

CARLOS ALBERTO FONSECA DO NASCIMENTO

**USO DE IMAGENS DIGITAIS E APRENDIZADO DE MÁQUINA PARA ESTIMAR O
COEFICIENTE DE CULTURA DO FEIJOEIRO-COMUM**

Botucatu

2023

CARLOS ALBERTO FONSECA DO NASCIMENTO

**USO DE IMAGENS DIGITAIS E APRENDIZADO DE MÁQUINA PARA ESTIMAR O
COEFICIENTE DE CULTURA DO FEIJOEIRO-COMUM**

Tese apresentada à Faculdade de Ciências Agrônômicas da Unesp – Campus de Botucatu, para obtenção do título de Doutor em Agronomia (Irrigação e Drenagem)

Orientador: Prof. Dr. João Carlos Cury Saad

Botucatu

2023

N244u

Nascimento, Carlos Alberto Fonseca do

Uso de imagens digitais e aprendizado de máquina para
estimar o coeficiente de cultura do feijoeiro-comum / Carlos
Alberto Fonseca do Nascimento. -- Botucatu, 2023
153 p. : il., tabs., fotos

Tese (doutorado) - Universidade Estadual Paulista (Unesp),
Faculdade de Ciências Agrônomicas, Botucatu
Orientadora: João Carlos Cury Saad

1. Índice de vegetação. 2. Coeficiente de cultura. 3.
Feijoeiro-comum. 4. Aprendizado de máquina. 5. Índice de área
foliar. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da
Faculdade de Ciências Agrônomicas, Botucatu. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

“Permitida a cópia total ou parcial deste documento, desde que citada a fonte”



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Botucatu



CERTIFICADO DE APROVAÇÃO

Título:

USO DE IMAGENS DIGITAIS E APRENDIZADO DE MÁQUINA PARA ESTIMAR O COEFICIENTE DE CULTURA DO FEIJOEIRO-COMUM

AUTOR: CARLOS ALBERTO FONSECA DO NASCIMENTO

ORIENTADOR: JOÃO CARLOS CURY SAAD

Aprovado como parte das exigências para obtenção do Título de Doutor em Agronomia (Irrigação e Drenagem), pela Comissão Examinadora:

Prof. Dr. JOÃO CARLOS CURY SAAD (Participação Presencial)
Engenharia Rural e Socioeconomia / Faculdade de Ciências Agrônomicas de Botucatu UNESP

Professor Doutor CARLOS ENRIQUE DANIEL LÓPEZ PINTO (Participação Virtual)
Fisiologia Vegetal / Universidade Estadual do Amazonas

Prof. Dr. ROGÉRIO PERES SORATTO (Participação Presencial)
Produção Vegetal / Faculdade de Ciências Agrônomicas de Botucatu

Prof. Dr. DIEGO AUGUSTO DE CAMPOS MORAES (Participação Presencial)
Engenharia Rural e Socioeconomia / Faculdade de Ciências Agrônomicas de Botucatu UNESP

Professor Doutor CRISTÓVÃO GOMES PLÁCIDO JÚNIOR (Participação Virtual)
Ciência do Solo / Instituto Federal do Amazonas

Botucatu, 28 de julho de 2023.

**Aos meus pais, Raimundo e Neuza,
que são a razão da minha existência
e aos meus filhos Bruno, Vanessa,
Dhayly, Heloísa e Sheila, que são a
razão da minha vida. Vocês me
enchem de ânimo e esperança para
seguir firme na nossa jornada.**

Dedico!

AGRADECIMENTOS

Ao meu Deus pela generosidade de estar sempre comigo me acolhendo em seus braços quando o fardo está muito pesado;

Aos meus pais, Raimundo Cruz do Nascimento e Neuza Nunes da Fonseca, que sempre estão comigo, sinto a força de vocês todos os dias torcendo pela minha vitória;

Aos meus filhos Bruno Barbosa Fonseca, Vanessa Barbosa do Nascimento, Dhayly Salyne Maciel da Silva, Heloísa Barbosa do Nascimento e Sheila Maciel do Nascimento, que são a razão do meu viver;

A minha esposa Dalia Macedo Maciel por está comigo nessa jornada, compartilhando os dias difíceis com amor e compreensão;

Aos meus irmãos que tanto torcem pela minha vitória;

Ao meu orientador, Dr. João Carlos Cury Saad, pela oportunidade de aprender com sua forma ímpar de ensinar e orientar, mais um amigo importante que tenho na minha vida;

À Fundação de Amparo à Pesquisa do Estado do Amazonas, pelo apoio financeiro, concedido por meio de bolsa de doutorado, aprovado no Edital nº 012/2021;

Aos amigos Thássio, Gilberto, Caio, Yudi e Lucas pelo apoio na implantação e acompanhamento do projeto de pesquisa;

Ao Programa de Irrigação e Drenagem da Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP) – Faculdade de Ciências Agrônômica, por conceder a oportunidade de aprimoramento profissional;

Ao Instituto Federal de Educação Ciência e Tecnologia do Amazonas, pela concessão do afastamento para cursar pós-graduação nível doutorado.

“Quando o sol bater na janela do teu quarto, lembra e vê que o caminho é um só, até bem pouco tempo atrás, poderíamos mudar o mundo, quem roubou nossa coragem? Tudo é dor, e toda dor vem do desejo, de não sentirmos dor”.

Legião Urbana. Quando o sol bater na janela do teu quarto. *In*: Legião Urbana. **As Quatro Estações**. Rio de Janeiro: EMI, 1989. CD. Faixa 4.

RESUMO

O uso do coeficiente de cultura (K_c) é essencial para o eficiente manejo da irrigação, entretanto quantificá-lo durante o ciclo da cultura ainda é um desafio, pois os métodos diretos de determinação são trabalhosos e onerosos. O objetivo principal deste trabalho foi estimar os valores de K_c durante as fases fenológicas da cultura do feijoeiro-comum em função dos graus-dia acumulados (GDA), do índice de área foliar (IAF), da fração de cobertura vegetal (FCV), do índice de vegetação por diferença normalizada (NDVI) e do índice de vegetação ajustado ao solo (NDVI). A pesquisa foi conduzida no Departamento de Engenharia Rural e Socioeconomia, da Faculdade de Ciências Agrônomicas - Campus Botucatu - UNESP. Os valores de GDA foram calculados a partir de dados meteorológicos locais; os valores de IV, NDVI e SAVI, foram obtidos a partir de imagens digitais multiespectrais, com uso de veículos aéreo não-tribulado (VANT); e os valores de IAF e FCV foram obtidos de imagens digitais proximais, classificadas com uso de algoritmos de aprendizado de máquina (AM). O experimento foi desenvolvido em campo, em dois ciclos da cultura, sendo o primeiro ciclo denominado de etapa de modelagem (11/05 a 09/08/2022) e o segundo ciclo de etapa de validação (16/10 a 31/12/2022). Em ambas as etapas foram determinadas: a evapotranspiração de cultivo pelo método do balanço hídrico do solo (ET_{c_BH}), a evapotranspiração de referência (ET_o) pelo método de Penman-Monteith, e o coeficiente de cultivo pelo método do balanço hídrico do solo (K_{c_BH}), a partir da relação entre ET_{c_BH} e ET_o . Na etapa de modelagem foram criados os modelos de AM a partir dos métodos de Máquina de Vetores de Suporte (SVM), Floresta Aleatória (RF) e Regressão Logística Multiclasse (LR) capazes de classificar corretamente os pixels da imagem digital proximal e extrair os valores IAF e FCV. Nesta etapa, utilizou-se análise de regressão para gerar os modelos matemáticos a partir da relação entre IAF, FCV, NDVI e SAVI em função de GDA, possibilitando estimar os valores de IAF (IAF_GDA), FCV (FCV_GDA), NDVI ($NDVI_GDA$) e SAVI ($SAVI_GDA$). Seguindo a mesma metodologia e utilizando o K_{c_BH} , obteve-se K_c em função dos GDA (K_{c_GDA}), K_c em função do IAF (K_{c_IAF}), K_c em função da FCV (K_{c_FCV}), K_c em função do NDVI (K_{c_NDVI}) e K_c em função do SAVI (K_{c_SAVI}). Os resultados mostraram que o modelo LR de AM é o mais adequado para classificar corretamente os pixels das imagens proximais e extrair os valores de IAF e FCV, com acurácia (100%) e em menor custo computacional em tempo (31 s). O ciclo fenológico da

cultura foi influenciado pelos GDA, sendo observado 91 dias e GDA de 864,91 °C para a etapa de modelagem, e 77 dias e GDA de 920,85 °C para a etapa de validação. Na etapa de modelagem, os valores estimados pelos modelos IAF_GDA, FCV_GDA, NDVI_GDA e SAVI_GDA tiveram desempenho adequado, quando comparados aos valores observados de IAF, FCV, NDVI e SAVI. Na validação, o modelo IAF_GDA teve uma leve tendência de subestimar os valores de IAF, enquanto os modelos FCV_GDA, NDVI_GDA e SAVI_GDA tiveram tendência de superestimar os valores de FCV, NDVI e SAVI. Na etapa de modelagem, todos os valores estimados pelos modelos Kc_GDA, Kc_FCV, Kc_IAF, Kc_SAVI e Kc_NDVI tiveram desempenho adequado, quando comparados com os valores observados de Kc_BH. Na validação, a relação entre os valores estimados e observados tiveram alta correlação para Kc_GDA, Kc_IAF, Kc_FCV, e baixa correlação para Kc_SAVI e Kc_NDVI. A produtividade em grãos da cultura foi semelhante, enquanto a eficiência de uso da água (EUA) diferiu estatisticamente, pelo teste t de Student, para as etapas de modelagem e validação.

Palavras-chave: índice de vegetação; coeficiente de cultura; feijoeiro-comum; aprendizado de máquina; índice de área foliar.

ABSTRACT

The use of the crop coefficient (K_c) is essential for efficient irrigation management; however, quantifying it during the crop cycle is still a challenge, as direct determination methods are laborious and expensive. The main objective of this work was to estimate the K_c values during the phenological phases of the common bean crop as a function of the accumulated degree days (GDA), the leaf area index (LAI), the vegetation cover fraction (FCV), the normalized difference vegetation index (NDVI) and the soil-adjusted vegetation index (SAVI). The research was conducted at the Department of Rural Engineering and Socioeconomics of the Faculty of Agricultural Sciences - Campus Botucatu - UNESP. GDA values were calculated from local meteorological data; the LAI, NDVI, and SAVI values were obtained from multispectral digital images using unmanned aerial vehicles (UAVs); and IAF and FCV values were obtained from proximal digital images, classified using Machine Learning (ML) algorithms. The experiment was carried out in the field in two crop cycles; the first cycle was called the modeling stage (05/11 to 08/09/2022), and the second cycle was the validation stage (10/16 to 12/31/2022). In both stages, the following parameters were determined: crop evapotranspiration using the soil water balance method (ET_{c_BH}), reference evapotranspiration (ET_o) using the Penman-Monteith method, and the crop coefficient using the soil water balance method (K_{c_BH}), based on the relationship between ET_{c_BH} and ET_o . In the modeling stage, AM models were created using Support Vector Machine (SVM), Random Forest (RF), and Multiclass Logistic Regression (LR), methods capable of correctly classifying the pixels of the proximal digital image and extracting the values IAF and FCV. At this stage, regression analysis was used to generate mathematical models based on the relationship between IAF, FCV, NDVI, and SAVI as a function of GDA, making it possible to estimate the values of IAF (IAF_GDA), FCV (FCV_GDA), NDVI ($NDVI_GDA$) and SAVI ($SAVI_GDA$). Following the same methodology and using K_{c_BH} , K_c was obtained as a function of GDA (K_{c_GDA}), K_c as a function of IAF (K_{c_IAF}), K_c as a function of FCV (K_{c_FCV}), K_c as a function of NDVI (K_{c_NDVI}) and K_c as a function of SAVI (K_{c_SAVI}). The results showed that the LR AM model is the most suitable for correctly classifying the pixels of the proximal images and extracting the IAF and FCV values with accuracy (100%) and at a lower computational cost in time (31 s). The GDA influenced the phenological cycle of the culture, with 91 days and a GDA of 864.91 °C being observed for the

modeling stage and 77 days and a GDA of 920.85 °C for the validation stage. In the modeling stage, the values estimated by the IAF_GDA, FCV_GDA, NDVI_GDA, and SAVI_GDA models performed adequately compared to the observed values of IAF, FCV, NDVI, and SAVI. In validation, the IAF_GDA model slightly underestimated the IAF values, while the FCV_GDA, NDVI_GDA, and SAVI_GDA models tended to overestimate the FCV, NDVI, and SAVI values. In the modeling stage, all values estimated by the Kc_GDA, Kc_FCV, Kc_IAF, Kc_SAVI, and Kc_NDVI models performed adequately when compared with the observed values of Kc_BH. In validation, the relationship between estimated and observed values had a high correlation for Kc_GDA, Kc_IAF, and Kc_FCV and a low correlation for Kc_SAVI and Kc_NDVI. The grain productivity of the crop was similar, while the water use efficiency (WUE) differed statistically, using the Student's t-test for the modeling and validation stages.

Keywords: vegetation index; culture coefficient; common bean; machine learning; leaf area index.

LISTA DE ILUSTRAÇÕES

Figura 1 - Esquema ilustrativo dos fluxos de entradas e saídas de água do balanço hídrico do solo.....	31
Figura 2 - Curva generalizada do Kc único.....	34
Figura 3 - Comportamento espectral de objetos na superfície terrestre	37
Figura 4 - Comportamento espectral de uma folha com e sem estresse hídrico	38
Figura 5 - Componentes básicos de um VANT	40
Figura 6 - Imagem proximal classificada usando algoritmo de AM.....	41
Figura 7 - Fluxo de trabalho de um algoritmo de AM supervisionado.....	45
Figura 8 - Fluxo de trabalho de um método hipotético de Comitê de Máquina.....	46
Figura 9 - Fluxo de trabalho do método Baggins	47
Figura 10 - Estrutura hierárquica genérica de uma árvore de decisão com três atributos (A, B, C) e duas classes (X e Y).	48
Figura 11 - Fluxo de trabalho, meramente ilustrativa, de um método Floresta aleatória com cinco atributos e duas classes (fruta ou hortaliça)	49
Figura 12 - Hiperplano perfeitamente separável para duas variáveis regressoras....	50
Figura 13 - Hiperplano perfeitamente separável para duas variáveis regressoras com os vetores de suporte	52
Figura 14 - Hiperplano com vetores de suporte permitindo algumas restrições.....	53
Figura 15 - Disposição hipotética de dados de duas classes não separáveis linearmente.....	54
Figura 16 - Criação do espaço de características por produtos escalares, com uso de um Kernel, passando de bidimensional para tridimensional.....	56
Figura 17 - Representação de um neurônio biológico com suas principais estruturas de transmissão de sinal.....	57
Figura 18 - Representação básica de uma RNA simples Perceptron	58
Figura 19 - Representação básica de uma RNA Multi-Layer Perceptron.....	59
Figura 20 - Mapa de localização da área experimental.....	61
Figura 21 - Procedimentos gerais de preparação do solo da área experimental. Aração com arado de disco reversível (A); gradagem com grade aradora (B); aplicação de calcário dolomítico (C); semearadura e aplicação de adubo com plantadeira Semeato plantio direto (D).	64
Figura 22 - Aplicação de adubo nitrogenado com carro distribuidor (A); aplicação produtos agroquímicos com pulverizador manual (B); capina manual com enxada (C); aplicação de produtos agroquímicos diversos via irrigação com venturi (D).....	66

Figura 23 - Etapas do método da bacia de saturação. Inserção e saturação da bacia (A); cobertura da bacia para evitar evaporação (B); material coletado diariamente, após 48 horas de saturação (C); amostras colocadas em estufas por 24 horas a 105 °C (D)	67
Figura 24 - Comportamento do conteúdo de água no solo, durante 11 dias de coleta de amostras de solo, em duas camadas	68
Figura 25 - Curvas características de retenções de água no solo	71
Figura 26 - Distribuição de tensiômetros dentro da área útil experimental, deixando bordas periféricas (A); instalações de tensiômetros na quarta linha, contado a partir do centro (B); tensiômetros instalados na área útil experimental (C); leitura dos tensiômetros utilizando tensímetro digital (D).	72
Figura 27 - Lago artificial usado como fonte de abastecimento de água (A); Conjunto motobomba utilizado para fornecer água ao sistema de irrigação (B); tubos e conexões de engate prático com rosca (C); montagem do sistema de irrigação por aspersão (D); Sistema de irrigação montado e testado (E).....	74
Figura 28 - Croqui de instalação dos coletores (A); Coleta volumétrica usando proveta (B); panorama real da disposição dos coletores (C)	75
Figura 29 - Folhas de uma única planta armazenada em saco de papel (A); folhas submetidas a um integrador óptico de área foliar LI_COR 3100 C (B); Suporte de mesa em pvc para digitalização de imagem (C); Imagem digitalizada com três rótulos (alvo – vermelho, fundo – branca, folhas –verde) (D)	80
Figura 30 - Fluxo de processos de classificação de imagem proximal utilizando AM no ambiente de programação JN, para extração do IAF	82
Figura 31 - Captura de imagem usando sensor proximal de câmera de Smartphone acoplado em um bastão selfie (A); imagem digital obtida com a moldura delimitadora (B)	83
Figura 32 - Fluxo de processos de classificação de imagem proximal utilizando AM no ambiente de programação JN, para extração do FCV	85
Figura 33 - Aquisição de imagens multiespectrais: Equipamentos necessários (A); decolagem do drone (B).....	86
Figura 34 - Etapas de calibração geométrica e radiométrica: Equipamento GNSS RTK (A); coleta e demarcação de pontos de controle (B); painel calibração (C); captura de imagem do painel de calibração (D)	88
Figura 35 - Geração de ortomosaico: sem correção radiométrica (A); com correção radiométrica (B).....	90
Figura 36 - Fluxo de processos de geração de NDVI e SAVI, usando software QGIS e ambiente de programação JN.....	91
Figura 37 - Fluxo de modelagem e validação dos modelos de regressão gerados a partir das relações entre IAF, FCV, SAVI e NDVI com os GDA.....	93

Figura 38 - Monitoramento do conteúdo de água no solo, pelo método do balanço hídrico, durante o 'ciclo 1' na cultura do feijoeiro	97
Figura 39 - Monitoramento de entradas e saídas de água do sistema solo – planta – atmosfera, durante o 'ciclo 1' na cultura do feijoeiro, segundo suas fases fenológicas	99
Figura 40 - Temperaturas mínimas e máximas e basal inferior aferidas na cultura do feijoeiro, durante o "ciclo 1" etapa de modelagem	100
Figura 41 - Temperaturas mínimas e máximas e basal inferior aferidas na cultura do feijoeiro, durante o "ciclo 2" etapa de validação	101
Figura 42 - Criando os modelos de AM a partir dos métodos SVM, RF e LR no ambiente JN	103
Figura 43 - Matriz de confusão gerada a partir dos resultados gerados pelos modelos classificadores.....	103
Figura 44 - Matriz de confusão gerada a partir dos dados de validação para três modelos de aprendizado de máquina	104
Figura 45 - Resultado de uma imagem lote classificada pelos modelos de AM.....	106
Figura 46 - Evolução da IAF durante a etapa de modelagem, usando imagens lotes classificadas pelo modelo classificador LR	107
Figura 47 - Comparação entre diferentes métodos de estimativa da IAF	108
Figura 48 - Comportamento do modelo não linear ajustado ao IAF em função dos GDA e DAE, durante as fases fenológicas do feijoeiro, etapa de modelagem	109
Figura 49 - Criando os modelos de AM a partir dos métodos SVM, RF e LR no ambiente JN	110
Figura 50 - Matriz de confusão gerada a partir dos dados de teste para três modelos de aprendizado de máquinas.....	111
Figura 51 - Matriz de confusão gerada a partir dos dados de validação para três modelos de aprendizado de máquinas.....	112
Figura 52 - Resultado de uma imagem lote classificada pelos modelos de AM.....	113
Figura 53 - Evolução da FCV durante a etapa de modelagem, usando imagens lotes classificadas pelo modelo classificador LR	114
Figura 54 - Comportamento do modelo não linear ajustado ao FCV em função dos GDA e DAE, durante as fases fenológicas do feijoeiro, na etapa de modelagem	115
Figura 55 - Evolução espacial e temporal do NDVI durante a etapa de modelagem	117
Figura 56 - Comportamento do modelo não linear ajustado ao NDVI em função dos GDA e DAE, durante as fases fenológicas do feijoeiro, na etapa de modelagem	118

Figura 57 - Evolução espacial e temporal do SAVI, durante a etapa de modelagem	119
Figura 58 - Comportamento do modelo não linear ajustado ao SAVI em função dos GDA e DAE, durante as fases fenológicas do feijoeiro, na etapa de modelagem.....	121
Figura 59 - Comparação entre IAF observado e IAF_GDA estimado durante as etapas de modelagem e validação	122
Figura 60 - Comparação entre FCV observado e FCV_GDA estimado durante as etapas de modelagem e validação	124
Figura 61 - Comparação entre NDVI observado e NDVI_GDA estimado durante as etapas de modelagem e validação	125
Figura 62 - Comparação entre SAVI observado e SAVI_GDA estimado durante as etapas de modelagem e validação	126
Figura 63 - Comportamento do modelo não linear ajustado ao Kc_BH em função dos GDA e DAE, durante as fases fenológicas do feijoeiro-comum, etapa de modelagem.....	128
Figura 64 - Relação linear entre as variáveis Kc_BH e IAF durante as fases fenológicas do feijoeiro, no “ciclo 1”, etapa de modelagem	130
Figura 65 - Relação exponencial entre as variáveis Kc_BH e FCV durante as fases fenológicas do feijoeiro, no “ciclo 1”, etapa de modelagem...	131
Figura 66 - Relação exponencial entre as variáveis Kc_BH e NDVI durante as fases fenológicas do feijoeiro, no “ciclo 1”, etapa de modelagem...	132
Figura 67 - Relação exponencial entre as variáveis Kc_BH e SAVI durante as fases fenológicas do feijoeiro, no “ciclo 1”, etapa de modelagem...	133
Figura 68 - Comparação entre Kc_BH observado e Kc_GDA estimado durante as etapas de modelagem e validação	134
Figura 69 - Comparação entre Kc_BH observado e Kc_IAF estimado durante as etapas de modelagem e validação	135
Figura 70 - Comparação entre Kc_BH observado e Kc_FCV estimado durante as etapas de modelagem e validação	137
Figura 71 - Comparação entre Kc_BH observado e Kc_NDVI estimado durante as etapas de modelagem e validação	138
Figura 72 - Comparação entre Kc_BH observado e Kc_SAVI estimado durante as etapas de modelagem e validação	139

LISTA DE TABELAS

Tabela 1 - Composição nutricional do feijão carioca cozido	28
Tabela 2 - Funções Kernel mais usadas pelo algoritmo SVM não linear	55
Tabela 3 – Descrição e tempo de duração, em dias, das etapas de modelagem e validação	62
Tabela 4 - Resultado da análise química de macro e micronutrientes do solo da área experimental dos ciclos 1 e 2	63
Tabela 5 - Resultado da análise física granulométrica e classe textural do solo.....	63
Tabela 6 - Valores de umidades e tensões de água no solo obtidos pelo método de Richards para duas camadas	69
Tabela 7 - Equações ajustadas, densidade do solo e coeficiente de determinação para duas camadas de solo.....	70
Tabela 8 - Valores encontrados para umidades no solo na capacidade de campo, crítica e ponto de murcha permanente, e suas respectivas tensões, para duas camadas	71
Tabela 9 - Escala de classificação de uniformidade de CUC e CUD	76
Tabela 10 - Duração de em dias de cada fase fenológica do feijoeiro cultivar TAA Dama do grupo “Carioca”	79
Tabela 11 - Especificações básicas da câmera multiespectral Parrot Sequoia para um planejamento de voo a 120 m de altura	87
Tabela 12 - Balanço hídrico do solo da área experimental durante o ‘ciclo 1’, início em 11/05 e término em 09/08/22.....	98
Tabela 13 - Graus-dias acumulados em cada fase fenológica e sua respectiva duração, em dias, durante as etapas de modelagem e validação.....	102
Tabela 14 - Métricas de avaliações dos três modelos classificadores de aprendizado de máquinas, para os dados de validação	105
Tabela 15 - Métricas de avaliações dos três modelos classificadores de aprendizado de máquinas, para os dados de validação	112
Tabela 16 - Desempenho dos modelos de regressão linear, comparando os valores observados e estimados, durante as etapas de modelagem e validação	127
Tabela 17 - Valores de coeficiente de cultura (Kc) médios obtidos por diferentes autores e pela pesquisa atual para diferentes fases fenológicas	129
Tabela 18 - Desempenho dos modelos de regressão linear, comparando os valores observados e estimados, durante as etapas de modelagem e validação	140

Tabela 19 - Componentes de produtividade e eficiência no uso da água para a cultura do feijoeiro obtidos durante as etapas de modelagem e validação	141
---	-----

SUMÁRIO

1	INTRODUÇÃO	25
2	REVISÃO DE LITERATURA	28
2.1	Cultura do feijoeiro.....	28
2.2	Uso da irrigação	29
2.3	Manejo da Irrigação.....	30
2.4	Evapotranspiração	32
2.5	Coeficiente de cultura (Kc)	33
2.6	Graus-dia acumulados - GDA.....	35
2.7	Sensoriamento remoto (SR)	36
2.8	Plataformas aéreas e proximais.....	39
2.9	Índice de vegetação (IV).....	42
2.10	Aprendizado de Máquinas (AM)	43
2.10.1	Random Forest ou Floresta Aleatória (RF)	46
2.10.2	Support Vector Machine ou Máquina de Vetores de Suporte (SVM) .	50
2.10.3	Redes Neurais Artificiais - RNA	56
3	MATERIAL E MÉTODOS	61
3.1	Local e caracterização do experimento.....	61
3.2	Clima e solo	62
3.3	Preparação, instalação e condução do experimento	64
3.4	Manejo da irrigação.....	67
3.4.1	Determinação da capacidade de campo	67
3.4.2	Curva característica de retenção de água no solo	69
3.4.3	Água facilmente disponível no solo (AFD).....	70
3.4.4	Acompanhamento diário da umidade retida no solo	71
3.5	Irrigação	73
3.5.1	Sistema de irrigação e uniformidade de aplicação	74
3.6	Medidas de Graus-Dia Acumulados (GDA)	76
3.7	Evapotranspiração de cultura (ETc)	77
3.8	Evapotranspiração de referência (ETo).....	78
3.9	Medidas do coeficiente de cultura (Kc_BH)	78

3.10	Medidas biofísicas da planta de feijoeiro	79
3.10.1	Índice de Área Foliar (IAF).....	79
3.10.2	Processamento das imagens e obtenção do IAF.....	80
3.10.3	Fração de cobertura Vegetal (FCV)	83
3.10.4	Processamento das imagens e obtenção do FCV	84
3.11	Obtenção das imagens multiespectrais.....	86
3.11.1	Planejamento do voo.....	86
3.11.2	Especificação da câmera Multiespectral Parrot Sequoia.....	87
3.11.3	Obtenção de dados para calibração geométrica e radiométrica	87
3.12	Geração do ortomosaico.....	89
3.13	Processamento das imagens ortomosaicos e obtenção dos IV.....	90
3.14	Medidas de Índices de Vegetações	92
3.15	IAF, FCA, NDVI e SAVI versus graus-dia acumulados (GDA)	92
3.16	Kc_BH versus GDA, IAF, FCV, NDVI e SAVI	93
3.17	Comportamento do IAF, FCV, NDVI, SAVI e Kc_BH em função do DAE e GDA	93
3.18	Produtividade e uso da água	94
3.19	Métricas de avaliação estatística.....	94
3.20	Avaliação de desempenho dos modelos	95
4	RESULTADOS E DISCUSSÃO.....	96
4.1	Monitoramento da água no solo pelo método do balanço hídrico	96
4.2	Graus-dia acumulados (GDA) e fases fenológicas do feijoeiro	99
4.3	Obtenção do índice de área foliares (IAF) por imagem usando métodos de aprendizado de máquina (AM).....	102
4.3.1	Aprendizado de máquinas e métricas em imagens IAF	102
4.4	Comparação entre IAF obtido das imagens e o IAF obtido LI-COR 3100.....	107
4.5	Índice de área foliar IAF versus graus-dia acumulados (GDA).....	108
4.6	Obtenção da fração de cobertura vegetal (FCV) por imagem, usando métodos de aprendizado de máquina (AM)	110
4.6.1	Aprendizado de máquinas e métricas em imagens FCV	110
4.6.2	Fração de cobertura vegetal FCV em função de graus-dia acumulados (GDA).....	115

4.7	Índice de vegetação (NDVI) obtidos de imagens multiespectrais....	116
4.7.1	Relação do NDVI com o GDA	117
4.8	Índice de vegetação (SAVI) obtidos de imagens multiespectrais	119
4.8.1	Relação do SAVI com o GDA.....	120
4.9	Desempenho dos modelos de regressão.....	121
4.9.1	IAF versus GDA	121
4.9.2	FCV versus GDA.....	123
4.9.3	NDVI versus GDA	124
4.9.4	SAVI versus GDA.....	126
4.10	Kc_BH em função dos (DAE) e graus-dia acumulados (GDA)	127
4.11	Relação entre Kc_BH em função do IAF	129
4.12	Relação entre Kc_BH em função do FCV	130
4.13	Relação entre Kc_BH em função do NDVI	131
4.14	Relação entre Kc_BH em função do SAVI.....	132
4.15	Desempenho dos modelos de regressão na modelagem e validação	133
4.15.1	Kc_BH versus Kc_GDA.....	133
4.15.2	Kc_BH versus Kc_IAF	135
4.15.3	Kc_BH versus Kc_FCV	136
4.15.4	Kc_BH versus Kc_NDVI	137
4.15.5	Kc_BH versus Kc_SAVI	139
4.16	Eficiência do uso da água e produtividade de grãos da cultura	140
5	CONCLUSÕES	142
	REFERÊNCIAS.....	143

1 INTRODUÇÃO

O feijão-comum (*Phaseolus vulgaris* L.) é o quarto grão mais produzido no Brasil, com uma área colhida de aproximadamente 2,6 milhões de hectares e uma produtividade média nacional entorno de 1.110 kg ha⁻¹ (IBGE, 2021). É um grão de grande valor nutricional, cultural e social, pois é base alimentar dos brasileiros há décadas, principalmente da camada social de menor renda (Canuto *et al.*, 2019).

Diferentemente dos demais grãos, cerca de 96% da produção nacional de feijão é destinada basicamente para atender o consumo interno (CONAB, 2023). Apesar de sua grande importância, sua produtividade média nacional ainda é baixa, pois a maioria dos plantios é conduzido em condições de sequeiro, isso é, ficando altamente dependente dos regimes de chuvas. A adoção de tecnologia, principalmente irrigação, propicia maior produtividade. No Estado de São Paulo, no município de Paranapanema, a produtividade média é de 3.000 kg ha⁻¹ com uso de irrigação (IBGE, 2022).

Essa produtividade pode ser melhorada com uma adequada estratégia de manejo da irrigação. Para Marouelli *et al.* (2011), o manejo da água de irrigação tem como princípios básicos o momento de irrigar e a quantidade de água a aplicar, favorecendo o aumento da produtividade e diminuindo o desperdício de água.

Uma das estratégias mais eficiente é conhecer a evapotranspiração de cultura (ET_c) desejada, que pode ser encontrada multiplicando o coeficiente de cultura (K_c) pela evapotranspiração de referência (ET_o), descrito por Doorenbos e Kassam (1979). Na ET_c, estão incorporados aspectos climáticos da ET_o, o que a torna instável e seu valor não pode ser transferido entre locais, pois varia muito como o clima; o K_c, por outro lado, está intrinsecamente relacionado com as características de crescimento da planta e seu valor varia desde a semeadura até a colheita. Segundo Albuquerque *et al.* (2002), por variar pouco em função do clima e muito com as características da cultura, isso torna o K_c mais estável, facilitando a transferência seus valores entre localidades.

Conhecer o K_c é essencial para manejar a irrigação, entretanto quantificá-lo durante o ciclo da cultura ainda é um desafio muito grande, pois os métodos diretos de determinação ainda são onerosos, trabalhosos e destrutivos. Por esse motivo,

muitos pesquisadores têm buscado estimá-lo de forma indireta, correlacionando-o com os aspectos biofísicos da cultura, dos Índices de vegetação (IV) e do clima.

Medeiros *et al.* (2000) estimaram os valores de Kc para a cultura do feijão em função dos graus-dia acumulados (GDA) para região Campinas, São Paulo; para a mesma localidade Medeiros *et al.* (2001) estimaram os valores de Kc para a cultura do feijoeiro-comum em função da porcentagem de cobertura vegetal (PCV) e índice de área foliar (IAF). Gontia e Tiwari (2009) estimaram o valor do Kc para a cultura do trigo em função do índice de vegetação por diferença normalizada (*Normalized Difference Vegetation Index* - NDVI) e do índice de vegetação ajustado ao solo (*Soil-adjusted Vegetation Index* - SAVI) para região oeste de Bengala, Índia.

Diante desse contexto, o uso de GDA obtido a partir de dados de estação meteorológica local, assim como IAF, FCV, NDVI e SAVI extraídos de imagens digitais capturadas de sensores proximais e aéreos são capazes de se correlacionar com Kc_BH, possibilitando estimar a necessidade hídrica da cultura do feijoeiro-comum, durante suas fases fenológicas.

O objetivo geral desse trabalho foi estimar os valores de Kc durante as fases fenológicas da cultura do feijoeiro-comum em função: dos GDA, dos IAF e FCV obtidos de imagens digitais de aquisição proximal classificadas com algoritmos de aprendizado de máquina (AM), e dos índices de vegetação NDVI e SAVI obtidos de imagens digitais multiespectrais de aquisição aérea capturadas com uso de veículos aéreo não-tribulado (VANT).

Os objetivos específicos foram:

Criar um modelo de aprendizado de máquina (AM) capaz de classificar corretamente os pixels das imagens digitais obtidas de aquisição proximal durante as fases fenológicas da cultura e assim extrair os aspectos biofísicos de IAF e FCV;

Gerar índices de vegetação NDVI e SAVI a partir de imagens digitais multiespectrais de aquisição aérea capturas com uso de VANT;

Monitorar o comportamento de crescimento da cultura de feijoeiro durante as fases fenológicas em função dos GDA, dos aspectos biofísicos IAF e FCV, e dos NDVI e SAVI;

Gerar modelos matemáticos a partir da relação entre os valores de coeficiente de cultura obtidos pelo método do balanço hídrico Kc_BH e os valores de GDA, durante as fases fenológicas da cultura, na etapa de modelagem;

Gerar modelos matemáticos a partir da relação entre os valores de coeficiente de cultura obtidos pelo método do balanço hídrico Kc_{BH} e os valores de IAF, FCV, NDVI e SAVI, durante as fases fenológicas da cultura, na etapa de modelagem;

Validar os modelos matemáticos gerados na etapa de modelagem.

2 REVISÃO DA LITERATURA

2.1 Cultura do feijoeiro

O feijoeiro-comum é uma leguminosa de grande importância alimentícia no cenário produtivo de grãos brasileiro, perdendo apenas para a soja (*Glycine max* L.). O grão é base alimentar indispensável na alimentação humana por apresentar características nutricionais desejáveis, tais como carboidrato, proteína e sais minerais, conforme descrito na Tabela 1.

Tabela 1 - Composição nutricional do feijão carioca cozido

Componente	Porção 100 g
Energia	71 kcal
Proteína	4,77 g
Lipídeos	0,54 g
Colesterol	0,00 mg
Carboidrato disponível	8,20 g
Fibra	7,06 g
Cálcio	28,7 mg
Ferro	1,39 mg
Potássio	274 mg

Fonte: adaptado de NEPA – Tabela Brasileira de Composição dos Alimentos.

Segundo IBGE (2021), a produtividade média brasileira de feijão em 2021 foi de aproximadamente de 1.110 kg ha⁻¹ e vem crescendo ao longo dos anos. Entretanto, ainda é considerada baixa quando comparada com a produtividade média de São Paulo que é de 2.793 kg ha⁻¹ (IBGE, 2022).

A adoção de tecnologias aumenta sensivelmente a produtividade desse grão, principalmente no que se refere ao manejo da irrigação. No Estado de São Paulo, no município de Paranapanema, a produtividade média é de 3.000 kg ha⁻¹ com uso de irrigação IBGE (2022).

2.2 Uso da irrigação

A irrigação é uma técnica agrícola que tem como princípio básico fornecer água as plantas no momento correto e na quantidade adequada, propiciando condições hídricas favoráveis para que esta possa expressar todo seu potencial produtivo. Segundo Mantovani, Bernardo e Palaretti (2012), a agricultura irrigada possibilita mais de um plantio por ano, otimização no uso da área, bem como geração de emprego; os mesmos autores, assim como ANA (2017), relatam que no Brasil a produtividade em diversas culturas com agricultura irrigada pode ser até 140% superior do que a média nacional.

Devido a essas vantagens, no Brasil, o uso dessa técnica vem aumentando a cada ano. ANA (2017), trabalhando os dados do Censo Agropecuário do IBGE de 1960 a 2006, relatou que a área irrigada vem crescendo a uma taxa média acima de 4% ao ano desde 1960. Na década de 1970 já ultrapassava a marca de 1 milhão de hectares, na década de 1990 ultrapassou os 3 milhões de hectares. Com base nisso, foi feita uma projeção da área irrigada no Brasil em torno de 6,95 milhões de hectares, para o ano de 2015.

Essa estimativa ficou muito próxima da realidade, pois segundo os dados do IBGE (2022), o Brasil possui uma área irrigada de aproximadamente 6,5 milhões de hectares, sendo que a região sudeste detém a maior área irrigada do país com cerca de 2,6 milhões de hectares; destes os sistemas de irrigação localizada por gotejamento, irrigação por aspersor convencional e irrigação por aspersor pivô central são os que têm mais destaque com cerca de 674, 635 e 618 mil hectares, respectivamente, e juntos detêm cerca de 75% de toda área irrigada desta região.

Destes sistemas, ANA (2019) estimou que até 2030 os sistemas por gotejamento e por aspersão pivô central terão tendências de aumento das suas participações na área irrigada total, sendo responsáveis por cerca de 75%; sendo que o primeiro terá participação em torno de 35%, enquanto que o segundo 40%, assumindo o primeiro lugar nacional.

Para que o sistema escolhido tenha ótima eficiência no fornecimento de água requerida pelas culturas é fundamental um manejo da irrigação adequado, pois irá determinar o momento exato de iniciar a aplicação de água e por quanto tempo,

repondo assim o conteúdo de água no solo e atendendo demanda hídrica decorrente da evapotranspiração da cultura.

2.3 Manejo da Irrigação

O manejo da irrigação deve fornecer informações de quando e quanto irrigar, ou seja, o momento exato de iniciar o fornecimento de água e o tempo necessário, de forma que fique armazenada no solo, na zona radicular de absorção, onde a planta possa capturá-la e absorvê-la em quantidade suficiente para prevenir o estresse hídrico e minimizar o desperdício de água (Mantovani; Bernardo; Palaretti, 2012).

Uma das formas de estimar a quantidade de água requerida pelas culturas é pela evapotranspiração de cultura ET_c , na qual tenta-se quantificar a água transferida para a atmosfera pelos processos de evaporação do solo e de transpiração da planta (Libardi, 2012).


Pelo balanço hídrico do solo (BH) é possível estimar a ET_c de forma direta; para isso faz-se necessário quantificar entradas e saídas de volumes de água no solo, em uma profundidade do sistema radicular de uma planta específica (Stone; Silveira, 1995; Libardi, 2012).

Para maior eficiência desse método é necessário conhecer a dinâmica dos componentes de entrada e saída de água do solo. Segundo Marouelli *et al.* (2011), os fluxos de entrada de água são precipitação efetiva (P), irrigação (I) e ascensão capilar (AC), enquanto que os fluxos de saída de água são evapotranspiração de cultura (ET), escoamento superficial (E), drenagem profunda (DP) e drenagem lateral (DL), conforme Figura 1. A partir dos fluxos de entrada e saída de água do sistema, será permitido contabilizar a variação no armazenamento de água no solo (ΔArm). Segundo Resende e Albuquerque (2002) o método pode ser usado com boa precisão para fins de estimativa da ET_c , desde que o acompanhamento do (ΔArm) seja feita diariamente.

Apesar desse método ser relativamente fácil de implantar, necessita de alguns equipamentos e condições ambientais para simplificá-lo. Conforme Libardi (2012), a P e I podem ser quantificadas através do uso de pluviômetro e controle da irrigação, respectivamente. Para Stone e Silveira (1995) e Marouelli *et al.* (2011) os efeitos do E, DP e DL no método podem ser minimizados escolhendo área planas para

implantação da cultura, um controle rigoroso da irrigação para não exceder a quantidade máxima de armazenamento de água no solo e que a intensidade de aplicação de água tanto por P quanto por I sejam menores que a velocidade de infiltração básica do solo (VIB).

Figura 1 – Esquema ilustrativo dos fluxos de entradas e saídas de água do balanço hídrico do solo



Fonte: Copilado de Pereira *et al.* (2002, p.248).

O ΔArm deve ser medido em valores de umidade no solo, até uma profundidade da zona radicular (ZR), em que se concentram 80% do sistema radicular de uma determinada cultura e em um intervalo de tempo, de preferência, em escala diária (Bastos *et al.*, 2005; Marouelli *et al.*, 2011; Frizzone, 2017).

Há vários métodos para determinar o conteúdo de água do solo, sendo dividido em métodos diretos, conhecidos como gravimétricos, e métodos indiretos que podem ser: eletrométricos, reflectometria no domínio do tempo (TDR), bomba de nêutrons e tensiométricos (Mantovani; Bernardo; Palaretti, 2012).

Dentre os métodos tensiométricos, o tensiômetro é o sensor mais utilizado para medição de forma indireta do conteúdo de água no solo. Suas principais vantagens, comparativas a outros indicadores, são: medição direta e em tempo real da tensão de água no solo, sendo a umidade determinada indiretamente; facilidade de instalação, manutenção e interpretação dos dados gerados; custo relativamente baixo; e

facilidade de ser encontrado no mercado (Marouelli *et al.*, 2011; Mantovani; Bernardo; Palaretti, 2012).

2.4 Evapotranspiração

Evapotranspiração (ET) é o termo designado para representar a perda de água para atmosfera, através dos processos da evaporação de uma superfície úmida e da transpiração metabólica das plantas. Este é um elemento de grande importância no balanço hídrico do solo, por isso é muito utilizado em estudos sobre manejo da irrigação (Castañeda; Rao, 2005; Carvalho *et al.*, 2011; Xiang *et al.*, 2020).

Um dos primeiros termos utilizados nesse sentido foi evapotranspiração potencial ET_p, criado por Thornthwaite (1948) e ratificado por Jensen (1968) como sendo o limite máximo de evapotranspiração que ocorre em cultivo bem irrigado, com superfície aerodinâmica áspera, tal como a alfafa com 30-50 cm de altura de crescimento. Nesse mesmo artigo se estabeleceu uma relação entre ET_p e Evapotranspiração de cultivo (ET_c) através do uso de um coeficiente de cultivo (K_c).

Anos depois, Doorenbos e Pruitt (1977) publicaram, pela primeira vez, o termo evapotranspiração de referência ET_o no boletim da Food and Agriculture Organization (FAO) n° 24, em substituição ao termo ET_p, que trouxe condições de existência semelhante ao proposto por Penman (1965) e Jensen (1968) para ET_p. Os autores também estabeleciam uma relação entre ET_o e ET_c através do uso do K_c.

Allen *et al.* (1998) descrevem que a ET_o refere-se à taxa evapotranspirativa de uma cultura hipotética, com altura de aproximadamente 12 cm, resistência superficial de 70 m s⁻¹ e albedo de 0,23, que seria muito semelhante uma superfície gramada, com altura uniforme, bem extensa, cobrindo completamente o solo, com crescimento ativo, completamente sadia e sem restrição hídrica.

