sup>;

NP - número de plantas por m<sup>2</sup>;

TA - área total considerada, 1 m<sup>2</sup>.

As imagens orbitais da área de estudo utilizadas foram obtidas pelos sensores de imagem operacional terrestre (OLI) do satélite Landsat 8, órbita 222, linha 71 e pelos sensores de instrumentos multiespectrais (MSI) dos satélites Sentinel-2A e Sentinel-2B, localizado no T22LGJ no sistema de referência da rede militar dos EUA (MGRS), as imagens foram obtidas próximo ao 76 DAT, data do início da coleta do IAF in loco (Tabela 1).

TABELA 1. Dados das passagens dos satélites na área de estudo: Identificador, satélite de origem das imagens, dias após o transplante, data e hora.

Identificador	Satélite	DAT	Data	Hora
L02	Landsat 8	69	02/07/2018	13:19:58
S02	Sentinel-2A	69	02/07/2018	13:32:25
S07	Sentinel-2B	74	07/07/2018	13:34:40
S12	Sentinel-2A	79	12/07/2018	13:36:09
S17	Sentinel-2B	84	17/07/2018	13:32:22
L18	Landsat 8	85	18/07/2018	13:20:05

Identificadores: L02, S02, S07, S12, S17 e L18 foram adotados para identificar a origem do conjunto de dados que variam de acordo com o satélite e o dia da imagem. DAT: Dias após o transplante.

As imagens passaram por um processo de refinamento para definir quais imagens podem ser usadas com base em: Visibilidade, atmosfera livre de nuvens; Qualidade de imagem do sensor, sem ruído; e, Homogeneidade do período em que as imagens foram capturadas.

Para cada imagem selecionada, a refletância da parte superior da atmosfera (TOA) foi convertida em valores de refletância da parte inferior da atmosfera (BOA) usando o arquivo de metadados que está disponível com as imagens. Este arquivo contém os parâmetros de transformação necessários para realizar a conversão de refletância de TOA em BOA.

O sistema de referência de coordenadas precisou ser convertido porque as imagens fornecidas pelo Landsat estão em WGS 84 / UTM zona 22 N e as imagens Sentinel estão em WGS 84 / UTM zona 22 S, mas no Brasil o sistema de referência oficial é o Datum SIRGAS 2000 (Geocêntrico Sistema de Referência para as Américas), o sistema de coordenadas é UTM e a área de estudo está na zona 22 S (SIRGAS, 2021).

O NDVI varia de -1 a +1 (quanto mais próximo de 1, maior a densidade da cobertura vegetal) e pode ser obtido na Equação 2, de acordo com Rouse et al. (1973):

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (2)$$

no qual:

NIR - Reflexão de faixa do infravermelho próximo;

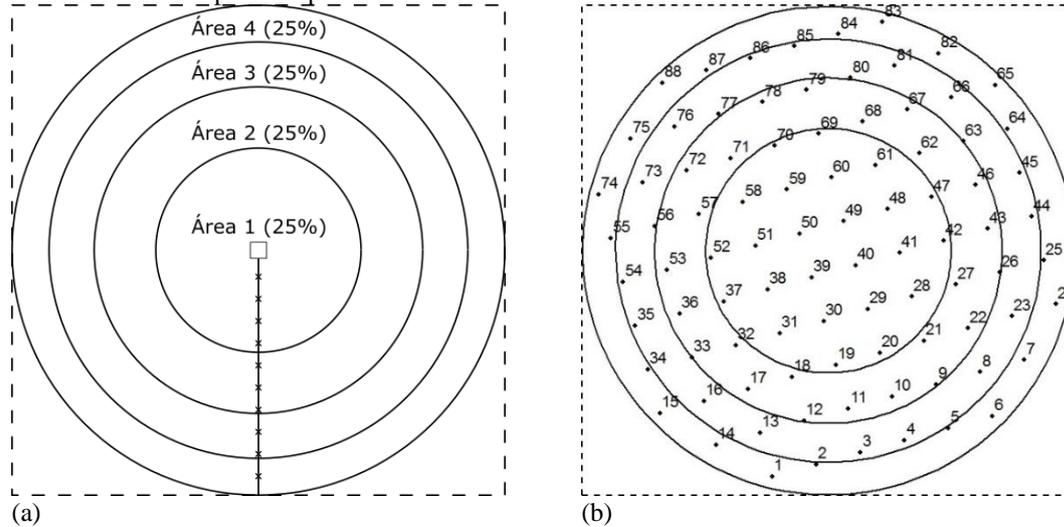
RED - refletância na faixa vermelha visível.

O NDVI foi calculado para cada data de imagem de satélite, gerando seis imagens em formato raster (Tabela 1). Os dados raster são formados por uma matriz de pixels (também conhecida como células), na qual cada pixel contém dados registrados em sua descrição que representam a condição da área coberta.

