



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE ENGENHARIA AGRÍCOLA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

VINÍCIUS BITENCOURT CAMPOS CALOU

**USO DE VANTS NO MONITORAMENTO DA SIGATOKA-AMARELA DA
BANANEIRA**

FORTALEZA

2018

VINÍCIUS BITENCOURT CAMPOS CALOU

USO DE VANTS NO MONITORAMENTO DA SIGATOKA-AMARELA DA BANANEIRA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola do Departamento de Engenharia Agrícola da Universidade Federal do Ceará, como parte dos requisitos para obtenção do Título de Mestre em Engenharia Agrícola. Área de Concentração: Irrigação e Drenagem.

Orientador: Prof. Dr. Adunias dos Santos Teixeira, Ph.D.

FORTALEZA

2018

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- C164u Calou, Vinícius Bitencourt Campos.
Uso de VANTs no monitoramento da sigatoka-amarela da bananeira / Vinícius Bitencourt Campos Calou. – 2018.
116 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Agrícola, Fortaleza, 2018.
Orientação: Prof. Dr. Adunias dos Santos Teixeira, Ph.D.
1. Mycosphaerella musicola. 2. Unmanned Aerial Vehicle. 3. Sensoriamento Remoto. 4. Machine Learning. I. Título.

CDD 630

VINÍCIUS BITENCOURT CAMPOS CALOU

USO DE VANTS NO MONITORAMENTO DA SIGATOKA-AMARELA DA BANANEIRA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola do Departamento de Engenharia Agrícola da Universidade Federal do Ceará, como parte dos requisitos para obtenção do Título de Mestre em Engenharia Agrícola. Área de Concentração: Irrigação e Drenagem.

Aprovada em: 30/07/2018.

BANCA EXAMINADORA

Prof. Dr. Adunias dos Santos Teixeira, Ph.D. (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Luis Clenio Jário Moreira
Instituto Federal de Educação Ciência e Tecnologia – Limoeiro do Norte (IFCE)

Prof. Dr. Joaquim Branco de Oliveira
Instituto Federal de Educação Ciência e Tecnologia – Iguatu (IFCE)

Prof. Dr. Cristiano Souza Lima
Universidade Federal do Ceará (UFC)

A Deus.

À minha amada noiva, Jéssica Porto;

A meu pai, professor e herói, Cícero Calou;

À minha mãe, professora e maior exemplo,
Maria José;

À minha irmã e ao meu cunhado, Marília e
Rubens;

Ao meu sobrinho que ainda irá chegar;

Em memória de minha irmã Maria Lídia;

A todos os meus amigos do Laboratório de
Eletrônica e Mecânica Agrícola – LEMA e do
Departamento de Engenharia Agrícola, em
especial ao meu orientador professor Adunias.

AGRADECIMENTOS

Ao Prof. Adunias dos Santos Teixeira por toda a orientação, confiança, profissionalismo e dedicação.

Aos professores participantes da banca examinadora Prof. D.Sc Luis Clenio Jário Moreira, Prof. Dr. Joaquim Branco de Oliveira, Prof. Dr. Cristiano Souza Lima por todo o tempo dedicado, pelas valiosas colaborações e sugestões.

Aos amigos do Laboratório de Eletrônica e Máquinas Agrícolas – LEMA e Grupo de Automação, Manejo Agrícola e Desenvolvimento Tecnológico – GAMA-DT, em especial Márcio, Thales, Acrísio, David Lino, Klênio, Rômulo, David Campelo, Adriano, Odílio, Amnon, Marcos, Lia, Eurileny, Arnaldo Sales, Firmino, Mayara e Samuel.

À Vânia da empresa Frutacor, Jailma e Gabriela pela ajuda nos trabalhos de campo.

Ao CNPq pelo apoio financeiro na execução do projeto.

À empresa Frutacor, por abrir as portas para a pesquisa e apoiar todo o progresso da agricultura de precisão.

À Universidade Federal do Ceará pelo incentivo a novas pesquisas, estrutura de salas de aula e professores.

À AgiSoft, desenvolvedora do PhotoScan utilizado neste trabalho.

Aos amigos da turma da Agronomia, em especial aos membros do Departamento de Incentivo e Valorização da Agronomia – DIVA.

Aos meus pais Cicero Calou e Maria José, pelo tempo dedicado, confiança e apoio.

À minha irmã Marília pelas orações e em memória de Maria Lídia, minha outra irmã.

À minha amada noiva e futura esposa Jéssica Porto, pela força e incentivo em todos os momentos.

RESUMO

As técnicas de Machine Learning aplicadas à agricultura de precisão oferecem novas prospecções para o monitoramento e a identificação de características e identificação de padrões. Neste cenário, insere-se a bananicultura, atividade de grande importância econômica, sendo uma das frutas mais consumidas em todo o mundo, com grande valor nutricional. A cultura é afetada por diversas doenças e, dentre elas, a sigatoka-amarela, que é um dos principais fatores limitantes ao seu cultivo, provocando consideráveis prejuízos na produção de frutos. Neste âmbito, buscando os pressupostos básicos de identificação, classificação, quantificação e predição de fatores fenotípicos, o objetivo geral deste trabalho foi utilizar técnicas de sensoriamento remoto, aprendizagem computacional e imagens aéreas de alta resolução espacial para realizar o monitoramento da severidade do ataque da sigatoka-amarela na cultura da banana. Foram realizados voos mensais em plantio comercial de bananeiras pertencente à empresa Frutacor, na cidade de Russas, Ceará, Brasil, utilizando VANT Inspire 1, embarcado com câmera X5 (pancromática RGB) de 16 megapixels e 8 bytes. Os processamentos foram realizados através do software PhotoScan e, para as classificações, foram utilizados os algoritmos Maximum Likelihood, Mahalanobis Distance e Minimum Distance, considerados de fácil interface e rápido processamento. Os algoritmos foram avaliados pela estatística de Kappa e Índice de Exatidão Global, e os dados obtidos pelos processamentos, confrontados com os levantamentos de campo. Como resultados, o algoritmo Minimum Distance alcançou melhor desempenho (99,28% de acurácia) para o mês de setembro de 2017, e 2,44% de grau de severidade da sigatoka-amarela, em comparação ao levantamento de campo, que resultou em grau de infecção de 1% a 5%. Para os meses de outubro e novembro, o algoritmo Maximum Likelihood obteve 89,77% e 78,76% de acurácia, se aproximando dos valores levantados em campo, demonstrando que as ferramentas de monitoramento de manchas foliares podem ser realizadas por meio de técnicas de sensoriamento remoto, aprendizagem computacional e imagens pancromáticas de alta resolução espacial.

Palavras-chave: *Mycosphaerella musicola*. *Unmanned Aerial Vehicle*. Sensoriamento remoto. *Machine learning*.

ABSTRACT

The Machine Learning techniques in precision agriculture offer new prospects for the monitoring and identification of phenotypic characteristics in crops, such as physiological, biotic and abiotic features, as a manifestation of diseases and pests, hydric and nutritional stress. The algorithms used in the processes seek the recognition of standards from Remote Sensing data, such as aerial images obtained through Unmanned Aerial Vehicles - UAVs. This scenario includes banana farming, an activity of great economic importance, being one of the most consumed fruits in the world, with big nutritional value. The banana crop is affected by several diseases and among them, yellow sigatoka, which is one of the main limiting factors to its cultivation, causing considerable losses in fruit production. In this context, searching for the basic assumptions for identification, classification, quantification and prediction (ICQP) of phenotypic factors, the general objective of this work was to use remote sensing techniques, machine learning and high spatial resolution aerial images to monitor the severity of the yellow sigatoka attack in banana culture. Monthly flights were carried out in banana plantations in the city of Russas, Ceará, Brazil, belonging to the company Frutacor, using UAV Inspire 1, shipped with X5 (panchromatic RGB) camera of 16 megapixels and 8 bytes. The algorithms Maximum Likelihood, Mahalanobis Distance and Minimum Distance, were considered as easy interface and fast processing, using the PhotoScan software. The algorithms were evaluated by the Kappa statistic and the Global Accuracy Index and the data obtained by the tests, compared to the field surveys. As a result, the Minimum Distance algorithm achieved better performance (99.28% accuracy) for the month of September 2017, and 2.44% of the degree of severity of the yellow sigatoka, compared to the field survey, which resulted in a degree of infection from 1% to 5%. For the months of October and November, the Maximum Likelihood algorithm obtained 89.77% and 78.76% of accuracy, approaching the values collected in the field, demonstrating that the tools for monitoring leaf spots can be performed by means of techniques remote sensing, computational learning, and high spatial resolution panchromatic images

Keywords: *Mycosphaerella musicola*. Unmanned Aerial Vehicle. Remote sensing. Machine learning.

LISTA DE FIGURAS

Figura 1	– A) Banana Prata na fase vegetativa pré-produção. B) Banana Prata na pré-colheita e C) Colheita manual de Banana Prata em Iguatu, Ceará – Brasil.....	18
Figura 2	– Ciclo infeccioso dos patógenos <i>M. musicola</i> e <i>P. musae</i>	21
Figura 3	– A) Desenho esquemático de ordenamento foliar em planta de bananeira; B) Foto aérea de bananeira obtida à altura de 30 metros, utilizando VANT	22
Figura 4	– Sintomas de infecção da sigatoka-amarela em folhas de bananeira	23
Figura 5	– Grau de Sintoma do ataque da sigatoka-amarela. Adaptado de Meredith (1970)	25
Figura 6	– A) VANT multirrotor, modelo Inspire 2, da DJI. B) VANT asa fixa, modelo Ebee, da senseFly.....	31
Figura 7	– Mapa da área de estudo. Empresa Frutacor, Russas, Ceará, Brasil 2018	44
Figura 8	– Plantio em fileiras duplas na cultura da bananeira. Frutacor, Russas, Ceará, Brasil 2018.....	45
Figura 9	– Grau de severidade do ataque da sigatoka-amarela. Adaptado de Gauhl (1994)	46
Figura 10	– Grau de Sintoma do ataque da sigatoka-amarela. Adaptado de Meredith (1970)	47
Figura 11	– Fluxograma dos levantamentos de campo. Frutacor, Russas, Ceará, Brasil 2018	48
Figura 12	– VANT Inspire 1, DJI, em pleno voo	49
Figura 13	– Software Litchi® com a programação de voo em área de estudos. Frutacor, Russas, Ceará, Brasil 2018	50
Figura 14	– A) Sistema GNSS ProMark 3, Magellan, para aquisição das coordenadas geográficas dos GCPs; B) GCP observado em imagem aérea obtida por meio do VANT Inspire 1, Frutacor, Russas, Ceará, Brasil 2018	52
Figura 15	– Fluxograma do processamento das imagens obtidas por meio do VANT	

	em plantio de bananeira. Frutacor, Russas, Ceará, Brasil 2018	55
Figura 16 –	Mapas IDW do Grau de Sintoma e Grau de Severidade do ataque da sigatoka-amarela (<i>Mycosphaerella musicola</i>). Frutacor, Russas, Ceará, Brasil 2018	59
Figura 17 –	Sintomas de ataque da sigatoka-amarela em folhas de bananeiras. Imagens aéreas obtidas por meio de VANT Inspire 1, Frutacor, Russas, Ceará, Brasil 2018	60
Figura 18 –	Perfil Espectral RGB de amostra aleatória no ortomosaico obtido a partir de processamento com VANT. A) Amostras no ortomosaico; B) Perfil Espectral das frequências RGB.....	61
Figura 19 –	Mapa temático da classificação com algoritmo Maximum Likelihood no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018.....	64
Figura 20 –	Mapa temático da classificação com algoritmo Mahalanobis Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018.....	65
Figura 21 –	Mapa temático da classificação com algoritmo Minimum Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018	66
Figura 22 –	Grau de Sintoma e Severidade do ataque da sigatoka-amarela, descritos por Meredith (1970) e Stover (1971), modificada por Gauhl et al. (1994), levantamento dia 27/09/2017	67
Figura 23 –	Recorte ampliado da área de estudos para voo no dia 27/09/2017, de acordo com A) Ortomosaico RGB; B) Classificação com algoritmo Maximum Likelihood; C) Classificação com algoritmo Mahalanobis Distance e; D) Classificação com algoritmo Minimum Distance	69
Figura 24 –	Recortes ampliados da área de estudos para voo no dia 27/09/2017	70
Figura 25 –	Mapa temático da classificação com algoritmo Maximum Likelihood no dia 10/10/17, Frutacor, Russas, Ceará, Brasil 2018	72
Figura 26 –	Mapa temático da classificação com algoritmo Mahalanobis Distance no dia 10/10/17, Frutacor, Russas, Ceará, Brasil 2018	73
Figura 27 –	Mapa temático da classificação com algoritmo Minimum Distance no dia	

	10/10/17, Frutacor, Russas, Ceará, Brasil 2018	74
Figura 28 –	Grau de Sintoma e Severidade do ataque da sigatoka-amarela, descritos por Meredith (1970) e Stover (1971), modificada por Gauhl et al. (1994) levantamento dia 10/10/2017	75
Figura 29 –	Recorte ampliado da área de estudos para voo no dia 10/10/2017, de acordo com A) Ortomosaico RGB; B) Classificação com algoritmo Maximum Likelihood; C) Classificação com algoritmo Mahalanobis Distance e; D) Classificação com algoritmo Minimum Distance	77
Figura 30 –	Recortes ampliados da área de estudos para voo no dia 10/10/2017	78
Figura 31 –	Mapa temático da classificação com algoritmo Maximum Likelihood no dia 07/11/17, Frutacor, Russas, Ceará, Brasil 2018	79
Figura 32 –	Mapa temático da classificação com algoritmo Mahalanobis Distance no dia 07/11/17, Frutacor, Russas, Ceará, Brasil 2018	80
Figura 33 –	Mapa temático da classificação com algoritmo Minimum Distance no dia 07/11/17, Frutacor, Russas, Ceará, Brasil 2018	81
Figura 34 –	Grau de Sintoma e Severidade do ataque da sigatoka-amarela, descritos por Meredith (1970) e Stover (1971), modificada por Gauhl et al. (1994), levantamento dia 07/11/2017	83
Figura 35 –	Recorte ampliado da área de estudos para voo no dia 07/11/2017, de acordo com A) Ortomosaico RGB; B) Classificação com algoritmo Maximum Likelihood; C) Classificação com algoritmo Mahalanobis Distance e; D) Classificação com algoritmo Minimum Distance	85
Figura 36 –	Recorte ampliado da área de estudos para voo no dia 07/11/2017	86
Figura 37 –	Imagem aérea obtida por meio de VANT Inspire 1 a 30 metros de altura em relação ao nível do solo. Frutacor, Russas, Ceará, Brasil, 2018	88
Figura 38 –	Mapa temático da classificação de imagem individual com algoritmo Maximum Likelihood no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018	89
Figura 39 –	Mapa temático da classificação de imagem individual com algoritmo	

	Mahalanobis Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018	90
Figura 40 –	Mapa temático da classificação de imagem individual com algoritmo Minimum Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018 .	91
Figura 41 –	Imagem aérea obtida por meio de VANT Inspire 1 a 30 metros de altura em relação ao nível do solo. Frutacor, Russas, Ceará, Brasil, 2018	93
Figura 42 –	Mapa temático da classificação de imagem individual com algoritmo Maximum Likelihood no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018	93
Figura 43 –	Mapa temático da classificação da imagem individual com algoritmo Mahalanobis Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018	94
Figura 44 –	Mapa temático da classificação da imagem individual com algoritmo Minimum Distance Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018	95
Figura 45 –	Perfil Espectral RGB de diferentes alvos no ortomosaico obtido a partir de processamento com VANT em 27/09/2017. A) Amostras no ortomosaico; B) Perfil Espectral das frequências RGB	96

LISTA DE TABELAS

Tabela 1 – Resumo do período das missões realizadas em campo na empresa Frutacor.....	46
Tabela 2 – Parâmetros de voo e configurações da câmera X5 16 megapixels a bordo do VANT Inspire 1.....	50
Tabela 3 – Categorias para interpretação do índice Kappa.....	56
Tabela 4 – Graus de Sintoma e Severidade do ataque da sigatoka-amarela (<i>Mycosphaerella musicola</i>) nas avaliações de campo. Frutacor, Russas, Ceará, Brasil 2018.....	58
Tabela 5 – Índice de Exatidão Global dos algoritmos classificadores.....	62
Tabela 6 – Índice de Kappa dos algoritmos classificadores.....	62
Tabela 7 – Matriz de confusão da classificação realizada com o algoritmo Maximum Likelihood no dia 27/09/2017.....	64
Tabela 8 – Matriz de confusão da classificação realizada com o algoritmo Mahalanobis Distance no dia 27/09/2017.....	65
Tabela 9 – Matriz de confusão da classificação realizada com o algoritmo Minimum Distance no dia 27/09/2017.....	66
Tabela 10 – Avaliações de campo e classificações da assertividade dos algoritmos para os processamentos referentes à 27/09/2017.....	67
Tabela 11 – Exatidões Específicas das classes referentes aos mapeamentos realizados em plantio de bananeiras. 27/09/2017, Frutacor, Russas, Ceará, Brasil, 2018.....	68
Tabela 12 – Matriz de confusão da classificação realizada com o algoritmo Maximum Likelihood no dia 10/10/2017.....	72
Tabela 13 – Matriz de confusão da classificação realizada com o algoritmo Mahalanobis Distance no dia 10/10/2017.....	73
Tabela 14 – Matriz de confusão da classificação realizada com o algoritmo Minimum Distance no dia 10/10/2017.....	74

Tabela 15 – Avaliações de campo e classificações da assertividade dos algoritmos para os processamentos referentes à 10/10/2017.....	75
Tabela 16 – Exatidões Específicas das classes referentes aos mapeamentos realizados em plantio de bananeiras. 10/10/2017, Frutacor, Russas, Ceará, Brasil, 2018.....	76
Tabela 17 – Matriz de confusão da classificação realizada com o algoritmo Maximum Likelihood no dia 07/11/2017.....	80
Tabela 18 – Matriz de confusão da classificação realizada com o algoritmo Mahalanobis Distance no dia 07/11/2017.....	80
Tabela 19 – Matriz de confusão da classificação realizada com o algoritmo Minimum Distance no dia 07/11/2017.....	81
Tabela 20 – Avaliações de campo e classificações da assertividade dos algoritmos para os processamentos referentes à 07/11/2017.....	82
Tabela 21 – Exatidões Específicas das classes referentes aos mapeamentos realizados em plantio de bananeiras. 07/11/2017, Frutacor, Russas, Ceará, Brasil, 2018.....	83
Tabela 22 – Exatidão Global, Índice de Kappa e classe "Folha Anormal" dos processamentos para a imagem central à cena, com coordenadas 605.006,937869 E, 9450660.51551 N, Zona 24 S – Sirgas 2000.....	87
Tabela 23 – Matriz de confusão da classificação realizada com o algoritmo Maximum Likelihood no dia 27/09/2017 em imagem individual.....	89
Tabela 24 – Matriz de confusão da classificação realizada com o algoritmo Mahalanobis Distance no dia 27/09/2017 em imagem individual.....	90
Tabela 25 – Matriz de confusão da classificação realizada com o algoritmo Minimum Distance no dia 27/09/2017 em imagem individual.....	91
Tabela 26 – Exatidão Global, Índice de Kappa e classe "Folha Anormal" dos processamentos para a imagem central à cena, com coordenadas 605034.679601 E, 9450721.9709 N, Zona 24 S – Sirgas 2000.....	92
Tabela 27 – Matriz de confusão da classificação realizada com o algoritmo Maximum	

Likelihood no dia 27/09/2017 em imagem individual.....	93
Tabela 28 – Matriz de confusão da classificação realizada com o algoritmo Mahalanobis Distance no dia 27/09/2017 em imagem individual.....	94
Tabela 29 – Matriz de confusão da classificação realizada com o algoritmo Minimum Distance no dia 27/09/2017 em imagem individual.....	95