A equação de Penman-Monteith é o método padrão recomendado pela Food and Agriculture Organization (FAO) para estimar a ET_o. O método foi reconhecido na publicação de 1998, no boletim n° 56. Na sua validação foi comprovado que este método é capaz de fornecer previsões corretas da ET_o para uma ampla variedade de locais e em diferentes condições climáticas (Allen *et al.*, 1998).

Esse método estima ET_o baseada em aspectos climáticos, por isso depende basicamente de dados de estações meteorológicas para efetuar o seu cálculo. Por

essas características, a ETo deve ser estimada por dados meteorológicos de cada localidade e independe das características de solo e cultura (Allen *et al.*, 1998).

No boletim nº 56 da FAO (Allen *et al.*, 1998) também foi conceituado evapotranspiração de cultura ETc para condição padrão, que ocorre quando uma cultura qualquer se encontra em ótimas condições de expressar todo seu potencial, livre de pragas e de doenças, bem nutrida, com crescimento ativo, sem déficit hídrico e sob determinadas condições específicas climáticas.

Segundo Venâncio *et al.* (2019), a ETc pode ser medida diretamente ou estimada dependendo do objetivo. Quando se deseja medidas mais precisas e confiáveis, recomenda-se o uso das seguintes técnicas: razão de Bowen, covariância de vórtices e lisimetria. Segundo os mesmos autores, o que inviabiliza o uso dessas técnicas é ainda o alto custo financeiro e requerem dedicação tanto na instalação como na coleta dos dados. Uma outra forma de se obter medidas de campo da ETc é usando a técnica descrita no próprio manual FAO nº 56 (Allen *et al.* 1998, p. 169), denominada de balanço hídrico do solo (BH) e também já foi descrita aqui no item manejo da irrigação.

A ETc também pode ser estimada pelo do método indireto, que é dado pela multiplicação da evapotranspiração de referência (ETo) pelo coeficiente de cultura (Kc), descrita por Doorenbos e Kassam (1979). É a técnica mais utilizada em campo, sendo que a ETo representa os aspectos das condições atmosféricas, que variam entre localidades e diferentes condições climáticas; enquanto o Kc contribui com as características intrínsecas de cada cultura e os efeitos médios da evaporação do solo (Albuquerque *et al.*, 2002).

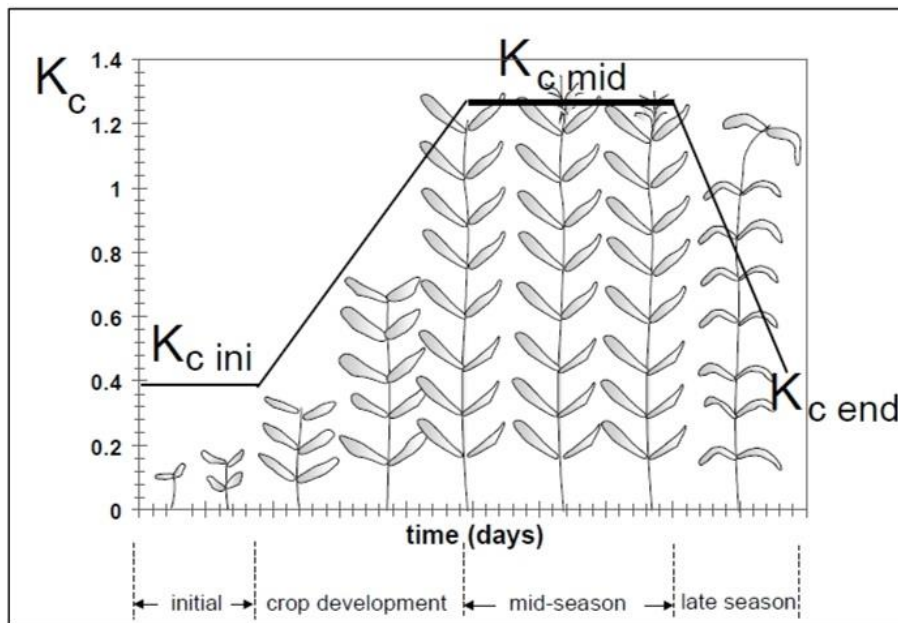
2.5 Coeficiente de cultura (Kc)

O Kc é específico para cada cultura e varia em cada fase de crescimento da planta. Segundo Allen *et al.* (1998) o Kc varia, principalmente, em função das características específicas de cada cultura, fase fenológica e umidade no solo, variando minimamente em função do clima. Albuquerque *et al.* (2002) afirmam que devido às variações nas características da cultura ao longo do seu ciclo de desenvolvimento, o Kc de uma certa cultura varia desde a semeadura até a colheita.

Devido a essa característica de variar pouco em relação ao clima, os valores padrões de K_c podem ser transferidos entre distintas áreas geográficas. Vários trabalhos científicos pelo mundo têm utilizado os valores do K_c padronizados pelo boletim nº 56 da FAO, assim como pelo manual 70 da American Society of Civil Engineers (ASCE), para comparar com os valores de K_c locais estimados (Fernández-Pacheco *et al.*, 2014; González-Esquivia *et al.*, 2017; Reyes-González *et al.*, 2018).

O K_c é um importante parâmetro para estimar a necessidade hídrica da cultura, pois varia com o crescimento e a demanda hídrica da cultura durante suas fases fenológicas (Figura 2).

Figura 2 – Curva generalizada do K_c único



Fonte: Allen *et al.* (1998, p.100).

O coeficiente de cultura pode ser único ou duplo, conforme descrito por Allen *et al.* (1998), em que o K_c duplo refere-se a soma do coeficiente basal (K_{cb}) e do coeficiente de evaporação de água no solo (K_e). Segundo Albuquerque *et al.* (2002), a escolha pelo K_c único ou K_c duplo depende da finalidade; para projeto de irrigação pode-se utilizar apenas o K_c único, já para trabalhos que requerem detalhamento da evaporação da água no solo, recomenda-se o K_c duplo.

2.6 Graus-dia acumulados - GDA

A temperatura do ar é um componente meteorológico que afeta diretamente o crescimento e o desenvolvimento das culturas vegetais, pois acelera os processos bioquímicos e fisiológicos (Pereira *et al.*, 2002). Toda cultura vegetal necessita acumular uma quantidade de energia em (°C) para completar seu ciclo fenológico, conhecido como graus-dia acumulado (GDA) ou constante térmica (CT) ou soma térmica (ST).

Segundo Ometto (1981), graus-dia (GD) é definido como o acúmulo diário de energia, em °C.dia⁻¹, quando a temperatura do ar está acima da condição mínima ou abaixo da condição máxima exigida pela cultura. Segundo Pereira *et al.* (2002) o conceito de GD pressupõe a existência de uma temperatura basal inferior (T_b) e uma temperatura basal superior (T_B), além das quais, a planta não se desenvolve ou o seu desenvolvimento é reduzido.

A partir desses conceitos, muitos modelos matemáticos foram desenvolvidos para quantificar os valores GD, sendo que os mais utilizados foram criados por Arnold (1959) e Ometto (1981). Para implementar os modelos matemáticos são necessários apenas os dados de temperaturas máximas e mínimas, que podem ser obtidas de uma estação meteorológica. Além disso, deve-se considerar se a temperatura do ar está dentro da faixa de T_B e T_b, caso contrário é necessário fazer alguns ajustes nos modelos.

Quantificar os valores de GDA durante as fases fenológicas das culturas possibilita fazer previsões em tempo termal (°C), em substituição ao tempo cronológico (dia). Segundo Pereira *et al.* (2002) acompanhar o desenvolvimento da cultura em tempo termal é mais útil do que em tempo cronológico, pois apresenta um índice estável e geralmente válido para qualquer região.

Muitas pesquisas foram desenvolvidas com intuito de determinar as T_B e T_b, além de avaliar o desempenho dos modelos matemáticos de GDA para a cultura do feijoeiro. Wutke *et al.* (2000) determinaram a T_b e GDA necessários para três cultivares de feijão carioca do Instituto Agrônomo de Campinas (IAC), em 14 municípios de São Paulo e em duas épocas da água e da seca, sendo que os resultados indicaram que a T_b variou de 6 °C a 10 °C e que os GDA variaram de 436 a 810 unidades térmicas. Medeiros *et al.* (2000), avaliando os GDA durante o ciclo

fenológico da cultivar de feijão carioca 80-SH para as condições do IAC, concluíram que os GDA foi de 1.155 °C.

Além disso, o trabalho desenvolvido por Medeiros *et al.* (2000) buscou estabelecer relações matemáticas entre IAF, FCV e Kc em função dos GDA, o que possibilitou o ajuste de modelos polinomiais com alto grau de significância.

2.7 Sensoriamento remoto (SR)

O sensoriamento remoto (SR) começou de fato no ano de 1960, que ficou conhecido como a década da corrida espacial, e isso só foi possível devido ao desenvolvimento de foguetes que pudessem colocar satélites artificiais meteorológicos no espaço, sendo que o primeiro foi o TIROS-1 (*Television Infrared Operational Satellite*), lançado neste mesmo ano pelo Estados Unidos (Meneses, 2012).

Em 1972, iniciou a era do sensoriamento remoto moderno com o lançamento do primeiro satélite da série do programa Landsat (*Land Remote Sensing Satellite*), que trazia várias novidades como o sensor imageador multiespectral que possibilitava a obtenção simultânea de quatro faixas do espectro do visível e do infravermelho próximo, assim como imagens no termal. Permitia ainda uma resolução espacial de 76 metros e uma resolução temporal de 18 dias (Meneses, 2012).

Em 2013 foi lançado ao espaço a última versão da série Landsat 8, com mais tecnologia e muitas vantagens, tais como: sensor com nove bandas espectrais com resolução que vai do comprimento de ondas de 0,433 a 1,660 μm , resolução espacial de 30 m, resolução temporal de 16 dias e resolução radiométrica de 12 bits; possibilitando obter imagens mais nítidas e reais (Florenzano, 2011).

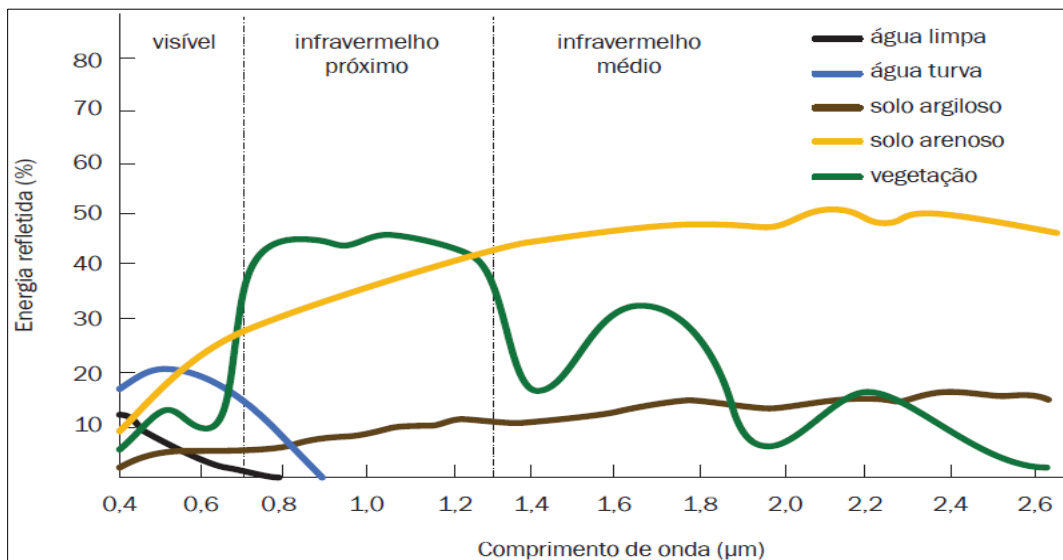
Segundo Meneses (2012), a definição mais científica que se pode dar ao sensoriamento remoto é: uma ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres.

Essas imagens após processadas têm inúmeras aplicações tais como: mapeamentos temáticos nas áreas dos recursos naturais, agricultura, silvicultura, pedologia, queimadas, proteção e conservação da natureza, monitoramento ambiental, poluição, uso da terra, cartografia, classificação de rochas, áreas irrigadas, planejamento urbano e até indicadores sociais (Florenzano, 2011).

O sensoriamento remoto (SR) apresenta grande potencial de uso na agricultura correlacionando bandas espectrais refletidas com o estado biofísico da vegetação, podendo estimar área plantada, produção agrícola e vigor vegetativo.

Os satélites estão equipados com sensores imageadores multiespectrais que observam e coletam dados da superfície terrestre. Eles operam em diferentes faixas do espectro eletromagnético, coletando assim energia refletida pelos objetos na superfície terrestre na forma multiespectral. Toda matéria na superfície terrestre reflete, absorve, transmite e/ou emite radiação eletromagnética (REM) de forma específica (Figura 3), portanto cada alvo reflete em distinto comprimento de onda eletromagnético, que vai do raio gama, passando pelo raio-X, ultravioleta, Luz visível, infravermelho, e indo até as ondas de rádios (Formaggio; Sanches, 2017).

Figura 3 - Comportamento espectral de objetos na superfície terrestre



Fonte: Florenzano (2011).


Entender esses comportamentos é fundamental no momento de extrair e interpretar as imagens geradas pelo SR, pois cada um tem uma assinatura espectral. Pode-se observar na Figura 3 que cada um dos objetos na superfície do solo tem uma certa reflectância a um determinado comprimento de onda, tanto na luz visível quanto na luz infravermelha. Tanto a água turva quanto a limpa tem pouca reflectância a luz visível e quase nenhuma as luzes infravermelhas; a vegetação absorve comprimento de onda nas faixas espectrais do visível, alcançando seu pico máximo nas bandas espectrais azul e vermelha, refletindo a maior parte da luz verde, já nas faixas

infravermelhas é altamente refletida; o solo arenoso tem a tendência de refletir mais, tanto nas faixas do visível como do infravermelho em relação ao solo argiloso (Pereira; Silva; Pamboukian, 2016).

Os vegetais, de forma geral, absorvem comprimentos de onda nas faixas espectrais da luz azul (400-500 nm) e da luz vermelha (600-700 nm), e refletem boa parte da luz verde na faixa de luz de (500-600 nm), na faixa infravermelho próximo é altamente refletida. Pode-se observar (Figura 4) ainda que, no comprimento de onda acima dos 1300 nm (infravermelho médio), o conteúdo de água na folha influencia nessa interação, principalmente na absorção dos comprimentos de ondas na faixa de 1450 e 1950 nm, podendo ser uma faixa espectral que serve como indicativo de estresse hídrico na folha.

Além disso, há também uma faixa espectral entre o vermelho e o infravermelho próximo, conhecida como borda vermelha (*red-edge*) que também é muito utilizada como indicativo de estresse hídrico, pois quando uma planta está bem hidratada, a faixa espectral logo acima de 700 nm é fortemente refletida, gerando uma curva vertical. Quando a planta está sob estresse hídrico ocorre um deslocamento em direção aos menores comprimentos de onda, então essa curva de transição (*red-edge*) é menos acentuada, conforme Figura 4 (Jafari; Hedley; Fourie, 2016; Shiratsuchi *et al.*, 2014).

Figura 4 - Comportamento espectral de uma folha com e sem estresse hídrico



Fonte: Trindade, Facco e Pereira Filho (2019).

Na agricultura, os dados de reflectância e absorvância podem ser relacionados às características das plantas tais como: índice de área foliar, biomassa, fotossíntese e estresse hídrico, avaliados pelas combinações matemáticas de diferentes bandas espectrais. Essas medidas utilizam, principalmente, as faixas do visível, infravermelho próximo (*Near-infrared - NIR*) e borda vermelha (*red-edge*), sendo denominadas de índices de vegetação (IV) (Brandão; Zonta; Shiratsuchi, 2018).

2.8 Plataformas aéreas e proximais

A plataforma que transporta os sensores define o nível de aquisição dos dados. Segundo Moreira (2001) os sistemas sensores são responsáveis pela aquisição das medidas espectrais dos alvos na superfície terrestre e podem ser feitos em três níveis: orbital, suborbital e terrestre. Também classificados como orbital, aérea e proximal segundo Formaggio e Sanches (2017).

No nível orbital, empregam-se satélites; no nível aéreo, geralmente, utilizam-se aeronaves, helicóptero e veículos aéreo não tripulado (VANT); no nível proximal podem ser fixados em torres, barcos e boias (Moreira, 2001).

Além disso, os sensores podem ser classificados como imageadores e não imageadores. Segundo Formaggio e Sanches (2017), os imageadores fornecem como produto uma imagem da área observada, sendo um exemplo a câmera fotográfica; por sua vez, os não imageadores fornecem os dados em formato numérico ou na forma de gráficos, sendo denominados de radiômetros ou espectrorradiômetros.

A plataforma aérea mais utilizada para transportar sensores, principalmente imageadores multiespectrais, é o VANT, também conhecido popularmente como drone. O uso de VANT na agricultura vem crescendo, favorecido pela oferta de tecnologias, redução dos custos e do tamanho dos equipamentos (Jorge; Inamasu, 2014).

O uso de imagem obtidas por sensor acoplado ao VANT tem sido preferido nas pesquisas de campo em relação as imagens obtidas por sensores embarcados em plataforma orbital, devido as baixas resoluções, espacial de 30 m e temporal de 16 dias, que causam algumas desvantagens na aplicação de campo. Muitas pesquisas apontam o VANT como uma ótima ferramenta para superar essa dificuldade, pois podem obter resolução espacial menor que 30 cm e alta frequência temporal (até

diariamente), além de não sofrer ruído pela obstrução das nuvens (Park *et al.*, 2017; Zhang *et al.*, 2019).

Um VANT é composto de uma estação de controle em solo, no qual é possível planejar a missão do voo e acompanhar virtualmente o descolamento durante a missão; possui um sistema de posicionamento global (*Global Positioning System* - GPS) integrado a uma unidade de navegação inercial, que garante melhor estabilidade ao equipamento, melhorando assim a precisão da posição; possui ainda um piloto automático que recebe o controle da estação em solo através da telemetria de controle do sistema que atua de forma autônoma (Figura 5) (Jorge; Inamasu, 2014).

Figura 5 - Componentes básicos de um VANT



Segundo Jorge e Inamasu (2014), para obter imagens de sensor acoplado ao VANT, é necessário cumprir algumas etapas, tais como: planejamento do voo, voo com sobreposição, imagens georreferenciadas, processamento das imagens, geração de mosaico, análise em uma ferramenta GIS e geração dos produtos. A maior dificuldade encontra-se no processamento das imagens, pois além de ter mão de obra especializada, a licença do software tem alto custo financeiro (Agisoft) e necessita de computadores com grande capacidade de processamento.


Os sensores proximais não entram em contato direto com os objetos de estudo, sendo na sua maioria de natureza óptica, uma vez que os fótons do espectro visível ou infravermelho incidem no objeto, que são direcionados para o sensor, que geralmente é tipo CCD (*charge-coupled device*) (Formaggio; Sanches, 2017).

Segundo Ferreira *et al.* (2001), uma imagem pode ser compreendida como uma matriz de linhas e colunas e em cada célula é representada por um pixel, que possui um número digital (*Digital Number - DN*), representando a intensidade média de energia eletromagnética refletida pelo alvo na superfície imageada.

Segundo Formaggio e Sanches (2017), o sensoriamento remoto proximal destina-se a aplicações locais, cobrindo áreas pequenas e específicas; por sua vez, o sensoriamento remoto feito com plataforma aérea, utilizando VANT, visa áreas extensas.

Ao contrário da imagem obtida por sensor aéreo, as imagens obtidas por sensores proximais são processadas em softwares livres, tais como: QGIS, SPRING, ENVI e outros. Pode-se usar também ambiente de programação nas diversas linguagens, tais como: Python, Java, Matlab, R e outros. Até mesmo aprendizado de máquina (AM) pode ser utilizado para classificar e quantificar os objetos (Figura 6) contido nas imagens (Ferreira *et al.* 2001).

Figura 6 - Imagem proximal classificada usando algoritmo de AM



A partir desses conceitos, muito trabalhos foram desenvolvidos com intuito, principalmente, de extrair características biofísicas da cultura. Godoy *et al.* (2007) utilizaram o software Corel Photo Paint para processar as imagens digitais com folhas de laranja “Pêra” e assim obter o índice de área foliar (IAF), que foi comparado com os valores de IAF obtidos pelo método padrão LI-COR-3100, apresentando alta correlação. Nesse mesmo sentido, Rico-Garcia *et al.* (2009) utilizaram os softwares Matlab 6.0.0.88 e AutoCad 2007 no processamento de imagens digitais com folhas de tomate visando a obtenção do IAF. Os valores estimados pelos softwares foram comparados com os obtidos pelo LI-COR-3100, sendo que ambos tiveram alta correlação.

Córcoles *et al.* (2013) utilizaram aprendizado de máquina para processar as imagens obtidas com sensor transportado por VANT e assim extrair e quantificar porcentagem de cobertura vegetal (FCV) na cultura da cebola; os valores de FCV obtidos foram relacionados com valores obtidos do IAF pela análise de regressão linear e o resultado mostrou alto coeficiente de determinação (R^2) de 0,84. Os trabalhos realizados reforçam que o uso de imagem na agricultura pode ser uma ótima ferramenta para extrair características biofísicas das culturas presentes nos alvos, na Figura 6 observa-se a extração da FCV usando AM.

2.9 Índice de vegetação (IV)

Cada objeto na superfície tem uma resposta específica a determinada banda espectral, denominada de assinatura espectral. Uma vegetação saudável, com crescimento ativo e sem restrição hídrica reflete pouco na faixa do espectro do visível, devido aos pigmentos da fotossíntese presente nas folhas, e reflete muito na faixa do infravermelho próximo, devido as estruturas celulares. Sabendo desse comportamento, ao longo dos anos, vários índices de vegetação (IV) foram desenvolvidos para tentar descrever essas relações entre os aspectos biofísicos das culturas e o comportamento das bandas espectrais, principalmente usando os espectros na faixa do visível e do infravermelho próximo (Shiratsuchi *et al.*, 2014).

Um dos mais importante IV foi criado por Tucker (1979), o qual propôs uma relação normalizada entre as bandas do espectro do vermelho e do infravermelho próximo, sendo conhecido como índice de vegetação por diferença normaliza (NDVI).

Os valores de NDVI podem variar de -1 a 1, sendo que quanto mais esse valor se aproxima de 1 indica vegetação fotossinteticamente ativa, quando tendendo a 0 'zero' significa solo exposto e decrescendo a -1 indica uma superfície bastante úmida. Inúmeros trabalhos têm relacionado o NDVI com diversos aspectos biofísicos da vegetação, tais como: índice de área foliar (IAF), fração de cobertura vegetal (FCV), estimativa da radiação fotossinteticamente ativa e sequestro de carbono (Meneses; Almeida, 2012).

Segundo Shiratsuchi *et al.* (2014), apesar de grande aceitação do NDVI, ele tem se mostrado muito susceptível a influência de solo exposto, interferindo diretamente em seus valores. Na tentativa de contornar essa dificuldade, Huete (1988) propôs um

novo índice com intuito de minimizar os efeitos do solo no espectro de radiação, denominado de índice de vegetação ajustado ao solo (SAVI).

Segundo Meneses e Almeida (2012), o SAVI segue os mesmos princípios que regem o NDVI, inclusive o mesmo modelo matemático, sendo que a principal diferença é a incorporação da constante (L), que pode variar de 0 a 1, dependendo do grau de maior ou menor cobertura do solo.

Na literatura há vários trabalhos utilizando esses dois índices. Gameiro *et al.* (2017) avaliaram a cobertura vegetal na sub-bacia hidrográfica do baixo Jaguaribe, no Estado do Ceará, usando os índices de vegetação NDVI e SAVI obtidos de imagens disponibilizada do Landsat 8, e os resultados mostraram que os índices são adequados para classificar a cobertura vegetal.

Calera *et al.* (2001) estabeleceram relação entre a fração de cobertura vegetal (FCV) da cevada, obtida com processamento de imagem com classificador supervisionado de máxima verossimilhança, e os valores de NDVI obtidos com radiômetro ativo de alta resolução GER-3700; o resultado foi altamente significativa com coeficiente de determinação (R^2) de 0,96.

Sampaio *et al.* (2021) avaliaram o potencial do NDVI, extraído de imagem obtida por sensor aéreo embarcado em VANT, em diagnosticar a atividade fotossintética das culturas da soja e do milho, porém os resultados indicaram que o NDVI pouco responde a mudança de fase fenológica em estágio mais avançados, devido a saturação dos seus valores com o aumento da biomassa. Safanelli *et al.* (2014) constataram que o índice SAVI é capaz de detectar a variabilidade espacial e temporal da cultura da soja em todos os estádios fenológicos, devido ao uso da constante adicional “L”.

2.10 Aprendizado de Máquinas (AM)

Com a evolução dos computadores, cada vez mais o aprendizado de máquina vem se tornando imprescindível em todos os ramos da sociedade. Na agricultura não é diferente, pois os dados gerados em campo necessitam ser processados em tempo real e com precisão. Várias pesquisas já vêm usando esse recurso computacional para processar os dados coletados em campo, principalmente imagens, com grande êxito. Shu *et al.* (2021) classificaram índice de área foliar de pepino (IAF) com rede neural artificial (RNA); Yang *et al.* (2020) classificaram folhas de diversas espécies de

plantas com diversos fundos; Safre *et al.* (2021) estimaram umidade do solo usando três métodos de aprendizado de máquina.

Segundo Mitchell (1997), aprendizado de máquina é definido como a capacidade de melhorar o desempenho na realização de alguma tarefa por meio de experiência. Deduziu ainda que, um programa de computador é dito aprendido com experiência 'E' respeitando alguma classe de tarefa 'T' e medido por uma performance 'P', se sua performance nas tarefas em 'T', conforme medido por 'P', melhora com a experiência 'E'.

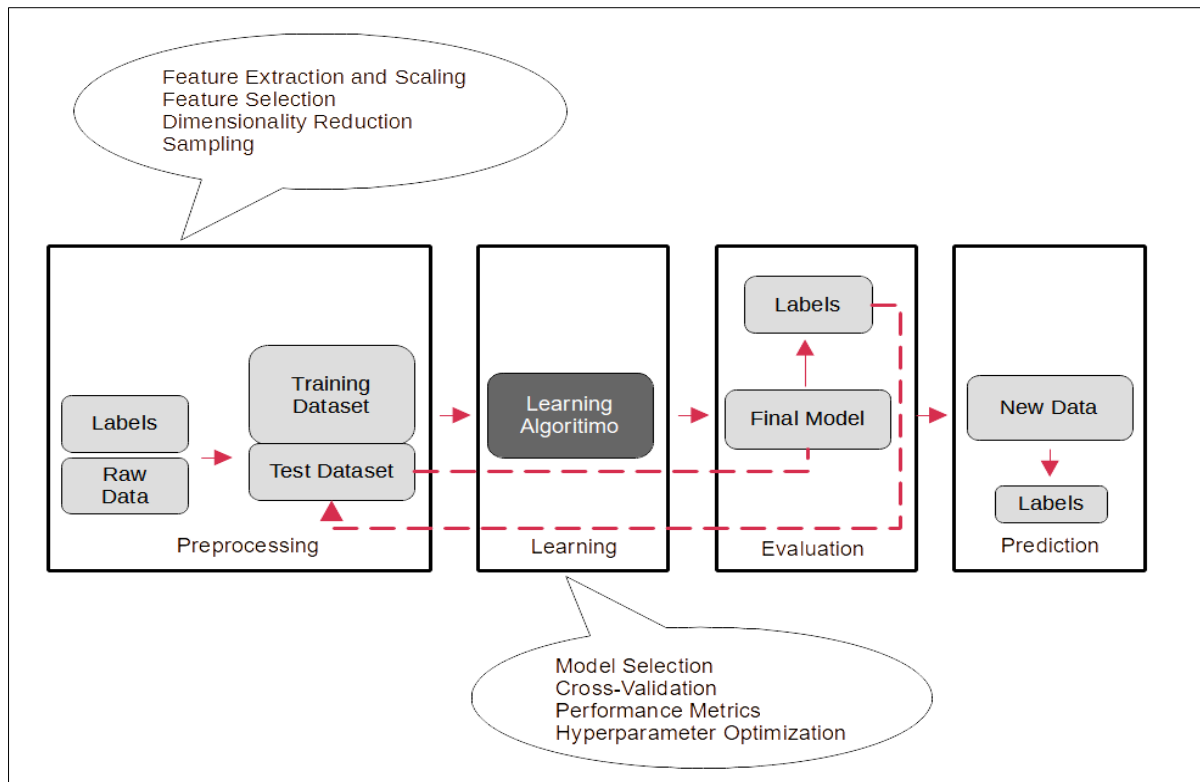
Para Raschka e Mirjalili (2019), 'T' são as tarefas de classificação, por exemplo, a imagem da folha ou solo; 'P' são as medidas de performance, por exemplo, porcentagem de classificações corretas, 'acurácia'; 'E' são as experiências de treinamento, por exemplo, o conjunto de dados de entradas e saídas, divididos entre atributos e rótulos.

Aprendizado de máquina (AM) é um subconjunto de inteligência artificial (IA), mas diferentemente da IA não precisa necessariamente de um programador para execução dos processos. O aprendizado ocorre por experiência, em que é fornecido um conjunto de dados de treinamento a algum algoritmo lógico que utiliza modelos matemáticos e estatísticos para treiná-los. Após isso, é avaliado se o modelo gerado no treinamento consegue classificar corretamente (Raschka; Mirjalili, 2019; Carvalho; Carvalho, 2022).

No AM existem vários métodos para treinar os conjuntos de dados e são divididos em métodos supervisionados e não-supervisionados. Os métodos supervisionados são os mais utilizados em trabalhos acadêmicos e profissionais em agricultura de precisão, conforme trabalho de revisão publicado por Benos *et al.* (2021).

Nos métodos supervisionados, os conjuntos de dados de atributos são fornecidos, junto com suas respectivas classes, aos algoritmos de aprendizado. Neste caso, o algoritmo de treinamento já sabe o resultado esperado, conforme pode ser visto na Figura 7. Neste conceito, um conjunto de dados é dividido em dois subconjuntos: treinamento e teste. O primeiro é utilizado como entrada no algoritmo de aprendizado e após aprendido é gerado um modelo, este por sua vez tem que ser testado com dados reais, ou seja, dados inéditos; então o subconjunto teste é usado para verificar o grau de efetividade de acerto do modelo.

Figura 7 - Fluxo de trabalho de um algoritmo de AM supervisionado



Fonte: adaptado de Raschka e Mirjalili (2019)

Espera-se dos modelos gerados a partir de métodos de AM que sejam robustos para lidar com ruídos nos dados tais como *'outliers'*, minimizando seus efeitos e que sejam generalistas para classificar corretamente novos dados. Quando o modelo é especializado demais para acertar os dados de treinamento e errar demais os dados de teste, ocorre um super-ajustamento conhecido como *'overfitting'*; já quando ocorrem baixas taxas de acerto, tanto no treinamento quanto no teste, ocorre um sub-ajustamento conhecido como *'underfitting'* (Izbicki; Santos, 2020).

Existem vários métodos de AM que foram criados para resolver determinadas tarefas, cada uma com um conjunto de regras lógicas, matemáticas e estatísticas, sendo que os mais utilizados em trabalhos com agricultura de precisão, nessa ordem, são: Redes Neurais Artificiais (RNAs), *Ensemble Learning*, Máquina de vetores de suporte (*Support Vector Machine - SVM*), Árvore de decisão (*Decision Trees - DT*), *Regression*, *Instance Based Models*, *Dimensionality Reduction*, *Bayesian Models* e *Clustering*, conforme levantamento realizado por Benos *et al.* (2021).

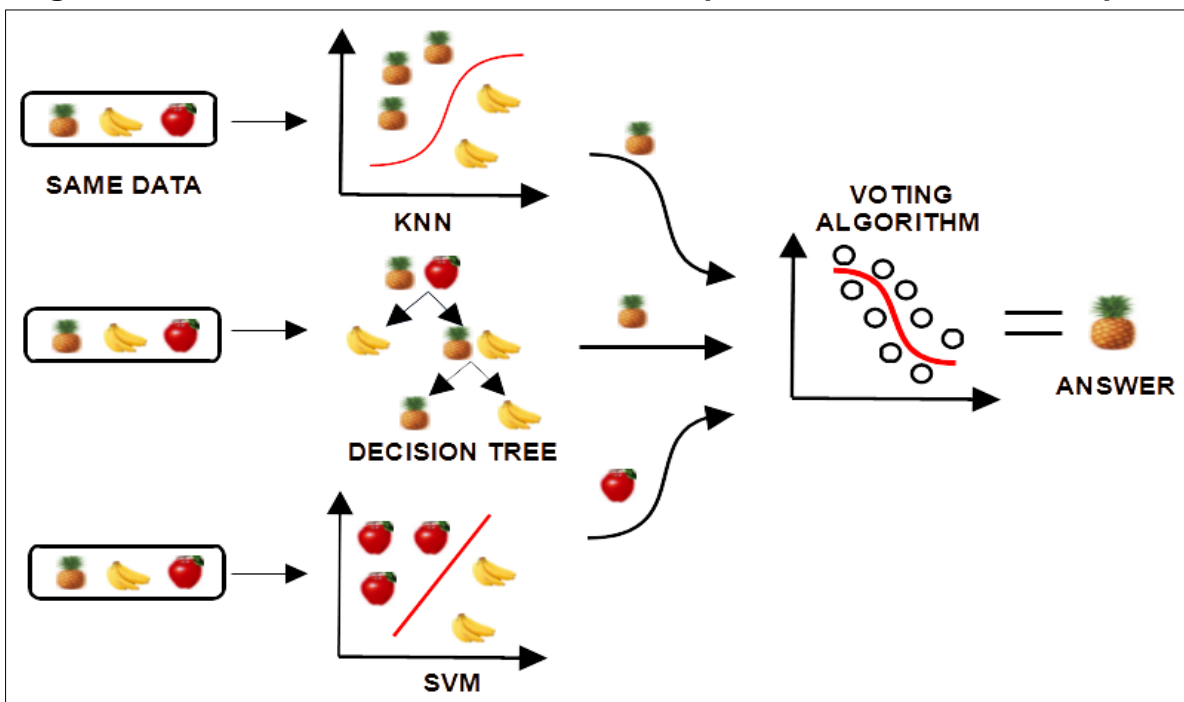
Apesar de haver muitos métodos de AM, nestes trabalhos foram escolhidos três modelos: Floresta Aleatória (*Random Forest - RF*), Máquina de Vetor de Suporte

(*Support Vector Machine* - SVM) e Regressão Logística Multiclasse (*Multiclass Logistic Regression* - LR). Os motivos das escolhas foram que os métodos apresentam capacidade de classificar atributos não lineares, além de serem algoritmos muito utilizados para classificação e segmentação de imagens (Neetu; Ray, 2019; Safre *et al.* 2021).

2.10.1 Random Forest ou Floresta Aleatória (RF)

O Comitê de Máquinas (*Ensemble Methods*) compreende um conjunto de algoritmos de AM, em que os principais métodos são *Majority Voting*, *Bagging*, *Boosting* e *Random Forests*. A principal característica do comitê de Máquinas é usar diferentes métodos AM para classificar um conjunto de dados; cada modelo elegerá uma classe em sua saída, que será submetida a um algoritmo de Voting, o qual classificará a classe final pelo voto majoritário, conforme Figura 8 (Raschka; Mirjalili, 2019).

Figura 8 - Fluxo de trabalho de um método hipotético de Comitê de Máquina

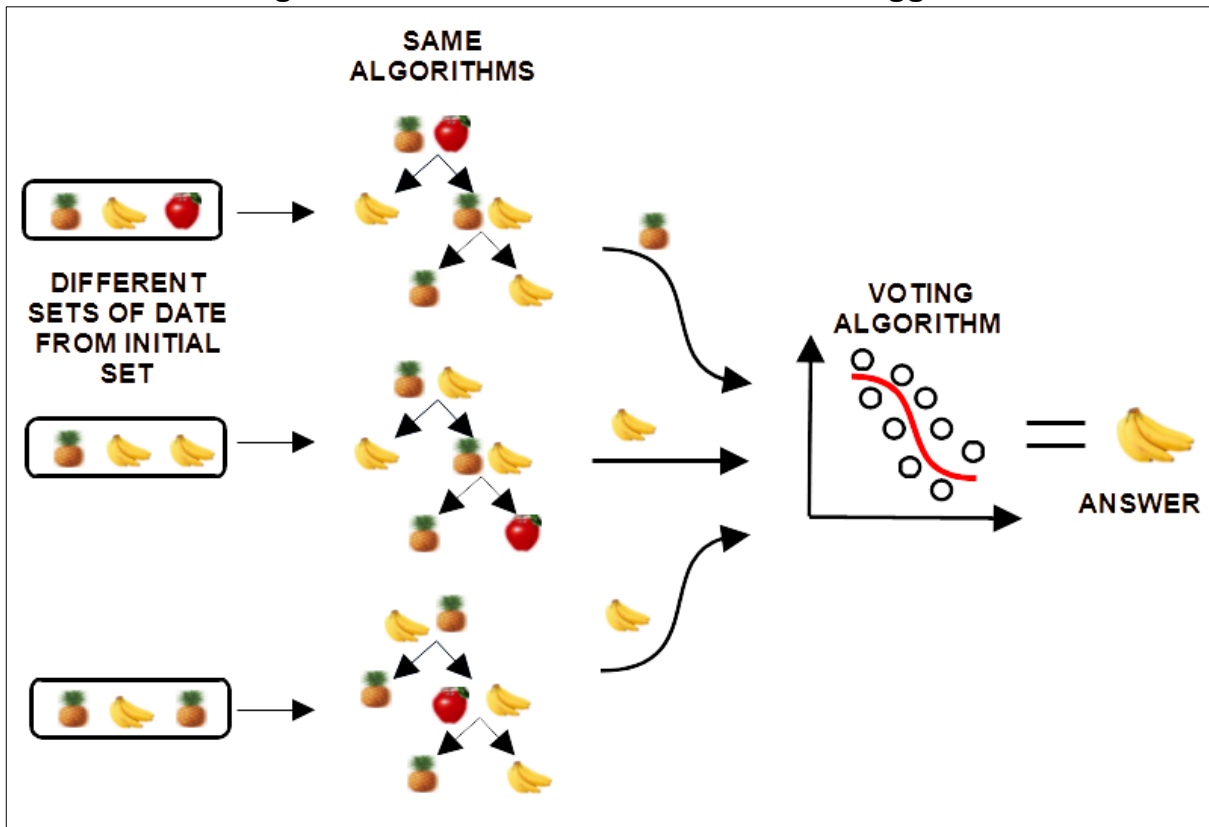


Fonte: adaptado de Raschka e Mirjalili (2019)

Outro método muito utilizado dentro da família Comitê de Máquinas é o *Bagging*, criada por Breiman (1996), que utiliza a técnica de *Bootstrap* para gerar erros decorrelacionados, gerando diversidades de características no conjunto de dados de

entrada, alterando os conjuntos de treinamentos, conforme Figura 9. Pode-se observar que os dados de entradas são diferentes pelo uso da técnica de *Bootstrap*, mas os algoritmos são os mesmos, neste caso *Decision Trees* (DT). Vale ainda ressaltar que essa estratégia garante uma amostragem aleatória com reposição, isto é, os dados de entradas são diferentes, mas apresentam os mesmos tamanhos.

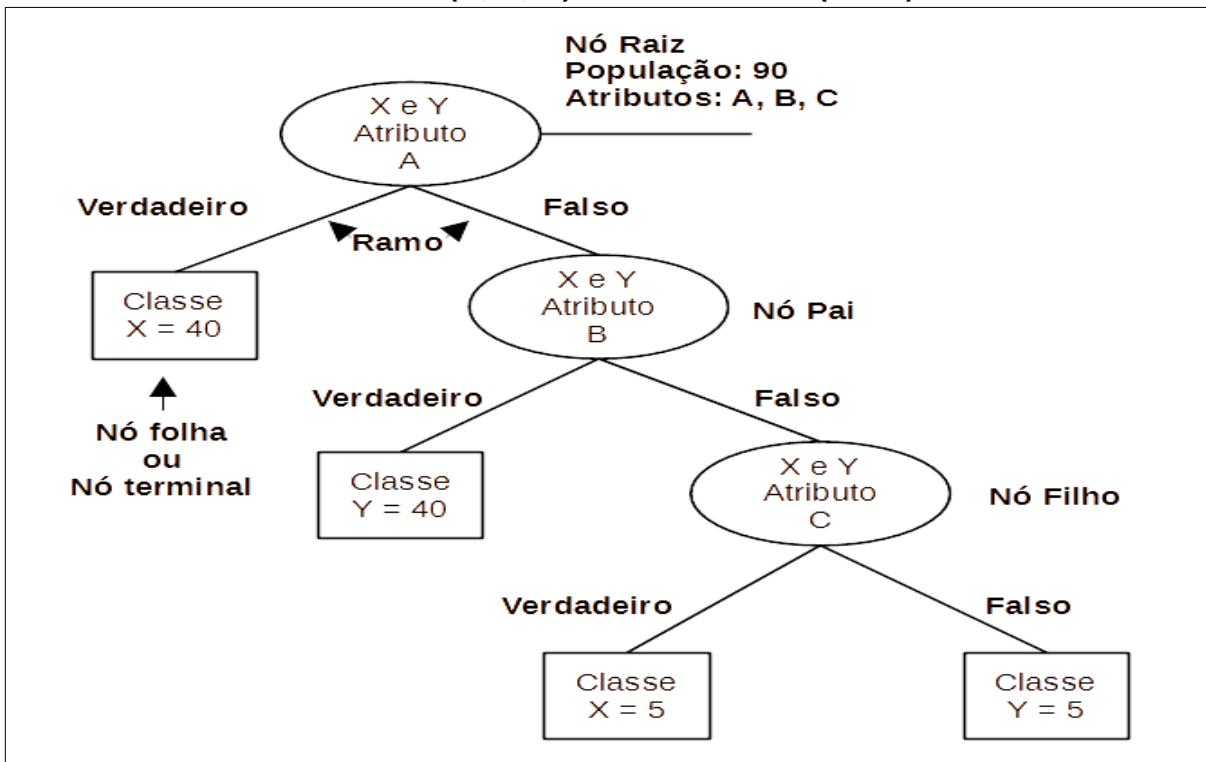
Figura 9 - Fluxo de trabalho do método Bagging



Fonte: adaptado de Raschka e Mirjalili (2019)

Árvores de Decisão (DT) são algoritmos de aprendizado baseados em técnicas iterativas, recursivas e dividindo para conquistar, seguindo um conjunto de regras estruturadas hierarquicamente em perguntas e respostas, conforme Figura 10.