Para realizar o treinamento das RNAs foram selecionadas características dos pontos amostrais, dados dos satélites e os dados colhidos in loco, sendo as características dos pontos amostrais: coordenadas X (longitude) e Y (latitude), altitude (metros) e área na qual o ponto está localizado. Os dados obtidos por sensoriamento remoto variaram de acordo com os satélites, do Landsat 8 foram as refletâncias nas bandas 4 (vermelho) e 5 (infravermelho próximo) e o produto destas o NDVI, do Sentinel 2A e B foram refletâncias nas bandas 4 (vermelho) e 8 (infravermelho próximo) e o produto destas o NDVI, e o IAF que foi obtido in loco. Essas variáveis foram normalizadas com o objetivo de equalizar os dados de entrada da RNA (Leal et al., 2015), buscando-se assim equalizar o peso inicial que a variável possa assumir no início do treinamento.

As variáveis podem ter grandezas diferentes, o que pode dificultar ou mesmo impedir que a RNA venha a convergir, o que ocorre quando a RNA atingir a performance definida como aceitável, além da questão das grandezas diferentes também deve ser tratado o caso de variáveis que não são valores numéricos mais categorias, que é o caso da variável Área, que categoriza a qual área o ponto está localizado seguindo a distribuição ilustrada na Figura 3. A variável Área é classificada como independente, para ela é recomendado seguir o mesmo tratamento dado a variáveis do tipo *dummy* da Análise de Regressão Múltipla (Bohl et al., 2016; Sharma et al., 2007).

FIGURA 3. (a) Divisão fictícia do pivô em percentual de área; (b) Posicionamento dos pontos em relação a divisão fictícia do pivô em percentual de área.



Para as características: coordenadas X e Y, e altitude dos pontos amostrais, foi desenvolvido uma nova metodologia com o objetivo de universalizar a utilização da RNA escolhida. Nesta metodologia, a rede pode ser aplicada em outros pivôs, não ficando restrita a somente à área de estudo. Os valores de DX, DY e DA foram obtidos pela diferença das coordenadas X e Y, e altitude de cada ponto em relação ao centro do pivô, respectivamente. Como resultado do pré-processamento, foram obtidas as variáveis de entrada apresentadas na Tabela 2.

TABELA 2. Variáveis apresentadas à camada de neurônio de entrada.

Variável	Descrição	Unidade
A1, A2, A3	Referentes a área na qual está localizado o ponto dentro do pivô.	un
DX	Diferença da coordenada X (longitude) do ponto amostral em relação ao centro do pivô.	graus
DY	Diferença da coordenada Y (latitude) do ponto amostral em relação ao centro do pivô.	graus
DA	Diferença da altitude (metros) do ponto amostral em relação ao centro do pivô.	m
RED	Reflectância na banda do vermelho para ambos os satélites Landsat 8 e Sentinel 2A e B.	$\mu m$
NIR	Reflectância na banda do infravermelho próximo, para o Landsat 8 é o R05 e para o Sentinel 2A e B é o R08.	$\mu m$
NDVI	Índice de Vegetação por Diferença Normalizada	$\mu m$

Tendo os dados categorizados, a próxima etapa é a normalização dos dados das variáveis com a intenção de equalizar as variáveis de entrada na RNA (Leal et al., 2015). Os valores foram normalizados na faixa de valor entre -1 e 1 (Equação 3).

$$y = \frac{(x-x_{min})(d_2-d_1)}{x_{máx}-x_{min}} + d_1 \quad (3)$$

no qual:

y - resultado normalizado;

x - valor a ser normalizado;

$x_{\text{mín}}$  - valor mínimo de x;

$x_{\text{máx}}$  - valor máximo de x;

$d_1$  - limite inferior do resultado da normalização (-1);

$d_2$  - limite superior do resultado da normalização (1).

Para o início do desenvolvimento da RNA do tipo Multilayer Perceptron (MLP) foi definido a camada de entrada, que utilizou um neurônio para cada uma das variáveis de entrada conforme Tabela 2, e a camada de saída contendo um neurônio, representando o IAF. A camada de entrada e saída foram os primeiros parâmetros definidos para o treinamento do MLP (Alves et al., 2018; Bittar et al., 2018), pois sem a definição desses parâmetros não seria possível a criação do arquivo com os dados que foram submetidos ao programa com o objetivo de realizar o treinamento da rede.

No desenvolvimento da rede MLP (Figura 4) foram consideradas as seguintes definições: Os dados devem ser divididos de forma aleatória em três conjuntos, sendo eles treinamento (65%), validação (25%) e teste (10%) (Alves et al., 2018); Utilização do algoritmo de treinamento Levenberg-Marquardt por ser um dos mais eficientes algoritmos do tipo Backpropagation (Schiavo et al., 2015); Utilização da função de performance Erro Quadrático Médio (EQM) do inglês Mean Squared Error (MSE), conforme Equação 4, definindo a condição de parada quando o erro EQM atingir valor menor ou igual a 0,0005;

$$MSE = \frac{1}{n} \sum_{i=1}^n (E_i - O_i)^2 \quad (4)$$

no qual:

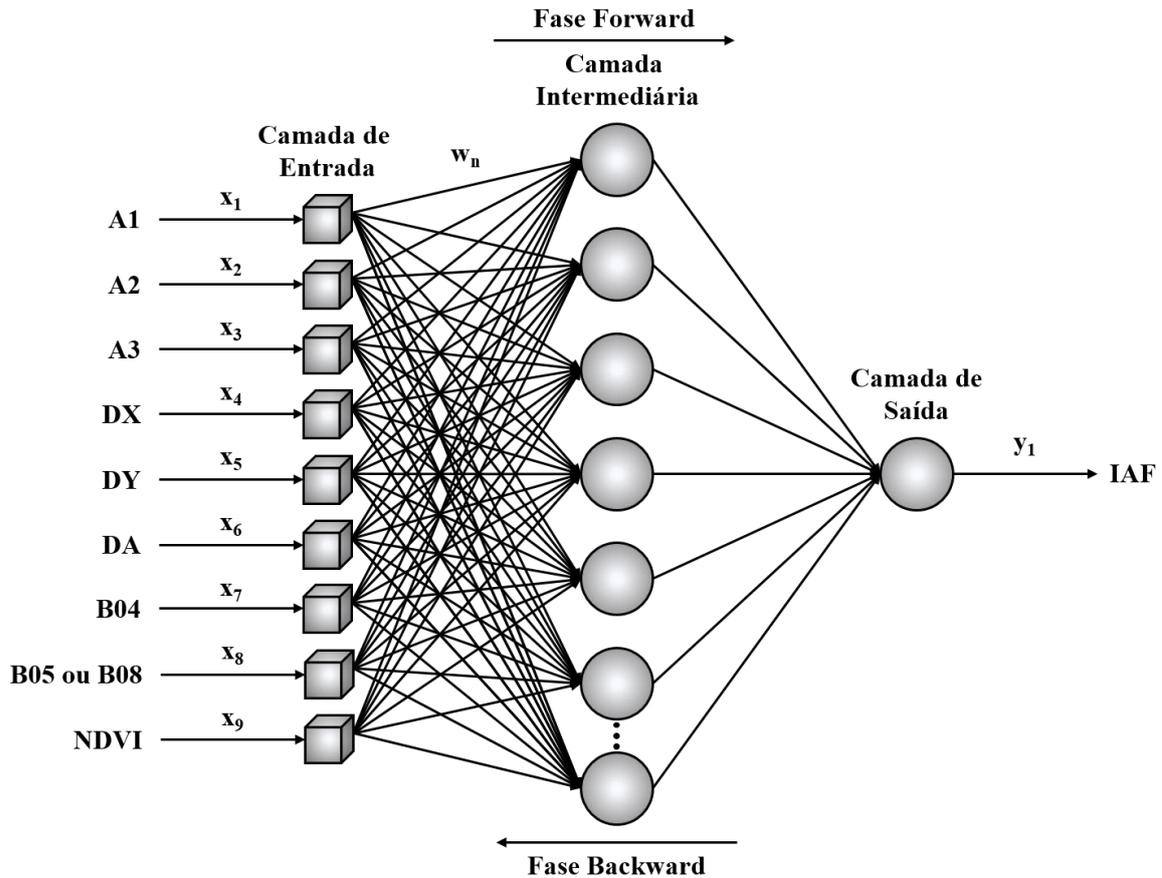
MSE - erro quadrático médio;

$E_i$  - valores estimados;

$O_i$  - valores observados;

n - quantidade de padrões de teste.

FIGURA 4. Representação da rede Multi Layer Perceptron.



Foram treinadas 120.000 (cento e vinte mil) redes, sendo 20.000 (vinte mil) para cada data de passagem dos satélites e mil redes para cada arquitetura. Nas arquiteturas variou-se o número de neurônios na camada intermediária entre 1 e 20 (Alves et al., 2018).

Após o treinamento da rede, foi feita a validação externa para as 120.000 (cento e vinte mil) redes treinadas. A validação externa consiste em comparar valores estimados pela rede, para determinados pontos, com valores que não foram apresentados para a rede na fase de treinamento. Para isto foi implementado uma função de validação, que utiliza os valores separados na função de normalização e as redes treinadas para estimar os valores de IAF e depois comparar os resultados estimados com os obtidos in loco. Após o treinamento e validação externa das redes, os valores tiveram sua grandeza original retornados de acordo com a Equação 5.

$$x = \frac{(x_{\max} - x_{\min})(y - d_1)}{d_2 - d_1} + x_{\min} \quad (5)$$

no qual:

x - valor retornado a grandeza original.;

$y$  - valor normalizado;

$x_{\text{mín}}$  - valor mínimo de  $x$ ;

$x_{\text{máx}}$  - valor máximo de  $x$ ;

$d_1$  - limite inferior do resultado da normalização (-1);

$d_2$  - limite superior do resultado da normalização (1).

Para verificação da eficiência dos valores estimados pelas RNAs, os indicadores estatísticos foram implementados: Erro médio relativo (P), Coeficiente de correlação ( $r$ ), Coeficiente de determinação ( $R^2$ ), Índice de concordância ( $c$ ) e Índice de desempenho ( $id$ ). Na tabela 3, estão apresentados os critérios de avaliação do desempenho da RNA quanto ao seu índice de desempenho, conforme Camargo e Sentelhas (1997).

TABELA 3. Análise do índice de desempenho da RNA.

