

UNIVERSIDADE ESTADUAL DE GOIÁS  
UNIDADE UNIVERSITÁRIA DE CIÊNCIAS EXATAS E TECNOLÓGICAS  
MESTRADO *STRICTO SENSU* EM ENGENHARIA AGRÍCOLA

**ESTIMATIVA DO ÍNDICE DE ÁREA FOLIAR PARA CULTURA IRRIGADA POR  
MEIO DE PIVÔ CENTRAL UTILIZANDO IMAGENS DE SENSORIAMENTO  
REMOTO E REDES NEURAIAS ARTIFICIAIS**

Ivandro José de Freitas Rocha

ANÁPOLIS – GO  
JUNHO / 2019

**ESTIMATIVA DO ÍNDICE DE ÁREA FOLIAR PARA CULTURA  
IRRIGADA POR MEIO DE PIVÔ CENTRAL UTILIZANDO  
IMAGENS DE SENSORIAMENTO REMOTO E REDES  
NEURAIS ARTIFICIAIS**

Ivandro José de Freitas Rocha

Orientadora: Profa. Dra. Sueli Martins De Freitas Alves

Co-orientador: Prof. Me. Guiliano Rangel Alves

Dissertação apresentada à Universidade Estadual de Goiás - UEG, Unidade Universitária de Ciências Exatas e Tecnológicas de Anápolis como parte das exigências do Programa de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola – Engenharia de Sistemas Agroindustriais, para obtenção do título de MESTRE.

ANÁPOLIS – GO

JUNHO / 2019

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

RR672e Rocha, Ivandro José de Freitas  
Estimativa do Índice de Área Foliar para Cultura Irrigada por meio de Pivô Central Utilizando Imagens de Sensoriamento Remoto e Redes Neurais Artificiais / Ivandro José de Freitas Rocha; orientador Sueli Martins de Freitas Alves; co-orientador Guiliano Rangel Alves. - Anápolis, 2019.  
123 p.

Dissertação (Mestrado - Programa de Pós-Graduação Mestrado Acadêmico em Engenharia Agrícola) -- Câmpus-Anápolis CET, Universidade Estadual de Goiás, 2019.

1. Ciência Agrárias. 2. Parâmetros fisiológicos da planta. 3. Radiação eletromagnética. 4. Multilayer Perceptron. I. Alves, Sueli Martins de Freitas, orient. II. Alves, Guiliano Rangel, co-orient. III. Título.

**ESTIMATIVA DO ÍNDICE DE ÁREA FOLIAR PARA CULTURA IRRIGADA  
POR MEIO DE PIVÔ CENTRAL UTILIZANDO IMAGENS DE  
SENSORIAMENTO REMOTO E REDES NEURAIS ARTIFICIAIS**

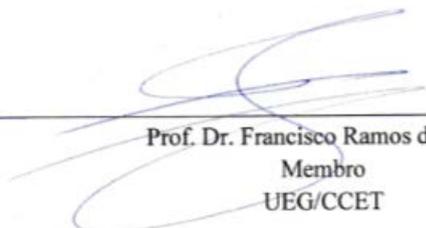
Por

Ivandro José de Freitas Rocha

Dissertação apresentada como parte das exigências para obtenção do título de  
**MESTRE EM ENGENHARIA AGRÍCOLA**

Aprovada em **28/06/2019**

  
\_\_\_\_\_  
Prof. Dra. Sueli Martins de Freitas Alves  
Orientadora  
UEG/CCET

  
\_\_\_\_\_  
Prof. Dr. Francisco Ramos de Melo  
Membro  
UEG/CCET

  
\_\_\_\_\_  
Prof. Dr. João Maurício Fernandes Souza  
Membro  
(UniEVANGÉLIA)

Aos meus familiares, em especial a meu pai, David Pereira da Rocha, e a minha mãe, Ana Maria de Freitas Rocha, que sempre incentivaram meu crescimento e acreditaram em meu potencial. À minha companheira, Letícia Sousa Silva, por todo amor, compreensão e apoio.

## AGRADECIMENTOS

Primeiramente a Deus, criador de todas coisas, que em sua imensa misericórdia e amor concedeu-me as ferramentas necessárias para que este trabalho pudesse ser concluído.

A minha estimada professora e orientadora Dra. Sueli Martins de Freitas Alves, que com a firmeza e paciência necessárias guiou-me em todo este trajeto de busca ao conhecimento. Que eu também possa contribuir para os demais profissionais com a mesma grandeza e simplicidade que lhe são admiráveis.

Ao Gestor Comercial da empresa GOIALLI, José Emivaldo de Moraes e ao diretor da Faculdade Evangélica de Goianésia, Mestre José Matheus dos Santos, pelo apoio e incentivo.

Ao produtor Robson Souza Silva e aos responsáveis técnicos Felipe Fernando Batista Silva e Nivaldo Assis de Moraes pela disponibilização da área experimental e pelas informações cedidas para realização da pesquisa.

Aos meus amigos, Cláudio Magela, Elaine de Fatima, Caroline Xavier, Sabrina Dias e Carlos Eduardo pela responsabilidade e companheirismo que sempre se fizeram presentes nesta jornada.

Aos professores: Guiliano Rangel Alves e Gustavo Henrique, por toda contribuição e orientação no desenvolvimento deste projeto.

Aos professores do mestrado. Em especial ao Prof. Dr. André José de Campos, a Profa. Dra. Roberta Passini e ao Prof. Dr. Francisco Ramos de Melo, pela humildade e prontidão às quais sempre estavam dispostos a ajudar.

Ao técnico do laboratório de Engenharia Agrícola, seu Waldeir, e à secretária do programa de mestrado, Eliete Feitosa, por todo o auxílio nas tarefas diárias.

À Universidade Estadual de Goiás - UEG, Campus de Ciências Exatas e Tecnológicas - CCET, ao departamento de Engenharia Agrícola e ao Programa de Pós-Graduação em Engenharia Agrícola.

À Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG), pela concessão da bolsa de estudos.

A todos, que de maneira direta ou indireta, contribuíram para a realização deste trabalho, meu muito obrigado, pois somente com a colaboração, de cada um, foi possível chegar ao objetivo final. Deus os abençoe imensamente!

## SUMÁRIO

	Página
<b>RESUMO</b> .....	xii
<b>ABSTRACT</b> .....	xiii
<b>1. INTRODUÇÃO</b> .....	1
<b>2. REVISÃO DE LITERATURA</b> .....	3
2.1. Irrigação por meio de pivô central .....	3
2.2. Cultura do tomate industrial .....	4
2.3. Características espectrais das folhas .....	5
2.4. Índices de Vegetação .....	6
2.4.1. Índice de Vegetação por Diferença Normalizada.....	6
2.4.2. Índice de Área Foliar .....	6
2.5. Sensoriamento remoto .....	7
2.5.1. Programa Landsat .....	7
2.5.2. Programa Copernicus .....	9
2.6. Redes Neurais Artificiais .....	11
2.6.1. Neurônio Artificial .....	11
2.6.2. Tipos de função de ativação .....	13
2.6.3. Arquitetura.....	14
2.6.4. Treinamento e aprendizagem.....	16
2.6.5. Tipos de redes.....	17
2.6.6. Normalização de variáveis.....	19
2.6.7. Aplicabilidade das Redes Neurais Artificiais.....	20
<b>3. REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	22
<b>CAPÍTULO 1</b>	
<b>SELEÇÃO DE MODELOS DE REGRESSÃO PARA ESTIMAR O ÍNDICE DE ÁREA FOLIAR UTILIZANDO IMAGENS DE SENSORIAMENTO REMOTO</b>	
<b>1. INTRODUÇÃO</b> .....	28
<b>2. MATERIAL E MÉTODOS</b> .....	32
2.1. Caracterização e localização da área de estudo .....	32
2.2. Formação da grade amostral .....	33
2.3. Características avaliadas e coleta de dados in loco.....	34
2.3.1. Contagem do número de plantas .....	34
2.3.2. Definição metodologia para calcular a área foliar.....	34
2.3.3. Obtenção da área foliar.....	37
2.3.4. Cálculo do índice de área foliar.....	38
2.4. Características avaliadas por sensoriamento remoto .....	38
2.4.1. Software e complementos.....	38

2.4.2.	Procedimentos operacionais .....	39
2.4.3.	Conversão da refletância do topo da superfície para valores de refletância da base da superfície.....	40
2.4.4.	Conversão do sistema de referência de coordenadas.....	40
2.4.5.	Cálculo do índice de vegetação por diferença normalizada .....	40
2.4.6.	Extrair valores <i>raster</i> de pontos específicos.....	41
2.4.7.	Exportar tabela de atributos par um software de planilhas eletrônicas .....	41
2.5.	Interpolação dos pontos por ponderação pelo inverso da distância.....	41
2.6.	Estatística descritiva .....	43
2.7.	Índice de área foliar em função do índice de vegetação por diferença normalizada .....	43
2.8.	Ajuste dos modelos .....	45
<b>3.</b>	<b>RESULTADOS E DISCUSSÕES .....</b>	<b>46</b>
3.1.	Características avaliadas e coleta de dados <i>in loco</i> .....	46
3.1.1.	Número de plantas por m <sup>2</sup> .....	46
3.1.2.	Área foliar.....	47
3.1.3.	Índice de área foliar obtido.....	49
3.2.	Características avaliadas por sensoriamento remoto .....	49
3.2.1.	Índice de vegetação por diferença normalizada .....	51
3.3.	Índice de área foliar em função do índice de vegetação por diferença normalizada .....	54
3.4.	Ajuste dos modelos .....	56
3.5.	Seleção do modelo .....	56
<b>4.</b>	<b>CONCLUSÕES.....</b>	<b>58</b>
<b>5.</b>	<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>59</b>

## **CAPÍTULO 2**

### **REDES NEURAIIS ARTIFICIAIS APLICADAS NA ESTIMATIVA DO ÍNDICE DE ÁREA FOLIAR UTILIZANDO IMAGENS DE SENSORAMENTO REMOTO**

<b>1.</b>	<b>INTRODUÇÃO .....</b>	<b>62</b>
<b>2.</b>	<b>MATERIAL E MÉTODOS .....</b>	<b>64</b>
2.1.	Caracterização e localização da área de estudo .....	64
2.2.	Formação da grade amostral .....	65
2.3.	Características avaliadas e coleta de dados <i>in loco</i> .....	66
2.3.1	Contagem do número de plantas .....	66
2.3.2	Obtenção da área foliar.....	66
2.3.3	Cálculo do índice de área foliar.....	68
2.4.	Características avaliadas por sensoriamento remoto .....	68
2.4.1.	Software e complementos.....	68
2.4.2.	Procedimentos operacionais .....	69
2.4.3.	Conversão da refletância do topo da superfície para valores de refletância da base da superfície.....	69
2.4.4.	Conversão do sistema de referência de coordenadas.....	70
2.4.5.	Cálculo do índice de vegetação por diferença normalizada .....	70

2.4.6.	Extrair valores <i>raster</i> de pontos específicos.....	70
2.4.7.	Exportar tabela de atributos par um software de planilhas eletrônicas .....	71
2.5.	Estatística descritiva .....	71
2.6.	Redes Neurais Artificias .....	71
2.6.1.	Recursos de informática utilizados.....	71
2.6.2.	Treinamento das RNAs .....	71
2.6.3.	Categorização e normalização das variáveis .....	72
2.6.4.	Desnormalização das variáveis.....	75
2.6.5.	Indicadores estatísticos para a escolha da RNA .....	76
2.6.6.	Desenvolvimento da Rede Neural Artificial .....	78
2.6.7.	Validação externa .....	81
2.6.8.	Seleção da melhor RNA .....	82
<b>3.</b>	<b>RESULTADOS E DISCUSSÕES</b> .....	<b>83</b>
3.1.	Exploração para treinamento .....	83
3.2.	Análise da estatística descritiva das variáveis de entrada.....	84
3.3.	Treinamento das RNAs.....	86
3.4.	Rede selecionada.....	90
<b>4.</b>	<b>CONCLUSÕES</b> .....	<b>96</b>
<b>5.</b>	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	<b>97</b>
<b>4.</b>	<b>CONCLUSÕES GERAIS</b> .....	<b>100</b>
<b>APÊNDICES</b>	.....	<b>101</b>
Apêndice A	– Calcular a área foliar usando o ImageJ .....	101
Apêndice B	– Correção atmosférica de TOA para BOA de bandas do Landsat e do Sentinel-2.....	103
Apêndice C	– Conversão do sistema de referência de coordenadas de WGS 84 para SIRGAS 2000 em imagens.....	104
Apêndice D	– Cálculo do Índice de Vegetação por Diferença Normalizada via complemento SCP .....	105
Apêndice E	– Extração de valores <i>raster</i> de pontos específicos .....	106
Apêndice F	– Exportar tabela de atributos para <i>software</i> de planilhas eletrônicas .....	107

## LISTA DE TABELAS

Página

### REVISÃO DE LITERATURA

TABELA 1 - Dados de produtividade, área e preço utilizados pela FAEG no ano de 2014. ....	3
TABELA 2 - Sensor, número, nome, resolução espectral e resolução espacial do LandSat-8..	8
TABELA 3 - Resolução espacial, número, nome, comprimento e combinações das bandas do Sentinel-2.....	9
TABELA 4 - Funções de ativação e seus respectivos gráficos. ....	13

### CAPÍTULO 1

TABELA 1 – Dias após transplântio, data, hora, e satélite de origem das imagens orbitais analisadas.....	39
TABELA 2 - Variação dos quadrantes em relação aos pontos da grade amostral, independente do satélite usado. ....	44
TABELA 3 - Identificadores dos conjuntos de dados originados dos satélites.....	51
TABELA 4 - Correlação de IAF por NDVI em diferentes distribuições dos valores em quadrantes de pixels.....	56
TABELA 5 - Resumo dos resultados da análise dos modelos de regressão e sua significância estatística para a relação IAF com o NDVI dos dados obtidos pelo satélite Sentinel-2A para o dia 12/07. ....	57

### CAPÍTULO 2

TABELA 1 – Dias após transplântio, data, hora, e satélite de origem das imagens orbitais analisadas.....	69
TABELA 2 - Valores para identificar a área em que o ponto amostral está localizado.....	72
TABELA 3 - Variáveis de entrada que são comuns para todas as redes treinadas. ....	73
TABELA 4 - Variáveis de entrada que mudam de acordo com o satélite e a data de passagem. ....	74
TABELA 5 - Análise do índice de desempenho da RNA. ....	78
TABELA 6 - Variáveis apresentadas à camada de neurônio de entrada. ....	79
TABELA 7 - Estatística Descritiva das variáveis específicas utilizadas no treinamento das RNAs. ....	85
TABELA 8 - Parâmetros utilizado para realizar treinamento da rede MLP.....	86
TABELA 9 - Identificadores dos dados de entrada da rede. ....	87
TABELA 10 - Resultados dos indicadores estatísticos da rede selecionada.....	91

## LISTA DE FIGURAS

Página

### REVISÃO DE LITERATURA

FIGURA 1 - Haste do tomateiro destacando uma folha.....	4
FIGURA 2 - Seção transversal de uma folha mostrando a distribuição dos tecidos no seu interior. ....	5
FIGURA 3 - Representação do neurônio de McCulloch e Pitts.....	12
FIGURA 4 - Representação das camadas de uma rede neural artificial. ....	14
FIGURA 5 - Representação de uma rede Feedforward (camada única). ....	15
FIGURA 6 - Representação de uma rede Feedforward (multicamadas).....	15
FIGURA 7 - Representação de uma rede recorrente.....	16
FIGURA 8 - Representação gráfica da fronteira de separação entre as duas classes de saída. ....	17
FIGURA 9 - Representação de uma rede do tipo MLP com camadas intermediárias ou ocultas. ....	18

### CAPÍTULO 1

FIGURA 1 - Mapa localizando o Município de Vila Propício-GO e o mapa da área experimental. ....	32
FIGURA 2 - Espaçamento de 0,3 m entre plantas e de 1 m entre linhas. ....	33
FIGURA 3 - Grade amostral da área experimental. ....	33
FIGURA 4 - Estaca marcando o primeiro ponto da grade amostral. ....	34
FIGURA 5 - Medidor foliar a laser portátil modelo LICOR (CI-202).....	35
FIGURA 6 - Folha composta por diferentes níveis de folíolos e com a presença de duas lacunas. ....	35
FIGURA 7 - Mesa de policloreto de polivinila (PVC) desenvolvida para tirar fotos no campo. ....	37
FIGURA 8 - Folha tirada do ponto 87,8° amostra, no canto inferior direito, reta medindo 2,1 cm de comprimento que é utilizada para calibração do software.....	38
FIGURA 9 - (a) Interpolação por ponderação pelo inverso da distância é baseada na distância ponderada de um ponto amostral. (b) Superfície interpolada a partir de pontos da grade amostral. ....	42
FIGURA 10 - Geração da superfície raster a partir da interpolação dos dados obtidos nos pontos amostrais. ....	42
FIGURA 11 - Transplante mecanizado de mudas.....	46
FIGURA 12 – Densa área foliar do tomateiro.....	47
FIGURA 13 - (a) Interpolação por IDW da AF em relação aos pontos da grade amostral; (b) histograma dessa distribuição.....	48
FIGURA 14 - (a) Interpolação por IDW da IAF em relação aos pontos da grade amostral; (b) histograma dessa distribuição.....	49
FIGURA 15 - NDVI gerado pelo satélite Landsat 8 com data de passagem 02/07/2018 e escala de 1:10000.....	50

FIGURA 16 - NDVI gerado pelo satélite Sentinel-2A com data de passagem 02/07/2018 e escala de 1:10000.....	50
FIGURA 17 - NDVI dos dias (a) 02 e (b) 18 de julho de 2018 do satélite Landsat 8 em função dos pontos da grade amostral.....	52
FIGURA 18 - NDVI dos dias (a) 02, (b) 07, (c) 12 e (d) 17 de julho de 2018 do satélite Sentinel-2 em função dos pontos da grade amostral. ....	53
FIGURA 19 - Comportamento do NDVI em função da área foliar de diferentes coberturas vegetais. ....	54
FIGURA 20 - Diagrama de dispersão entre valores de IAF e NDVI extraídos do LandSat 8 (a) dia 02/07; (b) dia 18/07. ....	55
FIGURA 21 - Diagrama de dispersão entre valores de IAF e NDVI extraídos do Sentinel-2 (A e B): (a) dia 02/07; (b) dia 07/07; (c) dia 12/07 e (d) dia 17/07. ....	55
FIGURA 22 - Diagrama de dispersão entre os valores de IAF medidos e estimados pelos modelos de regressão ajustados para plantios de tomate industrial.....	57

## CAPÍTULO 2

FIGURA 1 - Mapa localizando o Município de Vila Propício-GO e o mapa da área experimental. ....	64
FIGURA 2 - Espaçamento de 0,3 m entre plantas e de 1 m entre linhas. ....	65
FIGURA 3 - Grade amostral da área experimental. ....	65
FIGURA 4 - Estaca marcando o primeiro ponto da grade amostral. ....	66
FIGURA 5 - Mesa de policloreto de polivinila (PVC) desenvolvida para tirar fotos no campo. ....	67
FIGURA 6 - Folha tirada do ponto 87,8º amostra, no canto inferior direito, reta medindo 2,1 cm de comprimento que é utilizada para calibração do software.....	67
FIGURA 7 - (a) Divisão fictícia do pivô em percentual de área; (b) Posicionamento dos pontos em relação a divisão fictícia do pivô em percentual de área.....	72
FIGURA 8 - Obtenção dos valores das variáveis DX, DY e DA, pela diferença dos valores das coordenadas X e Y, e altitude dos pontos amostrais em relação ao centro do pivô.....	73
FIGURA 9 - Representação da rede Multi Layer Perceptron. ....	81
FIGURA 10 - Interface gráfica do programa criado para agilizar a utilização das funções desenvolvidas neste estudo. ....	83
FIGURA 11 - Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados do LandSat 8 (a) dia 02/07; (b) dia 18/07. ...	87
FIGURA 12 - Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados do Sentinel-2 A e B (a) dia 02/07; (b) dia 07/07; (c) dia 12/07; (d) dia 17/07.....	88
FIGURA 13 - 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.....	89
FIGURA 14 - Representação gráfica da fase de treinamento da rede selecionada (12 neurônios e treinamento 510). ....	91
FIGURA 15 - 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). ....	92
FIGURA 16 - Comparativo geral dos valores observados e estimados da rede selecionada (12 neurônios e treinamento 510). ....	93

FIGURA 17 - Comparativo do conjunto treinamento dos valores observados e estimados da rede selecionada (12 neurônios e treinamento 510). .....	93
FIGURA 18 - Comparativo do conjunto validação dos valores observados e estimados da rede selecionada (12 neurônios e treinamento 510). .....	94
FIGURA 19 - Comparativo dos valores observados e estimados da rede selecionada (12 neurônios e treinamento 510) (a) Conjunto teste; (b) Conjunto validação externa.....	94

## Estimativa do Índice de Área Foliar para Cultura Irrigada por meio de Pivô Central Utilizando Imagens de Sensoriamento Remoto e Redes Neurais Artificiais

### RESUMO

A irrigação tornou-se uma das principais ferramentas que possibilitaram o aumento da produtividade no mundo. O sistema de irrigação por pivô central é um dos mais utilizados no Estado de Goiás. São 3.326 equipamentos instalados no Estado, com uma área total irrigada de 242.872,58 ha. As principais culturas cultivadas em pivô são: soja, milho, tomate industrial e outras culturas. Para o desenvolvimento deste trabalho foi escolhida uma área comercial de 35 ha de tomate industrial, irrigado por pivô central, no município de Vila Propício - GO. A escolha da cultura do tomate industrial deu-se por ela apresentar densa área foliar e ser de grande importância comercial para o Estado, que devido aos investimentos na produção de tomate industrial aumentou o volume de produção levando o Estado a ocupar, desde 2008, o 1º lugar no ranking nacional de produção de tomate. O objetivo do trabalho é a obtenção do Índice de Área Foliar (IAF) do tomateiro, característica fisiológica que está diretamente relacionada à capacidade produtiva. Foram comparados dois métodos de obtenção do IAF: O primeiro, por ajustes nos modelos de regressão entre o IAF coletado *in loco* e o Índice de Vegetação por Diferença Normalizada (NDVI) obtido por meio de imagens de sensoriamento remoto. O segundo método, por Redes Neurais Artificiais (RNAs), no qual se utilizou os mesmos dados da regressão como variável de entrada no treinamento das redes. Para a coleta das amostras foi utilizando uma grade amostral de 60x60 m com 88 pontos georreferenciados, por dois meios: *In loco* utilizando uma armação com área de 1 m<sup>2</sup> e por sensoriamento remoto utilizando imagens dos satélites Landsat 8 e Sentinel-2. Os dados coletados *in loco* foram número de plantas e área foliar, ambos por m<sup>2</sup>, que serviram para calcular o IAF. Os dados coletados por sensoriamento remoto foram imagens georeferenciada, que foram tratadas com o objetivo de extrair valores para o cálculo do NDVI. O melhor modelo de regressão teve o Coeficiente de Determinação (R<sup>2</sup>) de 0,67 e o Erro Quadrático Médio (EQM) menor que 11%. A melhor rede treinada teve o R<sup>2</sup> geral de 0,74 e o EQM geral menor que 4%. Conclui-se que os valores de IAF do tomateiro, cultivado em pivô central, podem ser estimados por ambos os métodos: Modelo de regressão e RNA, ambos tendo como principal variável de entrada o NDVI derivado de sensoriamento remoto.

**Palavras Chave:** Tomate industrial; Pontos georreferenciados; Landsat 8; Sentinel-2; Índice de Vegetação por Diferença Normalizada.

## Estimation of Leaf Area Index for Irrigated Culture through Central Pivot Using Remote Sensing Images and Artificial Neural Networks

### ABSTRACT

Irrigation has become one of the main tools that made possible an increase in productivity in the world. The center pivot irrigation system is one of the most used in the state of Goiás. They are 3,326 equipment installed in the state, with a total irrigated area of 242,872.58 ha. The main cultures are grown on pivot soybean, corn, tomato and other industrial crops. For the development of this work was chosen a commercial area of 35 ha of industrial tomatoes, irrigated by center pivot in the municipality of Vila Propício - GO. The choice of the industrial tomato crop took place in that it has dense leaf area and be of great commercial importance to the state, which due to investments in the production of industrial tomatoes increased the volume of production leading the state to occupy since 2008 1st place in the national tomato production ranking. The objective is to obtain the Leaf Area Index (LAI) of tomato, physiological characteristic that is directly related to production capacity. We compared two methods of obtaining the LAI: First, by setting the regression models between LAI collected in situ and Normalized Difference Vegetation Index (NDVI) is obtained by means of remote sensing images. The second method, Artificial Neural Networks (ANN), which was used the same data as input variable regression in training networks. For Samples were collected using a sampling grid of 60x60 m to 88 georeferenced points by two means: In situ using a frame with an area of 1 m<sup>2</sup> and remote sensing images using Landsat 8 and the Sentinel-2. The data collected in situ were number of plants and leaf area, both per m<sup>2</sup>, which served to calculate the IAF. The data collected by remote sensing images were georeferenced, which have been treated in order to extract values for calculating the NDVI. The best regression model was the Coefficient of Determination ( $r^2$ ) of 0.67 and Root Mean Square Error (RMSE) of less than 11%. The best trained network had the general  $r^2$  of 0.74 and the overall RMSE less than 4%. It follows that the tomato LAI, grown in central pivot, can be estimated by both methods: Regression Model and ANN, both with the main input variable derived NDVI remote sensing.

**Keywords:** Industrial tomato; georeferenced points; Landsat 8; Sentinel-2; Normalized Difference Vegetation Index.

## 1. INTRODUÇÃO

Nas últimas décadas, as mais importantes alterações no ambiente global foram promovidas pela agropecuária, em parceria com os expressivos avanços científicos e tecnológicos (MATSON, 1997). Por meio dessas alterações, está sendo possível suprir a demanda de alimentos causada pelo crescimento populacional global (BARRETTO et al., 2013).

A irrigação se tornou uma das principais ferramentas que possibilitaram o aumento da produtividade no mundo. Segundo a Organização das Nações Unidas para Agricultura e Alimentação (do inglês *Food and Agriculture Organization of the United Nations* - FAO), no ano de 2011, as áreas irrigadas ocupavam 20% da área arável e era responsável por 47% da produção global. De acordo com Darko et al. (2016), no ano 2030 a atividade de irrigação terá alcançado a marca de 40% da área arável, devendo ocorrer, principalmente, nos países em desenvolvimento. Essa perspectiva de expansão se deve ao processo de intensificação da agropecuária, por meio de grandes investimentos em pivôs.

Segundo Landau et al. (2013), o sistema de irrigação por pivô central é um dos mais utilizados para o cultivo de soja, milho, tomate industrial e outras culturas no Estado de Goiás. São 3.326 equipamentos instalados no Estado, com uma área total irrigada de 242.872,58 ha, o que corresponde a 0,62% do território goiano (IMB, 2017). Dentre as culturas cultivadas em pivô, o tomate industrial apresenta maior produtividade e o melhor preço de venda (ALVES JÚNIOR et al., 2017), o que contribui significativamente na economia do Estado. Os investimentos em tomate industrial levaram Goiás a ocupar, desde 2008, o 1º lugar no ranking nacional de produção de tomate (FAO, 2017; IBGE, 2018).

A Agricultura de Precisão (AP) é outra ferramenta que possibilitou o aumento da produtividade global. Ela trouxe um novo conceito de tratamento da lavoura, o que antes era tratado de forma homogênea, passa a ser tratado como Unidades de Gestão Diferenciada (UGDs), e a amostragem georeferenciada é a ferramenta utilizada para delimitar as unidades. Por meio dela, se define os pontos de coleta de amostra, e a partir da avaliação de apenas uma pequena porção representativa do mesmo para caracterizar a variabilidade espacial dos atributos do solo e das plantas. A partir das amostragens obtém-se dados que serão utilizados para auxiliar na tomada de decisões permitindo o manejo de uma área isolada (MOLIN et al., 2015).

Um dos principais elementos observados para avaliar a adaptabilidade das culturas às condições de manejo é a Área Foliar (AF). O crescimento dela gera o aumento da capacidade da planta em aproveitar a energia solar, com o objetivo de realizar a fotossíntese e, desta forma, pode-se avaliar a produtividade ( REIS et al., 2013; ALMEIDA et al., 2015; SOARES et al., 2015). Os modelos matemáticos que estimam o Índice de Área Foliar (IAF) podem ser obtidos de forma direta, método destrutivo, ou indiretamente, método não destrutivo (BLANCO e FOLEGATTI, 2003; BRÉDA, 2003; WEISS et al., 2004). Os métodos não destrutivos têm como princípio modelos empíricos de estimação, exemplo, os que relacionam valores de IAF com os Índices de Vegetação (IVs) (DORIGO et al., 2007; XAVIER e VETTORAZZI, 2004; COHEN et al., 2003).

As obtenções dos IVs podem ser feitos a partir de sensores multiespectrais, que permitem quantificar a variação da energia refletida e absorvida pelas folhas e, consequentemente, o comportamento espectral da vegetação. Isto ocorre devido à combinação de valores de diferentes regiões do espectro eletromagnético, nas faixas do vermelho (V) e infravermelho próximo (IVP). Rouse et al. (1973) propôs o Índice de Vegetação por Diferença Normalizada (do inglês *Normalized Difference Vegetation Index* - NDVI) que remete a parâmetros biofísicos da cobertura vegetal, como biomassa, IAF, vigor vegetativo, atividade fotossintética e produtividade (OLIVEIRA et al., 2016; EIPHANIO et al., 1996).

O NDVI tem se mostrado altamente relacionado com o IAF em diferentes tipos de vegetação (GAMEIRO et al., 2016; ALMEIDA et al., 2015; BRAZ et al., 2015; PEREIRA et al., 2015). No entanto tem apresentado, em alguns casos, sensibilidade às variações do solo, não identificando as características e as mudanças ocorridas na cobertura vegetal, e ainda apresenta saturação para valores elevados de IAF (ALMEIDA et al., 2015; SANTOS et al., 2013; RIO et al., 2007; SIMÕES, 2004).

A tecnologia de inteligência artificial é outra ferramenta da AP, pois fornece métodos alternativos que são cada vez mais usados e produzem resultados bem-sucedidos em estudos de estimativa em comparação com métodos convencionais. Estudos mostraram que o método da Rede Neural Artificial (RNA), quando usado no campo agrícola, produz resultados altamente satisfatórios (ALVES et al., 2018; KÜÇÜKÖNDER et al., 2016; SOARES et al., 2015).

Objetivou-se com este trabalho definir um modelo preditivo para estimar o IAF do tomate industrial irrigado por pivô central, por meio de análise de modelos de regressão e RNAs, em que foram avaliadas o IAF medido *in loco* e o NDVI obtido por sensoriamento remoto.

## 2. REVISÃO DE LITERATURA

### 2.1. Irrigação por meio de pivô central

No Estado de Goiás, a irrigação teve início nos idos de 1984, com a ocupação das áreas aráveis pela irrigação por pivôs centrais, e devido à enorme riqueza de recursos hídricos vem se expandindo de forma sólida (PEREIRA JÚNIOR et al., 2017). O bioma Cerrado tem como uma das principais características o clima, com um longo período de chuvas, de novembro a março, e um longo período de estiagem, de abril a outubro (CARDOSO et al., 2014), julho e agosto são os meses de seca mais severa, chegando à taxa de precipitação de 0 mm.

A utilização dos pivôs centrais é uma das principais tecnologias empregadas para superar o longo período de estiagem no cerrado. Isso era uma barreira para a produção agrícola superintensiva. Devido a essa necessidade, o sistema de irrigação por meio de pivô central é um dos mais utilizados. Suas características: sistema motomecanizado, capacidade para irrigação de grandes áreas, o que possibilita a automação e quimigação, promove uniformidade de aplicação e facilita a sucessão de culturas, por não precisar ser removido durante os ciclos das culturas (plantio, tratos culturais e colheita) (CARVALHO e OLIVEIRA, 2012).

As principais culturas cultivadas em pivô central na região do Cerrado são: a soja, o milho e o tomate industrial. O comparativo das culturas pode ser feito utilizando os valores aceitos e utilizados pela Federação da Agricultura e Pecuária de Goiás (FAEG) para financiamentos (FEDERAÇÃO, 2014). As projeções são feitas utilizando-se os dados de produtividade, área e preço, conforme Tabela 1.

TABELA 1 - Dados de produtividade, área e preço utilizados pela FAEG no ano de 2014.

Culturas	Produtividade (kg.ha <sup>-1</sup> )	Área (ha)	Preço (kg <sup>-1</sup> )
Soja	4.200	80,78	R\$ 0,18
Milho	12.000	80,78	R\$ 0,25
Tomate industrial	80,78	80,78	R\$ 0,95

Fonte: Alves Júnior et al. (2017).

## 2.2. Cultura do tomate industrial

O tomate industrial (*Solanum lycopersicum* L) é uma das culturas mais importantes de Goiás, o que o torna responsável por 75% da produção nacional e o maior consumidor de produtos derivados do tomate na América do Sul (EMBRAPA, 2006; SILVA et al., 2015; IBGE, 2018). A cultura tem grande importância social e econômica devido ao seu valor nutricional, altos teores de vitaminas A, C, rico em licopeno e de boa aceitabilidade tanto para o consumo do tomate chamado de mesa (*in natura*), assim como para o consumo da linha de atomatados (molhos prontos, extratos, catchup, sopas, sucos e etc.) (HACKMANN e BARBIERI, 2018).

O tomateiro é uma planta com características herbáceas, de porte arbustivo, possui um caule piloso e flexível, com muitas ramificações laterais, que podem ser modificadas pela prática da poda. É considerada perene, mas é cultivada como anual (Figura 1) (PEIXOTO et al., 2017).



FIGURA 1 - Haste do tomateiro destacando uma folha.

Fonte: Pixabay (2019) (Modificada).

Pode-se desenvolver de forma rasteira, semi-ereta ou ereta, apresenta dois hábitos de crescimento:

- **Determinado:** apresentam um crescimento vegetativo menos vigoroso, em que as plantas se desenvolvem de forma rasteira e os frutos destinados à agroindústria, atingem a altura de 0,5 m (PEIXOTO et al., 2017).
- **Indeterminado:** produzem frutos destinados ao consumo *in natura*. As gemas destas plantas possuem um menor desenvolvimento devido à dominância da gema apical, um vigoroso crescimento vegetativo juntamente com a produção de flores e frutos, podendo chegar a 10 m de altura em um ano (PEIXOTO et al., 2017).