LISTA DE ABREVIATURAS E SIGLAS

2D	Bidimensional
3D	Tridimensional
ANAC	Agência Nacional de Aviação Civil
CONAB	Companhia Nacional de Abastecimento
EXIF	EXchangeable Image File format
FAO	Food and Agriculture Organization of the United Nations
GCP	Ground Control Points (Ponto de Controle em solo)
GNSS	Global Navigation Satellite System
GPS	Global Position System
GSD	Ground Sampling Distance
IAF	Índice de Área Foliar
ICAO	International Civil Aviation Organization
ICQP	Identificação, classificação, quantificação e predição
IMU	Inertial Measurement Unit
ML	Machine Learning
NDVI	Normalized Difference Vegetation Index
NGRDI	Normalized Green-Red Difference Index
RPA	Remotely Piloted Aircraft
ROI	Region of Interest
SfM	Structure from Motion
SR	Sensoriamento Remoto
SRA	Sensoriamento Remoto Agrícola
UAV	Unmanned Aerial Vehicle
VANTs	Veículos Aéreos Não Tripulados
VCANTs	Veículos de Combate Aéreo Não Tripulado

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Hipótese	15
1.2	Objetivos	15
1.2.1	Gerais	15
1.2.2	Específicos.....	16
2	REVISÃO BIBLIOGRÁFICA	17
2.1	A Cultura da Bananeira	17
2.1.1	Aspectos históricos, econômicos e fisiológicos	17
2.1.2	A sigatoka-amarela na cultura da bananeira	20
2.1.3	Monitoramento e controle da sigatoka-amarela	23
2.2	Sensoriamento remoto e processamento digital de imagens	26
2.2.1	O sensoriamento remoto como ferramenta de análise	26
2.2.2	O sensoriamento remoto no monitoramento de pragas agrícolas	28
2.2.3	Histórico e aplicações gerais dos VANTs	30
2.2.4	VANTs aplicados à agricultura de precisão	32
2.2.5	Identificação, classificação, quantificação e predição (ICQP) de padrões a partir de técnicas de sensoriamento remoto e Machine Learning	35
2.2.6	Classificação digital de imagens	38
3	MATERIAL E MÉTODOS	44
3.1	Área de estudos e coleta de dados	44
3.2	Plataforma e voo programado	48
3.3	Processamento e classificação das imagens	52
4	RESULTADOS E DISCUSSÃO	58
4.1	Graus de severidade e de sintomas da sigatoka-amarela	58
4.2	Classificações dos ortomosaicos	61
4.2.1	Classificações de setembro – 1ª missão de campo	63
4.2.2	Classificações de outubro – 2ª missão de campo	71
4.2.3	Classificações de novembro – 3ª missão de campo	79
4.3	Classificações de fotografias individuais	87
4.3.1	Imagem 01 (605.006,937869 E, 9450660.51551 N, Zona 24 S – Sirgas 2000)..	87
4.3.2	Imagem 02 (605034.679601 E, 9450721.9709 N, Zona 24 S – Sirgas 2000).....	91

5	CONCLUSÃO	97
6	RECOMENDAÇÕES	98
	REFERÊNCIAS	99

1 INTRODUÇÃO

A Organização das Nações Unidas para a Alimentação e a Agricultura (FAO) estima que, em 2050, a demanda por alimentos, fibras e combustíveis irá dobrar, direcionando atualmente a comunidade científica ao enfrentamento do grande desafio de aumentar as produtividades agrícolas. Os prejuízos causados devido às pragas e doenças também representam um grande entrave nos aumentos de produtividade, atingindo quase 5% do PIB mundial (cerca de US\$ 1,4 trilhão). No Brasil, pesquisas demonstram uma perda média anual de até 7,7% da produção agrícola, equivalendo a aproximadamente 25 milhões de toneladas, devido às moscas, às lagartas e a outras pragas e doenças que atacam as plantas, somando um montante de R\$ 55 bilhões em perdas ao ano, representando um enorme problema para a segurança alimentar global (SAVARY, AUBERTOT e HOLLIER 2012).

Neste cenário, são introduzidas técnicas de sensoriamento remoto (SR), caracterizando métodos não destrutivos, a partir da obtenção de informações de um alvo ou fenômeno sem um contato físico com o mesmo (LILLESAND, KIEFER E CHIPMAN, 2008). No contexto da agricultura de precisão, portanto, as ferramentas de SR são uma grande aliada no enfrentamento da crise alimentar do planeta, endossando novas prospecções para o monitoramento de características fenotípicas de plantios como a identificação de feições fisiológicas, bióticas e abióticas, como manifestação de doenças e pragas, estresse hídrico e nutricional, entre outros (COLOMINA *et al.*, 2014).

Os Veículos Aéreos Não Tripulados (VANTs) e as ferramentas de Machine Learning (ML – aprendizagem computacional), no panorama do SR, revolucionaram os processamentos de dados de maneira remota. A tecnologia dos VANTs tem proporcionado imagens de alta resolução espacial, aumentando a precisão dos dados de entrada para os processos computacionais, enquanto que, as ferramentas de ML realizam a manipulação, interpretação e geração dos resultados. A partir da extração de padrões e reconhecimento de características, tais técnicas formam as bases que fundamentam os quatro estágios de decisão no ciclo de monitoramento de uma característica fenotípica singular: identificação, classificação, quantificação e predição (ICQP) (HONKAVAARA *et al.*, 2013; SINGH *et al.*, 2016).

De modo específico, a fruticultura nacional se enquadra como forte setor empregatício e econômico, sendo destacado o cultivo da banana, uma das frutas mais consumidas em todo o mundo, principalmente na forma fresca. Esta atividade é afetada por diversas doenças e, dentre elas, a sigatoka-amarela que se constitui em um fator de grande

limitação ao seu cultivo, principalmente para pequenos produtores. Com grande poder de disseminação, a sigatoka-amarela se encontra presente em todas as regiões produtoras de banana do Brasil e do mundo, provocando consideráveis prejuízos na produção de frutos (FOURÉ, 1994; CORDEIRO *et al.*, 2005).

Pulverizações alternadas de fungicidas sistêmicos e protetores são as técnicas mais utilizadas em cultivares suscetíveis às doenças. O monitoramento semanal da severidade da doença é um dos elementos dos sistemas de pré-aviso biológico, definindo o momento ideal para aplicar o controle, observados por Stover (1971), Ganry e Meyer (1972), Ternesien (1985) e Fouré (1988). Entretanto, o monitoramento da severidade, na forma como está proposta, é uma tarefa trabalhosa que requer tempo, mão de obra e infraestrutura especializadas. Além disso, a decisão tomada em função dos dados coletados pela metodologia apresenta certa subjetividade por não considerar a variabilidade espacial na região/área afetada, pois a estimativa generaliza a área de produção a partir de poucas amostras (BENDINI *et al.*, 2013), o que pressupõe a necessidade de investimento no estudo de novas técnicas que possam cumprir essa tarefa de forma eficiente, mais rápida e menos onerosa.

Assim, visto a caracterização da temática do monitoramento de plantios, considera-se importante a proposição de novos métodos que auxiliem na identificação, classificação, quantificação e predição de patologias foliares em campo, como vem apresentado neste trabalho. A alta resolução espacial das imagens obtidas por meio dos VANTs pode se apresentar como um excelente dado de entrada no treinamento de algoritmos para o diagnóstico de patologias foliares na cultura da bananeira, inserindo-se como uma nova solução para o campo agrícola.

1.1 Hipótese

Imagens pancromáticas de alta resolução espacial podem ser usadas na identificação, classificação, quantificação e predição espaço-temporal da severidade da sigatoka-amarela na cultura da bananeira, através de técnicas de classificação digital de imagens e aprendizagem computacional.

1.2 Objetivos

1.2.1 Gerais

Utilizar técnicas de sensoriamento remoto, aprendizagem computacional e imagens aéreas de alta resolução espacial para realizar o monitoramento da severidade do ataque da sigatoka-amarela (*Mycosphaerella musicola* Leach) na cultura da banana (*Musa* spp.).

1.2.2 Específicos

- Utilizar sensor pancromático RGB para a identificação da sigatoka-amarela na cultura da bananeira;
- Classificar, quantificar e predizer os níveis de severidade do ataque da sigatoka-amarela;
- Avaliar a acurácia de algoritmos já consagrados em sensoriamento remoto agrícola para a utilização de aprendizagem computacional no auxílio às técnicas de campo;
- Avaliar a capacidade do uso de VANTs para auxiliar as técnicas convencionais de monitoramento da evolução severidade da sigatoka-amarela;
- Utilizar técnicas de geoprocessamento para espacializar o grau de sintomas e grau de severidade no ataque da sigatoka-amarela na cultura da bananeira; e
- Realizar avaliações diagnósticas qualitativas segundo método convencional proposto por Stover (1971).

2 REVISÃO BIBLIOGRÁFICA

Neste tópico será abordada de maneira sucinta e objetiva uma revisão bibliográfica acerca dos aspectos morfológicos da cultura da bananeira, assim como seu aspecto sanitário. O capítulo tratará também do histórico e das aplicações dos Veículos Aéreos Não Tripulados – VANTs, Sensoriamento Remoto e aprendizagem computacional, voltados principalmente para a área agrícola. Buscou-se, desta maneira, contribuir para a integração dos trabalhos mais importantes relacionados ao tema, introduzindo conceitos que ajudarão a compreender a metodologia e resultados obtidos. Espera-se contribuir com o avanço dos conhecimentos acerca dos VANTs associados principalmente à agricultura de precisão.

2.1 A cultura da bananeira

2.1.1 Aspectos históricos, econômicos e fisiológicos

A maior parte dos levantamentos históricos indica a origem das espécies comestíveis de banana (*Musa sp.*) predominantemente no sudeste asiático, nas regiões que hoje compreendem Filipinas, Malásia e Indonésia. Há evidências do cultivo da fruta em Papua, Nova Guiné, entre 5.000 e 10.000 a.C., o que caracterizaria sua população como a pioneira na plantação de bananeiras. Por meio do comércio estabelecido principalmente por árabes e persas, entre a Índia e o norte da Austrália, no decorrer dos séculos V e VI, a banana se espalhou significativamente pelo sul do continente asiático e chegou a diversas ilhas do Pacífico, incluindo o Havaí, junto com o deslocamento da população polinésia. A África Ocidental recebeu suas primeiras mudas cultivadas há mais de três mil anos, apesar de ainda não haver consenso com relação aos responsáveis por este transporte (LANGHE, 2017).

Na Europa, permaneceu razoavelmente desconhecida até o século X. As navegações portuguesas e espanholas no século XV foram as responsáveis pela rápida disseminação da bananeira na América, onde encontrou condições climáticas notáveis para seu desenvolvimento. No Brasil, o cultivo se espalhou rapidamente por entre as comunidades indígenas. Em pouco tempo, passou a ser parte integrante de um número significativo de pratos tradicionais. Também se mostrou excelente matéria-prima para a produção de artefatos de uso diário, como cestos e balaios. Os métodos de preparo do material foram gradualmente desenvolvidos e passados de geração em geração, sendo utilizados até hoje na elaboração de peças de artesanato (LANGHE, 2017).

Em sua fisiologia, a bananeira é planta monocotiledônea pertencente à família botânica Musaceae. É classificada como vegetal herbáceo completo devido presença da raiz, tronco, folhas, flores, frutos e sementes, com porte variável (2 a 5 metros), conforme Figura 1. O caule é representado pelo rizoma e o conjunto de bainhas das folhas, sendo denominado pseudocaule, conhecido popularmente como tronco da bananeira. A sua inflorescência tem flores masculinas, femininas e raramente hermafroditas. Como não há polinização, normalmente não há sementes viáveis, sendo propagadas vegetativamente pelo plantio de rizomas ou multiplicando-se naturalmente no campo, por via vegetativa, pela emissão de novos rebentos. Entretanto, o seu plantio também pode ser feito por meio de mudas, brotos ou micropropagação em cultura de tecidos (BLANCO; FRANCO; NOMURA, 2013).

Figura 1 - A) Banana Prata na fase vegetativa pré-produção. B) Banana Prata na pré-colheita e C) Colheita manual de Banana Prata em Iguatu, Ceará – Brasil



Fonte: Autor, 2018.

Até o início dos anos 2000, o setor produtivo de bananas era caracterizado no Brasil como atividade de baixa produtividade, baixo nível tecnológico e elevadas perdas em pré-colheita e pós-colheita (CORDEIRO, 2000). Tal cenário foi sendo modificado a partir de progressos tecnológicos empregados à cultura; disponibilidade de material genético diversificado; mudas sadias e de boa qualidade genética; práticas culturais de manejo pré-colheita e pós-colheita; técnicas fitossanitárias e técnicas de nutrição e de irrigação e a melhoria no nível técnico e organizacional do bananicultor brasileiro (RAMBO *et al.*, 2015).

Deste modo o emprego de tecnologia fez com que a banana se consolidasse atualmente como a segunda fruta mais consumida no planeta, com 11,4 kg/hab/ano, perdendo apenas para a laranja, com 12,2 kg/hab/ano. O continente americano é o maior consumidor, com 15,2 kg/habitantes/ano, destacando-se a América do Sul, com 20 kg/habitantes/ano e a América Central, com 13,9 kg/habitantes/ano (FAO, 2015).

No Brasil, a banana é a segunda fruta mais produzida, com aproximadamente 6 milhões de toneladas por ano e uma área em torno de 520 mil hectares. Fica atrás apenas da laranja, cuja produção está fortemente associada ao processamento industrial de suco concentrado para exportação. Desempenha papel relevante como elemento de fixação do homem no campo e como fonte de alimento e renda, por ser uma cultura que produz durante o ano todo (PLOETZ, KEMA e MA, 2015). A safra brasileira de bananas em 2017, conforme o AGRIANUAL (2018), registrou produção de 8,120 milhões de toneladas, área colhida de 499,17 mil ha e produtividade média de 16,267 ton ha⁻¹.

Cerca de 97% da produção brasileira é comercializada e consumida internamente, propiciando uma pequena participação brasileira no mercado externo. No mercado externo, a maior demanda da fruta se dá por variedades do grupo Cavendish, enquanto que o mercado brasileiro dá preferência a variedades do grupo Prata. De acordo com Embrapa (2006), as variedades Prata, Prata Anã e Pacovan ocupam aproximadamente 60% da área cultivada com banana no Brasil. Para a produção voltada ao mercado externo, fatores como altos índices de perdas, incidência de pragas e doenças na cultura e, principalmente, precária estrutura comercial e de escoamento da produção, são apresentados como as principais dificuldades do ramo (RANGEL *et al.*, 2002; PINHEIRO *et al.*, 2007).

Segundo dados do Ministério da Agricultura Pecuária e Abastecimento (2015), a bananicultura possui grande importância social na geração de emprego e renda para. O setor emprega cerca de dois milhões de trabalhadores, alcançando em 2015 a marca de mais de 500 mil produtores, sendo a maioria composta por agricultores familiares. O cultivo de bananas apresenta-se ainda como uma atividade economicamente viável, com índice de lucratividade de cerca de 20% a 45%, a depender do período (safra ou entressafra), distância do mercado consumidor, níveis de produção, emprego de tecnologia e variedade, como explicam Silva, Tarsitano e Boliani (2005), Furlaneto *et al.* (2005), Lacerda *et al.* (2013), e Rambo *et al.* (2015). Os resultados abaixo da média obtidos com a cultura da banana podem estar relacionados à utilização de mudas de bananeira de baixa qualidade; não realização de tratamentos culturais, tais como a aplicação de inseticidas e fungicidas; e baixo poder de investimento do produtor (RAMBO *et al.*, 2015).

A boa aceitação da banana deve-se ainda aos seus aspectos sensoriais e valor nutricional, consistindo em fonte energética, devido à presença de carboidratos, e contendo minerais, como o potássio, e vitaminas. A casca da banana constitui-se em uma “embalagem” individual, de fácil remoção, higiênica e, portanto, prática e conveniente. A ausência de suco na polpa, de sementes duras e a sua disponibilidade durante todo o ano também contribuem para a sua aceitação (MATSUURA; COSTA; FOLEGATTI, 2004).

Contudo, a produção mundial tem enfrentado problemas, principalmente fitossanitários, que se desenvolvem a partir da interação entre: o ambiente – que são as condições climáticas representadas, principalmente, por umidade e temperatura; o hospedeiro – que neste caso específico é a bananeira e a ação de vetores de doenças – que são os insetos ou o próprio homem com suas interferências diversas, aliados à presença de pragas e/ou patógenos, constituindo os quatro elementos fundamentais, responsáveis pela ocorrência de problemas fitossanitários e por sua gravidade (EMBRAPA, 2000).

Sempre que um ou mais de um dos três primeiros fatores citados acima são desfavoráveis às pragas ou doenças, ou quando o homem intervém positivamente para controlá-las, os problemas fitossanitários são minimizados ou, por vezes, eliminados. Estas são informações básicas que técnicos e agricultores devem ter em mente, para exercer ações de controle sobre esses problemas, valorizando-se a adoção de medidas preventivas e ações planejadas (EMBRAPA, 2000).

2.1.2 A sigatoka-amarela na cultura da bananeira

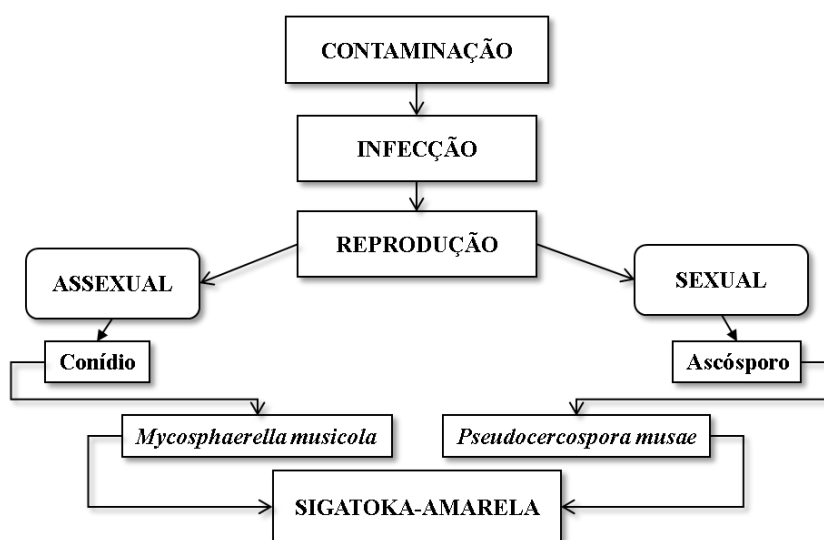
De acordo com Chillet *et al.* (2009) as doenças fúngicas representam um dos maiores fatores limitantes à produção de banana, principalmente devido ao poder infeccioso destes organismos. Os fungos possuem características de adaptação rápida, fácil disseminação, afetam a bananeira em todas as partes (raiz, pseudocaule, folha e fruto), causando grandes prejuízos econômicos, como constataram Peruch *et al.* (2015).

Também conhecida como mal-de-sigatoka e doença das manchas das folhas da bananeira, a sigatoka-amarela foi observada na sua forma epidêmica primeiramente em 1902, em Sigatoka, na ilha de Viti Levu, em Fiji. A doença teve seu início evidenciado no Brasil em 1944, no estado do Amazonas, se estendendo posteriormente para os demais estados (CORDEIRO; MATOS; KIMATI, 2005).

Sendo um dos grandes problemas da bananicultura nacional, a sigatoka-amarela apresenta-se como doença endêmica, com picos durante o período chuvoso no Brasil e

temperaturas ótimas de 25°C. A doença é causada por *Mycosphaerella musicola* Leach, a forma perfeita ou sexuada e *Pseudocercospora musae* (Zimm) Deighton, que corresponde à forma imperfeita ou assexuada do mesmo fungo. Dois tipos de esporos estão envolvidos no aparecimento da doença: o esporo sexuado, que é o ascósporo, e o assexuado, o conídio. As diferenças de comportamento, entre eles, podem se refletir na epidemiologia da doença, que é fortemente influenciada pelas condições climáticas (Figura 2, STOVER, 1971; CORDEIRO; MATOS; KIMATI, 2005).