Valor de $id$	Desempenho
$> 0,85$	Ótimo
$0,76 - 0,85$	Muito bom
$0,66 - 0,75$	Bom
$0,61 - 0,65$	Mediano
$0,51 - 0,50$	Sofrível
$0,41 - 0,50$	Mau
$< 0,41$	Péssimo

A seleção da melhor RNA foi feita analisando os dados dos treinamentos consolidados e das validações externas. Para determinar a rede com melhor desempenho foram utilizados os seguintes critérios:

- maior índice de desempenho ( $id$ ) no treinamento e na validação externa;
- maior coeficiente de determinação ( $R^2$ );
- menor erro médio relativo (P);
- menor erro quadrático médio (EQM).

O alto valor no índice de desempenho ( $id$ ) indica que a rede conseguiu estimar os dados apresentados na fase de treinamento e na validação externa. A rede escolhida apresentou o melhor resultado em ambas as fases. Quanto maior o valor do coeficiente de determinação ( $R^2$ ) maior é a correlação entre os dados observados e os estimados pela rede treinada. E em relação ao erro médio relativo (P) e o erro quadrático médio (EQM) quanto menor o valor de ambos, melhor será a performance da rede.

### 3 RESULTADOS E DISCUSSÕES

Dos 88 pontos amostrais coletados, foram descartados 10% dos valores tidos como *outliers*. Os valores dos 79 pontos restantes foram utilizados no treinamento (treinamento, validação e teste) e validação externa das redes MLP. Na Tabela 4, são apresentadas as variáveis de entrada específicas, para cada data de passagem dos satélites foi gerado um conjunto de dados de entrada diferente, a variável IAF foi comum a todos os conjuntos.

TABELA 4. Estatística Descritiva das variáveis específicas utilizadas no treinamento das RNAs.

Origem	DAT	Variável	Média	Mín	Máx	Desvio padrão	C.V. (%)
LandSat 8	69	RED	0,0480	0,0444	0,0930	0,0059	12
		NIR	0,5393	0,4712	0,5728	0,0164	3
		NDVI	0,8362	0,6701	0,8559	0,0227	2
	85	RED	0,0585	0,0510	0,1046	0,0079	14
		NIR	0,4910	0,4343	0,5292	0,0196	4
		NDVI	0,7866	0,6221	0,8216	0,0315	4
Sentinel-2A	69	RED	0,0476	0,0438	0,0536	0,0020	4
		NIR	0,4797	0,4374	0,5122	0,0145	3
		NDVI	0,8192	0,7871	0,8386	0,0104	1
	79	RED	0,0561	0,0506	0,0652	0,0027	5
		NIR	0,4525	0,4118	0,5016	0,0170	4
		NDVI	0,7788	0,7370	0,8140	0,0141	2
Sentinel-2B	74	RED	0,0489	0,0444	0,0564	0,0026	5
		NIR	0,4681	0,4308	0,5122	0,0150	3
		NDVI	0,8104	0,7772	0,8380	0,0125	2
	84	RED	0,0561	0,0491	0,0624	0,0028	5
		RNIR	0,4342	0,3868	0,4802	0,0176	4
		NDVI	0,7705	0,7221	0,8110	0,0157	2
<i>In loco</i>	76-78	IAF	2,6572	1,3535	4,0923	0,5389	20

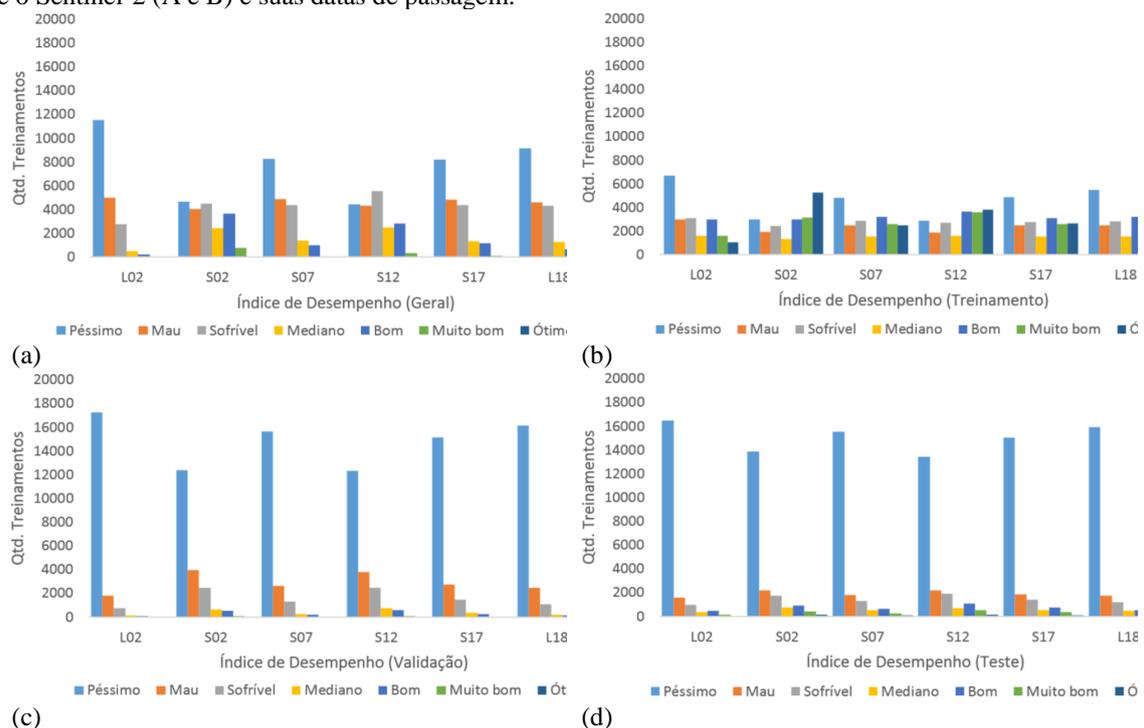
DAT: Dias após o transplântio; Mín: valor mínimo; Máx: valor máximo; C.V.: coeficiente de variação; RED: reflectância na banda do vermelho; NIR: reflectância na banda do infravermelho próximo; NDVI: índice de vegetação por diferença normalizada; IAF: índice de área foliar.