### 2.3. Características espectrais das folhas

As características espectrais das folhas estão relacionadas ao desenvolvimento da planta, pois as mesmas são em função de sua composição química, morfologia e estrutura interna. As folhas são constituídas por diferentes tecidos (Figura 2), entre eles a face ventral revestida pela cutícula e a epiderme, seguido pelo mesófilo paliçádico, mesófilo esponjoso, novamente epiderme e cutícula (SILVA et al., 2012; PONZONI et al., 2012).

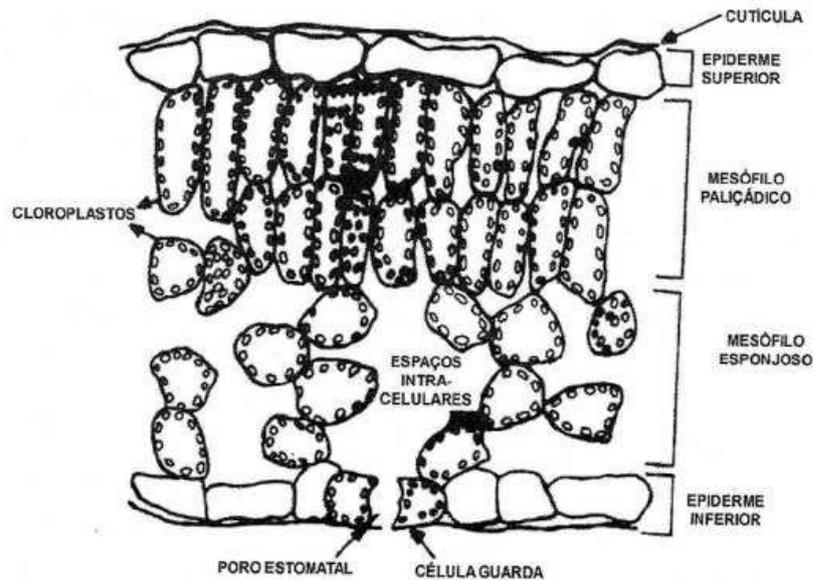


FIGURA 2 - Seção transversal de uma folha mostrando a distribuição dos tecidos no seu interior.

Fonte: Ponzoni et al (2012).

No mesófilo paliçádico encontram-se a maior parte dos cloroplastos, os quais armazenam os pigmentos, clorofilas e carotenóides, responsáveis pela fotossíntese. As clorofilas são as principais responsáveis pelo processo fotossintético e atuam diretamente na captação da energia eletromagnética. Os carotenóides são pigmentos auxiliares da fotossíntese e atuam indiretamente aumentando a capacidade da clorofila para converter a radiação eletromagnética em energia química (SILVA et al., 2012).

De acordo com Rêgo et al (2012) e Moreira (2003), a região do espectro eletromagnético classificada como visível (0,4-0,7  $\mu\text{m}$ ) estão inseridas as faixas do azul (0,45  $\mu\text{m}$ ) e vermelho (0,65  $\mu\text{m}$ ), e nestas respectivas faixas ocorrem baixa reflectância devido a absorção de energia pelos pigmentos fotossintetizantes como a clorofila. Por outro lado, a região do infravermelho que é dividida em: infravermelho próximo (0,7-1,3  $\mu\text{m}$ ), infravermelho médio (1,3-6,0  $\mu\text{m}$ ) e infravermelho distante (6,0-1000  $\mu\text{m}$ ), ocorre intensa reflexão da energia nas folhas.

## 2.4. Índices de Vegetação

Para quantificar a variação da energia refletida e absorvida pelas folhas, e consequentemente o comportamento espectral da vegetação, foram criados os índices de vegetação que realizam uma combinação de valores de diferentes regiões do espectro eletromagnético, geralmente nas faixas do vermelho e infravermelho próximo, que geram índices capazes de remeter a parâmetros biofísicos da cobertura vegetal, como biomassa, índice de área foliar, vigor vegetativo, atividade fotossintética e produtividade (OLIVEIRA et al., 2016; PONZONI et al., 2012; EIPHANIO et al., 1996).

O uso de índices de vegetação, como o Índice de Vegetação por Diferença Normalizada (do inglês *Normalized Difference Vegetation Index* - NDVI), o Índice de Água por Diferença Normalizada (do inglês *Normalized Difference Water Index* - NDWI) e o Índice de Vegetação Realçada (do inglês *Enhanced Vegetation Index* - EVI), permitem o monitoramento de culturas agrícolas com grande eficiência e baixo custo operacional (FERNANDES et al., 2011; YI et al., 2007; REMBOLD e MASELLI, 2006).

### 2.4.1. Índice de Vegetação por Diferença Normalizada

O NDVI é o índice de vegetação mais utilizado no processamento de dados de sensoriamento remoto. Explora as propriedades espectrais da vegetação em relação à quantidade de energia absorvida na faixa do visível do espectro eletromagnético e sua respectiva reflexão no infravermelho próximo. O NDVI foi proposto por Rouse et al (1973), varia de -1 a +1 (quanto mais próximo de 1, maior a densidade de cobertura vegetal), e pode ser obtido pela relação da reflectância na banda do infravermelho próximo e a reflectância na banda do vermelho para as imagens Landsat e Sentinel.

### 2.4.2. Índice de Área Foliar

O Índice de Área Foliar (IAF) é um dos principais parâmetros fisiológicos medidos ou estimados para avaliar a adaptabilidade das culturas às condições de manejo. Este índice representa a Área Foliar (AF) total por unidade de área do terreno, funciona como um indicador da superfície disponível para interceptação e absorção de luz visando à realização da fotossíntese (REIS et al., 2013).

Os processos para aquisição do IAF podem ser feitos pelos métodos:

- **Métodos indiretos** - são caracterizados pelas medidas de radiação total que penetram no interior da cobertura vegetal. Uma das maneiras de captação desta radiação é por meio de uma câmara digital acoplada a uma lente “olho-de-peixe”, como descrito por Norman & Campbell (1998).
- **Métodos diretos** - são caracterizados pela destruição da vegetação a ser analisada. No entanto é um dos processos mais confiáveis, por utilizar cálculos diretos sobre a quantidade de massa do vegetal analisado, não dependendo assim de radiação como recurso de análise e muito menos a influência das hastes no cálculo do IAF (ZANCHI et al., 2009).

## 2.5. Sensoriamento remoto

O sensoriamento remoto utiliza da radiação eletromagnética gerada por fontes naturais ou artificiais para captar informações de um alvo sem a necessidade de contato físico. O fluxo de energia proveniente do sol interage com um objeto e sua energia pode ser absorvida, refletida ou transmitida. A reflectância do objeto diz respeito à fração do fluxo que é refletida. A absorvância e transmitância correspondem à fração absorvida e a transmitida respectivamente. Portanto, para o sensoriamento remoto, a porção refletida é captada pelos sensores e permite detectar as diferenças relacionadas à densidade da cobertura vegetal, diferenciar as formas de uso do solo, estimar a biomassa, produtividade da cultura, monitorar o estresse hídrico, vigor das plantas, e até mesmo avaliar o estágio fenológico (LEITE et al., 2012; NASCIMENTO et al., 2005; SILVA et al., 2012; BRANDÃO et al., 2008).

As medições podem ser realizadas por imagens de sensores que podem ser operados, manualmente, ou instalados em alguma plataforma, como: veículos, máquinas agrícolas autônomas, Veículos Aéreos Não Tripulados (VANTs), aeronaves ou satélites. O que altera entre as opções é o custo de obtenção das imagens e a dimensão obtida (SHIRATSUCHI et al., 2014).

### 2.5.1. Programa Landsat

Os Estados Unidos da América foi o país pioneiro no uso de sensoriamento remoto por satélites. No início da década de 1970, lançou o primeiro satélite da série Landsat (inicialmente denominado ERTS, sigla de *Earth Resources Technology Satellite*), por meio do projeto LACIE (do inglês *Large Area Crop Inventory Experiment*), juntamente com a Agência Espacial Norte-Americana (do inglês *National Aeronautics and Space Administration* - NASA), a *Nationl*

*Oceanic and Atmospheric Administration* (NOAA) e o Departamento de Agricultura Norte-Americano (do inglês *United States Department of Agriculture* - USDA) (FORMAGGIO e SANCHES, 2017).

O programa Landsat tem como missão fornecer aquisição repetitiva de dados multiespectrais de resolução moderada da superfície da Terra, ou seja, entre 10 e 100m. Nos últimos 40 anos, o programa Landsat forneceu dados das superfícies continentais. É o registro mais longo visto do espaço (USGS, 2019).

O satélite Landsat-8 foi lançado em 2013, tem resolução temporal de 16 dias e imageamento de 185 km, faz parte de um programa de pesquisa global conhecido como *Science Mission Directorate* (SMD) da NASA, um programa de longo prazo que estuda mudanças no ambiente global da Terra (USGS, 2019).

O Landsat-8 Está equipado com os sensores OLI e *Thermal Infrared Sensor* (TIRS), o sensor OLI possui bandas espectrais para coleta de dados na faixa do visível, infravermelho próximo e infravermelho de ondas curtas, além de uma banda pancromática. Avanços tecnológicos demonstrados por outros sensores experimentais da NASA foram introduzidos no sensor OLI, que passou a ter quantização de 12 bits. O sensor TIRS possui bandas espectrais na faixa do infravermelho termal. Oferece continuidade à aquisição de dados captados pela banda 6 do TM e ETM+. Os dados do sensor TIRS possuem 100m de resolução espacial, com resolução radiométrica de 12 bits e corregristo com os dados oriundos do sensor OLI, conforme Tabela 2 (USGS, 2019).

TABELA 2 - Sensor, número, nome, resolução espectral e resolução espacial do LandSat-8

Sensor	Nr da Banda	Nome da Banda	Resolução Espectral (micron)	Resolução Espacial
OLI (Operational Land Imager)	B01	Costal	0.433 - 0.453	30 m
	B02	Azul	0.450 - 0.515	
	B03	Verde	0.525 - 0.600	
	B04	Vermelho	0.630 - 0.680	
	B05	Infravermelho próximo	0.845 - 0.885	15 m
	B06	Infravermelho médio	1.560 - 1.660	
	B07	Infravermelho médio	2.100 - 2.300	
	B08	Pancromático	0.500 - 0.680	
	B09	Cirrus	1.360 - 1.390	
TIRS (Thermal Infrared Sensor)	B10	LWIR - 1	10.30 - 11.30	100 m
	B11	LWIR - 2	11.50 - 12.50	

Fonte: USGS (2019).

### 2.5.2. Programa Copernicus

O programa Copernicus, nome dado para a monitoramento global do programa de segurança conduzido pela Comissão Europeia (do inglês *European Commission* – EC) e Agência Espacial Europeia (do inglês *European Space Agency* – ESA), desenvolveu os satélites chamados Sentinel. Cada missão do Sentinel é baseada em uma constelação de dois satélites para cumprir os requisitos de visitar e de cobertura, fornecendo imagens de alta resolução para monitoramento da terra, principalmente de agricultura, florestas, mudança no uso da terra, mudança de cobertura da terra, bem como mapear variáveis biofísicas: clorofila, teor de água foliar e índice de área foliar (DRUSCH et al., 2012).

A missão Sentinel-2 consiste em dois satélites: Sentinel-2A, que foi lançado em 23 de junho de 2015. E o segundo, Sentinel-2B, idêntico ao primeiro, que foi lançado em 7 de março de 2017, juntos, cobrem toda a superfície da Terra. Ambos os satélites têm estimativa de vida útil de 7,25 anos e operam em órbita sincronizada ao sol com ciclo de repetição de 10 dias (DRUSCH et al., 2012).

TABELA 3 - Resolução espacial, número, nome, comprimento e combinações das bandas do Sentinel-2

Resolução	Nr da Banda	Nome da Banda	Comprimento de Onda Central (nanômetro)	Combinações de Bandas
10 m	B02	Blue (Azul)	490	Cor Verdadeira RGB 04/03/02 Falsa Cor 1 e 2 RGB 08/04/03 e 04/08/03
	B03	Green (Verde)	560	
	B04	Red (Vermelho)	665	
	B08	NIR (Infravermelho Próximo)	842	
20 m	B05	Red Edge 1	705	SWIR 1 RGB 12/11/8A
	B06	Red Edge 2	740	
	B07	Red Edge 3	783	
	B08A	Red Edge 4	865	
	B11	SWIR 1	1610	
	B12	SWIR 2	2190	
60 m	B01	Aerossol	443	–
	B09	Water Vapor	940	
	B10	Cirrus	1375	

Fonte: adaptado de Drusch et al., 2012

Os Sentinel-2 (A e B) são equipados com o sensor *Multispectral Instrument* (MSI), com a largura da faixa de imageamento de 290 km, proporcionando boa resolução espacial, capitadas por 13 bandas: no visível, infravermelho próximo e infravermelho curto, conforme Tabela 3. As bandas do sensor estão localizadas, aproximadamente, entre 450 e 2200 nm e têm larguras variáveis. As imagens são disponibilizadas no chamado nível 1-C de processamento, com correções geométricas e radiométricas já aplicadas, de modo que as imagens são disponibilizadas ortoretificadas e em valores de reflectância do Topo da Atmosfera (do inglês *Top Of Atmosphere* - TOA). A resolução temporal é de 5 dias contando o tempo de passagem dos dois satélites da constelação (DRUSCH et al., 2012).

A partir das imagens de sensoriamento remoto, pode-se obter informações sobre áreas florestais e agrícolas de diferentes extensões, para tal, busca-se compreender as variações de refletância e emitância das folhas vegetais em função de sua espécie, espessura, estrutura e densidade do dossel, idade, estado nutricional e hídrico. Pode-se verificar então que os pigmentos existentes nas folhas, especialmente as clorofilas, são responsáveis por absorções preferenciais em diferentes comprimentos de ondas do espectro óptico (~400nm a 2500nm), constituindo as bases para o uso da refletância, tanto em sensores de banda estreita (espectrômetros hiperspectrais), como em IVs de sensores de banda larga (PONZONI et al., 2012).

Os novos sensores estão mais desenvolvidos apresentando resoluções geométricas e espectrais cada vez melhores, juntamente com os softwares de processamento de imagens digitais. Estão crescendo eficientemente e exibe modelos de simulação da refletância de dosséis vegetais capazes de descrever melhor os processos de interação entre a energia eletromagnética e os dosséis. Entender a refletância da folha e do dossel vegetal possibilita gerar vários tipos de informações especializadas e georreferenciadas sobre as áreas florestais ou agrícolas, como a porcentagem de cobertura verde sobre a superfície, área foliar, biomassa, tipo de cobertura vegetal, teor de umidade, componentes bioquímicos, etc (PONZONI et al., 2012).

Segundo Formaggio e Sanches (2017), o sensoriamento remoto pode acrescentar de modo significativo no fornecimento de dados adequados e precisos sobre a área agrícola, por possuir as geotecnologias como melhor meio para a coleta de informações confiáveis e detalhadas sobre grandes áreas, em termo de custo-benefício. Dentre as possíveis contribuições estão a estimativa de produtividade e biomassa, mapeamento de estresses e desenvolvimento fenológico das culturas, levantamento de informações de áreas plantadas com culturas agrícolas, identificação de sistemas de produção agrícola e padrões de plantio e avaliações de desastres naturais sobre produções agrícolas.

A utilização de sensoriamento remoto para obter dados de IVs é muito usado em aplicações florestais, nos meios de pesquisa, na agricultura e auxílio no campo. O IAF é um dos principais IVs que se obtém por sensoriamento remoto. É um parâmetro fisiológico da vegetação que pode ser correlacionado a informações como: produtividade, evapotranspiração, determinação de danos bióticos e abióticos e até mesmo exigências hídricas em espécies vegetais, como o eucalipto, cana-de-açúcar, morango, tomate, entre outras (ALMEIDA et al. 2015; ZEIST et al. 2014).

## 2.6. Redes Neurais Artificiais

Sistemas de processamento paralelo e distribuído, também conhecidas como Redes Neurais Artificiais (RNAs), são estruturas baseadas em modelos que lembram a estrutura do cérebro humano. Utilizam unidades de processamento simples, neurônios artificiais, que têm a função de calcular determinadas funções matemáticas para criar conexões que armazenam o conhecimento (BRAGA et al., 2012).

Braga et al. (2012) enumeram algumas características das redes neurais:

- Adaptação por experiência;
- Capacidade de aprendizado;
- Habilidade de generalização;
- Organização e classificação de dados;
- Tolerância a falhas (se deve ao elevado número de interconexões);
- Armazenamento distribuído.

Silva et al. (2010) define uma RNA como “um conjunto de unidades de processamento, caracterizados por neurônios artificiais que são interligados por sinapses artificiais”. Uma RNA possui a capacidade de adquirir, armazenar e administrar o conhecimento. Isso é possível graças ao seu sistema de interconexões representado por vetores e matrizes de pesos sinápticos.

### 2.6.1. Neurônio Artificial

Os neurônios artificiais são modelos matemáticos que visam representar, de maneira simplificada, os neurônios biológicos. O modelo matemático mais empregado nas arquiteturas de RNAs foi proposto e desenvolvido pelos pesquisadores McCulloch e Pitts (1943) (Figura 3). Este modelo engloba as características essenciais de uma rede neural biológica, que é o paralelismo e a alta conectividade (HAYKIN, 2005).

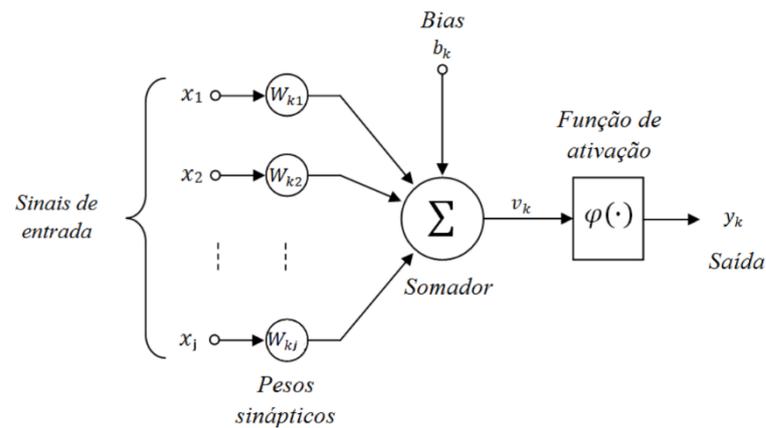


FIGURA 3 - Representação do neurônio de McCulloch e Pitts.

Fonte: Braga et al. (2012).

Conforme o modelo apresentado na Figura 3, são identificados três elementos básicos em sua composição:

- **Conjunto de sinapses** - cada uma é caracterizada por um peso. Assim, para todo sinal  $x_j$  na entrada da sinapse  $j$  vinculada ao neurônio  $k$  será ponderado um peso sináptico  $w_{kj}$ . Com relação ao peso sináptico  $w_{kj}$ , é importante observar que o primeiro índice refere-se ao neurônio em questão, enquanto que o segundo faz alusão ao terminal de entrada da sinapse ao qual o peso se refere;
- **Combinador linear** - empregado para executar o somatório dos sinais produzidos pelo produto dos pesos sinápticos pelas entradas fornecidas ao neurônio;
- **Função de ativação** - responsável por associar o sinal resultante do combinador linear, conhecido como potencial de ativação, a um valor de saída, que pode aplicar não-linearidade ou restrição. Essa função define, ainda, uma restrição ao intervalo permissível de amplitude do sinal de saída a um valor finito. Geralmente essa limitação fica entre  $[0, 1]$  ou  $[-1, 1]$ , por questão de normalização da informação (HAYKIN, 2005).

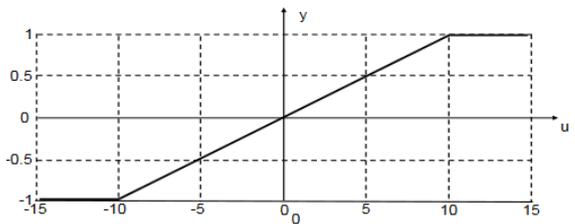
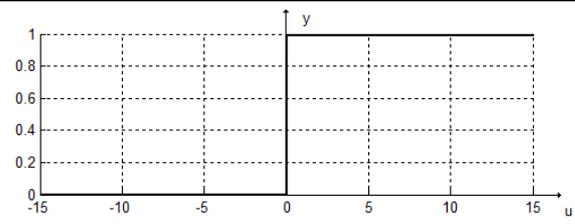
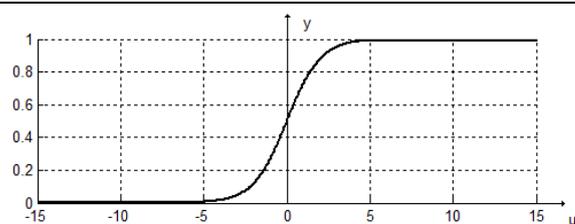
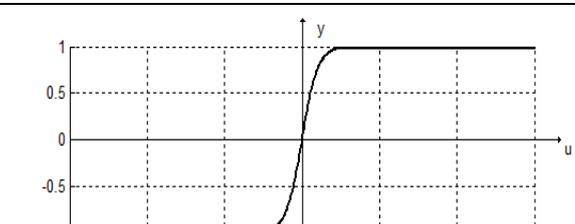
Um neurônio artificial opera da seguinte forma:

- Os sinais são apresentados à entrada;
- Cada sinal é multiplicado por um peso que representa o seu nível de relevância na saída da unidade;
- É feita uma soma ponderada dos sinais, resultando assim em um nível de atividade;
- Caso este nível de atividade exceda certo limite (*threshold*), então o neurônio produz uma saída.

### 2.6.2. Tipos de função de ativação

O valor de saída do neurônio artificial, em termos de campo local induzido, é determinado por uma função de ativação, representada por  $\varphi(v)$ , cujo propósito é manter a saída do neurônio artificial dentro do domínio de definição da mesma. Tal função pode assumir várias formas dentre os dois grupos principais, isto é, funções parcialmente diferenciáveis e funções totalmente diferenciáveis. Na Tabela 4, pode-se visualizar algumas das principais funções de ativação com seus respectivos gráficos (SILVA, 2010).

TABELA 4 - Funções de ativação e seus respectivos gráficos.

Função de Ativação	Gráfico da Função de Ativação
Rampa simétrica $\varphi(v) = \begin{cases} a, & \text{se } v_k > a \\ v, & \text{se } a \leq v_k \leq a \\ -a, & \text{se } v < a \end{cases}$	 <p>(a) Gráfico de ativação rampa simétrica.</p>
Limiar $\varphi(v) = \begin{cases} 1, & \text{se } v_k \geq 0 \\ 0, & \text{se } v_k < 0 \end{cases}$	 <p>(b) Gráfico de ativação degrau bipolar.</p>
Sigmoide $\varphi(v) = \frac{1}{1 + \exp(-av)}$	 <p>(c) Gráfico de ativação logística.</p>
Tangente hiperbólica $\varphi(v) = \frac{1 - \exp(-av)}{1 + \exp(-av)}$	 <p>(d) Gráfico de ativação tangente hiperbólica.</p>

Fonte: adaptado do Silva (2010).

As funções de ativação parcialmente diferenciáveis, representadas pelos Gráficos da Tabela 4a e Tabela 4b, são aquelas que possuem pontos cujas derivadas de primeira ordem são inexistentes. Entretanto, as funções de ativação totalmente diferenciáveis, consideradas nos Gráficos da Tabela 4c e Tabela 4d, apresentam derivadas de primeira ordem que são conhecidas em todos os pontos de seu domínio de definição (SILVA, 2010).

### 2.6.3. Arquitetura

A arquitetura de uma rede neural artificial é definida pela forma como os neurônios estão estruturadas. Esta estrutura está intimamente ligada ao algoritmo de aprendizagem que será utilizado para realizar seu treinamento (HAYKIN, 2005). A estrutura de uma rede neural, basicamente, se divide em três partes (Figura 4):

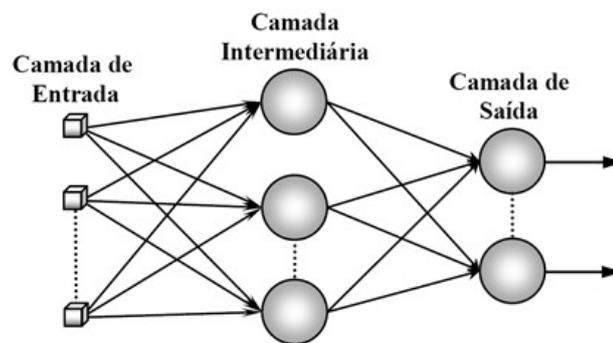


FIGURA 4 - Representação das camadas de uma rede neural artificial.

Fonte: Silva et al. (2010)

- **Camada de entrada** - responsável pelo recebimento das informações de entrada, isto é, onde os padrões são inicialmente apresentados à rede;
- **Camadas intermediárias ou ocultas** - responsáveis pela extração das características do processo ou sistema ao qual se está inferindo, é a camada onde praticamente todo o processamento da rede é realizado;
- **Camada de saída** - responsável pela apresentação do resultado alcançado, o qual foi processado por meio de todas as camadas da rede.

Em geral, pode-se classificar em três tipos de arquiteturas:

- **Redes Feedforward (Camada Única)** - caracterizada por possuir uma camada de entrada e uma única camada de neurônios que é a própria camada de saída. Ela é aplicada, principalmente, em reconhecimentos de padrões e em memórias associativas compostas por  $N$  entradas e  $m$  saídas (Figura 5).

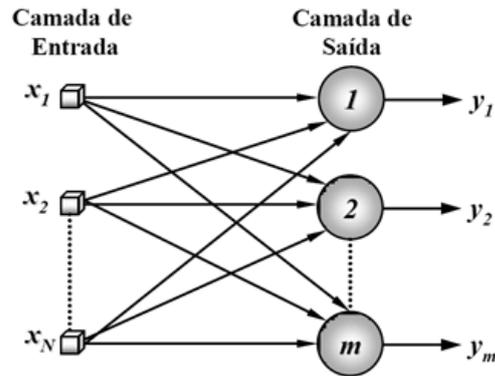


FIGURA 5 - Representação de uma rede *Feedforward* (camada única).

Fonte: Silva et al. (2010)

- **Redes *Feedforward* (Multicamadas)** - possui uma ou mais camadas ocultas. As informações são recebidas pela camada de entrada, processadas pela camada oculta, e apresentadas pela camada de saída (HAYKIN, 2005) (Figura 6). Geralmente, é aplicada em reconhecimento de padrões e como aproximador universal de funções, pois é capaz e aproximar funções não lineares.

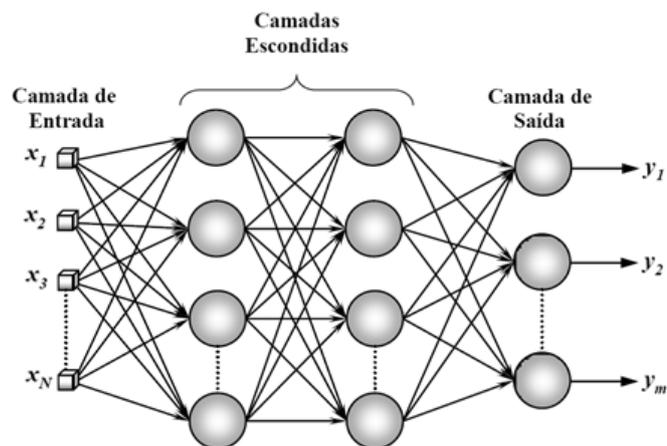


FIGURA 6 - Representação de uma rede *Feedforward* (multicamadas).

Fonte: Silva et al. (2010)

- **Redes Recorrentes** - possuem pelo menos uma realimentação durante o processo de execução da rede. A realimentação gera um impacto significativo na capacidade de aprendizagem da rede e na sua performance (MATSUNAGA, 2012). Uma rede recorrente tem uma camada de entrada de neurônios que alimenta sua saída de volta à entrada de todos os outros neurônios, podendo ou não ter auto realimentação (HAYKIN, 2005). As conexões de realimentação se originam dos neurônios da camada de saída e possuem uma memória de atraso que operam sobre todas as entradas  $x(n)$  produzindo

uma versão atrasada (Figura 7). Geralmente, são aplicadas em sistemas dinâmicos, séries temporais, previsões, identificação e controle.

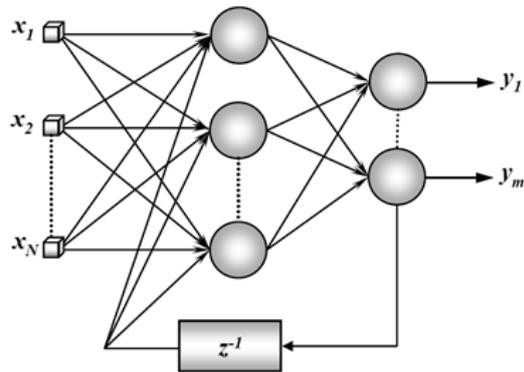


FIGURA 7 - Representação de uma rede recorrente.

Fonte: Silva et al. (2010)

#### 2.6.4. Treinamento e aprendizagem

Haykin (2005) apresenta uma RNA como um artefato computacional que possui a capacidade de aprender a partir de exemplos melhorando seu desempenho com o treinamento. A aprendizagem ocorre pelo processo de ajuste dos parâmetros livres da rede neural, que ocorre por meio das estimulações criadas pelos exemplos que são apresentados à rede. O tipo de aprendizagem é determinado pela maneira na qual os parâmetros são modificados.

Silva et al. (2010) explica que após a rede ter encontrado o relacionamento entre as entradas e saídas, ela adquire a capacidade de generalizar essa relação produzindo assim saídas próximas à esperada quando novos dados são apresentados a suas entradas.

O conjunto de passos para o treinamento da rede é denominado de algoritmo de aprendizagem. Segundo Haykin (2005) não existe um algoritmo único para realizar o treinamento. Eles se diferenciam um dos outros pela forma como ocorre o ajuste dos pesos de cada neurônio.

O treinamento das redes neurais artificiais pode ser dividido em dois modelos: as que utilizam a aprendizagem supervisionada e as que utilizam aprendizagem não-supervisionada. Pode-se selecionar o modelo conforme a disponibilidade de resposta esperada ou não da relação atributo e classe (RUSSELL e NORVIG, 2010).

A aprendizagem supervisionada baseia-se no erro entre a resposta esperada e a calculada pela rede, que é utilizada para ajustar os pesos. Se o resultado gerado pela rede for diferente da saída esperada, o algoritmo de treinamento ajusta os pesos, utilizando alguns critérios e procura reduzir o erro da rede a um valor aceitável (BRAGA et al., 2012).

Na aprendizagem não supervisionada não há associação previa a um resultado esperado. A rede se organiza buscando encontrar características similares nos subconjuntos que lhe são apresentados, de forma que os pesos da rede são ajustados pelo algoritmo de treinamento para criar sua própria representação das entradas (HAYKIN, 2005).

### 2.6.5. Tipos de redes

Na literatura, é possível encontrar diversos modelos de rede, cada um proveniente de uma linha de pesquisa diferente e que é mais adequado para a solução de determinados tipos de problemas. As redes neurais mais conhecidas são: *Perceptron*, que é o precursor no desenvolvimento das redes neurais e o *Multilayer Perceptron* (MLP), o mais amplamente utilizado (RUSSELL e NORVIG, 2010).

- **Perceptron** - é a configuração mais simples de uma rede neural artificial, constituída por apenas uma camada neural, que por sua vez, possui somente um neurônio. Apesar da sua simplicidade, esta rede atraiu vários pesquisadores que estudavam sobre inteligência artificial na época (SILVA et al., 2010), é representada pela arquitetura *feedforward*, pois as informações fluem da entrada para a saída de forma unidirecional (HAYKIN, 2005). Este tipo de rede é geralmente utilizado em problemas de reconhecimento de padrões com o objetivo de dividir as classes utilizadas na entrada, que sejam linearmente separáveis. Em um *Perceptron* constituído por duas classes a separação destas pode ser realizada com uma reta, se a função de ativação  $\varphi(v)$  utilizada for do tipo limiar, a reta irá separar os elementos apresentados da classe cuja saída for 0 (que estarão abaixo da reta) da classe cuja saída for 1 (que estarão acima da reta) (Figura 8).

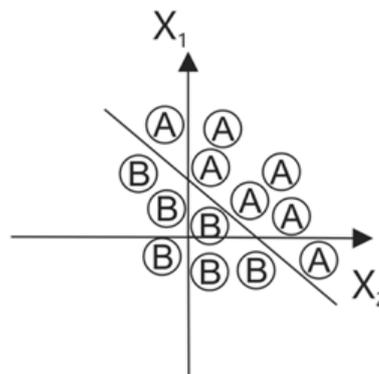


FIGURA 8 - Representação gráfica da fronteira de separação entre as duas classes de saída.

Fonte: Silva et al. (2010)

- **Multilayer Perceptron** - ou de retropropagação do erro possuem como característica principal ter no mínimo uma camada oculta de neurônios. Este tipo de rede se destaca por ser amplamente utilizada em diversas áreas do conhecimento. É considerada uma das mais versáteis quanto à aplicabilidade (BRAGA et al., 2012). Este tipo de rede implementa a arquitetura *feedforward* onde os dados fluem da camada de entrada para camada de saída. Os estímulos (dados) são apresentados à rede na camada de entrada. A camada intermediária (oculta) por sua vez extrai as informações e as codificam por meio dos pesos sinápticos, formando assim sua representação interna do ambiente externo. Por fim, a camada de saída recebe os estímulos da camada intermediária, mapeando o padrão de resposta que será a saída da rede (Figura 9).

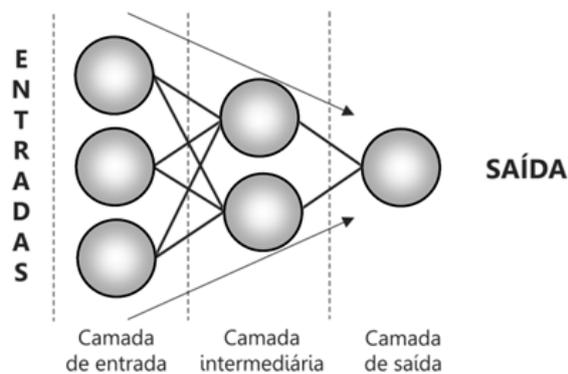


FIGURA 9 - Representação de uma rede do tipo MLP com camadas intermediárias ou ocultas.

Fonte: Silva et al. (2010) (modificada)

O treinamento da rede *Multilayer Perceptron* é realizado utilizando-se a regra Delta Generalizada, e o algoritmo mais empregado é conhecido por *backpropagation* ou algoritmo de retropropagação do erro por meio do treinamento supervisionado (HAYKIN, 2005). O processo de treinamento é realizado em duas fases bem definidas de aprendizagem (BRAGA et al., 2012; HAYKIN, 2005; SILVA et al., 2010).