Figura 2 – Ciclo infeccioso dos patógenos *M. musicola* e *P. musae*



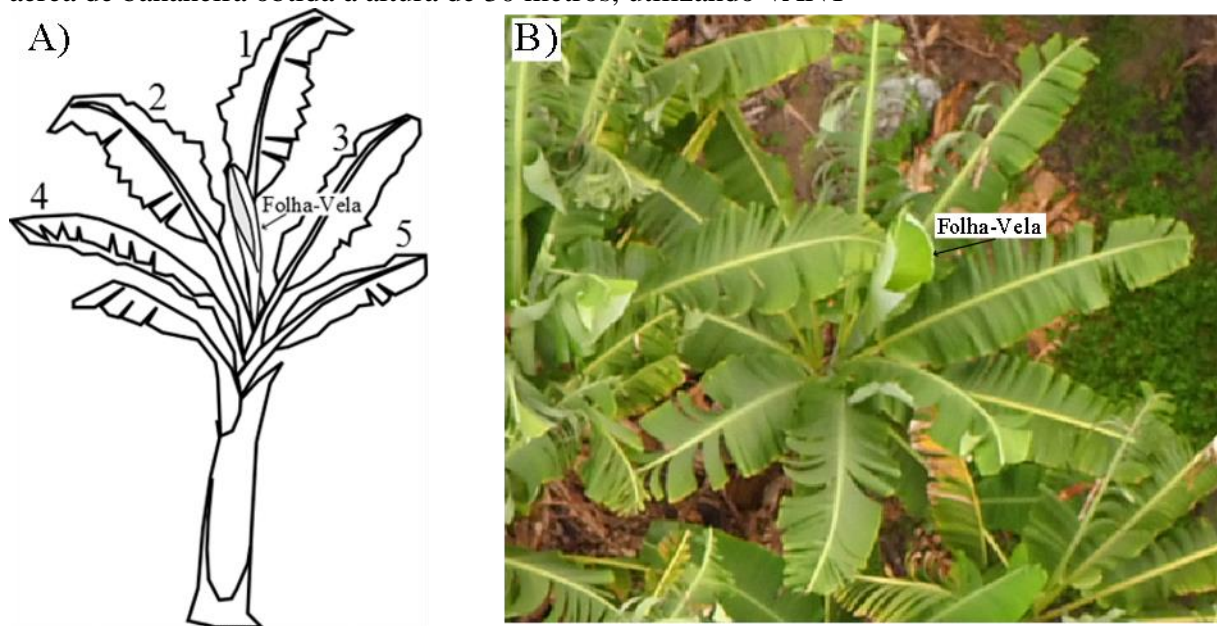
Fonte: Autor, 2018.

Apesar de a doença apresentar picos de infecção nos períodos mais chuvosos, uma característica evolutiva atribuída aos esporos do fungo faz com que, mesmo na ausência de água, a doença permaneça com alto poder de disseminação. Os conídios, desta forma, se tornam a maior fonte de inóculo, por não dependerem da água para serem produzidos, aumentando sua infecção no período seco, causando manchas foliares em todo o cultivo (CHILLET *et al.*, 2009).

A chuva, o orvalho e a temperatura formam juntos o conjunto de elementos fundamentais para que ocorram as infecções, produção e disseminação do inóculo. As folhas mais suscetíveis à infecção, em ordem decrescente, vão da folha “vela” à folha “3”, embora também possa ocorrer infecção na folha “4”, conforme Figura 3. Uma vez depositado sobre a folha, o esporo germinará se houver presença de umidade. A germinação se dará, a depender da temperatura, num intervalo de 2 a 6 horas, ocorrendo posteriormente, o crescimento da hifa

sobre a folha, num processo que pode estender-se pelo espaço de dois a seis dias. A estrutura de infecção do fungo buscará localizar um estômato, onde ocorrerá a formação de um tubo apressório, penetrando assim no tecido vegetal (FERREIRA; CORDEIRO; MATOS, 2003).

Figura 3 – A) Desenho esquemático de ordenamento foliar em planta de bananeira; B) Foto aérea de bananeira obtida à altura de 30 metros, utilizando VANT



Fonte: Autor, 2018.

Para a identificação visual da patologia, alguns sintomas são evidenciados após a infecção dos tecidos vegetais. Os primeiros sintomas observados são pequenos pontos entre as nervuras secundárias, com uma leve descoloração, aparecendo principalmente da segunda à quarta folha. Com a evolução da sintomática, são observadas estrias de coloração amarelada. Ao passar do tempo, as estrias amareladas passam para coloração marrom e, posteriormente, para manchas negras, necróticas, circundadas por um halo amarelo (Figura 4, QUIRINO *et al.*, 2014). Tais sintomas causam redução da área foliar, ou morte prematura dos tecidos, reduzindo o poder produtivo da cultura.

Figura 4 – Sintomas de infecção da sigatoka-amarela em folhas de bananeira



Fonte: Zilton José Maciel Cordeiro (adaptado de CORDEIRO; MATOS; KIMATI, 2005).

Os prejuízos causados pela doença são resultantes da morte precoce das folhas e do consequente enfraquecimento da planta, com reflexos imediatos na produção (STOVER, 1972). Altos níveis de infecção pela doença provocam ainda diminuição do número de pencas e do tamanho dos frutos, maturação precoce dos frutos no campo, enfraquecimento do rizoma e perfilhamento lento. Ao infectar as folhas, provoca a morte prematura das mesmas, causando perdas que podem ser superiores a 50% na produção, com o problema se agravando em microclimas muito favoráveis, com prejuízos que podem atingir 100%, uma vez que os frutos, quando produzidos sem nenhum controle, não apresentam valor comercial. (FERREIRA; CORDEIRO; MATOS, 2003).

Para o controle da patologia, são recomendadas diversas técnicas, dentre elas, o manejo integrado de pragas e doenças é largamente recomendado, sobretudo para colaborar com a redução do uso de agroquímicos nos plantios. Estratégias de controle cultural também são adotadas, visando principalmente criar um microclima desfavorável à disseminação da doença, lançando mão de técnicas de drenagem, combate às plantas invasoras, desfolha, correto manejo nutricional e hídrico (MARIN *et al.*, 2003; DE BELLAIRE *et al.*, 2010). Entretanto, o controle químico é ainda a arma mais eficaz contra a sigatoka-amarela, onde os principais grupos de fungicidas tem como princípio ativo Triadimenol, Benomyl, Tiofanato metílico, Óxido cuproso, Oxicloreto de cobre, Clorotnil, Maconzeb, entre outros (PERUCH *et al.*, 2015).

2.1.3 Monitoramento e controle da sigatoka-amarela

A sigatoka-amarela é uma doença de difícil controle. Geralmente, recomenda-se utilizar um conjunto de medidas, as quais envolvem, principalmente, o controle químico e o uso de variedades resistentes. O controle químico, apesar da sua simplicidade e eficiência,


tem como consequência maiores riscos, como contaminação ambiental e animal, além de encarecer os produtos. Já o controle genético, embora seja eficiente e ambientalmente ecológico, nem sempre agrada o consumidor, uma vez que restringe do mercado as variedades preferidas (FREITAS, 2013).

Quando a opção possível é o controle químico, geralmente, a decisão do momento da aplicação de fungicida é tomada com base no monitoramento da severidade (CORDEIRO; MATOS; KIMATI, 2005), mediante a realização de inspeções e medições semanais do estágio de desenvolvimento das lesões nas folhas 2, 3 e 4, e do ritmo de emissão de folhas (STOVER, 1972). Assim, coloca-se em prática um sistema de pré-aviso, para indicar o momento ideal para se fazer o controle químico.

O método conhecido como pré-aviso biológico foi desenvolvido pelos franceses e, posteriormente, modificado e adaptado para as condições da Costa Rica, possibilitando a redução do número de aplicações de fungicidas. Stover (1972) classificou o desenvolvimento das lesões em cinco estádios, que são: I – pintas amarelas com menos de 1 mm de largura, apresentando-se na superfície foliar; II – as pintas evoluem para estrias de coloração amarelada, com aproximadamente 3 ou 4 mm por 1 mm de largura; III – as estrias tornam-se mais largas e compridas, com margens não bem definidas que se misturam com a coloração normal das folhas e, ao final, tornam-se marrom-claras; IV – manchas com contorno bem definido, centro marrom e halo amarelado ao redor da lesão, com início da produção de esporodóquios e podendo haver conídios presentes na lesão; e V – as manchas completamente desenvolvidas apresentam o centro com coloração cinza e bordas escuras e preta. Pode apresentar formação de halo clorótico entre a lesão e o tecido normal da folha, como ilustra Figura 5.

Figura 5 – Grau de Sintoma do ataque da sigatoka-amarela. Adaptado de Meredith (1970)

Grau de Sintoma



Fonte: Adaptado de Meredith (1970).

O sistema de pré-aviso biológico prevê a taxa de desenvolvimento da doença por meio de escalas de sintomas vistos nas folhas da bananeira. O método de previsão se baseia na interação entre o estágio de desenvolvimento das folhas e a severidade da doença nas folhas mais novas. Este sistema leva em consideração um valor de soma bruta (SB) que quantifica a severidade da doença, indicando o melhor momento para realização do controle químico, logo, com maior probabilidade de racionalização do uso de fungicidas. No entanto, uma das premissas básicas para o sucesso no controle da sigatoka-amarela é a realização de estudos localizados, a fim de ajustar qualquer que seja o método, às condições da região (FERREIRA; CORDEIRO; MATOS, 2003). Os mesmos autores estudaram o sistema de pré-aviso biológico no Recôncavo Baiano, com redução de 40% no número de aplicações de fungicidas, utilizadas em intervalos pré-estabelecidos de 21 dias.

Geralmente, os trabalhos de pesquisa nessa linha adotam a taxa de emissão foliar (estádio de evolução da folha vela) segundo a escala proposta por Brun (1963) e a incidência da doença, nas folhas 2, 3 e 4, segundo a escala proposta por Fouré (1994). Para o monitoramento da severidade usa-se com muita frequência o método de Estado de Evolução (EE), baseado no sistema de pré-aviso biológico desenvolvido por Ganry e Meyer (1972). Este método considera o ritmo de emissão foliar semanal (REF) e os estádios precoces do desenvolvimento dos sintomas (1, 2 e 3) presentes na segunda (II), terceira (III) e quarta (IV) folha, a partir da folha-vela. Para o cálculo do valor de soma bruta atingido, os dados referentes ao estágio da lesão e densidade de ataque nas folhas 2, 3 e 4 são multiplicados pelos coeficientes como os estabelecidos por Ganry e Laville (1983).

Quirino *et al.* (2014) buscaram a correlação entre a temperatura e pluviosidade aos níveis de severidade do ataque da sigatoka-amarela. Os autores relataram um maior nível de infecção após chuvas intensas na região, o que aumentou a umidade relativa do ar. No entanto, segundo Meredith (1970), as infecções da sigatoka-amarela ocorrem nas primeiras três folhas novas, aparecendo os primeiros sintomas (estrias) entre 11 e 106 dias após a germinação dos esporos. A geminação dos esporos está diretamente ligada à presença de água livre na superfície das folhas, e o período de geminação, portanto, é relativamente longo e pode atrasar a visualização dos sintomas da doença.

2.2 Sensoriamento remoto e processamento digital de imagens

2.2.1 O Sensoriamento remoto como ferramenta de análise

Dados e técnicas de Sensoriamento Remoto (SR) têm sido progressivamente aplicados em diversos campos do conhecimento (MOREIRA, 2003) e, associado aos Sistemas de Informações Geográficas (SIGs), estabeleceram-se como ferramentas indispensáveis para diversas áreas do conhecimento.

Na definição de Lillesand, Kiefer e Chipman (2008), o sensoriamento remoto é tido como o conjunto de técnicas de obtenção de informações de um alvo ou fenômeno sem o contato físico com o mesmo. A aquisição de dados remotos é realizada com o auxílio de sensores capazes de capturar a reflectância da superfície de alvos, segmentando o espectro eletromagnético, podendo estar a bordo de satélites, aviões ou VANTs (ZHANG *et al.*, 2011). Desta maneira, é possível a diferenciação entre alvos de interesse, como corpos hídricos, vegetação e solo exposto, apresentando grande utilidade para a estimativa rápida e precisa do uso do solo em determinada localidade.

Com o rápido desenvolvimento da geoinformática, as potencialidades vêm sendo continuamente ampliadas e, com o passar dos anos, o avanço tecnológico tem favorecido o surgimento de novas soluções para o Sensoriamento Remoto Agrícola (SRA) (SHIMABUKURO; MAEDA; FORMAGGIO, 2012). Diversas aplicações orientadas para monitoramento e gestão dos recursos naturais (HORCHER e VISSER, 2004), monitoramento da vegetação (SUGIURA, *et al.*, 2005), agricultura de precisão (REIDELSTUERZ *et al.*, 2007), mapeamento de sítios arqueológicos (BENDEA, *et al.*, 2007; PATIAS, *et al.*, 2007), mineração e fiscalização (ROCK *et al.*, 2011), segurança e meio ambiente (ROIG *et al.*,

2013), cartografia (REMONDINO *et al.*, 2011), são desenvolvidas, colaborando para a sustentabilidade do planeta.

O sensoriamento remoto teve sua origem nos anos 1960, sendo considerado atualmente como uma das mais bem-sucedidas tecnologias de coleta automática de dados para o levantamento e monitoração dos recursos terrestres em escala global. A aquisição desses dados pode ser realizada a nível de campo, laboratório, plataformas sub-orbitais e orbitais, conforme elucida JENSEN (2007).

Com o advento da tecnologia, robótica e computação, o sensoriamento remoto se desenvolveu, possibilitando a observação da Terra em escala global e periódica, acompanhando e estudando os fenômenos naturais. Esta ciência empregada em escala mundial, talvez, reúna a maior diversidade de pesquisadores e usuários, em torno de uma tecnologia de aplicação. Assim, o sensoriamento remoto passou a ser largamente utilizado, permitindo o rápido monitoramento, a avaliação de importantes variáveis ambientais e de diversos outros fatores relacionados com as atividades humanas e ambientais. Atualmente, esta tecnologia está inserida, operacionalmente, nas mais diversas áreas do conhecimento, seja no âmbito acadêmico ou no comercial (SHIMABUKURO; MAEDA; FORMAGGIO, 2009).

Todo o princípio do sensoriamento remoto está baseado no conceito de Radiação Eletromagnética (REM). Como dito anteriormente, os dados de SR podem ser obtidos utilizando diferentes níveis de coleta: laboratório, campo, sub-orbital e orbital. Independentemente do nível de coleta das informações, os sensores podem ser inseridos em duas grandes classes: sensores ativos ou sensores passivos. Os sensores passivos não possuem fonte própria de energia eletromagnética e, portanto, captam a energia emitida ou refletida pelos alvos (principalmente pela luz solar). Os sensores ativos, por sua vez, possuem fonte própria de energia (CAMPBELL, 2011).

A REM é o meio pelo qual a informação é transferida do objeto ao sensor. A REM pode ser definida como uma forma dinâmica de energia que se manifesta a partir de sua interação com a matéria (CAMPBELL, 2011).

A quantidade de energia refletida por um alvo é função de três fatores: a energia eletromagnética incidente, que pode ser proveniente do sol ou uma lâmpada; a quantidade de energia absorvida e a quantidade de energia transmitida (BAUMGARDNER *et al.*, 1986). O fluxo radiante que incide sobre a superfície de área A é denominada de irradiância, e a radiação que deixa a superfície terrestre é denominada de radiância, assim a quantidade de radiância (radiação refletida em Wm^{-2}) comparada com a irradiância (radiação incidente em

Wm-2) sobre o solo, fornece a medida de reflectância que pode ser captada por sensores, como o espectrorradiômetro (LORENZZETTI, 2015).

Os sensores hiperespectrais permitem que a energia refletida seja adquirida em cada comprimento de onda ao longo de um espectro contínuo (CAMPBELL, 2011), fornecendo um conjunto de gráficos ou dados numéricos conhecidos como curva ou comportamento espectral.

Outro importante conceito a ser compreendido, são as definições de resolução espacial, resolução espectral, resolução temporal e resolução radiométrica. A resolução espacial indica o tamanho da menor separação angular ou linear que um sensor pode identificar, sendo medida geralmente em metros, quilômetros ou graus. É também utilizado o termo Ground Sampling Distance, para assim indicar o nível de detalhamento de uma imagem adquirida. A resolução espectral indica o número e o tamanho de intervalos de comprimentos de ondas (bandas) do espectro eletromagnético no qual o instrumento é sensível. A resolução temporal refere-se à frequência (geralmente em dias ou horas) em que um determinado sensor pode capturar imagens consecutivas de um determinado alvo e, por fim, a resolução radiométrica que é definida como a sensibilidade do sensor a diferenças na magnitude do sinal que é medido, ou seja, ela define o número de níveis em que o sinal pode ser discriminado (JENSEN, 2007).

2.2.2 O Sensoriamento remoto no monitoramento de pragas agrícolas

As perdas de produção ocasionadas por pragas e doenças agrícolas são substanciais no Brasil e no mundo, sendo um dos principais desafios da atualidade adotar manejos adequados, que sejam rápidos, eficientes e que causem pouca ou nenhuma agressão ao meio ambiente. Nessas circunstâncias, as tecnologias de sensoriamento remoto oferecem meios não destrutivos de análise, sem nenhum dano ao meio ambiente, promovendo um manejo dos recursos naturais com mais responsabilidade (REN *et al.*, 2012).

O manejo de pragas e doenças na agricultura pode ser realizado, classicamente, de duas maneiras: os técnicos fazem visitas à lavoura, obedecendo a uma frequência pré-estabelecida, observando a ocorrência e evolução dos sintomas e; instalando armadilhas individuais para cada praga para identificar a possível ocorrência de tais moléstias. Em ambos os casos, nota-se um consumo considerável de mão-de-obra e tempo, sendo necessária uma equipe treinada para a realização de tais serviços (REN *et al.*, 2012).

Naturalmente há uma grande variabilidade de culturas agrícolas, com diferentes estruturas de solo, estágio vegetativo ou porte. O manejo de adubação, irrigação, tratamentos culturais diversos, grupos e variedades diferentes, formam o conjunto de variáveis que individualizam cada cultivo, apresentando-se como um dos maiores desafios à padronização e ao entendimento dos fenômenos naturais, por técnicas de análise e processamento de dados remotos, onde as características espectrais (cor, reflectância, textura) são particulares e intrínsecas a cada cultura (LEE *et al.*, 2010).

Nos processos de aquisição das informações, destacam-se o monitoramento de plantios a partir de composições tridimensionais (BARTON, 2012). Tais processos utilizam a informação da composição 3D (Multi-angle remote sensing technology) dos dosséis correlacionando a diferentes tipos de estresse em campo, como nutricional, hídrico ou sanitário. A utilização de sensores orbitais, no entanto, dificulta esta análise principalmente devido ao período de revisitação do sensor a determinada localidade (resolução temporal) e o nível de detalhamentos (resolução espacial) dos levantamentos (HALL *et al.*, 2008). Os VANTs (Veículos Aéreos Não Tripulados), deste modo, são capazes de gerar informações com maiores níveis de detalhes, com resolução temporal conforme a tomada de decisão do operador e com nível de precisão fotogramétrico em padrões e níveis de excelência (CALOU *et al.*, 2017).

Ainda sobre a aquisição dos dados remotos, Qi *et al.* (2008) utilizaram técnicas multitemporais para avaliar doenças fúngicas na cultura do trigo (Oídio e Ferrugem). Tais técnicas consistem na análise de determinado fenômeno a partir de uma série histórica de dados orbitais. Qi *et al.* (2008) em cultivo de arroz, além de utilizarem técnicas de aquisição de dados multitemporais, correlacionaram as perdas causadas por um inseto à índices vegetativos, através de sensores multiespectrais. A correlação de parâmetros sanitários de cultivos à REM foi aplicada por Gao *et al.* (2007), Qi *et al.* (2008), Qiao *et al.* (2010), Wang *et al.* (2017).