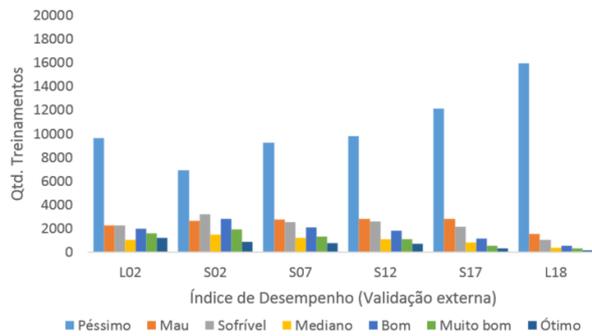
O coeficiente de variação de 20% do IAF contribuiu para o treinamento, pois a variação dos valores permite o melhor ajuste dos pesos das sinapses das conexões. O alto coeficiente de variação pode representar outliers nos dados, no entanto a utilização de redes do tipo MLP utilizando validação cruzada conseguiu lidar com esses valores evitando a influência desses no ajuste dos pesos das sinapses garantindo que a rede não modelasse os ruídos presentes nas amostras (Reed, 1993).

Dentre as 79 amostras, foram selecionadas aleatoriamente para validação externa quatro amostras: uma amostra de cada subárea do pivô. As 75 amostras restantes foram utilizadas no treinamento, o qual o algoritmo do MLP dividiu-as, de forma aleatória, em três subconjuntos: treinamento (48 amostras – 65%), validação (19 amostras – 25%) e teste (8 amostras – 10%).

Na Figura 5 é demonstrado o comparativo de desempenho das fases de treinamento (Geral, Treinamento, Validação e Teste) e validação externa, na fase de Treinamento a maioria das redes se especializou, pois tiveram boa classificação no id (Figura 5b), o que não se repete na validação (Figura 5c), no teste (Figura 5d) e na validação externa (Figura 5e), mas que acaba influenciando no id geral (Figura 5a), que apresenta resultados melhores. Resultados estes que corroboram com Alves et al. (2018), que afirma que não se pode classificar uma rede utilizando somente o id geral, pois ela pode ter um bom índice mas não ser capaz de estimar valores fora do conjunto de treinamento.

FIGURA 5. Comparativo do índice de desempenho (id) entre os dados originados dos satélites LandSat 8 e o Sentinel-2 (A e B) e suas datas de passagem.





(e)

Em relação ao comparativo dos satélites, é possível afirmar que os dados obtidos originados do Sentinel-2 (A e B) conseguiram estimar com melhor id os valores apresentados nas fases de treinamento (geral, treinamento, validação e teste) e validação externa, o que se comprova ao comparar isoladamente a classificação dos dados L02 e S02, e dos dados S17 e L18, notasse que as redes dos dados S02 e S18 tiveram melhor classificação no id geral (Figura 5a), resultado que se repete na validação externa (Figura 5e). Esses resultados ocorreram devido à resolução espacial dos satélites Sentinel-2, que é de 10 m<sup>2</sup>. Com essa resolução, a generalização do pixel é menor, 1 pixel equivale a 10 m<sup>2</sup>. à resolução do LandSat 8 é de 30 m<sup>2</sup>, sendo 1 pixel equivalente a 30 m<sup>2</sup>, detalhes da vegetação passam despercebidos nesta resolução.

Ao analisar a classificação das redes, pode-se definir um intervalo limite para que a rede treinada seja utilizada para estimar dados em outros pivôs, observando os dados dos satélites na Figura 5e, no intervalo de 69 até 79 DAP os dados são estimados com boa classificação, no 84 DAP a classificação piora, resultado que corrobora com Reis et al. (2013). Apesar do experimento de Reis ter sido feito em condições de ambiente protegido, obteve-se o mesmo resultado, o ápice do IAF ocorreu aproximadamente em 70 DAP, depois desta data a o declive do IAF.

A rede selecionada tem 12 neurônios e foi encontrada no treinamento 510. Ela necessitou de 8 ciclos para chegar à convergência estipulada no programa de treinamento (Figura 6), mas só interrompeu o treinamento no ciclo 23. O treinamento da rede neural ajustou os valores dos 12 neurônios da camada oculta e os valores dos bias de cada um, assim como do neurônio de saída. A Tabela 5 mostra os valores dos indicadores estatísticos da rede selecionada.

FIGURA 6. Representação gráfica da fase de treinamento da rede selecionada (12 neurônios e treinamento 510).