A primeira fase é denominada propagação *forward*. Nesta fase, os pesos sinápticos e os limiares dos seus neurônios não sofrem alteração, pois o objetivo é obter o resultado da rede levando em consideração os valores dos parâmetros atuais da rede, que posteriormente serão ajustados pelo processo. Assim um conjunto de amostras de treinamento é apresentado à camada de entrada e seus efeitos se propagam até a camada de saída.

Utilizando o treinamento supervisionado, as respostas da rede são comparadas com as respostas esperadas e os erros gerados pela diferença das saídas são calculados e na fase seguinte utilizados para ajustar os pesos e limiares de todos os neurônios. Desta forma, os pesos das sinapses são alterados de acordo com a regra de correção do erro (HAYKIN, 2005), ou seja, a resposta real é subtraída da resposta esperada para produzir um sinal de erro.

A segunda fase é denominada *backward*, na qual o sinal de erro é retropropagado por meio da rede. Assim, os pesos são ajustados utilizando os valores de erros produzidos na etapa anterior. As execuções sucessivas das duas fases fazem com que os pesos sinápticos sejam ajustados automaticamente em cada iteração. Como consequência ocorre a diminuição dos erros produzidos pelas respostas calculados em relação às esperadas. Estatisticamente, os pesos sinápticos são ajustados de forma que a resposta da rede se mova para mais próximo da resposta esperada (HAYKIN, 2005).

Vale destacar que o sistema de interconexões utilizados na rede é representado por vetores e matrizes de dados de entrada e pesos sinápticos e, geralmente, as funções de ativação utilizadas no método *backpropagation* são a logística ou a tangente hiperbólica.

#### **2.6.6. Normalização de variáveis**

As redes neurais trabalham ponderando os valores das entradas, assim uma variável que tenha valores mais elevados pode ser considerada, no início do treinamento, como mais relevante que outra variável de menor grandeza. No entanto com treinamento a rede ajustará os pesos para que a variáveis tenham o valor mais adequado conforme sua importância no problema considerado. O tratamento de variáveis com diferentes grandezas pode ser simplificado submetendo-se as variáveis à normalização para uma escala comum com valores entre -1 e 1 (ZARIFNESHAT et al., 2012).

As variáveis podem ter grandezas diferentes, o que pode dificultar ou mesmo impedir que a RNA venha a convergir (encontrar a relação entre as variáveis de entrada e a saída esperada); além da questão das grandezas diferentes também deve ser tratado o caso de variáveis que não são valores numéricos, mas categorias. Para as variáveis que definem categoria/tipo é recomendado seguir o mesmo tratamento dado a variáveis tipo *dummy* da Análise de Regressão Múltipla, que transforma variável categórica e numérica (BOHL et al., 2015; SHARMA et al., 2007), que diz que deve ser criado n-1 variáveis, no qual “n” é número de categorias que as variáveis podem assumir.

### 2.6.7. Aplicabilidade das Redes Neurais Artificiais

Devido à simplificação de problemas complexos e aos resultados confiáveis, características que garantem inúmeros benefícios as aplicações das RNAs. Assim, torna-se possível uma abordagem eficiente para aproximar funções de mapeamento de entrada-saída não-linear para qualquer grau de precisão de forma iterativa. Isso possibilita modelar sistemas complexos, com as seguintes propriedades: capacidade de aproximação de funções universais, tolerância a dados com ruídos (*outliers*) ou incompletos, suporte múltiplos variáveis não-lineares com interações desconhecidas e boa capacidade de generalização (HAGAN et al., 2014).

Aleksander e Marton (1995) e Russell e Norvig (2010) atestam que as RNAs são empregadas nos mais variados campos da ciência. Em grande parte, isso acontece devido a sua capacidade de aprendizagem e generalização que permitem formar modelos de sistemas altamente não-lineares em que a relação entre as variáveis é desconhecida ou muito complexa.

Vários campos da ciência fazem uso das RNAs graças a essas características: na medicina, durante quatro anos, foi feito o experimento para avaliar os fatores que influenciam na qualidade do atendimento de uma ala médica (SCHIAVO et. al., 2015). Com esse estudo, conclui-se que as RNAs podem ser utilizadas como uma ferramenta descritiva e preditiva para ajudar a determinar os parâmetros que mais influenciam na qualidade da ala médica. Também na medicina Amato et. al. (2013) empregou as RNAs em diagnósticos médicos. E comprovou-se que elas podem ser uma ferramenta poderosa no processamento de grande quantidade de dados, o que faz diminuir a probabilidade de deixar passar informações importantíssimas, e ainda ter o diagnóstico mais rápido em relação ao que ocorre hoje.

Nas ciências agrárias, vários trabalhos foram sugeridos. Na engenharia agrícola, utilizou-se a metodologia para simular a precipitação de um aspersor utilizado para irrigação (MENEZES et. al., 2015), a RNA obteve bons resultados ao simular a precipitação comparado a *Sprearns* por meio dos dados obtidos em ensaio de campo e os dados simulados variando entre 0,92 e 0,97, no qual o autor evidencia que tal resultado só ocorreu graças à alta capacidade de adaptação do algoritmo de treinamento *backpropagation*.

Outra aplicação foi no intuito de prever o rendimento de culturas como o milho (KAUL et. al., 2005) em que o autor concluiu que a metodologia poderia ser empregada por especialistas em gestão de nutrientes de Maryland para desenvolver, revisar ou atualizar os planos de gestão de nutrientes.

Safa et. al. (2015), na cultura do trigo, fez um experimento para estimar a produtividade e comprovou que a capacidade das redes neurais em prever a produção de trigo por meio do uso de dados heterógenos é superior à capacidade dos modelos de regressão múltiplas, comumente utilizado em estudos agrícolas.

Erzin et. al. (2010), exemplificando o uso de RNAs em seu experimento comprovou que as RNAs, especialmente, as do tipo *Mult Layer Perceptron* (MLP) podem ser utilizadas para prever a resistividade elétrica do solo por meio da resistividade térmica, tipo do solo e grau de saturação. A conclusão a que se chega é que é possível substituir testes de laboratório pelo uso das redes neurais do tipo MLP de forma simples e eficiente.

As RNAs têm sido aplicadas, por muitos pesquisadores, para solucionar diferentes tipos de problemas, quando não é possível a formulação explícita para o problema (FANG et. al., 2000). A sua capacidade de aprender com exemplos (dados históricos comprovados) para desenvolver uma representação da relação entre os dados apresentados e o resultado esperado é a maior vantagem no emprego das RNAs.

### 3. REFERÊNCIAS BIBLIOGRÁFICAS

ALEKSANDER, I.; MORTON, H. **An introduction to neural computing**. Lodon: Int Thomson Comput Press, 1995.

ALMEIDA, A. Q. De; RIBEIRO, A.; DELGADO, R. C.; RODY, Y. P.; OLIVEIRA, A. S. De; LEITE, F. P. Índice de área foliar de eucalyptus estimado por índices de vegetação utilizando imagens tm - landsat 5. **Floresta e Ambiente**, . v. 22, n. 3, p. 368–376. 2015.

ALVES, G. R.; TEIXEIRA, I. R.; MELO, F. R.; SOUZA, R. T. G.; SILVA, A. G. Estimativa da produtividade de soja com redes neurais artificiais. **Acta Scientiarum. Agronomy**, . v. 40, n. 2. 2018.

ALVES JÚNIOR, J.; SALES, D. L. A.; PEREIRA, R.M.; RODRIGUEZ, W. D. M.; CASAROLI, D.; EVANGELISTA, A. W. P. Viabilidade econômica da irrigação por pivô central nas culturas de soja, milho e tomate. p. 2970–2980. 2017.

AMATO, F.; LÓPEZ, A.; PEÑA-MÉNDEZ, E. M.; VAÑHARA, P.; HAMPL, A.; HAVEL, J. Artificial neural networks in medical diagnosis. **Journal of Applied Biomedicine**, v. 11, p. 47–58. 2013.

BARRETTO, A. G. O. P.; BERNDES, G.; SPAROVEK, G.; WIRSENIUS S. Agricultural intensification in Brazil and its effects on land-use patterns: an analysis of the 1975-2006 period. **Global Change Biology**, v. 19, p. 1804-1815, 2013.

BERNARDI, A. C. De C.; BETTIOL, G. M.; GREGO, C. R.; ANDRADE, R. G.; RABELLO, L. M.; YASSUSHI, R. Ferramentas de agricultura de precisão como auxílio ao manejo da fertilidade do solo. **Revista Agrogeoambiental**, . v. 8, n. 1, p. 205–221. 2015.

BLANCO, F. F.; FOLEGATTI, M. V. A new method for estimating the leaf area index of cucumber and tomato plants. **Horticultura Brasileira**, . v. 21, n. 4, p. 666–669. 2003.

BOHL, M. T.; DIESTELDORF, J.; SALM, C. A.; WILFLING, B. Spot market volatility and futures trading: the pitfalls of using a dummy variable approach. **Journal of Futures Markets**, v. XX, n. X, 2015.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: Teoria e Aplicações**. 2. ed. Rio de Janeiro: LTC, 2012.

BRANDÃO, Z. N.; BEZERRA, M. V. C.; FREIRE, E. C.; SILVA, B. B. Agricultura de precisão para gerenciamento do algodão. In: AZEVÊDO, D. M. P.; BELTRÃO, N. E. M. **O agronegócio do algodão no Brasil**. Brasília: Embrapa Informação Tecnológica, 2008. 1309 p. cap. 20. v. 2.

BRAZ, A. M.; ÁGUAS, T. D. A.; MIRANDOLA GARCIA, P. H. Análise de índices de vegetação ndvi e savi e índice de área foliar (IAF) para a comparação da cobertura vegetal na bacia hidrográfica do córrego ribeirãozinho, município de selvíria – ms. **Revista Percursos**, . v. 7, n. 2, p. 5–22. 2015.

BRÉDA, N. J. J. Ground-based measurements of leaf area index: a review of methods, instruments and current controversies. **Journal of Experimental Botany**, . v. 54, n. 392, p. 2403–2417. 2003.

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**, . v. 8, n. n. 16, (jan./março)-ISSN 1980-5772, p. 40–55. 2014.

CARVALHO, D. F.; OLIVEIRA, L. F. C. Planejamento e manejo da água na agricultura irrigada. Viçosa: Editora UFV, 2012. v. 1. 240 p.

COHEN, W. B.; MAIERSPERGER, T. K.; GOWER, S. T.; TURNER, D. P. An improved strategy for regression of biophysical variables and landsat etm+ data. **Remote Sensing of Environment**, . v. 84, p. 561–571. 2003.

DARKO, R. O.; YUAN, S.; HONG, L.; LIU, J.; YAN, H. Irrigation, a productive tool for food security – a review. **Acta Agriculturae Scandinavica Section B: Soil and Plant Science**, . v. 66, n. 3, p. 191–206. 2016.

DORIGO, W. A.; ZURITA-MILLA, R.; WIT, A. J. W. DE; BRAZILE, J.; SINGH, R.; SCHAEPMAN, M. E. A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling. **International Journal of Applied Earth Observation and Geoinformation**, . v. 9, n. 2, p. 165–193. 2007.

DRUSCH, M.; BELLO, U. DEL; CARLIER, S.; COLIN, O.; FERNANDEZ, V.; GASCON, F.; HOERSCH, B.; ISOLA, C.; LABERINTI, P.; MARTIMORT, P.; MEYGRET, A.; SPOTO, F.; SY, O.; MARCHESE, F.; BARGELLINI, P. Sentinel-2: esa's optical high-resolution mission for gmes operational services. **Remote Sensing of Environment**, . v. 120, p. 25–36. 2012.

EPIPHANIO, J. C. N.; GLERIANI, J. M.; FORMAGGIO, A. R.; RUDORFF, B. F. T. Índices de vegetação no sensoriamento remoto da cultura do feijão. Brasília: **Pesquisa Agropecuaria Brasileira**, . v. 31, n. 6, p. 445–454. 1996.

ERZIN, Y.; RAO, B. H.; PATEL, A.; GUMASTE, S. D.; SINGH, D. N. Artificial neural network models for predicting electrical resistivity of soils from their thermal resistivity. **International Journal of Thermal Sciences**, v. 49, n. 1, p. 118–130. 2010.

FAEG - FEDERAÇÃO DA AGRICULTURA E PECUÁRIA DE GOIÁS. Index: sistemas de cotações. 2014. Disponível em: <<http://sistemafaeg.com.br/mercados-e-cotacoes/milho>>. Acesso em: 10 nov. 2014.

FANG, Q.; HANNA, M. A.; HAQUE, E.; SPILLMAN, C. K. Neural network modeling of energy requirements for size reduction of wheat. **Transactions of the ASAE**, v. 43, n. 4, p. 947–952. 2000.

FAO - ORGANIZAÇÃO DAS NAÇÕES UNIDAS PARA ALIMENTAÇÃO E AGRICULTURA. Global agriculture towards 2050. In: HIGH LEVEL EXPERT FORUM – HOW TO FEED THE WORLD 2050. Anais... Rome (Italy): FAO, 2009  
\_\_\_\_\_. The state of the world's land and water resources for food and agriculture, managing systems at risk. Abingdon: SDGF, 2011.

\_\_\_\_\_. World Food Situation. Disponível em: <<http://www.fao.org/worldfoodsituation/csdb/en/>>. Acesso em: 30 maio 2016

FORMAGGIO, A. R., SANCHES, I. D. **Sensoriamento Remoto em Agricultura**. 1a edição, São Paulo: Oficina de Textos, 2017, 288 p.

GAMEIRO, S.; TEIXEIRA, C. P. B.; NETO, T. A. Da S.; LOPES, M. De F. L.; DUARTE, C. R.; SOUTO, M. V. S.; ZIMBACK, C. R. L. Avaliação da cobertura vegetal por meio de índices de vegetação (NDVI, SAVI e IAF) na sub-bacia hidrográfica do baixo jaguaribe , ce. n. 2000. 2016.

HACKMANN, R. F.; BARBIERI, M. G. Hortifrutí Brasil. **Edição Especial**, . v. Edição Esp, n. 33–34, p. 50. 2018.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H.; JESÚS, O. DE. **Neural network design**. 2. ed. Martin Hagan, 2014.

HAYKIN, S. **Neural network: A Comprehensive Foundation**. 2. ed. Ontario: Pearson Prentice Hall, 2005.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Levantamento Sistemático da Produção Agrícola, 2018. Disponível em: <<https://sidra.ibge.gov.br/pesquisa/lspa/tabelas>>. Acesso em: 21 jan. 2018.

KAUL, M.; HILL, R. L.; WALTHALL, C. Artificial neural networks for corn and soybean yield prediction. Beltsville: **Agricultural Systems**, v. 85, n. 1, p. 1–18. 2005.

KÜÇÜKÖNDER, H.; BOYACI, S.; AKYÜZ, A. A modeling study with an artificial neural network: developing estimation models for the tomato plant leaf area. **Turkish Journal of Agriculture and Forestry**, . v. 40, p. 203–212. 2016.

LANDAU, E. C.; GUIMARÃES, D. P.; REIS, R. J. Dos. Mapeamento das áreas irrigadas por pivôs centrais no estado de Goiás e no distrito federal - Brasil. **Boletim de Pesquisa e Desenvolvimento**, . v. 77. 2013.

LEITE, M. E.; ALMEIDA, M. I. S.; VELOSO, G. A.; FERREIRA, M. F. F. Sensoriamento remoto aplicado ao mapeamento da dinâmica do uso do solo na bacia do rio Pacuí, no Norte de Minas Gerais, nos anos de 1989, 1999 e 2009. **Revista do Departamento de Geografia**, v. 23, p. 217-231, 2012.

MATSUNAGA, V. Y. Curso de redes neurais utilizando o matlab. p. 20. 2012.

MATSON, P. A. Agricultural Intensification and Ecosystem Properties. *Science*, v. 277, n. 5325, p. 504-509, 25 jul. 1997.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. Illinois: **The Bulletin of Mathematical Biophysics**, v. 5, n. 4, p. 115–133. 1943.

MENEZES, P. L. De; AZEVEDO, C. A. V. De; EYNG, E.; NETO, J. D.; LIMA, V. L. A. De. Artificial neural network model for simulation of water distribution in sprinkle irrigation. **Revista Brasileira de Engenharia Agrícola Ambiental**, v. 19, n. 9, p. 817–822. 2015.

MOLIN, J. P.; AMARAL, L. R. Do; COLAÇO, A. F. **Agricultura de precisão**. 1. ed. São Paulo: Oficina de Textos, 2015.

NASCIMENTO, M. C.; SOARES, V. P.; RIBEIRO, C. A. S.; SILVA, E. Uso do geoprocessamento na identificação de conflito de uso da terra em áreas de preservação permanente na bacia hidrográfica do rio Alegre, ES. **Ciência Florestal**, Santa Maria, 2005, v. 15, n. 2, p. 207-220, 2007.

OLIVEIRA, T. C. De; FERREIRA, E.; DANTAS, A. A. A. Variação temporal do índice de vegetação por diferença normalizada (ndvi) e obtenção do coeficiente de cultura (kc) a partir do ndvi em áreas cultivadas com soja irrigada. **Ciência Rural**, . v. 46, n. 9, p. 1683–1688. 2016.

PEIXOTO, J. V. M.; MORAES, E. R. De; PEIXOTO, J. L. M.; NASCIMENTO, A. Dos R.; NEVES, J. G. Tomaticultura: aspectos morfológicos e propriedades físico-químicas do fruto. **Revista Científica Rural**, . v. 19, n. 1, p. 96–117. 2017.

PEREIRA JÚNIOR, L. C.; FERREIRA, N. C.; MIZIARA, F. A expansão da irrigação por pivôs centrais no estado de goiás (1984-2015). **Boletim Goiano de Geografia**, . v. 37, n. 2, p. 323–341. 2017.

PEREIRA, R. M.; CASAROLI, D.; QUIRINO, D. T.; CAETANO, J. M.; VELAME, L. M. Estimativa do índice de área foliar da cana-de-açúcar a partir de imagens do satélite landsat-8 (OLI). **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto**, . v. 8, n. 1, p. 6381–6388. 2015.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2. ed. atual. ampl. São Paulo: Oficina de Textos, 2012. 160 p.

REIS, L. S.; AZEVEDO, C. A V. De; ALBUQUERQUE, A. W.; S. JUNIOR, J. F. Índice de área foliar e produtividade do tomate sob condições de ambiente protegido. Campina Grande: **Revista Brasileira de Engenharia Agrícola e Ambiental**, . v. 17, n. 4, p. 386–391. 2013.

RIO, A.; SIBALDELLI, R. N. R.; CRUSIOL, L. G. T.; CARVALHO, J. F. C.; FERREIRA, L. C.; NEIVERTH, W. .; ALMEIDA, A. M. R. .; PROCOPIO, S. O.; NEUMAIER, N.; NEPOMUCENO, A. L.; FARIAS, J. R. B. Área foliar e comportamento espectral de cultivares de soja sob distintos arranjos de plantas. **vii Jornada Acadêmica Embrapa Soja**, . 2007.

ROUSE, J. W.; HASS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with erts. **Third Earth Resources Technology Satellite (ERTS) symposium**, . v. 1, p. 309–317. 1973.

RUSSELL, S.; NORVIG, P. **Inteligência artificial**. 3ª ed. CAMPUS, 2010.

SANTOS, E. Das V.; RODRIGUES, A. M. B.; ALMEIDA, Andre Quintão De; CERQUEIRA, E. S. A.; LOUREIRO, D. C. Estimativa do índice de área foliar em plantio de eucalipto com dados orbitais landsat. p. 1316–1320. 2013.

- SAFA, M.; SAMARASINGHE, S.; NEJAT, M. 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**, v. 17, n. 4, p. 791–803. 2015.
- SCHIAVO, M. LO; PRINARI, B.; GRONSKI, J. A.; SERIO, A. V. An artificial neural network approach for modeling the ward atmosphere in a medical unit. **Mathematics and Computers in Simulation**, v. 116, p. 44–58. 2015.
- SHARMA, A. K.; SHARMA, R. K.; KASANA, H. S. Prediction of first lactation 305-day milk yield in karan fries dairy cattle using ann modeling. **Applied Soft Computing Journal**, v. 7, n. 3, p. 1112–1120. 2007.
- SHIRATSUCHI, L. S.; BRANDAO, Z. N.; VICENTE, L. E.; VICTORIA, D. C.; DUCATI, J. R.; OLIVEIRA, R. P.; VILELA, M. F. Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. (Ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 58-73.
- SILVA, H. A.; PIMENTEL, R. M. M.; GALVÍNCIO, J. D. Conceitos Básicos: princípios físicos em sensoriamento remoto. In: GALVÍNCIO, J. D. **Sensoriamento Remoto e Análise Ambiental**. Recife: Ed. Universitária da UFPE, 2012, 13-19 p.
- SILVA, I. N. Da; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas – curso prático**. São Paulo: Artliber, 2010.
- SILVA, L. F. M. Da; SILVA, C. J. Da; SILVA, C. A. Da; SILVA, N. E. P. Da; FREITAS, C. A. De; GOLYNSKI, A. Área foliar e índice de área foliar de plantas de tomateiro em função de níveis de reposição da evapotranspiração da cultura. n. 64, p. 1676–1681. 2015.
- SIMÕES, M. D. S. **Relação entre indicadores de crescimento e de produção da cana-de-açúcar e dados espectrais terrestres e orbitais mauricio dos santos simões**. 2004. 2004.
- SOARES, F. C.; ROBAINA, A. D.; PEITER, M. X.; RUSSI, J. L. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, . v. 45, n. 11, p. 1987–1993. 2015.
- USGS. Landsat 8 (18) data users handbook v4.0. v. 8, n. April. 2019.
- WEISS, M.; BARET, F.; SMITH, G. J.; JONCKHEERE, I.; COPPIN, P. Motives to respond without prejudice: predictors of greater expressed inclusiveness toward students with disabilities by pre-service teachers? **Agricultural and Forest Meteorology**, . v. 121, n. 1, p. 37–53. 2004.
- XAVIER, A. C.; VETTORAZZI, C. A. Mapping leaf area index through spectral vegetation indices in a subtropical watershed. **International Journal of Remote Sensing**, . v. 25, n. 9, p. 1661–1672. 2004.
- ZANCHI, F. B.; WATERLOO, M. J.; AGUIAR, L. J. G.; RANDOW, C. VON; KRUIJT, B.; CARDOSO, F. L.; MANZI, A. O. Estimativa do índice de área foliar (IAF) e biomassa em pastagem no estado de rondônia, brasil. **Acta Amazonica**, . v. 39, n. 2, p. 335–348. 2009.

ZARIFNESHAT, S.; ROHANI, A.; GHASSEMZADEH, H. R.; SADEGHI, M.; AHMADI, E.; ZARIFNESHAT, M. Predictions of apple bruise volume using artificial neural network. Mashhad: **Computers and Electronics in Agriculture**, v. 82, p. 75–86. 2012.

ZEIST, A.R.; OLIVEIRA, J.R.F.; LIMA FILHO, R.B.; SILVA, M.L.S.; RESENDE, J.T.V. Comparação de métodos de estimativa em área foliar em morangueiro. **Pesquisa Agropecuária Gaúcha**, Porto Alegre, v.20, ns. 1/2, p. 33-41, 2014.

## CAPÍTULO 1

### SELEÇÃO DE MODELOS DE REGRESSÃO PARA ESTIMAR O ÍNDICE DE ÁREA FOLIAR UTILIZANDO IMAGENS DE SENSORIAMENTO REMOTO

#### 1. INTRODUÇÃO

Devido ao crescente aumento da população consumidora se torna necessário que a obtenção de alimentos siga o mesmo ritmo de crescimento. Para isso, a prática da agricultura precisa ser uma atividade econômica minimamente sustentável, precisa que haja o aumento da produção, sem o aumento das áreas atualmente cultivadas. Então é necessário que ocorra o aumento da produtividade. A solução apresentada por Molin et al. (2015) e por Tschiedel e Ferreira (2002) é oferecer tratamentos diferenciados conforme a necessidade da área.

Os agricultores que trabalham com pequenas áreas e que não possuem grande quantidade de maquinário ou implementos, acabam adquirindo maior conhecimento do local de trabalho e fazem o tratamento diferenciado naturalmente. Quando se trata de grandes campos cultivados, não é possível que o agricultor tenha o mesmo conhecimento, pois para tratar todo o campo em tempo hábil é necessário a utilização de maquinários que generalizam a área de maneira uniforme. O que não é a melhor forma de otimização da produtividade, visto que o solo, o relevo e a cultura podem apresentar diferenças dentro da mesma área (MOLIN et al., 2015).

A agricultura de precisão (AP) visa resgatar a habilidade que o agricultor tem ao trabalhar com pequenas extensões de terra, permitindo que ele trabalhe com grandes extensões e suas operações mecanizadas tratando as diferenças intrínsecas das áreas. Só que no lugar da observação visual, utiliza-se sensores e ajustes automáticos das operações e tratamentos culturais a partir da investigação da variabilidade espacial da lavoura, o conhecimento agrônomo adquirido com o uso de máquinas e automação dos processos, reproduzindo parte do detalhamento promovido pelo agricultor no gerenciamento de pequenas áreas (MOLIN et al., 2015).

A definição de AP é muito vasta, pode se apresentar de diferentes formas e definições, dependendo das ferramentas que estejam sendo empregadas. A utilização do Sistema de Posicionamento Global (GPS) permite o georreferenciamento de dados nas lavouras, o que gera um nível de detalhamento das áreas que permite tratar devidamente as diferenças de solo, relevo, cultivar. A aplicação de conhecimentos da Tecnologia da Informação (TI), que consiste no conjunto das atividades e soluções promovidas por recursos computacionais, é utilizada de formas bastante diferentes desde as etapas pré-lavoura até pós-lavoura. A AP, da forma como é tratada hoje, pode ser compreendida como a aplicação de TI durante a condução das lavouras (MOLIN et al., 2015).

Bramley (2009) sugere que AP é um conjunto de tecnologias que promovem uma melhor gestão da produção agrícola por meio do reconhecimento do “potencial de resposta” das lavouras, potencial este que pode variar, consideravelmente, mesmo em pequenas distâncias, da ordem de poucos metros. Uma das formas para avaliar o “potencial de resposta” é aplicar o conceito de amostragem georeferenciada, que é semelhante às amostragens convencionais. No entanto, visam caracterizar um todo a partir da avaliação de apenas uma pequena porção representativa do mesmo. E a determinação da posição de cada amostra no espaço, ou seja, georeferenciada a um sistema de coordenadas. O tipo mais comum de amostragem georeferenciada utilizada na AP é a amostragem em grade, que se caracteriza em dividir o campo em células e dentro de cada uma é coletada uma amostra georeferenciada (COLAÇO e MOLIN, 2015).

Para criação da amostragem em grade ou grade amostral, deve-se seguir uma estratégia de coleta própria para caracterizar a variabilidade espacial do fator investigado. Tendo essa caracterização, se define a densidade amostral (tamanho das células) por meio de um sistema de informação geográfica (SIG) ou algum software dedicado, se cria uma grade virtual sobre a área, que é dividida em polígonos (geralmente quadrados), no centro de cada polígono é gerado um ponto amostral (COLAÇO e MOLIN, 2015).

Entretanto, a qualidade da grade amostral está diretamente relacionada com a densidade amostral. Deste modo, o planejamento da quantidade de pontos amostrais por unidade de área depende do raio de influência da variável analisada, que a torna representativa de uma área. Se o raio de influência da variável for pequeno, serão necessários mais pontos para representar a área. O produto da grade amostral é um mapa de pontos, em que cada ponto representa uma área, com cerca de alguns metros quadrados. Os pontos são plotados num sistema cartesiano, no qual o eixo x é a longitude e o eixo y é a latitude (COLAÇO e MOLIN, 2015).

O Índice de Área Foliar (IAF) representa a Área Foliar (AF) total por unidade de área do terreno, que funciona como um indicador da superfície disponível para interceptação e absorção luminosa visando realizar a fotossíntese. A variação do IAF durante o ciclo das culturas agrícolas é um dado importante para determinação da data de semeadura e transplante. A semeadura das culturas deve ser programada de modo que os valores máximos do IAF coincidam com a época em que a radiação esteja elevada, quando a fotossíntese líquida será máxima (REIS et al., 2013; SILVA et al., 2015).

O IAF é um dos principais parâmetros fisiológicos da planta relacionado com a transpiração, a produtividade e as condições hídricas. Esse parâmetro representa uma importante propriedade do dossel da vegetação no qual a área das folhas medida por unidade de área do terreno também pode ser utilizada em estudos biogeoquímicos e ecológicos de uma cultura, bem como em avaliações da interceptação da água e a cobertura de terreno e na determinação das trocas gasosas de água e carbono (ALMEIDA et al., 2015; DANELICHEN et al., 2017).

A partir da correlação entre a largura e o comprimento das folhas e por meio da análise de regressão pode-se obter os modelos matemáticos que estimam a área foliar. O IAF pode ser obtido de forma direta (método destrutivo), onde há retirada das folhas, ou indiretamente (método não destrutivo), onde não tem necessidade de remoção das folhas, garantindo assim a integridade da planta, destacando-se entre estes métodos não destrutivos os modelos que relacionam valores de IAF com índices de vegetação (IVs) derivados de sensores remotos (RODY et al. 2014; SOUZA et al. 2018).

Os produtos provenientes das técnicas de sensoriamento remoto têm sido relacionados com estudos que monitoram o crescimento vegetal, onde normalmente busca-se estabelecer relações entre o padrão de evolução do crescimento das plantas no decorrer do tempo com a geração e análises dos índices de vegetação. Um deles é o Índice de Vegetação da Diferença Normalizada (NDVI), obtido a partir da razão entre a diferença e a soma das refletâncias nas bandas do visível e do infravermelho próximo. O NDVI vem apresentando associação direta com a quantidade da biomassa, cobertura do solo, índice de área foliar e interceptação da radiação (PEREIRA et al., 2015).

A medida do IAF obtida a partir do sensoriamento remoto é uma ferramenta acessível que combina a refletância da superfície vegetada medida por sensores sem alterar a área de estudos. Entretanto, a estimativa do IAF a partir dos dados obtidos por estes sensores orbitais não podem ser generalizados e necessitam de validações que levem em consideração as especificidades do local e a dinâmica da vegetação. Por isso, o uso de dados de campo integrados a dados obtidos por sensores orbitais, a partir dos índices de vegetação, como o caso do IAF, tem grande utilidade na área científica, pois ao término das avaliações das estimativas, estes dados fornecem informações úteis a respeito da área de trabalho (DANELICHEN et al., 2016).

Neste sentido, tem-se utilizado o IAF estimado pelas imagens de sensoriamento remoto como um dos principais parâmetros fisiológicos da vegetação, e correlacionando estas informações com a produtividade, evapotranspiração, determinação de danos bióticos e abióticos e até mesmo exigências hídricas em espécies vegetais, como o eucalipto, cana-de-açúcar, morango, tomate, entre outras (ALMEIDA et al., 2015; ZEIST et al. 2014).

Objetivou-se com este trabalho obter estimativas do IAF na cultura do tomate industrial irrigado por meio de pivô central, utilizando técnicas de sensoriamento remoto e modelos de regressão, com o objetivo de selecionar o modelo que melhor relacionasse as variáveis NDVI e o IAF, visando gerar um modelo matemático para estimar o IAF.

## 2. MATERIAL E MÉTODOS

### 2.1. Caracterização e localização da área de estudo

O estudo foi desenvolvido em área comercial de 35 ha de tomate industrial, irrigado por pivô central, no município de Vila Propício-GO, localizado a 15°24'12"S e 48°53'59.69"W com altitude média de 686 m (Figura 1).

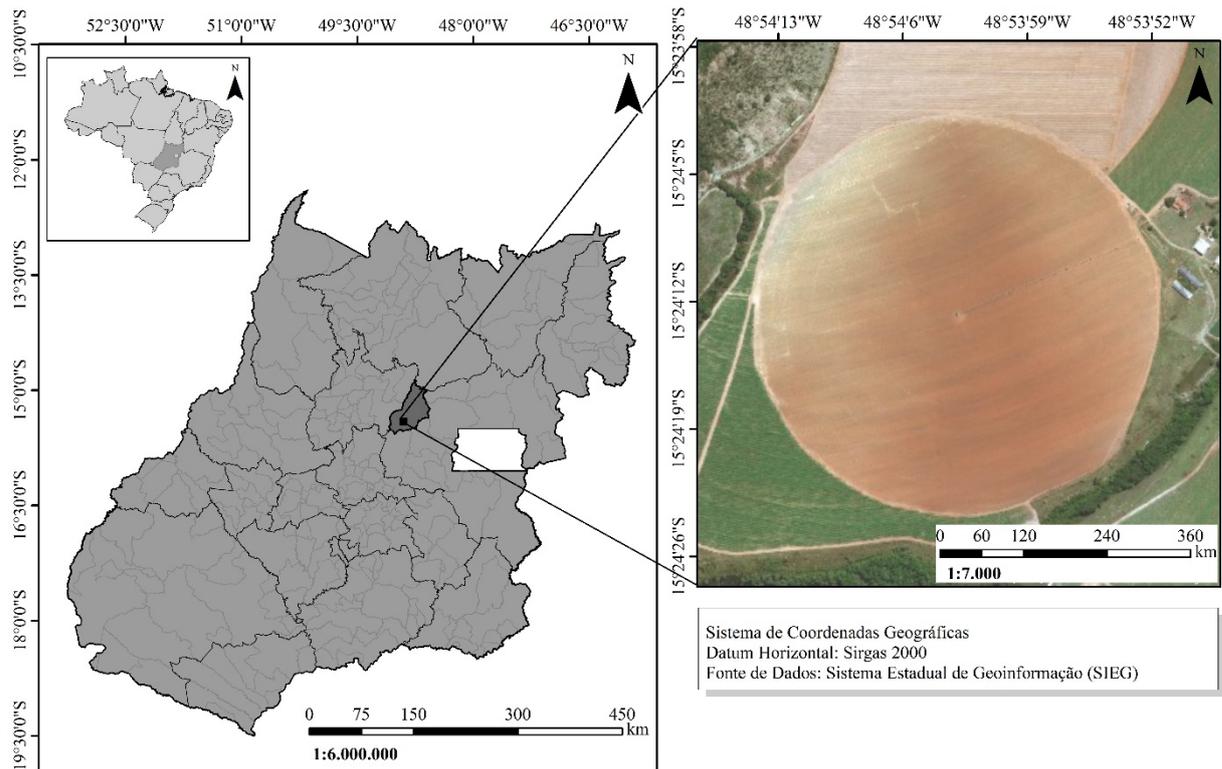


FIGURA 1 - Mapa localizando o Município de Vila Propício-GO e o mapa da área experimental.

O clima da região, segundo classificação de Köppen, é Aw com duas estações bem definidas, com verão chuvoso e inverno seco. A temperatura média anual é de 22,5 °C e a média anual de pluviosidade é 1370 mm (CARDOSO et al., 2014).