Figura 10 - Estrutura hierárquica genérica de uma árvore de decisão com três atributos (A, B, C) e duas classes (X e Y)



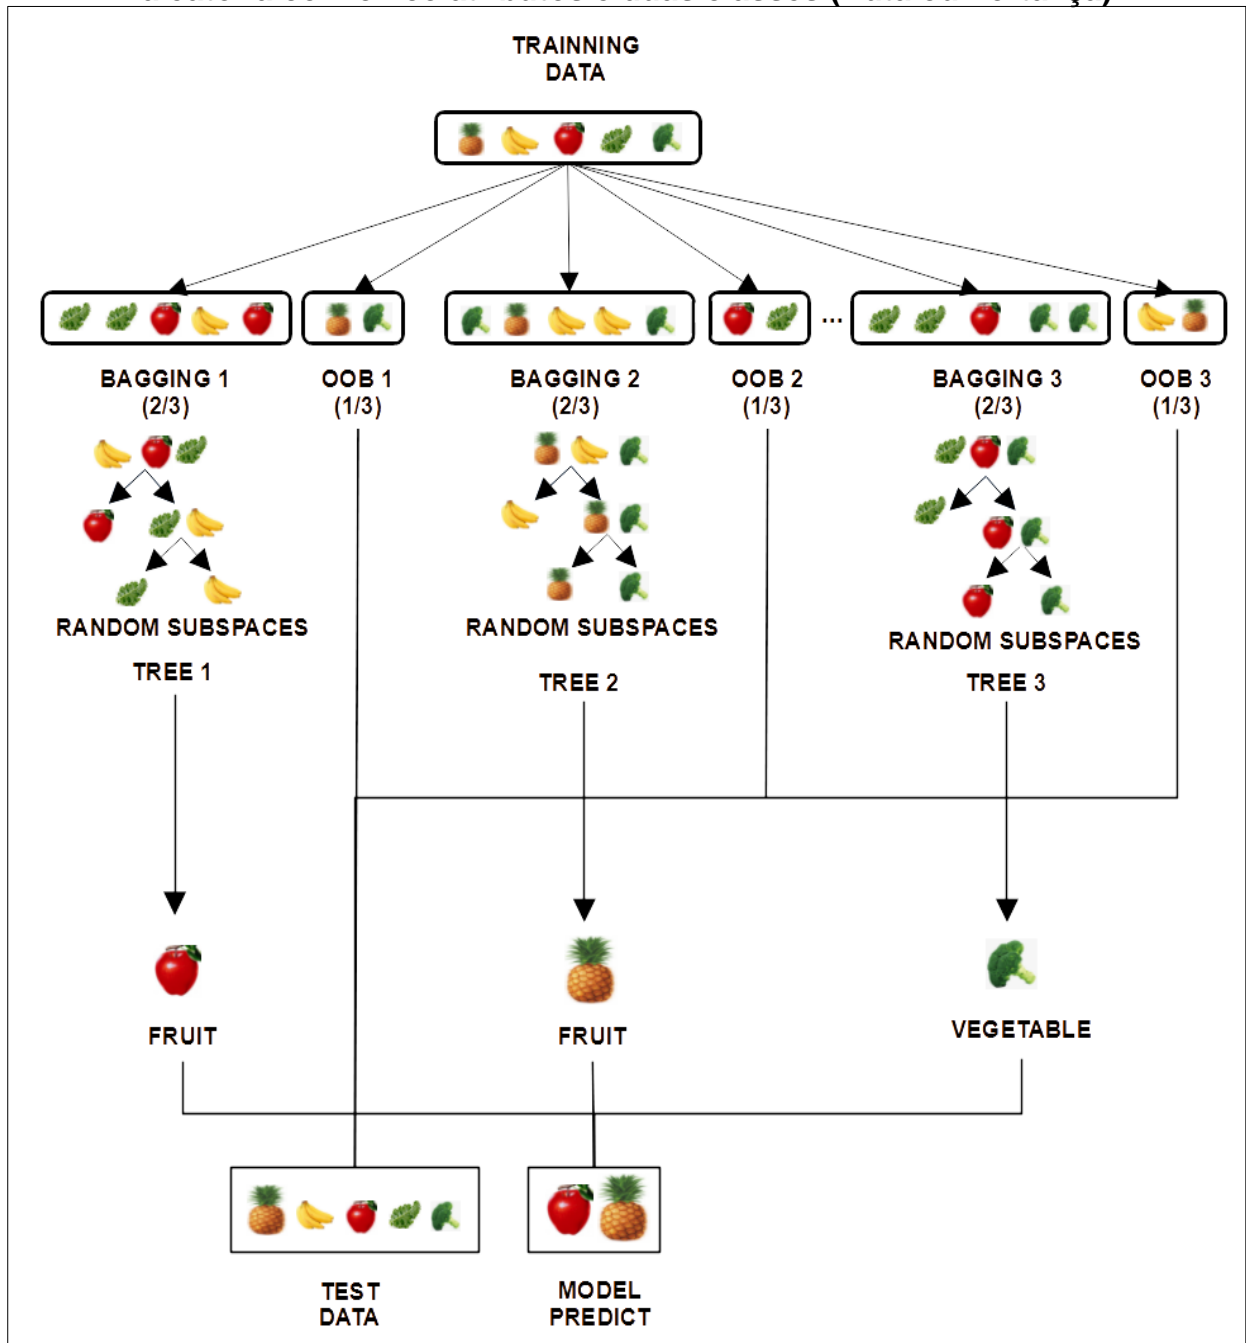
Fonte: adaptado de Raschka e Mirjalili (2019).

Cada DT começa com um nó raiz ou nó principal, sendo que em cada nó é feito um teste de atributo, chamado de nó de decisão (elipse na Figura 10) e cada ramo leva a uma resposta desse teste, podendo ser um nó folha, que representa uma classe (retângulo na Figura 10) ou um nó pai que gera outro teste. Esse processo se repete até todas as ramificações alcançarem nós terminais.

O método de AM Floresta Aleatória (RF) foi criado por Breiman (2001). Este método é praticamente a combinação de dois métodos: método Bagging com o método de Árvore de Decisão (DT). Na Figura 11, pode-se observar que o conjunto de dados de entrada é o mesmo para todos (*TRAINNING DATA* - TD). Nesse é aplicado o método de *Bagging* com a técnica de *bootstrap* gerando 'n' subconjuntos de entradas, com 2/3 do total de dados TD; os outros 1/3 do total de dados TD são usados para formar os dados de validação '*out-of-bag*' (OOB), que servem para encontrar a taxa de erro do modelo. Em cada 'n' subconjunto é criado um algoritmo de DT para classificar os atributos dos dados de treinamento com suas respectivas classes; em cada nó de cada árvore é aplicada uma técnica denominada de *random subspaces*, que subtrai 1/3 dos dados de cada subconjunto, criando uma maior

variabilidade de características. As melhores árvores são escolhidas por critérios de votação majoritária ou por médias, e são usadas como modelos preditores.

Figura 11 - Fluxo de trabalho, meramente ilustrativa, de um método Floresta aleatória com cinco atributos e duas classes (fruta ou hortaliça)



Fonte: adaptado de Raschka e Mirjalili (2019).


2.10.2 Support Vector Machine ou Máquina de Vetores de Suporte (SVM)

SVM é mais um método de aprendizado de máquinas, proposto por Cortes e Vapnik (1995). É muito utilizado para fazer regressão ou classificação, apresentando características desejáveis, tais como: grande capacidade de generalização para dados inéditos, robustez diante de dados de grandes dimensões e característica de convexidade do problema de otimização possuindo um único mínimo global (Lorena; Carvalho, 2007).

O princípio básico de um SVM é encontrar um plano (reta linear) que separe perfeitamente duas classes (hiperplano) com a maior margem possível, para isso, deve-se considerar que o problema é linear e possui duas variáveis regressoras, x_1 e x_2 , sendo uma $+1$ e outra -1 , conforme Figura 12, e considerando a função linear para o hiperplano, expresso pela Equação 1.

$$f(x) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k = 0 \quad (1)$$

Figura 12 - Hiperplano perfeitamente separável para duas variáveis regressoras



Segundo Izbicki e Santos (2020), o classificador $g(x)$ dado pelo SVM tem a seguinte forma, Equações 2 e 3:

$$\text{Se } f(x) > 0, g(x) = +1 \quad (2)$$

$$\text{Se } f(x) < 0, g(x) = -1 \quad (3)$$

Podendo ser resumido na Equação 4, segundo Raschka e Mirjalili (2019).

$$y_i(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k) > 0, \forall i = 1, \dots, k \quad (4)$$

Segundo Lorena e Carvalho (2007), o SVM busca por um hiperplano que maximiza a margem, buscando sempre as distâncias para os pontos observados que estão mais próximos ao hiperplano, conforme Figura 13. Os pontos utilizados para encontrar a margem ótima são chamados de vetores de suporte.

Pode-se observar na Figura 13 que as margens ótimas podem ser alcançadas usando a função Max, descrita na Equação 5.


$$\text{Max} = \frac{2}{\|M\|}, \text{ podendo ser reescrita pela função } \text{Min} = \frac{1}{2} \|M\|^2 \text{ e } \text{Min} = \frac{1}{2} b^T b \quad (5)$$

Sujeita as restrições na Equação 6 (Lorena; Carvalho, 2007; Raschcka; Mirjalili, 2019).

$$y_i(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k) \geq 1, \forall i = 1, \dots, k \quad (6)$$

As restrições são impostas para assegurar que não haja dados de treinamento entre as margens de separação das classes. Agora, como a função objetivo é de minimizar, os pontos que satisfazem as restrições formam um conjunto convexo e, portanto, possui um único mínimo global. Com isso é possível modelar um classificador de máxima margem (Lorena; Carvalho, 2007).

Figura 13 - Hiperplano perfeitamente separável para duas variáveis regressoras com os vetores de suporte




Segundo Izbicki e Santos (2020), a existência de um hiperplano que separe perfeitamente duas classes implica em uma sensibilidade muito grande e qualquer pequena alteração nos dados provoca grande alteração no hiperplano. Na realidade, os conjuntos de dados dificilmente encontram-se linearmente separados. Sendo assim, um bom classificador SVM deve permitir que alguns pontos possam estar do lado errado das margens, conforme Figura 14.

Para permitir essa restrição, é necessário inserir uma variável de folga ε_i . Com isso a equação de restrição geral pode ser reescrita, conforme Equação 7.

$$y_i(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k) \geq 1 - \varepsilon_i, \varepsilon_i \geq 0, \sum_{i=1}^k \varepsilon_i \leq C, \forall i = 1, \dots, k \quad (7)$$


Figura 14 - Hiperplano com vetores de suporte permitindo algumas restrições



O ξ_i pode ser maior que um, permitindo que a equação seja negativa, ou seja, que a i -ésima amostra fique do lado errado do hiperplano (Lorena; Carvalho, 2007). O hiperparâmetro C desloca a posição do hiperplano e regula ξ_i , uma vez que não pode ser maior que C . Quanto maior é o valor de C , mais se permite que as observações sejam classificadas do lado 'errado' das margens (Izbicki; Santos 2020). Segundo os mesmos autores, o termo ξ_i refere-se aos 'erros' que estão posicionados dentro e fora das margens, podendo ser explicado pelas seguintes situações: a) se $\xi_i = 0$, então a classificação está correta; b) se $\xi_i \leq 1$, o ponto está dentro das margens; c) se $\xi_i > 1$, então o ponto está além da margem, portanto está classificado erradamente.

Para problemas complexos, quando não são separáveis linearmente, as suposições anteriores não podem ser aplicadas, conforme Figura 15. Segundo Lorena e Carvalho (2007), quando a função objetivo é convexa, o problema de não linearidade pode ser solucionado usando uma função Lagrangiana, que engloba as restrições à função objetivo, associadas aos aspectos denominados multiplicadores de Lagrange α_i , conforme Equação 8.

Figura 15 - Disposição hipotética de dados de duas classes não separáveis linearmente



Função Lagrangiana na forma vetorial (L)

$$L(b, \beta_0) = \frac{1}{2} b^T b - \sum_{i=1}^n \alpha_i [y_i (b^T x_i + \beta_0) - 1], \alpha_i \geq 0, \forall i = 1, \dots, k; \alpha_i [y_i (b^T x_i + \beta_0) - 1] = 0 \quad (8)$$

Com as seguintes restrições:

$$\alpha_i \geq 0, \forall i = 1, \dots, n; \alpha_i [y_i (b^T x_i + \beta_0) - 1] = 0 \quad (9)$$

Para satisfazer a restrição dada pela Equação 9, tem-se dois casos: a) quando $\alpha_i > 0$, a restrição está ativa, ou seja, somente os vetores de suporte estão influenciando na criação do hiperplano; b) quando $\alpha_i = 0$, a restrição está inativa, não precisa dos multiplicadores de Lagrange, pois os pontos não são vetores de suporte.

Isso pode ser revolido fazendo derivadas parciais, Equação 10, para função de Lagrangiana L em relação a 'b' e ' β_0 ', $\left[\frac{\partial L}{\partial b}, \frac{\partial L}{\partial \beta_0} \right] = 0$ (10)

Com isso, o problema original passa da forma primal para a forma dual, tendo restrições mais simples e permite a representação do problema de otimização em termos de produtos internos entre os dados. Nesse contexto, a formulação problema utiliza somente os dados de treinamento e as suas classes, em que o α_i é a solução do problema (Lorena; Carvalho, 2007).

Usando as restrições de Lagrange na Equação 11, obtém-se o seguinte problema de otimização:

$$Max_{\alpha} = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \alpha_i \alpha_j y_i y_j x_i x_j \quad (11)$$

Segundo Raschka e Mirjalili (2019) na nova forma dual (Equação 11), o problema torna-se linearmente separável. Conforme pode ser observado na Figura 16, neste caso pode-se transformar um conjunto de dados bidimensional em um novo espaço de atributo tridimensional, em que as classes tornam-se separáveis. Para isso basta substituir o produto linear $x_i x_j$ da Equação 11 por um 'Kernel' e essa técnica escalar é chamada de 'Truque de Kernel'. Há vários Kernel, por isso a escolha do Kernel é fundamental para obter uma ótima separação das classes, conforme Tabela 2.

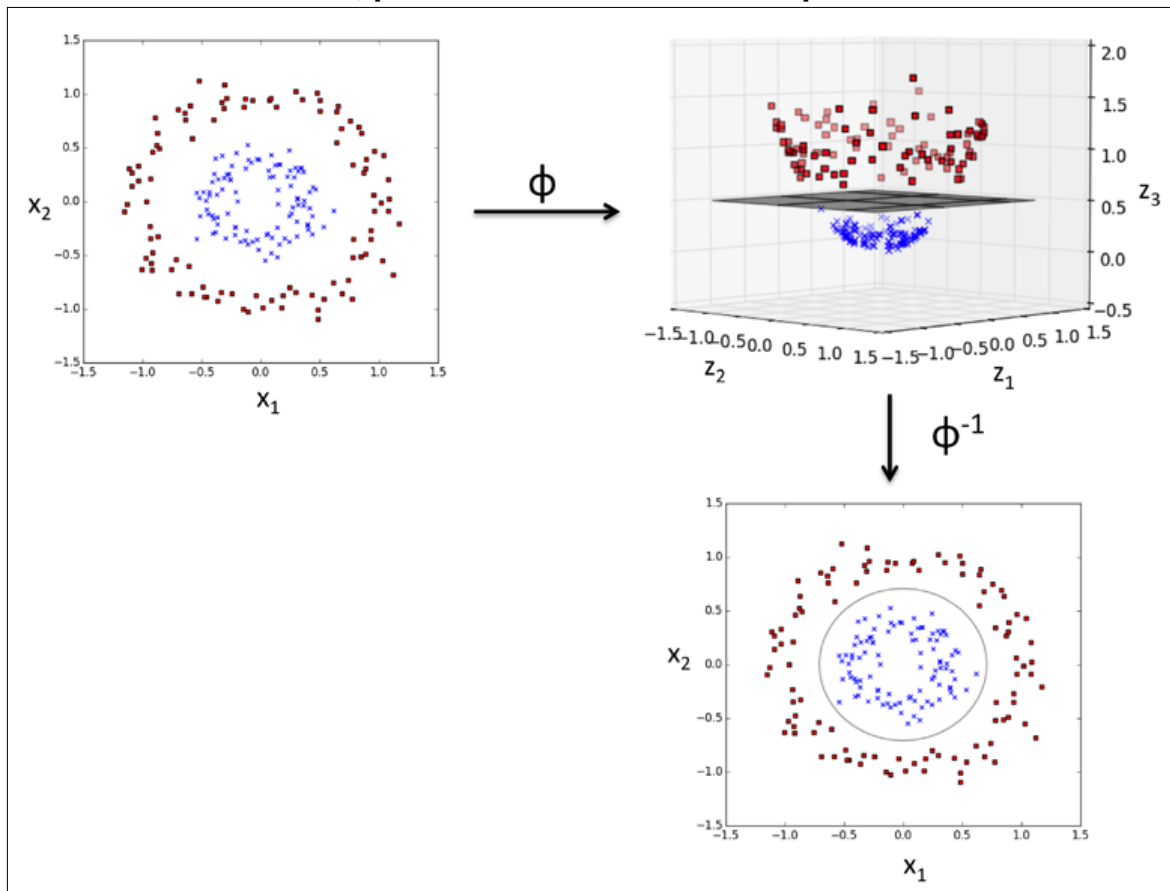
Tabela 2 - Funções Kernel mais usadas pelo algoritmo SVM não linear

Kernel	Função $K(x_i, x_j)$	Parâmetros
Polinomial	$(\delta(x_i \cdot x_j) + k)^d$	δ, k e d
Gaussiano (RBF)	$\exp(-\sigma \ x_i - x_j\ ^2)$	σ
Sigmoidal	$\tanh(\delta(x_i \cdot x_j) + k)$	δ e k

RBF é a função de base radial

Fonte: Adaptado de Lorena e Carvalho (2007).

Figura 16 - Criação do espaço de características por produtos escalares, com uso de um Kernel, passando de bidimensional para tridimensional



Fonte: Raschka e Mirjalili (2019).

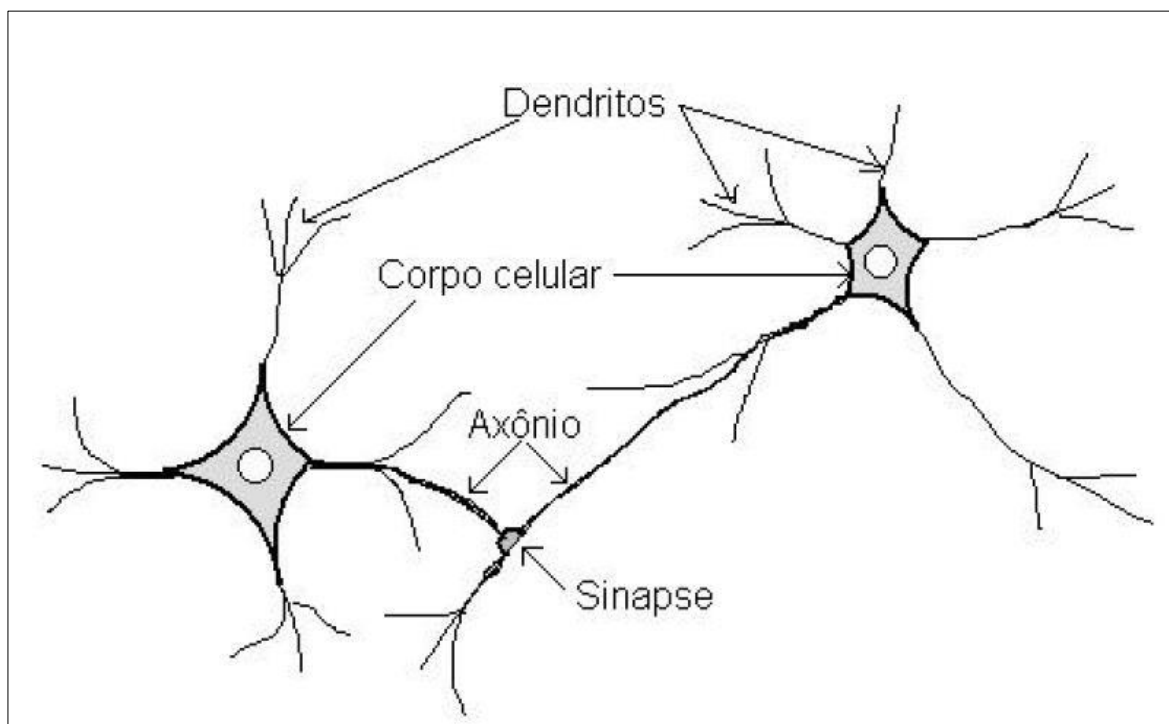
Uma questão muito importante, descrita por Lorena e Carvalho (2007), é que o espaço de característica pode ter muitas dimensões, até mesmo infinita, e a computação do produto escalar pode ser extremamente custosa, podendo inviabilizar o uso dessa técnica.

2.10.3 Redes Neurais Artificiais - RNA

Redes Neurais Artificiais (RNA) são métodos computacionais de aprendizado de máquinas e seu funcionamento se baseia na complexidade estrutural de neurônios biológicos (Mitchell, 1997). Segundo Moreira (2013), neurônios são células altamente estimuláveis, que processam e transmitem informações através de sinais eletroquímicos.

Um neurônio é composto por corpo celular, dendrites, axônio e terminações do axônio, conforme estrutura apresentada na Figura 17. Para Singh (2019), o neurônio transfere sinal, na forma de sinapse, a outro neurônio e esse processo é contínuo até o sinal chegar ao cérebro. Dessa forma os dendritos recebem os sinais de um outro neurônio e os transmite para o próximo neurônio.

Figura 17 - Representação de um neurônio biológico com suas principais estruturas de transmissão de sinal

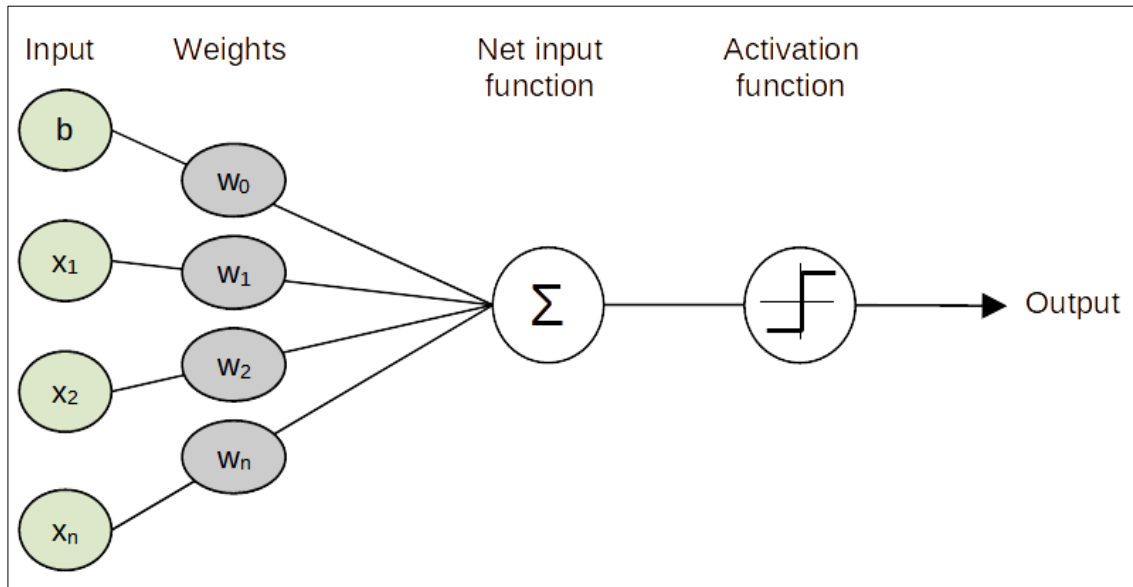


Fonte: Bonini Neto e Bonini (2010)

A RNA usa metodologia análoga, processando informações com uso de neurônios artificiais. McCulloch e Pitts (1943) foram os primeiros a publicar trabalho nesse sentido. Os autores fizeram um modelo de cérebro eletrônico, com formulação matemática de um neurônio biológico, capaz de resolver problemas de funções (AND, OR e NOT). Em 1958, Rosenblatt (1958), inspirado no trabalho de McCulloch e Pitts (1943), desenvolveu o primeiro algoritmo de aprendizado, que ficou conhecido como Perceptron.

Uma RNA, de forma geral, possui estrutura descrita na Figura 18, onde b é o bias, (x_i) são os dados de entrada de cada característica; (w_i) são os pesos dos dados, (\sum) é o somatório do produto $(x_i) (w_i)$ e o f é a função de ativação.

Figura 18 - Representação básica de uma RNA simples Perceptron



Fonte: Adaptado de Raschka e Mirjalili (2019).


Na Figura 18, observa-se que há um fluxo de aprendizado que segue regras bem definidas. Os dados de entrada (x_i), inclusive o bias (b), são multiplicados pelos seus respectivos pesos (w_i) e seus produtos são submetidos a uma função de ativação, Equação 12. Neste caso se o produtório for menor que zero não ativa, caso contrário ativa, Equação 13.

$$\sigma(\sum_{i=0}^m x_i w_i) = \sigma(x^T w) = \hat{y} \quad (12)$$

$$\sigma(z) = \begin{cases} 0, & z \leq 0 \\ 1, & z > 0 \end{cases} \quad (13)$$

O modelo Perceptron, descrito acima, somente é efetivo se o problema for linear e as classes forem perfeitamente separáveis. Para problemas de classificação mais complexos e não lineares é necessário adotar uma RNA de múltiplas camadas, conhecida como Perceptron Multicamadas (*Multi-Layer Perceptron – MLP*). A RNA MLP se diferencia da RNA Perceptron por apresentar camada escondida (*Hidden layer*), correção dos erros, ajustes dos pesos e *bias*, por retropropagação (*backpropagation*), além de função de ativação não linear (Figura 19).

Figura 19 - Representação básica de uma RNA Multi-Layer Perceptron



Fonte: Zainal-Mokhtar e Mohamad-Saleh (2013).

Na MLP o fluxo de aprendizado segue a mesma trajetória do Perceptron camada simples. Ela tem uma fase positiva chamada de *Feed-Forward* que ocorre quando os dados de entrada, interagindo com os pesos, vão passando pelas camadas de neurônios até alcançar a camada de saída *Output layer*. Nesta camada são avaliados os valores preditos com os valores observados e, caso haja divergência, inicia-se a fase negativa chamada de *Feed-Backward*. Esse processo tem que calcular o erro e o gradiente descendente, atualizando pesos até ajustá-los na camada de entrada (Equações 14, 15 e 16). Esses ciclos positivos e negativos se repetem até ajustar o modelo.

$$e_m = (T_m - X_m)F'(y_m) \quad (14)$$

Em que (e_m) é o erro na saída, T_m é valor desejado na saída; X_m é o valor obtido; $F'(y_m)$ é a derivada da função de ativação.

$$\Delta w_{km} = \eta x_k e_m \quad (15)$$

Em que Δw_{km} é a atualização dos pesos em cada camada; η é a taxa de aprendizado; x_k é o dado de entrada do neurônio; e_m é o erro.

$$e_k = F'(y_k) \sum e_i w_{ki} \quad (16)$$

Em que e_k é o erro associado aquele neurônio; $e_i w_{ki}$ é o erro ponderado pelo peso.

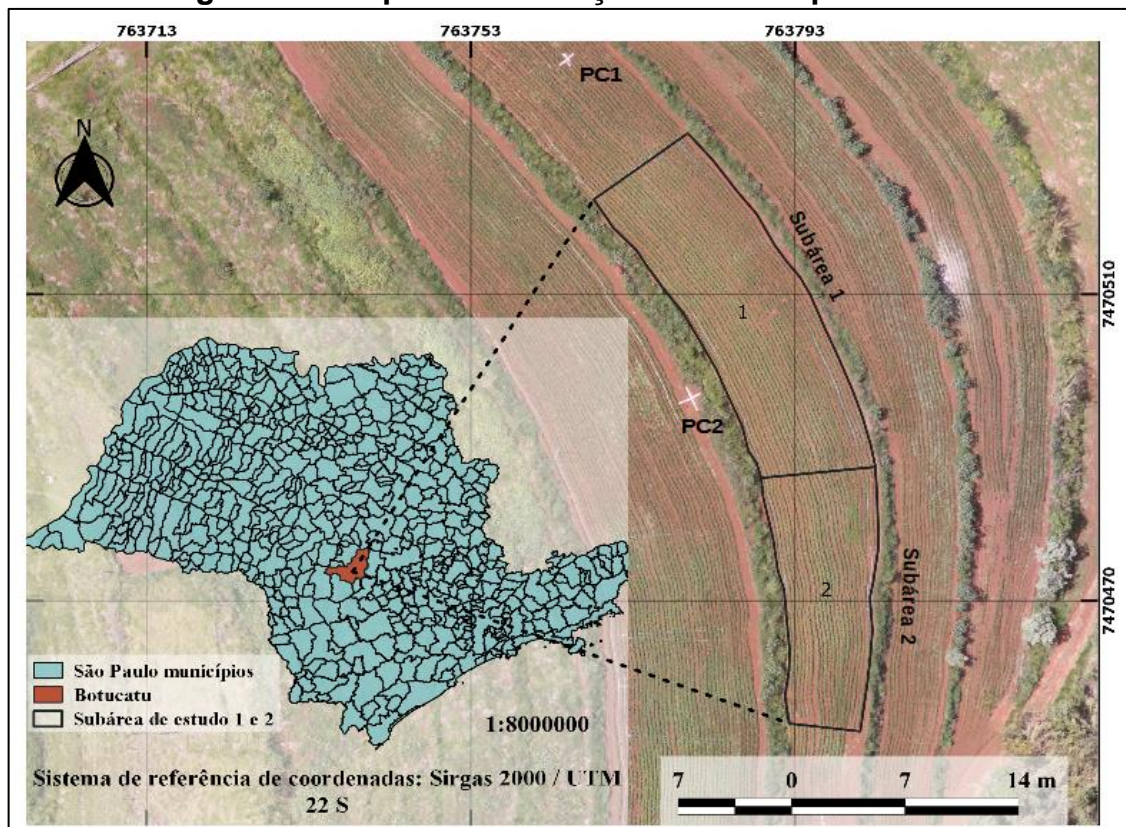
A RNA MLP é amplamente utilizada para resolver problemas de classificação por apresentar tolerância a ruídos e resolver problemas lineares e não lineares. Entretanto, devido suas características multicamadas, a função erro é não convexa, podendo ter vários mínimos locais; além disso a definição de quantas camadas ou quantos neurônios terão por camada pode deixar o algoritmo bastante custoso computacionalmente.

3 MATERIAL E MÉTODOS

3.1 Local e caracterização do experimento

A pesquisa foi conduzida em campo na área experimental do Departamento de Engenharia Rural e Socioeconomia, da Faculdade de Ciências Agrônômicas (FCA), da Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), Campus Botucatu, São Paulo (Figura 20).

Figura 20 - Mapa de localização da área experimental



A área experimental, de aproximadamente 1.000 m², foi dividida em duas subáreas: subárea 1, com área de 650 m², que foi utilizada para coletar dados não destrutivos (obtenção de imagens com sensores proximais e aéreos); e subárea 2, com área de 350 m², que foi utilizada para coletar dados destrutivos (amostras de plantas).

O experimento foi conduzido em dois ciclos: o “ciclo 1” que foi destinado à criação e calibração dos modelos matemáticos, denominado de etapa de modelagem e ocorreu nas estações climáticas outono/inverno; o “ciclo 2” foi denominado de etapa de validação e ocorreu nas estações climáticas primavera/verão (Tabela 3).

Tabela 3 – Descrição e tempo de duração, em dias, das etapas de modelagem e validação

Ciclo	Etapa	Data		Duração	Estação climática
		emergência	colheita	DAE (dias)	
1	Modelagem	11/05/2022	09/08/2022	91	outono/inverno
2	Validação	16/10/2022	31/12/2022	77	primavera/verão

Em que, DAE são os dias após a emergência das plantas

3.2 Clima e solo

De acordo com Cunha e Martins (2009), pela classificação climática de Köppen, o clima da região é caracterizado como “Cfa”, clima temperado quente (mesotérmico) úmido, com chuva no verão e seca no inverno, com precipitações pluviiais médias anuais de 1.428,4 mm, sendo as maiores médias mensais no mês de janeiro e as menores no mês de agosto com 246,2 mm e 36,1 mm, respectivamente e temperaturas médias mensais de 20,3 °C, sendo a maior no mês de fevereiro e menor no mês de julho com 23,1 °C e 17,1 °C, respectivamente.

O solo da área experimental é classificado como Nitossolo Vermelho Distroférico (EMBRAPA, 2018). Desta área foram coletadas amostras de solo na profundidade de 0 a 20 cm para caracterização química.

As amostras de solo foram encaminhadas ao Laboratório de Fertilidade do solo, no Departamento de Solos e Recursos Ambientais, da FCA/UNESP/Botucatu. Os resultados das análises químicas de macro e micronutrientes estão descritas na Tabela 4 e foram realizadas conforme metodologia de Rajj *et al.* (2001).

Tabela 4 - Resultado da análise química de macro e micronutrientes do solo da área experimental dos ciclos 1 e 2

Característica	Descrição	Unidade	Ciclo	
			1	2
pH	CaCl ₂	-	4,9	5,5
P	Fósforo resina	mg dm ⁻³	14	12
K	Potássio	mmol _c dm ⁻³	0,9	1,3
Ca	Cálcio	mmol _c dm ⁻³	22	36
Mg	Magnésio	mmol _c dm ⁻³	22	24
H+Al	Acidez potencial	mmol _c dm ⁻³	38	35
SB	Soma bases	mmol _c dm ⁻³	45	62
CTC	PH 7,0	mmol _c dm ⁻³	83	97
V	Saturação por Bases	%	54	64
MO	Mat. Orgânica	mg dm ⁻³	21	22
Zn	Zinco	mg dm ⁻³	2,7	1,5
Fe	Ferro	mg dm ⁻³	24	22
Mn	Manganês	mg dm ⁻³	13,4	22,6
Cu	Cobre	mg dm ⁻³	10,4	7,7
B	Boro	mg dm ⁻³	0,21	0,24
S	Enxofre	mg dm ⁻³	18	27

Para definir a classe textural adotou-se os resultados de granulometria do solo obtidos por Jadosky (2002), informados na Tabela 5. Com base nesses dados foi possível classificar o solo da área experimental como de textura Argilosa, conforme metodologia descrita por Lemos e Santos (1984).

Tabela 5 - Resultado da análise física granulométrica e classe textural do solo

Camada cm	Areia	Silte	Argila	Classe Textural
	g kg ⁻¹			
0 – 30	402,50	132,50	465,00	Argila

Fonte: Adaptado de Jadoski (2002).

3.3 Preparação, instalação e condução do experimento

O preparo do solo da área experimental iniciou no dia 02/02/2022, de forma mecanizada, com uso de tratores e implementos fornecidos pela administração da fazenda Lageado (Figura 21).

Figura 21 - Procedimentos gerais de preparação do solo da área experimental. Aração com arado de disco reversível (A); gradagem com grade aradora (B); aplicação de calcário dolomítico (C); semearadura e aplicação de adubo com plantadeira Semeato plantio direto (D)



No preparo do solo utilizou-se uma aração (11/02) e duas gradagens, sendo uma após a aração (14/02) e a outra após a realização da calagem (21/02), sendo que esta seguiu a recomendação de Ambrosano *et al.* (1997) em elevar a saturação por

base a 70 %, aplicando-se um total de 1,5 t ha⁻¹ de calcário dolomítico com PRNT de 90 %.

Antes da semeadura, as sementes foram protegidas com uso dos agroquímicos Standak®Top e Ubyfol CoMo ML-14; o primeiro como fungicida e inseticida, na dosagem de 200 ml do p.c / 100 kg de sementes; o segundo como fonte de nutrientes molibdênio e cobalto, na dosagem de 0,15 l ha.

Com o resultado da análise química do solo foi possível elaborar uma recomendação de adubação para alta produtividade do feijoeiro-comun, seguindo proposta elaborada por Ambrosano *et al.* (1997), aplicando assim 290 kg ha⁻¹ do formulado 8-28-16 durante a semeadura e 80 kg ha⁻¹ de N de cobertura, parcelada em duas vezes.

No dia 26/04, realizou-se a semeadura e aplicação de adubação usando a plantadeira marca Semeato, com sete saídas de sementes e adubos (Figura 21 D).

Nos ciclos 1 e 2 utilizou-se sementes de feijão da cultivar TAA Dama do grupo “Carioca”, com espaçamento de 0,5 m entre linhas e 10 sementes por metro linear, resultando em uma densidade de 200 mil plantas por hectare.

Para fins de contagem de dias após a emergência (DAE), considerou-se planta emergida quando mais de 50% apresentavam o par de folhas primárias totalmente expandidas, no início da fase fenológica V2, isso ocorreu no dia 11/05/2022.

A partir de então, levou-se 91 dias até a completa maturação dos grãos (vagens de cor bege e umidade em torno de 18 %). No “ciclo 2” o início da contagem do DAE ocorreu no dia 16/10 e finalizou no dia 31/12/2022, levando 77 dias para completar o ciclo fenológico.

No “ciclo 1”, a primeira adubação de cobertura ocorreu no dia 28/05, quando foram aplicados manualmente 40 kg ha⁻¹ de N, tendo como fonte o sulfato de amônio (Figura 22 A); a segunda aplicação ocorreu 15 dias depois, tendo como fonte a ureia, aplicada via fertirrigação, conforme Figura 22 D. No “ciclo 2”, seguiu-se a mesma recomendação adotada no “ciclo 1”, sendo a primeira aplicação no dia 26/10/2022 e a segunda aplicação 15 dias depois.

Para o controle das plantas daninhas foram feitas capinas manuais (Figura 22 C) e aplicação de agroquímicos, usando dois tipos de herbicidas seletivos pós-emergência; o primeiro (Flex®) para controle de folha larga na dose de 1,0 l ha⁻¹ e o

segundo (Cletodim Nortox) para controle de folha estreita, na dose de $0,4 \text{ l ha}^{-1}$, aplicados de forma manual (pulverizador costal) e via irrigação (Figuras 22 B e 22 D).

Para o controle de pragas e doenças foram aplicados os agroquímicos Acefato Nortox e Orkestra[®] SC, nas dosagens $0,5 \text{ do kg ha}^{-1}$ e 250 ml ha^{-1} , inseticida e fungicida, respectivamente; as aplicações foram feitas via irrigação (Figura 22 D).

Figura 22 - Aplicação de adubo nitrogenado com carro distribuidor (A); aplicação produtos agroquímicos com pulverizador manual (B); capina manual com enxada (C); aplicação de produtos agroquímicos diversos via irrigação com injetor venturi (D)



3.4 Manejo da irrigação

O manejo da irrigação foi realizado pelo método do balanço hídrico diário de água solo (BH), sendo necessário determinar a umidade do solo na capacidade de campo (CC) e no ponto de murcha permanente (PMP), a capacidade de água disponível (CAD), a umidade crítica (CR) e a água facilmente disponível (AFD).

3.4.1 Determinação da capacidade de campo (CC)

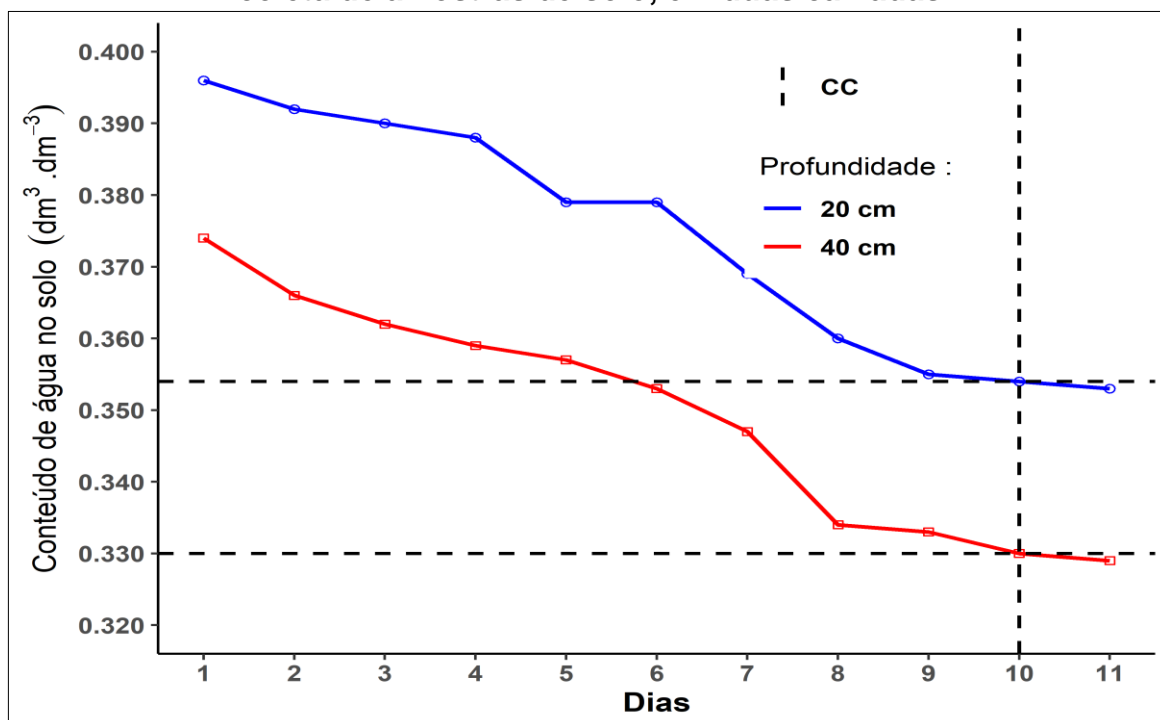
De maneira geral, adota-se que a capacidade de campo é atingida quando o potencial matricial é de $-0,03$ mPa e de $-0,01$ mPa, para solos arenosos e argilosos, respectivamente. Entretanto, Brito *et al.* (2011) afirmam que este critério pode subestimar ou superestimar a capacidade de campo. Nesse sentido adotou-se o método da bacia de saturação para estimar a capacidade de campo do solo “*in situ*”, conforme descrição fornecida por Zonta *et al.* (2016), Figura 23.

Figura 23 - Etapas do método da bacia de saturação. Inserção e saturação da bacia (A); cobertura da bacia para evitar evaporação (B); material coletado diariamente, após 48 horas de saturação (C); amostras colocadas em estufas por 24 horas a $105\text{ }^{\circ}\text{C}$ (D)



Na Figura 24, observa-se o comportamento médio de 66 amostras de solo para duas profundidades (20 e 40 cm), coletadas ao longo de 11 dias. A primeira coleta de solo foi no dia 11/03/22 e a última no dia 21/03/22. Ao longo desse período constatou-se que o conteúdo de água no solo, calculado pela Equação 17 descrita por Viana *et al.* (2017), foi diminuindo com o transcorrer dos dias, para as duas profundidades avaliadas.

Figura 24 - Comportamento do conteúdo de água no solo, durante 11 dias de coleta de amostras de solo, em duas camadas



Estas tiveram comportamentos semelhantes até o oitavo dia, com densidade de fluxo, de aproximadamente, $1,03 \text{ mm dia}^{-1}$. Para os três dias restantes a densidade de fluxo foi de aproximadamente $0,2 \text{ mm dia}^{-1}$. Segundo Twarakavi *et al.* (2009), uma densidade de fluxo em torno de $0,1 \text{ mm dia}^{-1}$ é uma boa estimativa para determinar a capacidade de campo para uma grande variedade de solo, conforme Equação 18. Sendo assim, a linha pontilhada, na vertical, serve de referência para indicar a capacidade de campo do solo da área experimental, com os valores $0,354$ e $0,330 \text{ dm}^3 \text{ dm}^{-3}$ para as profundidades de 20 e 40 cm, respectivamente.

$$\theta_v = \left(\frac{M_U - M_S}{M_S} \right) D_a \quad (17)$$

Em que θ_v é o conteúdo volumétrico de água na amostra de solo, em ($\text{dm}^3 \text{ dm}^{-3}$); M_U é a massa da amostra úmida, em (g); M_S é a massa da amostra seca, em (g); D_a é a densidade aparente da amostra de solo, em (g cm^{-3}).

$$q_z = - \int_0^z \frac{\partial \theta}{\partial t} dz \quad (18)$$

Em que θ é o conteúdo de água no solo; t é o tempo de redistribuição da água; q_z é a densidade de fluxo da água na camada de solo z .

3.4.2 Curva característica de retenção de água no solo

Foram coletadas amostras indeformadas do solo para construir as curvas características de retenção de água no solo e determinar as densidades do solo nas camadas de 0 a 20 cm e de 20 a 40 cm. As amostras foram devidamente processadas e encaminhadas ao Laboratório de Fertilidade do solo, no Departamento de Solos e Recursos Ambientais, da FCA/UNESP/Botucatu. Com os valores de umidades do solo e suas respectivas tensões (Tabela 6) foi possível ajustar a equação não linear proposta por Van Genuchten (1980), conforme a Equação 19.