No cenário da agricultura de precisão, portanto, as ferramentas de análise e processamento de dados obtidos a partir de plataformas aéreas já são uma realidade no campo, como elucidam Columina e Molina (2014). Os trabalhos envolvendo a detecção e monitoramento de pragas e doenças utilizando imagens aéreas obtidas por meio de VANTs (RPAs, UAVs, UAS) são de estudo recente, auxiliados principalmente pela evolução dos sensores e ferramentas de análise computacional. Dentro deste contexto, Di Gennaro *et al.* (2016), buscaram correlacionar o aparecimento de manchas fúngicas na cultura da uva a índice de vegetação, partindo do pressuposto que a perda de clorofila pelas folhas acometidas

pela doença terá uma resposta da reflectância diferente de uma folha normal, principalmente na banda infravermelha, que de acordo com Novo (2010), está fortemente correlacionada com os níveis de pigmentos fotossintéticos.

Tetila *et al.* (2017) propuseram metodologia para a identificação de doenças foliares na soja utilizando VANTs (Phantom 3, DJI), indicando a grande possibilidade de utilização de ferramentas imageadoras para fins de detecção de anomalias foliares. Realizaram processamentos com seis algoritmos classificadores (SMO, RandomForest, J48, NaiveBayes, K-NN, Ada Boost) em cinco alturas de voo (1, 2, 4, 8 e 16 metros). Os autores propuseram um método para identificação e segmentação das folhas em um plantio, demonstrando que as cores e textura dos pixels podem ser utilizadas como poderosas ferramentas aliadas à aprendizagem computacional. Os algoritmos alcançaram níveis de acertos excelentes, com valores acima de 98%, sendo reduzidos cerca de 2% conforme se aumentavam as altitudes de voo.


A busca por métodos de análise e processamento de dados que sejam rápidos, baratos e de fácil execução, portanto, é objeto de grande número de pesquisas, como relatam Sankaran *et al.* (2010) e Singh *et al.* (2016). Pesquisas utilizando sistemas remotos de identificação de doenças, deste modo, foram fortemente alavancadas pelo consórcio de ferramentas computacionais, como algoritmos de classificação e aquisição de imagens aéreas com alta resolução espacial, como discorrem Garcia-Ruiz *et al.* (2013); métodos computacionais para a identificação local de doenças foliares com Shrivastava e Hooda (2014), Zhou *et al.* (2014), Gui *et al.* (2015), Pires *et al.* (2016), Singh e Misra (2017) e Bajwa, Rupe e Mason (2017); utilização de algoritmo SVM (Support Vector Machine) e redes neurais artificiais para a identificação e cálculo da área foliar na cultura da soja, utilizando VANTs, com Yuan *et al.* (2017).

2.2.3 Histórico e aplicações gerais dos VANTs

Grande parte da tecnologia atualmente conhecida e utilizada em aplicações civis é decorrente de uma demanda bélica envolvendo os conflitos armados no curso da história da humanidade. A aviação mundial, neste contexto, é continuamente marcada pelos avanços tecnológicos decorrente de tais conflitos e guerras. Assim, os veículos aéreos não tripulados (VANTs, derivação da língua inglesa UAV – Unmanned Aerial Vehicle) (Figura 6) surgiram como uma resposta às necessidades da indústria armamentista, sendo utilizados no mapeamento de áreas estratégicas, reconhecimento de terrenos e identificação de alvos, ou até

mesmo em ataques aéreos, como o Kettering Aerial Torpedo, o primeiro VANT usado para combates, em 1918. Neste período, porém, os VANTs eram imprecisos na coleta de informações e suas aplicações não tiveram reconhecimento por muitos militares e líderes políticos (VALAVANIS, 2008; FAHLSTROM; GLEASON, 2012).

Figura 6 – A) VANT multirrotor, modelo Inspire 2, da DJI. B) VANT asa fixa, modelo Ebee, da senseFly



Fonte: DJI Inovations e Ebee.

No Brasil, desde o ano de 2016, vem ocorrendo uma discussão acerca da legislação para o uso dos VANTs. É de competência do DECEA (Departamento de Controle do Espaço Aéreo), Órgão do Sistema de Controle do Espaço Aéreo Brasileiro (SISCEAB) legislar acerca do espaço aéreo, com a portaria N°282/DGCEA, de 22 de dezembro de 2016. A plataforma SARPAS foi desenvolvida com o objetivo de facilitar o acesso ao espaço aéreo brasileiro para o uso dos VANTs. Observam-se algumas prerrogativas para este acesso como o cadastramento do piloto responsável e cadastramento e homologação do equipamento de voo. Para a solicitação do acesso ao espaço aéreo, faz-se necessário a definição do local de decolagem e plano de voo, descrição dos objetivos do voo, data e hora pretendidos para a execução da missão, altura de voo. A solicitação será avaliada pelo órgão regional do DECEA e, de acordo com as características da missão, as permissões de acesso ao espaço aéreo serão efetuadas num prazo que pode variar de 45 minutos a 18 dias.

O Código Brasileiro de Aeronáutica, CBA (Lei n° 7.565, de dezembro de 1986), orienta a apuração e a aplicação das sanções administrativas através de várias penalidades, como multas para pilotos que infringirem qualquer orientação previstas na legislação vigente.

Segundo Glade (2000), o Departamento de Defesa dos Estados Unidos definiu os veículos aéreos não tripulados como aeronaves que não possuem um piloto a bordo, podendo ser pilotadas remotamente por operadores humanos ou guiados por programas

computacionais. São comumente chamados de “drones”, porque o som emitido pelos VANTS multirrotores assemelha-se ao de um “zangão”, tradução em inglês, mas também podem assumir outras denominações, como no caso dos veículos de combate aéreo não tripulado – VCANTs, ou Remotely Piloted Aircraft – RPA (BRASIL, 2015).

Os VANTs podem ainda ser classificados em categorias que dizem respeito ao design de voo, podendo ser multirrotor ou asa fixa. Lucieer *et al.* (2014) e Mattiello *et al.* (2015) apontam algumas vantagens que o sistema multirrotor apresenta em relação ao sistema de asa fixa, como a possibilidade de manter-se em posição estática no ar, voar a baixas velocidades e possuir uma aterrissagem mais suave. A principal desvantagem deve-se ao fato da autonomia de voo ser menor que os VANTs de asa fixa, por conta da baixa aerodinâmica.

O desenvolvimento tecnológico possibilitou a evolução dos modelos passados para robustos e precisos sistemas atuais. Na última década, pesquisadores de diversas áreas testaram e comprovaram a eficiência dos VANTs para variados fins, como controle do trânsito, contagem eficiente de veículos e apoio de equipes em solo em eventuais acidentes (DOHERTY, 2004; HAARBRINK e KOERS, 2006; PURI, VALAVANIS, KONTITSIS, 2007).

Aplicações para o monitoramento, documentação, reconstrução de edificações históricas e sítios arqueológicos de difícil acesso (RUBIO *et al.*, 2005; EISENBEISS; ZHANG, 2006; ÇABUK; DEVECI; ERGINCAN, 2007); Medição do fluxo de dióxido de carbono de erupções vulcânicas (MCGONIGLE *et al.*, 2008) e monitoramento das atividades vulcânicas (AMICI *et al.*, 2013); Identificação de incêndios e apoio no monitoramento de queimadas (CASBEER *et al.*, 2005; RESTAS, 2006; MAZA *et al.*, 2011; MERINO *et al.*, 2012); Aplicação pioneira no monitoramento do degelo no Himalaia através de mapas de elevação gerados a partir da coleta de dados utilizando VANTs (IMMERZEEL *et al.*, 2014); Identificação e monitoramento de vegetação subaquática em rios (FLYNN e CHAPRA, 2014).

2.2.4 VANTs aplicados à agricultura de precisão

A explosão do uso das aeronaves não tripuladas trouxe também ao campo agrícola sua contribuição, onde dentre as aplicações, podem ser citadas o monitoramento das lavouras para identificação de pragas, doenças e mapeamento de plantas invasoras, deficiências nutricionais nas culturas agrícolas, déficit hídrico, previsão de safras, monitoramento da erosão do solo.

O início dos trabalhos aplicados à agricultura se deu com Herwitz *et al.* (2004), que realizou os testes de um VANT projetado pela NASA, onde sobrevoou diversos campos de produção de café, no Havaí. Foram identificadas nas imagens diversas características como plantas invasoras nas linhas de plantio, falhas na irrigação, anomalias de fertilidade e sanidade. A missão abriu as portas para as diversas pesquisas relacionando VANTs na agricultura.

Muitos pesquisadores buscaram demonstrar a relação entre a reflectância da luz dos vegetais (alvos) e os parâmetros biofísicos destes, como índice de área foliar, biomassa ou status hídrico (COHEN *et al.*, 2003). Porém somente a partir da segunda metade dos anos 2000, foram feitas associações de VANTs e sensores multiespectrais com resultados expressivos, com Hunt Jr. *et al.* (2005), que buscaram correlacionar o teor de nitrogênio em plantas de milho com um índice calculado a partir da reflectância das bandas verde e vermelha, (Normalized Green-Red Difference Index - NGRDI), onde não obtiveram nenhuma correlação, apesar dos tratamentos com baixas doses de nitrogênio serem facilmente identificados pelas imagens aéreas. Estudaram também a relação do NGRDI com a biomassa de plantas de milho, alfalfa e soja, onde encontraram uma correlação linear para valores de biomassa abaixo de 120 g.m⁻². Lelong *et al.* (2008) foram adiante, buscando analisar a relação entre o índice de área foliar e o Normalized Difference Vegetation Index (NDVI – Rouse *et al.*, 1973), utilizando as câmeras Canon EOS 350D e Sony DSC-F828, onde encontraram coeficientes de correlação acima de 0,80. Nesta mesma linha, Gay *et al.* (2009) utilizaram um VANT de asa fixa associado a um sensor multiespectral (350 a 950 nm) para calcular o NDVI de um plantio de cevada, adubado com diferentes doses de nitrogênio, encontrando forte relação entre os parâmetros.

No campo da pesquisa direcionada a inserção de novos produtos no mercado, como herbicidas, inseticidas, fungicidas e fertilizantes, são realizadas diversas inspeções visuais durante os processos de testes. Tais procedimentos, atualmente, segundo Nebiker *et al.* (2008), podem ser substituídos por VANTs, por gerarem produtos de ótima resolução espacial para pequenas áreas de pesquisa. Além disso, a associação de VANTs a sensores multiespectrais já era idealizado por Nebiker *et al.* (2008), quando desenvolveram o protótipo de um sensor multiespectral de alta resolução espacial para a avaliação da sanidade dos cultivos.

Hunt Jr. *et al.* (2010) testaram duas variedades de trigo no segmento de monitoramento de culturas agrícolas, associando o índice de área foliar com o GNDVI (Green Normalized Difference Vegetation Index), encontrando alta correlação.

Remondino *et al.* (2011) inauguraram a segunda década dos anos 2000 dissertando sobre as perspectivas futuras da utilização de VANTs conjugados a softwares de geração de mapas 3D a partir da sobreposição de imagens aéreas. Xiang e Tian (2011) buscaram o desenvolvimento de um VANT (RC Helicopter) associado com um sensor multiespectral (Agricultural Digital Camera, USA), sensível às bandas do verde (520 – 620 nm), vermelho (620 – 750 nm) e infravermelho próximo (750 – 950 nm) com o objetivo de promover o monitoramento da aplicação de um herbicida (Glifosato) em um gramado.

Ainda sobre a agricultura de precisão, alguns pesquisadores buscaram o correto manejo dos recursos hídricos a partir de ferramentas de SR. No contexto, Zarco-Tejada e Berni (2011) realizaram a detecção de estresse hídrico em um pomar de laranjeira, utilizando dois sensores: um termal e outro hiperespectral (400 – 885 nm, com 260 bandas espectrais, intervalo de 1,85 nm) a bordo de um VANT, possibilitando a obtenção da reflectância e radiância das copas individuais das árvores, obtendo resultados expressivos para tal finalidade.

No campo do monitoramento de lavouras, Peña-Barragán *et al.* (2012) realizaram a classificação das linhas de plantio de milho para a identificação de plantas invasoras, utilizando um software que faz uso de um algoritmo (Looping Algorithm) que integrou diversas características, como os padrões de crescimento e desenvolvimento das culturas, propriedades espectrais (NDVI), relacionamento entre os alvos vizinhos, com base na distância, posição e ângulo. O software utilizado, denominado eCognition Developer 8, mostrou grande eficiência na classificação do ortomosaico produzido por meio de imagens obtidas com VANT, apesar da grande similaridade no estágio inicial entre a cultura do milho e as plantas invasoras.

Baluja *et al.* (2012), Zarco-Tejada, González-Dugo, Berni (2012) e Bellvert *et al.* (2014) relacionaram câmeras termais e multiespectrais a VANTs, buscando a correlação entre a temperatura e o teor de água em plantações. No segmento da conservação e manejo do solo, d'Oleire-Oltmanns *et al.* (2012), buscaram o monitoramento da erosão do solo a partir de um modelo digital de terreno gerado a partir das imagens capturadas por um VANT de asa fixa.

Bending (2014) utilizou técnicas de sensoriamento remoto em consórcio com os VANTs para buscar um método eficiente de estimativa da biomassa e da altura de plantas, acompanhando e monitorando um cultivo de cevada e arroz. Shahbazi *et al.* (2015) buscaram desenvolver e avaliar o sistema de um VANT, incluindo hardware e software conjugados para um mapeamento de alta precisão e geração de modelo 3D. Feng, Liu e Gong (2015) obtiveram resultados satisfatórios ao mapear a vegetação de uma área urbana e classificar os

diferentes tipos de cobertura na superfície. Shahbazi *et al.* (2015) e James *et al.* (2016) buscaram desenvolver e avaliar o sistema de um VANT, incluindo hardware e software conjugados para um mapeamento de alta precisão e geração de modelo 3D, avaliando a qualidade do georreferenciamento do modelo e nuvem de pontos gerada. Ming Han *et al.* (2016) e Santesteban *et al.* (2016) relacionaram câmeras termais e multiespectrais a VANTs, buscando a correlação entre a temperatura e o teor de água em plantações. Alsalam (2017) utilizou imagens de alta resolução, obtidas por meio de VANT, para a identificação e mapeamento de plantas invasoras, em cultivo de espécie forrageira.

No mercado, atualmente, não há um grande número de sensores multi ou hiperespectrais para a utilização em conjunto aos VANTs. Algumas marcas se consolidaram no mercado, como a MicaSense, Rikola, Tetracam Inc, XIMEA, senseFly, ofertando câmeras, que variam de \$ 3.500,00, como a Parrot Sequoia®, fabricada pela MicaSense e € 40.000 a Rikola®, fabricada pela MosaicMill Ltd. Neste cenário, Bareth *et al.* (2014) realizaram uma comparação entre duas câmeras hiperespectrais a bordo de um VANT, validando os resultados utilizando um Espectrorradiômetro FieldSpec 3, com amostragens em plantio de cevada. Os resultados foram considerados promissores, atestando a fidedignidade dos sensores na coleta do espectro de alvos.

2.2.5 Identificação, classificação, quantificação e predição (ICQP) de padrões a partir de técnicas de sensoriamento remoto e *machine learning*

A agricultura de precisão utiliza dados coletados através de sensores variados, processados no tempo e espaço, para auxiliarem nos processos de tomada de decisão, aumentando a eficiência no uso dos insumos agrícolas (HARMON *et al.*, 2005). O sensoriamento remoto (SR) foi sendo incorporado às técnicas da agricultura de precisão ao longo dos anos, oferecendo soluções satisfatórias para o desenvolvimento das atividades agrícolas, com o aumento das produtividades e colaboração para a sustentabilidade dos recursos naturais (MULLA, 2013). Atreladas a tais técnicas, as ferramentas de Machine Learning (ML – aprendizagem computacional), revolucionaram os processamentos de dados de maneira remota, identificando, classificando, quantificando e predizendo (ICQP) fenômenos singulares e padrões em campo (HONKAVAARA *et al.*, 2013; SINGH *et al.*, 2016).

Bashish, Braik e Bani-Ahmad (2010) realizaram a classificação de cinco doenças foliares, utilizando um processamento em duas etapas: a segmentação a partir de algoritmo K-

means e a classificação dos padrões com base em Redes Neurais Artificiais, indicando uma precisão de 93% nos resultados. Gurjar e Gulhane (2012), em outra vertente, a partir de método PCA, obtiveram 90% de acerto e precisão para a identificação de três doenças foliares na cultura do algodão, utilizando câmera digital comum.

Phadikar, Sil e Das (2012), utilizaram classificadores do tipo Bayes (Maximum Likelihood) e SVM para identificar doenças fúngicas foliares na cultura do arroz (mancha parda e brusone do arroz) através de câmera comum (Nikon Coolpix p4). Como resultados, os autores discutem a precisão do método Bayes que obteve um sucesso de acertos de 79,5% enquanto o algoritmo SVM, 68,1%. A identificação da mancha parda foi mais assertiva, acumulando individualmente 96,4% de acurácia classificação, devido principalmente à suas características de cor e geometria. Os níveis de infecção e estágio de evolução da brusone do arroz foram responsáveis por gerar uma maior dificuldade de identificação e classificação da doença, levando a acurácia para o patamar de 84%, o que ainda é um nível excelente de assertividade.

Calderón *et al.* (2013) utilizaram um VANT associado a sensores multiespectrais e termais para a identificação de fungos em um plantio de oliveira. Os autores relataram altas correlações ($R^2 = 0.83$) das plantas infestadas pelos fungos e comprimentos de banda infravermelha.

No âmbito de potencial classificador de algoritmos em conformidade com altas resoluções espaciais, Garcia-Ruiz *et al.*, (2013) realizaram uma comparação entre duas plataformas de coleta de dados aéreas para a identificação da podridão cítrica em pomar de laranjeiras. Foram embarcados, em uma aeronave e em um VANT, sensores hiperespectrais para o cálculo de sete índices de vegetação, buscando as bandas que melhor se correlacionavam aos sintomas da doença fúngica em campo. Utilizaram o algoritmo SVM para classificação das imagens, no qual 26 plantas foram utilizadas para o treinamento e a calibração do modelo, e 12 plantas utilizadas para a validação. As imagens adquiridas por meio do VANT alcançaram uma acurácia mais elevada na identificação de plantas doentes (67 a 85%), devido principalmente à alta resolução espacial em relação à aeronave (5,45 cm/pixel GSD VANT; 5,0 m/pixel GSD aeronave tripulada).

Hernández-Rabadán, Ramos-Quintana e Juk (2014) discorreram sobre a identificação de doenças foliares no tomateiro utilizando métodos supervisionados (Bayesian classifier) e não supervisionados (self-organizing map – SOM), através de fotografias simples obtidas com câmera digital comum (Kodak EasyShare C913). A metodologia incluiu processo de correção da iluminação das fotografias e uma normalização nos canais RGB das imagens,

demonstrando que os processos obtiveram níveis de acerto elevados (acima de 97%) na identificação principalmente de manchas foliares.

Shrivastava e Hooda (2014) realizaram a aquisição de fotografias de plantio de soja, utilizando um smartphone (Samsung GT-S3770, resolução 1200x1600 pixels), para identificação de duas doenças fúngicas, causadoras de manchas foliares. O método de classificação supervisionada, denominado k-Nearest Neighbors – KNN (vizinho mais próximo), foi empregado para auxiliar no processo de identificação e diferenciação de cada doença fúngica na folha, resultando em uma estimativa geral de infestação das moléstias, apresentando resultados precisos. Os autores ainda pontuam que os métodos de reconhecimento de padrões por treinamento de algoritmos computacionais são ferramentas interessantes pelo fato de serem rápidos, eficazes e não destrutivos.