Os solos são do tipo Cambissolo Háplico Distrófico, com textura argilosa. O início do transplântio foi em 24 de abril de 2018, numa área de plantio direto na palha, com mudas de 30 dias após a germinação. O espaçamento de 0,3 m entre plantas e de 1 m entre linhas com densidade de 30 mil plantas por hectare (Figura 2). O híbrido de tomate industrial plantado foi o N901, que se destaca pelo excelente enfolhamento, tendo como estimativa de produção 50 frutos por planta (NUNHEMS, 2016).



FIGURA 2 - Espaçamento de 0,3 m entre plantas e de 1 m entre linhas.  
Fonte: arquivo pessoal (2018).

## 2.2. Formação da grade amostral

Com base nos experimentos de Soares et al. (2019) e Scavacini et al. (2015) foi adotada a grade amostral de 60x60 m (Figura 3), gerada com o auxílio do *software* de informações geográficas QGIS, no sistema de coordenadas planas *Universal Transversa de Mercator* (UTM) fuso 22 S, totalizando 88 pontos, a grade amostral foi construída tendo como referência as linhas de plantio.

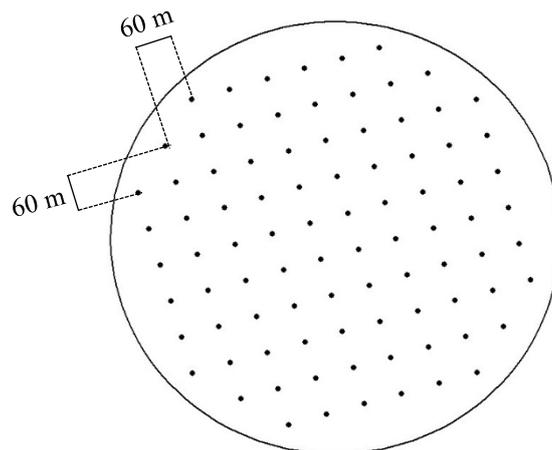


FIGURA 3 - Grade amostral da área experimental.  
Fonte: autoria própria (2018).

Com 30 dias após o transplântio (DAT) foi feito o estaqueamento dos 88 pontos da grade amostral (Figura 4).



FIGURA 4 - Estaca marcando o primeiro ponto da grade amostral.

Fonte: arquivo pessoal (2018).

### 2.3. Características avaliadas e coleta de dados in loco

Aos 76 Dias Após o Transplântio (DAT), dia 09 do julho de 2018, data escolhida para coincidir com a passagem do satélite e o estágio pós-floração, período do ápice do IAF e início do seu declive. Foram avaliados o Número de Plantas (NP), Área Foliar (AF) e o Índice de Área Foliar (IAF), para cada demarcação do ponto da grade amostral. Para coleta dos dados, foi utilizado uma armação com área de 1 m<sup>2</sup>.

#### 2.3.1. Contagem do número de plantas

Foi contada a quantidade de plantas dentro da armação.

#### 2.3.2. Definição metodologia para calcular a área foliar

As metodologias disponíveis e viáveis para mensurar AF foram por meio da análise de imagem por *software* e por meio de um medidor foliar a laser portátil modelo LICOR (CI-202) (Figura 5), para a escolha da metodologia foi feito o estudo comparativo entre os dados obtidos por um *software* e os dados obtidos pelo medidor foliar, o resultado do estudo pode ser visto em Barbosa et al. (2018).



FIGURA 5 - Medidor foliar a laser portátil modelo LICOR (CI-202).  
Fonte: CID Bio-Science (2018).

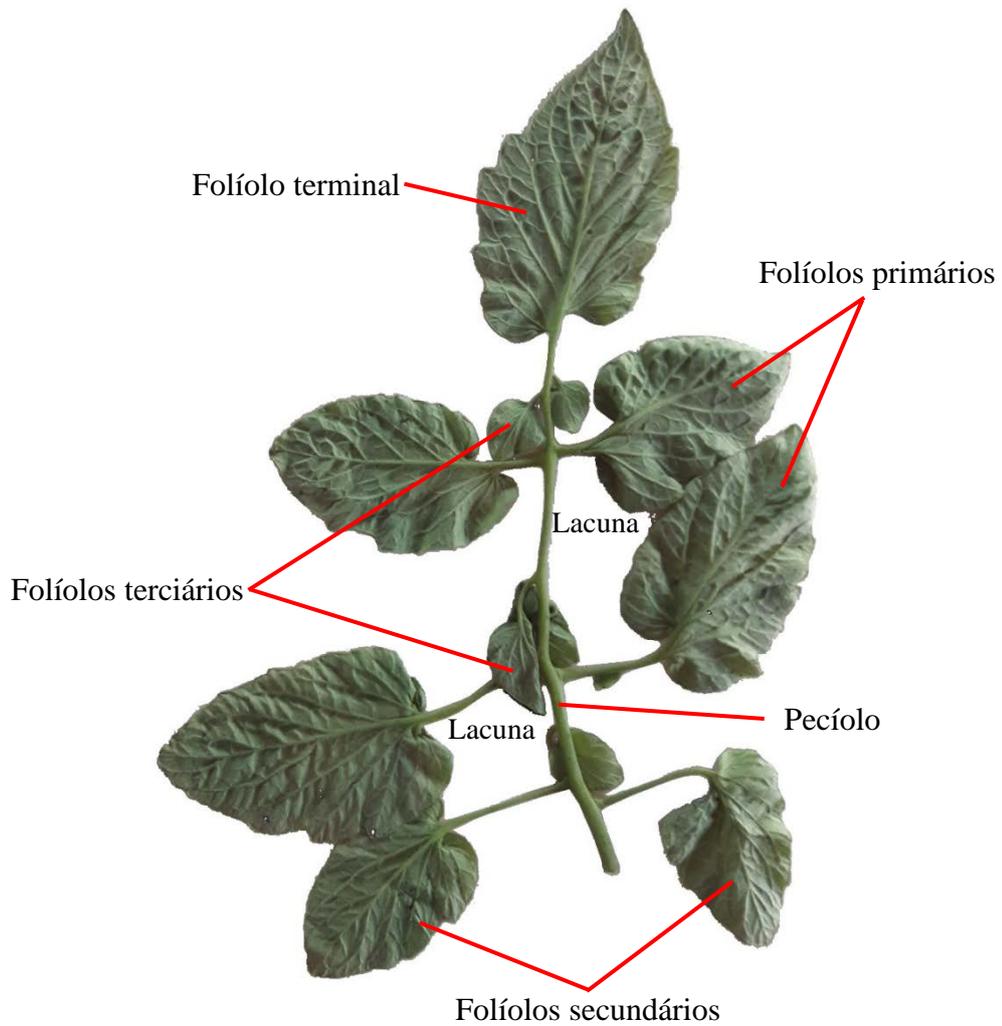


FIGURA 6 - Folha composta por diferentes níveis de folíolos e com a presença de duas lacunas.  
Fonte: arquivo pessoal (2018).

Segundo Martin et al., (2013) e Sfair (2016) o *software* ImageJ possui as funções necessárias para mensurar a AF. Para testar o *software* foi mensurado a AF de uma folha, Figura 6, e obteve-se o valor de 292.382 cm<sup>2</sup> enquanto que o medidor foliar obteve o valor de 292,46 cm<sup>2</sup>, resultado que corrobora com os resultados encontrados por Barbosa et al. (2018). Como ambas as metodologias, por *software* e por medidor foliar, apresentaram AF semelhante, o critério de aplicabilidade foi avaliado.

- **Software ImageJ:** para calcular a AF de folha de estrutura simples, segue-se a metodologia proposta por Sfair (2016), mas devido as folhas do tomateiro serem compostas foi necessário fazer alterações que levassem em conta a presença dos folíolos. Os folíolos estão ligados ao pecíolo com alternância de níveis (Figura 6), o que faz surgir lacunas ao fotografar uma folha, na metodologia de Sfair (2016) essas lacunas são mensuradas como parte da AF, gerando um valor maior que o real. Outra característica observada é que se a imagem apresentar sombra, esta será mensurada como parte da AF, gerando valor maior.
- **Medidor foliar a laser portátil modelo LICOR (CI-202):** para calcular a AF de folhas quem tem o mesmo ou menor tamanho que sua base o procedimento é padrão, coloca a folha de forma que todos os folíolos fiquem abertos, sem que nenhum sobreponha outro, passa o scanner do medidor foliar e obtêm-se AF. Em casos que a folha é maior que a base/capacidade do medidor é necessário desmembrar a folha, remover os folíolos e medi-los, separadamente, gerando vários dados para a mesma folha. No término, é necessário fazer a soma dos valores das partes.

Ambas as metodologias apresentaram alguma limitação na aplicabilidade, os fatores decisivos para a escolha da metodologia foram os critérios: tempo de aferição, manuseio, conservação e transporte da folha. Com a utilização de análise de imagem foi possível retirar as folhas das ramas, tirar as fotos e descartar as folhas no próprio ponto da grade amostral, mesmo o processo sendo rápido, observou-se que havia uma perda de água das folhas.

Apesar do medidor foliar ser portátil é necessária uma superfície para colocá-lo em cima enquanto posiciona/organiza a folha. Por isso é necessário coletar, armazenar e transportar as folhas, o que aumenta o tempo gasto entre a coleta e a análise, gerando desgaste das folhas. Levando em consideração as características avaliadas em relação à folha do tomate industrial, a análise de imagem apresentou melhor tempo na aquisição dos dados, não sendo necessário o armazenamento e transporte das folhas, sendo ainda possível fazer análises visuais nas folhas, visto que as imagens não foram descartadas.

### 2.3.3. Obtenção da área foliar

Duas plantas de forma aleatória foram separadas dentro da armação, com cuidado para não as danificar. Depois, foi feita a contagem do número de folhas (NF) das ramas separadas seguindo o padrão. Inicialmente, contando as folhas da haste principal e depois das hastes laterais. Dentre as folhas contadas, dez foram retiradas de forma aleatória e identificadas, colocando-as sobre uma mesa redonda de cloreto de polivinila (PVC) de raio 25 cm (Figura 7), que contém uma reta medindo 2,1 cm de comprimento que é utilizada para calibração do *software*.



FIGURA 7 - Mesa de policloreto de polivinila (PVC) desenvolvida para tirar fotos no campo.  
Fonte: arquivo pessoal (2018).

As dez folhas foram fotografadas, individualmente, com a câmera de um celular com a resolução de 8.0 *megapixels* (Figura 8), que posteriormente, foram submetidas à análise de AF por meio do *software* ImageJ de domínio público, (disponível gratuitamente via internet <http://rsbweb.nih.gov/ij/>), seguindo os procedimentos detalhados no Apêndice A. Os dados obtidos referentes às AFs foram armazenados em um *software* de planilhas eletrônicas.

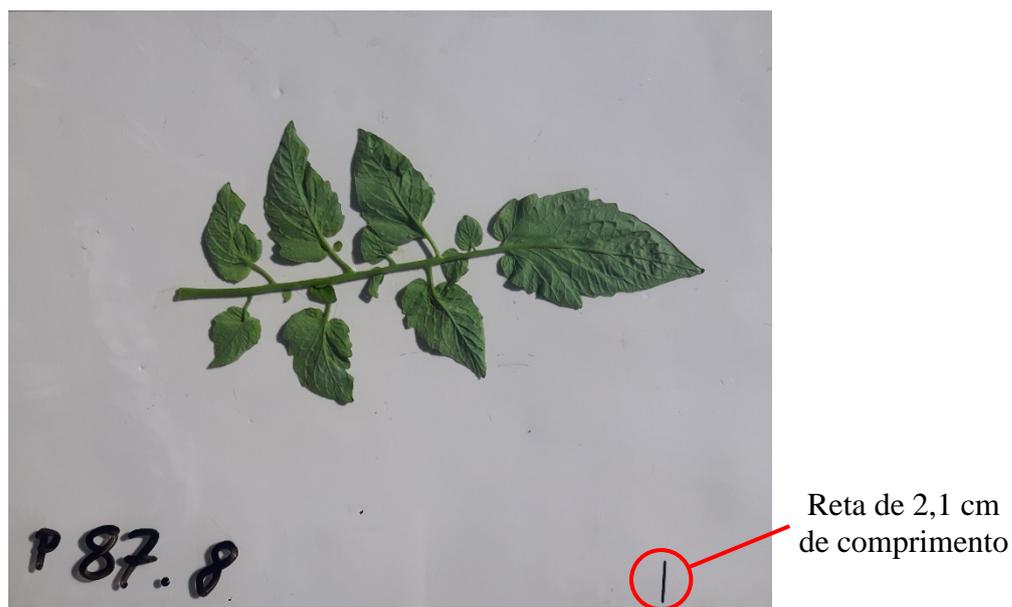


FIGURA 8 - Folha tirada do ponto 87,8° amostra, no canto inferior direito, reta medindo 2,1 cm de comprimento que é utilizada para calibração do software.

Fonte: arquivo pessoal (2018).

#### 2.3.4. Cálculo do índice de área foliar

Os dados de IAF foram obtidos por meio da relação AF sobre a superfície do solo ocupada pela planta, representando a AF total por unidade de área (Equação 1), os cálculos e o armazenamento foram feitos utilizando um *software* de planilhas eletrônicas.

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

em que:

- IAF - índice de área foliar,  $m^2 m^{-2}$ ;
- AF - área foliar média de duas plantas,  $m^2$ ;
- NP - número de plantas por metro quadrado;
- AT - área total considerada,  $1 m^2$ .

### 2.4. Características avaliadas por sensoriamento remoto

#### 2.4.1. Software e complementos

Para o processamento das imagens orbitais foi utilizado o *software* QGIS, versão 3.4.1-Madeira, licenciado sob *General Public License* (GNU) e os complementos: *Semi-Automatic Classification Plugin* (SCP) e *Point sampling tool*. Ambos os complementos foram instalados no QGIS pelo “Gerenciar e Instalar Complementos...”.

O SCP é um complemento que oferece diversas funcionalidades como:

- Download de imagens disponíveis para Landsat, Sentinel-2, Sentinel-3 e ASTER;
- Pré-processamentos (exemplo: correção atmosférica);
- Pós-processamentos;
- Calculadora *raster* (que pode ser utilizada para calcular os índices de vegetação).

Entre tantas outras funcionalidades, como pode ser visto com mais detalhes em Congedo (2017). O complemento *Point Sampling Tool* coleta atributos de polígonos e valores *raster* de várias camadas em pontos de amostragem especificados (JURGIEL, 2018).

A integração dos processamentos e a facilidade no manuseio são as principais características desses complementos que objetivam prover um conjunto de ferramentas entrelaçadas para o processamento rasterizado, a fim de efetuar um fluxo de trabalho automático, com o intuito de facilitar a classificação da cobertura terrestre e a extração de valores de imagens (CONGEDO, 2017; JURGIEL, 2018).

#### 2.4.2. Procedimentos operacionais

Para a captura das imagens orbitais, da área estudada, foi utilizado o sensor *Operational Land Imager* (OLI) do satélite Landsat 8, órbita 222, ponto 71 e os sensores *Multispectral Instrument* (MSI) dos satélites Sentinel-2A e Sentinel-2B, localizado na T22LGJ da *Military Grid Reference System* (MGRS) dos EUA, as imagens são disponibilizadas de maneira gratuita pela *United States Geological Survey* (USGS) na guia do produto Landsat 8 (USGS, 2015a) e Sentinel-2 (USGS, 2015b). As imagens analisadas foram capturadas em datas próximas ao dia 09 de julho de 2018, DAT 76, data do início da coleta do IAF *in loco* (Tabela 1).

TABELA 1 – Dias após transplântio, data, hora, e satélite de origem das imagens orbitais analisadas.

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

Fonte: autoria própria (2018).

As imagens passaram por um processo de refinamento para definir quais imagens podem ser utilizadas em função da:

- Visibilidade, atmosfera livre de presença de nuvens;
- Qualidade do imageamento do sensor, sem ruídos;
- Homogeneidade do período da captura da imagem.

#### **2.4.3. Conversão da refletância do topo da superfície para valores de refletância da base da superfície**

Em cada imagem, previamente, selecionada foi realizada a conversão da refletância do topo da superfície (TOA) para valores de refletância da base da superfície (BOA) por meio do arquivo *metadata* que é disponibilizado junto com as imagens. Esse arquivo contém os parâmetros de transformação necessários para realizar a conversão da reflectância de TOA para BOA, os procedimentos detalhados estão no Apêndice B.

#### **2.4.4. Conversão do sistema de referência de coordenadas**

Foi necessário fazer a conversão do Sistema de Referência de Coordenadas (SRC), seguindo os procedimentos detalhados no Apêndice C, pois as imagens disponibilizadas pelo Landsat são em WGS 84 / UTM zona 22N e as do Sentinel são em WGS 84 / UTM zona 22S, mas no Brasil o sistema de referência oficial é o Datum SIRGAS 2000 (Sistema de Referência Geocêntrico para as Américas) e o sistema de coordenadas é UTM e a área de estudo está na zona 22S (IBGE, 2018; SIRGAS, 2018).

#### **2.4.5. Cálculo do índice de vegetação por diferença normalizada**

O NDVI varia de -1 a +1 (quanto mais próximo de 1, maior a densidade de cobertura vegetal), e pode ser obtido pela Equação 2, de acordo com Deering et al (1975):

$$NDVI = \frac{(\rho_{ivp} - \rho_v)}{(\rho_{ivp} + \rho_v)} \quad (2)$$

em que:

- $\rho_{ivp}$  - reflectância na banda do infravermelho próximo - NIR;
- $\rho_v$  - reflectância na banda do vermelho visível.

Para elaboração desse índice de vegetação foi utilizado o roteiro apresentado no Apêndice D, que para o satélite Landsat 8 foram utilizadas as reflectâncias das bandas do vermelho (R04) e do infravermelho próximo (R05). A relação é demonstrada na Equação 3 e para os satélites Sentinel-2(A e B) foram utilizadas as reflectâncias das bandas do vermelho (R04) e do infravermelho próximo (R08) a relação é demonstrada na Equação 4.

$$\text{NDVI} = \frac{(R05 - R04)}{(R05 + R04)} \quad (3)$$

$$\text{NDVI} = \frac{(R08 - R04)}{(R08 + R04)} \quad (4)$$

Foram calculados o NDVI para cada data de passagem mostrada na Tabela 2, gerando seis imagens no formato *raster*. Dados *raster* são formados por uma matriz de *pixels* (também conhecido como células), no qual cada *pixel* contém dados gravados na sua descrição que representam a condição da área coberta por ele (QGIS, 2018a).

#### **2.4.6. Extrair valores *raster* de pontos específicos**

Para se obter o valor do NDVI de um determinado *pixel* é necessário extrair o valor da descrição do *pixel* (QGIS, 2018a), para determinar os pontos de extração dos dados de NDVI foi utilizada a grade amostral (Figura 3) e seguido o roteiro apresentado no Apêndice E.

#### **2.4.7. Exportar tabela de atributos par um software de planilhas eletrônicas**

Para fazer as análises estatísticas nos dados de NDVI extraídos é necessário exportar a tabela de atributos da camada gerada para um *software* de planilhas eletrônicas, para exportar segue o roteiro demonstrado no Apêndice F.

### **2.5. Interpolação dos pontos por ponderação pelo inverso da distância**

Para melhor visualização e compreensão das grades amostrais foram criadas superfícies *raster*, também conhecidas como superfície de *pixels* ou mapa de *pixels*. Elas foram feitas mediante ao processo de interpolação dos pontos por Ponderação pelo Inverso da Distância (IDW). Nesse método, cada amostra tem um peso e uma posição no espaço. O valor em um ponto é influenciado pelo valor dos seus vizinhos. Essa influência é maior quanto maior a proximidade entre os pontos desconhecidos que se deseja interpolar (Figura 9a). Utilizando essa lógica, é realizada a interpolação dos dados, ou seja, a estimativa de valores em locais não amostrados, gerando assim o mapa final do atributo (Figura 9b) (QGIS, 2018b).

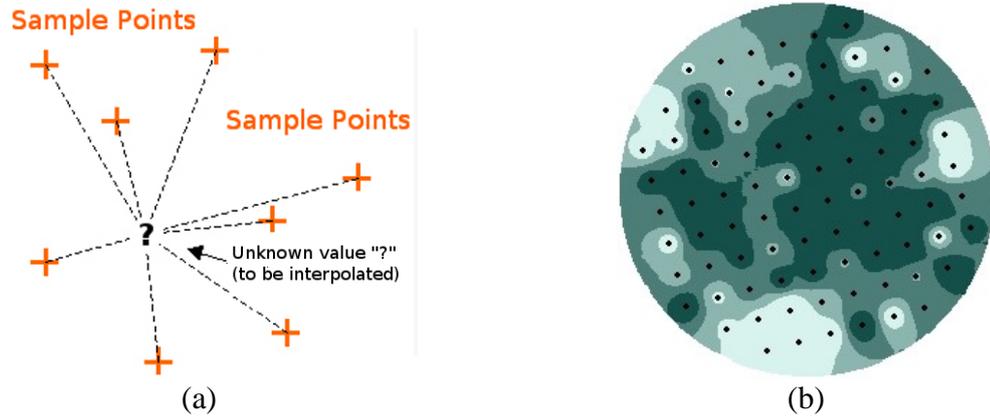


FIGURA 9 - (a) Interpolação por ponderação pelo inverso da distância é baseada na distância ponderada de um ponto amostral. (b) Superfície interpolada a partir de pontos da grade amostral.

Fonte: QGIS (2018b) (Modificada).

A Ponderação é atribuída a pontos amostrais por meio da utilização de um coeficiente de ponderação que controla como a influência da ponderação irá diminuir à medida que a distância a partir do ponto desconhecido aumenta. Quanto maior for o coeficiente de ponderação, sobre menos pontos terá efeito, quanto mais longes do ponto desconhecido durante o processo de interpolação. Aumentando o coeficiente, o valor do ponto desconhecido será mais próximo ao valor dos pontos vizinhos observados (QGIS, 2018b).

Foram feitas interpolações por IDW para os dados obtidos *in loco*, AF e IAF, e os dados obtidos por imagem orbital, NDVI (Figura 10). Após a aplicação deste método de geração de mapas, cada *pixel* da superfície *raster* representa uma área definida, possuindo valores próprios (COLAÇO e MOLIN, 2015).

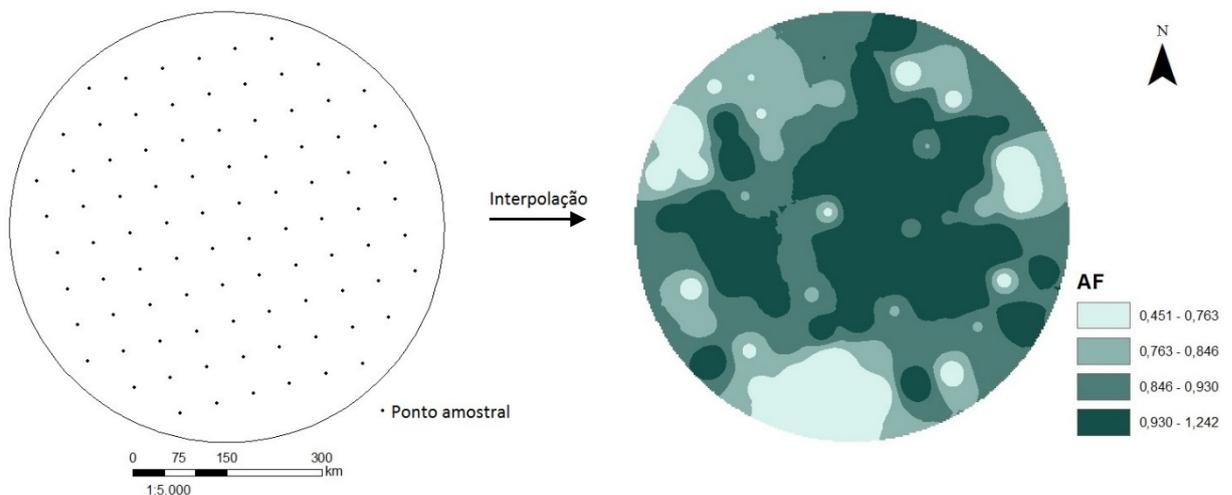


FIGURA 10 - Geração da superfície *raster* a partir da interpolação dos dados obtidos nos pontos amostrais.

Fonte: autoria própria (2019).

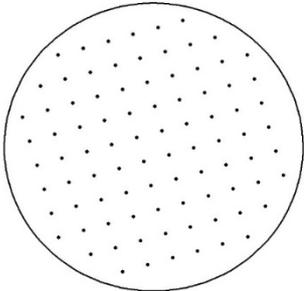
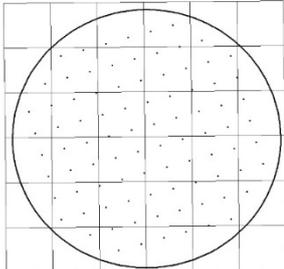
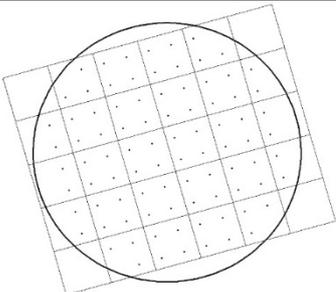
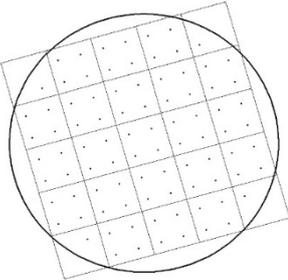
## 2.6. Estatística descritiva

Tendo armazenado em um *software* de planilhas eletrônicas os valores de IAF obtidos *in loco* e o NDVI que foram obtidos por sensoriamento remoto foram submetidos à estatística descritiva por meio da análise exploratória dos dados. Isto possibilitou conhecer e visualizar a tendência, medidas de dispersão e distribuição dos mesmos. A partir dos conjuntos dos dados, foram calculadas as medidas descritivas: média, mediana, variância, desvio-padrão, assimetria, curtose e coeficiente de variação. Os valores *outliers* foram identificados por meio da amplitude Interquartil (IQR).

## 2.7. Índice de área foliar em função do índice de vegetação por diferença normalizada

A análise de correlação foi realizada entre os conjuntos de dados de IAF e NDVI, visto que os valores são associados pelos pontos da grade amostral (coordenadas geográficas: latitude e longitude). As análises foram feitas em quatro variações, nos quais variaram-se a utilização, posicionamento e sentido dos quadrantes em relação aos pontos da grade amostral. Cada quadrante possui o espaçamento de 120x120 m e foi feita a média dos pontos contidos no quadrante, a direção dos quadrantes variou de acordo com os *pixels* e as linhas de plantio, o posicionamento dos quadrantes variou de acordo com a quantidade de pontos dentro de cada quadrante. As variações geraram quantidades diferentes de pontos que podem ser vistos na Tabela 2.

TABELA 2 - Variação dos quadrantes em relação aos pontos da grade amostral, independente do satélite usado.

Variação	Descrição	Imagem
1 <sup>a</sup>	<p><b>Quadrante:</b> nenhum;</p> <p><b>Direção:</b> nenhuma;</p> <p><b>Posicionamento:</b> nenhum;</p> <p><b>Total de pontos gerados:</b> 88.</p>	
2 <sup>a</sup>	<p><b>Quadrante:</b> 120x120 m;</p> <p><b>Direção:</b> seguindo o alinhamento dos <i>pixels</i>;</p> <p><b>Posicionamento:</b> todos os pontos fiquem dentro de um quadrante;</p> <p><b>Total de pontos gerados:</b> 28.</p>	
3 <sup>a</sup>	<p><b>Quadrante:</b> 120x120 m;</p> <p><b>Direção:</b> seguindo a linha de plantio;</p> <p><b>Posicionamento:</b> nenhum ponto fique isolado dentro de um quadrante;</p> <p><b>Total de pontos gerados:</b> 26.</p>	
4 <sup>a</sup>	<p><b>Quadrante:</b> 120x120 m;</p> <p><b>Direção:</b> seguindo a linha de plantio;</p> <p><b>Posicionamento:</b> todos os pontos fiquem dentro de um quadrante;</p> <p><b>Total de pontos gerados:</b> 25.</p>	

Fonte: autoria própria (2018).

As análises de correlação foram feitas para os dados obtidos por ambos os satélites e para todos os dias, o que gerou uma tabela de correlação. Nos tratamentos que apresentaram maior valor de correlação foram aplicados modelos de regressão do tipo linear, exponencial, potência e logarítmica (Equação 5, 6, 7 e 8) para gerar modelos de estimativa de IAF.

$$Y = aX + b \quad (5)$$

$$Y = ae^{bX} \quad (6)$$

$$Y = aX^b \quad (7)$$

$$Y = a + b \ln X \quad (8)$$

em que:

- $Y$  - valores de NDVI;
- $X$  - valores IAF;
- $a$  e  $b$  - estimativas do parâmetro dos modelos.

## 2.8. Ajuste dos modelos

Os modelos de estimativa de IAF foram ajustados a partir da análise de correlação entre as medidas do plantio em campo e os valores dos NDVI. Depois do ajuste dos possíveis modelos, foram selecionados os que apresentaram melhores resultados em 5 critérios conforme Almeida et al. (2015):

1. Teste F para o modelo de regressão deve ser significativo a 5% de probabilidade;
2. Teste t de *Student* para as estimativas de cada parâmetro do modelo de regressão devem ser significativas a 5% de probabilidade;
3. Erro Quadrado Médio da Raiz (EQMR): o modelo de regressão deve apresentar o menor valor de erro quadrado médio da raiz estimados pela Equação 9.

$$EQMR = \sqrt{\frac{\sum_{i=1}^N (P_i - O_i)^2}{N}} \quad (9)$$

em que:

- $P_i$  - valores preditos;
- $O_i$  - valores observados;
- $N$  - coeficientes dos modelos

4. Coeficiente de determinação ( $R^2$ ): o modelo de regressão que apresentar o maior valor do coeficiente de determinação.
5. Critério Bayesiano de Informação (CBI): o modelo de regressão com menor valor do critério bayesiano de informação estimado pela Equação 10.

$$CBI_p = -2\log(L_p) + [(p + 1) + 1] \log(n) \quad (10)$$

em que:

- $L_p$  - função de máxima verossimilhança do modelo;
- $p$  - número de variáveis explicativas consideradas no modelo.

### 3. RESULTADOS E DISCUSSÕES

#### 3.1. Características avaliadas e coleta de dados *in loco*

##### 3.1.1. Número de plantas por m<sup>2</sup>

Os valores de NP contados em campo variaram entre 2 a 5 plantas por m<sup>2</sup>. O valor de 5 plantas por m<sup>2</sup> foi encontrado apenas uma vez no ponto 22 da grade amostral, o qual foi identificado como um valor disperso (*outliers*). O valor que mais se repetiu foi 3 plantas por m<sup>2</sup>, justificado pelo espaçamento adotado no transplanteio de 0,3 m entre plantas e de 1 m entre linhas, gerando um padrão de 3 plantas por m<sup>2</sup>.

Apesar do transplanteio ser mecanizado (Figura 11), podem ocorrer de mais de uma muda ser transplantada para o mesmo ponto, o que ocorre quando o equipamento “engasga”, deixando de transplantar uma muda em um ponto para transplantar duas no próximo, as lacunas que são geradas são preenchidas por uma segunda equipe que segue o trator, outra possibilidade para ter menos plantas é que a planta pode morrer durante o seu ciclo.



FIGURA 11 - Transplante mecanizado de mudas.

Fonte: arquivo pessoal (2018).

### 3.1.2. Área foliar

O cálculo da AF apresentou grande complexidade devido às características dos híbridos do tomate industrial, que têm o seu cultivo rasteiro e, por isso, se espalham rente ao solo, por não possuir tratos culturais específicos do tomate de mesa, como tutoramento e amarrio, desenvolve várias hastes laterais de primeira ordem em diferentes posições na haste principal, o que torna difícil a identificação da haste principal, e devido ao espaçamento adotado, uma rama disputa espaço com as outras (AGEITEC, 2018; MELO, 2017).

A média de folhas por planta foi de 51 cm<sup>2</sup> e a avaliação visual do enfolhamento (Figura 12) corroboraram com os dados técnicos fornecidos pelo produtor da semente, o híbrido do tomate industrial N901 apresenta excelente enfolhamento, característica que gerou densa área foliar (NUNHEMS, 2016).



FIGURA 12 – Densa área foliar do tomateiro.

Fonte: arquivo pessoal (2018).

Devido à configuração do *software* ImageJ e o tamanho das folhas, o cálculo da AF é feito por cm<sup>2</sup>, mas como o cálculo do IAF é medido em m<sup>2</sup>, foi necessário fazer a conversão de centímetros para metros, os valores resultantes da conversão são apresentados na Figura 13a, que mostra a disposição dos valores de AF em relação aos 88 pontos da grade amostral.

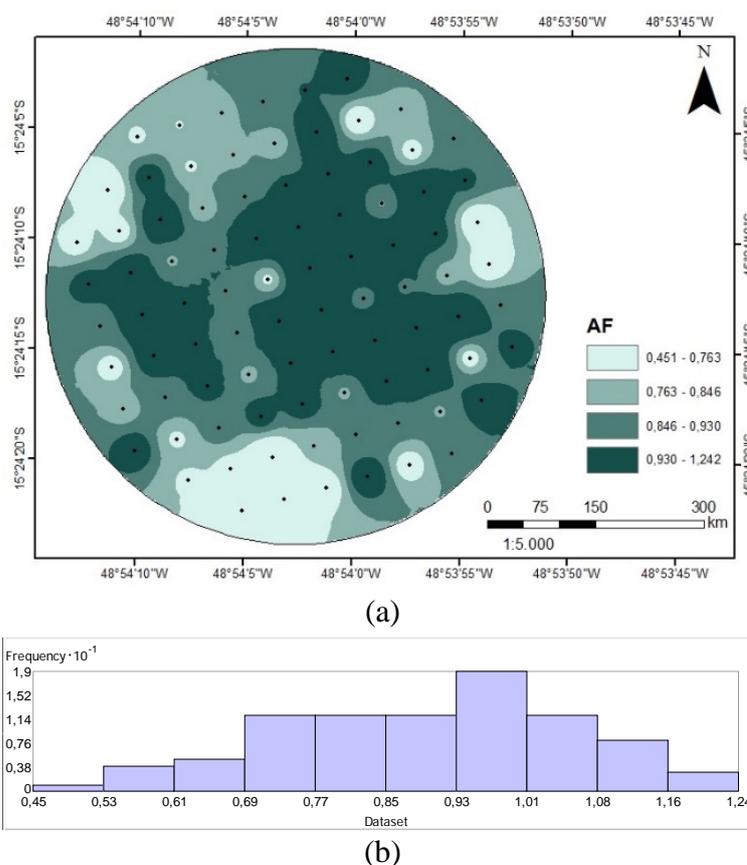


FIGURA 13 - (a) Interpolação por IDW da AF em relação aos pontos da grade amostral; (b) histograma dessa distribuição.