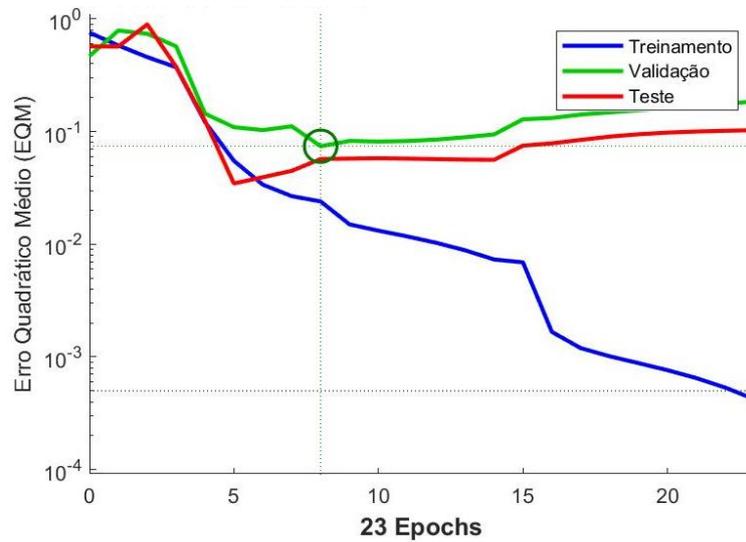


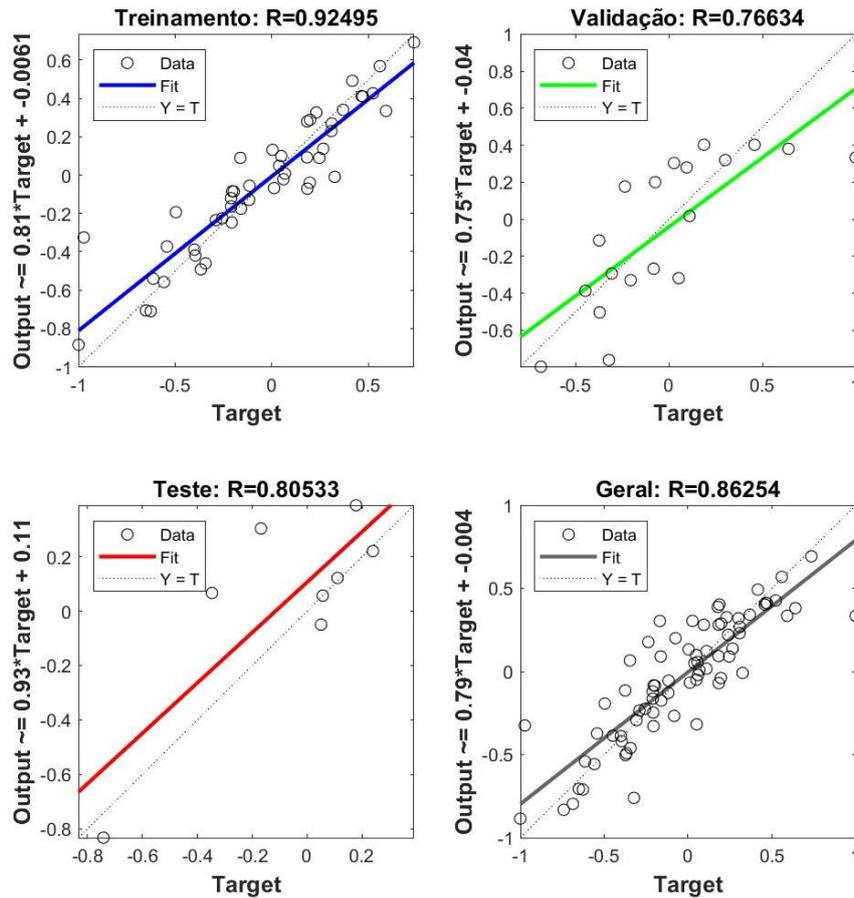
TABELA 5. Resultados dos indicadores estatísticos da rede selecionada.

Fases	Amostras	EQM	P(%)	R <sup>2</sup>	id	Classificação
Geral	75	0,040161	135,9	0,740474	0,798538	Muito bom
Treinamento	48	0,023953	126,1	0,852398	0,884635	Ótimo
Validação	19	0,074015	178,3	0,562996	0,666079	Bom
Teste	8	0,057004	93,4	0,589989	0,701841	Bom
Validação Externa	4	0,020248	343,1	0,756315	0,868461	Ótimo

EQM: Erro Quadrático Médio; P(%): Erro médio relativo; R<sup>2</sup>: Coeficiente de determinação; id: Índice de desempenho.