Gui *et al.* (2015) propuseram metodologia inovadora, tendo como embasamento a saliência causada às folhas de soja pelas doenças foliares. Os autores utilizaram câmera simples para capturar as folhas infestadas e o algoritmo K-means para a classificação e separação entre as partes saudáveis e as partes infectadas. O método demonstrou que fotografias compostas puramente pelas informações de cores RGB são capazes de fornecer o subsídio necessário a algoritmos de aprendizagem computacional e reconhecimento de padrões para fins agrícolas, principalmente.

Para a cultura da soja, Pires *et al.* (2016) propuseram método de identificação de doenças foliares através de reconhecimento computacional (técnicas de descrição local, algoritmos SURF, HOG, SIFT, PHOW), escaneando amostras foliares (no espectro visível ao olho humano, sem utilização de imagens hiperespectrais), validando as classificações com o algoritmo SVM – Support Vector Machine. Em seu estudo, concluíram que a utilização de imagens pancromáticas (na escala de cinza e na faixa espectral visível ao olho humano), são ferramentas interessantes aliadas a métodos classificadores, resultando em uma eficiência de acertos de 98% para doenças fúngicas, como mofo e ferrugens. Os autores elucidam ainda que, para trabalhos futuros, a utilização de smartphones para as fotografias em campo, ou ainda câmeras a bordo de VANTs, serão fortes aliados para a diminuição das perdas ocasionadas por doenças na agricultura.

Ainda na cultura da soja, Tetila *et al.* (2017) buscaram a identificação de doenças foliares por meio de imagens obtidas através de aerolevanteamento com VANT (Phantom 3) e câmera pancromática (RGB, 12 megapixels) com seis algoritmos classificadores (SMO, RandomForest, J48, NaiveBayes, K-NN, Ada Boost) em cinco alturas de voo (1, 2, 4, 8 e 16 metros). Os autores propuseram um método para identificação e segmentação das folhas em

um plantio, demonstrando que as cores e textura dos pixels podem ser utilizadas como poderosas ferramentas aliadas à aprendizagem computacional. Os algoritmos alcançaram níveis de acertos excelentes, com valores acima de 98%, sendo reduzidos cerca de 2% conforme se aumentavam as altitudes de voo. Os autores foram conclusivos ao citarem que a abordagem pode ser ferramenta poderosa no monitoramento de plantios.

Singh e Misra (2017) apresentaram algoritmo para uma automática detecção e classificação de doenças foliares na cultura da bananeira, feijoeiro, roseira e limoeiro, utilizando imagens RGB. O algoritmo proposto foi comparado com outros métodos de classificação, como K-means e SVM, se mostrando mais assertivo na identificação de doenças foliares. A acurácia geral do algoritmo em todas as análises atingiu o patamar de 97,6%.

Os autores ainda demonstram que, utilizando o caso das doenças foliares na folha da bananeira, a acurácia do algoritmo proposto atingiu um acerto de 90%, comparado com 80% do método K-means. As avaliações são promissoras, configurando perspectivas futuras de implementação do algoritmo juntamente com outros métodos mais avançados, como Redes Neurais Artificiais e Lógica Fuzzy.

Atualmente, os trabalhos continuam avançando, conforme se popularizam os sensores e VANTs utilizados em aerolevantamentos. No segmento da identificação de pragas e doenças, Joalland *et al.* (2018) utilizaram imagens aéreas obtidas por meio de VANT para discriminar cultivares de beterraba suscetíveis à nematoides e prever a produtividade. Nhamo *et al.* (2018) reportou a possibilidade de melhorar a qualidade de classificações e identificação de alvos utilizando processos de pós-classificação de imagens de satélite com imagens aéreas providas de plataformas VANTs. Louargant *et al.* (2018) combinaram sensores multiespectrais às imagens de alta resolução espacial obtidas com VANTs para detecção de plantas invasoras, visando minimizar o uso de herbicidas.

2.2.6 Classificação digital de imagens

Um dos principais desafios do processamento digital de imagens é acessar informações precisas de um determinado alvo ou fenômeno, através de imagens digitais, utilizando ferramentas matemáticas e estatísticas. Os avanços da eletrônica, da computação, da robótica e da geomática possibilitaram a criação de técnicas inovadoras capazes de identificar, prever, acompanhar, classificar, quantificar e relacionar tais fenômenos, com objetivos variados.

Para um maior entendimento das técnicas de classificação e processamento digital, portanto, deve-se entender a estrutura básica das imagens. Em sua conformação mais simples, as imagens são formadas por elementos denominados pixels, compondo uma matriz de x linhas e y colunas, conforme a resolução de cada fotografia. Tais pixels trazem informações em sua estrutura, como níveis de brilho, coloração, intensidade luminosa, quantidade de energia, temperatura, de acordo com o sensor utilizado para capturar uma determinada cena. Diversas abordagens são utilizadas para extrair estas informações brutas dos pixels, realizando um exame individual baseado nos seus atributos (RICHARDS, 1999).

As análises quantitativas dos atributos individuais de cada elemento da imagem são realizadas de modo a categorizar os pixels em classes de interesse do usuário. O resultado destes processamentos é chamado, rotineiramente, de classificação digital de imagens. As classificações têm por objetivo a identificação de feições, promovendo uma melhor fotointerpretação, quantificando a área que cada classe ocupa em determinada cena (RICHARDS, 1999).

De acordo com Mather e Koch, (2011), o reconhecimento e a identificação das classes de pixels de acordo com seus atributos e sua correspondência a feições específicas de alvos (cobertura de solo), são realizados utilizando técnicas de reconhecimento e classificação de padrões matemáticos, compondo os processos de aprendizagem computacional. No caso de dados obtidos por sensor pancromático, os pixels são matematicamente representados como vetores, tais como:

$$\mathbf{X} = \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$

Onde R, G e B são valores que variam de acordo com a resolução radiométrica do sensor (0 a 255 para 8 bits, 0 a 4095 para 12 bits, por exemplo) e x é o pixel em análise. Esta variação é utilizada pelos algoritmos de processamentos matemáticos para categorizar cada elemento da imagem uma classe.

Os métodos de classificação podem ainda ser divididos em Supervisionados e Não Supervisionados, conforme destaca Richards, (1999). A diferença básica entre os métodos consiste em um treinamento prévio do algoritmo no que diz respeito à quantidade de classes e os atributos pertencentes a estas classes. Alguns autores consideram que os métodos de classificação não supervisionados são predecessores aos métodos supervisionados, orientando o usuário no embasamento da quantidade de classes a serem criadas com base nas diferenças entre os atributos de cada pixel. Deste modo, a partir de amostragens representativas de pixels

“puros” pelo próprio usuário, os processamentos matemáticos são realizados, fazendo uma leitura individual pixel a pixel e, de modo probabilístico, classificando cada célula da cena total em classes de interesse.

Como citam Singh *et al.* (2016), o volume de dados gerados a partir da aquisição de imagens utilizando plataformas intraorbitais, tais como o uso de aviões, VANTs, ou captura de imagens *in situ*, em muito vêm colaborando para o aumento das precisões dos métodos de Machine Learning (ML – aprendizagem computacional), categorizando feições com sensibilidade elevada, contribuindo para o avanço das pesquisas no âmbito do processamento digital de imagens que possuem como objetivos a identificação, a classificação, a quantificação e a predição de determinado fenômeno.

Os procedimentos para uma classificação supervisionada envolvem algoritmos que permitam a categorização de cada pixel de uma cena em classes pré-estabelecidas. Cada algoritmo possui sua particularidade estatística e matemática, sendo possível acessar, inclusive, a acurácia dos produtos gerados, comprovando a assertividade dos mesmos. Comumente, as etapas para gerar as classificações das imagens, segundo Richards (1999), são:

a) Decisão da quantidade de classes com base em um conhecimento prévio da cena, segmentando a imagem por tipo de cobertura do solo;

b) Utilização de grupos de pixels representativos às classes (training data – dados de treinamento), com o objetivo de treinar o algoritmo acerca das regiões de interesse. Alguns autores citam que cerca de 1% da cena total deve ser utilizada para o treinamento;

c) Uso dos atributos de cada pixel de treinamento para caracterizar cada classe, de acordo com as características intrínsecas de cada grupo de treinamento. Nesta etapa adentram aos procedimentos as particularidades de cada método de classificação supervisionada, com seus parâmetros, modelos estatísticos e matemáticos. Os grupos de parâmetros inter-relacionados formam a assinatura de cada classe (class signature);

d) Extrapolação da classificação a todos os pixels da cena, categorizando-os e segmentando-os nas classes estabelecidas pelo usuário;

e) Produção de mapa temático e/ou resumos tabulares expondo o resultado das classificações, demonstrando os percentuais que cada classe ocupa na cena;

f) Avaliação da assertividade da classificação, utilizando indicadores estatísticos com base em verdades de campo (amostras que não foram utilizadas no treinamento prévio do algoritmo, para comprovação da acurácia do modelo utilizado).

Algumas das técnicas mais populares de classificação foliar em cultivos agrícolas são citadas por Singh *et al.* (2016), e podem ser categorizadas em técnicas comuns, tais como K-Nearest Neighbor (como o Maximum Likelihood, Minimum Distance, Mahalanobis Distance e Parallelepiped Distance), K-Means e ISODATA (ERDAS, 1999; MATHER e KOCH, 2011). Por outro lado, categorizadas como técnicas avançadas, podem ser citadas as Redes Neurais (Neural Network), o Algoritmo Genético, o SVM (Support Vector Machine), a PCA (Principal Component Analysis) e a Decisions Trees (LAWRENCE *et al.*, 2004; LUCIEER, 2008).

Os métodos KNN (k-Nearest Neighbor) são considerados simples, de fácil implementação e precisos na grande área da aprendizagem computacional, como elucidam (MATHER e KOCH, 2011). As classificações são baseadas pela identificação dos pixels mais próximos (vizinho mais próximo), a partir do cálculo da distância Euclidiana entre as amostras utilizadas para o treinamento.

Os processos matemáticos e probabilísticos envolvidos no algoritmo Maximum Likelihood considera a ponderação das distâncias utilizando parâmetros estatísticos (vetor média e matriz de covariância) de distribuição de pixels dentro de uma determinada classe (QUEIROZ *et al.*, 2004). Por outro lado, a técnica SVM busca minimizar o erro com relação ao conjunto de treinamento (risco empírico), assim como o erro com relação ao conjunto de teste, isto é, conjunto de amostras não empregadas no treinamento do classificador (risco na generalização) (VAN DER LINDEN, *et al.*, 2014). Desta forma, o algoritmo SVM é especializado nas peculiaridades e ruídos dos pixels, ao invés de extrair as características gerais que permitiram a generalização ou reconhecimento de padrões não utilizados no treinamento do classificador (SMOLA *et al.*, 2000). Este fato provavelmente explica o melhor desempenho do algoritmo SVM quando a base de dados de entrada possui altos níveis de ruídos.

Por outro lado, o algoritmo Minimum Distance considera as matrizes de covariância de todas as classes iguais (RICHARDS, 1999), ocorrendo a classificação e categorização dos pixels a partir da menor distância entre o pixel e o centroide das classes compostas por suas respectivas amostras de treinamento. Este processo é realizado a partir da distância Euclidiana. Este algoritmo possui um excelente desempenho para trabalhos que possuem como objetivos a detecção de diferentes alvos utilizando imagens de satélite, como demonstram Rao *et al.* (2017) e Abbas *et al.* (2017).

A classificação de Mahalanobis é sensível à direção, que assume todas as covariâncias de classe são iguais e, portanto, foi um método com desempenho ligeiramente mais rápido, porém, neste trabalho, apresentaram os piores resultados.

No cenário da agricultura de precisão, as técnicas de ML com objetivos de classificação de fatores bióticos, tais como estresses nutricionais, hídricos e sanitários, são consideradas poderosas ferramentas aliadas aos métodos clássicos. O sensoriamento remoto hiper e multiespectral, desta forma, surge como as plataformas mais completas de entrada de dados, no sentido de fornecer as informações necessárias para o aumento das taxas de acurácia dos algoritmos, como citam Powell *et al.* 2004.

Por outro lado, diversos pesquisadores têm trabalhado com imagens pancromáticas simples (RGB), demonstrando grande potencial de aplicações. Tais métodos são vantajosos, pois, comparativamente com métodos hiper ou multiespectrais, são menos onerosos e de mais simples entendimento. Tais produtos obtidos por meio de processamento digital de imagens, deste modo, devem ter sua acurácia devidamente avaliada a partir de uma verdade de campo a fim de conferir maior confiabilidade e facilitar o processo de tomada de decisão, utilizando meios estatísticos como índice de Kappa e Exatidão Global (REMOTE SENSING RESOURCES, 2006).

A comparação entre o poder classificador de algoritmos é recorrente na literatura internacional, na qual se realizam avaliações dos níveis de assertividade dos métodos aplicados. Otukei e Blaschke (2010) realizaram uma avaliação da cobertura de uma cena utilizando imagens Landsat em uma série histórica de 15 anos, avaliando os algoritmos SVM, Maximim Likelihood e Decisions Trees (árvore de decisões). A acurácia dos métodos apresentou sempre valores acima de 85%, porém o desempenho do método de árvores de decisões superou os outros dois em todos os anos avaliados.

Bauer, Korč e Förstner (2011) realizaram a fusão de imagens RGB a multiespectrais para identificar duas doenças fúngicas foliares na cultura da beterraba. Utilizaram os métodos k-Nearest Neighbor e Bayes classification resultando em assertividades acima de 86%.

Kruse *et al.* (2014) citam a utilização de imagens RGB para a identificação de poluição (gás ozônio) na cultura do trevo, alcançando valores de assertividade acima de 95%, com o algoritmo K-means em fusão com técnica LDA (linear discriminant analysis).

Hernández-Rabadán, Ramos-Quintana e Juk (2014) utilizaram técnicas de classificação não supervisionadas e supervisionadas para identificação de manchas foliares na cultura do tomateiro utilizando câmera fotográfica simples (imagens RGB). O autor destaca o

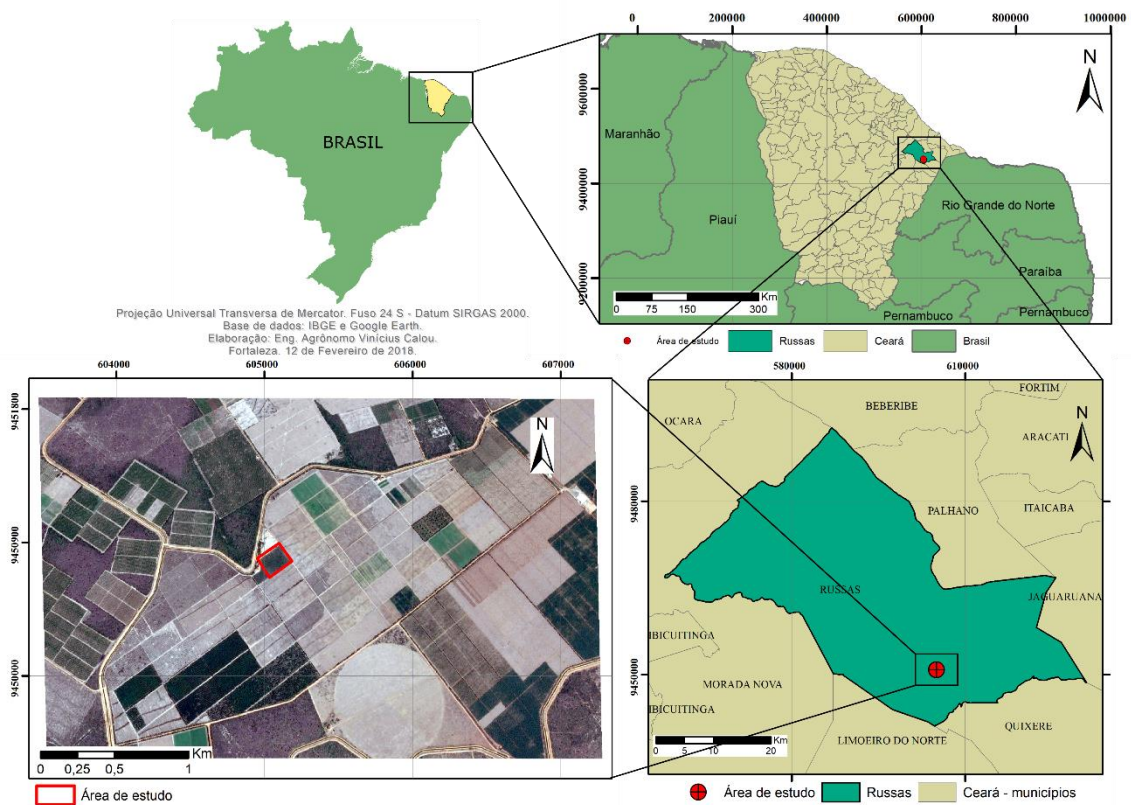
fato da dificuldade de identificação em alguns casos devido à falta de controle de luminosidade entre as imagens principalmente. A identificação e classificação dos alvos, no entanto, apresentaram acurácia acima de 97%, demonstrando o potencial dos algoritmos.

3 MATERIAL E MÉTODOS

3.1 Área de estudo e coleta de dados

O trabalho foi realizado em plantio comercial de bananeiras (*Musa spp.*, Banana Prata) pertencente à empresa Frutacor, localizado geograficamente em 4°58'7,33" Sul e 38° 3'8.88" Oeste, conforme Figura 5, inserida no perímetro irrigado do Tabuleiro de Russas. A empresa é especializada principalmente na produção de bananas, goiabas e limões, atuando no mercado interno. A empresa conta com uma área total plantada de aproximadamente 240 hectares, sendo 120 ha de Banana Prata, 40 de Limão Tahiti (*Citrus aurantifolia*) e 80 de Goiaba Paluma (*Psidium guajava* L.).

Figura 7 – Mapa da área de estudo. Empresa Frutacor, Russas, Ceará, Brasil 2018



Fonte: Elaboração do autor, 2018. Dados do Google Earth e IBGE.

A organização da empresa, no que diz respeito aos tratos culturais na produção de banana, são intensivos, com o envolvimento de grande número de colaboradores, desde os processos de produção de mudas até a pós-colheita e a comercialização.

Toda a água de irrigação é proveniente do açude Castanhão, que possui uma capacidade em torno de 6,7 trilhões de metros cúbicos de água. No entanto, no momento da realização deste trabalho, o reservatório se encontrava com cerca de 3% de sua capacidade. Grande parte da irrigação foi prejudicada devido ao longo período de estiagem que acometeu todo o Nordeste, sendo suprimidas drasticamente as lâminas efetivas aplicadas às culturas. A irrigação dos pomares da empresa é do tipo localizada, com microaspersores Gironet® Netafim, com vazão de 58 L/hora.

A empresa realiza tratamentos culturais principalmente voltados para a nutrição, sanidade, suporte hídrico à cultura, condução, produção e pós-colheita. No que diz respeito à sanidade, o intensivo controle da sigatoka-amarela é realizado a partir de levantamentos de severidade e infestação com equipes de campo, fornecendo o subsídio para a tomada de decisão do momento ideal para a aplicação das medidas de controle e prevenção.

A área específica utilizada para o presente estudo foi um recorte de quatro hectares dentro de uma área de 10 hectares de produção de Banana Prata, conforme Figura 6. As missões foram realizadas dentro do período de setembro a novembro de 2017, segundo a Tabela 1.