Tabela 6 - Valores de umidades e tensões de água no solo obtidos pelo método de Richards (1965) para duas camadas

Camada	Conteúdo de água (dm dm^{-3})							
	Saturado	3	6	10	30	100	500	1500
(cm)								
0 a 20	0.480	0.410	0.380	0.350	0.320	0.300	0.280	0.270
20 a 40	0.470	0.380	0.370	0.330	0.310	0.290	0.270	0.260

$$\theta = \frac{\theta_r + (\theta_s - \theta_r)}{[(1 + \alpha \psi_m)^n]^m} \quad (19)$$

Em que θ é o conteúdo de água no solo, em (dm dm^{-3}); θ_r é o conteúdo de água residual, (dm dm^{-3}); θ_s é o conteúdo de água na saturação, em (dm dm^{-3}); ψ_m é o potencial matricial, em (mPa); α , n e m são os aspectos empíricos do modelo.

Para o ajuste da curva foi utilizado o programa computacional RETC desenvolvido por Van Genuchten *et al.* (2009). As equações ajustadas, as densidades do solo e o coeficiente de determinação estão presentes na Tabela 7.

Tabela 7 - Equações ajustadas, densidade do solo e coeficiente de determinação para duas camadas de solo

Camada cm	Dens. solo g cm^{-3}	Equação	R^2
0 a 20	1.390	$\Theta = 0,262220 + \frac{0,481473 - 0,262220}{[1 + (0,655184 \Psi_m)^{1,444422}]^{0,307682}}$	0.998
20 a 40	1.360	$\Theta = 0,242431 + \frac{0,473562 - 0,242431}{[1 + (1,300056 \Psi_m)^{1,332912}]^{0,249763}}$	0.992

3.4.3 Água facilmente disponível no solo (AFD)

Com os valores obtidos na Tabela 6 e com as equações da Tabela 7 foi possível gerar as curvas características de retenção de água no solo para duas camadas de solo, conforme Figura 25. Além disso, foi possível determinar as seguintes umidades volumétricas do solo: capacidade de campo (θ_{CC}), crítica (θ_{CR}) e ponto de murcha permanente (θ_{PMP}), apresentados na Tabela 8, com suas respectivas tensões. Para determinar a umidade crítica adotou-se um fator depleção de 0,50, recomendado por Doorenbos e Kassam (1979) para a cultura de feijoeiro. A água facilmente disponível no solo (AFD) é a faixa do conteúdo de água no solo que compreende o intervalo entre a umidade na capacidade de campo e umidade crítica, presente na Figura 25, e foi calculada usando a Equação 20.

Tabela 8 - Valores de umidade no solo na capacidade de campo, crítica e ponto de murcha permanente, e suas respectivas tensões, para duas camadas

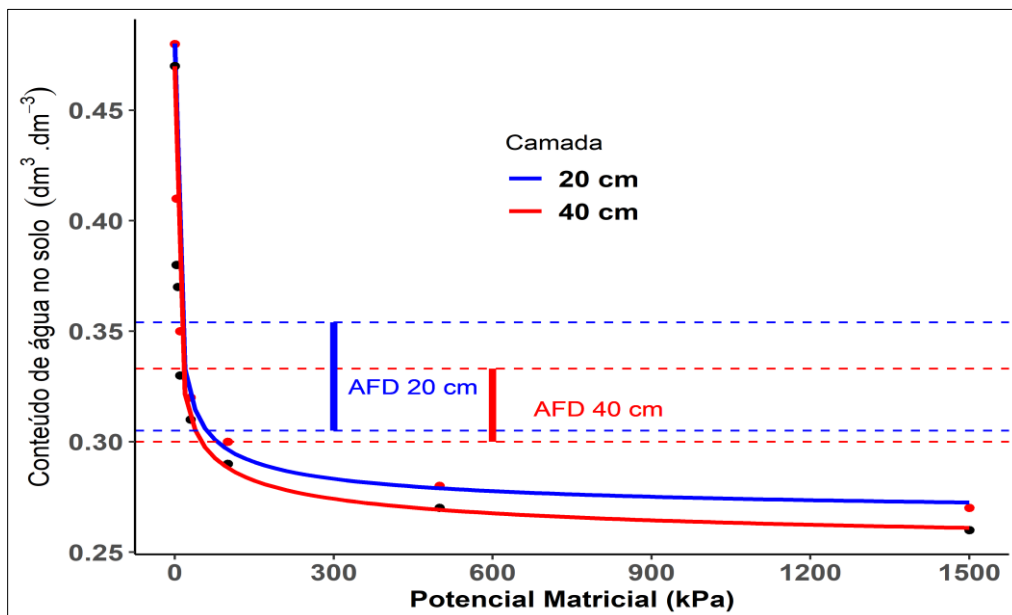
Camada (cm)	Conteúdo de água ($\text{dm}^3 \text{dm}^{-3}$)			Tensão (kPa)		
	θ_{CC}	θ_{CR}	θ_{PMP}	Ψ_{CC}	Ψ_{CR}	Ψ_{PMP}
0 a 20	0.354	0.299	0.244	7.0	29.0	1510.0
20 a 40	0.333	0.296	0.259	9.5	46.0	1510.0

Em que, θ_{CC} é a umidade na capacidade de campo; θ_{CR} é a umidade crítica; θ_{PMP} é a umidade no ponto de murcha permanente; Ψ_i é a tensão para referida condição de umidade.

$$AFD = 10 * (\theta_{CC} - \theta_{CR}) * Z \quad (20)$$

Em que AFD é a água facilmente disponível no solo, em (mm); z é a profundidade da camada avaliada, em (cm).

Figura 25 - Curvas características de retenções de água no solo

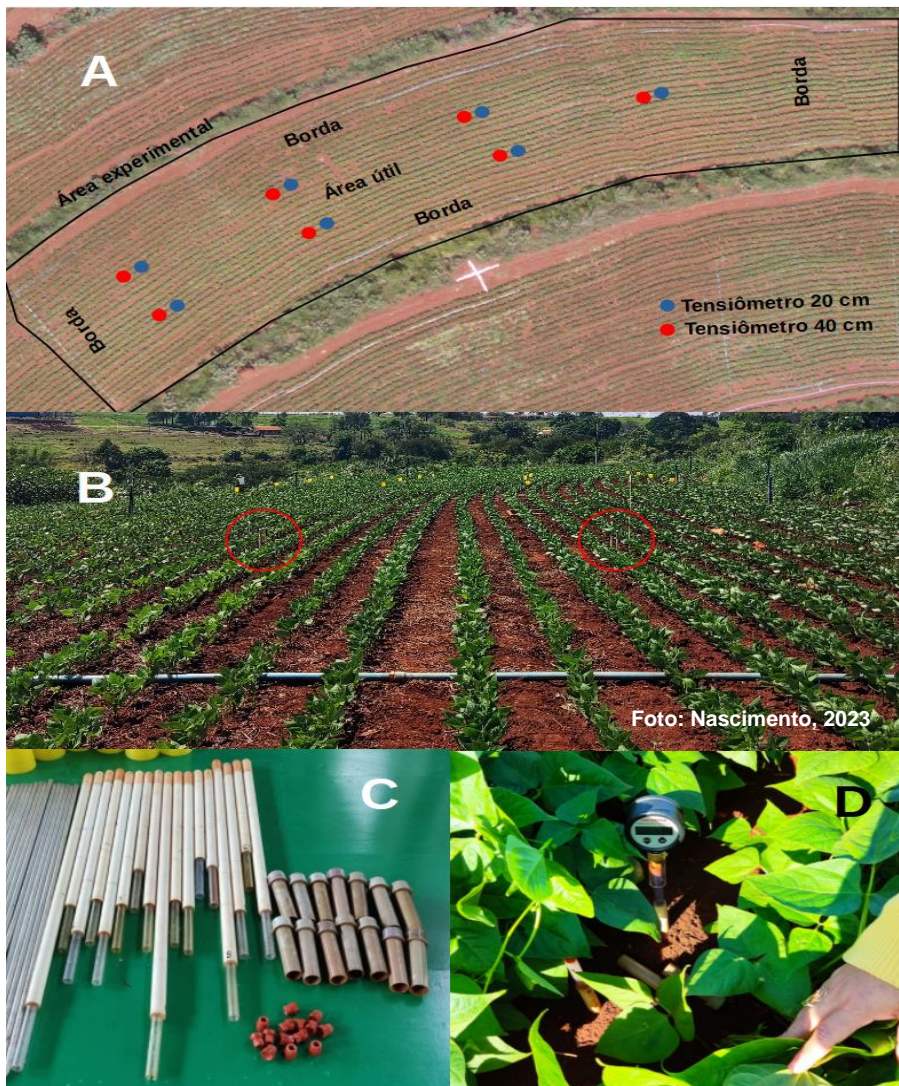


3.4.4 Acompanhamento diário da umidade retida no solo

Com as curvas características de retenção de água no solo e com os valores AFD para as duas camadas (Figura 25), foi possível realizar o balanço diário de entradas e saídas de água do solo. Para isso foram instalados 14 tensiômetros, nas

profundidades de 20 e 40 cm, na área útil experimental de aproximadamente 5 m de largura, deixando bordas periféricas de no mínimo 5 m para cada lado, conforme Figura 26.

Figura 26. Distribuição de tensiômetros dentro da área útil experimental, deixando bordas periféricas (A); instalações de tensiômetros na quarta linha, contado a partir do centro (B); tensiômetros instalados na área útil experimental (C); leitura dos tensiômetros utilizando tensímetro digital (D)



O armazenamento de água no solo (A_{m}) foi aferido com tensímetro digital, através de leituras diárias, usando a Equação 21, conforme metodologia descrita por Marouelli *et al.* (2011). Os valores de T_m foram utilizados para encontrar o conteúdo de água no solo em função curva característica de retenção de água no solo.

$$T_m = L - 0,098 \cdot H_{H_2O} \quad (21)$$

Em que T_m é a tensão de água na matriz do solo, em (kPa); L é a leitura de tensão no vacuômetro, em (kPa); H_{H_2O} é a altura da coluna de água no tensiômetro, considerando-se o centro da cápsula, em (cm).

Com o conteúdo de água no solo foi possível determinar a variação do armazenamento diário de água no solo (ΔArm), usando a Equação 22, adaptada de Frizzone (2017).

$$\Delta Arm_i = (\theta_{0:20i} - \theta_{0:20i+1}) \cdot \Delta z_{0:20} + (\theta_{20:40i} - \theta_{20:40i+1}) \cdot \Delta z_{20:40} \quad (22)$$

Em que ΔArm é a variação no armazenamento de água no solo, em (mm); $\theta_{0:20i}$ é conteúdo de água no solo na camada de 0 a 20 cm do dia, em ($dm^3 dm^{-3}$); $\theta_{0:20i+1}$ é conteúdo de água no solo na camada de 0 a 20 cm do dia seguinte, em ($dm^3 dm^{-3}$); $\theta_{20:40i}$ é conteúdo de água no solo na camada de 20 a 40 cm do dia, em ($dm^3 dm^{-3}$); $\theta_{20:40i+1}$ é conteúdo de água no solo na camada de 20 a 40 cm do dia seguinte, em ($dm^3 dm^{-3}$); $\Delta z_{0:20}$ e $\Delta z_{20:40}$ são as variações nas profundidades das camadas de interesse, em (mm).

3.5 Irrigação

A lâmina de irrigação foi aplicada com a finalidade de repor o armazenamento de água no solo até a condição de capacidade de campo. Esse evento ocorreu quando a ΔArm , na camada de 0 a 20 cm, se aproximou de 11 mm, considerando a umidade crítica θ_{CR} de $0,299 dm^3 dm^{-3}$, equivalente à tensão crítica ψ_{CR} de 29,00 kPa. A lâmina de reposição foi calculada usando a Equação 23. O momento de irrigar foi determinado pelos tensiômetros instalados na camada de 0 a 20 cm; os tensiômetros na camada de 20 a 40 cm monitoravam o fluxo de água na profundidade abaixo de 30 cm e foram usados no total de lâmina aplicada.

A adoção da lâmina bruta, Equação 24, é uma técnica muito utilizada para repor as perdas de água devido, principalmente, às ações do vento e alta temperatura; para esse cálculo foi adotado uma eficiência de aplicação (E_A) de 80 %.

$$L_L = 10(\theta_{CC} - \theta_{atual})z \quad (23)$$

$$L_B = \frac{L_L}{E_A} \quad (24)$$

Em que L_L é a lâmina líquida, em (mm); θ_{CC} e θ_{atual} são as umidades do solo na capacidade de campo e atual, em ($dm^3 dm^{-3}$); z é a profundidade da camada desejada, em (cm).

3.5.1 Sistema de irrigação e uniformidade de aplicação

A fonte de água necessária para satisfazer as necessidades hídricas das plantas de feijoeiro veio de lago artificial, localizado no próprio campo experimental da Unesp, conforme Figura 27. Para levar a água do lago até a área experimental foi utilizado a bomba KSB, tipo Etabloc 40-200, rotor 209 mm de diâmetro, vazão de operação de aproximadamente $52 \text{ m}^3 \text{ h}^{-1}$ e altura manométrica de até 80 m; acoplada ao motor marca Weg, rotação 3520 rpm e 20 cv.

Figura 27 - Lago artificial usado como fonte de abastecimento de água (A); conjunto motobomba utilizado para fornecer água ao sistema de irrigação (B); tubos e conexões de engate prático com rosca (C); montagem do sistema de irrigação por aspersão (D); Sistema de irrigação montado e testado (E)



Na área experimental foi instalado o sistema de irrigação por aspersão convencional, tipo engate rápido com rosca, com duas linhas laterais paralelas distanciadas por 12 m. Foram instalados 14 aspersores da marca Agropolo NY-23S setorial, 7 em cada linha, com espaçamento de 12 x 12 m, bocal de 3,5 mm, pressão de serviço de 35 mca, diâmetro de alcance de 25,2 m, vazão de 0,803 m³ h⁻¹ e intensidade de aplicação de 5,58 mm h⁻¹ (Figura 27 E).

Figura 28 - Croqui de instalação dos coletores (A); Coleta volumétrica usando proveta (B); panorama real da disposição dos coletores (C)



Durante o desenvolvimento experimental foram realizados testes de uniformidade seguindo metodologia descrita por Mantovani *et al.* (2012). Em uma subárea de 12 x 12 m, com aspersores em todos os vértices, foram instalados 16 coletores de água no espaçamento 3m x 3m. Os volumes coletados foram medidos com uma proveta, com a velocidade do vento sempre abaixo de 2 m s⁻¹, Figura 28. Os valores coletados foram usados para calcular os coeficientes de: uniformidade de Christiansen (CUC) e uniformidade de distribuição (CUD). Os resultados médios

obtidos foram de 81,06 % e 70,73 % para CUC e CUD, respectivamente, sendo classificados como bons, segundo classificação recomendado por Mantovani (2001) na Tabela 9.

Tabela 9 - Escala de classificação de uniformidade de CUC e CUD

Classificação	CUC (%)	CUD (%)
Excelente	>90	>84
Bom	80-90	68-84
Razoável	70-80	52-68

Fonte: adaptado de Mantovani (2001).

3.6 Medidas de Graus-Dia Acumulados (GDA)

As medidas de graus-dia (GD) foram calculadas usando dois métodos: o primeiro proposto por Ometto (1981), Equação 25, que considera somente a temperatura basal inferior (Tb) e que a temperatura mínima (Tm) seja maior que a Tb; o segundo proposto por Arnold (1959), Equação 26, o qual considera que em algum momento a Tb será maior que a Tm. A Equação 26 foi utilizada somente no “ciclo 1”, etapa de modelagem, na condição que Tb > Tm. O GDA foi calculado com a Equação 27 para o “ciclo 1” e “ciclo 2” do feijoeiro, etapas de modelagem e validação, respectivamente.

Os dados diários de temperatura máxima (TM) e temperatura mínima (Tm), utilizados nos cálculos, foram obtidos da Estação Meteorológica da FCA/UNESP/Botucatu. A temperatura basal inferior (Tb) utilizada nos cálculos de GD foi de 10 °C, valor adotado por Medeiros *et al.* (2000), Wutke *et al.* (2000) e Renato *et al.* (2013) para a cultura do feijão e usando as equações propostas neste trabalho.

$$GD = \frac{TM+Tm}{2} - Tb \quad (25)$$

$$GD = \frac{(TM-Tb)^2}{2(TM-Tm)} \quad (26)$$

Em que, GD são os graus-dia, em (°C); T_M é a temperatura máximo do dia (°C); T_m é a temperatura mínima do dia (°C); T_b é a temperatura basal inferior, em (°C).

$$GDA = \sum_{i=1}^n GD_{i,j} \quad (27)$$

Em que, GDA representa o somatório dos graus-dia, no período i até n, durante o ciclo j da cultura.

3.7 Evapotranspiração de cultura (ETc)

A evapotranspiração da cultura (ETc) foi obtida pelo método do balanço hídrico do solo (BH), expressa pela Equação 28. Com intuito de simplificar, foram desconsiderados os efeitos de escoamento superficial (R), drenagem profunda (D) e ascensão capilar (AC). Esses efeitos foram minimizados adotando um controle rigoroso da irrigação, escolha de área plana e homogênea e solo profundo com lençol freático bem distante da camada estudada. Tomando-se esses cuidados e evitando exceder a capacidade máxima de armazenamento de água no solo nas camadas estudadas, pode-se minimizar esses efeitos conforme sugestões de Stone e Silveira (1995), Marouelli *et al.* (2011) e Frizzone (2017).

$$ETc = P + I + AC - D \pm \Delta Arm \pm R \quad (28)$$

Em que P é a precipitação pluviométrica; I é a lâmina de irrigação aplicada; AC é a ascensão capilar; D é a drenagem profunda; ΔArm é a variação do armazenamento diário de água no solo; R é o escoamento superficial. Todos os componentes desta equação são expressos em mm dia⁻¹.

Com as simplificações adotadas, foi possível determinar a ETc diária em função da ΔArm , usando a Equação 29 adotada por Andrade Júnior *et al.* (2018).

$$ETc_{BH} = \Delta Arm_i - \Delta Arm_{i+1} \quad (29)$$

Em que ETc_{BH} é a evapotranspiração de cultura obtida pelo balanço hídrico diário do solo, em (mm); ΔArm_i é a variação do armazenamento diário de água no solo no dia i, em (mm); ΔArm_{i+1} é a variação do armazenamento diário de água no solo no dia seguinte, em (mm).

3.8 Evapotranspiração de referência (ET_o)

A evapotranspiração de referência (ET_o) foi calculada usando o método de Penman-Monteith proposta por Allen *et al.* (1998) no boletim FAO nº 56, para isso utilizou-se a Equação 30.

$$ET_o = \frac{0.408\Delta(R_n - G) + \frac{\gamma(900)}{T+273}u_2(e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (30)$$

Em que, ET_o é a evapotranspiração de referência (mm d⁻¹); R_n é o saldo de radiação à superfície da cultura (MJ m⁻² d⁻¹); G é a densidade do fluxo de calor do solo (MJ m⁻² d⁻¹); T é a temperatura média do ar a 2 m de altura (°C); u₂ é a velocidade do vento a 2 m de altura (m s⁻¹); e_s é a pressão do vapor de saturação (kPa); e_a é a pressão parcial do vapor (kPa); Δ é declividade da curva de pressão de vapor de saturação (kPa °C⁻¹); γ é o coeficiente psicrométrico (kPa °C⁻¹).

Os dados meteorológicos diários de entrada necessários, descrito acima, para calcular a ET_o foram obtidos pela Estação Meteorológica da FCA/UNESP/Botucatu. Utilizou-se planilha eletrônica LibreOffice Calc, versão 7.26.4, para determinar os valores diários de ET_o, em mm dia⁻¹.

3.9 Medidas do coeficiente de cultura (K_{c_BH})

Nesse trabalho foi adotado o coeficiente de cultura simples diário K_{c_BH}, que foi calculado (Equação 31) pela razão entre os valores da evapotranspiração de cultura ET_{c_BH}, contabilizada pelo balanço hídrico do solo e os valores da evapotranspiração de referência diária ET_o.

$$K_{c_BH} = \frac{ET_{c_BH}}{ET_o} \quad (31)$$

Os valores K_{c_BH} obtidos durante o período estudado foram distribuídos ao longo dos estádios fenológicos do feijoeiro, seguindo critérios sugeridos por Bizari *et al.* (2009), e Fischer Filho e Zocoler (2016). O ciclo do feijoeiro-comum foi dividido em quatro fases fenológicas conforme o tempo de duração em dias, Tabela 10.

Tabela 10 – Duração em dias de cada fase fenológica do feijoeiro cultivar TAA Dama do grupo “carioca”

DAE	Duração (dias)	Fase	Descrição do Estádio Fenológico
1-42	42	I	Vegetativo: folha primária até primeiros botões florais (V2,V3 e V4)
43-63	21	II	Início da floração até primeiras vagens (R5 e R6)
64-84	21	III	Enchimento dos grãos (R7 e R8)
85-91	7	IV	Maturação dos grãos (R9)

* DAE são os dias após a emergência, contados a partir das folhas primárias totalmente abertas

3.10 Medidas biofísicas da planta de feijoeiro


Durante os “ciclos 1 e 2” foram realizadas medidas biofísicas destrutivas e não-destrutivas das plantas de feijoeiro, com a finalidade de estimar o Índice de Área Foliar (IAF) e a Fração de cobertura vegetal (FCV), usando sensor proximal de uma câmera digital de Smartphone com 48 mpx de resolução (Poco X3 Pro).

3.10.1 Índice de Área Foliar (IAF)

O IAF foi obtido, semanalmente, a partir de amostras destrutivas, retiradas de seis plantas, sorteadas aleatoriamente na subárea 2 (Figura 20). As folhas, sem pecíolo, de cada planta foram separadas e identificadas em sacos de papel de 5 kg (Figura 29 A); em seguida foram submetidas a um integrador óptico de área foliar (LI-COR-3100 C) do Departamento de Produção Vegetal da UNESP Botucatu, seguindo metodologia descrita por Favarin *et al.* (2002) (Figura 29 B).

Em um segundo momento, as folhas de cada saco, denominada de “lote”, foram agrupadas numa folha de papel cartolina branca, sobre uma mesa (Figura 29 D), visando a captura de imagens digitais usando câmera digital de Smartphone, marca Poco x3 pro, 48 megapixels, resolução de 8.000 x 6.000 pixels, fixa em um suporte de mesa em pvc, numa altura de 80 cm, conforme descrição feita por Godoy *et al.* (2007) (Figura 29 C). As imagens de cada lote, obtidas com a câmera digital, foram armazenadas para posteriormente serem processadas.

Figura 29 - Folhas de uma única planta armazenada em saco de papel (A); folhas submetidas a um integrador óptico de área foliar LI_COR 3100 C (B); Suporte de mesa em pvc para digitalização de imagem (C); Imagem digitalizada com três rótulos (alvo – vermelho, fundo – branca, folhas - verde) (D)



3.10.2 Processamento das imagens e obtenção do IAF

As imagens lote foram processadas em um ambiente de programação interativo Jupyter notebook (JN), com a linguagem de programação em Python, usando um notebook Dell Inspiron 3583, com processador Intel® Core™ i7-8565U, memória RAM de 16 gb e placa de vídeo dedicada AMD Radeon Graphics.

Cada imagem lote foi composta por três classes: fundo, referência e folha, que foram denominadas de classes: 0, 1 e 2, respectivamente; com três canais conhecidos como Red (R), Green (G) e Blue (B), que foram denominados como atributos.

Determinar os atributos e as classes de uma imagem são fundamentos básicos para implementar um algoritmo de aprendizado de máquina (AM).

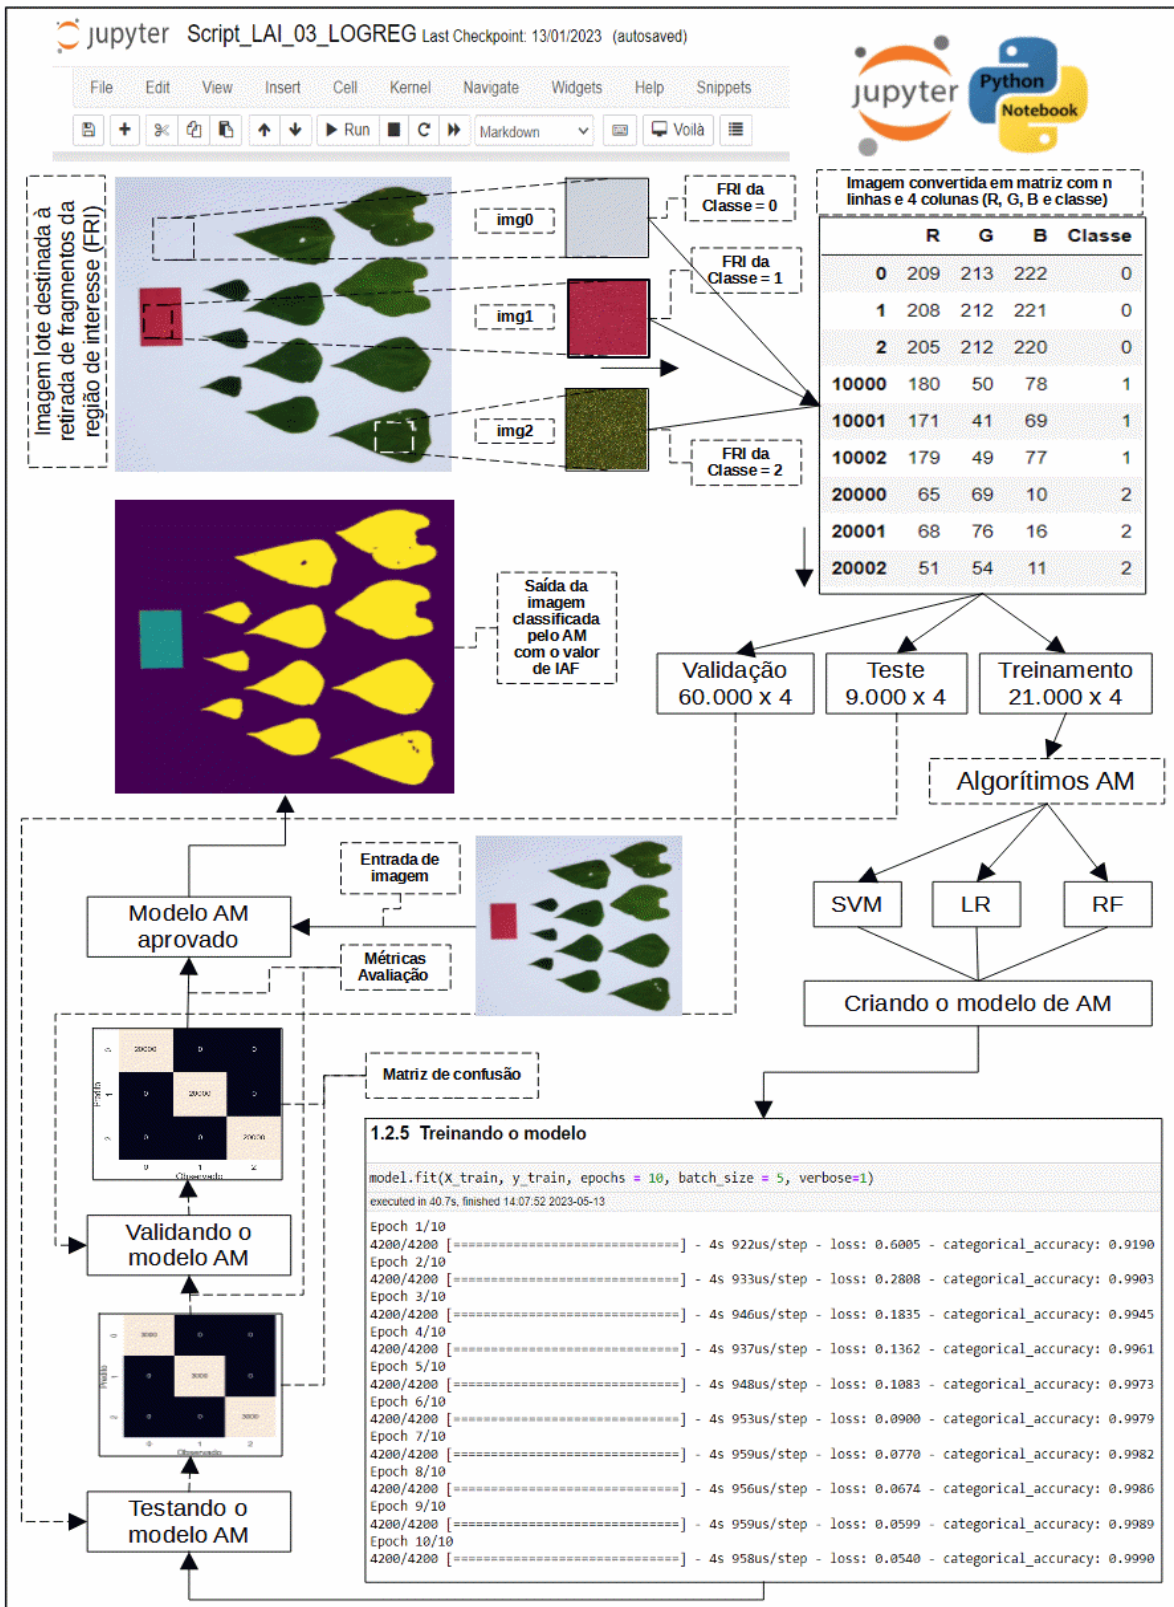
Foram escolhidas 20 imagens lotes, aleatoriamente, e destas foram extraídos fragmentos da região de interesse (FRI) para compor três novas imagens denominadas de img0, img1 e img2, uma para cada classe. No ambiente JN, as novas imagens foram aglutinadas e convertidas em uma matriz $m \times n$ contendo 100.000 linhas e 4 colunas, sendo três colunas atributos (R, G e B) e 1 coluna classe (0, 1 e 2).

No ambiente JN a matriz $m \times n$ foi subdividida em: matriz treinamento 21.000 x 4, matriz teste 9.000 x 4 e matriz validação 60.000 x 4. A matriz treinamento foi submetido a três métodos de Aprendizado de máquina (AM): Máquina de Vetores de Suporte (SVM), Floresta aleatória (RF) e Regressão Logística Multiclasse (LR). Cada método criou um modelo de AM e no treinamento utilizou-se as bibliotecas Keras, Sklearn, Numpy e Pandas.

As matrizes testes e validação foram submetidos aos modelos de AM gerados pelos algoritmos e seus resultados foram avaliados por métricas específicas, a partir de uma matriz de confusão composta por valores observados e preditos. Após isso, foi possível avaliar os modelos de AM, usando as métricas de precisão, recall, acurácia e custo (em tempo) e assim definir o melhor modelo de AM classificador para processar as imagens lotes. Concomitantemente, as imagens lotes foram pré-processadas no ambiente JN, as quais foram cortadas, padronizadas e separadas em conjuntos de dados organizados por data.

O melhor modelo de aprendizado de máquina foi escolhido para classificar cada imagem lote e com as imagens classificadas, foi possível mensurar os pixels de cada classe (0:fundo, 1:referência e 2:folha). A quantidade total de pixel da classe folha foi transformada para área (cm^2) usando regra de três simples, relacionando a quantidade total de pixel da classe referência sendo igual a 40 cm^2 . Com a Equação 32 foi possível determinar o valor de IAF, sendo $AP = 500 \text{ cm}^2$. Os procedimentos descritos estão na Figura 30.

Figura 30 – Fluxo de processos de classificação de imagem proximal utilizando AM no ambiente de programação JN, para extração do IAF



$$IAF = \frac{\sum_{i=1}^n AF_i}{AP} \quad (32)$$

Em que, IAF é o índice de área foliar; AF_i é a área foliar de uma planta, em (cm²); AP é a área ocupada por uma planta no campo, em (cm²)

3.10.3 Fração de cobertura Vegetal (FCV)

O valor da FCV foi obtido, semanalmente, a partir de amostras não-destrutivas por imagem. Para isso, utilizou-se sensor proximal de câmera digital de Smartphone, marca Poco x3 pro, 48 megapixels, resolução de 8.000 x 6.000 pixels, fixo em bastão de *selfie* “*selfie rod*” com *bluetooth wireless remote*, numa altura de aproximadamente 1,0 m, na posição horizontal sobre as plantas (Figura 31 A). Como referência utilizou-se uma moldura, confeccionada em madeira, com dimensões de 80 cm de comprimento por 80 cm de largura, perfazendo um total de 6.400 cm², conforme metodologia proposta por Fernández-Pacheco *et al.* (2014).

As imagens foram capturadas na subárea 1 (Figura 20), na área útil experimental, evitando as bordas do experimento (Figura 31 B).

Figura 31 - Captura de imagem usando sensor proximal de câmera de Smartphone acoplado em um bastão selfie (A); imagem digital obtida com a moldura delimitadora (B)



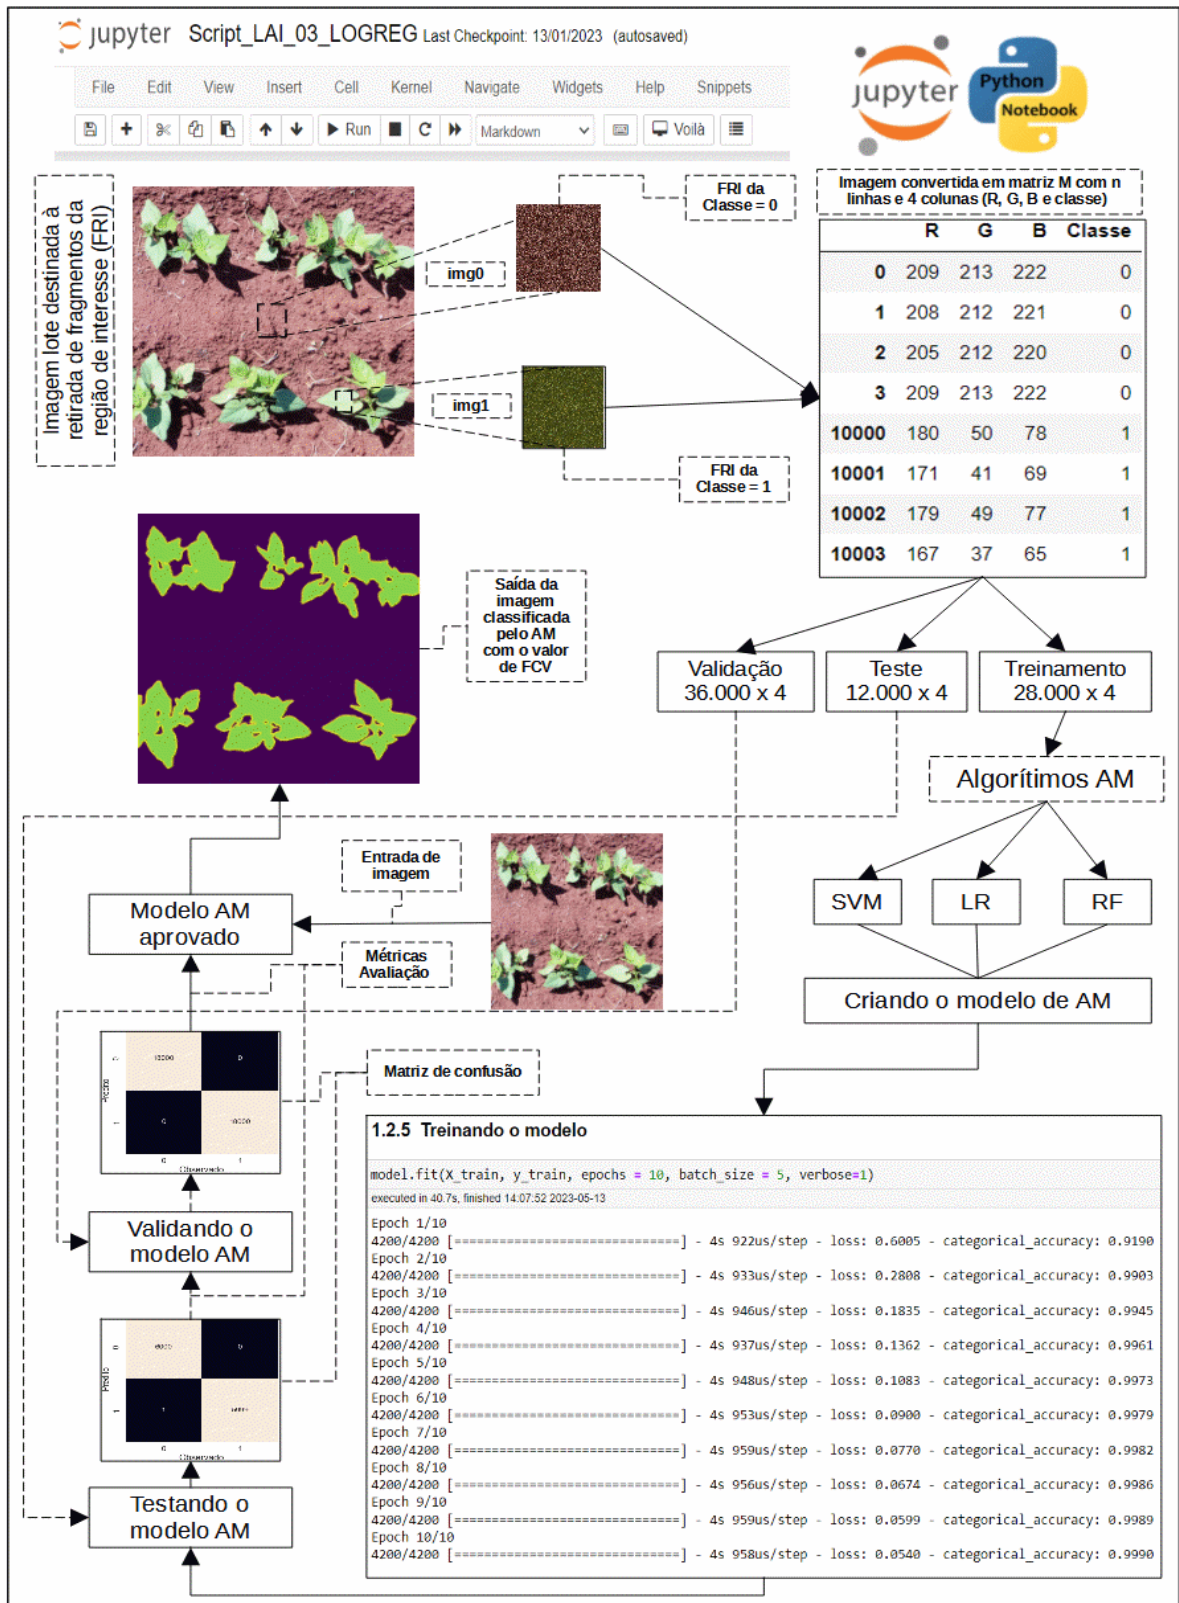
3.10.4 Processamento das imagens e obtenção do FCV

Nessa etapa adotou-se a mesma metodologia descrita anteriormente no processamento das imagens e obtenção do IAF. A principal diferença foi que as imagens convertidas em matriz $m \times n$ tiveram 100.000 linhas, 4 colunas, sendo três colunas atributos (R, G e B) e 1 coluna classe, agora com apenas duas classes (solo = 0 e vegetação = 1). Os procedimentos estão descritos na Figura 32.

O melhor modelo de AM foi escolhido para classificar cada imagem lote e com as imagens classificadas, foi possível mensurar os pixels de cada classe (solo = 0, vegetação = 1). A quantidade total de pixel da classe vegetal (QPCV) foi dividida pela quantidade total de pixel da imagem (QTPI), Equação 33.

$$FCV = \frac{QPCV}{QTPI} \quad (33)$$

Figura 32 – fluxo de processos de classificação de imagem proximal utilizando AM no ambiente de programação JN, para extração do FCV



3.11 Obtenção das imagens multiespectrais

Na obtenção das imagens multiespectrais foram utilizados os seguintes equipamentos: câmera sensor multiespectral Parrot Sequoia, Drone de mapeamento Spectral 2 da NUVEM UAV e notebook Dell Inspiron 3583, com processador Intel® Core™ i7-8565U, memória RAM de 16 gb e placa de vídeo dedicada AMD Radeon Graphics (Figura 33). Os voos ocorreram semanalmente entre 11:00 e 14:00 h.

Figura 33 - Aquisição de imagens multiespectrais: Equipamentos necessários (A); decolagem do drone (B)



3.11.1 Planejamento do voo

O planejamento do voo automático foi realizado utilizando o software NControl fornecido pela empresa NUVEM UAV. Neste programa foi possível estabelecer algumas configurações básicas, tais como: atitude de voo (120 m), sobreposição frontal (80%) e lateral (60%), ângulo da linha de voo (131°), escolher a câmera acoplada e estabelecer pontos de partida e pouso. Vale ressaltar que o esse drone só liga as hélices (partida) se tiver um plano de voo.

3.11.2 Especificação da câmera Multiespectral Parrot Sequoia

A câmera multiespectral Parrot Sequoia utilizada neste trabalho tem um sensor RGB de 16 mpx e quatro sensores monocromáticos 1.2 mpx, nas bandas: verde (Green), vermelho (Red), borda do vermelho (Red-edge) e infravermelho (NIR) (Tabela 11). Outro sensor muito importante que acompanha a câmera Sequoia é o sensor sunshine, que permite calibrar as imagens de acordo com a luminosidade do sol, possibilitando comparação de imagens no tempo.

Tabela 11 - Especificações básicas da câmera multiespectral Parrot Sequoia para um planejamento de voo a 120 m de altura

Sensor	Banda espectral	Comp. onda (nm)	Resolução espacial (cm/pix)
Monocromático	Verde - Green	530 - 570	14,8
	Vermelho - Red	640 - 680	
	Borda do vermelho - Rededge	730 - 740	
	Infravermelho próximo - Nir	770 - 810	
RGB	---	---	3,3

3.11.3 Obtenção de dados para calibração geométrica e radiométrica

É de extrema importância realizar a correção geométrica das imagens, devido as distorções provocadas pelas variações: da mecânica do sensor, do movimento da aeronave e do ângulo de visada. Segundo Prudkin e Breunig (2019), variações de vento podem provocar variação no ângulo de visada das câmeras.

Por isso é necessário demarcar e coletar pontos de controle no campo com coordenadas conhecidas, para auxiliar na ortorretificação e georreferenciamento das imagens (Figura 34 B). A coleta dos pontos de controle foi realizada em campo utilizando equipamento GNSS, receptor geodésico, *Real Time Kinematic* (RTK) de dupla frequência (L1, L2), modelo Kronos 200 da fabricante HORIZON. Além disso, os quatro pontos de controle foram demarcados com piquetes de madeira, cravados

no solo. Na semana de voo esses pontos foram expandidos com uso da cal, em forma de cruz, facilitando assim sua visualização na geração dos ortomosaicos.

Figura 34 - Etapas de calibração geométrica e radiométrica: Equipamento GNSS RTK (A); coleta e demarcação de pontos de controle (B); painel calibração (C); captura de imagem do painel de calibração (D)



A correção radiométrica é necessária para converter imagens brutas, com valores de pixels em número digital, em grandeza física de reflectância (Janzen *et al.*, 2006). Esse procedimento é importante, pois permite comparar imagens no tempo com maior veracidade. Na câmera Sequoia esse procedimento foi realizado usando um painel de calibração e o sensor sunshine. Para isso é necessário capturar imagens do painel de calibração antes e depois do voo, sempre com a máxima presença de luz solar (Figuras 34 C e 34 D).