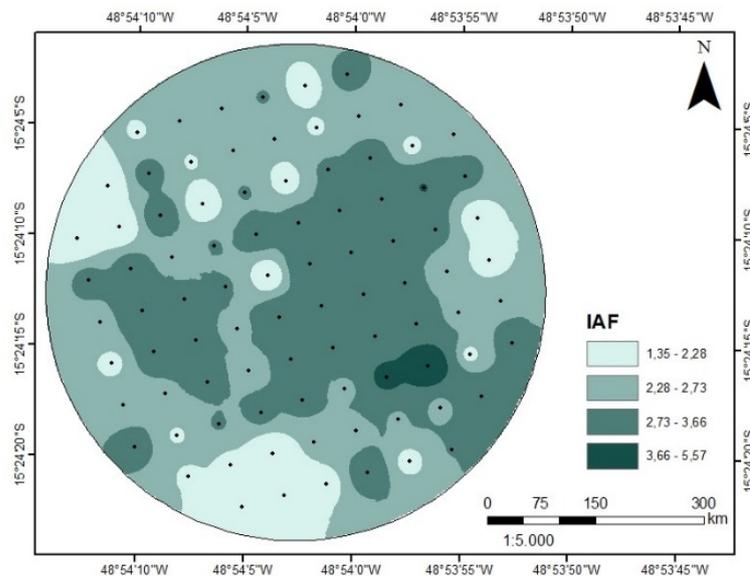
Fonte: autoria própria (2018).

O método de interpolação IDW apresentou desvantagens, as mesmas que são listadas na documentação do QGIS (2018b): a qualidade da interpolação diminuiu na representação das bordas do pivô, isso ocorre devido à distribuição dos pontos amostrais nessas áreas serem irregulares. Além disso, ocorreu pequenos picos e poços em torno dos pontos de dados amostrais, isso se deve aos valores máximos e mínimos na superfície interpolada só poderem ocorrer em pontos de dados de amostra, como mostrado na Figura 13a.

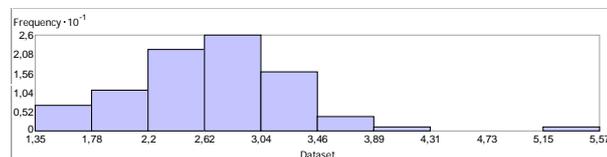
Pela avaliação do histograma (Figura 13b), a distribuição dos dados se aproxima de uma distribuição normal.

### 3.1.3. Índice de área foliar obtido

Os valores de IAF calculados em campo variaram entre 1,35 e 5,57  $\text{m}^2 \text{m}^{-2}$ , sendo o maior valor encontrado em um único ponto, onde foi comprovado pela análise descritiva se tratar de um valor disperso (*outliers*). A Figura 14 mostra a disposição dos valores de IAF em relação aos 88 pontos da grade amostral.



(a)



(b)

FIGURA 14 - (a) Interpolação por IDW da IAF em relação aos pontos da grade amostral; (b) histograma dessa distribuição.

Fonte: autoria própria (2018).

### 3.2. Características avaliadas por sensoriamento remoto

A Figura 15 mostra o NDVI calculado da área de estudo obtida pelo satélite Landsat-8 no qual o tamanho de cada *pixel* é de  $30 \text{ m}^2$  e a Figura 16 mostra a mesma área só que obtida pelo Sentinel-2A no qual o tamanho do *pixel* é de  $10 \text{ m}^2$ .

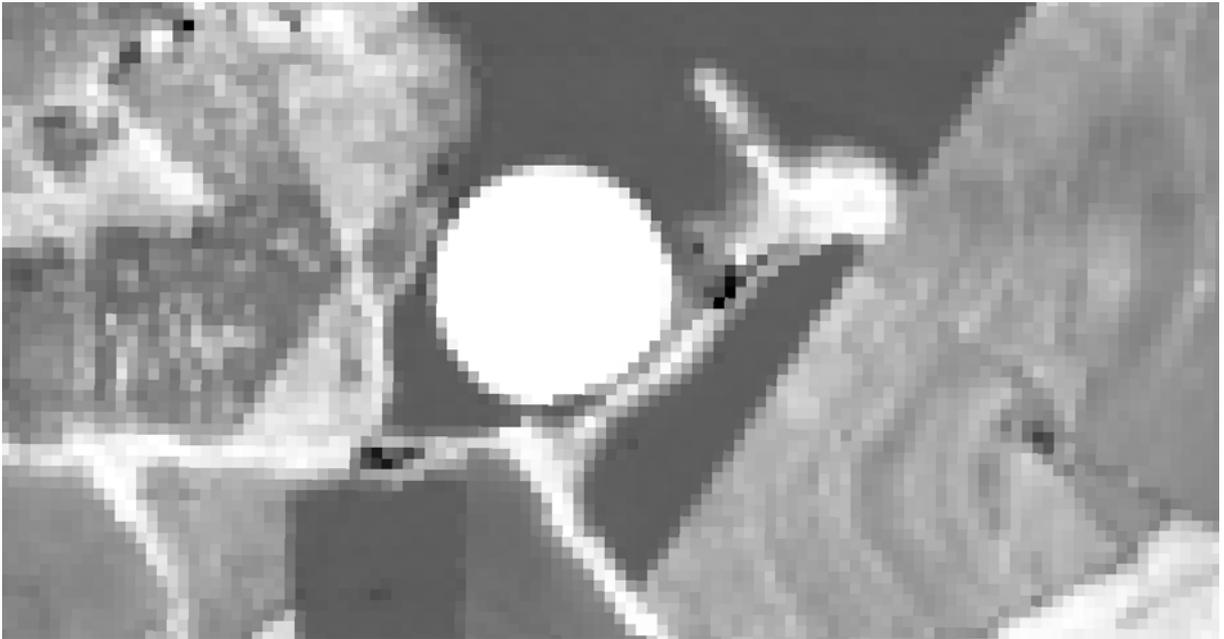


FIGURA 15 - NDVI gerado pelo satélite Landsat 8 com data de passagem 02/07/2018 e escala de 1:10000.

Fonte: autoria própria (2018).



FIGURA 16 - NDVI gerado pelo satélite Sentinel-2A com data de passagem 02/07/2018 e escala de 1:10000.

Fonte: autoria própria (2018).

As imagens não foram tratadas com nenhuma ferramenta de suavização. Na Figura 15 gerada pelo LandSat 8, um *pixel* é igual a 30 m<sup>2</sup>. Qualquer característica dentro dessa área é generalizada, se os 30 m<sup>2</sup> do *pixel* estiver representando parte de uma estrada e a outra parte for uma lavoura. A representação final será a média dos valores quantificados da captura da parte da estrada e da parte da lavoura. Na Figura 16, gerada pelo Sentinel-2A, ocorre o mesmo tipo de generalização, mas a área é menor, um *pixel* é igual a 10 m<sup>2</sup>.

### 3.2.1. Índice de vegetação por diferença normalizada

O NDVI foi calculado para cada imagem, gerando 6 conjuntos de dados. Para identificar a origem dos conjuntos, foi adotado identificadores que variam de acordo com o satélite e a data da imagem (Tabela 3).

TABELA 3 - Identificadores dos conjuntos de dados originados dos satélites.

Satélite	Data imagem	Identificador
LandSat 8	02/07	L02
	18/07	L18
Sentinel-2	02/07	S02
	07/07	S07
	12/07	S12
	17/07	S17

Fonte: autoria própria (2019).

O NDVI calculado dos dados L02 variou de 0,61 a 0,85 (Figura 17a) e dos dados L18 variou de 0,56 a 0,82 (Figura 17b), a diminuição dos valores, entre uma data e outra, é justificada pelo período de declive do IAF, que teve o seu ápice por volta de 70 DAP (REIS, L. S. *et al.*, 2013), o que vale a data aproximada de 03/07.

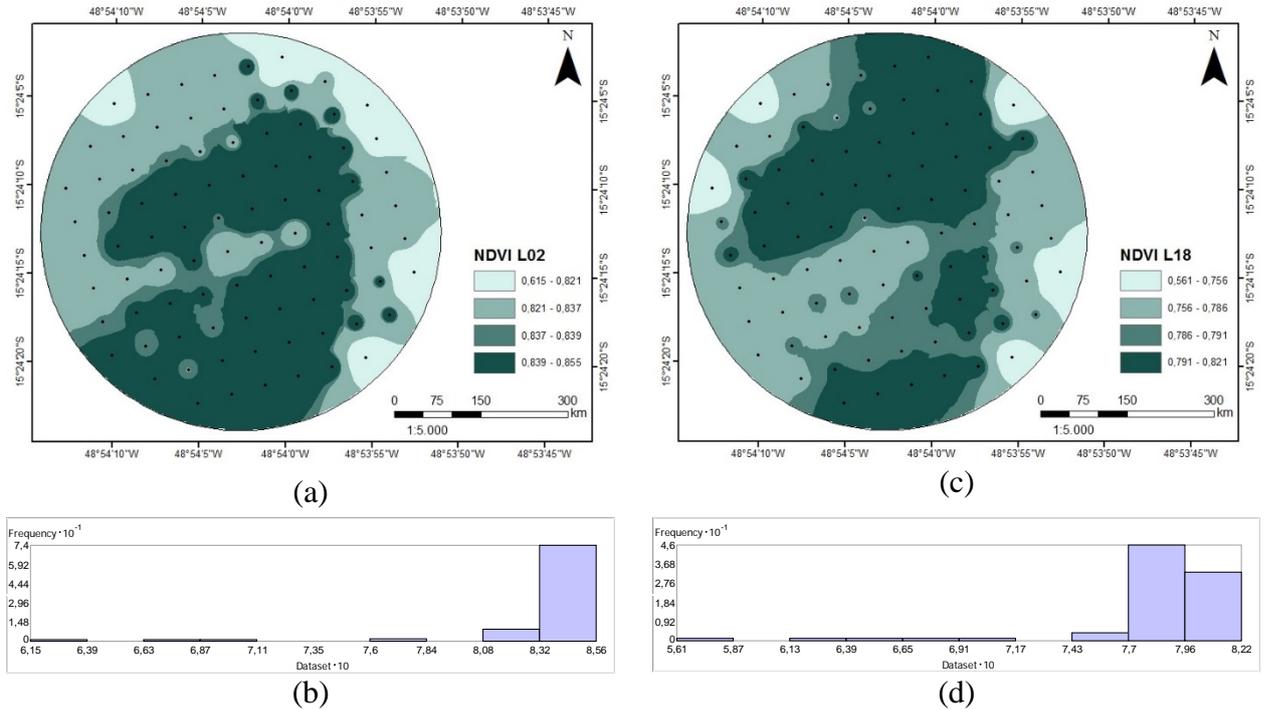


FIGURA 17 - NDVI dos dias (a) 02 e (b) 18 de julho de 2018 do satélite Landsat 8 em função dos pontos da grade amostral.

Fonte: autoria própria (2018).

O NDVI calculado dos dados dos satélites sentinel-2(A e B) variou no conjunto S02 (Figura 18a) de 0,87 a 0,83, no conjunto S07 (Figura 18c) variou de 0,77 a 0,83 e no conjunto S17 (Figura 18g) variou de 0,72 a 0,81, confirmando que o IAF chegou no ápice entre as datas 02/07 e 07/07 e depois começou a declinar.

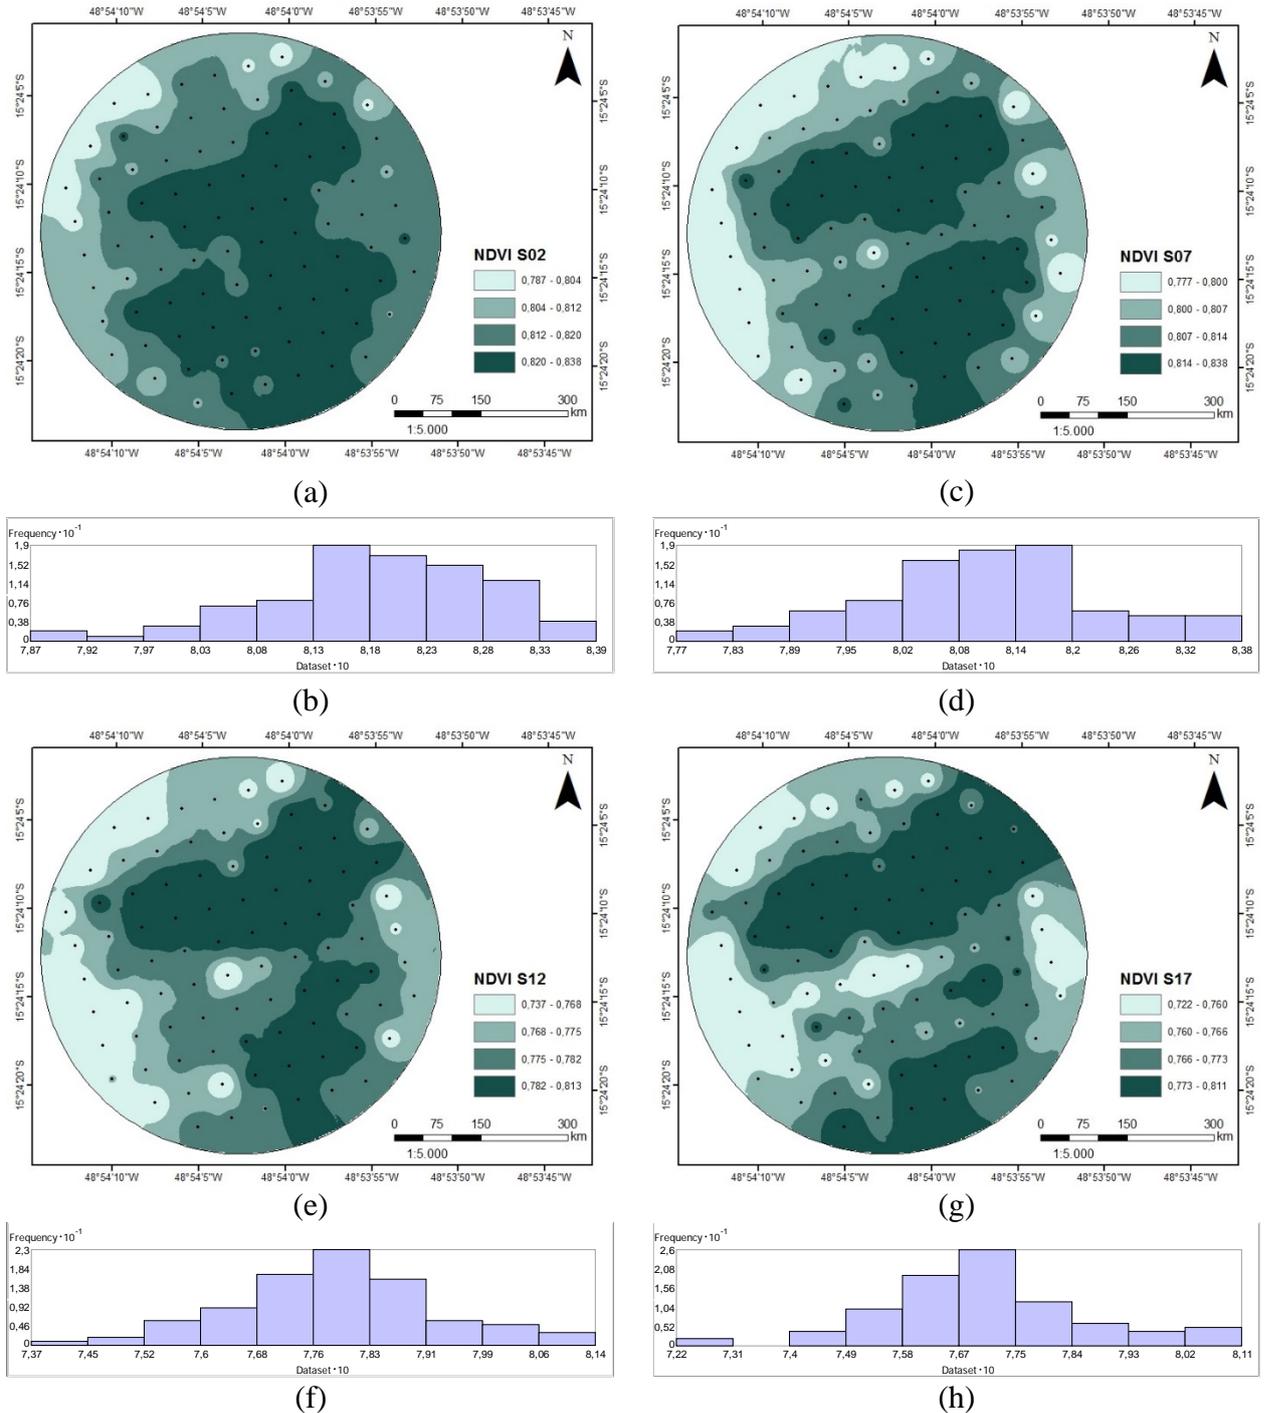


FIGURA 18 - NDVI dos dias (a) 02, (b) 07, (c) 12 e (d) 17 de julho de 2018 do satélite Sentinel-2 em função dos pontos da grade amostral.

Fonte: autoria própria (2018).

A variação dos valores de NDVI ocorrem em função do IAF, quanto maior a AF, maior os valores do NDVI. Essa relação é confirmada por Almeida et al. (2015), que acrescenta que a relação é sempre positiva entre AF e o NDVI.

### 3.3. Índice de área foliar em função do índice de vegetação por diferença normalizada

Em condições de elevado IAF o NDVI torna-se pouco sensível para detectar variações na biomassa, fenômeno conhecido com saturação assintótica (RISSO et al., 2012). Tal fato sugere que o NDVI deve ser calibrado para cada condição de cultivo e espécie vegetal. Esse comportamento foi demonstrando por Wang et al. (2001), conforme a Figura 19. Observa-se que a partir de determinado valor de IAF há pouca alteração no NDVI. Nesse momento, é dito que houve a saturação.

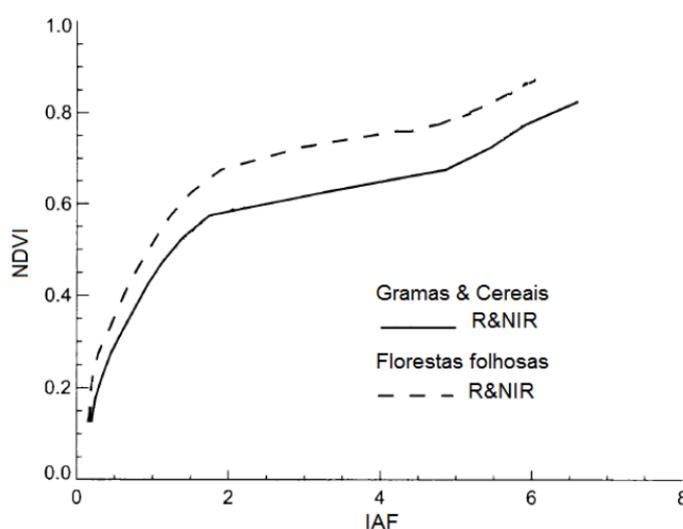


FIGURA 19 - Comportamento do NDVI em função da área foliar de diferentes coberturas vegetais.

Fonte: adaptado de Wang et al. (2001).

Ao analisar os diagramas de dispersão entre os valores de IAF e os NDVI, nota-se uma clara saturação dos dados orbitais originados do LandSat 8 (Figura 20) e do Sentinel-2 (Figura 21). Tal comportamento ocorre em decorrência da completa absorção da radiação na região do vermelho por parte da clorofila e carotenos presentes nas folhas, a partir de um determinado valor de IAF (LIANG, 2004). Em estudos que buscam extrair características da vegetação (i.e., IAF, diâmetro, altura, biomassa etc.) a saturação dos dados nos sensores orbitais é uma das limitações destes produtos.

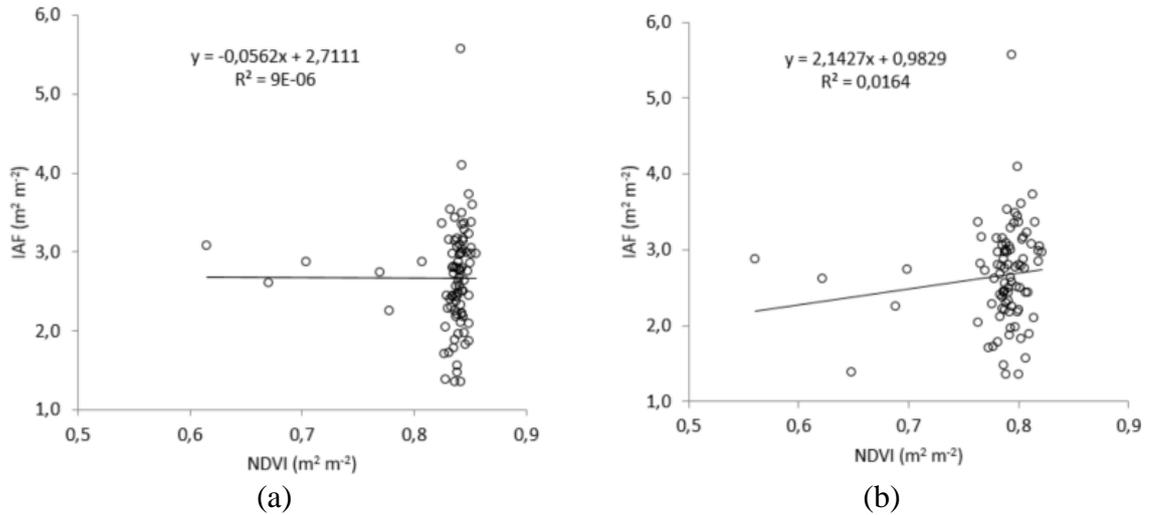


FIGURA 20 - Diagrama de dispersão entre valores de IAF e NDVI extraídos do LandSat 8 (a) dia 02/07; (b) dia 18/07.

Fonte: autoria própria (2019).

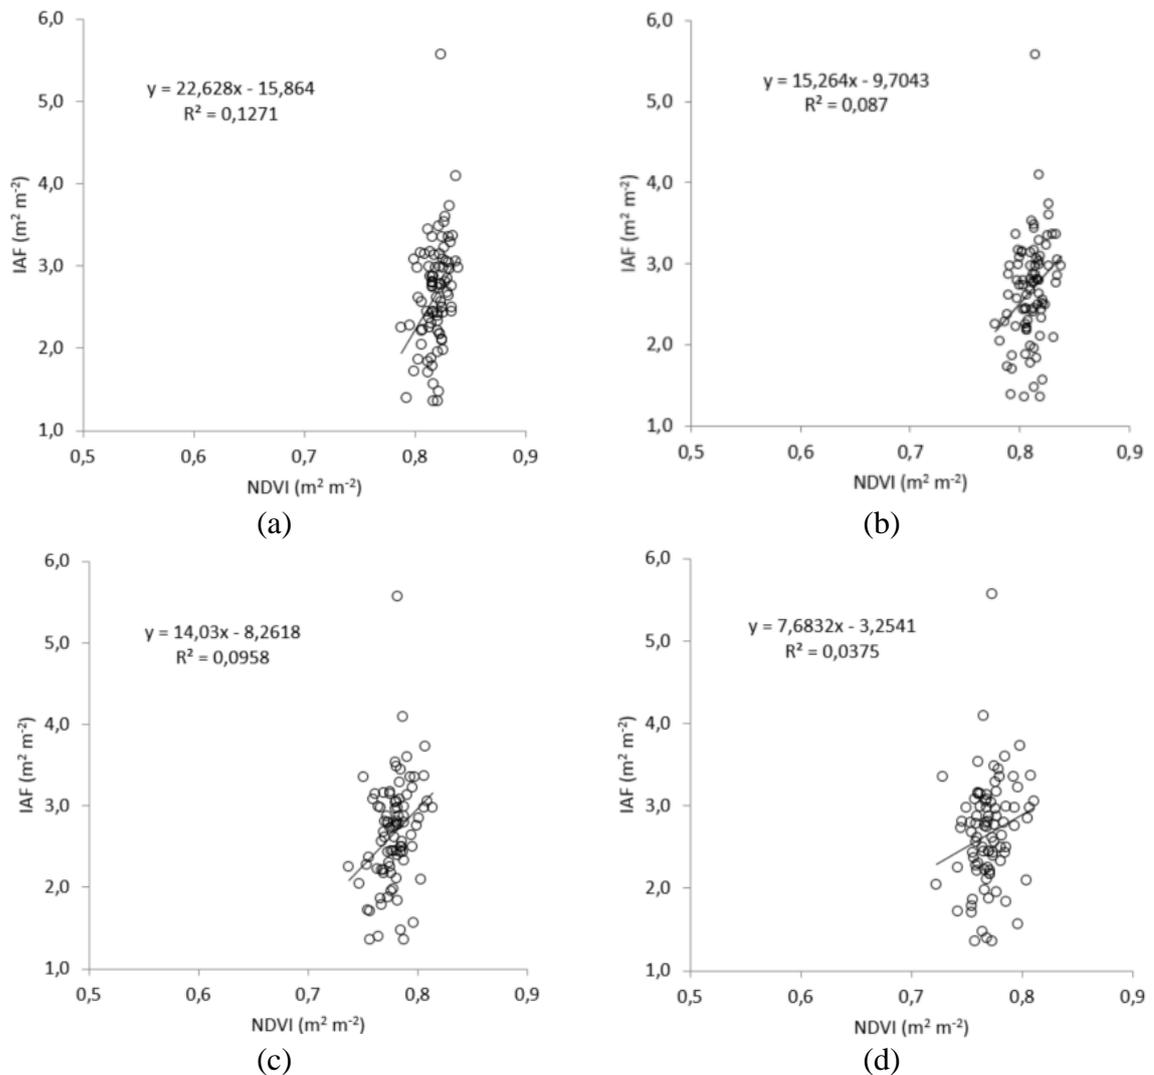


FIGURA 21 - Diagrama de dispersão entre valores de IAF e NDVI extraídos do Sentinel-2 (A e B): (a) dia 02/07; (b) dia 07/07; (c) dia 12/07 e (d) dia 17/07.

Fonte: autoria própria (2019).

### 3.4. Ajuste dos modelos

A correlação entre o IAF e o NDVI é representada na Tabela 4, testado em diferentes distribuições dos valores seguindo a orientação dos quadrantes de *pixels* (Tabela 2), para os conjuntos de dados L02, S02, S07, S12, S17 e L18.

TABELA 4 - Correlação de IAF por NDVI em diferentes distribuições dos valores em quadrantes de *pixels*.

Quadrante	Dados					
	L02	L18	S02	S07	S12	S17
Q1	-0,00302	0,127982	0,356525	0,294879	0,309559	0,19363
Q2	0,125987	0,194604	0,574163	0,553735	0,549075	0,4404
Q3	-0,00099	0,095336	0,545099	0,479300	0,53562	0,316977
Q4	0,207542	0,221065	0,610391	0,50806	0,48243	0,346567

Q1 - sem quadrante; Q2 - quadrante de 120 m<sup>2</sup>, seguindo o alinhamento dos *pixels*; Q3 - quadrante de 120 m<sup>2</sup>, seguindo a linha de plantio e nenhum ponto pode ficar sozinho dentro do quadrante; Q4 - quadrante de 120 m<sup>2</sup>, seguindo a linha de plantio e pode um ponto ficar sozinho dentro do quadrante.

Fonte: autoria própria (2019).

Os conjuntos de dados que tiveram correlação acima de 0,50 foram ajustados nos modelos de regressão: linear simples, potência, exponencial e logarítmica.

### 3.5. Seleção do modelo

O modelo selecionado foi o conjunto de dados S12 por potência (Tabela 5), com os valores distribuídos em quadrantes de *pixels* de 120 m<sup>2</sup>, seguindo a linha de plantio e nenhum ponto ficando sozinho dentro do quadrante. O modelo foi ajustado pela relação linear entre o *log* do IAF e o NDVI. Ele apresentou o melhor desempenho, com elevado valor de coeficiente de determinação ( $R^2 > 0,6$ ) e baixo valor de erro quadrado médio da raiz (EQMR < 11). A análise dos resíduos confirmou a inexistência de tendência na estimativa dos erros. Na relação linear do NDVI com o IAF, os valores do  $R^2$  (0,6 - 0,75) são semelhantes aos encontrados em outros trabalhos envolvendo: eucalyptus (ALMEIDA et al., 2015; SANTOS et al., 2013), cana-de-açúcar (PEREIRA et al., 2015) e plantios de coníferas (FASSNACHT et al., 1997).

TABELA 5 - Resumo dos resultados da análise dos modelos de regressão e sua significância estatística para a relação IAF com o NDVI dos dados obtidos pelo satélite Sentinel-2A para o dia 12/07.

	<b>Modelo</b>	<b>r<sup>2</sup></b>	<b>EQMR</b>	<b>p value</b>
Linear simples	$IAF = 27,665NDVI - 18,855$	0,69	26%	<0,01
Potência	$IAF = 22,333NDVI^{8,5257}$	0,67	11%	<0,01
Exponencial	$IAF = 0,0005e^{10,943NDVI}$	0,66	11%	<0,01
Logarítmica	$IAF = 8,0783 + 21,536 \ln NDVI$	0,70	26%	<0,01

Fonte: autoria própria (2019).

Apesar dos valores de  $r^2$  da regressão linear simples (0,69) e da regressão logarítmica (0,70) terem sido maior do que a regressão por potência (0,67) não foram selecionados porque apresentarem maior EQMR dentre os modelos de regressão.

A Figura 22 apresenta o diagrama de dispersão entre os valores medidos e estimados de IAF. Apesar da saturação dos dados orbitais, o diagrama de dispersão mostra que o modelo ajustado conseguiu estimar os valores de IAF para a área analisada.

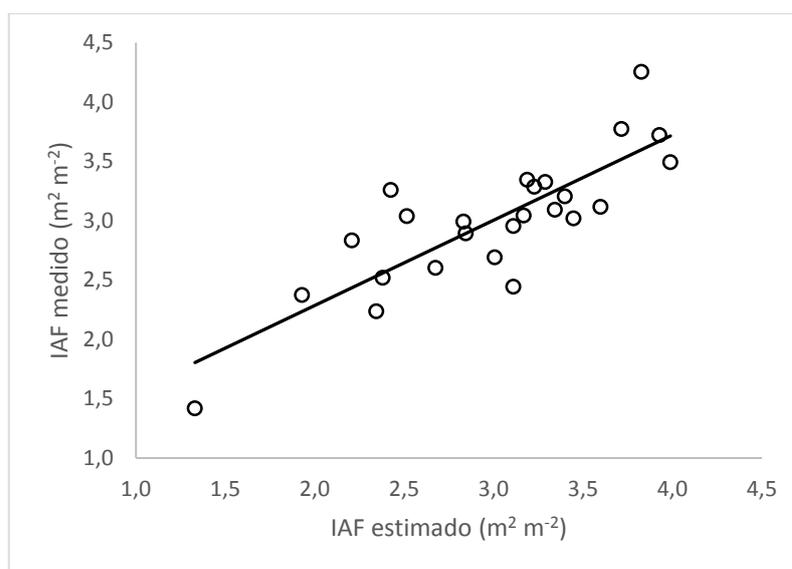


FIGURA 22 - Diagrama de dispersão entre os valores de IAF medidos e estimados pelos modelos de regressão ajustados para plantios de tomate industrial.

Fonte: autoria própria (2019).

Os resultados encontrados neste estudo corroboram com os apresentados em outros trabalhos. Eles mostram que as técnicas de sensoriamento remoto e os índices de vegetação derivados dos sensores orbitais, podem ser utilizados para a estimativa do IAF do tomateiro na área do pivô em estudo. E apresentam como vantagens, em relação aos métodos tradicionais (destrutivos), uma estimativa rápida, confiável e espacial desse parâmetro tão importante no monitoramento da vegetação.

#### 4. CONCLUSÕES

Os modelos de regressão ajustados apresentaram um coeficiente de determinação acima de 65% entre os valores de IAF obtidos *in loco* com o NDVI obtido a partir das imagens do Sentinel-2(A e B) de uma área de plantio de tomate industrial irrigado por meio de pivô central.

Apesar da saturação dos valores de NDVI, os modelos ajustados a partir desse índice apresentaram os melhores resultados, podendo ser utilizados para estimar os valores de IAF da área de plantio analisada.

Fazem-se necessários estudos futuros com outras plataformas, sensores orbitais, outros índices de vegetação, além de uma análise sazonal, para que se possa inferir sobre a precisão e correlação dos dados.

## 5. REFERÊNCIAS BIBLIOGRÁFICAS

AGEITEC - AGÊNCIA EMBRAPA DE INFORMAÇÃO TECNOLÓGICA, 2018.

Disponível em:

<<http://www.agencia.cnptia.embrapa.br/gestor/tomate/arvore/CONT000fa2qor2r02wx5eo01xezlschewkfx5.html>>. Acesso em: 14 jul. 2018.

ALMEIDA, A. Q. De; RIBEIRO, A.; DELGADO, R. C.; RODY, Y. P.; OLIVEIRA, A. S. De; LEITE, F. P. Índice de área foliar de eucalyptus estimado por índices de vegetação utilizando imagens tm - landsat 5. **Floresta e Ambiente**, . v. 22, n. 3, p. 368–376. 2015.

BARBOSA, C. E. B.; MELO, F. R. De; ALVES, S. M. D. F.; ROCHA, I. J. D. F.; SILVA JÚNIOR, R. M. V.; FERREIRA, B. A.; GOMES, F. A.; ARAÚJO, R. S. L. De. Algoritmo de determinação de área foliar do tomate. **XVI CEEL**, . p. 1–4. 2018.

BRAMLEY, R. G. V. Lessons from nearly 20 years of Precision Agriculture research, development, and adoption as a guide to its appropriate application. **Crop and Pasture Science**, Clayton, v.60, n.3, p.197-217, 2009.

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**, . v. 8, n. n. 16, (jan./março)-ISSN 1980-5772, p. 40–55. 2014.

CID Bio-Science. Tools that work where you work. CI-202 Portable Laser Leaf Area Meter. Disponível em: <<https://cid-inc.com/plant-science-tools/leaf-area-measurement/ci-202-portable-laser-leaf-area-meter/>>. Acesso em: 19 dez. 2018.

CONGEDO, L. Semi-Automatic Classification Plugin Documentation Versão 5.3.6.1. Tutorial. 2017. Disponível em: <<https://media.readthedocs.org/pdf/semiautomaticclassificationmanual-v5-pt/latest/semiautomaticclassificationmanual-v5-pt.pdf>> Acesso em: 14 jul. 2018.