Figura 8 – Plantio em fileiras duplas na cultura da bananeira. Frutacor, Russas, Ceará, Brasil 2018



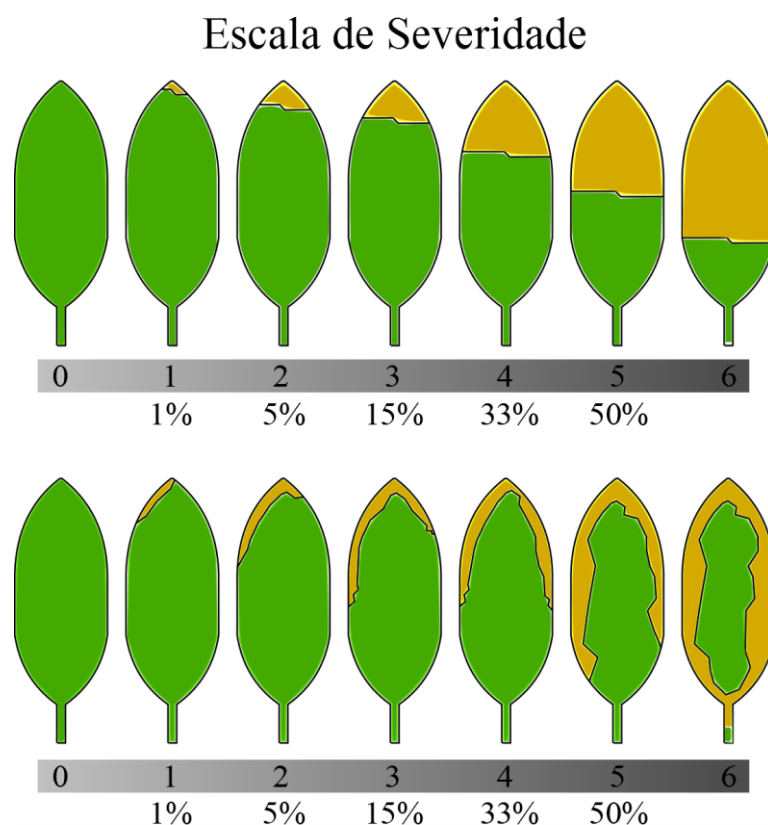
Fonte: Autor (2017).

Tabela 1 – Resumo do período das missões realizadas em campo na empresa Frutacor.

Dia 27 de setembro de 2017	Dia 10 de outubro de 2017	Dia 07 de novembro de 2017
1ª missão de campo	2ª missão de campo	3ª missão de campo

Durante as avaliações de campo, foram realizados, por um técnico especialista, as análises de severidade e grau de sintomas do ataque da sigatoka-amarela, conforme metodologia de Meredith (1970) e Stover (1971), modificada por Gauhl *et al.* (1994). As análises consistiram em um levantamento de 30 amostras aleatórias para representar a área em sua totalidade, atribuindo uma nota de severidade, que se situa entre uma escala de 1 a 5, conforme Figura 9 e 10, respectivamente.


Figura 9 – Grau de severidade do ataque da sigatoka-amarela. Adaptado de Gauhl (1994)



Fonte: Adaptado de Gauhl *et al.* (1994).

Figura 10 – Grau de Sintoma do ataque da sigatoka-amarela. Adaptado de Meredith (1970)

Grau de Sintoma



Fonte: Adaptado de Meredith (1970).

O monitoramento mensal foi realizado por especialistas a partir de levantamento em campo. Em cada missão, a equipe portou pranchetas para anotações, sistema GNSS para aquisição das coordenadas geográficas das plantas amostradas, escada para melhor avaliação da severidade e dos sintomas da sigatoka-amarela, sacos plásticos e isopor para coleta do material vegetal, para posterior análise laboratorial.

A proposta da metodologia, segundo Stover (1971), modificada por Gauhl *et al.* (1994), atribui notas a cada folha das plantas individuais avaliadas, sendo: 0 – sem sintomas; 1 – menos de 1% da lâmina foliar com sintomas (presença de estrias e/ou superior a 10 manchas); 2 – de 1 a 5% da lâmina foliar com sintomas; 3 – de 6 a 15% da lâmina foliar com sintomas; 4 – de 16 a 33% da lâmina foliar com sintomas; 5 – de 34 a 50% da lâmina foliar com sintomas; 6 – de 51 a 100% da lâmina foliar com sintomas.

As avaliações de campo, portanto, foram delineadas de modo aleatório, onde foram selecionadas 30 plantas dentro dos quatro hectares em estudo, georreferenciadas e representativamente distribuídas. Dentre as 30 plantas, foram selecionadas 10 para análise foliar, sendo coletada uma amostra conforme metodologia da Embrapa, para ser levada ao laboratório de Fitopatologia da Universidade Federal do Ceará para confirmação do patógeno principal incidente na área.

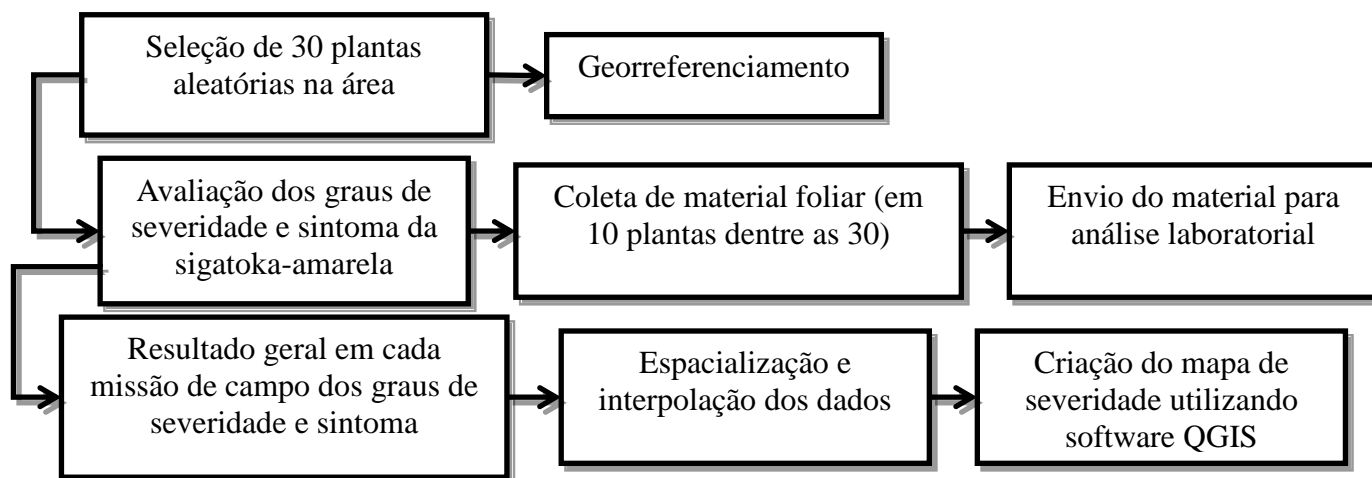
As notas referentes aos graus de severidade e de sintoma da doença fúngica foram anotadas e tabuladas no Microsoft Excel®, onde se realizou uma ponderação com base na localização da folha (inserção no pseudocaule). Após a realização da média ponderada do ataque nas folhas de cada uma das 30 plantas avaliadas em cada missão de campo, foi

realizado o somatório da quantidade de plantas que obtiveram notas de graus de sintomas e severidade, separadamente, isto é, no fim da avaliação tinha-se o quantitativo do número de plantas que foram classificadas em cada uma das categorias de grau de severidade e sintoma da sigatoka-amarela.

Por fim, para obter a média geral do estado sanitário da área, realizou-se o cálculo da média das notas de graus de sintoma e severidade das 30 plantas em análise referente a cada missão de campo. Deste modo, foi possível estudar a evolução da doença fúngica ao longo dos meses de avaliação.

De posse dos dados levantados em campo, foi possível gerar um mapa de severidade e grau de sintoma em cada missão de campo, com o auxílio do software livre QuantumGis®. Realizou-se uma interpolação utilizando a distância Euclidiana a partir do algoritmo IDW (Inverse Distance Weighted) para uma melhor visualização da sintomática do ataque da sigatoka-amarela, conforme Figura 11.

Figura 11 – Fluxograma dos levantamentos de campo. Frutacor, Russas, Ceará, Brasil 2018



Fonte: Elaboração do autor, 2018.

3.2 Plataforma e voo programado

Foi utilizado um veículo aéreo não tripulado (VANT) fabricado pela DJI Innovations: Inspire 1, conforme Figura 10. A linha Inspire está categorizada dentro dos veículos multirrotores (Quadrirrotor), com autonomia de voo aproximada de 22 minutos (Bateria com capacidade de 5700mAh e tensão de 22,8 V). É incluído na linha abaixo de 25 kg, pesando cerca de 2900 gramas, juntamente com a bateria. Os comandos de voo são realizados nos três eixos, podendo ser para frente e para trás (Pitch), para direita e para

esquerda (Roll), para cima e para baixo (Elevator) e rotação no próprio eixo para direita e esquerda (Yaw). A sua velocidade máxima de voo (velocidade de cruzeiro) é de 22 m/s (80 km/h) e máxima altitude de 4500 m.

Figura 12 – VANT Inspire 1, DJI, em pleno voo



Fonte: Autor (2017).

A plataforma do VANT possui um sistema embutido denominado Vision Positioning System que auxilia a aeronave a identificar seu posicionamento através de dois sensores ultrassônicos (sonar) e dados de imagens coletadas por uma câmera monocular. O sistema GPS (Global Position System) realiza o cálculo da posição e da altura do VANT, compondo, desta forma, os mecanismos de localização. O Inspire 1 também possui um sistema de estabilização da câmera (Gimbal) denominado Zenmuse, que minimiza as distorções das imagens ou vídeos obtidos da plataforma durante o voo. A câmera embarcada, denominada X5, possui resolução de 16,0 megapixels (4000 x 4000 pixels) e campo de visada (FOV – Field Of View) de 94°, pancromática. É atribuída a cada imagem aérea obtida uma informação de latitude, longitude e altitude (pixel central da fotografia), com precisão métrica (2 a 10 metros), auxiliando os algoritmos de identificação de padrões, os quais serão mais bem detalhados nos capítulos de processamento de imagens.

A definição da área do voo foi estabelecida com o auxílio do software Lichi® (Figura 13), onde é possível programar parâmetros do voo do VANT, como a altura desejada, a rota e a velocidade de voo. Uma superposição de 80% frontal e 60% lateral foi adotada para atender os requisitos fotogramétricos para o processo de mosaicagem das imagens. Os parâmetros de voo utilizados nas missões de campo se encontram na Tabela 2.

Figura 13 – Software Litchi® com a programação de voo em área de estudos. Frutacor, Russas, Ceará, Brasil 2018



Fonte: Software Litchi®.

Tabela 2 – Parâmetros de voo e configurações da câmera X5 16 megapixels a bordo do VANT Inspire 1.

Item	Configuração
ISO	Automático
Altitude de voo	60 metros
Velocidade de cruzeiro	12 km/h
Comprimento entre linhas de voo	21 m
Comprimento das linhas de voo	155 m
Área sobrevoada	4 ha
Ground Sampling Distance (GSD)	0,016781 m


Foi realizado um voo na altura de 30 metros em relação ao nível do solo, com o objetivo de capturar imagens individuais (sem a composição do ortomosaico) para avaliação descrita posteriormente.

Dentre os parâmetros de voo, o Ground Sampling Distance (GSD, cm/pixel) é o equivalente à resolução espacial do produto digital gerado a partir das imagens obtidas por meio do VANT. O GSD expressa o tamanho do pixel componente da imagem e diz respeito ao nível de detalhamento da imagem. Tal parâmetro depende exclusivamente da distância do sensor ao alvo (altura de voo), da resolução do sensor utilizado nos levantamentos e da distância focal da câmera.

No caso das bananeiras, a folha da planta é naturalmente larga (aproximadamente 0,5 metros de largura), facilitando a observação aérea. Porém, as manchas foliares que ocorrem devido às pragas, doenças, estresse hídrico e nutricional, ocorrem na ordem de centímetros ou até milímetros. Desta maneira, é imprescindível a utilização de sensores com alta resolução espacial (menores que 0,1 metro), os quais possibilitarão uma observação mais fiel das feições de campo. Neste caso, trabalha-se principalmente com a altitude sobrevoada e a resolução da câmera fotográfica. Neste trabalho, o sensor da câmera X5 utilizada possui resolução de 16 megapixels, conferindo um GSD de 0,016781 metro em uma altura de voo de 60 metros.

Um georreferenciamento preciso é indispensável para trabalhos desta natureza justamente por estarem sendo trabalhados cálculos de áreas, como área total de folhas sadias, folhas anormais (secas ou amareladas), área de solo exposto ou área sombreada, por exemplo. A precisão do sistema GPS embarcado no próprio VANT confere uma precisão apenas na ordem métrica (2 a 10 metros de precisão), o que ocasionaria em grandes erros associados ao cálculo de áreas. O Georreferenciamento das imagens aéreas obtidas foi realizado por meio de Pontos de Controle do Terreno (GCP's – Ground Control Points). Foram distribuídas na área de estudo placas de controle e suas coordenadas obtidas por meio de sistema GNSS Pro Mark 3® Magellan, com precisão milimétrica, como ilustra Figura 14. Para identificação das plantas amostradas em campo nos ortomosaicos produzidos a partir das imagens aéreas, também foi utilizado o equipamento descrito acima.

Figura 14 – A) Sistema GNSS ProMark 3, Magellan, para aquisição das coordenadas geográficas dos GCPs; B) GCP observado em imagem aérea obtida por meio do VANT Inspire 1, Frutacor, Russas, Ceará, Brasil 2018



Fonte: Autor, 2017.

Na fase computacional de georreferenciamento, o software utiliza a informação de coordenadas geográficas dos GCP's para extrapolar as coordenadas para os demais pixels. O produto deste processo é uma imagem da área sobrevoada onde cada pixel possui coordenadas tridimensionais (latitude, longitude e altitude) referidas a determinado sistema de projeção cartográfica.

3.3 Processamento e Classificação das imagens

Para este trabalho, empregou-se um Computador Gamer Ibyte IGW10 com Intel® Core™ i7-6700 3.4GHz, com memória RAM de 8GB e Sistema Operacional Windows 10, 64 bits. Para o processamento das imagens aéreas, foi utilizado o software PhotoScan®, da AgiSoft, que se divide em cinco etapas, sendo 1ª) importação das imagens aéreas, 2ª) Alinhamento das imagens, 3ª) Criação da malha e georreferenciamento, 4ª) Geração da Nuvem Densa de Pontos e 5ª) Geração e exportação do ortomosaico e dos relatórios. O software ainda permite a texturização do modelo 3D, bem como outras opções de fluxo de trabalho.

Na fase de importação das imagens, foi realizada uma triagem entre as fotografias, excluindo-se do conjunto as imagens indesejadas (imagens fora de foco, borradas, imagens do pouso e decolagem). Tal procedimento auxilia nos processamentos realizados posteriormente.

O processo de alinhamento das imagens resultará em uma nuvem esparsa de pontos tridimensionais. A partir do reconhecimento de padrões de cores e geometrias, além da informação geográfica que as fotografias possuem, o algoritmo identifica pontos (pixels) em comum em duas ou mais fotografias. Deste modo, aí se explica a importância de uma correta superposição das imagens para a geração de modelos 3D e a confecção de ortomosaico.

A criação da malha auxilia no georreferenciamento, criando um objeto sólido a partir dos pontos que compõem a nuvem esparsa. O georreferenciamento associa cada pixel da imagem a uma coordenada geográfica tridimensional (X, Y e Z).

A partir da nuvem esparsa georreferenciada, é criada a nuvem densa de pontos, onde se implementa uma interpolação entre os pixels tridimensionais, intensificando as informações do terreno e de cor dos pixels. O processo de aumentar a densidade da nuvem de pontos eleva de cerca de 20 pontos/m² para mais de 1000 pontos/m².

O produto final dos processamentos é o ortomosaico, com alta resolução espacial (menor que 0,1 metro), que é constituído das imagens obtidas por meio do VANT e suas devidas informações de cores e coordenadas geográficas. Foram gerados três ortomosaicos com base nas três missões de campo realizadas.

Para a classificação dos ortomosaicos, foi utilizado o software ENVI®, da SulSoft®, que oferece poderosas ferramentas de visualização, exploração, análise e apresentação de dados na área do sensoriamento remoto.

O processo de classificação se iniciou com a importação dos ortomosaicos e a aplicação de filtro de contraste, servindo como um realce nas cores, auxiliando nos processos posteriores de treinamento do algoritmo (Enhance a nível linear de 2%). Tal filtro melhora a apresentação visual da imagem, possibilitando uma maior distinção entre alvos. Em seguida, foi realizada uma classificação não supervisionada (método ISOdata), servindo como uma classificação preliminar à classificação supervisionada, de modo a informar quantas classes diferentes podem compor a cena da imagem.

As classificações supervisionadas têm como característica o treinamento do algoritmo a partir de amostragens de pixels pelo próprio usuário. Esta etapa é definida como a criação de regiões de interesse (ROIs – Regions of Interest) que irão compor as classes pré-definidas. Neste trabalho, as classes fixadas para cada uma das classificações foram: Folha Sadia, Solo, Folha Anormal, Nervura Central e Sombra. Na classe “Folha Sadia”, se enquadravam os pixels com características marcantes a coloração verde predominantemente, que deveriam abranger todas as porções foliares com coloração esverdeadas e sem anomalias,

enquanto que regiões de coloração mais amareladas, como folhas acometidas pela sigatoka e/ou outros fatores, por exemplo, foram categorizadas em “Folha Anormal”.

Após a criação dos ROIs, procedeu-se com a escolha do método de classificação. Para este trabalho, foram utilizados três métodos diferentes, sendo os algoritmos classificadores denominados Maximum Likelihood, Minimum Distance e Mahalanobis Distance. Nesta fase, todos os pixels da imagem são agrupados em classes pré-estabelecidas pelo usuário, resultando em uma imagem totalitariamente classificada, onde as classes são representadas por cores, dando origem aos mapas temáticos.

O classificador Maximum Likelihood (Máxima Verossimilhança) assume que os pixels respeitam uma distribuição normal estatística em suas características. Calcula-se, então, a probabilidade deste pixel pertencer a uma classe criada previamente pelo usuário. Assim, cada pixel é alocado na classe que possui a maior probabilidade de pertencê-lo.

No caso da Distância Euclidiana (Minimum Distance), o algoritmo se baseia na distância média entre as classes previamente estabelecidas pelo usuário e calcula a distância euclidiana de cada pixel desconhecido para o vetor médio de cada classe. Os pixels são alocados nas classes que se apresentam mais próximas.

O classificador Mahalanobis Distance possui grande semelhança ao método Maximum Likelihood, porém o processo considera que todas as covariâncias de classe são iguais e, portanto, é um método de processamento mais rápido. Utiliza as distâncias entre as informações dos pixels para agrupá-los em classes pré-estabelecidas.

Os resultados das classificações foram exportados para o ArcGis®, da ESRI®, versão 10.2, para a composição de seu layout, introduzindo ali os elementos para apresentação da imagem como um mapa.