3.12 Geração do ortomosaico

O procedimento fotogramétrico para geração dos ortomosaicos foi realizado usando o software Agisoft Metashape profissional 1.6.1 em um notebook Dell Inspiron 3583, com processador Intel® Core™ i7-8565U, memória RAM de 16 gb e placa de vídeo dedicada AMD Radeon Graphics. Para geração dos ortomosaicos, seguiu-se as recomendações de Vargas-Ramírez e Paneque-Gálvez (2019).

Com o alinhamento das imagens, busca-se por pontos homólogos dentro das sobreposições das imagens, com isso as posições da câmera são encontradas e como resultado, uma nuvem esparsa de pontos é formada. Realizou-se a calibração radiométrica das imagens usando os valores extraídos do painel de calibração. Na calibração geométrica, realizou-se a inserção das coordenadas coletadas dos pontos de controle e assim ajustamento todas as imagens, as quais possuem uma marca em forma de cruz dos pontos de controle, círculos na Figura 35 B. Na etapa de criação de nuvem de pontos, depende principalmente da calibração geométrica (georreferenciamento), são criados muitos pontos homólogos, formando uma nuvem, capazes de recriar uma imagem de superfície com profundidade, elevação, geometria e localização. Na etapa Mesh é gerado um modelo de superfície 3D, ou seja, uma malha para criação de Modelos Digital de Elevação (MDE), discriminando os elementos que compõem a superfície do terreno.

Após a conclusão de todas as etapas anteriores, foi possível construir o ortomosaico, que é a representação fidedigna da área experimental em questão. Ele é importante, pois possui informações valiosíssimas de reflectância em suas bandas espectrais (Figura 35).

Figura 35 - Geração de ortomosaico: sem correção radiométrica (A); com correção radiométrica (B)

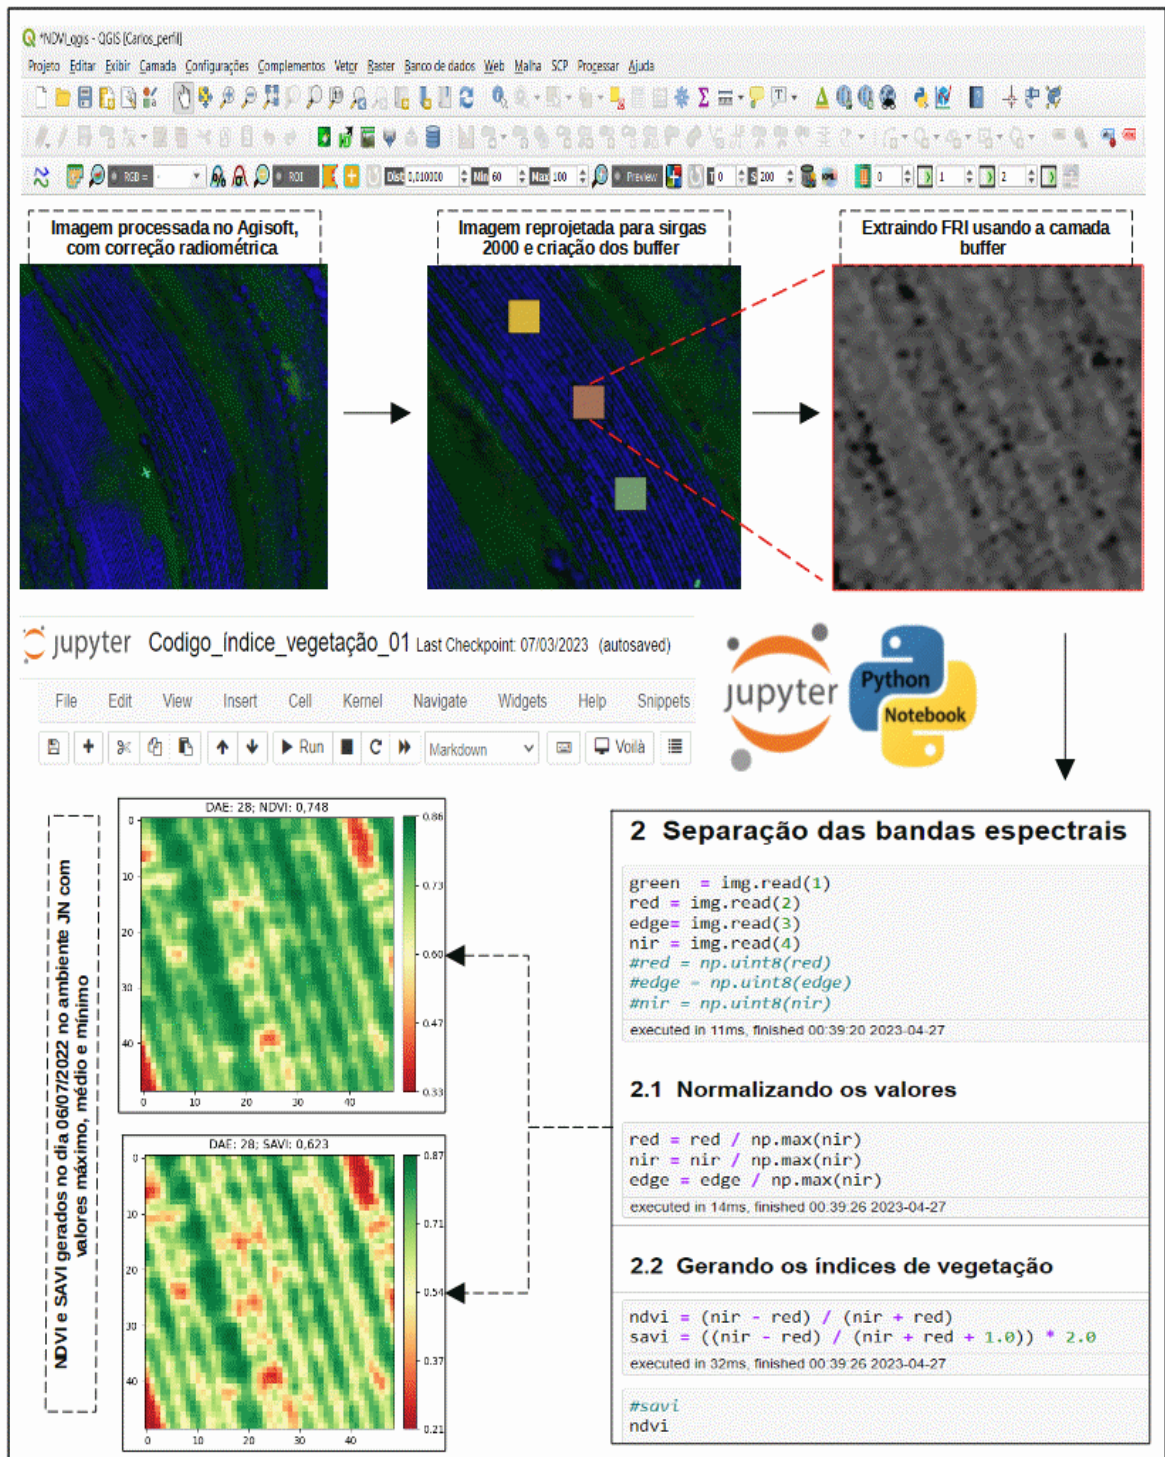


3.13 Processamento das imagens ortomosaicos e obtenção dos IV

Com os ortomosaicos prontos, utilizou-se o sistema de informação geográfica (SIG) denominado de QGIS na versão 3.10.14-A Coruña, que é um software livre e aberto. Burrough e McDonnel (1998) definem que o QGIS é uma poderosa ferramenta para coleta, armazenamento, recuperação, transformação e visualização de dados espaciais.

O QGIS foi utilizado para reprojeter os ortomosaicos para o sistema de referência de coordenadas: SIRGAS 2000 / UTM, 22 S e criar buffer de FRI e recortá-los com dimensão de 5 x 5 m, dentro da área útil, na subárea 1, para geração dos IV. Em seguida, no ambiente de programação interativo Jupyter notebook (JN), usando a linguagem de programação em Python, foi possível gerar os índices de vegetação NDVI e SAVI, empregando as seguintes bibliotecas: pandas, numpy, time, os, matplotlib.pyplot e rasterio; os procedimentos estão descritos na Figura 36. Foi usado um notebook Dell Inspiron 3583, com processador Intel® Core™ i7-8565U, memória RAM de 16 gb e placa de vídeo dedicada AMD Radeon Graphics, para realizar todos os procedimentos computacionais.

Figura 36 – Fluxo de processos de geração de NDVI e SAVI, usando software QGIS e ambiente de programação JN



3.14 Medidas de Índices de Vegetações

Para gerar os índices de vegetações NDVI e SAVI foram usadas as Equações 34 e 35, respectivamente. NDVI é o resultado da razão entre a diferença das reflectâncias das bandas no infravermelho próximo (NIR) e no vermelho (RED) pela soma dessas mesmas bandas espectrais. O valor pode variar de 1 a -1, sendo que quanto mais esse valor se aproxima de 1 indica vegetação fotossinteticamente ativa e quando tendendo a 0 significa solo exposto.

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (34)$$

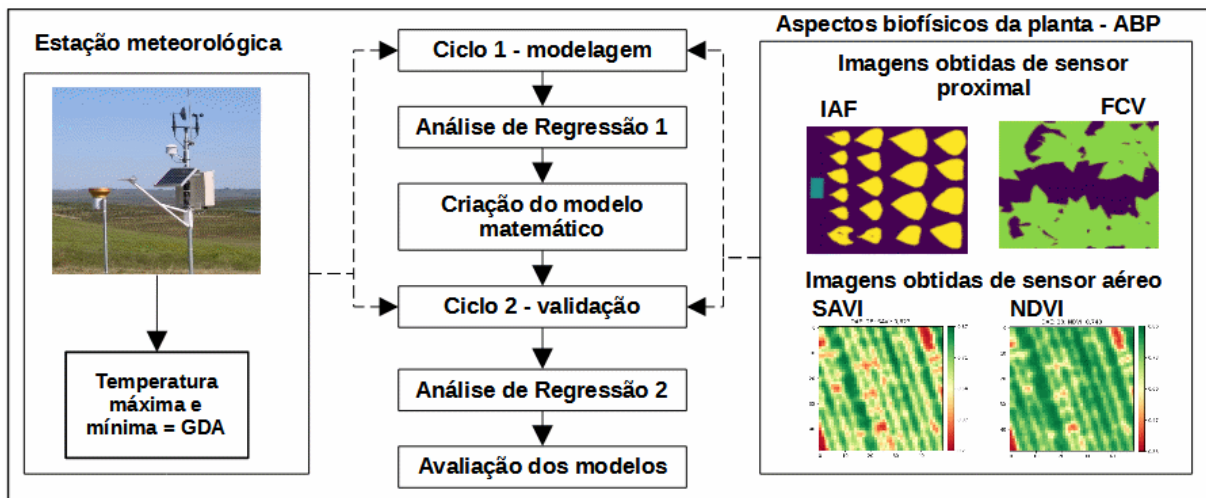
O SAVI é o índice de vegetação ajustado ao solo, proposto por Huete (1988) para minimizar os efeitos do solo no espectro de radiação, o qual incorpora uma constante L de ajuste. Nesse trabalho o L=0,25 foi usado quando o plantio teve baixa densidade; L= 0,5 quando o plantio apresentava densidade intermediária; e L = 1 quando o plantio apresentava alta densidade. Seus valores seguem a mesma interpretação que o NDVI.

$$SAVI = \frac{NIR-RED}{NIR+RED+L} (1 + L) \quad (35)$$

3.15 IAF, FCA, NDVI e SAVI versus graus-dia acumulados (GDA)

Foram comparados os aspectos biofísicos da planta (ABP) com os graus-dia acumulados (GDA) durante as fases fenológicas do feijoeiro. Os modelos matemáticos foram ajustados pela análise de regressão para os ciclos 1 e 2, etapas de modelagem e validação, Figura 37. Para realizar a análise estatística dos modelos, utilizou-se o software R, versão 4.1.1.

Figura 37 – Fluxo de modelagem e validação dos modelos de regressão gerados a partir das relações entre IAF, FCV, SAVI e NDVI com os GDA



3.16 Kc_BH versus GDA, IAF, FCV, NDVI e SAVI

Foram comparados o coeficiente de cultura (Kc_BH) com os GDA, IAF, FCV, NDVI e SAVI obtidos durante as fases fenológicas do feijoeiro. Os modelos matemáticos foram ajustados pela análise de regressão para os ciclos 1 e 2, etapas de modelagem e validação. Para realizar a análise estatística dos modelos, utilizou-se o software R, versão 4.1.1.

3.17 Comportamento do IAF, FCV, NDVI, SAVI e Kc_BH em função do DAE e GDA.

Para descrever comportamento do IAF, FCV, NDVI, SAVI e Kc_BH em função do DAE e GDA, adotaram-se as equações não lineares desenvolvida por Yin *et al.* (2003) para ajustar os modelos de regressão aos dados (Equação 36 e 37).

Segundo Zeviani *et al.* (2013), geralmente, os modelos não lineares são mais vantajosos do que modelos lineares, pois são mais parcimoniosos, apresentam parâmetros providos de interpretabilidade e possibilitam realizar predições fora do domínio observado.

$$y = y_b + (y_e - y_b) \left(1 + \frac{t_e - t}{t_e - t_m} \right) \left(\frac{t}{t_e} \right)^{\frac{t_e}{t_e - t_m}} \quad (36)$$

$$y = y_e \left(\frac{t_e - t}{t_e - t_m} \right) \left(\frac{t}{t_e} \right)^{\frac{t_e}{t_e - t_m}} \quad (37)$$

Em que y é a variável resposta, t é a variável exploratória (tempo ou graus-dia acumulados), em dia ou ° C; y_b é o crescimento inicial no tempo ou no graus-dia acumulados, quando inicia o crescimento t_b ; t_b é o tempo ou graus-dia acumulados que inicia o crescimento, em dia ou ° C; y_e é o crescimento máximo alcançado no tempo ou nos graus-dia acumulados t_e ; t_m é o tempo ou graus-dia acumulados em que ocorre o ponto de inflexão, quando a taxa de crescimento é máxima, em dias ou ° C; t_e é o tempo ou graus-dia acumulados em que o crescimento máximo é alcançado, em dia ou ° C.

3.18 Produtividade e eficiência no uso da água

As análises de produtividade foram realizadas nos “ciclos 1 e 2”, quando a cultura apresentava 84 e 70 DAE, respectivamente. Nesse momento as plantas já apresentavam senescência monocárpica, ou seja, as sementes já se encontravam em completa maturação fisiológica, pois já apresentavam estrias. Para isso, foram coletadas 20 plantas, escolhidas aleatoriamente, dentro da área útil experimental.

Então foram avaliadas: produtividade de grãos (kg ha^{-1}), número de vagens por planta, número de grãos por vagens e peso de 100 grãos (g). Os grãos foram secos à sombra e depois pesados em balança analítica, obtendo assim a produtividade, com 13 % de umidade.

Com os valores médios de produtividade de grãos (kg ha^{-1}) e ETc_{BH} acumulada em (mm) foi possível estimar a eficiência de uso de água pela cultura em (kg m^{-3}), usando a Equação 38.

$$EUA = \frac{\text{Produtividade média dos grãos}}{ETc_{BH} \text{ acumulada}} \quad (38)$$

3.19 Métricas de avaliação estatística

Para avaliar os modelos de aprendizado de máquina RF, SVM e LR foram utilizadas matrizes de confusão para gerar as métricas de avaliação Precisão, Recall e Acurácia, conforme Equações 39, 40 e 41, respectivamente (Mariano, 2021); já o custo levou em consideração o tempo médio, em segundo, para classificar quatro imagens lotes.

Segundo Chawla *et al.* (2002) quando os dados são balanceados, é razoável o uso de taxas de erros como métricas de performance, tais como: precisão, recall e acurácia.

$$Precisão = \frac{VP}{VP+FP} \quad (39)$$

$$Recall = \frac{VP}{VP+FN} \quad (40)$$

$$Acurácia = \frac{VP+VN}{N} \quad (41)$$

Em que VP são os verdadeiros positivos; VN são os verdadeiros negativos; FP são os falsos positivos; FN são os falsos negativos; N são todos os elementos.

3.20 Avaliação de desempenho dos modelos

Foram avaliados os desempenhos dos modelos gerados a partir das relações entre IAF, FCV, NDVI e SAVI com GDA; e também dos modelos gerados a partir das relações entre Kc_BH com GDA, IAF, FCV, NDVI e SAVI, utilizando os seguintes indicadores estatísticos: coeficiente de determinação (R^2), Erro Médio Absoluto (*Mean Absolute Error* – MAE) e Erro Médio Quadrático (*Root Mean Square Error* – RMSE) calculados pelas Equações 42, 43, e 44, respectivamente. Todas as análises estatísticas foram realizadas usando o software R, versão 4.0.

$$R^2 = \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (42)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (43)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (44)$$

Em que y_i são os valores observados; x_i são os valores estimados, n é o número de observações e \bar{y} é a média das observações.

4 RESULTADOS E DISCUSSÃO

4.1 Monitoramento da água no solo pelo método do balanço hídrico, durante a etapa de modelagem

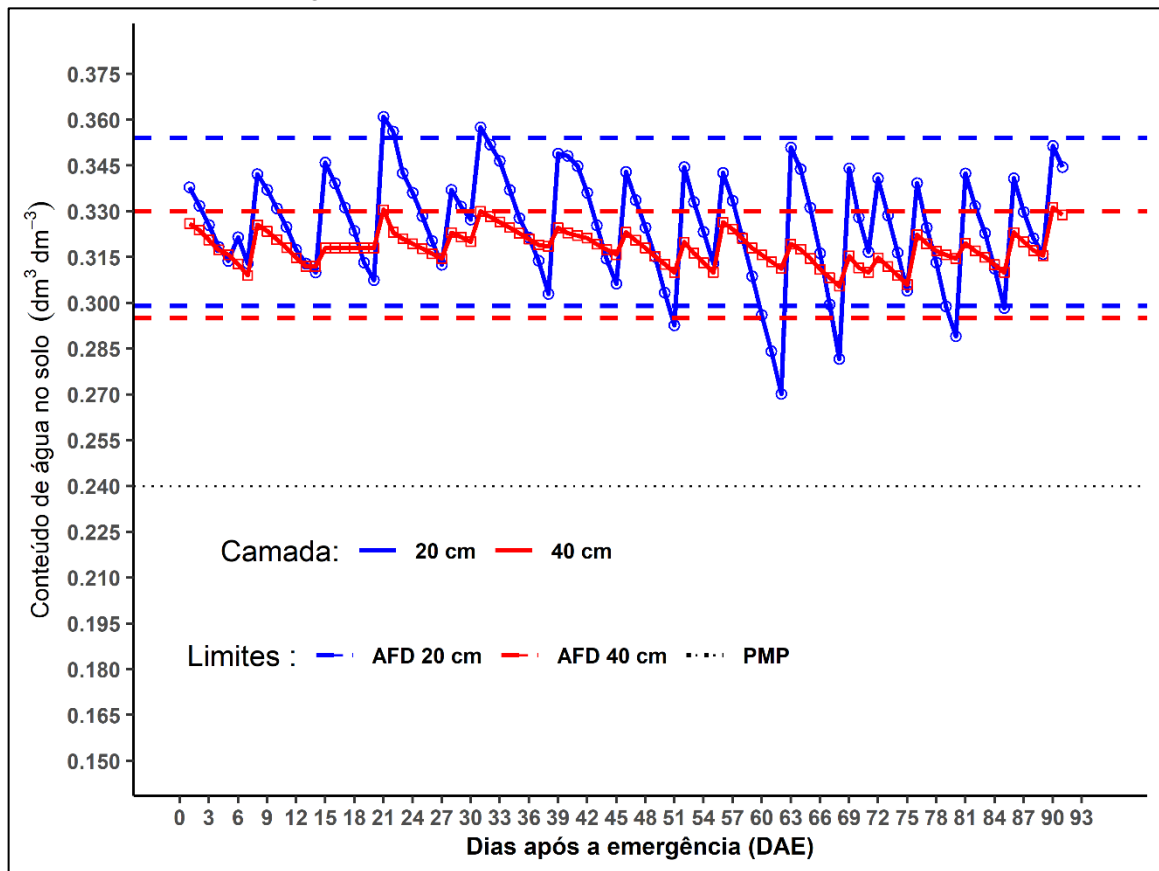
Na Figura 38, observa-se o comportamento do conteúdo de água nas camadas de 0 a 20 cm e 20 a 40 cm, monitorados com uso de tensiômetros. Os tensiômetros instalados na camada de 0 a 20 cm monitoravam o momento de irrigar e nas duas camadas a quantidade de água a ser aplicada.

Segundo Conceição (2010), no manejo por balanço hídrico no solo, o ideal é que o conteúdo de água no solo esteja na faixa da água facilmente disponível (AFD), evitando assim, o déficit hídrico da planta.

Nesse sentido, buscou-se manter a variação do conteúdo de água nas duas camadas dentro da faixa da AFD, Figura 38. Entretanto, na camada de 0 a 20 cm, essa condição não foi satisfeita completamente, principalmente, em dois períodos, dos DAE 60 a 62 e DAE 67 e 68, Figura 38, devido à indisponibilidade humana e/ou tecnológica para realização da irrigação. Segundo Conceição (2010), teoricamente, quando o conteúdo de água fica abaixo da AFD, inicia-se um processo de déficit hídrico, com redução da evapotranspiração de cultura, cuja severidade depende da duração e da intensidade da restrição de água. Neste experimento, foram apenas dois períodos de curta duração em que se verificou a umidade abaixo da AFD, não sendo suficiente para impactar significativamente a produtividade da cultura. O processo de déficit hídrico também foi colaborado pela alta exigência hídrica da fase III de enchimento dos grãos.

A variação de umidade na camada de 20 a 40 cm não ultrapassou o limite inferior da AFD. Em ambas as camadas ocorreu percolação profunda, principalmente nas datas DAE 21, 22 e DAE 30, 31, Figura 38, com conteúdo de água no solo acima da capacidade de campo, devido às precipitações registradas, conforme Tabela 12. Segundo Frizzone (2017), quando a precipitação excede a capacidade de campo, ocorre a percolação profunda.

Figura 38 - Monitoramento do conteúdo de água no solo, pelo método do balanço hídrico, durante a etapa de modelagem



O monitoramento de entradas e saídas de água no solo pelo método do balanço hídrico ocorreu durante o período de crescimento e desenvolvimento da cultura, aproximadamente 91 dias, conforme descrito na Tabela 12. O monitoramento teve início no dia 11/05/22, quando as plantas encontravam-se na fase fenológica (I-V2), com as folhas primárias totalmente formadas, conforme suas fases fenológicas descritas na Tabela 10.

Buscou-se manter a umidade do solo dentro do intervalo da AFD, tendo como limite inferior a umidade crítica para as duas profundidades, correspondente ao fator depleção de 0,50. Com isso, a máxima reposição admitida para esse solo foi de 18 mm; sendo assim, precipitações acima desse valor levaram a um excesso de água e conseqüentemente a uma percolação total de 50,91 mm. A lâmina de irrigação aplicada foi de 135,98 mm, enquanto que a contribuição da precipitação efetiva foi de 41,09 mm (precipitação – drenagem). A ETc_{BH} acumulada foi de 168,87 mm, enquanto que a ETo foi de 209,69 mm, Tabela 12.

O consumo acumulado de água pela planta durante suas fases fenológicas foi de: 56,52 mm para fase I, 46,26 mm para fase II, 53,69 mm para fase III e 12,41 mm para fase IV. O consumo de água na fase III correspondem a 31,79% do total de água demandada pela planta durante todo o seu ciclo fenológico e um consumo diário de aproximadamente de 2,56 mm.dia⁻¹, esse resultado foi bastante expressivo quando comparado com a fase I com 1,34 mm.dia⁻¹. Resultado semelhante foi obtido por Junqueira *et al.* (2004), na fase de enchimento dos grãos, com um consumo diário de 2,52 mm dia⁻¹.

Tabela 12 - Balanço hídrico do solo da área experimental, durante a etapa de modelagem, início em 11/05 e término em 09/08/22

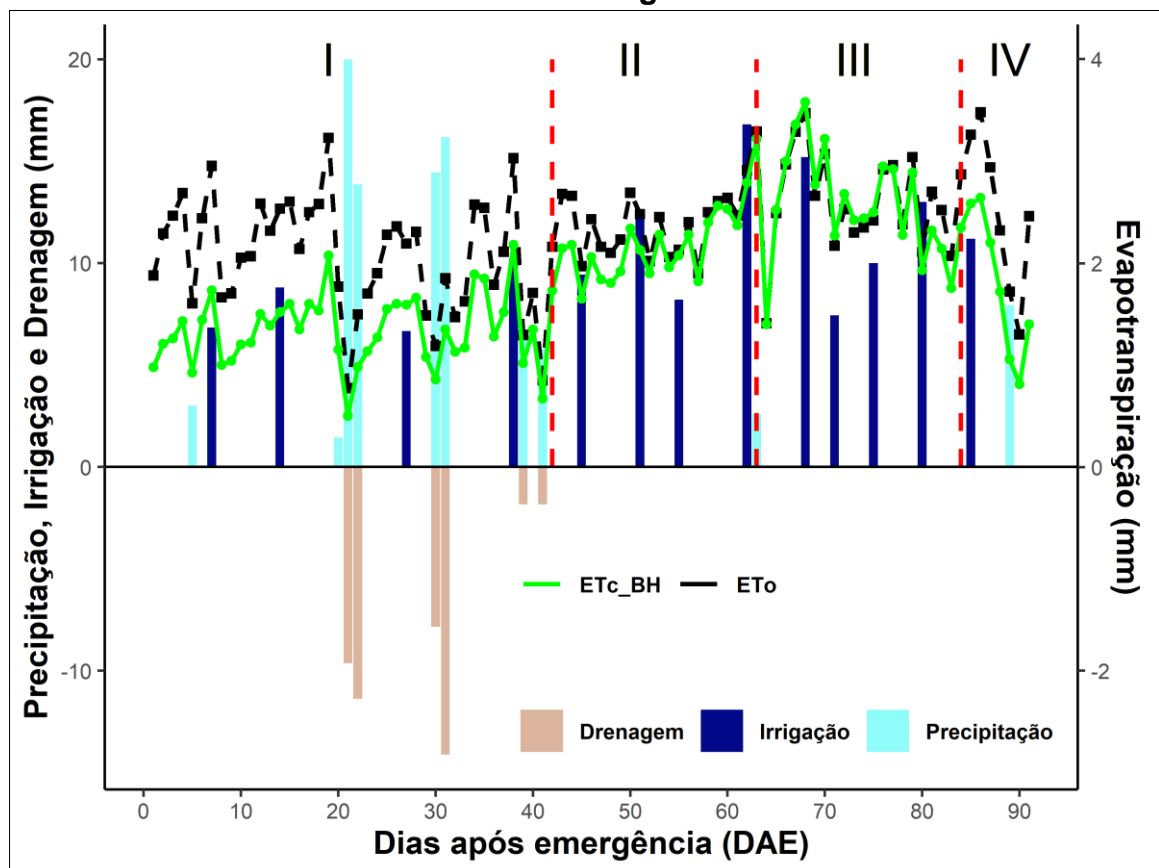
DAE dias	ETo	Irrigação	Precipitação mm	Drenagem	ETc_BH	Kc_BH und
1 – 7	16,32	6,84	3,00	0,00	8,97	0,55
8 – 14	14,92	8,80	0,00	0,00	8,87	0,60
15 – 21	15,59	0,00	21,44	9,64	9,81	0,63
22 – 28	14,23	6,66	13,86	11,38	9,79	0,68
29 – 35	12,73	0,00	30,61	21,96	9,33	0,73
36 – 42	12,94	10,20	12,55	7,93	9,75	0,76
43 – 49	16,23	9,44	0,00	0,00	13,60	0,84
50 – 56	16,23	20,40	0,00	0,00	14,97	0,93
57 – 63	18,32	16,80	2,60	0,00	17,69	0,97
64 – 70	19,36	15,20	0,00	0,00	19,85	1,02
71 – 77	17,65	17,44	0,00	0,00	18,18	1,03
78 – 84	17,69	13,00	0,00	0,00	15,66	0,89
85 – 91	17,48	11,20	7,94	0,00	12,41	0,69
Total	209,69	135,98	92,00	50,91	168,88	

Na Figura 39, observa-se que a evapotranspiração de cultura real ETc_BH, de maneira geral, esteve sempre abaixo da evapotranspiração de referência ETo. Entretanto, na fase III, houve uma inversão, com a ETc_BH sendo igual ou superior a ETo. Bizari *et al.* (2009) e Cunha *et al.* (2013), em condições de plantio direto e

convencional descreveram resultados semelhantes na fase III, argumentando que isso ocorreu em função do maior índice de área foliar e da maior atividade fotossintética.

Nota-se também, de maneira geral, que os eventos de irrigação foram iguais ou inferiores as demandas de ET_{c_BH} , podendo-se afirmar que não houve aplicação em excesso de água por irrigação.

Figura 39 - Monitoramento de entradas e saídas de água do sistema solo-planta-atmosfera, durante o ‘ciclo 1’ na cultura do feijoeiro, segundo suas fases fenológicas




4.2 Graus-dia acumulados (GDA) e fases fenológicas do feijoeiro

Durante o “ciclo 1” etapa de modelagem, a menor temperatura ocorreu no dia 18/05/2022 (3,7 °C), enquanto que a maior foi no dia 05/08/2022 (30,38 °C); a temperatura média durante os 91 dias estudados foi de 19,10 °C. Na Figura 40, observa-se que nas datas: 17/05, 18/05, 19/05, 20/05/ 21/05, 12/06, 13/06, 31/07 e 09/08/2022 as temperaturas mínimas ficaram abaixo da temperatura basal inferior,

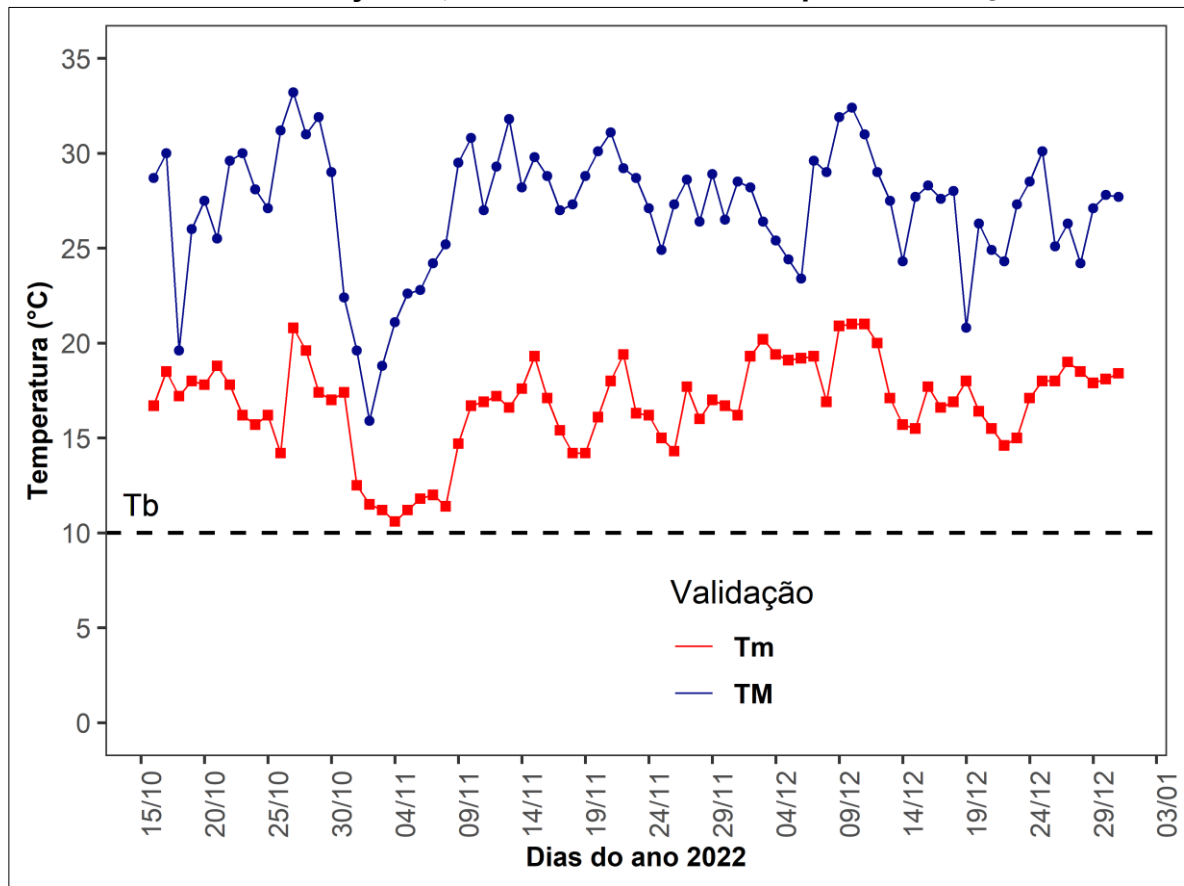
isso ocasionou um aumento em número de dias para a cultura completar o seu ciclo fenológico. Prela e Ribeiro (2002) observaram que em épocas com temperatura mais amenas, o feijoeiro levou maior número de dias para completar seu ciclo fenológico, devido ao menor acúmulo diário de graus-dia.

Figura 40 - Temperaturas mínimas e máximas e basal inferior aferidas na cultura do feijoeiro, durante o “ciclo 1” etapa de modelagem



Durante o “ciclo 2” etapa de validação, a menor temperatura ocorreu no dia 04/11/2022 (10,6 °C), enquanto que a maior foi no dia 27/10/2022 (33,20 °C); a temperatura média durante os 77 dias estudados foi de 21,04 °C. Na Figura 41, observa-se que a temperatura mínima ficou sempre acima da temperatura basal inferior, ocasionando redução no ciclo fenológico da planta. Prela e Ribeiro (2002) também observaram que em épocas com temperatura mais elevadas, o feijoeiro levou menor número de dias para completar seu ciclo fenológico, devido ao maior acúmulo diário de graus-dia.

Figura 41 - Temperaturas mínimas e máximas e basal inferior aferidas na cultura do feijoeiro, durante o “ciclo 2” etapa de validação



O “ciclo 2” etapa de validação, de maneira geral, obteve maior graus-dia acumulados e menor duração em dias para todas as fases fenológicas, o que já era esperado, pois a fase de validação ocorreu na estação climática primavera/verão, quando as temperaturas são naturalmente mais elevadas, conforme Tabela 13. Durante a etapa de validação, a temperatura média foi superior à fase de modelagem em aproximadamente 2° C, o que resultou no maior GDA de 920,85° C e redução na duração de ciclo fenológico de 77 dias. A etapa de validação teve o ciclo fenológico reduzido em 14 dias e um acúmulo termal maior de aproximadamente 56° C, quando comparado a etapa de modelagem. Esses resultados foram condizentes com a pesquisa desenvolvida por Praela e Ribeiro (2002), evidenciando que a variável térmica influencia diretamente na duração do ciclo fenológico da cultura do feijoeiro.

Tabela 13 - Graus-dia acumulados em cada fase fenológica e sua respectiva duração em dias, durante as etapas de modelagem e validação

Fase fenológica	DAE (dias)		GDA (° C)	
	Modelagem	Avaliação	Modelagem	Avaliação
I	42	32	350,03	361,90
II	21	19	219,42	232,75
III	21	19	225,51	238,10
IV	7	7	69,95	88,10
Soma	91	77	864,91	920,85 **

** São diferentes pelo teste t de Student ao nível de 1% de significância.

4.3 Obtenção do índice de área foliares (IAF) por imagem usando métodos de aprendizado de máquina (AM)

4.3.1 Aprendizado de máquinas e métricas em imagens IAF

Os modelos classificadores foram criados a partir dos métodos de Aprendizado de máquina RF, SVM e LR. No ambiente de programação JN foram criados três imagens a partir dos FRI: a) imagem treinamento com 63.000 pixels, que foi convertida em uma matriz com 21.000 linhas e quatro colunas (R, G, B e classes); b) imagem teste com 27.000 pixels, que foi convertida em uma matriz com 9.000 linhas e quatro colunas (R, G, B e classe); c) imagem validação com 180.000 pixels, que foi convertida em matriz com 60.000 linhas e quatro colunas (R, G, B e classe).

Na fase treinamento, os três métodos SVM, RF e LR tiveram ótimos desempenho, na criação dos modelos, com baixos valores de perda (*loss*) (< 0,06) e altos valores de acurácia (> 0,99), Figura 42.

Figura 42 - Criando os modelos de AM a partir dos métodos SVM, RF e LR no ambiente JN

```


1.2.5 Treinando o modelo

model.fit(X_train, y_train, epochs = 10, batch_size = 5, verbose=1)
executed in 40.7s, finished 14:07:52 2023-05-13

Epoch 1/10
4200/4200 [=====] - 4s 922us/step - loss: 0.6005 - categorical_accuracy: 0.9190
Epoch 2/10
4200/4200 [=====] - 4s 933us/step - loss: 0.2808 - categorical_accuracy: 0.9903
Epoch 3/10
4200/4200 [=====] - 4s 946us/step - loss: 0.1835 - categorical_accuracy: 0.9945
Epoch 4/10
4200/4200 [=====] - 4s 937us/step - loss: 0.1362 - categorical_accuracy: 0.9961
Epoch 5/10
4200/4200 [=====] - 4s 948us/step - loss: 0.1083 - categorical_accuracy: 0.9973
Epoch 6/10
4200/4200 [=====] - 4s 953us/step - loss: 0.0900 - categorical_accuracy: 0.9979
Epoch 7/10
4200/4200 [=====] - 4s 959us/step - loss: 0.0770 - categorical_accuracy: 0.9982
Epoch 8/10
4200/4200 [=====] - 4s 956us/step - loss: 0.0674 - categorical_accuracy: 0.9986
Epoch 9/10
4200/4200 [=====] - 4s 959us/step - loss: 0.0599 - categorical_accuracy: 0.9989
Epoch 10/10
4200/4200 [=====] - 4s 958us/step - loss: 0.0540 - categorical_accuracy: 0.9990
    
```

Na fase de teste, os modelos classificadores SVM, RF e LR foram submetidos aos dados de teste (matriz com 9.000 linhas e quatro colunas), o resultado gerado pelo modelo classificador foi expresso em uma matriz de confusão. Na Figura 43, observa-se que todos os modelos tiveram desempenhos adequados, acertando praticamente todos os pixels de cada classe. O modelo LR e SVM classificaram erradamente 6 e 1 pixels da classe 2 na classe 0, respectivamente.


Figura 43 - Matriz de confusão gerada a partir dos resultados gerados pelos modelos classificadores



Na fase de validação, os modelos classificadores SVM, RF e LR foram submetidos aos dados de validação (matriz com 20.000 linhas e quatro colunas); o resultado gerado por modelo classificador foi expresso em uma matriz de confusão. Na Figura 44, observa-se que o modelo classificador RF, que no teste acertou 100% das classes, agora classificou erradamente 100% da classe 0 na classe 2; os modelos SVM e LR mostraram-se robustos suficientes em classificar corretamente os pixels de cada classe, sendo que o modelo SVM classificou erradamente apenas sete pixels da classe 0 na classe 2.

O modelo RF foi bastante específico para classificar os dados de treino e teste, mas quando precisou classificar dados desconhecidos (validação) teve baixa performance, classificando erradamente 100% dos pixels da classe '0' na classe 2. Essa discrepância de performance é conhecida como '*overfitting*'. Segundo Kim *et al.* (2019) o modelo RF pode ser susceptível a '*overfitting*' quando é treinado com um pequeno conjunto de dados e pouca característica, que foi o caso desse trabalho.

Figura 44 - Matriz de confusão gerada a partir dos dados de validação para três modelos de aprendizado de máquina



Os modelos LR e SVM tiveram acurácias semelhantes, 1,00 e 0,99, respectivamente, demonstrando que são adequados para classificar essas imagens. Entretanto o tempo gasto (custo) para classificar as imagens presentes na Figura 45 foi bastante distinto, conforme Tabela 14. O modelo LR teve um custo computacional de 130 segundos para classificar a imagem, enquanto que o modelo SVM teve um custo computacional de 886 segundos para classificar a mesma imagem. Isso significa

que o modelo LR consegue classificar, cada imagem, 6,8 vezes mais rápido do que o modelo SVM.

Tabela 14 - Métricas de avaliações dos três modelos classificadores de aprendizado de máquinas, para os dados de validação

Modelo	Classe	Precisão	Recall	Acurácia	Custo (s)
LR	0	1,00	1,00	1,00	130,00
	1	1,00	1,00		
	2	1,00	1,00		
SVM	0	0,99	1,00	0,99	886,00
	1	1,00	1,00		
	2	1,00	0,99		
RF	0	0,00	0,00	0,67	62,75
	1	1,00	1,00		
	2	1,00	0,50		

Segundo Kim *et al.* (2019), o modelo baseado em RNA (LR) promove alta acurácia na predição por sua estrutura de rede profunda, melhores configurações para função custo, otimizador, função de ativação e 'dropout'. Ratificado por Meeradevi *et al.* (2020), que analisando algoritmos e técnicas de AM aplicados à agricultura, concluíram que os algoritmos baseados em RNA apresentaram maiores acurácias nas predições. Os mesmos autores afirmam que o tempo necessário para processar um algoritmo também deve ser considerado, pois expressa qual algoritmo é mais eficiente e mais rápido.

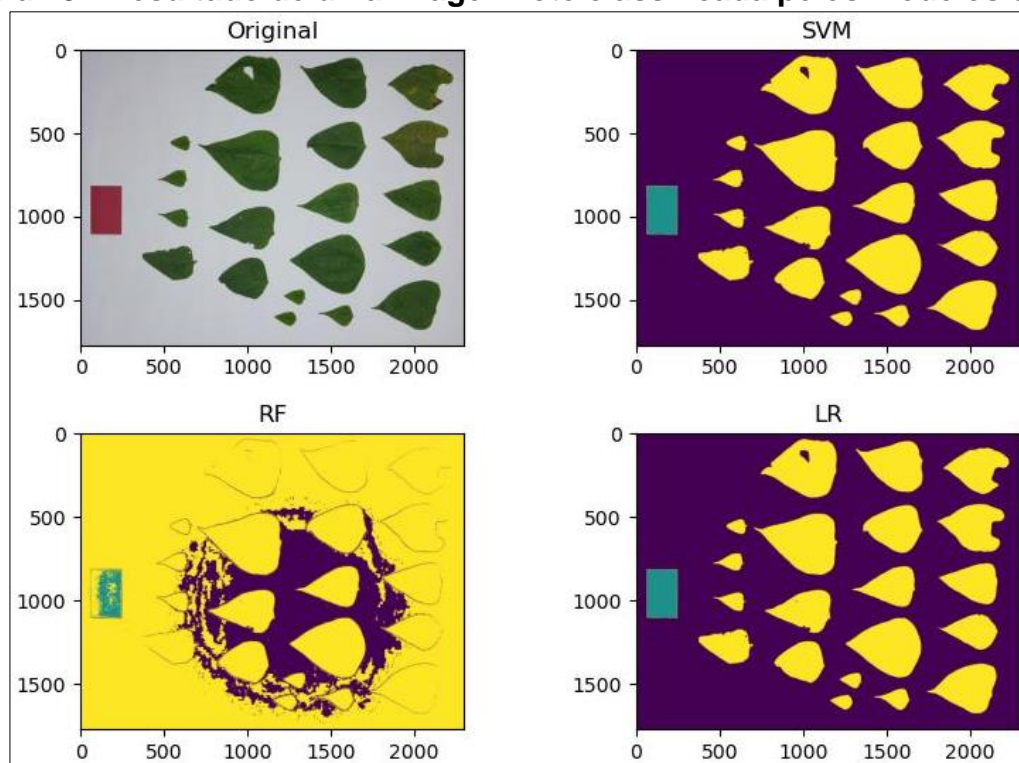
Vakili *et al.* (2020) consideram que os métodos de RNA, por apresentarem estruturas complexas de redes, demandam mais tempo de execução em relação a outros métodos de AM. Contudo nessa avaliação pôde-se observar que o modelo LR teve menor tempo de execução computacional para classificar a imagem, conforme Tabela 14.