COLAÇO, A. F; MOLIN, J. P. Amostragem georreferenciada. Piracicaba: **LAP - Laboratório de Agricultura de Precisão**, 2015. p. 4.

DANELICHEN, V. H. D. M.; BIUDES, M. S.; MACHADO, N. G.; VELASQUE, M. C. S.; SILVA, B. B. DA; NOGUEIRA, J. D. S. Uso do sensoriamento remoto na estimativa do índice de área foliar em floresta tropical. **Ciência e Natura**, . v. 38, n. 3, p. 1352. 2016.

DEERING, D. W., ROUSE, JR, J. W., HAAS, R. H., SCHELL, J. A. Measuring forage production of grazing units from Landsat MSS data, In: Internacional Syposium on Remote Sensing of Environment, 10, Ann Arbor, **Proceedings**. Ann Arbor, MI: ERIM, 1975. v. 2, p. 1169–1178.

FASSNACHT, K. S., GOWER, S. T., MACKENZIE, M. D., NORDHEIM, E. V., LILLESAND, T. M. Estimating the leaf area index of north central Wisconsin forests using the Landsat thematic mapper. **Remote Sensing of Environment** 1997; 61(2): p. 229- 245.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2018. **SGB - Sistema Geodésico Brasileiro**. Disponível em: <<https://ww2.ibge.gov.br/home/geociencias/geodesia/>>. Acesso em: 14 jul. 2018.

- JURGIEL, B. Point Sampling Tool, 2018. Disponível em: <<https://github.com/borysiasty/pointsamplingtool>>. Acesso em: 14 jul. 2018.
- LIANG, S. **Quantitative remote sensing of land surfaces**. New Jersey, USA: Wiley Interscience, p. 534, 2004.
- MARTIN, N.; ABRAMO, J.; SOUSA, F. De; KARENINA, A.; MARTIN, T. N.; MARCHESE, J. A.; KARENINA, A.; SOUSA, F. De; CURTI, G. L. Uso do software imagej na estimativa de área foliar para a cultura do feijão. 2013.
- MELO, P. C. T. De. Desenvolvimento tecnológico para o cultivo do tomateiro de mesa em condições agroecológicas tropicais e subtropicais. **ESALQ**, . 2017.
- MOLIN, J. P.; AMARAL, L. R. Do; COLAÇO, A. F. **Agricultura de precisão**. 1. ed. São Paulo: Oficina de Textos, 2015.
- NUNHEMS. Sementes de hostaliças catálogo 2016. **Nunhems**. Disponível em: <[http://nunhems.com.br/www/nunhemsinternet.nsf/id/BR\\_PT\\_Product\\_Catalogue\\_2/\\$file/BR\\_Catalogo\\_Multicrop\\_16pgs\\_A4.pdf](http://nunhems.com.br/www/nunhemsinternet.nsf/id/BR_PT_Product_Catalogue_2/$file/BR_Catalogo_Multicrop_16pgs_A4.pdf)>. Acesso em: 19 maio. 2018.
- PEREIRA, R. M.; CASAROLI, D.; QUIRINO, D. T.; CAETANO, J. M.; VELAME, L. M. Estimativa do índice de área foliar da cana-de-açúcar a partir de imagens do satélite landsat-8 (OLI). **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto**, . v. 8, n. 1, p. 6381–6388. 2015.
- QGIS - Documentação do QGIS2.14.  
 \_\_\_\_\_. (a) **Raster**. 2018. Disponível em: <[https://docs.qgis.org/2.14/pt\\_BR/docs/gentle\\_gis\\_introduction/raster\\_data.html](https://docs.qgis.org/2.14/pt_BR/docs/gentle_gis_introduction/raster_data.html)>. Acesso em: 29 jun. 2018.  
 \_\_\_\_\_. (b) **Ponderação pelo Inverso da Distância (IDW)**. 2018. Disponível em: <[https://docs.qgis.org/2.14/pt\\_BR/docs/gentle\\_gis\\_introduction/spatial\\_analysis\\_interpolation.html#figure-idw-interpolation](https://docs.qgis.org/2.14/pt_BR/docs/gentle_gis_introduction/spatial_analysis_interpolation.html#figure-idw-interpolation)>. Acesso em: 30 jun. 2018.
- REIS, L. S.; AZEVEDO, C. A V. De; ALBUQUERQUE, A. W.; S. JUNIOR, J. F. Índice de área foliar e produtividade do tomate sob condições de ambiente protegido. Campina Grande: **Revista Brasileira de Engenharia Agrícola e Ambiental**, . v. 17, n. 4, p. 386–391. 2013.
- RISSO, J.; RIZZI, R.; RUDORFF, B. F. T.; ADAMI, M.; SHIMABUKURO, Y. E.; FORMAGGIO, A. R.; EPIPHANIO, R. D. V. Índices de vegetação Modis aplicados na discriminação de áreas de soja. **Pesquisa Agropecuária Brasileira**, Brasília, v. 47, n. 9, p.1317-1326, 2012.
- RODY, H. P.; RIBEIRO, A.; PEZZOPANE, J. E. M.; GLERIANI, J. M.; ALMEIDA, A. Q.; LEITE, F. P. Estimates of the leaf area index (LAI) using LAI-2000 and hemispherical photos in Eucalyptus plantations. **Ciência Florestal**, n. 4, p. 923-932, 2014.
- SANTOS, E. Das V.; RODRIGUES, A. M. B.; ALMEIDA, Andre Quintão De; CERQUEIRA, E. S. A.; LOUREIRO, D. C. Estimativa do índice de área foliar em plantio de eucalipto com dados orbitais landsat. p. 1316–1320. 2013.
- SFAIR, J. C. Usando o imagej para calcular a área foliar. n. July. 2016.

SILVA, L. F. M. Da; SILVA, C. J. Da; SILVA, C. A. Da; SILVA, N. E. P. Da; FREITAS, C. A. De; GOLYNSKI, A. Área foliar e índice de área foliar de plantas de tomateiro em função de níveis de reposição da evapotranspiração da cultura. n. 64, p. 1676–1681. 2015.

SIRGAS - SISTEMA DE REFERÊNCIA GEOCÊNTRICO PARA AS AMÉRICAS, 2018. Disponível em: <<http://www.sirgas.org/pt/>>. Acesso em: 8 jun. 2018.

SOUZA, A. L. P.; COSTA, M. M.; SENA JUNIOR D. G.; PAZ, R. B. O.; Análise de três métodos de obtenção do índice de área foliar para cultura da soja. SIMAP – Simpósio Mato-Grossense de Mecanização Agrícola e Agricultura de Precisão, 1, 2018. **Anais... SIMAP UFMT**, Campus Universitário de SINOP, 2018.

TSCHIEDEL, M.; FERREIRA, M. F. Introdução à agricultura de precisão: conceitos e vantagens. **Ciência Rural**, . v. 32, n. 1, p. 159–163. 2002.

USGS - UNITED STATES GEOLOGICAL SURVEY.

\_\_\_\_\_. (a) **Landsat 8 Operational Land Imager (OLI) and Thermal Infrared Sensor (TIRS) Level-1 Data Products**. 2015. Disponível em: <<https://lta.cr.usgs.gov/L8>>. Acesso em: 27 jun. 2018.

\_\_\_\_\_. (b) **Sentinel-2 - The Long Term Archive - USGS**. 2015. Disponível em: <[https://lta.cr.usgs.gov/sentinel\\_2](https://lta.cr.usgs.gov/sentinel_2)>. Acesso em: 27 jun. 2018.

WANG, Y.; TIAN, Y.; ZHANG, Y.; EL-SALEOUS, N.; KNYAZIKHIN, Y.; VERMOTE, E.; MYNENI, R. B. Investigation of product accuracy as a function of input and model uncertainties. **Remote Sensing of Environment**, New York, v. 78, n. 3. p. 299-313, 2001.

ZEIST, A. R.; OLIVEIRA, J. R. F.; LIMA FILHO, R. B.; SILVA, M. L. S.; RESENDE, J. T. V. Comparação de métodos de estimativa em área foliar em morangueiro. **Pesquisa Agropecuária Gaúcha**, Porto Alegre, v.20, ns. 1/2, p. 33-41, 2014.

## CAPÍTULO 2

### **REDES NEURAIIS ARTIFICIAIS APLICADAS NA ESTIMATIVA DO ÍNDICE DE ÁREA FOLIAR UTILIZANDO IMAGENS DE SENSORAMENTO REMOTO**

#### **1. INTRODUÇÃO**

Redes neurais é uma denominação empregada para indicar a estrutura biológica que o cérebro usa para realizar diversas atividades como identificação de padrões, percepção, controle motor, etc. bem como para as Redes Neurais Artificiais (RNAs) que se usa em atividades computacionais.

Segundo os autores Braga et al. (2012) e Haykin (2005), uma rede neural biológica consiste de neurônios interconectados cuja ativação é definida por um caminho linear reconhecível. Os neurônios interagem com seus vizinhos por meio dos terminais dos axônios conectados via sinapses para dendritos em outros neurônios.

Aleksander e Morton (1995) e Russell e Norvig (2010), afirmam que as 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.

Vários são os campos de estudo em que se utilizam as RNAs: na zootecnia, com o objetivo de avaliar a produção de leite (KOMINAKIS et. al. 2002; SHARMA et. al., 2007, TORRES et. al. 2005), 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; UNO et. al., 2005), do trigo (ALVAREZ, 2009; 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

### 2.1. Caracterização e localização da área de estudo

O estudo foi desenvolvido em área comercial de 35 ha de tomate industrial, irrigado por pivô central, no município de Vila Propício-GO, localizado a 15°24'12''S e 48°53'59.69''W com altitude média de 686 m (Figura 1).

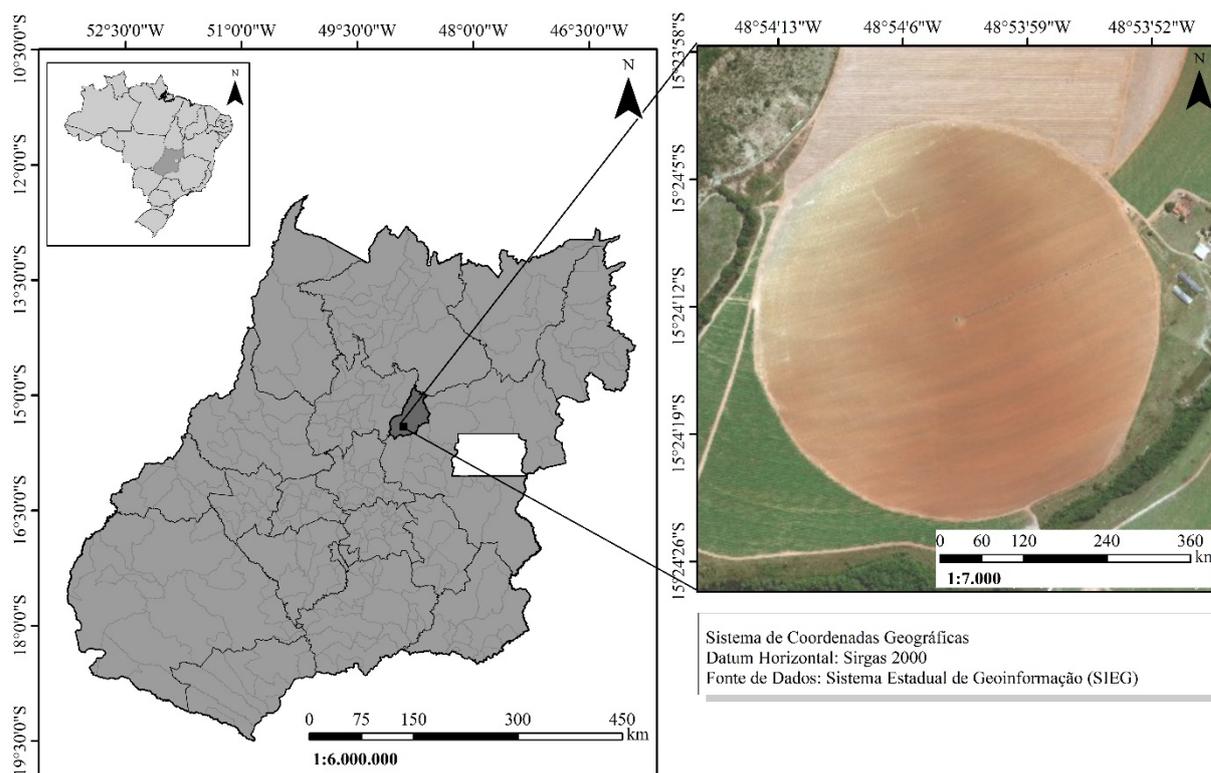


FIGURA 1 - Mapa localizando o Município de Vila Propício-GO e o mapa da área experimental.

O clima da região, segundo classificação de Köppen, é Aw com duas estações bem definidas, com verão chuvoso e inverno seco. A temperatura média anual é de 22,5 °C e a média anual de pluviosidade é 1370 mm (CARDOSO et al., 2014).

Os solos são do tipo Cambissolo Háplico Distrófico, com textura argilosa. O início do transplante foi em 24 de abril de 2018, numa área de plantio direto na palha, com mudas de 30 dias após a germinação. O espaçamento de 0,3 m entre plantas e de 1 m entre linhas com densidade de 30 mil plantas por hectare (Figura 2). O híbrido de tomate industrial plantado foi o N901, que se destaca pelo excelente enfolhamento, tendo como estimativa de produção 50 frutos por planta (NUNHEMS, 2016).



FIGURA 2 - Espaçamento de 0,3 m entre plantas e de 1 m entre linhas.

Fonte: arquivo pessoal (2018).

## 2.2. Formação da grade amostral

Com base nos experimentos de Soares et al. (2019) e Scavacini et al. (2015) foi adotada a grade amostral de 60x60 m (Figura 3), gerada com o auxílio do *software* de informações geográficas QGIS, no sistema de coordenadas planas *Universal Transversa de Mercator* (UTM) fuso 22 S, totalizando 88 pontos, a grade amostral foi construída tendo como referência as linhas de plantio.

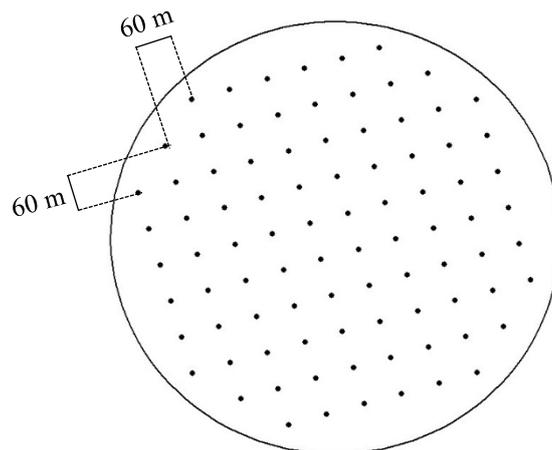


FIGURA 3 - Grade amostral da área experimental.

Fonte: autoria própria (2018).

Com 30 dias após o transplântio (DAT) foi feito o estaqueamento dos 88 pontos da grade amostral (Figura 4).



FIGURA 4 - Estaca marcando o primeiro ponto da grade amostral.

Fonte: arquivo pessoal (2018).

### 2.3. Características avaliadas e coleta de dados *in loco*

Aos 76 Dias Após o Transplântio (DAT), dia 09 do julho de 2018, data escolhida para coincidir com a passagem do satélite e o estágio pós-floração, período do ápice do IAF e início do seu declive. Foram avaliados o Número de Plantas (NP), Área Foliar (AF) e o Índice de Área Foliar (IAF), para cada demarcação do ponto da grade amostral. Para coleta dos dados, foi utilizado uma armação com área de 1 m<sup>2</sup>.

#### 2.3.1 Contagem do número de plantas

Foi contada a quantidade de plantas dentro da armação.

#### 2.3.2 Obtenção da área foliar

Duas plantas de forma aleatória foram separadas dentro da armação, com cuidado para não as danificar. Depois, foi feito a contagem do número de folhas (NF) das ramas separadas seguindo o padrão. Inicialmente, contando as folhas da haste principal e depois das hastes laterais. Dentre as folhas contadas, dez foram retiradas de forma aleatória e identificadas, colocando-as sobre uma mesa redonda de cloreto de polivinila (PVC) de raio 25 cm (Figura 5), que contém uma reta medindo 2,1 cm de comprimento que é utilizada para calibração do *software*.



FIGURA 5 - Mesa de policloreto de polivinila (PVC) desenvolvida para tirar fotos no campo.  
Fonte: arquivo pessoal (2018).

As dez folhas foram fotografadas, individualmente, com a câmera de um celular com a resolução de 8.0 *megapixels* (Figura 6), que posteriormente, foram submetidas à análise de AF por meio do *software* ImageJ de domínio público, (disponível gratuitamente via internet <http://rsbweb.nih.gov/ij/>), seguindo os procedimentos detalhados no Apêndice A. Os dados obtidos referentes às AFs foram armazenados em um *software* de planilhas eletrônicas.

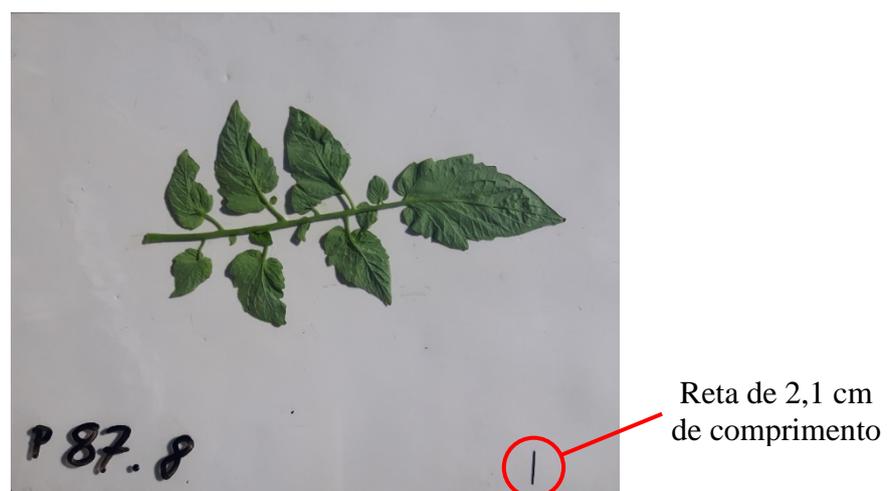


FIGURA 6 - Folha tirada do ponto 87,8° amostra, no canto inferior direito, reta medindo 2,1 cm de comprimento que é utilizada para calibração do software.  
Fonte: arquivo pessoal (2018).

### 2.3.3 Cálculo do índice de área foliar

Os dados de IAF foram obtidos por meio da relação AF sobre a superfície do solo ocupada pela planta, representando a AF total por unidade de área (Equação 1), os cálculos e o armazenamento foram feitos utilizando um *software* de planilhas eletrônicas.

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

em que:

- 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 metro quadrado;
- AT - área total considerada, 1 m<sup>2</sup>.

## 2.4. Características avaliadas por sensoriamento remoto

### 2.4.1. Software e complementos

Para o processamento das imagens orbitais foi utilizado o *software* QGIS, versão 3.4.1-Madeira, licenciado sob *General Public License* (GNU) e os complementos: *Semi-Automatic Classification Plugin* (SCP) e *Point sampling tool*. Ambos os complementos foram instalados no QGIS pelo “Gerenciar e Instalar Complementos...”.

O SCP é um complemento que oferece diversas funcionalidades como:

- Download de imagens disponíveis para Landsat, Sentinel-2, Sentinel-3 e ASTER;
- Pré-processamentos (exemplo: correção atmosférica);
- Pós-processamentos;
- Calculadora *raster* (que pode ser utilizada para calcular os índices de vegetação).

Entre tantas outras funcionalidades, como pode ser visto com mais detalhes em Congedo (2017). O complemento *Point Sampling Tool* coleta atributos de polígonos e valores *raster* de várias camadas em pontos de amostragem especificados (JURGIEL, 2018).

A integração dos processamentos e a facilidade no manuseio são as principais características desses complementos que objetivam prover um conjunto de ferramentas entrelaçadas para o processamento rasterizado, a fim de efetuar um fluxo de trabalho automático, com o intuito de facilitar a classificação da cobertura terrestre e a extração de valores de imagens (CONGEDO, 2017; JURGIEL, 2018).

### 2.4.2. Procedimentos operacionais

Para a captura das imagens orbitais, da área estudada, foi utilizado o sensor *Operational Land Imager* (OLI) do satélite Landsat 8, órbita 222, ponto 71 e os sensores *Multispectral Instrument* (MSI) dos satélites Sentinel-2A e Sentinel-2B, localizado na T22LGJ da *Military Grid Reference System* (MGRS) dos EUA, as imagens são disponibilizadas de maneira gratuita pela *United States Geological Survey* (USGS) na guia do produto Landsat 8 (USGS, 2015a) e Sentinel-2 (USGS, 2015b). As imagens analisadas foram capturadas em datas próximas ao dia 09 de julho de 2018, DAT 76, data do início da coleta do IAF *in loco* (Tabela 1).

TABELA 1 – Dias após transplântio, data, hora, e satélite de origem das imagens orbitais analisadas.

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

Fonte: autoria própria (2018).

As imagens passaram por um processo de refinamento para definir quais imagens podem ser utilizadas em função da:

- Visibilidade, atmosfera livre de presença de nuvens;
- Qualidade do imageamento do sensor, sem ruídos;
- Homogeneidade do período da captura da imagem.

### 2.4.3. Conversão da refletância do topo da superfície para valores de refletância da base da superfície

Em cada imagem, previamente, selecionada foi realizada a conversão da refletância do topo da superfície (TOA) para valores de refletância da base da superfície (BOA) por meio do arquivo *metadata* que é disponibilizado junto com as imagens. Esse arquivo contém os parâmetros de transformação necessários para realizar a conversão da reflectância de TOA para BOA, os procedimentos detalhados estão no Apêndice B.

#### 2.4.4. Conversão do sistema de referência de coordenadas

Foi necessário fazer a conversão do Sistema de Referência de Coordenadas (SRC), seguindo os procedimentos detalhados no Apêndice C, pois as imagens disponibilizadas pelo Landsat são em WGS 84 / UTM zona 22N e as do Sentinel são em WGS 84 / UTM zona 22S, mas no Brasil o sistema de referência oficial é o Datum SIRGAS 2000 (Sistema de Referência Geocêntrico para as Américas) e o sistema de coordenadas é UTM e a área de estudo está na zona 22S (IBGE, 2018; SIRGAS, 2018).

#### 2.4.5. Cálculo do índice de vegetação por diferença normalizada

O NDVI varia de -1 a +1 (quanto mais próximo de 1, maior a densidade de cobertura vegetal), e pode ser obtido pela Equação 2, de acordo com Deering et al (1975):

$$NDVI = \frac{(\rho_{ivp} - \rho_v)}{(\rho_{ivp} + \rho_v)} \quad (2)$$

em que:

- $\rho_{ivp}$  - reflectância na banda do infravermelho próximo - NIR;
- $\rho_v$  - reflectância na banda do vermelho visível.

Para elaboração desse índice de vegetação foi utilizado o roteiro apresentado no Apêndice D, que para o satélite Landsat 8 foram utilizadas as reflectâncias das bandas do vermelho (R04) e do infravermelho próximo (R05). A relação é demonstrada na Equação 3 e para os satélites Sentinel-2(A e B) foram utilizadas as reflectâncias das bandas do vermelho (R04) e do infravermelho próximo (R08) a relação é demonstrada na Equação 4.

$$NDVI = \frac{(R05 - R04)}{(R05 + R04)} \quad (3)$$

$$NDVI = \frac{(R08 - R04)}{(R08 + R04)} \quad (4)$$

Foram calculados o NDVI para cada data de passagem mostrada na Tabela 2, gerando seis imagens no formato *raster*. Dados *raster* são formados por uma matriz de *pixels* (também conhecido como células), no qual cada *pixel* contém dados gravados na sua descrição que representam a condição da área coberta por ele (QGIS, 2018a).

#### 2.4.6. Extrair valores *raster* de pontos específicos

Para se obter o valor do NDVI de um determinado *pixel* é necessário extrair o valor da descrição do *pixel* (QGIS, 2018a), para determinar os pontos de extração dos dados de NDVI foi utilizada a grade amostral (Figura 3) e seguido o roteiro apresentado no Apêndice E.

#### **2.4.7. Exportar tabela de atributos par um software de planilhas eletrônicas**

Para fazer as análises estatísticas nos dados de NDVI extraídos é necessário exportar a tabela de atributos da camada gerada para um *software* de planilhas eletrônicas, para exportar segue o roteiro demonstrado no Apêndice F.

#### 2.5. Estatística descritiva

Tendo armazenado em um *software* de planilhas eletrônicas os valores de IAF obtido *in loco* e o NDVI obtido por sensoriamento remoto foram submetidos à estatística descritiva por meio da análise exploratório dos dados, que possibilitou conhecer e visualizar a tendência, medidas de dispersão e distribuição dos mesmos. A partir dos conjuntos dos dados, foram calculadas as medidas descritivas: média, mediana, variância, desvio-padrão, assimetria, curtose e coeficiente de variação. Os valores *outliers* foram identificados por meio da amplitude Interquartil (IQR).

#### 2.6. Redes Neurais Artificiais

##### **2.6.1. Recursos de informática utilizados**

Foi utilizado um computador com processador Intel® Core™ i7-4510U 2GHz, 8GB de RAM e HD SSD de 256 GB e Sistema Operacional Windows 8.1 64bits. Foi desenvolvido um *software* com as funções de carregar dados, normalizar/desnormalizar, treinamento, validação externa e classificação das RNAs.

Para auxiliar na preparação dos dados foi utilizado um *software* de planilha eletrônica para fazer o pré-processamento dos dados de entrada.

##### **2.6.2. Treinamento das RNAs**

Para realizar o treinamento das RNAs foram selecionadas 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*, 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 reflectâncias nas bandas 4 (vermelho) e 5 (infravermelho próximo) e o produto destas o NDVI, do Sentinel 2A e B foram reflectâncias 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 (JOSÉ et al., 2015), buscando-se assim equalizar o peso inicial que a variável possa assumir no início do treinamento.

### 2.6.3. Categorização e normalização das variáveis

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 7. Esta variável é classificada como independente. Para esta variável é recomendado seguir o mesmo tratamento dado a variáveis tipo *dummy* da Análise de Regressão Múltipla (BOHL et al., 2015; SHARMA et al., 2007). Desta maneira, foram definidas as variáveis A1, A2 e A3 para a área, sendo que estas assumem valores de 0 ou 1.

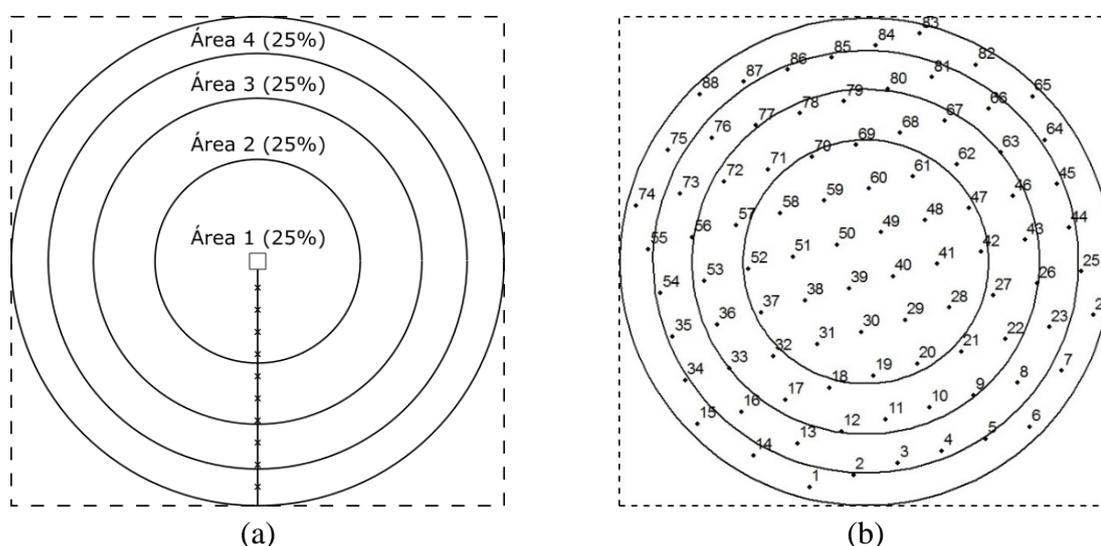


FIGURA 7 - (a) Divisão fictícia do pivô em percentual de área; (b) Posicionamento dos pontos em relação a divisão fictícia do pivô em percentual de área.

Fonte: autoria própria (2019).

Na Tabela 2, observa-se como identificar a área na qual o ponto amostral está localizado, utilizando as variáveis A1, A2 e A3. Quando as três variáveis assumem o valor de 0 trata-se da área 4.

TABELA 2 - Valores para identificar a área em que o ponto amostral está localizado

Área	A1	A2	A3
1	1	0	0
2	0	1	0
3	0	0	1
4	0	0	0

Fonte: autoria própria (2019).

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 (Figura 8).

			Centro do Pivô		
			X	Y	Altura
			-48,900755	-15,403481	685
X	Y	altitude (m)	DX	DY	DA
-48,901402	-15,406184	667	-0,000647	-0,002703	-18
-48,900902	-15,406034	673	-0,000147	-0,002553	-12
-48,900299	-15,405884	669	0,000456	-0,002403	-16
-48,899799	-15,405734	671	0,000956	-0,002253	-14

FIGURA 8 - Obtenção dos valores das variáveis DX, DY e DA, pela diferença dos valores das coordenadas X e Y, e altitude dos pontos amostrais em relação ao centro do pivô.

Fonte: autoria própria (2019).

Depois do pré-processamento feito, foram obtidos os dados de entrada e seus respectivos valores de máximo e mínimo. Devido aos dados obtidos por sensoriamento remoto mudarem de acordo com os satélites, dividiu-se as variáveis de entrada em dois grupos:

- **Variáveis comuns** – são as variáveis comuns a todas as redes treinadas e que não variam entre os treinamentos. Neste grupo, estão as variáveis contendo as características dos pontos amostrais (classificação da área, coordenadas de latitude e longitude, e altura) e o IAF obtido *in loco* (Tabela 3).

TABELA 3 - Variáveis de entrada que são comuns para todas as redes treinadas.

Variável	Unidade
A1, A2, A3	un
DX	graus
DY	graus
DA	m
IAF	m <sup>2</sup> m <sup>-2</sup>

Fonte: autoria própria (2019).

- **Variáveis específicas** – são as variáveis que mudam de acordo com o satélite e a data de passagem, que são as variáveis das reflectâncias nas bandas de vermelho e infravermelho próximo, e o produto destas, o NDVI (Tabela 4).

TABELA 4 - Variáveis de entrada que mudam de acordo com o satélite e a data de passagem.

Variável	Unidade	Origem	Dia
R04			
R05	µm	LandSat	02
NDVI			
R04			
R05	µm	LandSat	18
NDVI			
R04			
R08	µm	Sentinel-2A	02
NDVI			
R04			
R08	µm	Sentinel-2B	07
NDVI			
R04			
R08	µm	Sentinel-2A	12
NDVI			
R04			
R08	µm	Sentinel-2B	17
NDVI			

Fonte: autoria própria (2019).

Depois dos 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). Devido à grande quantidade de dados a serem normalizados, foi desenvolvido uma função para fazer a normalização dos dados, sua principal instrução é a *mapminmax* (Instrução 1), instrução que processa matrizes mapeando os valores mínimo e máximo de cada linha para valores dentro de um intervalo estabelecido, os valores do intervalo foram de -1 e 1 (MATHWORKS, 2019).

$$[Y, PS] = \text{mapminmax}(X, Y_{\text{MIN}}, Y_{\text{MAX}}); \quad (\text{Ins. 1})$$

em que:

- X - matriz com os valores a ser normalizado;
- $Y_{\text{MIN}}$  - valor mínimo para cada linha de Y (o padrão é -1);
- $Y_{\text{MAX}}$  - valor máximo para cada linha de Y (o padrão é +1);
- Y - matriz com os valores normalizados;
- PS - configurações de processamento.

Na documentação da instrução *mapminmax* (MATHWORKS, 2019) mostra que o algoritmo da instrução segue a Equação 5. Para validar a função desenvolvida, os mesmos valores foram normalizados utilizando um *software* de planilha eletrônica na faixa de valor entre -1 e 1 (SILVA et al., 2010). Conforme Equação 5, os valores obtidos foram os mesmos.

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

em que:

- 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).

A função desenvolvida para normalização dos dados tem como objetivo, além de normalizar, separar os valores utilizados para o treinamento dos valores utilizados para a validação externa (segundo uma lista de valores estipulados), salvando-os em dois arquivos diferentes, ambos com valores normalizados no formato *Comma Separated Values* (CSV). Posteriormente, os arquivos foram utilizados para o treinamento e validação externa das RNAs.

#### 2.6.4. Desnormalização das variáveis

Após o treinamento e validação externa das redes, o valor resultante foi retornado a sua grandeza original, para realizar a transformação do valor normalizado para a sua grandeza original foi desenvolvido uma função que usa a instrução *mapminmax*, passando como um dos parâmetros a instrução *'reverse'*, que inverte o processamento (Instrução 2) (MATHWORKS, 2019).

$$X = \text{mapminmax}(\text{'reverse'}, Y, PS) \quad (\text{Ins. 2})$$

em que:

- Y - matriz com os valores normalizados;
- PS - configurações de processamento;
- reverse - parâmetro para inverter o processamento;
- X - matriz com valores retornados à grandeza original.

Outra função do *software* de “desnormalização” é unir os arquivos resultantes do treinamento com os arquivos resultantes da validação externa. Para validar a função os mesmos valores tiveram sua grandeza original retornados utilizando um *software* de planilha eletrônica de acordo com a Equação 6, os valores obtidos foram os mesmos.

$$x = \frac{(x_{m\acute{a}x} - x_{m\grave{i}n})(y - d_1)}{d_2 - d_1} + x_{m\grave{i}n} \quad (6)$$

em que:

- $x$  - valor retornado a grandeza original.;
- $y$  - valor normalizado;
- $x_{m\grave{i}n}$  - valor mínimo de  $x$ ;
- $x_{m\acute{a}x}$  - valor máximo de  $x$ ;
- $d_1$  - limite inferior do resultado da normalização (-1);
- $d_2$  - limite superior do resultado da normalização (1).