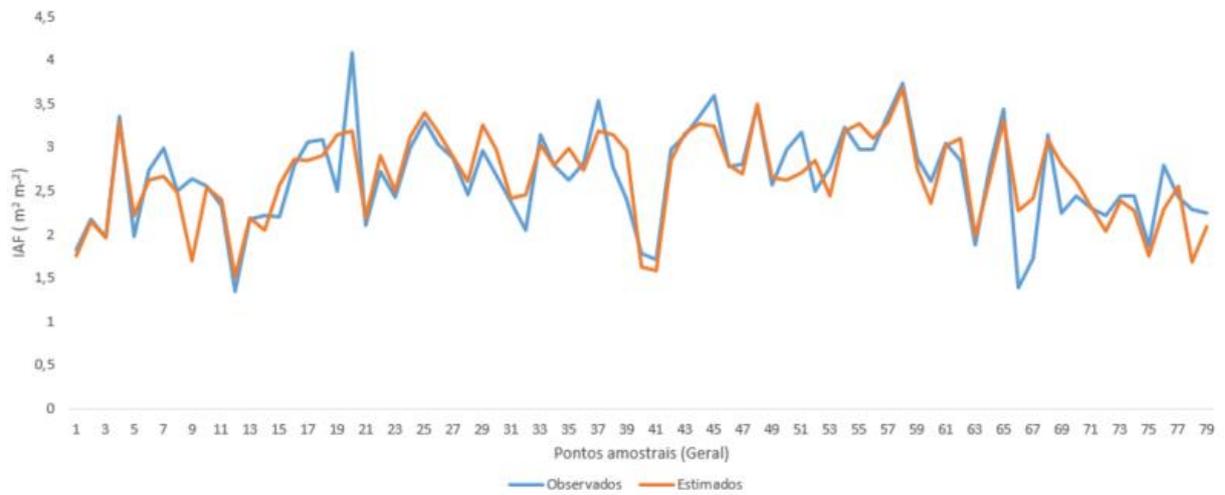
O principal critério para a escolha da rede foi a boa classificação do id em todas as fases, principalmente, na fase de validação externa, que garante que a rede tem capacidade de estimar valores com precisão. A Figura 7 mostra a representação gráfica do coeficiente de correlação (R) da rede selecionada.

FIGURA 7. Representação gráfica do coeficiente de correlação (R) da fase de treinamento (treinamento, validação, teste e geral) da rede selecionada com (12 neurônios e treinamento 510).



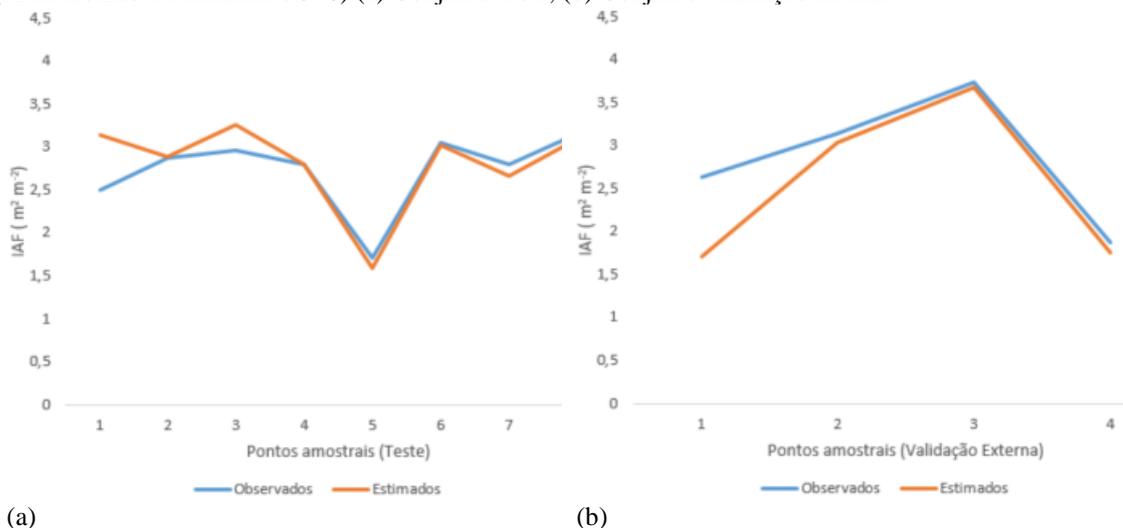
A Figura 8 mostra os valores observados em relação aos valores estimados pela rede, isto para todos os dados. A rede estimou bem os dados, visto que os valores estimados praticamente acompanham os valores observados. Pode-se afirmar ainda que mesmo removendo outliers, ainda permaneceram alguns e que, pela análise do gráfico, seriam os pontos 20 e 65, visto que os valores estimados distanciaram dos valores observados nestes pontos.

FIGURA 8. Comparativo geral dos valores observados e estimados da rede selecionada (12 neurônios e treinamento 510).



Quanto menor o conjunto de dados, maior será a influência de valores discrepantes. A Figura 9a, representa o comparativo entre os valores observados e os valores estimados na fase de teste. O ponto um é o único valor estimado que está contrário ao sentido do valor observado. Só esse ponto fez com que essa fase fosse classificada como Bom. A Figura 9b mostra o resultado da validação externa, os valores observados estão nos mesmos sentidos dos valores estimados, o que fez com que a rede fosse classificada como Ótimo.

FIGURA 9. Comparativo dos valores observados e estimados da rede selecionada (12 neurônios e treinamento 510) (a) Conjunto teste; (b) Conjunto validação externa.



#### 4 CONSIDERAÇÕES FINAIS

Com base no coeficiente de correlação obtido entre o IAF estimado e o aferido, o emprego de sistemas computacionais inteligentes na estimativa do IAF é viável.