Com intuito de melhorar o desempenho do modelo SVM, foi necessário adicionar hiperparâmetro não linear, kernel RBF, ao modelo, penalizando-o com maior custo computacional. Segundo Izbicki e Santos (2020), o uso de kernel pode

ocasionar um tempo computacional maior, uma vez que foi necessário inverter matrizes.

Na Figura 45, pode-se visualizar o desempenho dos modelos SVM, RF e LR na classificação de uma imagem lote, confirmando visualmente os resultados alcançados nas métricas de avaliação.

Figura 45 - Resultado de uma imagem lote classificada pelos modelos de AM

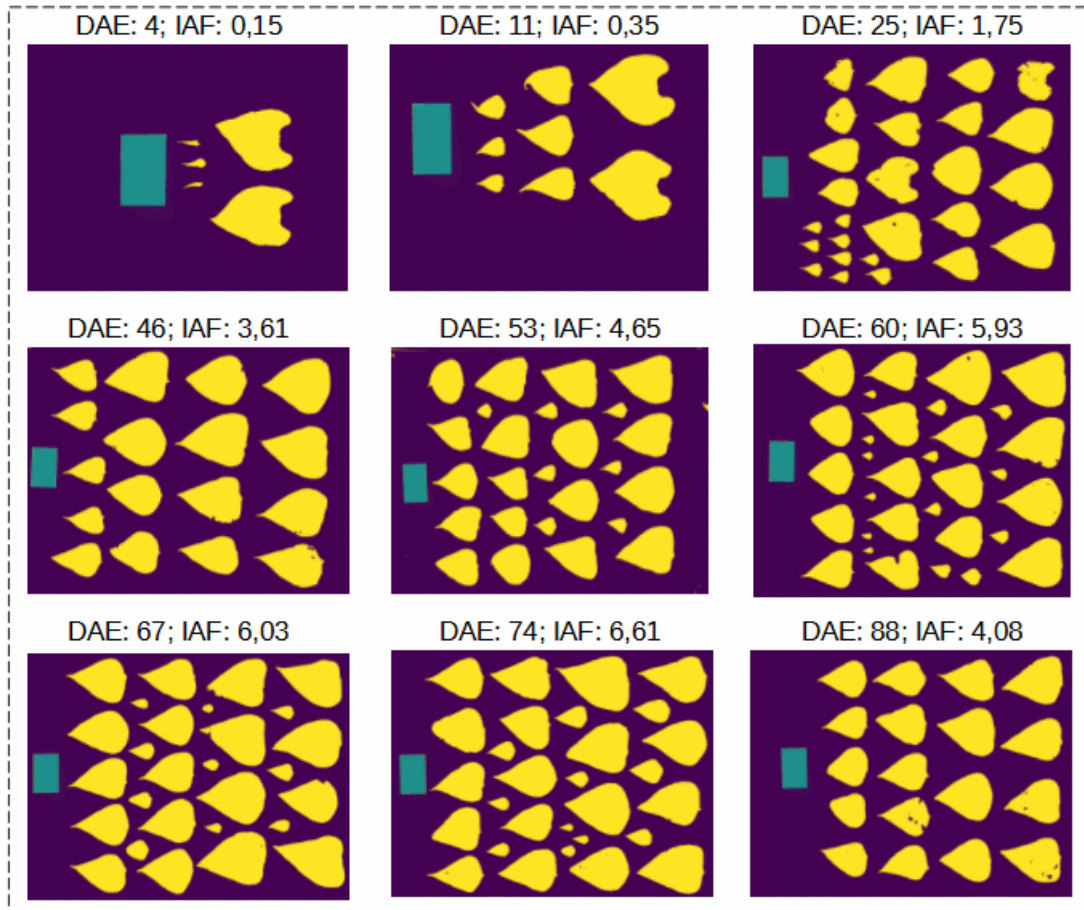


Na Figura 46, constam nove imagens lotes, que representam nove datas de coleta de imagens durante as fases fenológicas do feijoeiro. As nove imagens lotes foram classificadas usando o modelo classificador LR. Na Figura 46, observa-se que modelo LR mostrou-se bastante adequado para classificar as imagens, em 3 classes bem distintas: fundo (cor roxo), referência (cor ciano) e folha (cor amarelo), pertencentes as classes 0, 1 e 2, respectivamente.

Com as imagens já classificadas, foi possível extrair a área foliar e usá-la na Equação 32 para determinar o IAF para o período estudado 'ciclo 1' etapa de modelagem. Na Figura 46, observa-se que no DAE 4 o IAF foi de 0,15 e foi crescendo até alcançar seu maior valor no DAE 74 com IAF de 6,61, a partir de então passou a

decrecer e no DAE 88 o IAF foi de 4,08. Esse comportamento também foi evidenciado por Medeiros *et al.* (2000); Medeiros *et al.* (2001) e Junqueira *et al.* (2004) durante as fases fenológicas do feijoeiro.

Figura 46 - Evolução da IAF durante a etapa de modelagem, usando imagens lotes classificadas pelo modelo classificador LR




4.4 Comparação entre IAF obtido das imagens e o IAF obtido LI-COR 3100

As folhas fotografadas usadas para extrair o IAF com uso de modelo classificador LR de AM, também foram submetidas ao integrador óptico LI-COR 3100 para obtenção de IAF de referência. Na Figura 47, observa-se que ambos os métodos de estimativa da IAF tiveram correlação forte e positiva, com coeficiente de correlação (R) de 0,998, mostrando que a classificação realizada com o modelo LR foi adequada. Martin *et al.* (2013) obtiveram resultados semelhantes na estimativa da IAF do

feijoeiro, correlacionando o método integrador de área foliar LI-COR 3100 com o método imageador que utiliza o software ImageJ, com coeficiente de correlação (R) de 0,937.

Figura 47 - Comparação entre diferentes métodos de estimativa da IAF



4.5 Índice de área foliar IAF versus graus-dia acumulados (GDA)

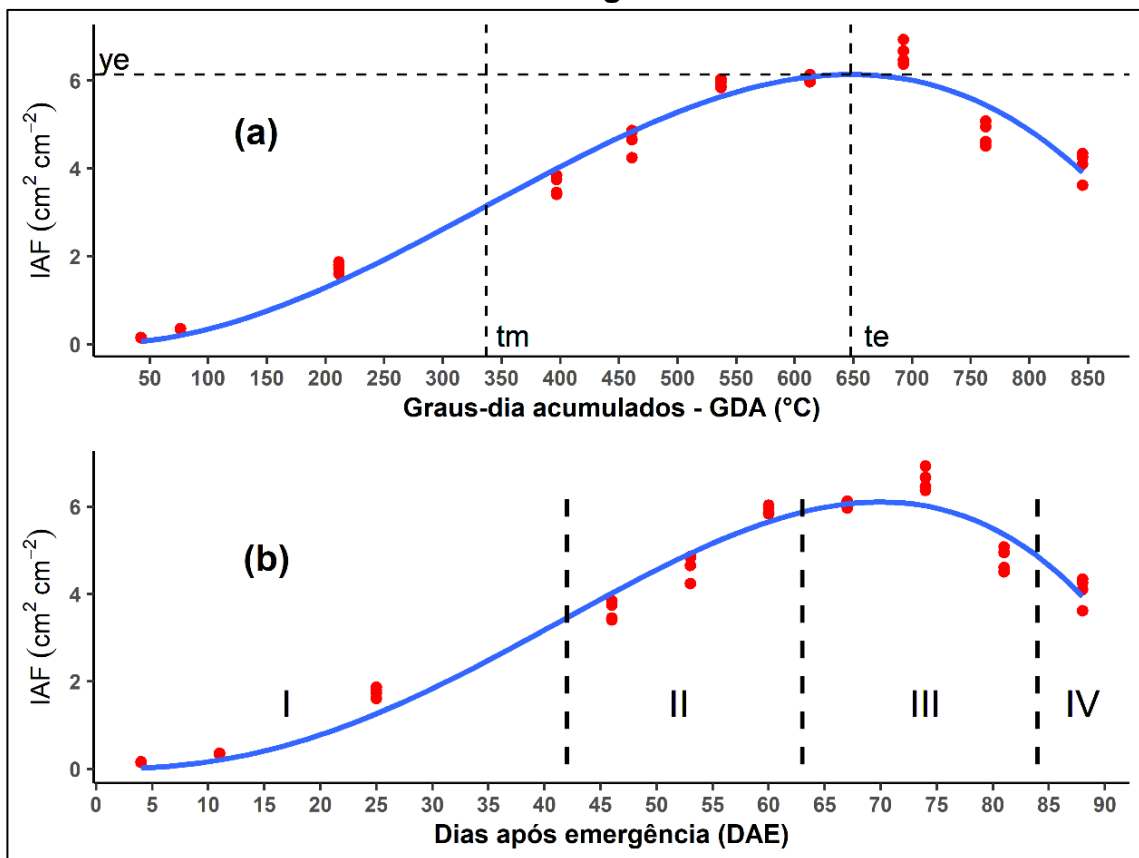
Na Figura 48, pode-se observar o comportamento do IAF em relação aos GDA e aos DAE. Para o ajuste do modelo de regressão utilizou-se a Equação 37, os parâmetros y_b e t_b foram desconsiderados da equação, pois no crescimento inicial o IAF e os graus-dia acumulados são iguais a zero. Os coeficientes do modelo foram ajustados aos dados do IAF em função dos GDA, sendo significativos estatisticamente, com $p\text{-value} < 0,05$ e $R^2 = 0,97$, para os coeficientes: $t_m = 336,74$ °C, $y_e = 6,14$ e $t_e = 647,88$ °C.

Na Figura 48a, O t_m representa o momento em GDA, que ocorre o ponto de inflexão, no qual taxa de crescimento é máxima para IAF (3,14), a partir desse ponto o IAF continua crescendo, mas a menores taxas. No GDA (647,88 °C) ocorre o máximo crescimento de IAF ($y_e = 6,14$), a partir desse ponto o IAF começa a

decrecer, quando ocorre o início do processo de senescência monocárpica. Esse termo foi definido por Taiz e Zeiger (2009) como sendo um processo natural e genético de amarelecimento e morte da planta inteira após um ciclo reprodutivo, mesmo sob condições ótimas de crescimento.

Na Figura 48b, observa-se o comportamento descrito pela equação ajustada em relação aos DAE durante as fases fenológicas. O ponto de inflexão ocorre na fase I de crescimento vegetativo, no DAE (35) e o máximo crescimento de IAF ocorre na fase III de enchimento dos grãos, no DAE (68). Comportamento semelhante de crescimento do IAF foi descrito por Oliveira e Silva (1990), em que IAF inicial foi de $0,41 \text{ cm}^2 \cdot \text{cm}^{-2}$ e o IAF máximo de $3,73 \text{ cm}^2 \cdot \text{cm}^{-2}$ alcançado no DAE 55, coincidindo com a máxima ETc.

Figura 48 – Comportamento do modelo não linear ajustado ao IAF em função dos GDA e DAE, durante as fases fenológicas do feijoeiro, etapa de modelagem



4.6 Obtenção da fração de cobertura vegetal (FCV) por imagem, usando métodos de aprendizado de máquina (AM)

4.6.1 Aprendizado de máquinas e métricas em imagens FCV

Para obtenção da FCV a partir de imagem, adotou-se a mesma metodologia aplicada na obtenção do IAF, agora utilizando apenas duas classes (solo = 0 e vegetal = 1). No ambiente de programação JN foram criadas três imagens a partir dos FRI: a) imagem treinamento com 84.000 pixels, que foi convertida em uma matriz com 28.000 linhas e 4 colunas (R, G, B e classe); b) imagem teste com 36.000 pixels, que foi convertida em uma matriz com 12.000 linhas e 4 colunas (R, G, B e classe); c) imagem validação com 108.000 pixels, que foi convertida em matriz com 36.000 linhas e quatro colunas (R, G, B e classes).

Na fase treinamento, os três métodos SVM, RF e LR tiveram ótimos desempenho, na criação dos modelos, com baixos valores de perda (*loss*) (< 0,2) e altos valores de acurácia (> 0,99), Figura 49.

Figura 49 - Criando os modelos de AM a partir dos métodos SVM, RF e LR no ambiente JN

```

1.2.5 Treinando o modelo

model.fit(X_train, y_train, epochs = 10, batch_size = 5, verbose=1)
executed in 1m 18.3s, finished 16:10:04 2023-04-24


Epoch 1/10
5600/5600 [=====] - 8s 1ms/step - loss: 0.6193 - categorical_accuracy: 0.7865
Epoch 2/10
5600/5600 [=====] - 8s 1ms/step - loss: 0.5076 - categorical_accuracy: 0.9841
Epoch 3/10
5600/5600 [=====] - 8s 1ms/step - loss: 0.4261 - categorical_accuracy: 0.9989
Epoch 4/10
5600/5600 [=====] - 10s 2ms/step - loss: 0.3644 - categorical_accuracy: 0.9997
Epoch 5/10
5600/5600 [=====] - 8s 1ms/step - loss: 0.3167 - categorical_accuracy: 0.9999
Epoch 6/10
5600/5600 [=====] - 6s 1ms/step - loss: 0.2791 - categorical_accuracy: 0.9999
Epoch 7/10
5600/5600 [=====] - 8s 1ms/step - loss: 0.2489 - categorical_accuracy: 0.9999
Epoch 8/10
5600/5600 [=====] - 8s 1ms/step - loss: 0.2243 - categorical_accuracy: 0.9999
Epoch 9/10
5600/5600 [=====] - 8s 1ms/step - loss: 0.2038 - categorical_accuracy: 0.9999
Epoch 10/10
5600/5600 [=====] - 8s 1ms/step - loss: 0.1866 - categorical_accuracy: 0.9999

<keras.callbacks.History at 0x21d4c3fb550>

```

Na fase de teste, os modelos classificadores SVM, RF e LR foram submetidos aos dados de teste (matriz com 12.000 linhas e 4 colunas), o resultado gerado por modelo classificador foi expresso em uma matriz de confusão. Na Figura 50, observe que todos os modelos tiveram desempenhos adequados, acertando praticamente todos os pixels de cada classe. Os modelos LR e SVM classificaram erradamente 1 e 3 pixels da classe 0 na classe 1, respectivamente.


Figura 50 - Matriz de confusão gerada a partir dos dados de teste para três modelos de aprendizado de máquinas



Na fase de validação, os modelos classificadores SVM, RF e LR foram submetidos aos dados de validação (matriz com 36.000 linhas e quatro colunas), o resultado gerado por modelo classificador foi expresso em uma matriz de confusão.

Na Figura 51, observa-se que o modelo classificador RF, que na fase de teste acertou 100% das classes, agora classificou erradamente 6.351 da classe 1 na classe 0, isso é conhecido como '*Overfitting*', ou seja, quando um modelo classificador se ajusta adequadamente aos dados de treinamento e não consegue ter a mesma performance para dados desconhecidos (validação). Segundo Roelofs (2019), um bom classificador tem que ser capaz de aprender adequadamente os dados de treinamento e generalizá-lo para dados ainda não vistos. Os modelos SVM e LR mostraram-se robustos suficientes em classificar corretamente todos os pixels em suas respectivas classes.

Figura 51 - Matriz de confusão gerada a partir dos dados de validação para três modelos de aprendizado de máquinas



Os modelos LR e SVM tiveram acurácias de 1,00, demonstrando que são adequados para classificar essas imagens. Entretanto o tempo gasto (custo) para classificar a imagem presente na Figura 52 foi bastante distinto, conforme Tabela 15.

Tabela 15 - Métricas de avaliações dos três modelos classificadores de aprendizado de máquinas, para os dados de validação

Modelo	Classe	Precisão	Recall	Acurácia	Custo (s)
LR	0	1,00	1,00	1,00	31,00
	1	1,00	1,00		
SVM	0	1,00	1,00	1,00	1087,00
	1	1,00	1,00		
RF	0	1,00	0,74	0,82	11,50
	1	0,65	1,00		

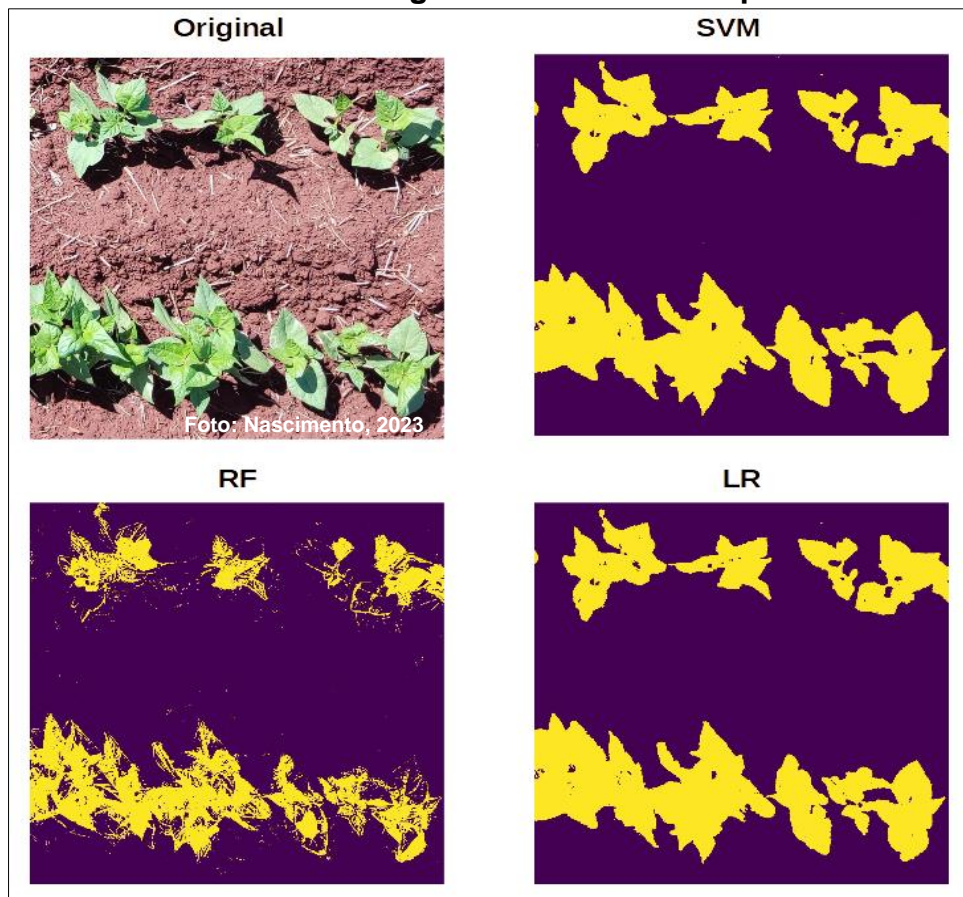
O modelo LR teve um custo computacional em média de 31 segundos para classificar a imagem, enquanto que o modelo SVM teve um custo computacional de 1.087 segundos para classificar a mesma imagem. Isso significa que o modelo LR consegue classificar, cada imagem, 35 vezes mais rápido do que o modelo SVM.

Com intuito de melhorar o desempenho do modelo SVM, foi necessário adicionar hiperparâmetro não linear, kernel RBF, ao modelo, penalizando-o com maior custo computacional. Segundo Izbicki e Santos (2020), o uso de kernel pode

ocasionar um tempo computacional maior, uma vez que foi necessário inverter matrizes.

Na Figura 52, pode-se visualizar o desempenho dos modelos SVM, RF e LR na classificação de uma imagem lote, confirmando visualmente os resultados alcançados nas métricas de avaliação.

Figura 52 – Resultado de uma imagem lote classificada pelos modelos de AM

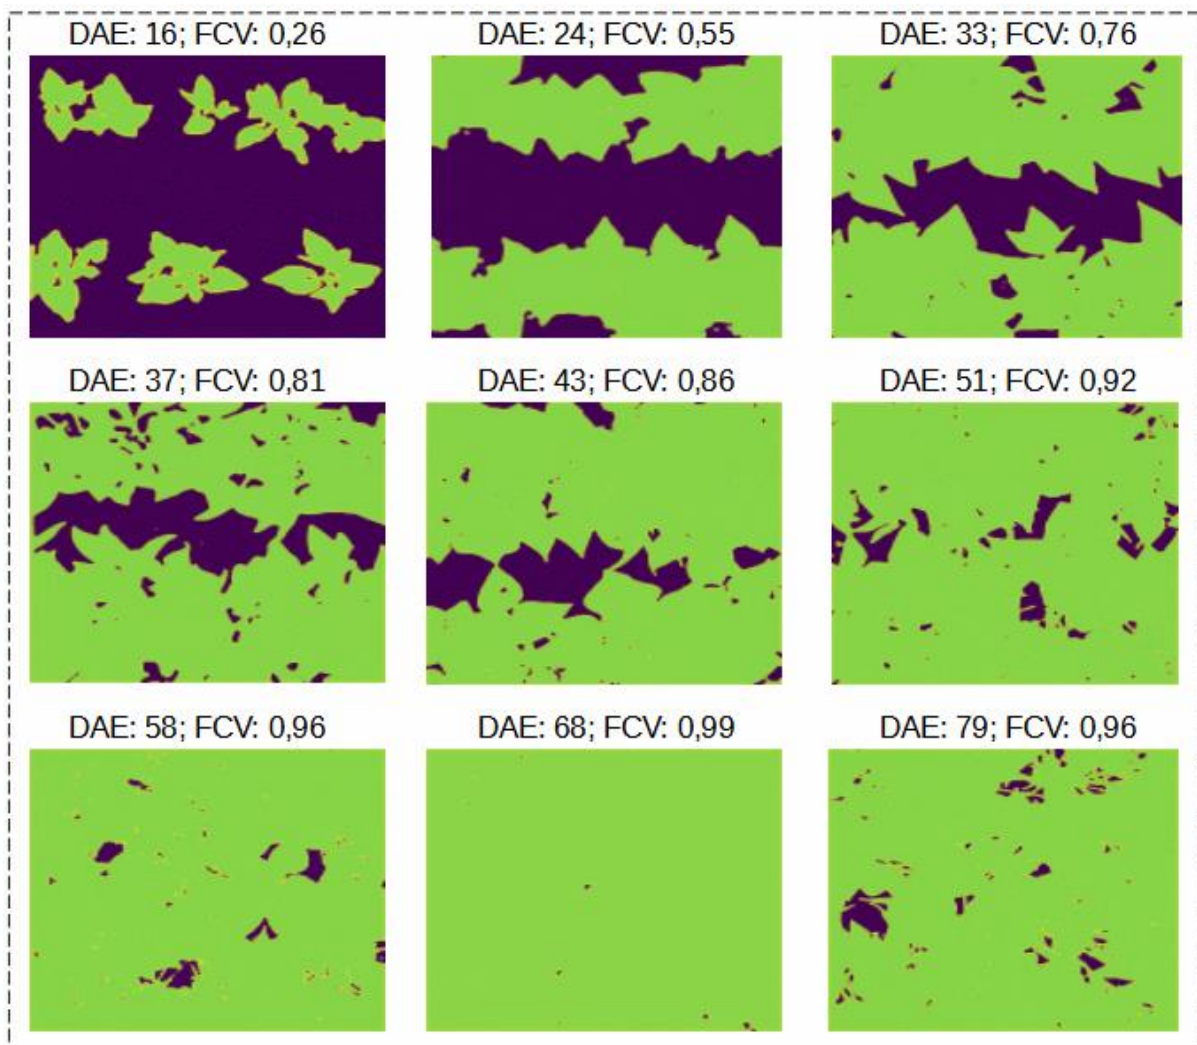


Na Figura 53, constam nove imagens lotes, que representam nove datas de coleta de imagens durante as fases fenológicas do feijoeiro, as nove imagens lotes foram classificadas usando o modelo classificador LR. Na Figura 53, observa-se que modelo LR mostrou-se bastante adequado para classificar as imagens classificando-as em 2 classes bem distintas: solo (cor roxo) e vegetação (cor verde), pertencentes as classes 0 e 1, respectivamente.

Com as imagens já classificadas, foi possível extrair a quantidade de pixel de cada classe e usá-la na Equação 33, e assim determinar a FCV para o período

estudado 'ciclo 1' etapa de modelagem. Na Figura 53, observa-se que no DAE 16 a FCV foi de 0,26 e foi crescendo até alcançar seu maior valor no DAE 68 com FCV de 0,99, a partir de então passou a decrescer e no DAE 79 a FCV foi de 0,96. Esse comportamento também foi evidenciado por Medeiros *et al.* (2000) e Medeiros *et al.* (2001) durante as fases fenológicas do feijoeiro.

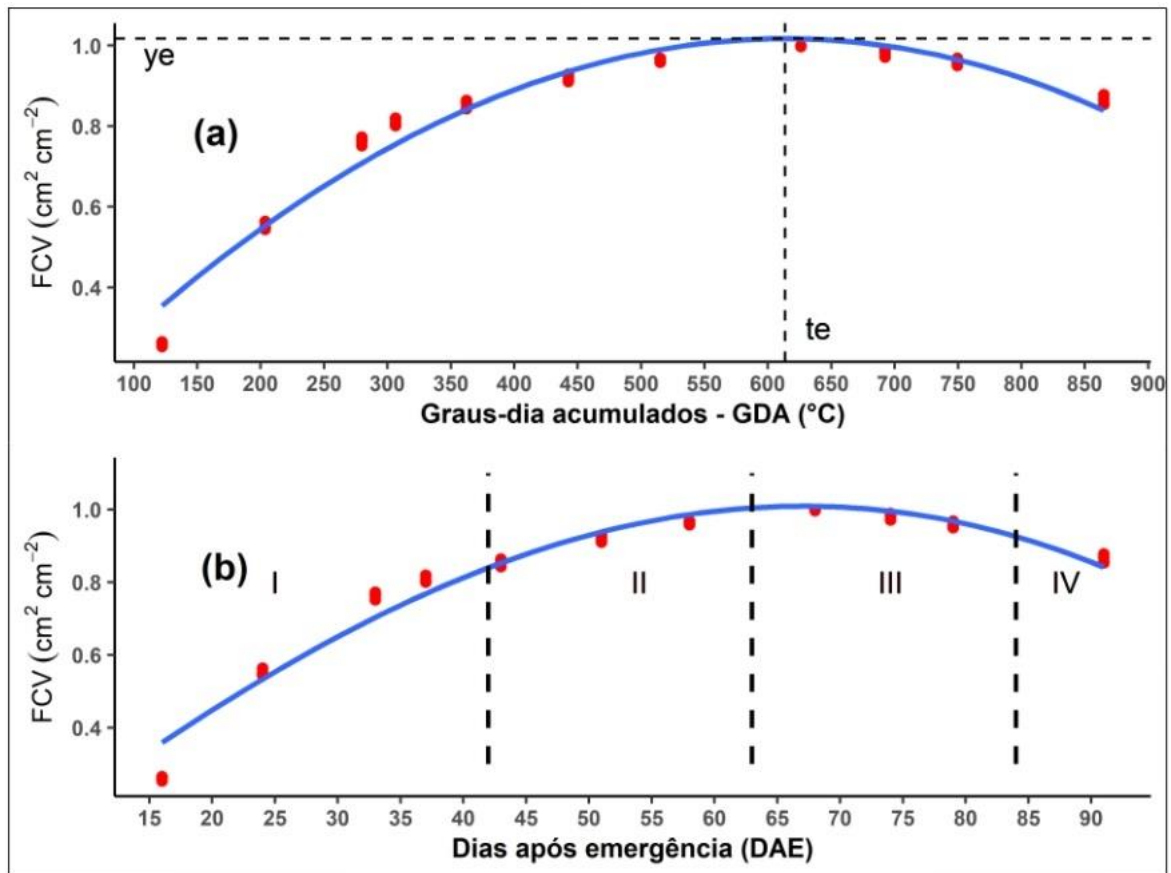
Figura 53 - Evolução da FCV durante a etapa de modelagem, usando imagens lotes classificadas pelo modelo classificador LR



4.6.2 Fração de cobertura vegetal FCV em função de graus-dia acumulados (GDA)

Na Figura 54, pode-se observar o comportamento do FCV em relação aos GDA e aos DAE. Para o ajuste do modelo de regressão utilizou-se a Equação 37, os parâmetros y_b e t_b foram desconsiderados da equação, pois no crescimento inicial a FCV e os graus-dia acumulados são iguais a zero. Os coeficientes do modelo foram ajustados aos dados do FCV em função dos GDA, sendo significativos estatisticamente, com $p\text{-value} < 0,05$ e $R^2 = 0,96$, para os coeficientes: $t_m = 14,75$ °C, $y_e = 1,017$ e $t_e = 613,51$ °C.

Figura 54 – Comportamento do modelo não linear ajustado ao FCV em função dos GDA e DAE, durante as fases fenológicas do feijoeiro, na etapa de modelagem



Na Figura 54a, O coeficiente $t_m = 14,75 \text{ }^\circ\text{C}$, nesse caso, não possui interpretabilidade. No GDA (613,51 $^\circ\text{C}$) ocorre o máximo crescimento da FCV ($y_e = 1,017$), a partir desse ponto a FCV começa a decrescer, quando ocorre o início do processo de senescência monocárpica. Esse termo foi definido por Taiz e Zeiger (2009) como sendo um processo natural e genético de amarelecimento e morte da planta inteira após um ciclo reprodutivo, mesmo sob condições ótimas de crescimento.

Na Figura 54b, observa-se o comportamento descrito pela equação ajustada em relação aos DAE durante as fases fenológicas. O máximo crescimento de FCV ocorre na fase III de enchimento dos grãos, no DAE (66). Comportamento semelhante de crescimento da FCV foi descrito por Medeiros *et al.* (2001).

4.7 Índice de vegetação (NDVI) obtido de imagens multiespectrais


Na Figura 55, constam nove imagens NDVI, que representam nove voos de aquisição de imagens aéreas, durante as fases fenológicas do feijoeiro. A aquisição das imagens foi realizada usando duas câmeras, sendo que as imagens dos DAE 14, 28, 37, 42 e 85 foram capturadas com a câmera Sequoia, enquanto que as imagens dos DAE 49, 57, 65 e 70 foram capturadas com a câmera Mapir, por isso houve variação na resolução espacial das imagens.

No DAE 14 o valor médio do NDVI foi de 0,435, quando o solo ainda estava exposto, nessa condição há alta absorção da radiação no espectro do infravermelho próximo. A partir de então, com o crescimento vegetativo os valores de NDVI também foram aumentando.

Os valores médios de NDVI aumentaram rapidamente, passando de 0,435 no DAE 14 para 0,931 no DAE 49, no início da fase II de floração; a partir de então apresentou pouca variação nos seus valores, diminuindo para 0,897 no DAE 85, no momento da colheita.

Os valores de NDVI saturaram a partir do DAE 49, mostrando-se pouco sensível às mudanças de fases da cultura. Miller *et al.* (2018) e Sampaio *et al.* (2021), avaliando o NDVI nos estádios fenológicos da soja, concluíram que os valores tendem a saturar os pixels nas fases fenológicas com maior densidade do dossel. Resultado também relatado por Bonfil (2017) para cultura do trigo, durante as fases fenológicas com maior cobertura do dossel.

Figura 55 - Evolução espacial e temporal do NDVI, durante a etapa de modelagem

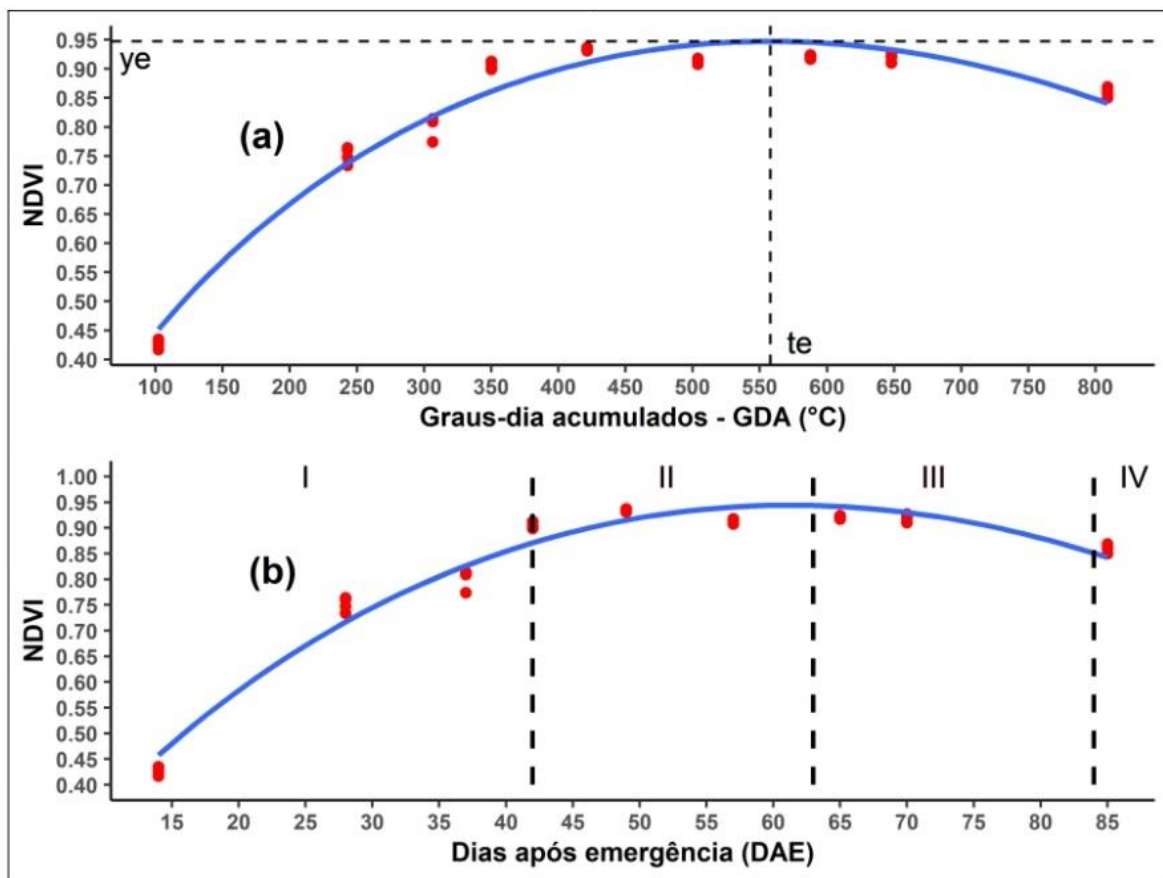


4.7.1 Relação do NDVI com o GDA

Na Figura 56, pode-se observar o comportamento do NDVI em relação aos GDA e aos DAE. Para o ajuste do modelo de regressão utilizou-se a Equação 37, os parâmetros y_b e t_b foram desconsiderados da equação, pois no crescimento inicial o NDVI e os graus-dia acumulados são iguais a zero. Os coeficientes do modelo foram ajustados aos dados do NDVI em função dos GDA, sendo significativos estatisticamente, com $p\text{-value} < 0,05$ e $R^2 = 0,97$, para os coeficientes: $t_m = -234,6$, $y_e = 0,947$ e $t_e = 557,8$ °C.

Na Figura 56a, o coeficiente $t_m = -234,6$ não possui interpretabilidade. No GDA (557,8 °C) ocorre o máximo crescimento NDVI ($y_e = 0,947$), a partir desse ponto o NDVI começa a decrescer lentamente.

Figura 56 - Comportamento do modelo não linear ajustado ao NDVI em função dos GDA (a) e DAE (b), durante as fases fenológicas do feijoeiro, na etapa de modelagem



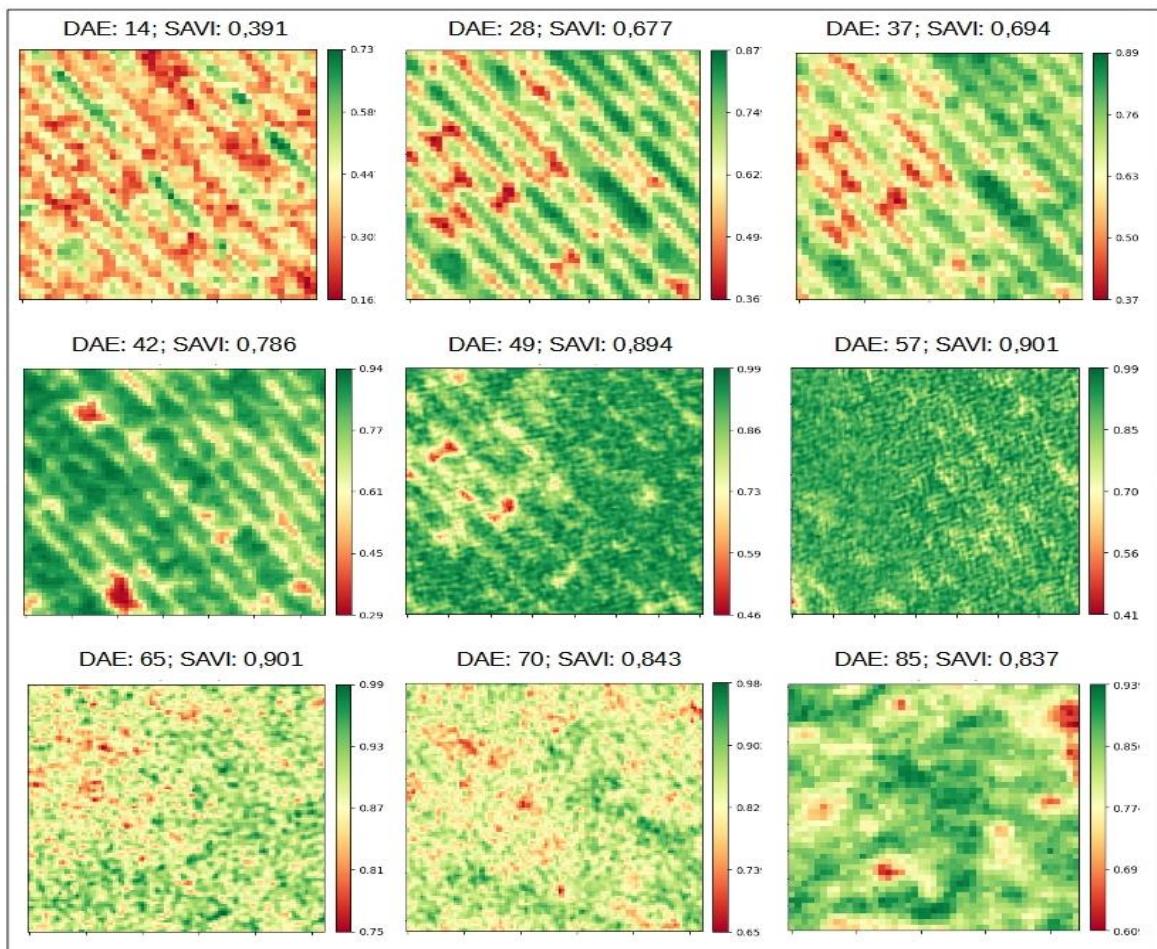
Na Figura 56b, observa-se o comportamento descrito pela equação ajustada em relação aos DAE durante as fases fenológicas. O máximo crescimento do NDVI ocorreu na fase II de floração e formação das vagens, no DAE (61). Segundo Epiphanyo *et al.* (1996) a resposta espectral do solo interfere no valor do NDVI, pois é mais sensível ao espectro vermelho do que ao infravermelho, e portanto, uma pequena diminuição na reflectância do solo no espectro vermelho faz com que aumente o valor desse índice, levando-o a saturação. Já Safre *et al.* (2021) afirmam que o Nitossolo Vermelho Distroférico possui correlação negativa entre a banda do

vermelho e a umidade do solo, ou seja, quanto mais úmido menor reflectância nessa faixa do espectro eletromagnético.

4.8 Índice de vegetação (SAVI) obtidos de imagens multiespectrais

Na Figura 57, constam nove imagens SAVI, que representam nove voos de aquisição de imagens aéreas, durante as fases fenológicas do feijoeiro. A aquisição das imagens foi realizada usando duas câmeras, sendo que as imagens dos DAE 14, 28, 37, 42 e 85 foram capturadas com a câmera Sequoia, enquanto que as imagens dos DAE 49, 57, 65 e 70 foram capturadas com a câmera Mapir, por isso há variação na resolução espacial das imagens.

Figura 57 - Evolução espacial e temporal do SAVI, durante a etapa de modelagem



No DAE 14 o valor médio do SAVI foi de 0,391, quando o solo ainda estava exposto, nessa condição há alta absorção da radiação no espectro do infravermelho próximo, a partir de então, com o crescimento vegetativo, os valores de SAVI também foram aumentando.

Os valores médios de VI foram crescentes, passando de 0,391 no DAE 14 (menor valor) para 0,901 no DAE 65 (maior valor), na fase III de enchimento dos grãos; a partir de então começou a decrescer, diminuindo para 0,837 no DAE 85, no momento da colheita.

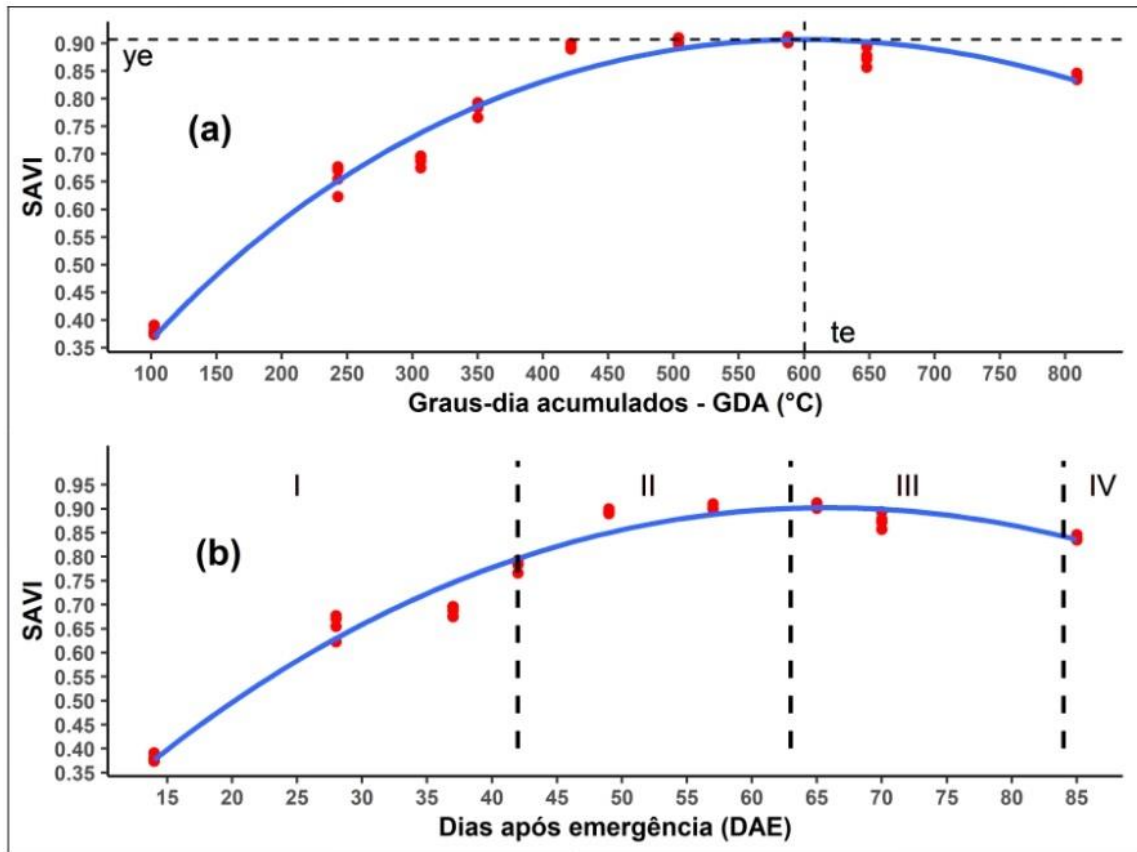
4.8.1 Relação do SAVI com o GDA

Na Figura 58, pode-se observar o comportamento do SAVI em relação aos GDA e aos DAE. Para o ajuste do modelo de regressão utilizou-se a Equação 37, os parâmetros y_b e t_b foram desconsiderados da equação, pois no crescimento inicial o SAVI e os graus-dia acumulados são iguais a zero. Os coeficientes do modelo foram ajustados aos dados do SAVI em função dos GDA, sendo significativos estatisticamente, com $p\text{-value} < 0,05$ e $R^2 = 0,97$, para os coeficientes: $t_m = -156,1$, $y_e = 0,907$ e $t_e = 600,3$ °C.