### 2.6.5. Indicadores estatísticos para a escolha da RNA

Para verificação da eficiência dos valores estimados pelas RNAs, os indicadores estatísticos foram implementados:

- Erro médio relativo (P), conforme Equação 7:

$$P = \frac{100}{n} \sum \left| \frac{O-E}{O} \right| \quad (7)$$

em que:

- $P$  - erro médio relativo;
  - $n$  - número de elementos;
  - $O$  - valores observados experimentalmente;
  - $E$  - valores estimados.
- Coeficiente de correlação (r), conforme Equação 8, que permite quantificar o grau de associação, para cada atributo, entre as duas variáveis envolvidas na análise, valores originais e valores estimados pela RNA. O coeficiente de correlação pode variar de -1 a 1 e, quanto maior o seu valor absoluto, maior o grau de associação entre os valores observados e os valores estimados (SCHNEIDER, 1998).

$$r = \frac{\sum_{i=1}^n (E_i - E)(O_i - O)}{\sqrt{[\sum_{i=1}^n (E_i - E)^2][\sum_{i=1}^n (O_i - O)^2]}} \quad (8)$$

em que:

- $r$  - coeficiente de correlação de Pearson;
- $E_i$  - valores estimados;
- $O_i$  - valores observados;
- $E$  - média dos valores estimados;
- $O$  - média dos valores observados;
- $n$  - quantidade de padrões de teste.

- Coeficiente de determinação ( $R^2$ ), conforme Equação 9, indica quanto da variação total é comum aos elementos que constituem os pares analisados, valores originais e valores estimados pela RNA. Quanto mais próximo da unidade for o coeficiente de determinação, tanto maior será a validade do modelo.

$$R^2 = r^2 \quad (9)$$

em que:

- $R^2$  - coeficiente de determinação;
- $r$  - coeficiente de correlação de Pearson.

- Índice de concordância ( $c$ ), conforme Equação 10, fornece o grau de exatidão entre as variáveis envolvidas na análise, valores originais e valores estimados pela RNA, uma vez que relaciona a diferença entre os valores estimados em relação e os valores observados. Esse índice varia entre 0 (zero) (nenhuma concordância) até 1 concordância perfeita (WILLMONT, 1981).

$$c = 1 - \frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (|E_i - O| + |O_i - O|)^2} \quad (10)$$

em que:

- $c$  - índice de concordância de Willmont;
- $E_i$  - valores estimados;
- $O_i$  - valores observados;
- $E$  - média dos valores estimados;
- $O$  - média dos valores observados;
- $n$  - quantidade de padrões de teste.

- Índice de desempenho ( $id$ ), conforme Equação 11. Na tabela 5, estão apresentados os critérios de avaliação do desempenho da RNA quanto ao seu índice de desempenho, conforme Camargo e Sentelhas (1997).

$$id = r \cdot c \quad (11)$$

em que:

- $id$  - índice de desempenho;
- $r$  - coeficiente de correlação de Pearson;
- $c$  - índice de concordância de Willmont.

TABELA 5 - 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

Fonte: Camargo e Sentelhas (1997).

#### 2.6.6. Desenvolvimento da Rede Neural Artificial

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 6, 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 (HAYKIN, 2005), 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.

TABELA 6 - Variáveis apresentadas à camada de neurônio de entrada.

Variável	Descrição
A1, A2, A3	Referentes a área na qual está localizado o ponto dentro do pivô.
DX	Diferença da coordenada X (longitude) do ponto amostral em relação ao centro do pivô.
DY	Diferença da coordenada Y (latitude) do ponto amostral em relação ao centro do pivô.
DA	Diferença da altitude (metros) do ponto amostral em relação ao centro do pivô.
R04	Reflectância na banda do vermelho para ambos os satélites Landsat 8 e Sentinel 2A e B.
R05 ou R08	Reflectância na banda do infravermelho próximo, para o Landsat 8 é o R05 e para o Sentinel 2A e B é o R08.
NDVI	Índice de Vegetação por Diferença Normalizada

Fonte: autoria própria (2019).

Para fazer a importação e tratamento dos valores para inserir na RNA foi desenvolvido uma função que carrega o arquivo no formato CSV, faz o desmembramento em variáveis isoladas e depois divide em duas matrizes:

- **Input** - matriz que contém as variáveis independentes (entrada): A1, A2, A3, DX, DY, DA, R04, R05 ou R08 e NDVI.
- **Target** - matriz com a variável dependente (resultado): IAF, que é o resultado esperado da rede quando um item correspondente da matriz *input* for apresentado à rede MLP.

No desenvolvimento da função de treinamento da rede MLP 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%) (BRAGA et al., 2012);
- 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 12, definindo a condição de parada quando o erro EQM atingir valor menor ou igual a 0,0005;

$$MSE = \frac{1}{n} \sum_{i=1}^n (E_i - O_i)^2 \quad (12)$$

em que:

- $MSE$  - erro quadrático médio;
- $E_i$  - valores estimados;
- $O_i$  - valores observados;
- $n$  - quantidade de padrões de teste.

- número máximo de falhas de validação igual a 6;
- possibilitar especificar os parâmetros de entrada:
  - número máximo de épocas (ciclos de treinamento);
  - número de redes para treinar;
  - números de neurônios iniciais na camada oculta;
  - número final de neurônio na camada oculta;
  - incremento de neurônios na camada oculta.
- armazenar as informações de cada etapa do treinamento:
  - quantidade de neurônios;
  - número do treinamento;
  - época da convergência (parada);
  - EQM (geral, treinamento, validação, teste);
  - P (%) (geral, treinamento, validação, teste);
  - r (geral, treinamento, validação, teste);
  - $R^2$  (geral, treinamento, validação, teste);
  - c (geral, treinamento, validação, teste);
  - id (geral, treinamento, validação, teste);
  - análise do índice de desempenho (geral, treinamento, validação, teste).

Após a implementação da função treinamento seguindo os itens descritos, obteve-se a rede MLP representada na Figura 9. A função TREINAR foi utilizada para treinar 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, seguindo a recomendação de Hecht-Nielsen (1989) que afirma que com  $2i+1$  neurônios na camada oculta é o necessário para mapear qualquer função contínua com  $i$  entradas.

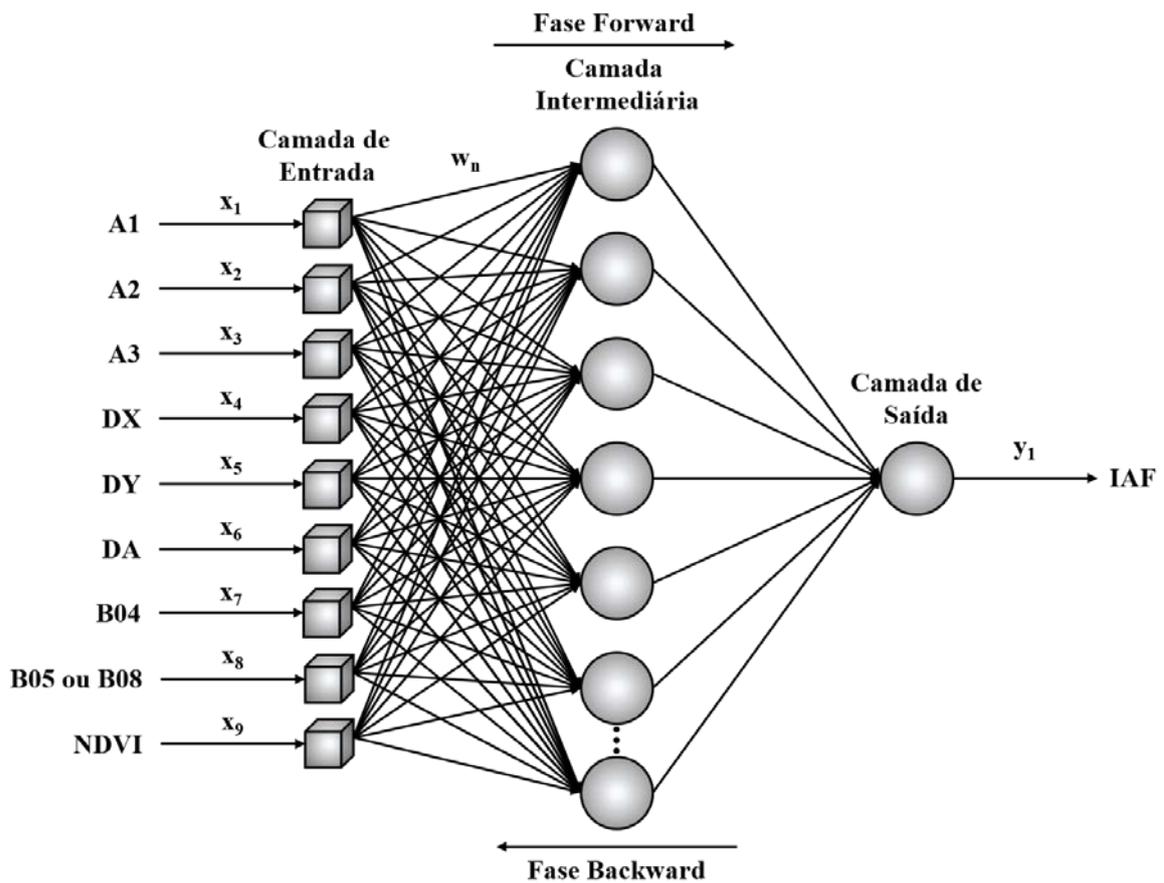


FIGURA 9 - Representação da rede Multi Layer Perceptron.

Fonte: autoria própria (2019).

### 2.6.7. Validação externa

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.

A função de validação retorna um arquivo em planilha eletrônica contendo os valores estimados, a quantidade de neurônios, o número do treinamento, performance e os indicadores estatísticos referentes à comparação dos valores: P (%), r,  $R^2$ , c, id e análise do índice de desempenho. A validação externa foi feita para as 120.000 (cento e vinte mil) redes treinadas.

### 2.6.8. Seleção da melhor RNA

A seleção da melhor RNA foi feita analisando os dados dos treinamentos consolidados e das validações externas, por meio das planilhas eletrônicas geradas pelas funções de treinamento e validação. 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,

Para as redes com melhor desempenho, foi executada a função de geração de gráficos, gerando dois arquivos: um com o gráfico de treinamento e outro com os gráficos do R linear dos conjuntos de treinamento, validação, teste e geral.

### 3. RESULTADOS E DISCUSSÕES

#### 3.1. Exploração para treinamento

A utilização do programa desenvolvido foi fundamental para a determinação da arquitetura que conseguisse resultados satisfatórios, pois segundo Braga et al., (2012) o problema de dimensionamento envolve o ajuste entre a complexidade do modelo neural e a complexidade do problema a ser resolvido. Com a utilização do programa, foi possível variar a complexidade da arquitetura (variando o número de neurônio na camada oculta) permitindo assim a avaliação do índice de desempenho em diferentes arquiteturas e configurações (Figura 10).

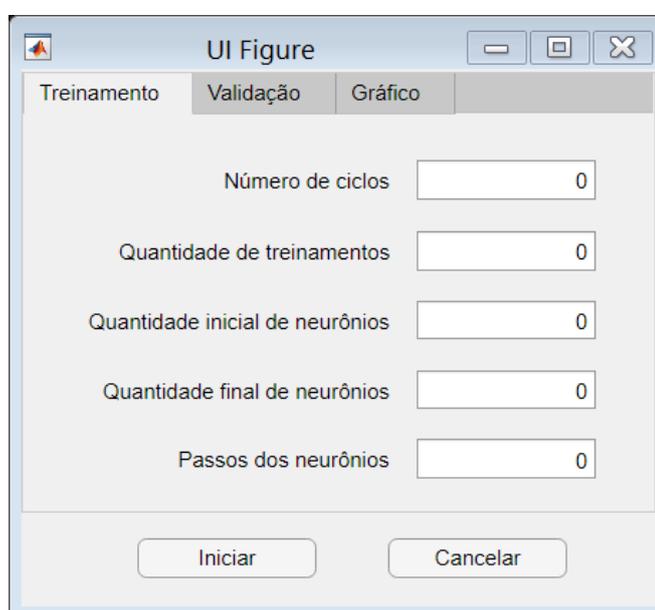


FIGURA 10 - Interface gráfica do programa criado para agilizar a utilização das funções desenvolvidas neste estudo.

Fonte: autoria própria (2019).

O parâmetro de configuração de quantidade de repetições, no treinamento de cada arquitetura, mostrou-se ser de grande importância na obtenção de um bom resultado. Essa configuração faz com que a cada novo treinamento, os pesos das sinapses sejam novamente inicializados e outro sorteio dos conjuntos de treinamento, validação e teste seja feito. Essa configuração permitiu superar um problema comum no treinamento de redes MLP, que utilizam algoritmo *backpropagation* devido à propensão de ficar preso em mínimos locais (ZWEIRI et al., 2005).

Neste experimento, foram desenvolvidas mais que 120.000 (cento e vinte mil) redes neurais do tipo MLP. Para agilizar a fase de treinamento foi criada uma função para automatizar o desenvolvimento das redes, isso permitiu realizar vários testes de configurações, parâmetros e dados de entrada, possibilitando chegar ao resultado obtido neste estudo. Na configuração final o número de neurônios da camada oculta variou de 1 a 20, com mil treinamentos distintos por variação, totalizando 20.000 (vinte mil) redes.

Na primeira versão do programa, eram necessárias aproximadamente 30h para treinar 20.000 (vinte mil) redes, fato devido ao esforço computacional para manter a janela do programa atualizada. Para cada rede treinada, a janela do programa era aberta e depois fechada. O código da função de treinamento foi modificado para que todo o processo computacional executasse em segundo plano, com isso a janela foi removida. Além disso, o código foi revisado, removendo instruções que pudessem causar processamento computacional desnecessário, ações que otimizaram consideravelmente o tempo necessário para o treinamento das redes, que passou a ser de 4 a 6h para treinar 20.000 (vinte mil) redes.

Nas primeiras redes treinadas, foram utilizados os dados dos 88 pontos amostrais, o que retornou redes na fase de treinamento com classificação “Ótima” segundo o índice de desempenho, mas na validação externa as mesmas redes tiveram classificação inferior a “Bom”. Resultado que corrobora com Braga et al., (2012), o conjunto de treinamento da RNA foi originado de dados experimentais, estes contêm implicitamente erros inerentes aos processos de amostragem e devido à configuração da rede MLP, que divide os dados em três subconjuntos de forma aleatória, o que facilita a ocorrência de *overfitting*, que é quando a rede se adapta aos *outliers* na fase de treinamento, gerando bons índices de desempenho, mas não consegue um índice de acerto bom na fase de validação.

### 3.2. Análise da estatística descritiva das variáveis de entrada

Dos 88 pontos amostrais coletados, foram descartados 10% dos valores tidos como *outliers*, os mesmos pontos que foram retirados na regressão. Os valores dos 79 pontos restantes foram utilizados no treinamento (treinamento, validação e teste) e validação externa das redes MLP. Na Tabela 7, 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 7 - Estatística Descritiva das variáveis específicas utilizadas no treinamento das RNAs.

Origem	Data	DAT	Variável	Média	Mín	Máx	Desvio padrão	C.V. (%)
LandSat 8	02/7	69	R04	0,0480	0,0444	0,0930	0,0059	12
			R05	0,5393	0,4712	0,5728	0,0164	3
			NDVI	0,8362	0,6701	0,8559	0,0227	2
	18/7	85	R04	0,0585	0,0510	0,1046	0,0079	14
			R05	0,4910	0,4343	0,5292	0,0196	4
			NDVI	0,7866	0,6221	0,8216	0,0315	4
Sentinel-2A	02/7	69	R04	0,0476	0,0438	0,0536	0,0020	4
			R08	0,4797	0,4374	0,5122	0,0145	3
			NDVI	0,8192	0,7871	0,8386	0,0104	1
	12/7	79	R04	0,0561	0,0506	0,0652	0,0027	5
			R08	0,4525	0,4118	0,5016	0,0170	4
			NDVI	0,7788	0,7370	0,8140	0,0141	2
Sentinel-2B	07/7	74	R04	0,0489	0,0444	0,0564	0,0026	5
			R08	0,4681	0,4308	0,5122	0,0150	3
			NDVI	0,8104	0,7772	0,8380	0,0125	2
	17/7	84	R04	0,0561	0,0491	0,0624	0,0028	5
			R08	0,4342	0,3868	0,4802	0,0176	4
			NDVI	0,7705	0,7221	0,8110	0,0157	2
<i>In loco</i>	09-11/7	76-	IAF	2,6572	1,3535	4,0923	0,5389	20

Mín: valor mínimo; Máx: valor máximo; C.V.: coeficiente de variação; R04: reflectância na banda do vermelho; R05: reflectância na banda do infravermelho para o satélite Landsat 8; R08: reflectância na banda do infravermelho para os satélites Sentinel-2A e B; NDVI: índice de vegetação por diferença normalizada; IAF: índice de área foliar.

Autoria própria (2019).

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%).

Ao realizar a divisão aleatória sem considerar os tratamentos utilizados para a obtenção das amostras, os conjuntos foram formados com amostras com pouca representatividade, o que disfarçou os *outliers*. Como consequência, obteve-se várias redes com performances elevadas nas fases de treinamento, validação e teste, mas ao fazer a validação externa, as redes não foram capazes de prever os valores.

Ao remover os *outliers*, aumentaram a quantidade de redes com índices de desempenho melhor em ambas as fases, treinamento e validação externa, e as redes que tiveram um alto índice de desempenho na fase de treinamento conseguiram estimar valores com precisão na fase de validação externa. A configuração, os parâmetros e o formato dos dados utilizados na rede teste foram o modelo seguido para as outras redes apresentadas neste estudo.

### 3.3. Treinamento das RNAs

Os treinamentos das RNAs do tipo MLP foram realizadas utilizando a função TREINAR e as configurações do computador descritos anteriormente, para realizar o treinamento de 120.000 (cento e vinte mil) redes foram necessárias aproximadamente 30h. Ao iniciar a função TREINAR é necessário preencher alguns parâmetros, os valores utilizados nos treinamentos estão descritos na Tabela 8.

TABELA 8 - Parâmetros utilizado para realizar treinamento da rede MLP

Parâmetro	Valor	Descrição
NrCiclos	1000	Número de ciclos – número máximo de vezes que os dados de treinamento serão apresentados para cada treinamento.
QteTreina	1000	Número de treinamentos – número de treinamentos que devem ser realizados em cada arquitetura (número de neurônio na camada oculta).
QteIniO	1	Quantidade de neurônios iniciais na camada oculta.
QteFimO	20	Quantidade final de neurônios na camada oculta.
QtePasO	1	Passos - é o incremento que será realizado na quantidade de neurônios na camada oculta cada vez que o número de treinamentos especificado for atingido.

Fonte: autoria própria (2019).

No treinamento, cada satélite e data de passagem se tornaram uma arquitetura que foi treinada separadamente, para identificação a origem dos dados, foram adotados identificadores (Tabela 9).

TABELA 9 - Identificadores dos dados de entrada da rede.

Satélite	Data imagem	Identificador
LandSat 8	02/07	L02
	18/07	L18
Sentinel-2	02/07	S02
	07/07	S07
	12/07	S12
	17/07	S17

Fonte: autoria própria (2019).

A classificação do id resultante das redes treinadas é apresentada nas Figuras 11a e 11b para os dados do satélite LandSat 8 e nas Figuras 12a, 12b, 12c e 12d são os dados dos satélites Sentinel-2 (A e B).

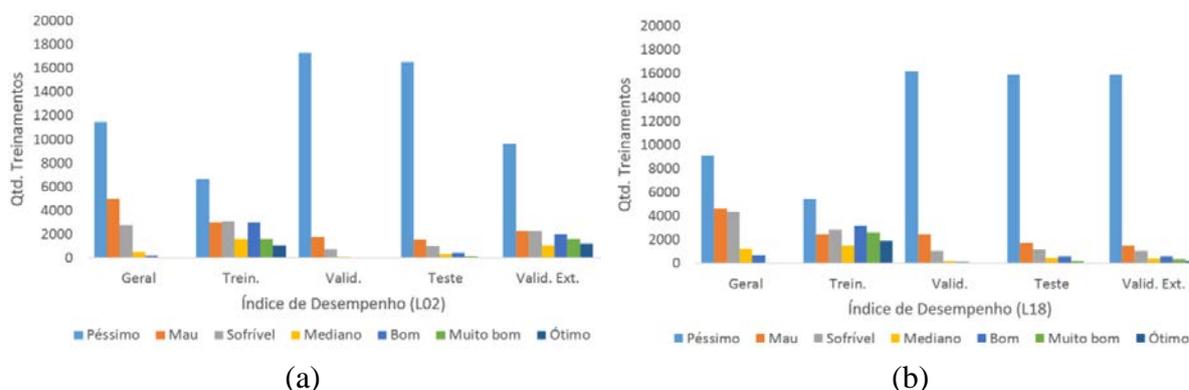


FIGURA 11 - Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados do LandSat 8 (a) dia 02/07; (b) dia 18/07.

Fonte: autoria própria (2019).

Apesar das configurações dos satélites do Sentinel-2 (A e B) serem a mesma, é possível observar uma diferença entre os dados do Sentinel-2A (Figura 12a) em relação ao Sentinel-2B (Figura 12b), a classificação realizada dos dados do satélite A no dia 02/07 segue um padrão de valor máximo e mínimo, diferente dos dados do satélite B no dia 07/07, mas a diferença pode ser justificada por se tratar de datas diferentes, mas o padrão de dados do satélite A se repete no dia 12/07 (Figura 12c) e o mesmo acontece com o padrão de dados do satélite B que se repete no dia 17/07 (Figura 12d).

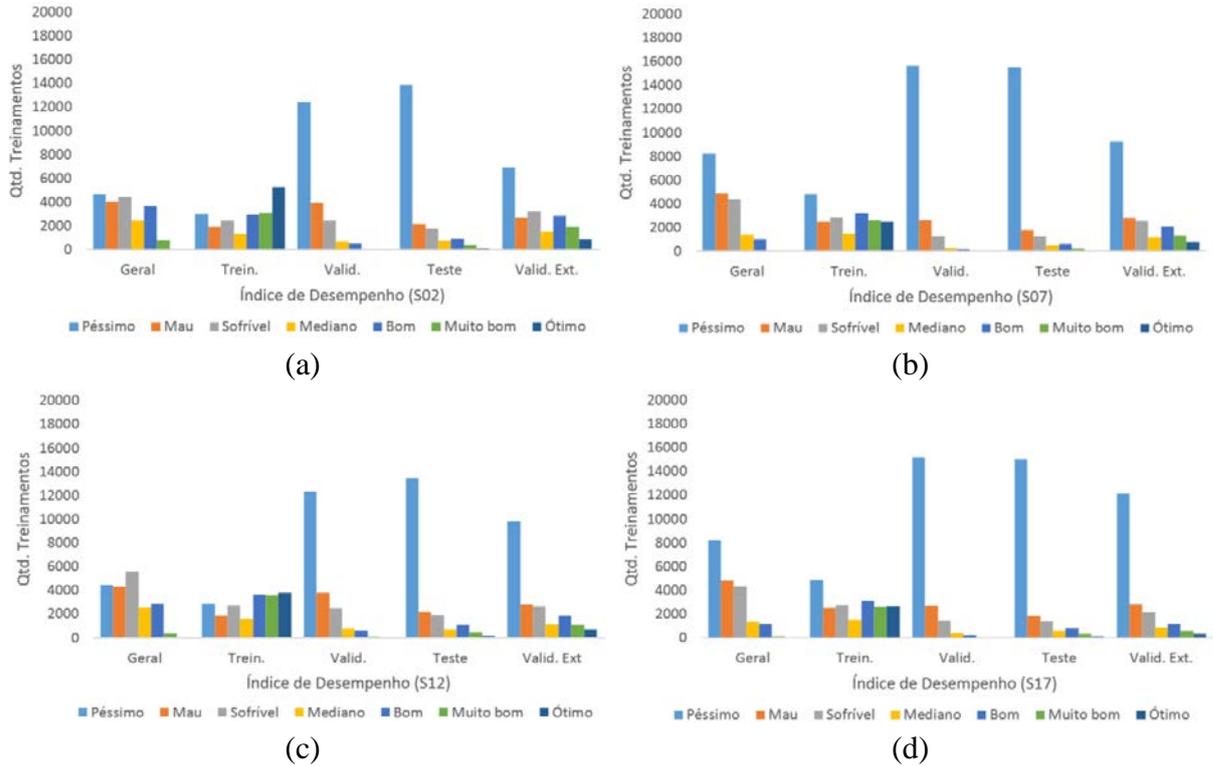


FIGURA 12 - Índice de Desempenho (id) das fases de treinamento (Geral, Treinamento, validação e teste) e validação externa dos dados do Sentinel-2 A e B (a) dia 02/07; (b) dia 07/07; (c) dia 12/07; (d) dia 17/07.

Fonte: autoria própria (2019).

Durante a fase de treinamento foi observado que a estratégia de um novo sorteio dos conjuntos de treinamento, validação e teste ocasionou problemas para a convergência e generalização das redes, pois a cada novo sorteio os tratamentos não foram levados em consideração, o que resultou no agrupamento de amostras no conjunto de treinamento, teste e validação com pouca representatividade, e que corrobora com os resultados obtidos por Lisboa e Taktak (2006) e comprovando que a rede passou a se especializar no conjunto de treinamento.

Ao comparar a Figura 13b com as Figuras 13c, 13d e 13e comprovasse que a maioria das redes se especializou no treinamento, pois tiveram boa classificação no id, o que não se repete na validação, no teste e na validação externa, mas que acaba influenciando no id geral, que apresenta resultados melhores. Resultados estes que corroboram com Braga et al. (2012), 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.

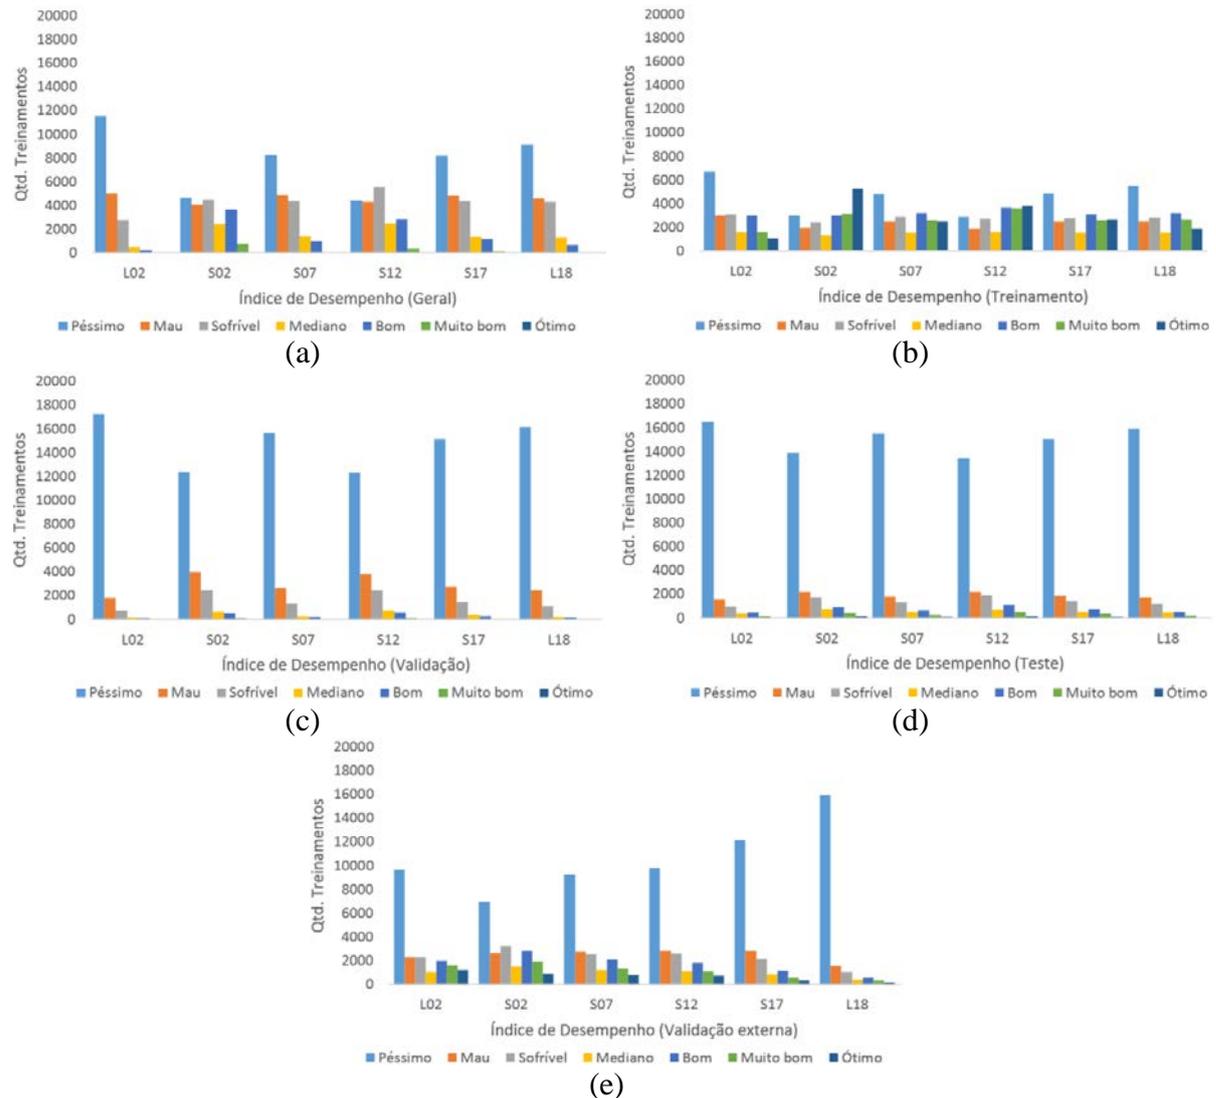


FIGURA 13 - Comparativo do índice de desempenho (id) entre os dados originados dos satélites LandSat 8 e o Sentinel-2 (A e B) e suas datas de passagem.

Fonte: autoria própria (2019).

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 13a), resultado que se repete na validação externa (Figura 13e). Esses resultados ocorreram devido à resolução espacial dos satélites Sentinel-2, que é de  $10 \text{ m}^2$ . Com essa resolução, a generalização do *pixel* é menor, 1 *pixel* equivale a  $10 \text{ m}^2$  à resolução do LandSat 8 é de  $30 \text{ m}^2$ , sendo 1 *pixel* equivalente a  $30 \text{ m}^2$ , 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 13e, no intervalo do dia 02 (69 DAP) até o dia 12 (79 DAP) os dados são estimados com boa classificação, no dia 17 (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, o que vale a data aproximada de 03/07, depois desta data a o declive do IAF.

#### 3.4. Rede selecionada

Para selecionar a rede que melhor conseguiu generalizar o problema foram utilizados vários critérios para garantir que fosse selecionada a rede com maior capacidade de generalização. Redes com menor número de neurônios na camada oculta têm maior capacidade de generalização. No entanto, a escolha de uma rede com poucos neurônios na camada oculta para um problema com alto grau de complexidade pode não conseguir modelar o problema incorrendo em *underfitting* (BRAGA et al., 2012).

Redes com grande número de neurônios na camada oculta podem resultar em *overfitting*. Quanto maior a estrutura, maior o número de parâmetros livres ajustáveis e, conseqüentemente, maior a flexibilidade da rede, gerando redes que memorizam os dados de entrada. superdimensionadas (BRAGA et al., 2012).

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 14), 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 10 mostra os valores dos indicadores estatísticos da rede selecionada.

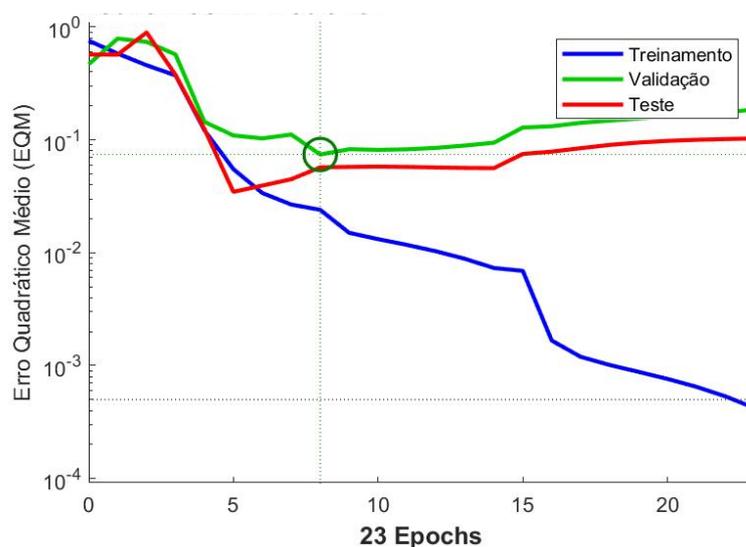


FIGURA 14 - Representação gráfica da fase de treinamento da rede selecionada (12 neurônios e treinamento 510).

Fonte: autoria própria (2019).

TABELA 10 - 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.

Fonte: autoria própria (2019).

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 15 mostra a representação gráfica do coeficiente de correlação (R) da rede selecionada. O gráfico foi gerado pela função PLOTAR desenvolvida para o programa.

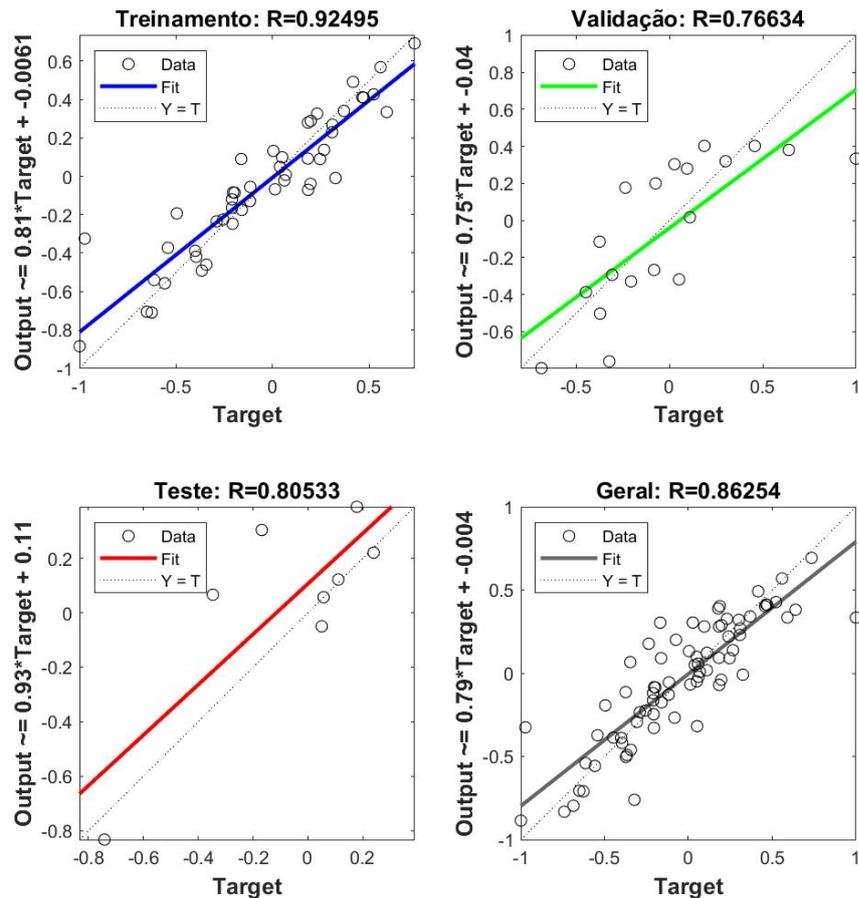


FIGURA 15 - Representação gráfica do coeficiente de correlação (R) da fase de treinamento (treinamento, validação, teste e geral) da rede selecionada com (12 neurônios e treinamento 510).