A RNA do tipo Multilayer Perceptron (MLP) com treinamento supervisionado conseguiu estimar com assertividade acima de 70% o índice de área foliar (IAF). Utilizando as características dos pontos amostrais, dados dos satélites em função da data de passagem próxima à data de ida a campo, e os dados colhidos in loco.

A arquitetura que melhor estimou o Índice de Área foliar em área de pivô central foi de 9 neurônios na camada de entrada, 12 na camada oculta e 1 na camada de saída (9-12-1).

A metodologia utilizada para a obtenção das coordenadas X e Y, e altitude, possibilitou a universalização da RNA escolhida em relação ao pivô no qual a rede foi desenvolvida, independente da cultura.

## REFERÊNCIAS

ALVES GR, TEIXEIRA IR, MELO FR, SOUZA RTG, SILVA AG (2018) Estimativa da produtividade de soja com redes neurais artificiais. *Acta Scientiarum. Agronomy*, v40, n2. DOI: 10.4025 / actasciagron.v40i1.35250

BITTAR RD, ALVES SMD, MELO FRDE (2018) Estimation of physical and chemical soil properties by artificial neural networks. *Revista Caatinga*, v31, n3, p704–712. DOI: 10.1590 / 1983-21252018v31n320rc

BOHL MT, DIESTELDORF J, SALM CA, WILFLING B (2016) Spot market volatility and futures trading: the pitfalls of using a dummy variable approach. *Journal of Futures Markets*, v36, n1. DOI: 10.1002 / fut.21723

CAMARGO AP, SENTELHAS PC (1997) Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. *Revista Brasileira de Agrometeorologia*, v5, n1, p89-97.

CARDOSO M, MARCUZZO FFN, BARROS JR (2014) Classificação Climática de Köppen-Geiger para o Estado de Goiás e o Distrito Federal. *ACTA Geográfica, Boa Vista*, v8, n16, p40-55. DOI: 10.5654 / actageo2014.0004.0016

LEAL AJF, MIGUEL EP, BAIO FHR, NEVES DDEC, LEAL UAS (2015) Redes neurais artificiais na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do solo. *Bragantia*, v74, p436 – 444. DOI: 10.1590 / 1678-4499.0140

KAUL M, HILL RL, WALTHALL C (2005) Artificial neural networks for corn and soybean yield prediction. *Beltsville: Agricultural Systems*, v85, n1, p1–18. DOI: 10.1016 / j.agsy.2004.07.009

REED R (1993) Pruning algorithms-a survey. *IEEE Transactions on Neural Networks*, v4, n5, p740–747. DOI: 10.1109 / 72.248452

REIS LS, AZEVEDO CAVDE, ALBUQUERQUE AW, S. JUNIOR JFS (2013) Índice de área foliar e produtividade do tomate sob condições de ambiente protegido. *Campina Grande: Revista Brasileira de Engenharia Agrícola e Ambiental*, v17, n4, p386–391. DOI: 10.1590 / S1415-43662013000400005

ROUSE JW, HASS RH, SCHELL JA, DEERING DW (1973) Monitoring vegetation systems in the great plains with erts. *Third Earth Resources Technology Satellite (ERTS) symposium*. v1, p309–317.

SAFA M, SAMARASINGHE S, NEJAT M (2015) Prediction of wheat production using artificial neural networks and investigating indirect factors affecting it: case study in canterbury province, new zealand. *Journal of Agricultural Science and Technology*, v17, n4, p791–803.

SCAVACINI AT, OLIVEIRA DGDEM, MARTINS PDEO, REIS EFDOS (2015). Comportamento espacial e correlação da produtividade de tomate industrial com níveis

de potássio e teores de sólidos solúveis na cultura. XLIV Congresso Brasileiro de Engenharia Agrícola.

SCHIAVO MLO, PRINARI B, GRONSKI JA, SERIO AV (2015) An artificial neural network approach for modeling the ward atmosphere in a medical unit. *Mathematics and Computers in Simulation*, v116, p44–58. DOI: 10.1016 / j.matcom.2015.04.006

SHARMA AK, SHARMA RK, KASANA HS (2007) Prediction of first lactation 305-day milk yield in karan fries dairy cattle using ann modeling. *Applied Soft Computing Journal*, v7, n3, p1112–1120. DOI: 10.1016 / j.asoc.2006.07.002

SIRGAS - Sistema de Referência Geodésico para as Américas (2021). Disponível: <https://sirgas.ipgh.org/pt/home-pt/>. Acessado em 16 de junho de 2021.

SOARES CM, ALVES SMDEF, FREITAS EDEFM, ROCHA IJDEF, SANTOS CXDOS, FARIAS HFLDE (2019) Diagnóstico de perdas na colheita mecanizada de duas cultivares de tomate industrial. *Revista Brasileira de Ciências Agrárias*, v14, n1. DOI: 10.5039 / agraria.v14i1a5608

SOARES JDR, PASQUAL M, LACERDA WS, SILVA SO, DONATO SLR (2013) Utilization of artificial neural networks in the prediction of the bunches' weight in banana plants. *Scientia Horticulturae*, v155, p24–29. DOI: 10.1016 / j.scienta.2013.01.026