Na Figura 58a, o coeficiente $t_m = -156,1$ não possui interpretabilidade. No GDA (600,3 °C) ocorre o máximo crescimento SAVI ($y_e = 0,907$), a partir desse ponto o SAVI começa a decrescer lentamente.

Na Figura 58b, observa-se o comportamento descrito pela equação ajustada em relação aos DAE durante as fases fenológicas. O máximo crescimento do SAVI ocorreu na fase III de enchimento dos grãos, no DAE (65). Os valores médios do SAVI foram menores que os valores médios do NDVI, mostrando-se mais sensível as mudanças das fases fenológicas da cultura, isso foi possível pela incorporação do fator de ajuste 'L', proposto por Huete (1988), que atenua os efeitos radiométricos da presença do solo. Segundo Gontia e Tiwari, 2009, o SAVI foi capaz de detectar a variabilidade espacial em todos os estádios fenológicos para a cultura do trigo; ratificado por Safanelli *et al.* (2014) para a cultura da soja.

Figura 58 - Comportamento do modelo não linear ajustado ao SAVI em função dos GDA e DAE, durante as fases fenológicas do feijoeiro, na etapa de modelagem



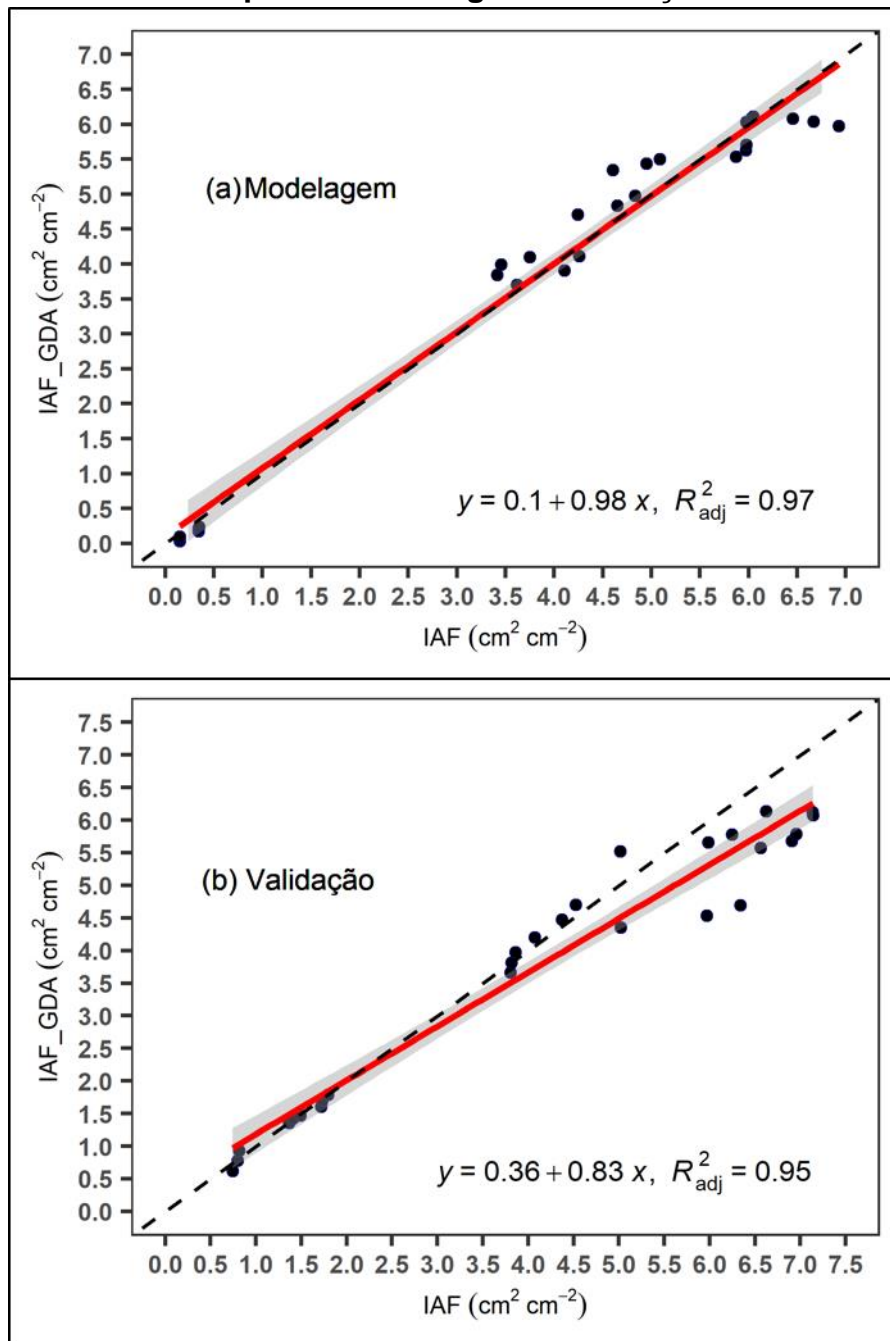
4.9 Desempenho dos modelos de regressão

4.9.1 IAF versus GDA

Com o modelo matemático ajustado aos dados foi possível estimar os valores de IAF em função dos GDA e depois compará-los com os valores de IAF observados durante as etapas de modelagem e validação. A comparação foi realizada usando análise de regressão linear e os resultados estão presentes nas Figuras 59a e 59b. Na etapa de modelagem (Figura 59a), visivelmente há correlação alta entre o IAF e IAF_GDA, apresentando coeficiente linear próximo de 0 (0,1), coeficiente angular próximo de 1 (0,98) e coeficiente de determinação R^2 de 0,97. Os erros entre valores observados IAF e estimados IAF_GDA foram baixos, com MAE de $0,293 \text{ cm}^2 \text{ cm}^{-2}$ em

suas previsões e RMSE de 0,371 (Tabela 16). Na etapa de validação o modelo apresentou leve tendência de subestimar os valores de IAF, principalmente nas fases fenológicas II e III, em média 10%, com coeficiente angular de 0,83 e R^2 de 0,95; apresentando MAE de 0,448 $\text{cm}^2 \text{cm}^{-2}$ e RMSE de 0,742 (Tabela 16).

Figura 59 - Comparação entre IAF observado e IAF_GDA estimado durante as etapas de modelagem e validação



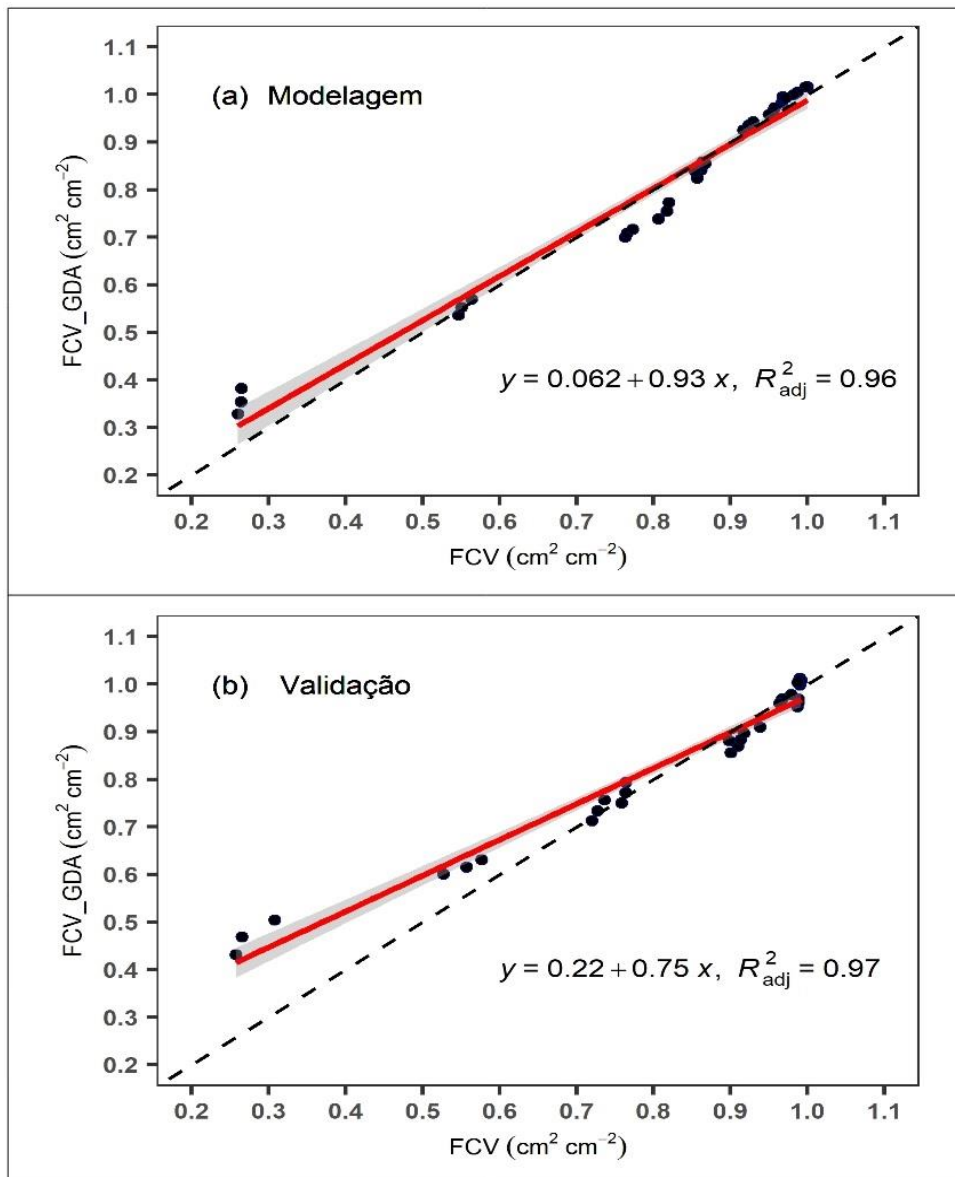
4.9.2 FCV versus GDA

Com o modelo matemático ajustado aos dados foi possível estimar os valores de FCV em função dos GDA e depois compará-los com os valores de FCV observados durante as etapas de modelagem e validação.

A comparação foi realizada usando análise de regressão linear e os resultados estão representados nas Figuras 60a e 60b. Na etapa de modelagem Figura 60a, visivelmente há correlação alta entre o FCV e FCV_GDA, apesar de uma leve superestimação no crescimento inicial, apresentando coeficiente linear próximo de 0 (0,062), coeficiente angular próximo de 1 (0,93) e coeficiente de determinação R^2 de 0,96.

Os erros entre valores observados FCV e estimados FCV_GDA foram baixos, com MAE de 0,030 $\text{cm}^2 \text{cm}^{-2}$ em suas previsões e RMSE de 0,041 Tabela 16. Na etapa de validação o modelo apresentou forte tendência de superestimar os valores de FCV, principalmente na fase fenológica I e IV, em média 19,16%, com coeficiente angular de 0,75 e R^2 de 0,97; apresentando MAE de 0,040 $\text{cm}^2 \text{cm}^{-2}$ e RMSE de 0,067 (Tabela 16).

Figura 60 - Comparação entre FCV observado e FCV_GDA estimado durante as etapas de modelagem e validação

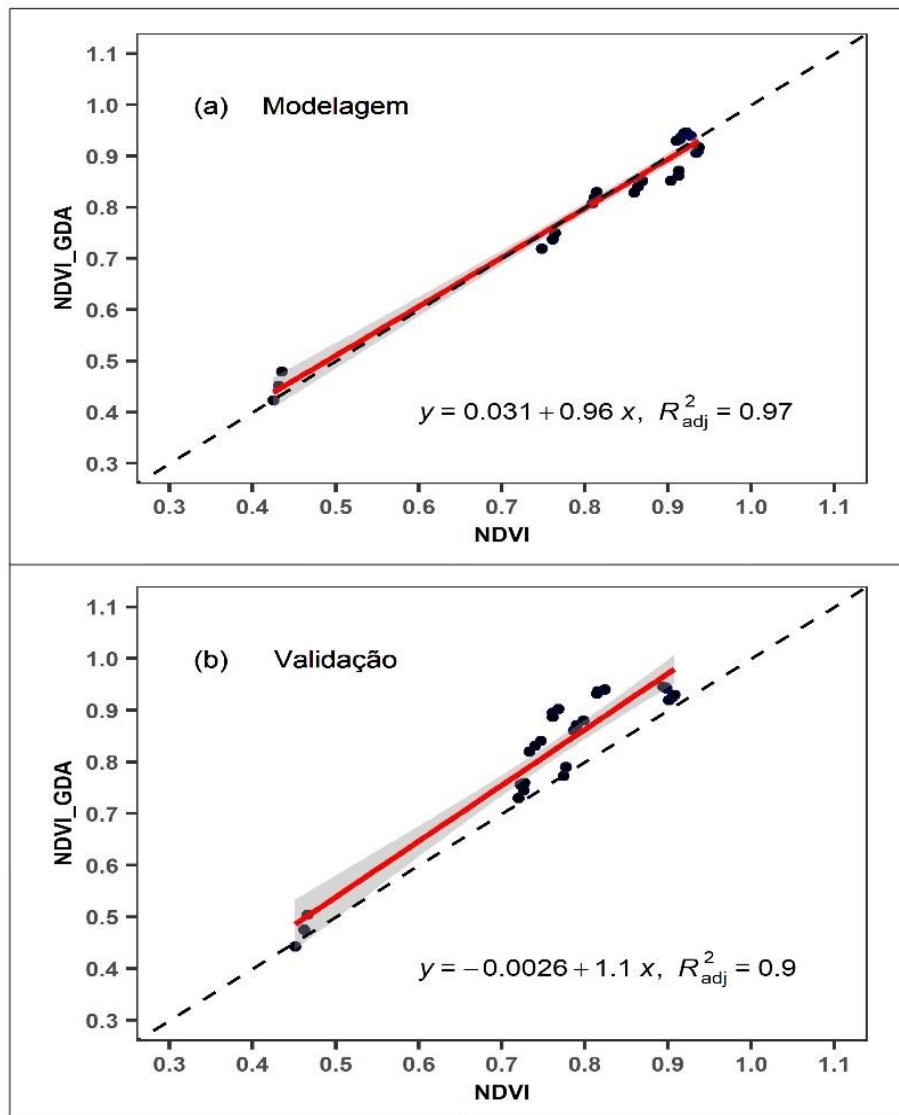


4.9.3 NDVI versus GDA

Com o modelo matemático ajustado aos dados foi possível estimar os valores de NDVI em função dos GDA e depois compará-los com os valores de NDVI observados durante as etapas de modelagem e validação. A comparação foi realizada usando análise de regressão linear e os resultados estão representados nas Figuras 61a e 61b. Na fase de modelagem Figura 61a, visivelmente há correlação alta entre o

NDVI e NDVI_GDA, apresentando coeficiente linear próximo de 0 (0,031), coeficiente angular próximo de 1 (0,96) e coeficiente de determinação R^2 de 0,97.

Figura 61 - Comparação entre NDVI observado e NDVI_GDA estimado durante as etapas de modelagem e validação

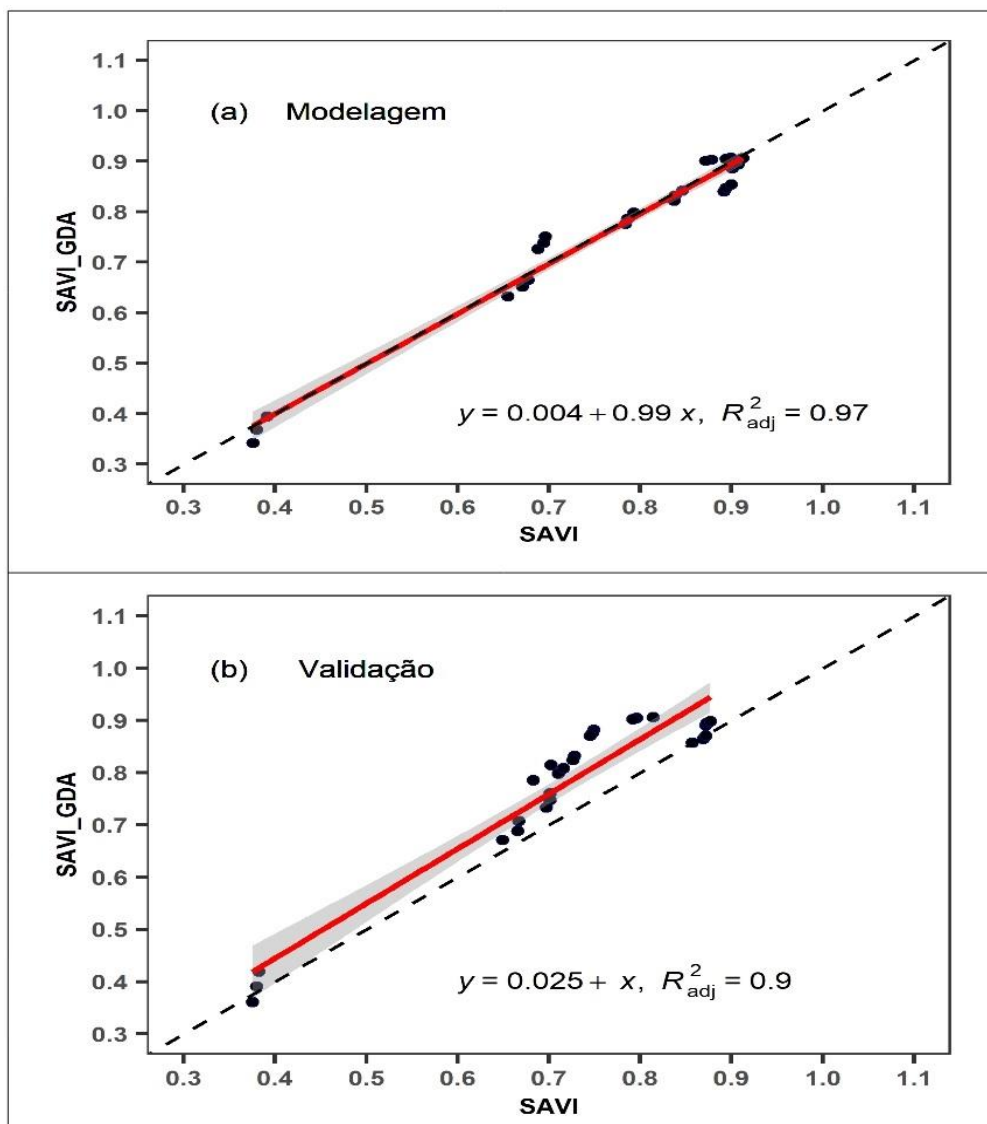


Os erros entre valores observados NDVI e estimados NDVI_GDA foram baixos, com MAE de 0,023 em suas previsões e RMSE de 0,026, Tabela 16. Na fase de validação o modelo apresentou tendência de superestimar os valores de NDVI durante as fases fenológicas, em média 9,7%, com coeficiente angular de 1,1 e R^2 de 0,90; apresentando MAE de 0,061 $\text{cm}^2 \text{cm}^{-2}$ e RMSE de 0,075 (Tabela 16).

4.9.4 SAVI versus GDA

Com o modelo matemático ajustado aos dados foi possível estimar os valores de SAVI em função dos GDA e depois compará-los com os valores de SAVI observados durante as etapas de modelagem e validação.

Figura 62 - Comparação entre SAVI observado e SAVI_GDA estimado durante as etapas de modelagem e validação



A comparação foi realizada usando análise de regressão linear, os resultados estão presentes no gráfico 1:1 nas Figuras 62a e 62b. Na etapa de modelagem Figura

62a, visivelmente há correlação alta entre o SAVI e SAVI_GDA, apresentando coeficiente linear próximo de 0 (0,004), coeficiente angular praticamente 1 (0,99) e coeficiente de determinação R^2 de 0,97. Os erros entre valores observados SAVI e estimados SAVI_GDA foram baixos, com MAE de 0,020 em suas previsões e RMSE de 0,026, Tabela 16. Na etapa de validação o modelo apresentou tendência de superestimar os valores de SAVI durante as fases fenológicas, em média 3,3 %, com coeficiente angular de 1,0 e R^2 de 0,90; apresentando MAE de 0,061 $\text{cm}^2 \text{cm}^{-2}$ e RMSE de 0,076 (Tabela 16).

Tabela 16 – Desempenho dos modelos de regressão linear, comparando os valores observados e estimados, durante as etapas de modelagem e validação

Fase	X	Y	n	Angular	Linear	R^2	MAE	RMSE
Modelagem	IAF	IAF_GDA	27	0,975	0,103	0,978	0,293	0,371
	FCV	FCV_GDA	33	0,926	0,062	0,960	0,030	0,041
	NDVI	NDVI_GDA	27	0,959	0,307	0,970	0,023	0,026
	SAVI	SAVI_GDA	27	0,990	0,004	0,970	0,020	0,026
Validação	IAF	IAF_GDA	27	0,827	0,359	0,950	0,448	0,669
	FCV	FCV_GDA	30	0,754	0,221	0,970	0,040	0,067
	NDVI	NDVI_GDA	27	1,082	-0,003	0,900	0,061	0,075
	SAVI	SAVI_GDA	27	1,048	0,025	0,900	0,061	0,076


4.10 Kc_BH em função dos (DAE) e graus-dia acumulados (GDA)

O modelo matemático ajustado aos dados foi criado a partir da relação não linear entre o Kc_BH e o GDA usando a Equação 36, em que $y = Kc_GDA$, $y_b = 0,582$, $y_e = 1,021$, $t_e = 624,4$ ($^{\circ}\text{C}$), $t_m = 374,2$ ($^{\circ}\text{C}$), $t = \text{GDA}$ ($^{\circ}\text{C}$); e coeficiente de determinação de 0,93.

Na Figura 63a, observa-se os valores de Kc_BH semanais em função dos valores de GDA ajustado ao modelo, todos os coeficientes da Equação 36 foram significativos com p-value < 0,05. O valor de $y_b = 0,582$, significa que no tempo inicial, mesmo com ausência de plantas, o Kc_BH foi no mínimo igual a 0,582. Allen *et al.* (1998) descreveram que no momento inicial do crescimento vegetal, quase que 100 % da evapotranspiração ocorre pelo processo de evaporação da água no solo. O valor

de t_m representa o momento em GDA (374,2 °C) que ocorre o ponto de inflexão, no qual taxa de crescimento da evapotranspiração é máxima para Kc_BH (0,83), a partir desse ponto o Kc_BH continua crescendo, mas a menores taxas. O valor de $y_e = 1,02$, significa que o valor de Kc_BH alcançou seu valor máximo no momento em GDA (624,4 °C), e que a partir de então, a evapotranspiração foi decrescente. Medeiros *et al.* (2000) obtiveram Kc máximo de 1,00 com GDA de 653 °C.

Figura 63 - Comportamento do modelo não linear ajustado ao Kc_BH em função dos GDA e DAE, durante as fases fenológicas do feijoeiro-comum, etapa de modelagem



Na Figura 63b, observa-se o comportamento descrito pela equação ajustada em relação aos DAE durante as fases fenológicas. O ponto de inflexão ocorre na fase I de crescimento vegetativo, no DAE (39) e o máximo crescimento de Kc_BH ocorre na fase III de enchimento dos grãos, no DAE (68). Pode-se informar ainda que no DAE 84, quando se inicia a fase IV de maturação dos grãos, a maioria das plantas

encontravam-se em senescência monocárpica com poucas folhas, apresentando grãos formados e com estrias. Segundo Vieira e Vieira (1997) a maturação fisiológica é o estágio de desenvolvimento em que não ocorre mais aumento de matéria seca na semente. Segundo os mesmos autores o estabelecimento de estrias nas sementes de feijão carioca coincide com a maturação fisiológica. Para Oliveira *et al.* (2018) o final da fase fisiológica III seria o momento propício para a dessecação.

Os valores de coeficiente de cultura médios obtidos por Doorenbos e Kassam (1979), Santana *et al.* (2008) e Fischer Filho e Zocoler (2016), apresentado na Tabela 17, durante as fases fenológicas I, II, III e IV, servem apenas de referência para esta pesquisa, mostrando que os valores médios de Kc_BH observados estão próximo aos valores de referência.

Tabela 17 - Valores de coeficiente de cultura (Kc) médios obtidos por diferentes autores e pela pesquisa atual para diferentes fases fenológicas

Fase	Doorenbos e Kassam (1979)	Santana et al. (2008)	Fischer Filho e Zocoler (2016)	Pesquisa atual (Kc_BH)
I	0,30	0,53	0,67	0,66
II	0,70	0,81	1,06	0,91
III	1,05	1,07	1,12	0,98
IV	0,65	0,78	0,80	0,69


4.11 Relação entre Kc_BH em função do IAF

A relação matemática entre Kc_BH em função do IAF foi estabelecida pela regressão linear simples, Equação 45, presente também na Figura 64, com $a = 0,54$, $b = 0,12$ e $x = \text{IAF}$. Os coeficientes da equação e a análise de variância foram significativos com $p\text{-value} < 0,05$ e com coeficiente de determinação ajustado (R^2) de aproximadamente 0,87.

$$y = a + bx \quad (45)$$

O modelo linear ajustou-se bem aos dados, Figura 64, e a variável independente IAF explica 86 % da variação na variável dependente Kc_BH. O coeficiente linear da Equação 45 representa o Kc_BH inicial (0,54), pois ele existe independentemente do valor de IAF e é devido a evaporação da água no solo, pois no estabelecimento inicial de uma cultura vegetal, a água é perdida, predominantemente por processos evaporativos do solo (Allen *et al.*, 1998). O coeficiente angular é positivo e significa que a cada um IAF aumenta 0,07 em Kc_BH.

Figura 64 - Relação linear entre as variáveis Kc_BH e IAF durante as fases fenológicas do feijoeiro, no “ciclo 1”, etapa de modelagem




4.12 Relação entre Kc_BH em função do FCV

A relação matemática entre Kc_BH em função do FCV foi estabelecida pela regressão exponencial, Equação 46, presente também na Figura 65, com $\alpha = 0,0011$, $\beta = 5,98$, $\theta = 0,63$ e $x = FCV$. Os coeficientes da equação e a análise de variância foram significativos com p-value < 0,05 e com coeficiente de determinação ajustado (R^2) de aproximadamente 0,96.

O modelo exponencial ajustou-se bem aos dados, Figura 65, e a variável independente FCV explica 96 % da variação na variável dependente Kc_BH. O coeficiente θ , da Equação 46, representa o Kc_BH inicial (0,63), pois ele existe independentemente do valor de FCV e é devido a evaporação da água no solo, pois no estabelecimento inicial de uma cultura vegetal, a água é perdida, predominantemente por processos evaporativos do solo (Allen *et al.*, 1998).

$$Kc_{FCV} = \alpha e^{(\beta x)} + \theta \quad (46)$$

Figura 65 - Relação exponencial entre as variáveis Kc_BH e FCV durante as fases fenológicas do feijoeiro, no “ciclo 1”, etapa de modelagem




4.13 Relação entre Kc_BH em função do NDVI

A relação matemática entre Kc_BH em função do NDVI foi estabelecida pela regressão exponencial, Equação 46, presente também na Figura 66, com $\alpha = 0,0004$, $\beta = 7,25$, $\theta = 0,604$ e $x = NDVI$. Os coeficientes da equação e a análise de variância

foram significativos com p-value < 0,05, com coeficiente de determinação ajustado (R^2) de aproximadamente 0,73.

O modelo exponencial ajustou-se bem aos dados, Figura 66, e a variável independente NDVI explica 73 % da variação na variável dependente Kc_{BH} . O coeficiente θ , da Equação 46, representa o Kc_{BH} inicial (0,604), pois ele existe independentemente do valor de NDVI e é devido a evaporação da água no solo, pois no estabelecimento inicial de uma cultura vegetal, a água é perdida, predominantemente por processos evaporativos do solo (Allen *et al.*, 1998).

Figura 66 - Relação exponencial entre as variáveis Kc_{BH} e NDVI durante as fases fenológicas do feijoeiro, no “ciclo 1”, etapa de modelagem




4.14 Relação entre Kc_{BH} em função do SAVI

A relação matemática entre Kc_{BH} em função do SAVI foi estabelecida pela regressão exponencial, Equação 46, presente também na Figura 67, com $\alpha = 0,0049$, $\beta = 4,81$, $\theta = 0,59$ e $x = SAVI$. Os coeficientes da equação e a análise de variância foram significativos com p-value < 0,05, com coeficiente de determinação ajustado (R^2) de aproximadamente 0,79.

O modelo exponencial ajustou-se bem aos dados, Figura 67, e a variável independente SAVI explica 79 % da variação na variável dependente Kc_BH. O coeficiente θ da Equação 46 representa o Kc_BH inicial (0,59), pois ele existe independentemente do valor de SAVI e é devido a evaporação da água no solo, pois no estabelecimento inicial de uma cultura vegetal, a água é perdida, predominantemente por processos evaporativos do solo (Allen *et al.*, 1998).

Figura 67 - Relação exponencial entre as variáveis Kc_BH e SAVI durante as fases fenológicas do feijoeiro, no “ciclo 1”, etapa de modelagem

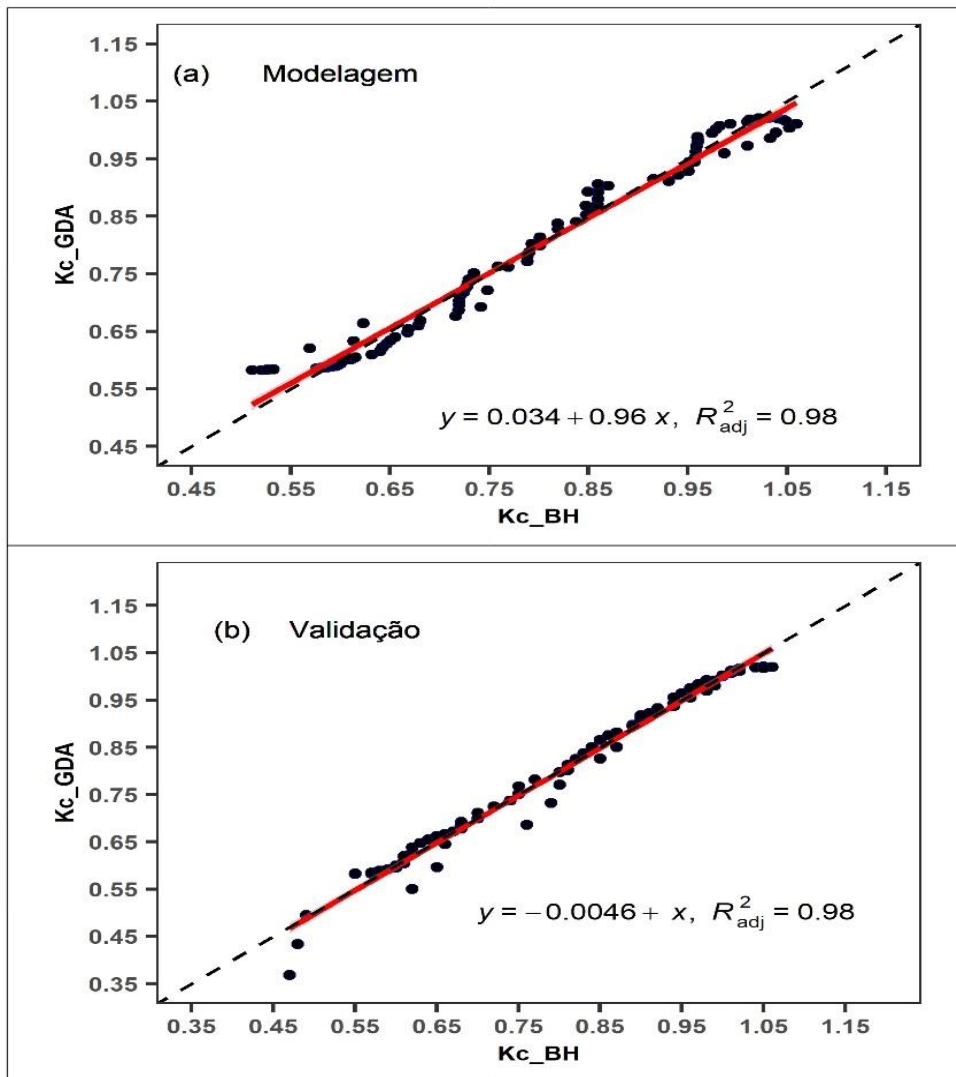


4.15 Desempenho dos modelos de regressão na modelagem e validação

4.15.1 Kc_BH versus Kc_GDA

Com o modelo matemático ajustado aos dados foi possível estimar os valores de Kc_GDA em função dos GDA e depois compará-los com os valores de Kc_BH observados durante as etapas de modelagem e validação.

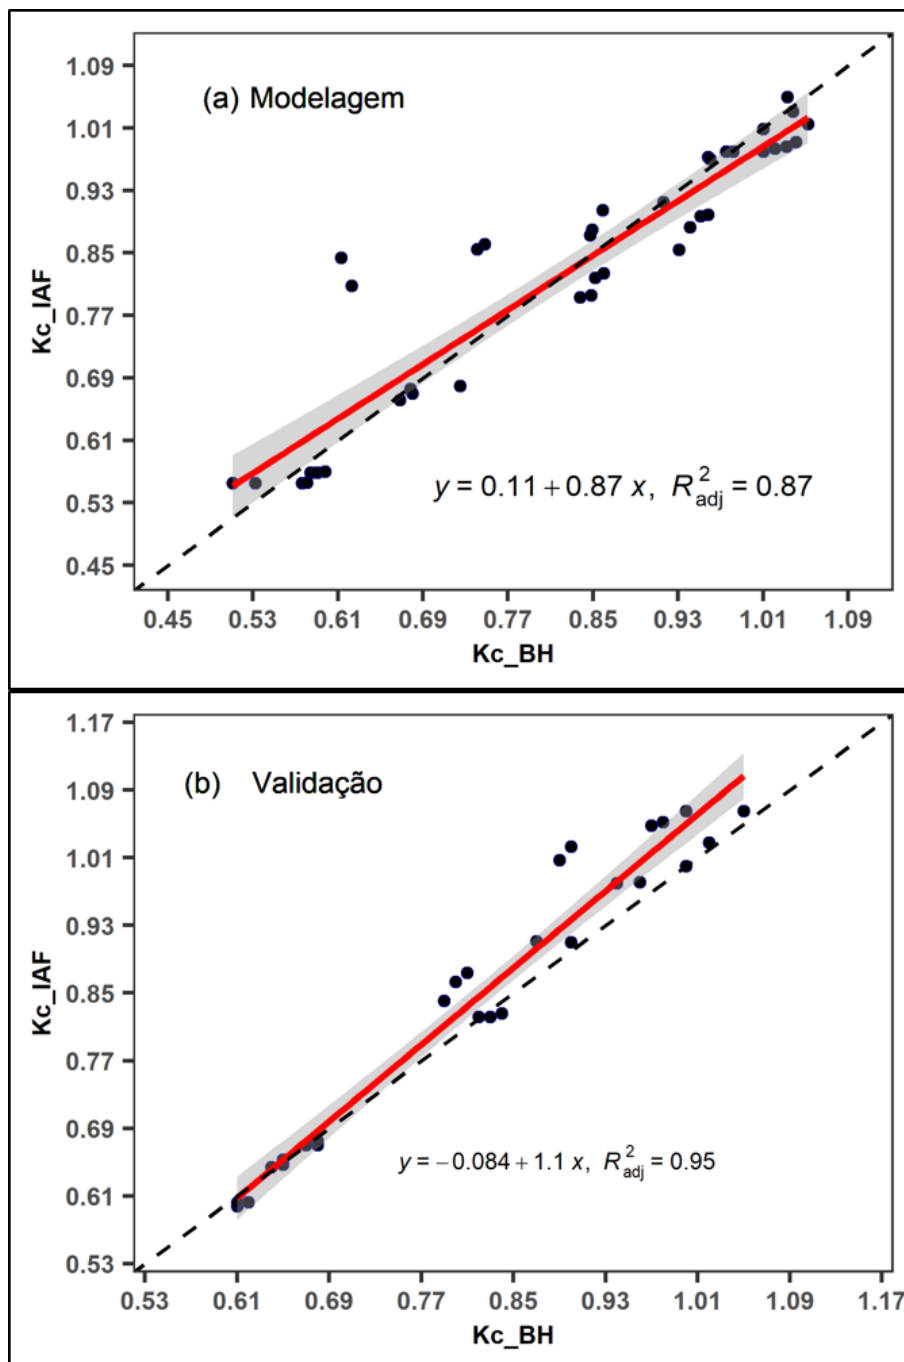
Figura 68 - Comparação entre Kc_BH observado e Kc_GDA estimado durante as etapas de modelagem e validação



A comparação foi realizada usando análise de regressão linear, os resultados estão presentes no gráfico 1:1 na Figura 68a e 68b. Na etapa de modelagem Figura 68a, visivelmente há correlação alta entre o Kc_BH e Kc_GDA, apresentando coeficiente linear próximo de 0 (0,034), coeficiente angular próximo de 1 (0,96) e coeficiente de determinação R^2 de 0,98. Os erros entre valores observados Kc_BH e estimados Kc_GDA foram baixos, com MAE de 0,019 em suas previsões e RMSE de 0,025, Tabela 18. Na etapa de validação o modelo apresentou desempenho adequado, com coeficiente angular de 1,00 e R^2 de 0,98; apresentando MAE de 0,021 e RMSE de 0,024 (Tabela 18).

4.15.2 Kc_BH versus Kc_IAF

Figura 69 - Comparação entre Kc_BH observado e Kc_IAF estimado durante as etapas de modelagem e validação



Com o modelo matemático ajustado aos dados foi possível estimar os valores de Kc_IAF em função dos IAF e depois compará-los com os valores de Kc_BH observados durante as etapas de modelagem e validação.

A comparação foi realizada usando análise de regressão linear, os resultados estão presentes no gráfico 1:1 nas Figuras 69a e 69b. Na etapa de modelagem, Figura 69a, visivelmente há correlação alta entre o Kc_BH e Kc_IAF, apresentando coeficiente linear de (0,11), coeficiente angular de (0,87) e coeficiente de determinação R^2 de 0,87. O modelo teve uma leve tendência de superestimar os valores de Kc_IAF na fase fenológica I e IV, em média 4,7% (3,04 mm), e subestimar nas fases II e III, em média 1,4% (1,35 mm).

Os erros entre valores observados Kc_BH e estimados Kc_IAF foram baixos, com MAE de 0,042 em suas previsões e RMSE de 0,062 Tabela 18. Na etapa de validação o modelo apresentou leve tendência de superestimar os valores de Kc_IAF, em todas as fases fenológicas, em média 1,2% (3,90 mm), com coeficiente angular de 1,13 e R^2 de 0,95; apresentando MAE de 0,032 e RMSE de 0,047 (Tabela 18).

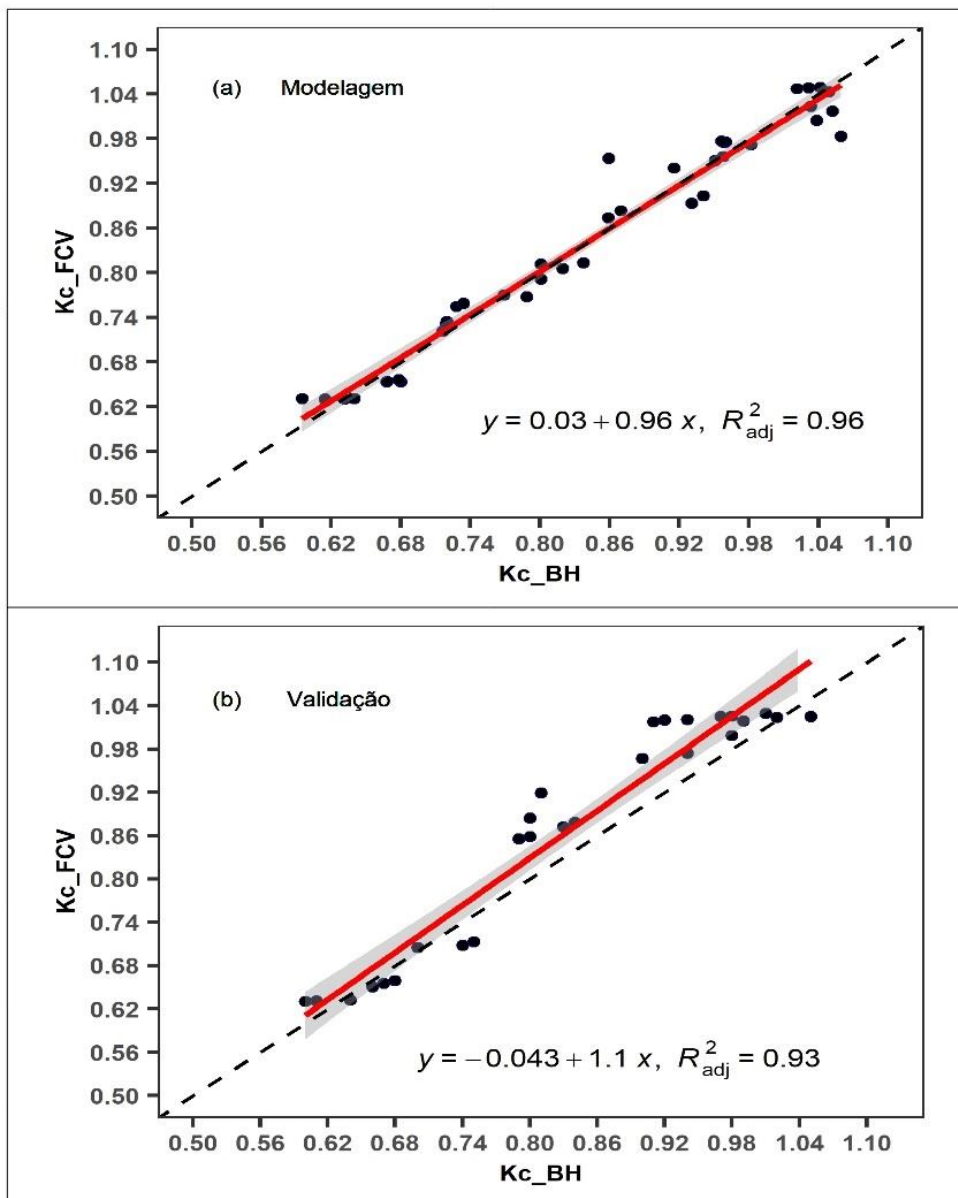
4.15.3 Kc_BH versus Kc_FCV

Com o modelo matemático ajustado aos dados foi possível estimar os valores de Kc_FCV em função dos FCV e depois compará-los com os valores de Kc_BH observados durante as etapas de modelagem e validação.

A comparação foi realizada usando análise de regressão linear, os resultados estão presentes no gráfico 1:1 na Figura 70. Na etapa de modelagem Figura 70a, visivelmente há correlação alta entre o Kc_BH e Kc_FCV, apresentando coeficiente linear de (0,03), coeficiente angular de (0,96) e coeficiente de determinação R^2 de 0,96.

Os erros entre valores observados Kc_BH e estimados Kc_FCV foram baixos, com MAE de 0,020 em suas previsões e RMSE de 0,027, Tabela 18. Na etapa de validação o modelo apresentou leve tendência de superestimar os valores de Kc_FCV, em todas as fases fenológicas, em média 4,3% (12,02 mm), com coeficiente angular de 1,13 e R^2 de 0,93; apresentando MAE de 0,043 e RMSE de 0,053 (Tabela 18).