Fonte: autoria própria (2019).

A importância das repetições realizadas no treinamento pode ser observada na escolha da rede que foi encontrada após 510 repetições no treinamento da arquitetura com 12 neurônios na camada oculta.

A Figura 16 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.

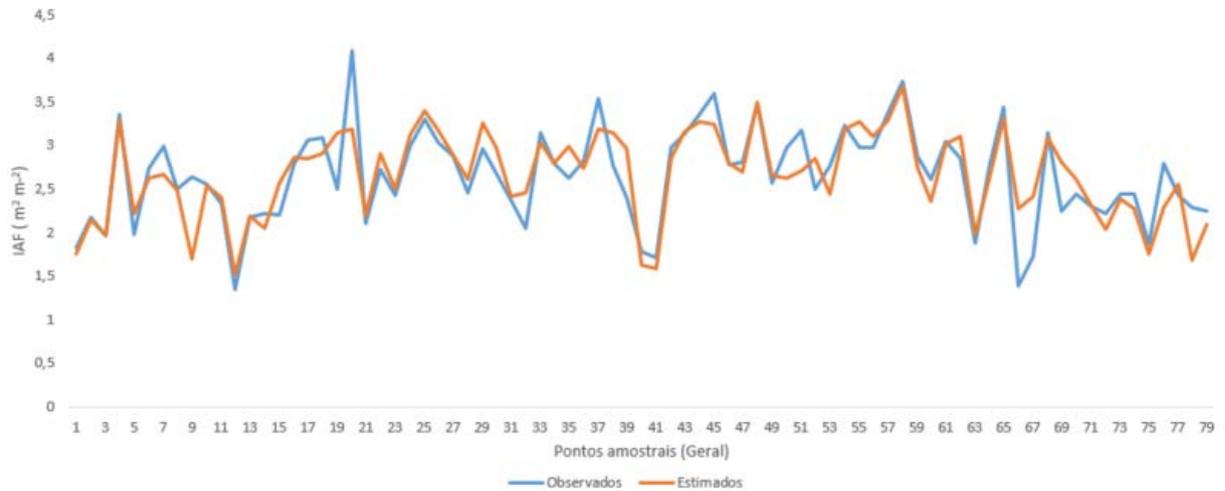


FIGURA 16 - Comparativo geral dos valores observados e estimados da rede selecionada (12 neurônios e treinamento 510).

Fonte: autoria própria (2019).

Se os *outliers* forem sorteados e ficarem, no conjunto treinamento, no início do treinamento da rede, a influência dele será amenizada. Na Figura 17, mostra o comparativo dos valores do conjunto treinamento, observa-se que um dos *outliers* identificados ficou no conjunto de treinamento, e como esperado teve sua influência amenizada, visto que a rede foi classificada como Ótima no id (BRAGA et al., 2012).

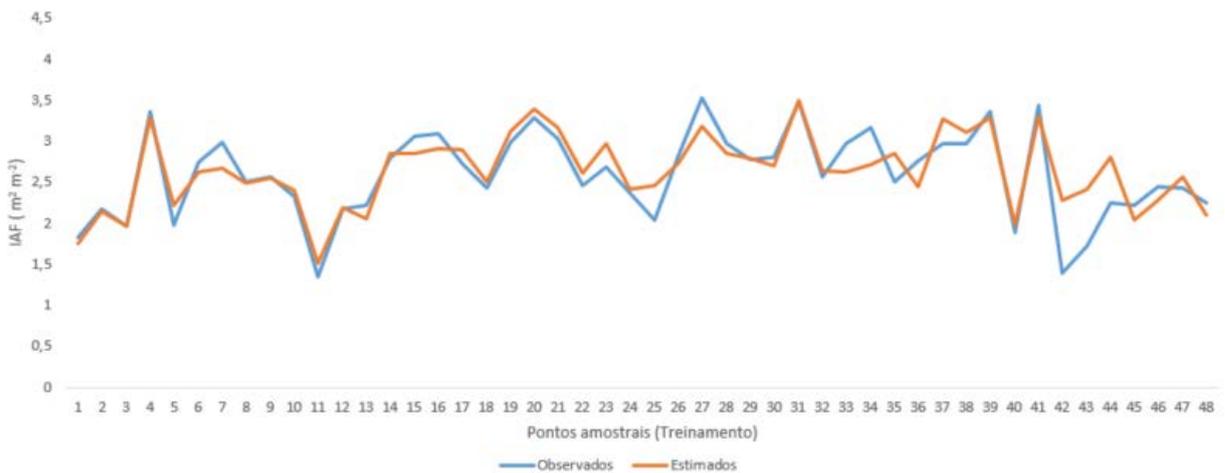


FIGURA 17 - Comparativo do conjunto treinamento dos valores observados e estimados da rede selecionada (12 neurônios e treinamento 510).

Fonte: autoria própria (2019).

Analisando a Figura 18, pode-se afirmar que o segundo *outlier* identificado foi sorteado para o conjunto de validação, como a quantidade de valores neste conjunto é menor, o *outlier* tem uma maior influência na classificação desta fase, que foi classificada com Bom.

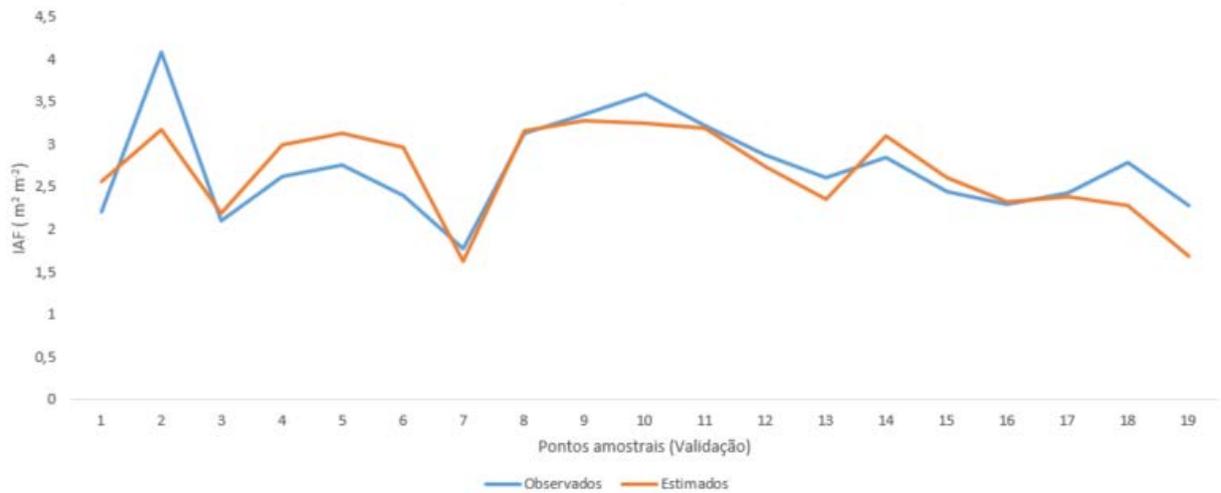


FIGURA 18 - Comparativo do conjunto validação dos valores observados e estimados da rede selecionada (12 neurônios e treinamento 510).

Fonte: autoria própria (2019).

Quanto menor o conjunto de dados, maior será a influência de valores discrepantes. A Figura 19a, representa o comparativo entre os valores observados e os valores estimados na fase de teste. O ponto um é o único que valor estimado está contrário ao sentido do valor observado. Só esse ponto fez com que essa fase fosse classificada como Bom. A Figura 19b 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.

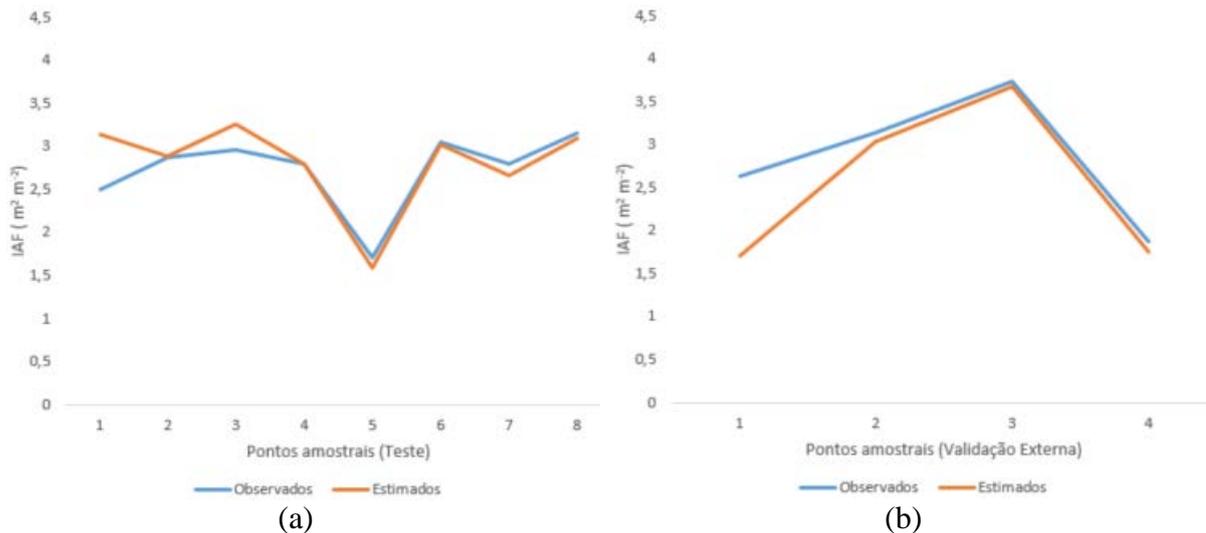


FIGURA 19 - Comparativo dos valores observados e estimados da rede selecionada (12 neurônios e treinamento 510) (a) Conjunto teste; (b) Conjunto validação externa.

Fonte: autoria própria (2019).

O desempenho apresentado pela RNA do tipo MLP foi considerado bom comparado com outros trabalhos envolvendo estimativas, pois dentre os trabalhos estudados para fazer este experimento não foi identificado nenhum outro trabalho que treinasse as redes com os mesmos parâmetros e arquitetura. Também não foi identificado nenhuma rede que fizesse a validação externa para confirmar a eficiência da rede.

#### 4. CONCLUSÕES

Com base no coeficiente de correlação obtido entre o IAF estimado e o aferido, é viável o emprego de sistemas computacionais inteligentes na estimativa do IAF do tomate industrial irrigado por meio de pivô central.

A RNA do tipo *Multilayer Perceptron* (MLP) com treinamento supervisionado conseguiu estimar com coeficiente de correlação acima de 70% o 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 obtidos *in loco*.

A presença de *outlier* nos dados de entrada da RNA podem mascarar os resultados e até mesmo inviabilizar estimativas confiáveis.

Para validar as RNAs é necessário implementar e executar a validação externa, com dados ainda não apresentados para a rede na fase de treinamento.

A arquitetura que melhor estimou o IAF do tomateiro 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, possibilita a universalização da RNA escolhida em relação ao pivô no qual a rede foi desenvolvida, sendo necessário a aplicação da rede treinada em outros pivôs para validá-la.

## 5. REFERÊNCIAS BIBLIOGRÁFICAS

- ALVES, G. R.; TEIXEIRA, I. R.; MELO, F. R.; SOUZA, R. T. G.; SILVA, A. G. Estimativa da produtividade de soja com redes neurais artificiais. **Acta Scientiarum. Agronomy**, . v. 40, n. 2. 2018.
- ALEKSANDER, I.; MORTON, H. **An introduction to neural computing**. Lodon: Int Thomson Comput Press, 1995.
- ALVAREZ, R. Predicting average regional yield and production of wheat in the argentine pampas by an artificial neural network approach. **European Journal of Agronomy**, v. 30, n. 2, p. 70–77. 2009.
- BITTAR, R. D.; ALVES, S. M. D. F.; MELO, F. R. DE. Estimation of physical and chemical soil properties by artificial neural networks. **Revista Caatinga**, . v. 31, n. 3, p. 704–712. 2018.
- BOHL, M. T.; DIESTELDORF, J.; SALM, C. A.; WILFLING, B. Spot market volatility and futures trading: the pitfalls of using a dummy variable approach. **Journal of Futures Markets**, v. XX, n. X, 2015.
- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro, 2012.
- CAMARGO, 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**, v.5, n.1, p. 89-97, 1997.
- CID Bio-Science. Tools that work where you work. CI-202 Portable Laser Leaf Area Meter. Disponível em: <<https://cid-inc.com/plant-science-tools/leaf-area-measurement/ci-202-portable-laser-leaf-area-meter/>>. Acesso em: 19 dez. 2018.
- CONGEDO, L. Semi-Automatic Classification Plugin Documentation Versão 5.3.6.1. Tutorial. 2017. Disponível em: <<https://media.readthedocs.org/pdf/semiautomaticclassificationmanual-v5-pt/latest/semiautomaticclassificationmanual-v5-pt.pdf>> Acesso em: 14 jul. 2018.
- DEERING, D. W., ROUSE, JR, J. W., HAAS, R. H., SCHELL, J. A. Measuring forage production of grazing units from Landsat MSS data, In: Internacional Syposium on Remote Sensing of Environment, 10, Ann Arbor, **Proceedings**. Ann Arbor, MI: ERIM, 1975. v. 2, p. 1169–1178.
- HAYKIN, S. **Neural network: A Comprehensive Foundation**. 2. ed. Ontario: Pearson Prentice Hall, p. 823, 2005.
- HECHT-NIELSEN, R. **Neurocomputing**. San Diego: Addison-Wesley, p. 433, 1989.
- IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2018. **SGB - Sistema Geodésico Brasileiro**. Disponível em: <<https://ww2.ibge.gov.br/home/geociencias/geodesia/>>. Acesso em: 14 jul. 2018.

JOSÉ, A.; LEAL, F.; MIGUEL, E. P.; HENRIQUE, F.; BAILO, R.; NEVES, D. D. C.; ALVES, U.; LEAL, S. Redes neurais artificiais na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do solo. **Bragantia**, v. 74, p. 436 – 444. 2015.

JURGIEL, B. Point Sampling Tool, 2018. Disponível em: <<https://github.com/borysiasty/pointsamplingtool>>. Acesso em: 14 jul. 2018.

KAUL, M.; HILL, R. L.; WALTHALL, C. Artificial neural networks for corn and soybean yield prediction. Beltsville: **Agricultural Systems**, . v. 85, n. 1, p. 1–18. 2005.

KOMINAKIS, A. P.; ABAS, Z.; MALTARIS, I.; ROGDAKIS, E. A preliminary study of the application of artificial neural networks to prediction of milk yield in dairy sheep. **Computers and Electronics in Agriculture**, v. 35, n. 1, p. 35–48. 2002.

LISBOA, P. J.; TAKTAK, A. F. G. The use of artificial neural networks in decision support in cancer: a systematic review. Liverpool: **Neural networks: the official journal of the International Neural Network Society**, v. 19, n. 4, p. 408–415, 2006.

MARTIN, N.; ABRAMO, J.; SOUSA, F. De; KARENINA, A.; MARTIN, T. N.; MARCHESE, J. A.; KARENINA, A.; SOUSA, F. De; CURTI, G. L. Uso do software imagej na estimativa de área foliar para a cultura do feijão. 2013.

MATHWORKS, 2019. Disponível em: <<https://la.mathworks.com/help/deeplearning/ref/mapminmax.html;jsessionid=9db8c10bb2cc8c9d6dbd8cb3278b>>. Acesso em: 19 jan. 2019.

NUNHEMS. Sementes de hostaliças catálogo 2016. **Nunhems**. Disponível em: <[http://nunhems.com.br/www/nunhemsinternet.nsf/id/BR\\_PT\\_Product\\_Catalogue\\_2/\\$file/BR\\_Catalogo\\_Multicrop\\_16pgs\\_A4.pdf](http://nunhems.com.br/www/nunhemsinternet.nsf/id/BR_PT_Product_Catalogue_2/$file/BR_Catalogo_Multicrop_16pgs_A4.pdf)>. Acesso em: 19 maio. 2018.

QGIS - Documentação do QGIS2.14. **Raster**. 2018. Disponível em: <[https://docs.qgis.org/2.14/pt\\_BR/docs/gentle\\_gis\\_introduction/raster\\_data.html](https://docs.qgis.org/2.14/pt_BR/docs/gentle_gis_introduction/raster_data.html)>. Acesso em: 29 jun. 2018.

REED, R. Pruning algorithms - a survey. **IEEE Transactions on Neural Networks**, v. 4, n. 5, p. 740–747. 1993.

REIS, L. S.; AZEVEDO, C. A V. De; ALBUQUERQUE, A. W.; S. JUNIOR, J. F. Índice de área foliar e produtividade do tomate sob condições de ambiente protegido. Campina Grande: **Revista Brasileira de Engenharia Agrícola e Ambiental**, . v. 17, n. 4, p. 386–391. 2013.

RUSSELL, S.; NORVIG, P. **Inteligência artificial**. 3<sup>a</sup> ed. CAMPUS, 2010.

SAFA, M.; SAMARASINGHE, S.; NEJAT, M. 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**, v. 17, n. 4, p. 791–803. 2015.

SCHIAVO, M. LO; PRINARI, B.; GRONSKI, J. A.; SERIO, A. V. An artificial neural network approach for modeling the ward atmosphere in a medical unit. **Mathematics and Computers in Simulation**, v. 116, p. 44–58. 2015.

SCHNEIDER, P.R. Análise de regressão aplicada à Engenharia Florestal. 2. Ed. Santa Maria. UFSM/CEPEF, p. 236, 1998.

SFAIR, J. C. Usando o imagej para calcular a área foliar. n. July. 2016.

SHARMA, A. K.; SHARMA, R. K.; KASANA, H. S. Prediction of first lactation 305-day milk yield in karan fries dairy cattle using ann modeling. **Applied Soft Computing Journal**, v. 7, n. 3, p. 1112–1120. 2007.

SILVA, I. N. Da; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas – curso prático. São Paulo: Artliber, 2010.

SIRGAS - SISTEMA DE REFERÊNCIA GEOCÊNTRICO PARA AS AMÉRICAS, 2018. Disponível em: <<http://www.sirgas.org/pt/>>. Acesso em: 8 jun. 2018.

SOARES, J. D. R.; PASQUAL, M.; LACERDA, W. S.; SILVA, S. O.; DONATO, S. L. R. Utilization of artificial neural networks in the prediction of the bunches' weight in banana plants. Lavras: **Scientia Horticulturae**, v. 155, p. 24–29. 2013.

TORRES, M.; HERVÁS, C.; AMADOR, F. Approximating the sheep milk production curve through the use of artificial neural networks and genetic algorithms. **Computers & Operations Research**, v. 32, n. 10, p. 2653–2670. 2005.

UNO, Y.; PRASHER, S. O.; LACROIX, R.; GOEL, P. K.; KARIMI, Y.; VIAU, A.; PATEL, R. M. Artificial neural networks to predict corn yield from compact airborne spectrographic imager data. **Computers and Electronics in Agriculture**, v. 47, n. 2, p. 149–161. 2005.

USGS - UNITED STATES GEOLOGICAL SURVEY.

\_\_\_\_\_. (a) **Landsat 8 Operational Land Imager (OLI) and Thermal Infrared Sensor (TIRS) Level-1 Data Products**. 2015. Disponível em: <<https://lta.cr.usgs.gov/L8>>. Acesso em: 27 jun. 2018.

\_\_\_\_\_. (b) **Sentinel-2 - The Long Term Archive - USGS**. 2015. Disponível em: <[https://lta.cr.usgs.gov/sentinel\\_2](https://lta.cr.usgs.gov/sentinel_2)>. Acesso em: 27 jun. 2018.

WILLMONT, C.J. On the validation of models. **Physical Geography**, Palm Beach, v.2, n.2, p.184-194, 1981.

ZWEIRI, Y. H.; SENEVIRATNE, L. D.; ALTHOEFER, K. Stability analysis of a three-term backpropagation algorithm. **Neural Networks**, v. 18, p. 1341–1347, 2005.

#### 4. CONCLUSÕES GERAIS

Ambos os métodos, modelo de regressão e RNA, conseguiram estimar o IAF com o coeficiente de determinação maior que 65% e o erro quadrado médio da raiz menor que 20%, a partir do NDVI obtido por sensoriamento remoto, o que representa uma redução de custo e tempo de trabalho, visto que não é necessário o deslocamento do agrônomo e nem o dia de trabalho coletando dados.

A principal variável para estimar o IAF é o NDVI, que pode ser obtido por sensoriamento remoto, a partir de imagens de satélite. As imagens do Sentinel-2 apresentaram serem promissoras no fornecimento de dados, devido ao espaçamento temporal de 5 dias, a resolução do sensor *Multispectral Instrument* (MSI) ser de 10 m<sup>2</sup> em algumas bandas e a disponibilização gratuita das imagens.

A estimativa pelo método da RNA mostrou-se ser melhor em estimar o IAF pontualmente, visto que os dados do pivô são inseridos como variáveis de entrada, já o modelo de regressão mostrou-se melhor para estimar valores médios. Sendo necessário mais estudos para comprovar e quantificar a diferença entre os modelos.

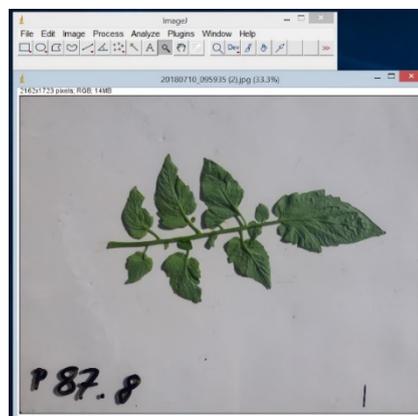
## APÊNDICES

### Apêndice A – Calcular a área foliar usando o ImageJ

#### Calcular a área foliar usando o ImageJ

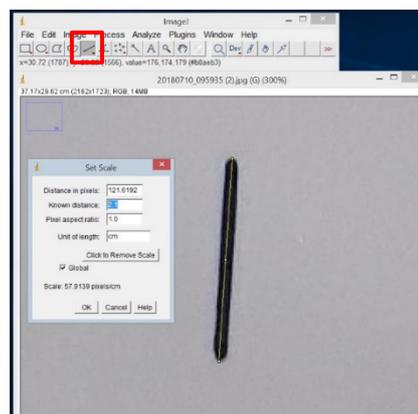
##### Carregar imagem

Com o software aberto, acesse o menu *File* e no submenu selecione a opção *Open* e a imagem a ser analisada.



##### Configurar a escala

Utilizando a ferramenta *Straighten*, marque o início e o fim da linha de 2,1 cm existente na imagem. Na função *Set Scale* (menu *Analyze*) defina que para a “Distância em pixels” mostrada tem-se a “Distância conhecida” de 2,1 cm.



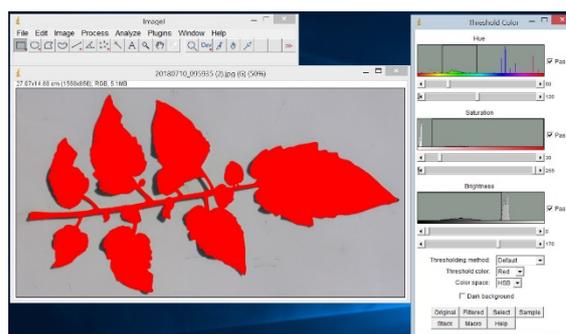
##### Eliminar os objetos desnecessários para mensurar a área foliar

Utilize as ferramentas de *Rectangle* para selecionar a área desejada e a função *Crop* (menu *Image*) para excluir os *pixels* fora da área selecionada.



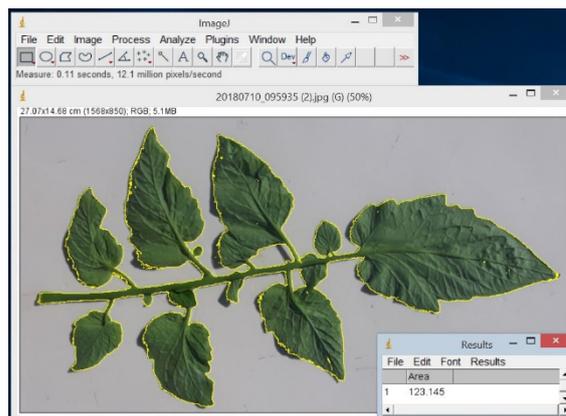
### Selecionar a área da folha

Usando a ferramenta de ajuste de imagem *Color Threshold* (menu *Image*, submenu *Adjust*) selecione somente a área da folha, descartando as sombras e possíveis sujeiras presentes na imagem.



### Mensurar a área foliar

Tendo somente a folha selecionada, utilize a função *Measure* (menu *Analyze*), que retornará à tabela com a área dos objetos selecionados em  $\text{cm}^2$ .



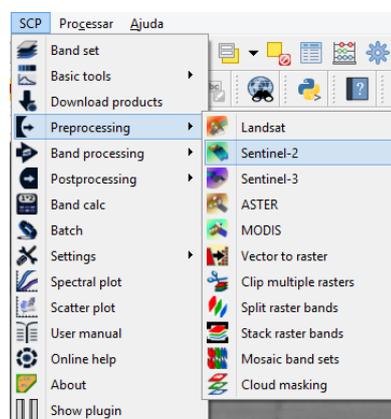
Fonte: adaptado do Sfair (2016).

## Apêndice B – Correção atmosférica de TOA para BOA de bandas do Landsat e do Sentinel-2

### Correção atmosférica de imagens

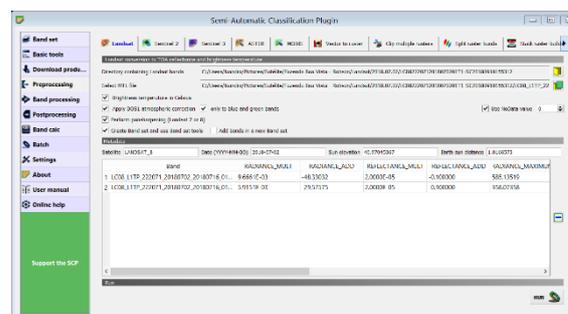
#### Carregar bandas

Selecione o módulo específico para as bandas do Landsat ou Sentinel-2 (menu *SCP*, submenu *Preprocessing*).



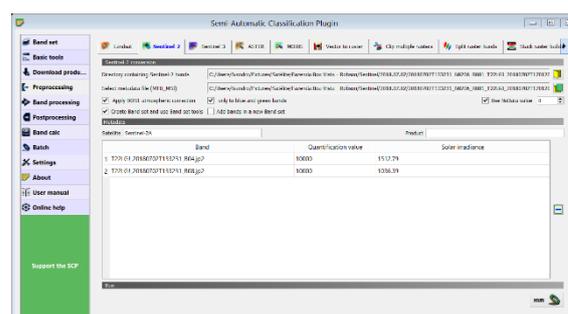
#### Conversão da refletância de imagens Landsat

Selecione a pasta que contém as bandas no formato *tif*. Depois selecione o arquivo MTL no formato *txt*. Por fim, ative os itens: *Brightness temperature in Celsius*, *Apply DOS1 atmospheric correction*, *Perform pansharpening (Landsat 7 or 8)* e clique em *Run*.



#### Conversão da refletância de imagens Sentinel-2

Selecione a pasta que contém as bandas no formato *jp2*. Depois selecione o arquivo metadata no formato *xml*. Por fim, ative o item *Apply DOS1 atmospheric correction* e clique em *Run*.



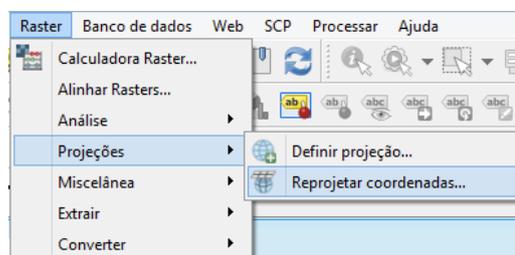
Fonte: adaptado do Congedo (2017).

## Apêndice C – Conversão do sistema de referência de coordenadas de WGS 84 para SIRGAS 2000 em imagens

### Conversão do sistema de referência de coordenadas

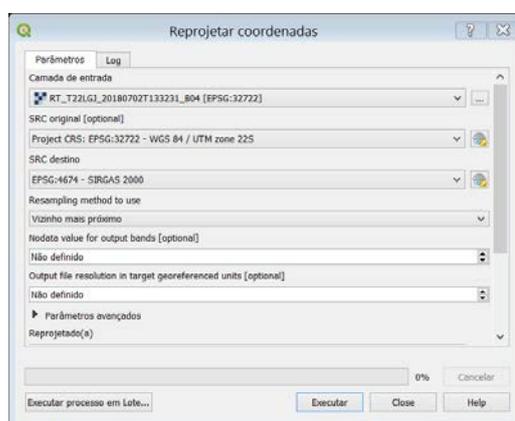
#### Reprojetar coordenadas

Selecione a função Reprojetar coordenadas...  
(menu *Raster*, submenu *Projeções*)



#### Conversão do sistema de referência de coordenadas

Selecione a camada de entrada que será convertida, o SRC original e o SRC destino, depois clique em Executar.



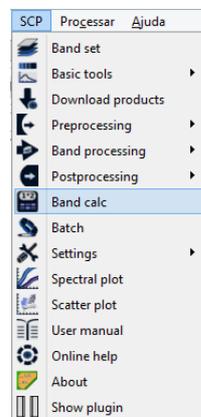
Fonte: adaptado do Congedo (2017).

## Apêndice D – Cálculo do Índice de Vegetação por Diferença Normalizada via complemento SCP

### Cálculo do NDVI

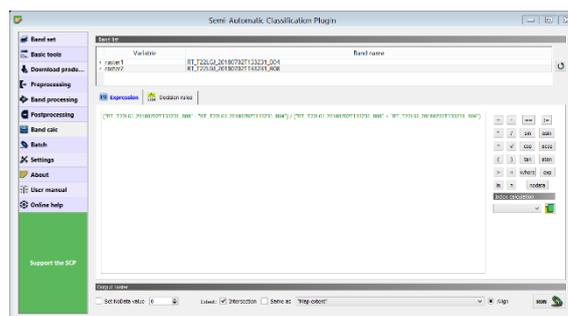
#### *Band calc*

Abra as imagens referentes às reflectâncias das bandas do vermelho e de infravermelho próximo, na sequência, acesse a função *Band calc* (menu *SCP*).



#### Calcular o NDVI

Clique em *Refresh list* para atualizar o sistema. Digite no campo *Expression* a fórmula do NDVI, para o Landsat (“R05” – “R04”) / (“R05” + “R04”) e se for Sentinel (“R08” – “R04”) / (“R08” + “R04”) e clique em *Run*.



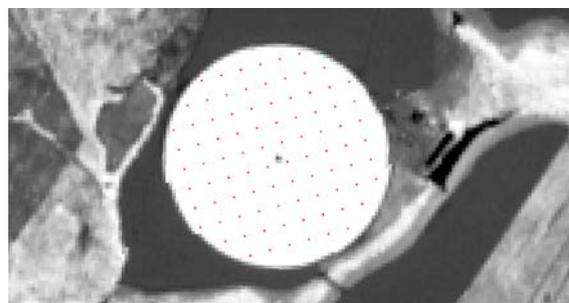
Fonte: adaptado do Congedo (2017).

## Apêndice E – Extração de valores *raster* de pontos específicos

### Extrair valores *raster* de pontos específicos

#### Grade amostral

Carregue a grade amostral para determinar os pontos de extração dos valores *raster*.



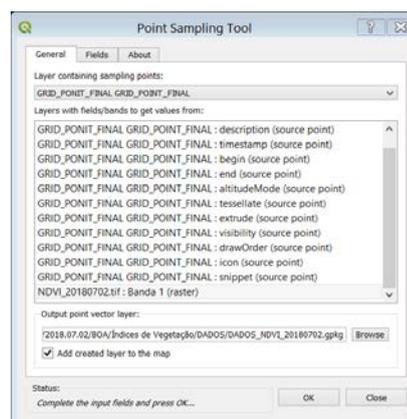
#### *Point Sampling Tool*

Abra o complemento *Point Sampling Tool* (menu Complementos, submenu *Analyses* ou na barra de Complementos).



#### Extrair valores

Selecione a camada contendo os pontos (*Layer containing sampling points*), depois selecione os campos que contenham os valores que serão extraídos (*Layers with fields/bands to get values from*), defina o local e o nome da camada que será criada (*Output point vector layer*). Clique no *Ok*.



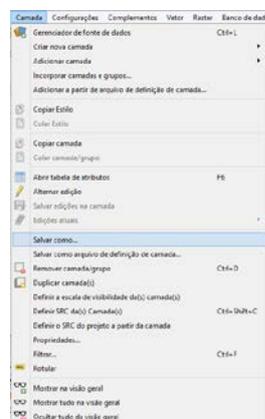
Fonte: autoria própria (2018).

## Apêndice F – Exportar tabela de atributos para *software* de planilhas eletrônicas

### Exportar tabela de atributos

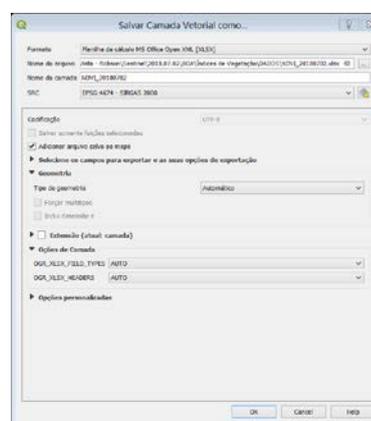
#### Salvar Camada Vetorial como...

Selecione a função Salvar como... (menu Camada) ou a função Salvar Feições Como... (clique o botão direito do *mouse* sobre a camada, menu Exportar).



#### Salvar

No campo Formato selecione a opção Planilha de cálculo MS Office Open XML [XLSX], depois selecione o diretório e o nome do arquivo que será criado. Clique no *Ok*.



Fonte: autoria própria (2018).