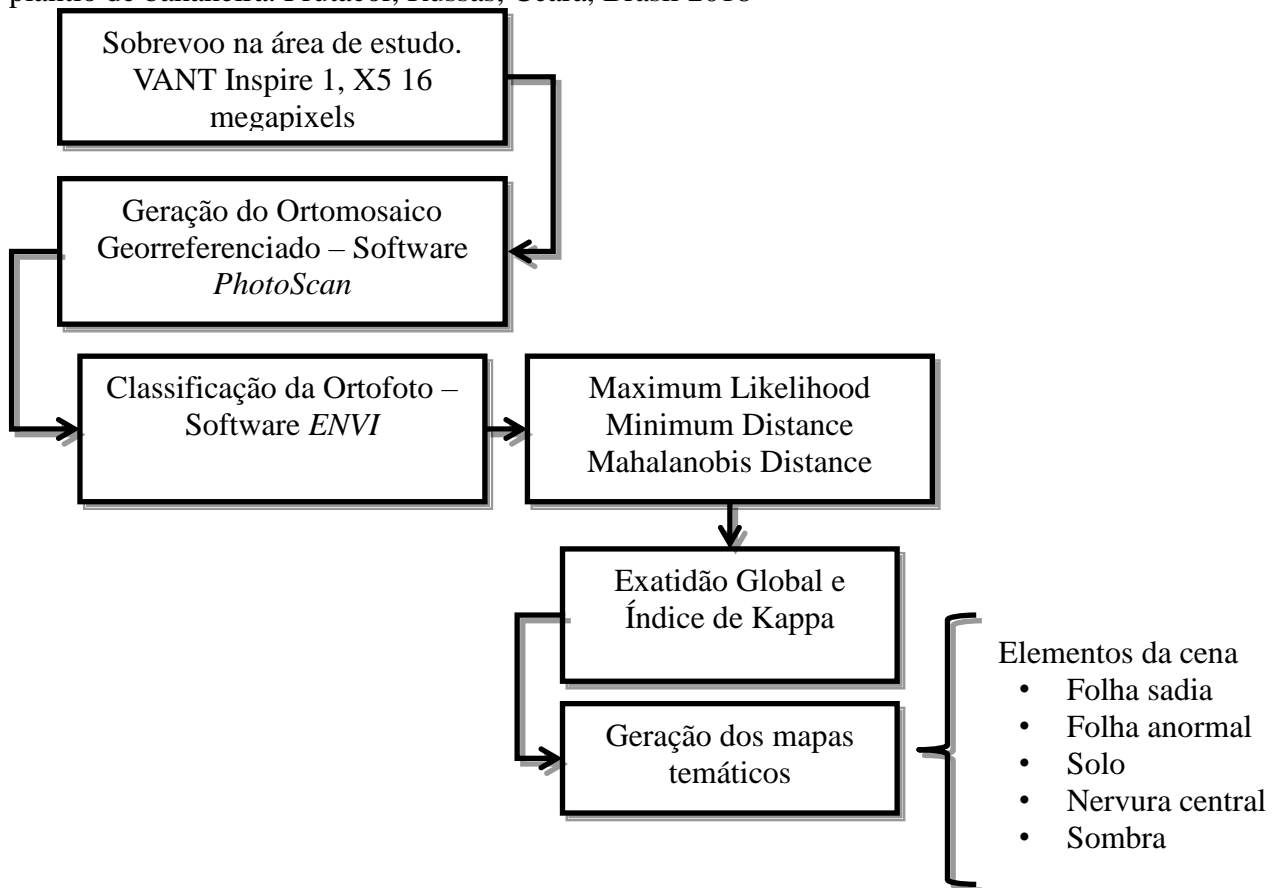
Voltando ao ambiente de trabalho do software ENVI®, outras regiões de interesse (ROIs) foram criadas, com o objetivo de servirem como “verdade de campo” para o cálculo do índice de Kappa e Exatidão Global. Estes índices avaliam o poder classificador do algoritmo, comparando os pixels classificados com as verdades de campo, criando a denominada matriz de confusão.

Paralelamente aos voos de 60 metros de altura em relação ao nível do solo, foi realizado voo de 30 metros de altura na área de estudo, no dia 27/09/2017. Foram selecionadas duas imagens do sobrevoo para classificação individual, isto é, sem a composição do ortomosaico.

Nesse contexto, as duas imagens foram submetidas à classificação supervisionada, utilizando os algoritmos Maximum Likelihood, Mahalanobis Distance e Minimum Distance. Devido à altura de voo estar situada a 30 metros de altura em relação ao solo, o nível de detalhamento dos produtos é maior, possibilitando uma melhor diferenciação das feições em campo.

Para cada ortomosaico construído após cada missão de campo, foram realizadas três classificações, resultando em nove mapas temáticos diferentes avaliados pelo índice de Kappa e Exatidão Global, conforme Figura 15.

Figura 15 – Fluxograma do processamento das imagens obtidas por meio do VANT em plantio de bananeira. Frutacor, Russas, Ceará, Brasil 2018



Fonte: Elaboração do autor, 2018.

As amostras foliares infestadas pelo fungo foram utilizadas como verdade de campo no processamento das imagens para fins de comprovação do poder classificador dos algoritmos pelo índice de Exatidão Global (Equação 1), Exatidão Específica (Equação 2) e estatística de Kappa (Equação 3), conforme citam Ma e Redmond (1995).

$$G = \frac{\sum_{i=1}^M n_{ii}}{n} \quad \text{Equação (1).}$$

Onde:

G = Exatidão Global (%);

n_{ii} = elementos da diagonal da matriz de confusão;

n = número total de observações; e

M = número de temas mapeados.

$$EE = \frac{x_{ii}}{n} \times 100 \quad \text{Equação (2).}$$

Onde:

EE = Exatidão Específica;

x_{ii} = Elementos da diagonal da matriz de confusão;

n = quantidade total de pontos amostrais da classe mapeada.

$$Kappa = \frac{n \sum_{i=1}^M x_i - \sum_{i=1}^M (x_{i+} x_{+i})}{n^2 - \sum_{i=1}^M (x_{i+} x_{+i})} \quad \text{Equação (3).}$$

Onde:

Kappa = Índice de Kappa;

x_{ii} = elementos da diagonal da matriz de confusão;

n = número total de observações;

x_{i+} e x_{+i} = somatório na linha e na coluna, respectivamente; e

M = número de temas mapeados.

Os resultados do índice Kappa calculado para cada teste de classificação recebem uma categorização de acordo com Landis e Koch (1977) (Tabela 3).

Tabela 3 – Categorias para interpretação do índice Kappa.

Índice de Kappa (%)	Classificação
80 a 100	Excelente
60 a 80	Muito boa
40 a 60	Boa
20 a 40	Razoável

0 a 20
< 0

Ruim
Péssima

Fonte: Landis e Koch (1977).

4 RESULTADOS E DISCUSSÃO

4.1 Graus de Severidade e de Sintomas da sigatoka-amarela

São apresentados na Tabela 4 os resultados das análises de campo, realizadas por especialista, para inferência dos graus de sintoma e severidade em plantio de bananeira para os meses de setembro, outubro e novembro de 2017.

Tabela 4 – Graus de Sintoma e Severidade do ataque da sigatoka-amarela (*Mycosphaerella musicola*) nas avaliações de campo. Frutacor, Russas, Ceará, Brasil 2018.

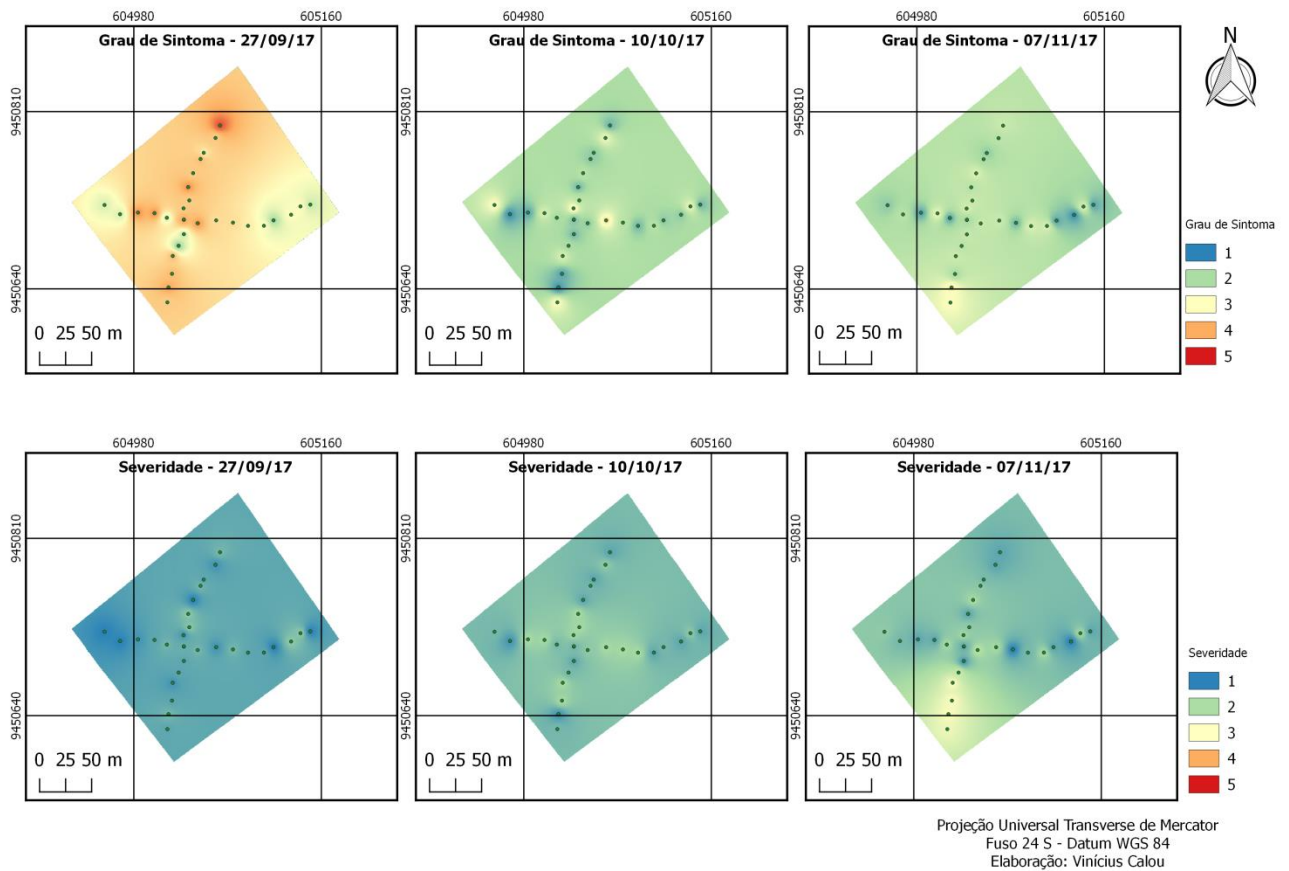
Data	Grau de Sintoma	Mínimo	Máximo	Grau de severidade	Mínimo	Máximo
27/09/2017	3,4	2,0	5,0	1,4	1,0	2,0
10/10/2017	2,1	1,0	3,0	1,7	1,0	2,0
7/11/2017	2,1	1,0	3,0	1,8	1,0	3,0

Os valores acima descritos ilustram uma tendência decrescente nos graus de sintoma no plantio de bananeira para os meses de setembro e outubro, ocasionada principalmente pela técnica da desfolha, considerada um controle cultural muito utilizado no Brasil, como relata Meredith (1970). No mês de outubro, a empresa realizou o raleamento das folhas mais velhas, aerando e iluminando melhor o dossel, o que reflete em um enfraquecimento na evolução da sigatoka-amarela.

O Grau de Severidade, ao longo dos meses em análise, apresentou valores situados entre 1 e 2, indicando severidade de infestação entre 1% e 5%, conforme metodologia de Stover (1971), modificada por Gauhl *et al.* (1994). Em trabalho utilizando cinco híbridos de bananeira no estado da Bahia, Donato *et al.* (2012) foram conclusivos a respeito da cultivar “Prata-anã”, apontando-a como a mais suscetível ao ataque da sigatoka-amarela. Os pesquisadores avaliaram os níveis de infecção em dois ciclos, observando valores entre 2,3 e 5,4, enquanto que os outros híbridos apresentaram valores entre 1,0 e 3,0 no período da floração.

A consorciação entre os dados de severidade e sintoma levantados em campo, juntamente com a informação espacializada de cada planta individualizada, permitiu uma leitura dos dados de modo a compreender a maneira como a doença se comporta de acordo com sua localização geográfica. A Figura 16 ilustra a interpolação dos dados por meio do algoritmo IDW (Inverse Distance Weighted), estimando os graus de infecção em toda a área de estudo.

Figura 16 – Mapas IDW do Grau de Sintoma e Grau de Severidade do ataque da sigatoka-amarela (*Mycosphaerella musicola*). Frutacor, Russas, Ceará, Brasil 2018




Fonte: Elaboração do autor, 2018.

As técnicas de geoprocessamento aplicadas ao manejo de cultivos têm auxiliado nas tomadas de decisões no campo agrícola. Desta forma, utilizando ferramentas básicas de geoestatística, Freitas *et al.* (2016) buscaram uma espacialização da sigatoka-amarela em relação à fertilidade do solo, à nutrição das plantas e à atributos físicos do solo, avaliando seis meses consecutivos. Os autores demonstraram que a doença fúngica pode ser associada às áreas do terreno que possuam maiores quantidades de areia em sua fração granulométrica. Os autores ainda espacializaram os índices de severidade a partir de algoritmo de Krig (Krigagem, descrito por Burrough e McDonnell, 1998), encontrando taxas mínimas de severidade de 19,41% no mês de novembro de 2011 e taxas máximas de 54,93% em abril de 2012. Tais valores de severidade situam-se acima dos valores encontrados neste trabalho, indicando que a severidade e grau de sintomas da infecção da sigatoka-amarela está associado a fatores diversos, como material genético utilizado, tratos culturais e medidas de controle.

As imagens aéreas obtidas a partir dos mapeamentos realizados com o VANT Inspire 1 formaram poderosos dados de entrada no treinamento computacional dos algoritmos utilizados neste trabalho, conforme ilustrado na Figura 17. Os sintomas ocasionados pela sigatoka-amarela podem ser observados e categorizados utilizando as imagens aéreas, ampliando os horizontes das aplicações dentro da agricultura de precisão.

Figura 17 – Sintomas de ataque da sigatoka-amarela em folhas de bananeiras. Imagens aéreas obtidas por meio de VANT Inspire 1, Frutacor, Russas, Ceará, Brasil 2018

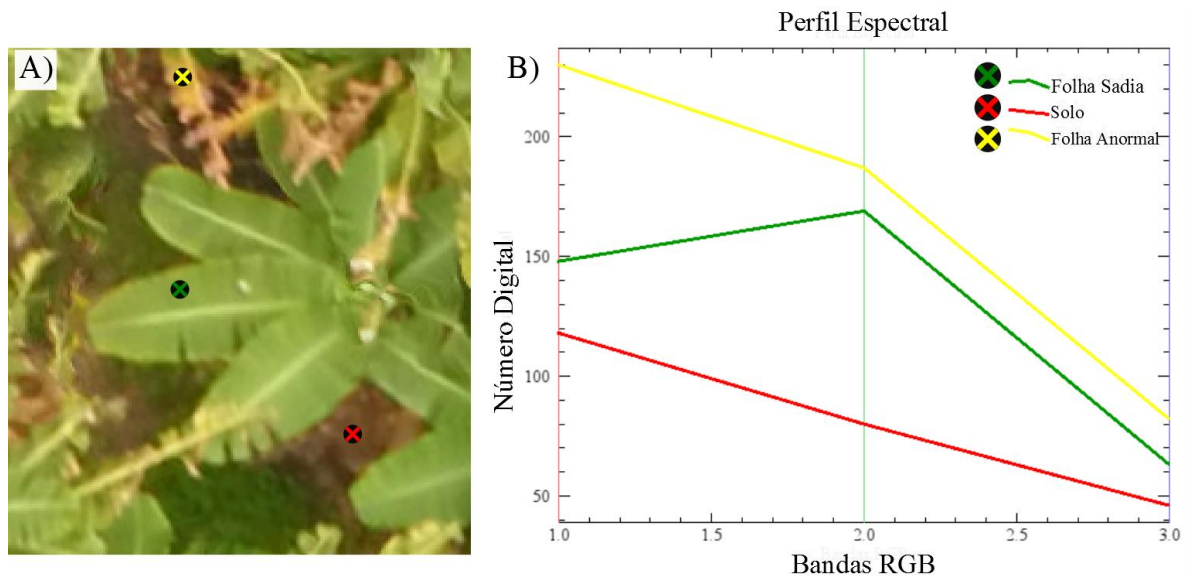


Fonte: Elaboração do autor, 2018.

4.2 Classificações dos ortomosaicos

Na Figura 18 são ilustrados os perfis espectrais dos três alvos de interesse ao trabalho, expondo a maneira como a informação radiométrica é traduzida em forma de bytes. Em cada banda RGB, são computados valores de 0 a 255 bytes representando a informação de cor da cena real. Desta forma, os algoritmos utilizam tais informações para segmentar a imagem e categorizar os pixels dentro de classes pré-estabelecidas.

Figura 18 – Perfil Espectral RGB de amostra aleatória no ortomosaico obtido a partir de processamento com VANT. A) Amostras no ortomosaico; B) Perfil Espectral das frequências RGB



Fonte: Elaboração do autor, 2018.

Para a categorização dos pixels das cenas em análise, os algoritmos utilizados neste trabalho realizam processos que envolvem as informações em número digital das bandas RGB, as probabilidades de pertencerem a uma classe, ou as distâncias médias entre as classes pré-definidas. No entanto, na literatura também são observados métodos para incrementar o poder classificador de algoritmos, como relatam Bashir e Sharma (2012). Os autores realizaram a classificação de doenças foliares na cultura da macieira a partir de segmentação da coloração e da textura de fotografias simples. Para a classificação utilizando as cores (espectro RGB – visível), utilizaram o processamento com algoritmo CMM, que consiste na transformação da informação de cor RGB em HSI (Hue Saturation Intensity), para depois gerar três matrizes de co-ocorrência, classificando a folha em classes com base na frequência

em que cada característica era observada e em comparação com as outras matrizes (H,S e I). Na análise textural, a técnica K-means foi utilizada agrupando os pixels com maior proximidade (soma do quadrado das distâncias), o que resultou no aumento da acurácia na distinção de classes de pixels de regiões com a infestação das doenças foliares e porções da folha saudável.

Além da informação RGB, a qualidade dos dados de entrada para o treinamento dos algoritmos de classificação de imagens também é marcante na definição da acurácia dos mesmos. Desta maneira, a despadronização do conjunto de imagens em análise é citada com um dos principais fatores que dificulta a aprendizagem da máquina, reduzindo a assertividade dos métodos. Garcia-Ruiz *et al.*, (2013) dissertaram acerca da influência que a resolução espacial dos produtos dos mapeamentos aéreos como uma forma de diminuir os ruídos ocasionados pela mistura de pixels e acurácia dos algoritmos.

Os autores ressaltam que o mapeamento aéreo realizado com VANT gerou resoluções espaciais (GSD) na ordem de 5 cm/pixel, o que resultou em uma acurácia de até 85% na identificação da podridão cítrica em pomar de laranjeiras, sendo valores comparáveis aos obtidos neste trabalho. A resolução espacial para os mapeamentos aqui citados, situam-se abaixo dos valores encontrados por Garcia-Ruiz *et al.*, (2013), indicando maior nível de detalhes, o que provavelmente ocasionou maiores assertividades, principalmente para os voos realizados em setembro e outubro de 2017, conforme Tabelas 5 e 6.

Para a avaliação dos algoritmos utilizados, são expostos nas Tabelas 5 e 6 os respectivos valores de assertividade, dados por meio da Precisão Global e Índice de Kappa.

Tabela 5 – Índice de Exatidão Global dos algoritmos classificadores.

Data	Exatidão Global		
	Maximum Likelihood	Mahalanobis Distance	Minimum Distance
27/09/2017	90,21%	87,83%	99,28%
10/10/2017	89,77%	82,74%	87,71%
07/11/2017	78,76%	70,36%	70,66%

Tabela 6 – Índice de Kappa dos algoritmos classificadores.

Data	Índice de Kappa		
	Maximum Likelihood	Mahalanobis Distance	Minimum Distance
27/09/2017	90,45%	78,57%	98,59%
10/10/2017	79,61%	66,99%	75,76%
07/11/2017	62,88%	50,87%	51,12%

Singh *et al.* (2016) citam que, para o ciclo de identificação de fenótipos nas culturas agrícolas, quatro estágios de decisão são formulados dentro do aprendizado computacional, os quais são: Identificação, Classificação, Quantificação e Predição. Nesta perspectiva, os esforços para o aumento da exatidão dos métodos computacionais se fazem buscando aumentar o número de dados de entrada e treinamento dos algoritmos a partir de amostras puras, implementar e melhorar os métodos matemáticos que regem os processamentos e desenvolver sensores capazes de captar diferentes comprimentos de onda.