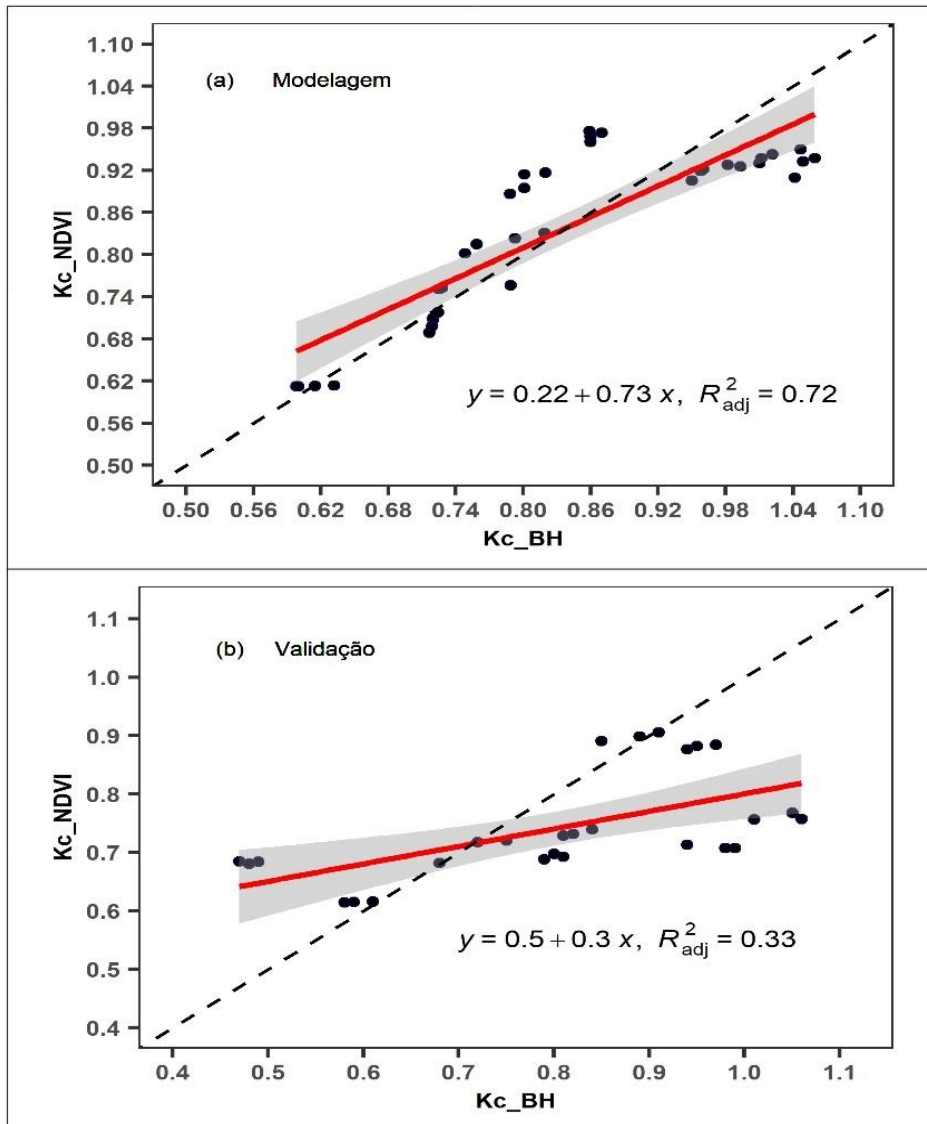
Figura 70 - Comparação entre Kc_BH observado e Kc_FCV estimado durante as etapas de modelagem e validação.



4.15.4 Kc_BH versus Kc_NDVI

Com o modelo matemático ajustado aos dados foi possível estimar os valores de Kc_NDVI em função dos NDVI e depois compará-los com os valores de Kc_BH observados durante as etapas de modelagem e validação.

Figura 71 - Comparação entre Kc_BH observado e Kc_NDVI estimado durante as etapas de modelagem e validação



A comparação foi realizada usando análise de regressão linear, os resultados estão presentes no gráfico 1:1 na Figura 71. Na etapa de modelagem Figura 71a, visivelmente há correlação moderada entre o Kc_BH e Kc_NDVI, apresentando coeficiente linear de (0,22), coeficiente angular de (0,73) e coeficiente de determinação R^2 de 0,72. O modelo teve tendência de superestimar e subestimar os valores de Kc_NDVI em todas as fases fenológicas.

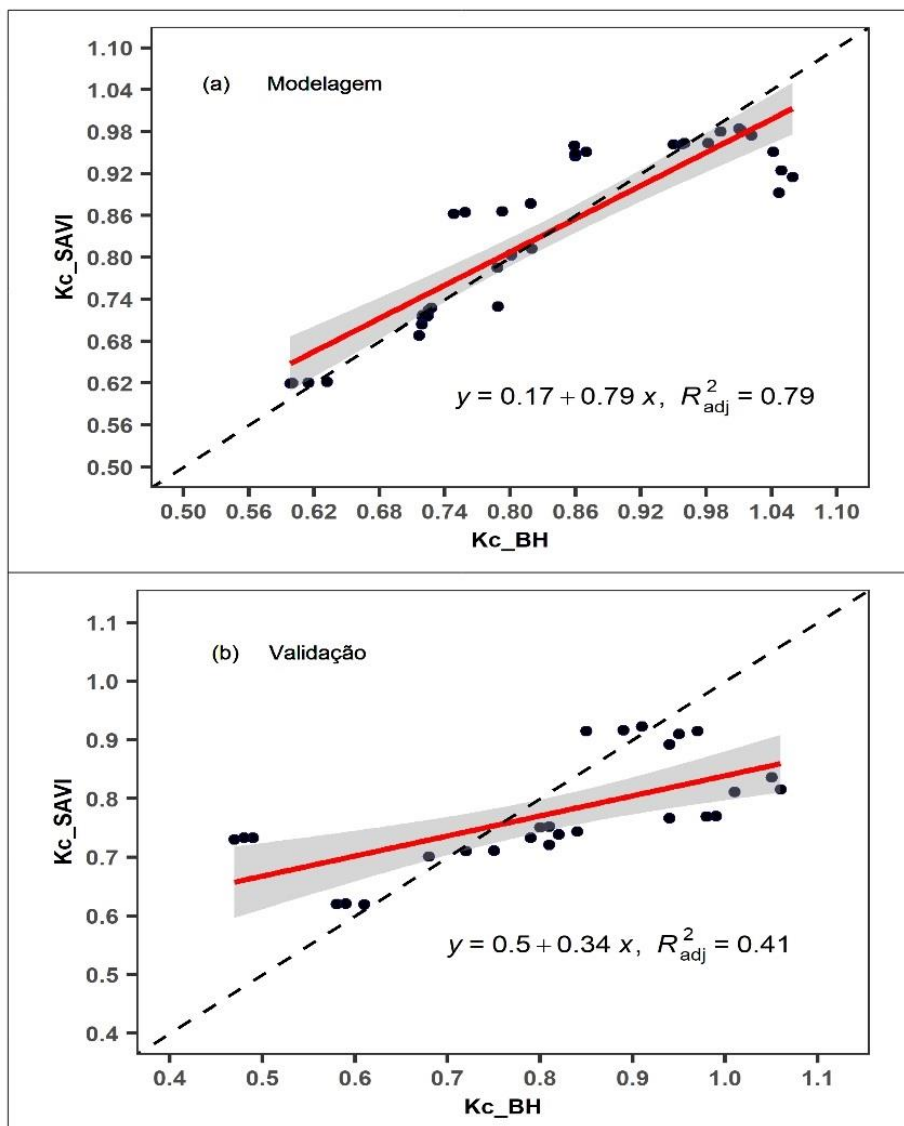
Os erros entre valores observados Kc_BH e estimados Kc_NDVI foram baixos, com MAE de 0,059 em suas previsões e RMSE de 0,072, Tabela 18. Na etapa de validação o modelo teve forte tendência de superestimar e subestimar os valores de

Kc_NDVI em todas as fases fenológicas, com coeficiente angular de 0,3 e R^2 de 0,33; apresentando MAE de 0,118 e RMSE de 0,154 (Tabela 18).

4.15.5 Kc_BH versus Kc_SAVI

Com o modelo matemático ajustado aos dados foi possível estimar os valores de Kc_SAVI em função dos SAVI e depois compará-los com os valores de Kc_BH observados durante as etapas de modelagem e validação.

Figura 72 - Comparação entre Kc_BH observado e Kc_SAVI estimado durante as etapas de modelagem e validação



A comparação foi realizada usando análise de regressão linear, os resultados estão presentes no gráfico 1:1 na Figura 72. Na etapa de modelagem Figura 3a, visivelmente há correlação moderada entre o Kc_BH e Kc_SAVI, apresentando coeficiente linear de (0,17), coeficiente angular de (0,79) e coeficiente de determinação R² de 0,79. O modelo teve tendência de superestimar e subestimar os valores de Kc_SAVI em todas as fases fenológicas.

Os erros entre valores observados Kc_BH e estimados Kc_SAVI foram baixos, com MAE de 0,043 em suas previsões e RMSE de 0,063, Tabela 18. Na etapa de validação o modelo teve forte tendência de superestimar e subestimar os valores de Kc_NDVI em todas as fases fenológicas, com coeficiente angular de 0,34 e R² de 0,41; apresentando MAE de 0,105 e RMSE de 0,137 (Tabela 18).

Tabela 18 - Desempenho dos modelos de regressão linear, comparando os valores observados e estimados, durante as etapas de modelagem e validação

Fase	X	Y	n	Angular	Linear	R ²	MAE	RMSE
Modelagem	Kc_BH	Kc_GDA	91	0,957	0,034	0,980	0,019	0,025
	Kc_BH	Kc_IAF	40	0,872	0,106	0,870	0,042	0,062
	Kc_BH	Kc_FCV	33	0,965	0,030	0,960	0,020	0,027
	Kc_BH	Kc_NDVI	27	0,732	0,224	0,720	0,059	0,072
	Kc_BH	Kc_SAVI	27	0,792	0,174	0,790	0,043	0,063
Validação	Kc_BH	Kc_GDA	77	1,003	0,005	0,980	0,015	0,024
	Kc_BH	Kc_IAF	27	1,134	-0,084	0,950	0,032	0,048
	Kc_BH	Kc_FCV	30	1,090	-0,043	0,930	0,043	0,053
	Kc_BH	Kc_NDVI	27	0,299	0,500	0,330	0,118	0,154
	Kc_BH	Kc_SAVI	27	0,342	0,497	0,410	0,105	0,137

4.16 Eficiência do uso da água e produtividade de grãos da cultura

A produtividade foi estimada levando em consideração 20 plantas m⁻², 0,50 m entre fileiras, com densidade de aproximadamente 200.000 plantas ha⁻¹. Na etapa de modelagem a Etc_BH acumulada foi de 168,87 mm, enquanto que na etapa de validação a ETc_BH acumulada foi de 254,79 mm.

Na Tabela 19, observa-se que na etapa de modelagem a produtividade estimada foi de 4.258,31 kg ha⁻¹, na etapa de validação a produtividade estimada foi de 4.342,14 kg ha⁻¹, não diferindo entre si pelo teste a 5% de probabilidade pelo teste t. A produtividade alcançada está acima da média brasileira que é de 1.110 kg ha⁻¹ (IBGE, 2021), ficando um pouco acima da produtividade encontrada por Junqueira *et al.* (2004), que foi de 3.870 kg ha⁻¹, para o município de Jaboticabal/SP, utilizando uma cultivar IAC - Carioca, cultivada em solo Nitossolo Vermelho Distroférico, fornecendo condições ótimas de adubação, água e sanidade. Santos *et al.* (2022), avaliando o coeficiente de produtividade para a cultivar TAA Dama, para o município de Botucatu/SP, em ambiente controlado (estufa), com fornecimento adequado de adubação, água e sanidade, obtiveram uma produtividade de 4.983,20 kg ha⁻¹. A eficiência no uso da água foi de 2,52 kg m⁻³ e 1,70 kg m⁻³, para as etapas de modelagem e validação, respectivamente, Tabela 19, sendo diferente entre si pelo teste t a 5% de probabilidade. O ciclo de validação ocorreu durante as estações do ano primavera/verão, quando a temperatura foi em média 2 °C acima da temperatura média registrada no ciclo de modelagem (outono/inverno), isso acarretou um aumento da evapotranspiração de 50,9%, diminuindo assim a EUA no ciclo de modelagem. O valor encontrado para a etapa de validação foi um superior ao valor de EUA alcançado por Junqueira *et al.* (2004), que foi de 1,41 kg m⁻³ para cultivar de feijoeiro-comum IAC – Carioca.

Tabela 19 - Componentes de produtividade e eficiência no uso da água para a cultura do feijoeiro obtidos durante as etapas de modelagem e validação

Ciclo	Vagens/planta	Grãos/vagem	Massa 100 grãos	Produtividade	EUA
	(und)	(g)	(g)	kg ha ⁻¹	kg m ⁻³
Modelagem	20,07 a	5,12 a	20,72 a	4.258,31 a	2,52 a
Validação	20,80 a	5,04 a	20,71 a	4.342,14 a	1,70 b

Médias com letras iguais, na vertical, não diferem entre si pelo teste t de Student ao nível de 5%.

5 CONCLUSÕES

O modelo classificador Multiclass Logistic Regression (LR), desenvolvido nesta pesquisa, mostrou-se adequado para classificar os pixels das imagens digitais e extrair os valores de IAF e FCV, com alta acurácia e em menor tempo, ao longo das fases fenológicas da cultura, durante as etapas de modelagem e validação, usando ambiente de programação JN.

O ciclo fenológico da cultivar TAA Dama foi influenciado pelos GDA, sendo que durante a etapa de modelagem a duração do ciclo fenológico foi de 91 dias com GDA de 864,91 °C, enquanto que na etapa de validação a duração do ciclo fenológico foi de 77 dias com GDA de 920,85 °C.

Das relações entre os aspectos biofísicos da planta e GDA foi possível criar quatro equações que possibilitam estimar os valores de IAF_GDA, FCV_GDA, NDVI_GDA e SAVI_GDA. Na etapa de modelagem a relação entre os valores estimados e observados tiveram alta correlação. Na validação, a relação entre os valores estimados e observados também tiveram alta correlação, com uma leve tendência de subestimar os valores de IAF_GDA e superestimar os valores de FCV_GDA, NDVI_GDA e SAVI_GDA.

Das relações entre Kc_BH e os aspectos biofísicos da planta, e Kc_BH e GDA foram possíveis criar cinco equações que possibilitam estimar os valores de Kc_GDA, Kc_IAF, Kc_FCV, Kc_NDVI e Kc_SAVI. Na etapa de modelagem a relação entre os valores estimados e observados tiveram alta correlação. Na validação, a relação entre os valores estimados e observados tiveram alta correlação para Kc_GDA, Kc_IAF, Kc_FCV, e baixa correlação, para Kc_NDVI e Kc_SAVI.

A produtividade em grãos da cultura foi semelhante, enquanto a EUA diferiu estatisticamente, pelo teste t de Student, para as etapas de modelagem e validação.

REFERÊNCIAS

- ALBUQUERQUE, P. E. P.; ANDRADE JÚNIOR, A. S.; SOUZA, F.; SEDIYAMA, G. C.; BEZERRA, J. R. C.; STONE, L. S.; SILVEIRA, P. M. **Coefficiente de cultivo das principais culturas anuais**. Sete Lagoas: Embrapa Milho e Sorgo, 2002, 9p. (Embrapa Milho e Sorgo. Documentos, 52/53).
- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. **Crop Evapotranspiration: guidelines for computing crop water requirements**. FAO Irrigation and Drainage Paper 56, Rome, Italy, 1998.
- AMBROSANO, E. J.; TANAKA, R. T.; MASCARENHAS, H. A. A.; RAIJ, B. V.; QUAGGIO, J. A.; CANTARELLA, H. Leguminosas e oleaginosas. In: RAIJ, B. V.; CANTARELLA, H.; QUAGGIO, J. A.; FURLANI, A. M. C. (ed.). **Recomendações de adubação e calagem para o Estado de São Paulo**. 2.ed. Campinas: IAC, 1997, 285p. (Boletim técnico, 100).
- ANA – Agência Nacional de Águas. **Atlas irrigação: uso da água na agricultura irrigada**. Brasília: ANA, 2017. 86 p.
- ANA – Agência Nacional de Águas. **Levantamento da Agricultura Irrigada por Pivôs Centrais no Brasil (1985-2017)**. 2.ed. Brasília: ANA, 2019. 47 p.
- ANDRADE JÚNIOR, A. S.; BASTOS, E. A.; MONTEIRO, M. M. S.; SILVA JÚNIOR, J. S. Evapotranspiração e coeficiente de cultura do feijão-caupi sob sistema de cultivo convencional e plantio direto. **Agrometeoros, Passo Fundo**, v. 26, n. 1, p. 191-199, jun, 2018.
- ARNOLD, C. Y. The determination and significance of the base temperature in a linear heat units system. **Journal of the American Society for Horticultural Science**, Geneva, v. 74, p. 430-445, 1959.
- BASTOS, E. A.; ANDRADE JÚNIOR, A. S.; SOUSA, V. F. **Manejo da irrigação**. Teresina: EMBRAPA MEIO-NORTE, 2005. 54 P. (EMBRAPA MEIO-NORTE. Documentos, 113).
- BENOS, L.; TAGARAKIS, A. C.; DOLIAS, G.; BERRUTO, R.; KATERIS, D.; BOCKTIS, D. Machine learning in agriculture: a comprehensive updated review. **Sensor**, v. 21, 3758, 2021.
- BIZARI, D. R.; MATSURA, E. E.; ROQUE, M. W.; SOUZA, A. L. Consumo de água e produção de grãos do feijoeiro irrigado em sistemas plantio direto e convencional. **Ciência Rural**, v. 39, n. 7, p. 2073-2079, 2009.

BONFIL, D. J. Wheat phenomics in the field by RapidScan: NDVI vs. NDRE. **Israel Journal of plant Sciences**, v. 64, 2017.

BONINI NETO, A.; BONINI, C. S. B. Redes neurais artificiais: apresentação e utilização do algoritmo perceptron em biosistemas. **BioEng**, v. 4, n. 2, p. 87-95, 2010.

BRANDÃO, Z. N.; ZONTA, J. H.; SHIRATSUCHI. Sensoriamento Remoto na Cultura do Algodão. *In*: TULLIO, L. (Org.). **Aplicações e Princípios do Sensoriamento Remoto**. Ponta Grossa, PR: Atena Editora, 2018. Capítulo 19, p. 209-224.

BREIMAN, L. Bagging predictors. **Machine Learning**, v. 24(2), p. 123-140, 1996.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5-32, 2001.

BRITO, A. S.; LIBARDI, P. L.; MOTA, J. C. A.; MORAES, S. O. Estimativa da capacidade de campo pela curva de retenção e pela densidade de fluxo da água. **R. Bras. Ci. Solo**, v. 35, p. 1939-1948, 2011.

BURROUGH, P. A., McDONNELL, R. A. **Principles of geographical information systems**. Oxford: University Press, 1998.

CALERA, A.; MARTÍNEZ, C.; MELIA, J. A procedure for obtaining green plant cover: Relation to NDVI in a case study for barley. **Int. J. Remote Sensing**, v. 22, p. 3357-3362, 2001.

CANUTO, R.; FANTON, M; LIRA, P. I. C. Iniquidades sociais no consumo alimentar no Brasil: uma revisão crítica dos inquéritos nacionais. **Ciência e Saúde Coletiva**, v. 22 (9), 3193-3212, 2019.

CARVALHO, L. G.; RIOS, G. F. A.; MIRANDA, W. L. CASTRO NETO, P. Evapotranspiração de referência: uma abordagem atual de diferentes métodos de estimativa. **Pesq. Agropec. Trop.** v. 41(3), p. 456-465, 2011.

CARVALHO, R. S.; CARVALHO, J. E. B. **Processamento digital e aprendizado de máquina de imagens aéreas obtidas por aeronaves remotamente pilotadas (RPA) para estimar percentual de cobertura do solo por gramíneas perenes em pomar de citros**. Cruz das Almas, BA: Embrapa Mandioca e Fruticultura, 2022. 45 p. (Embrapa Mandioca e Fruticultura. Boletim de pesquisa e desenvolvimento, 137).

CASTAÑEDA, L.; RAO, P. Comparison of methods for estimating reference evapotranspiration in southern California. **Journal of Environmental Hydrology**, v. 13, paper 14, Jul. 2005.

CHAWLA, N. V.; BOWYER, K. W.; HALL, L. O.; KEGELMEYER, W. P. SMOTE: synthetic minority over-sampling technique. **Journal of Artificial Intelligence Research**, v. 16, p. 321-357, 2002.

COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da safra brasileira – grãos**: quarto levantamento, janeiro 2023 – safra 2022/2023.: Brasília: CONAB. 2023. Disponível em: < https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos/item/download/46113_192029ba72caabcdef42df8abf0eeb90>. Acesso em: 20 fevereiro 2023.

CONCEIÇÃO, M. A. F. **Balço hídrico em fruteiras**. Bento Gonçalves, RS: Embrapa Uva e Vinho, 2010. 12 p. (Embrapa Uva e Vinho. Circular técnica, 82).

CÓRCOLES, J. I.; ORTEGA, J. F.; HERNÁNDEZ, D.; MORENO, M. A. Use of digital photography from unmanned aerial vehicles for estimation of leaf area index in onion (*Allium cepa* L.). **Europ. J. Agronomy**, v. 45, p. 96-104, 2013.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, p. 273-297, 1995.

CUNHA, A. R.; MARTINS, D. Classificação climática para os municípios de Botucatu e São Manoel, SP. **Irriga, Botucatu**, v. 14, n. 1, p. 1-11, jan-mar, 2009.

CUNHA, P. C. R.; SILVEIRA, P. M.; NASCIMENTO, J. L.; ALVES JÚNIOR, J. Manejo da irrigação no feijoeiro cultivado em plantio direto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 17, n. 7, p. 735-742, 2013.

DOOREMBOS, J.; PRUITT, W. O. **Crop water requirements**. ROME: FAO, 1977. 213p. (Irrigation and drainage paper, 24).

DOOREMBOS, J.; KASSAM, A. H. **Yield response to water**. ROME: FAO, 1979. 193p. (Irrigation and drainage paper, 33).

EMBRAPA - EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Sistema brasileiro de classificação de solos**. 5. ed. rev. ampl. Brasília, DF: Embrapa, 2018.

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

FAVARIN, J. L.; DOURADO NETO, D.; GARCÍA Y GARCÍA, L.; VILLA NOVA, N. A.; FAVARIN, M. G. G. V. Equações para estimativa do índice de área foliar do cafeeiro. **Pesq. Agropec. Bras., Brasília**, v. 37, n. 6, p. 769-773, jun., 2002.

FERNÁNDEZ-PACHECO, D. G.; ESCARABAJAL-HENAREJOS, D.; RUIZ-CANALES, A.; CONESA, J.; MOLINA-MARTÍNEZ, J. M. A digital image-processing-based method for determining the crop coefficient of lettuce crops in the southeast of Spain. **Biosystems Engineering**, v. 117, p. 23-34, 2014.

FERREIRA, M. E.; ANDRADE, L. R. M.; SANO, E. E.; CARVALHO, A. M.; JUNQUEIRA, N. T. V. Uso de imagens digitais na avaliação da cobertura do solo. Planaltina, DF: Embrapa Cerrado, 2001. 50 p. (Boletim de pesquisa e desenvolvimento, 21).

FISCHER FILHO, J. A.; ZOCOLER, J. L. Estimativa do coeficiente de cultura (Kc) do feijoeiro em Ilha Solteira, SP. **REVENG**, v. 23, n. 3, p. 229-235, 2016.

FLORENZANO, T. G. **Iniciação ao Sensoriamento Remoto**. 3ª ed. São Paulo: Oficina de Texto, 2011.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento Remoto em Agricultura**. São Paulo: Oficina de texto, 2017.

FRIZZONE, J. A. **Necessidade de água para Irrigação**. 2017. Disponível em: <http://www.leb.esalq.usp.br/leb/disciplinas/Frizzone/LEB_1571/TEXTO_COMPLEMNTAR_2_-_NECESSIDADE_DE_AGUA_PARA_IRRIGACAO.pdf>. Acesso em: 14 de junho de 2020.

GAMEIRO, S.; TEIXEIRA, C. P. B.; SILVA NETO, T. A.; LOPES, M. 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. **TERRAE**, v. 13(1-2), p. 15-22, 2017.

GODOY, L. J. G.; YANAGIWARA, R. S.; VILLAS BÔAS, R. L.; BACKES, C.; LIMA, C. P. Análise da imagem digital para estimativa da área foliar em plantas de laranja "Pera". **Rev. Bras. Frutic., Jaboticabal**, v. 29, n. 3, p. 420-424, 2007.

GONTIA, N. K.; TIWARI, K. N. Estimation of Crop Coefficient and Evapotranspiration of Wheat (*Triticum aestivum*) in an Irrigation Command Using Remote Sensing and GIS. **Water Resour Manage**, v. 24, p. 1399-1414, 2010.

GONZÁLEZ-ESQUIVA, J. M.; GARCÍA-MATEOS, G.; ESCARABAJAL-HENAREJOS, D.; HERNÁNDEZ-HERNÁNDEZ, J. L.; RUIZ-CANALES, A.; MOLINA-MARTÍNEZ, J. M. A new model for water balance estimation on lettuce crops using effective diameter obtained with image analysis. **Agricultural Water Management**, v. 183, p. 116-122, 2017.

HUETE, A.R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, p. 295–309, 1988.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Produção Agrícola Municipal 2021**. Disponível em <https://biblioteca.ibge.gov.br/visualizacao/periodicos/66/pam_2021_v48_br_informativo.pdf>. Acesso em: 25 de junho de 2022.

IBEGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Levantamento sistemático da produção agrícola**. Dezembro, 2022. Disponível em: <<https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=72415>>. Acesso em: 20 janeiro 2023.

IZBICKI, R.; SANTOS, T. M. **Aprendizado de máquina: uma abordagem estatística**. São Carlos, SP: 2020.

JADOSKI, S. O. **Alterações morfo-fisiológicas em plantas de pimentão sob deficiência hídrica**. 2002. Tese (Doutorado em Agronomia/Irrigação e Drenagem) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2002.

JAFARI, A.; HEDLEY, C. B.; FOURIE, J. Using Multispectral Imaging for Indicating the Water Status of Barley. **CICR-AgEng. Conference**, Aarhus, Denmark, p. 26-29, jun. 2016.

JANZEN, D. T.; FREDEEN, A. L.; WHEATE, R. D. Radiometric correction techniques and accuracy assessment for Landsat TM data in remote forested regions. **Can. J. Remote Sensing**, v. 32, n. 5, p. 330-340, 2006.

JENSEN, M. E. Water consumption by agricultural plants. In: KOZLOWSKI, T. T. (ed) **Water deficits and plant growth**. New York & London: Academic Press, 1968, p. 1-22.

JORGE, L. A. C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em 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. Capítulo 8, p. 109-134.

JUNQUEIRA, A. M.; ANDRÉ, R. G. B.; PINHEIRO, F. M. A. Consumo de água pelo feijoeiro comum, cv. Carioca. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 12, n. 1, p. 51-56, 2004.

KIM, N.; HA, K.; PARK, N.; CHO, J.; HONG, S.; LEE, Y. A comparison between major artificial intelligence models for crop yield predictions: case study of the midwestern united states, 2006-2015. **International Journal of Geo-Information**, v. 8, 240, 2019.

LEMONS, R. C.; SANTOS, R. D. **Manual de descrição e coleta de solo no campo**. 2.ed. Campinas: Sociedade Brasileira de Ciência do Solo, Embrapa – SNLCS, 1984, 46p.

LIBARDI, P. L. **Dinâmica da água no solo**. 2. Ed. São Paulo: EDUSP, 2012.

LORENA, A. C.; CARVALHO, A. C. P. L. F. Uma introdução às support vector machines. **RITA**, v. 15, n. 2, 2007.

MANTOVANI, E. C. **AVALIA**: Programa de avaliação da irrigação por aspersão e localizada. Viçosa, MG: UFV, 2001.

MANTOVANI, E. C.; BERNARDO, S.; PALARETTI, L. F. **Irrigação – princípios e métodos**. 3. ed. Viçosa, MG: Editora UFV, 2012. 355p.

MARIANO, D. Métricas de avaliação em machine learning. **BIOINFO**, v. 1, 2021.

MARQUELLI, W. A.; OLIVEIRA, A. S.; COELHO, E. F.; NOGUEIRA, L. C.; SOUSA, V. F. Manejo da Água de Irrigação. *In*: SOUSA, V. F. de; MARQUELLI, W. A.; COELHO, E. F.; PINTO, J. M.; COELHO FILHO, M. A. (Ed.). **Irrigação e Fertirrigação em Fruteiras e Hortaliças**. Brasília, DF: Embrapa Informação Tecnológica, 2011. Capítulo 5, p. 158-232.

MARTIN, T. N.; MARCHESE, J. A.; SOUSA, A. K. F.; CURTI, G. L.; FOGOLARI, H.; CUNHA, G. L. Uso do software imageJ na estimativa de área foliar para a cultura do feijão. **INTERCIENCIA**, v. 38, n. 12, 2013.

McCulloch, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Mathematical Biophysics**, v. 5, 1943.

MEDEIROS, G. A.; ARRUDA, F. B.; SAKAI, E.; FUJIWARA, M.; BONI, N. R. Crescimento vegetativo e coeficiente de cultura do feijoeiro relacionados a graus-dia acumulados. **Pesq. Agropec. Bras.**, v. 35, n. 9, p. 1733-1742, 2000.

MEDEIROS, G. A.; ARRUDA, F. B.; SAKAI, E.; FUJIWARA, M. The influence of crop canopy on evapotranspiration and crop coefficient of beans (*Phaseolus vulgaris* L.). **Agricultural Water Management**, v. 49, p. 211-224, 2001.

MENESES, P. R. Princípios de Sensoriamento Remoto. *In*: MENESES, P. R.; ALMEIDA, T. (Org.). **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília, DF: UnB, 2012. Capítulo 1, p. 1-31.

MENESES, P. R.; ALMEIDA, T. Distorções e correções dos dados da imagem. *In*: MENESES, P. R.; ALMEIDA, T. (Org.). **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília, DF: UnB, 2012. Capítulo 6, p. 82-102.

MEERADEVI.; SINDHU, N.; MUNDADA, M. R. Machine learning in agriculture application: algorithms and techniques. **International Journal of Innovative Technology and Exploring Engineering**, v. 9, n. 6, 2020.

MITCHELL, T. M. **Machine learning**. Redmode,WA: McGraw-Hill Science, 1997.

MILLER, J. J.; SCHEPERS, J. S.; SHAPIRO, C. A.; ARNESON, N. J.; ESKRIDGE, K. M.; OLIVEIRA, M. C.; GIESLER, L. J. Characterizing soybean vigor and productivity using multiple crop canopy sensor readings. **Field Crops Research**, v. 216, p. 22-31, 2018.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. São José dos Campos, SP: INPE, 2001.

MOREIRA, C. Neurônio. **Revista de Ciência Elementar**, v. 1(01), 2013.

NEETU.; RAY, S. S. Exploring machine learning classification algorithms for crop classification using Sentinel 2 data. In: Workshop on "Earth Observations for Agricultural Monitoring, 2019, New Dalhi. **Apresentação** [...] 2019. Disponível em: <https://doi.org/10.5194/isprs-archives-XLII-3-W6-573-2019>. Acesso em: 25 mar 2022.

NEPA - NÚCLEO DE ESTUDO E PESQUISA EM ALIMENTO. **Tabela Brasileira de Composição de Alimento (Taco)**. 4. ed. Campinas: NEPA, UNICAMP, 2011, 164 p.

OLIVEIRA, L. F. C.; OLIVEIRA, M. G. C.; WENDLAND, A.; HEINEMMAN, A. B.; GUIMARÃES, C. M.; FERREIRA, E. P. B.; QUINTELA, E. D.; BARBOSA, F. R.; CARVALHO, M. C. S.; LOBO JÚNIOR, M.; SILVEIRA, P. M.; SILVA, S. C. **Conhecendo a fenologia do feijoeiro e seus aspectos fitotécnicos**. 2.ed. revista e ampliada. Santo Antônio de Goiás, GO: Embrapa Arroz e Feijão, 2018. 61 p.

OLIVEIRA, F. A.; SILVA, J. J. S. Evapotranspiração, índice de área foliar e desenvolvimento radicular do feijão irrigado. **Pesquisa Agropecuária Brasileira**, Brasília, v. 25, n. 3, p. 317-322, 1990.

OMETTO, J. C. **Bioclimatologia vegetal**. São Paulo: Agronômica Ceres, 1981, 440p.

PARK, S.; RYU, D.; FUENTES, S.; CHUNG, H.; HERNANDEZ, D.; O'CONNELL, M. Adaptive Estimation of Crop Water Stress in Nectarine and Peach Orchards Using High-Resolution Imagery from an Unmanned Aerial Vehicle (UAV). **Remote sensing**, v. 9, p. 1-15, 2017.

PENMAN, H. L. Evaporation: an introductory survey. **Journal of Agricultural Science**, V. 4, P. 9-29, 1965.

PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. **Agrometeorologia: fundamentos e aplicações práticas**. Guaíba, RS: Livraria e Editora Agropecuária, 2002.

PEREIRA, L. S.; SILVA, D. O.; PAMBOUKIAN, S. V. D. Sensoriamento Remoto Aplicado à Agricultura de Precisão no Cultivo de Banbu. **Revista Mackenzie de Engenharia e Computação**, São Paulo, v. 16, n.1, p. 8-33, 2016.

PRELA, A.; RIBEIRO, A. M. A. Determinação de graus-dia acumulados e sua aplicação no planejamento do cultivo de feijão-vagem (*Phaseolus vulgaris* L.) para Londrina-PR. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 10, n. 1, p. 83-86, 2002.

PRUDKIN, G.; BREUNIG, F. M. **Drones e ciência: teoria e aplicações metodológicas**. (org.). Santa Maria, RS: FACOS-UFSM, 2019. 126p.

RAIJ, B. V.; ANDRADE, J. C.; CANTARELLA, H.; QUAGGIO, J. A. (ed.). Análise química para avaliação da fertilidade de solos tropicais. Campinas: IAC, 2001, 285p.

RASCHKA, S.; MIRJALILI, V. **Python machine learning**. 3. ed. Birmingham: Packt Publishing, 2019.

RENATO, N. S.; SILVA, J. B. L.; SEDIYAMA, G. C.; PEREIRA, E. G. Influência dos métodos para cálculo de graus-dia em condições de aumento de temperatura para as culturas de milho e feijão. **Revista Brasileira de Meteorologia**, v. 28, n. 4, p. 382-388, 2013.

RESENDE, M.; ALBUQUERQUE, P. E. P. **Métodos e Estratégias de Manejo da Irrigação**. Sete Lagoas, MG: Embrapa Milho e Sorgo, 2002. 10p. (Embrapa Milho e Sorgo. Circular Técnica, 19).

REYES-GONZÁLEZ, A.; KJAERGAARD, J.; TROOIJEN, T.; HAY, C.; AHIABLAME, L. Estimation of Crop Evapotranspiration Using Satellite Remote Sensing-Based Vegetation Index. **Advances in Meteorology**, p. 12, 2018.

RICO-GARCÍA, E.; HERNÁNDEZ-HERNÁNDEZ, F.; SOTO-ZARAZÚA, G. M.; HERRERA-RUIZ, G. Two new methods for the estimation of leaf area using digital photography. **International Journal of Agriculture & Biology**, v. 11, n. 4, p. 397-400, 2009.

RICHARDS, L. A.; Physical conditions of water soil. In: BLACK, C. A.; EVANS, D. D.; WHITE, J. L.; ENSMINGER, L. E.; CLARK, F. E. (ed.) **Methods of soil analysis – physical and mineralogical properties, including statistics of measurements and sampling**. Madison: ASA-SSSA, 1965. p. 128-153.

ROELOFS, R. **Measuring generalization and overfitting in machine learning**. 2019. Dissertation (Doctor of Philosophy/Computer Science) – University of California, Berkeley, 2019.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, 1958.

SAFANELLI, J. L.; BOTTEGA, E. L.; CATEN, A. T.; KUIAWSKI, A. C. M. B.; BOESING, B. F. B. Variabilidade temporal do índice de vegetação ajustado ao solo (SAVI) na cultura da soja. In: Congresso Brasileiro de Agricultura de Precisão – ConBAP, 1., 2014, São Pedro, SP. Apresentação [...] 2014. Disponível em: http://conbap.sbea.org.br/crbst_2.html. Acesso em: 25 mar 2022.

SAFRE, A. L. S.; FERNANDES, C. N.; SAAD, J. C. C. Estimativa de umidade do solo por meio de aprendizado de máquina usando imagens de veículo aéreo não tripulado (VANT). **Irriga**, Botucatu, v. 26, n. 3, p. 684-700, jun-set, 2021.

SAMPAIO, M. I. R.; KUNZ, A.; HILLEBRAND, F. L.; ZAMBERLAN, J. F.; IDALINO, F. D. Análise dos índices de vegetação NDVI e NDRE em imagens obtidas por meio de sensor embarcado em um RPAS para as culturas da soja (*Glycine max*) e (*Zea mays*) irrigados. **Revista Brasileira de Geomática**, v. 9, n. 4, p. 350-362, out/dez. 2021.

SANTANA, M. J.; CARVALHO, J. A.; ANDRADE, M. J. B.; BRAGA, J. C.; GERVÁSIO, G. G. Coeficiente de cultura e análise do rendimento do feijoeiro sob regime de irrigação. **Irriga**, Botucatu, v. 13, n. 1, p. 92-112, 2008.

SANTOS, R. M.; ROMÁZ, R. M. S.; GRASSI FILHO, H.; SILVA, V. M.; PEREIRA, A. J. Coeficiente de produtividade – KY do feijão carioca (*Phaseolus vulgaris* L. TAA DAMA) para o município de Botucatu-SP. **Irriga**, Botucatu. v. 27, n. 4, p. 785 – 794, 2022.

SINGH, H. Practical machine learning and image processing. Uttar Pradesh: Apress, 2019, 169p.

SHIRATSUCHI, L. S.; BRANDÃO, 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. Capítulo 4, p. 58-73.

SHU, W.; WANG, L.; LIU, B.; LIU, J. Lai estimation of cucumber crop based on improved fully convolutional network. **arXiv**, 2104.07955v1, apr. 2021.

STONE, L. F.; SILVEIRA, P. Q. **Determinação da evapotranspiração para fins de irrigação**. Goiânia: EMBRAPA-CNPAP, 1995. 49 p. (EMBRAPA-CNPAP. Documentos, 55).

TAIZ, L.; ZEIGER, E. **Fisiologia Vegetal**. 4. ed. Porto Alegre: Artmed, 2009.

THORNTON, C. W. An approach toward a rational classification of climate. **Geographical Review**. v. 38(1), p. 55-94, 1948.

TRINDADE, P. M. P.; FACCO, D. S.; PEREIRA FILHO, W. **Sensoriamento Remoto: Radiometria Espectral e Técnicas de Análise de Espectros**. Disponível em: < https://www.ufsm.br/app/uploads/sites/676/2019/08/topico_5.compressed.pdf>. Acesso em: 02 nov. 2019.

TUCKER, C. J. Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. **Remote Sensing of Environment**. v.8, n.2, p. 127-150, 1979.

TWARAKAVI, N. K. C.; SAKAI, M.; SIMUNEK, J. An objective analysis of the dynamic nature of field capacity. **Water Resources Research**, v. 45, w10410, 2009.

VAKILI, M.; GHAMSARI, M.; REZAEI, M. Performance analysis and comparison of machine and deep learning algorithms for IoT data classification. **Computer Science**, 2020.

Van GENUCHTEN, M. T. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. **Soil Science Society of America Journal**, v. 44, n.5, p. 892-898, 1980.

Van GENUCHTEN, M. T.; SIMUNEK, J.; LEIJ, F. J.; SEJNA, M. RETC version 6.02., 2009. Disponível em: <http://www.pcprogress.com/en/Default.aspx?retc-downloads>. Acesso em 20 out. 2021.

VARGAS-RAMÍRES, N.; PANEQUE-GÁLVEZ, J. The global emergence of community drones (2012-2017). **Drones**, v. 3, n. 76, 2019.

VENÂNCIO, L. P.; CUNHA, F. F.; MANTOVANI, E. C.; AMARAL, C. H.; REIS, E. F. Evapotranspiração de cultura: uma abordagem dos principais métodos aplicados às pesquisas científicas e na agricultura. **Irriga Botucatu**, v. 24, n. 4, p. 719-746, outubro, 2019.

VIANA, J. H. M.; TEIXEIRA, W. G.; DONAGEMMA, G. K. Umidade atual. In: TEIXEIRA, P. C.; DONAGEMMA, G. K.; FONTANA, A.; TEIXEIRA, W. G. (Ed.). **Manual de métodos de análise de solo**. 3. ed. rev. ampl. Brasília, DF: Embrapa, 2017. cap. 2, p. 28-30.

VIEIRA, E. H. N.; VIEIRA, N. R. A. **Indicadores visuais da maturação fisiológica do feijão**. Goiânia, GO: Embrapa-CNPAF, 1997. 22 p. (Embrapa-CNPAF. Documentos, 73).

WUTKE, E. B.; BRUNINI, O.; BARBANO, M. T.; CASTRO, J. L.; GALLO, P. B.; KANTHACK, R. A. D.; MARTINS, A. L. M.; PEREIRA, J. C. V. N. A.; BORTOLETTO, N.; PAULO, E. M.; SAKAI, M.; SAES, L. A.; AMBROSANO, E. J.; CARBONELL, S. A.

M.; SILVEIRA, L. C. P. Estimativa de temperatura base e graus-dia para feijoeiro nas diferentes fases fenológicas. **Revista Brasileira de Agrometeorologia**, Santa Marta, v. 8, n. 1, p. 55-61, 2000.

XIANG, K.; Li, Y.; HORTON, B.; FENG, H. Similarity and difference of potential evapotranspiration and reference crop evapotranspiration – a review. **Agricultural Water Management**. 232, 106043-16, 2020.

YANG, K.; ZHONG, W.; LI, F. Leaf segmentation and classification with a complicated background using deep learning. **Agronomy**, v. 10, 1721, 2020.

YIN, X.; GOUDRIAAN, J.; LANTINGA, E. A.; VOS, J.; SPIERTZ, H. J. A flexible sigmoid function of determinate growth. **Annals of Botany**, v. 91, p. 361-371, 2003.

ZEVIANI, W. M.; RIBEIRO JÚNIOR, P. J.; BONAT, W. H. Modelos de regressão não linear. Universidade Federal do Paraná, p. 109, 2013. Disponível em: <https://www.ime.unicamp.br/~cnaber/cursomodelosnaolinearesR.pdf>. Acesso em 14 de junho de 2021.

ZAINAL-MOKHTAR, K.; MOHAMAD-SALEH, J. An oil fraction neural sensor developed using electrical capacitance tomography sensor data. **Sensor**, v. 13, p. 11385-11406, 2013.

ZHANG, L.; ZHANG, H.; NIU, Y.; HAN, W. Mapping Maize Water Stress Based on UAV Multispectral Remote Sensing. **Remote Sens**. v. 11, n. 605. 2019.

ZONTA, J. H.; BEZERRA, J. R. C.; PEREIRA, J. R.; SOFIATTI, V. **Manejo de irrigação do algodoeiro**. Campina Grande, PB: EMBRAPA ALGODÃO, 2016. 8p. (EMBRAPA ALGODÃO. Circular técnica, 139).