Desta forma, o volume de dados gerado pela alta resolução espacial, a partir de aerolevantamentos com os VANTs, aumenta a precisão e o nível de acertos dos algoritmos. Neste trabalho, a uma altitude de voo de 60 metros em relação ao nível do solo, o levantamento proporcionou uma resolução espacial (GSD) de 1,7 centímetros (0,016781 metros), auxiliando na identificação das manchas foliares causadas pela sigatoka-amarela, até mesmo em seus estádios iniciais.

Notadamente, os valores supracitados possuem uma tendência decrescente ao longo dos meses (voos nos meses de setembro, outubro e novembro), principalmente devido à forte estiagem que acometeu o nordeste de modo geral, privando os produtores de abastecimento hídrico, causando um estresse gradativo nas culturas irrigadas (BRITO *et al.*, 2018). É típico da cultura da bananeira um fechamento natural de suas folhas, expondo menos suas estruturas à insolação, diminuindo a evaporação e as taxas de transpiração. Tal fenômeno ocasionou uma maior dificuldade na identificação das manchas foliares, expondo mais o solo e reduzindo os níveis de acerto dos algoritmos.


Para a aquisição das imagens aéreas e a identificação de manchas foliares, neste cenário, é ideal que a estrutura celular das folhas esteja túrgida, aberta, captando a energia proveniente da luz solar. Os índices de Kappa e Exatidão Global para os processamentos realizados no dia 27/09/2017, portanto, apresentaram patamares mais elevados, demonstrando sua possibilidade de utilização. De acordo com Freitas (2013), o aporte hídrico à cultura da bananeira possibilita maior abertura e exposição ao sol de suas estruturas foliares, aumentando as taxas fotossintéticas e, conseqüentemente, favorecendo a produção de bananas.

4.2.1 Classificações de setembro – 1ª missão de campo

Nesta seção serão discutidos os resultados obtidos com a primeira missão de campo, buscando uma equiparação ao levantamento de campo, atestando a assertividade dos algoritmos empregados.

Nas Figuras 19, 20 e 21 são demonstrados os resultados das classificações realizadas a partir da missão de campo realizada no dia 27 de setembro de 2017, expondo o percentual de cada classe, bem como a Exatidão Global e o Índice de Kappa. Nas Tabelas 7,8 e 9 são apresentadas as matrizes de confusão em percentagem, detalhando a maneira como cada algoritmo categorizou os pixels do ortomosaico.

Figura 19 – Mapa temático da classificação com algoritmo Maximum Likelihood no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018




Fonte: Elaboração do autor, 2018.

Tabela 7 – Matriz de confusão da classificação realizada com o algoritmo Maximum Likelihood no dia 27/09/2017.

		Verdade de campo (%)			
		Folha Sadia	Nervura Central	Folha Anormal	Solo
Classificação	Folha Sadia	91,93	6,55	0,63	6,75
	Nervura Central	7,99	93,45	3,91	2,25
	Folha Anormal	0,08	0	91,46	0,45
	Solo	0	0	4,00	90,55
Total		100	100	100	100

Figura 20 – Mapa temático da classificação com algoritmo Mahalanobis Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018




Fonte: Elaboração do autor, 2018.

Tabela 8 – Matriz de confusão da classificação realizada com o algoritmo Mahalanobis Distance no dia 27/09/2017.

		Verdade de campo (%)			
		Folha Sadia	Nervura Central	Folha Anormal	Solo
Classificação	Folha Sadia	49,51	51,39	0	0
	Nervura Central	43,78	48,21	4,48	0
	Folha Anormal	6,71	0,40	81,30	21,41
	Solo	0	0	14,22	78,59
Total		100	100	100	100

Os processamentos realizados pelo algoritmo Mahalanobis Distance não foram capazes de separar satisfatoriamente as classes “Nervura Central” e “Folha Sadia”, conforme observado na Tabela 8. Thomson *et al.* (2005) observaram acurácias entre 67 e 82% no mapeamento de plantas invasoras na cultura do algodão utilizando o classificador Mahalanobis Distance e imagens obtidas através de aeronave tripulada. Os autores relataram que o classificador foi o mais eficiente em comparado com outros métodos supervisionados e não supervisionados, discordando dos resultados obtidos no atual trabalho.

Figura 21 – Mapa temático da classificação com algoritmo Minimum Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018



Fonte: Elaboração do autor, 2018.

Tabela 9 – Matriz de confusão da classificação realizada com o algoritmo Minimum Distance no dia 27/09/2017.

		Verdade de campo (%)			
		Folha Sadia	Nervura Central	Folha Anormal	Solo
Classificação	Folha Sadia	89,77	2,58	0,50	0,02
	Nervura Central	9,09	90,28	1,03	0
	Folha Anormal	0	0,60	93,16	0
	Solo	0,33	0	5,30	99,98
Total		100	100	100	100

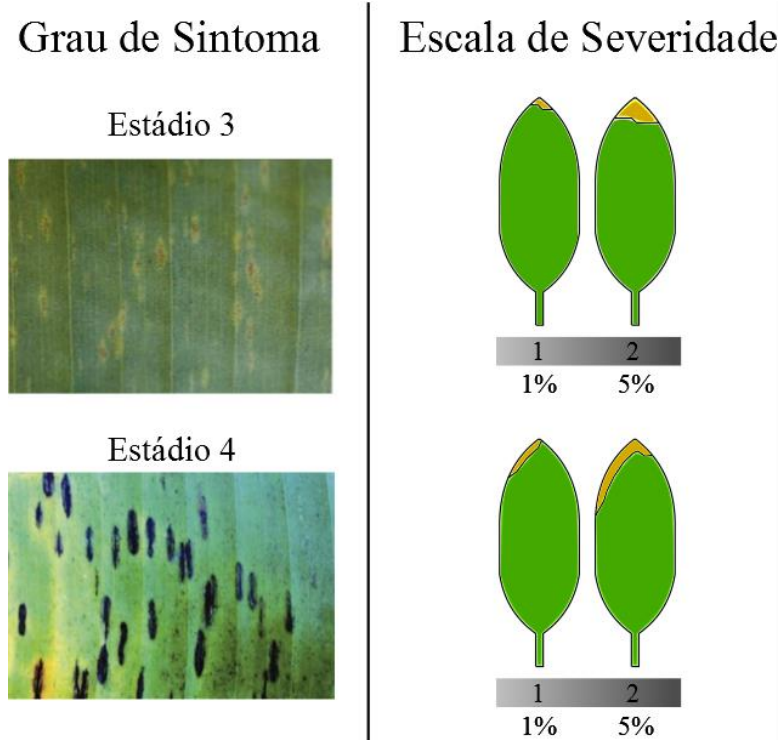
Nos levantamentos de campo, a quantificação dos níveis de infestação da sigatoka-amarela foi realizada de acordo com metodologia de Meredith (1970) e Stover (1971), modificado por Gauhl (1994), atribuindo uma nota ao grau de sintomas e severidade ao estado de infecção encontrado em campo no momento da análise. Neste cenário, são demonstrados na Tabela 10, as notas de campo conforme levantamento realizado por especialista na identificação e quantificação da doença. Ainda na Tabela 10 são apresentados os valores percentuais da classe “Folha Anormal”, para comparação com os levantamentos em campo.

Tabela 10 – Avaliações de campo e classificações da assertividade dos algoritmos para os processamentos referentes à 27/09/2017.

Nota de Campo		Algoritmo	Classe "Folha Anormal"	Índice de Kappa	Exatidão Global
Grau de Sintoma	3,4	Maximum Likelihood	9,61%	90,45%	90,21%
Severidade	1,4	Mahalanobis Distance	19,57%	78,57%	87,83%
		Minimum Distance	2,44%	98,59%	99,28%

Conforme apresentado na Tabela 10, sendo utilizado o algoritmo Minimum Distance (Distância Euclidiana), a partir do índice de Exatidão Global em 99,28% e Kappa classificado como “Excelente”, o valor encontrado de percentual de “Folha Anormal”, provavelmente afetadas pela sigatoka-amarela foi de 2,44%, muito se aproximando do levantamento em campo (metodologia convencional), no qual a nota de severidade (1,4) representa níveis de infecção entre 1% e 5%, como ilustra a Figura 22. No quesito “Grau de Sintoma”, as notas de campo indicaram que a cultura encontrava-se entre os estádios 3 e 4, o que facilitou sua identificação a partir de imagens aéreas providas do aerolevanteamento.

Figura 22 – Grau de Sintoma e Severidade do ataque da sigatoka-amarela, descritos por Meredith (1970) e Stover (1971), modificada por Gauhl *et al.* (1994), levantamento dia 27/09/2017



Fonte: Adaptado de Gauhl *et al.* (1994).

No caso dos algoritmos Maximum Likelihood e Mahalanobis Distance, as classificações resultaram em valores da classe “Folha Anormal” (9,61% e 19,57%, respectivamente) acima daqueles levantados em campo (conforme metodologia de Gauhl (1994)), indicando uma possível superestimação dos níveis de ataque da sigatoka-amarela.

Para uma análise mais detalhada do poder classificador dos algoritmos, apresenta-se na Tabela 11 as Exatidões Específicas de cada processamento supracitado.


Tabela 11 – Exatidões Específicas das classes referentes aos mapeamentos realizados em plantio de bananeiras. 27/09/2017, Frutacor, Russas, Ceará, Brasil, 2018.

Classe	Maximum Likelihood	Mahalanobis Distance	Minimum Distance
Solo	90,55%	78,59%	99,98%
Folha Sadia	91,93%	49,51%	89,77%
Folha Anormal	91,46%	81,30%	93,16%
Nervura Central	93,45%	48,21%	90,28%

Entre as classificações, destacam-se os algoritmos Minimum Distance e Maximum Likelihood, atingindo valores elevados principalmente na distinção de feições relacionadas à classe “Folha Anormal”.

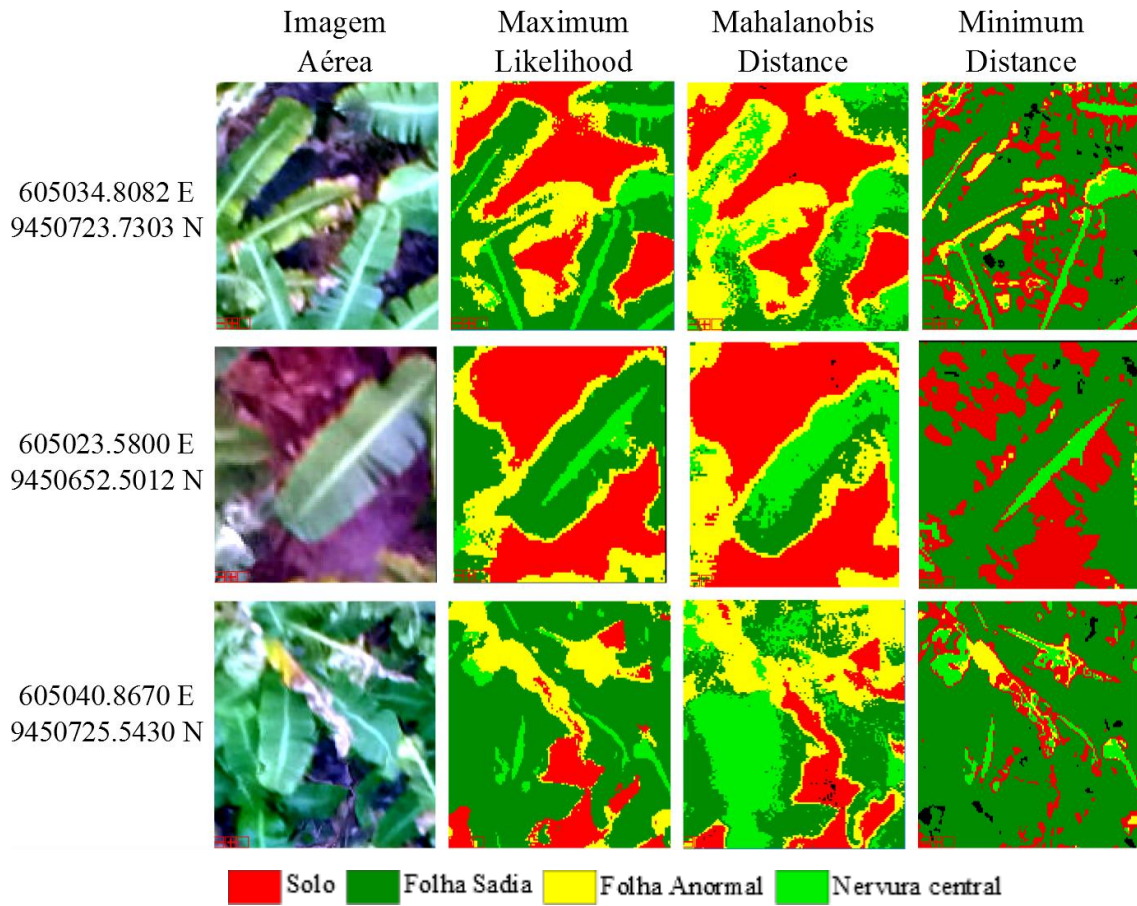
Nas Figuras 23 e 24 são exibidos recortes ampliados das três classificações para uma averiguação mais detalhada da maneira como os algoritmos alocaram os pixels em cada processamento.

Figura 23 – Recorte ampliado da área de estudos para voo no dia 27/09/2017, de acordo com A) Ortomosaico RGB; B) Classificação com algoritmo Maximum Likelihood; C) Classificação com algoritmo Mahalanobis Distance e; D) Classificação com algoritmo Minimum Distance



Fonte: Elaboração do autor, 2018.

Figura 24 – Recortes ampliados da área de estudos para voo no dia 27/09/2017



Fonte: Elaboração do autor, 2018.

É notória a qualidade da classificação por Distância Euclidiana (Minimum Distance), principalmente no que diz respeito à identificação das áreas amarelecidas causadas, provavelmente, por ataque da sigatoka-amarela. Por outro lado, é perceptível a confusão na maneira de agrupar as classes de “Nervura Central” e “Folha Sadia” do algoritmo Mahalanobis Distance, rebaixando os valores do seu índice de Kappa e Exatidão Global em comparação aos demais métodos.

Através de fotografias simples obtidas com câmera digital comum (Kodak EasyShare C913, 9,2 megapixels), Hernández-Rabadán, Ramos-Quintana e Juk (2014) discutiram sobre a identificação de doenças foliares no tomateiro utilizando métodos supervisionados (Bayesian classifier) e não supervisionados (self-organizing map – SOM). Os processos resultaram em níveis de acertos categorizados como “Excelentes”, acima de 97%. Os níveis de assertividade encontrados no atual trabalho, principalmente nos processamentos para o mês de setembro, muito se assemelham aos resultados obtidos por Hernández-Rabadán, Ramos-Quintana e Juk (2014), apesar da resolução espacial dos autores

supracitados alcançarem patamares bem menores (devido a utilização de câmera in situ), indicando maior nível de detalhamento no set de imagens avaliado.

Buscando a identificação de manchas foliares ocasionadas por fungos na cultura da soja, Pires *et al.* (2016) apresentaram resultados em que as acurácias dos algoritmos utilizados superaram os 98%, a partir de amostras foliares escaneadas (imagens pancromáticas). Tais resultados superam os obtidos neste trabalho principalmente devido ao fato das altas resoluções das imagens obtidas com o material vegetal escaneado, além da padronização das folhas. No entanto, os resultados dos processamentos realizados com as imagens do dia 27/09/2017 e algoritmo Minimum Distance, obtidos no atual trabalho, se assemelham aos valores de assertividade encontrados por Pires *et al.* (2016), o que corrobora com as conclusões dos autores, que afirmam que a utilização de smartphones para as fotografias em campo, ou ainda câmeras a bordo de VANTs, serão fortes aliados para a diminuição das perdas ocasionadas por doenças na agricultura em um futuro próximo.

Utilizando VANT de baixo custo (Phantom 3, câmera RGB 12 megapixels), Tetila *et al.* (2017) realizaram a obtenção de imagens aéreas de plantio de soja, visando a identificação de doenças foliares causadas por fungos, a partir de seis algoritmos classificadores em cinco alturas de voos diferentes. Como resultados, obtiveram níveis de acurácia classificados como “Excelentes” em patamares que variaram de 88% a 98%. Os maiores valores de assertividade foram observados em altitudes de voo menores (2 metros de altura), devido ao nível de detalhes das imagens. No atual trabalho, os voos foram realizados em altitudes de 60 metros em relação ao nível do solo, gerando resultados equiparados aos encontrados por Tetila *et al.* (2017), provavelmente devendo-se ao fato das estruturas foliares das bananeiras serem maiores, comparadas com a cultura da soja. Diferente do atual trabalho, Tetila *et al.* (2017) não geraram um ortomosaico, mas utilizaram as fotografias individuais para gerar seus resultados.


4.2.2 Classificações de outubro – 2ª missão de campo

Nas Figuras 25, 26 e 27 são demonstrados os resultados das classificações realizadas a partir da missão de campo realizada no dia 10 de outubro de 2017, expondo o percentual de cada classe, bem como a Exatidão Global e o Índice de Kappa. Os resultados das classificações nesta data foram afetados pelo estresse hídrico, resultando em recolhimento natural da folha da bananeira. Esta forma natural de defesa, que reduz os níveis de transpiração, dificultou a identificação das feições sobre a estrutura foliar das bananeiras,

diminuindo os índices de acerto do algoritmo, rebaixando os índices de Kappa e Exatidão Global.

Para uma avaliação mais detalhada da categorização em percentual das classes obtidas nos processamentos, são demonstradas nas Tabelas 11, 12 e 13 as matrizes de confusão dos processamentos referentes as imagens obtidas no dia 10/10/2017.

Figura 25 – Mapa temático da classificação com algoritmo Maximum Likelihood no dia 10/10/17, Frutacor, Russas, Ceará, Brasil 2018




Fonte: Elaboração do autor, 2018.

Tabela 12 – Matriz de confusão da classificação realizada com o algoritmo Maximum Likelihood no dia 10/10/2017.

		Verdade de campo (%)			
		Solo	Folha Sadia	Nervura Central	Folha Anormal
Classificação	Solo	81,94	0	0	0,16
	Folha Sadia	15,22	98,05	1,75	3,76
	Nervura Central	0	1,95	88,16	5,31
	Folha Anormal	2,84	0	10,09	90,77
Total		100	100	100	100

Figura 26 – Mapa temático da classificação com algoritmo Mahalanobis Distance no dia 10/10/17, Frutacor, Russas, Ceará, Brasil 2018




Fonte: Elaboração do autor, 2018.

Tabela 13 – Matriz de confusão da classificação realizada com o algoritmo Mahalanobis Distance no dia 10/10/2017.

		Verdade de campo (%)			
		Solo	Folha Sadia	Nervura Central	Folha Anormal
Classificação	Solo	94,63	0	0	2,29
	Folha Sadia	5,37	58,09	9,21	33,99
	Nervura Central	0	41,16	72,37	20,02
	Folha Anormal	0	0,76	18,42	43,71
Total		100	100	100	100

Figura 27 – Mapa temático da classificação com algoritmo Minimum Distance no dia 10/10/17, Frutacor, Russas, Ceará, Brasil 2018



Fonte: Elaboração do autor, 2018.

Tabela 14 – Matriz de confusão da classificação realizada com o algoritmo Minimum Distance no dia 10/10/2017.

		Verdade de campo (%)				
		Solo	Folha Sadia	Nervura Central	Folha Anormal	Sombra
Classificação	Solo	91,04	0	0,44	0,49	0,49
	Folha Sadia	2,6	99,62	7,02	7,52	0
	Nervura Central	3,92	0	87,72	6,67	0
	Folha Anormal	2,42	0	4,82	85,33	0
	Sombra	0	0,38	0	0	99,65
Total		100	100	100	100	100

Apesar dos valores do índice de Kappa e Exatidão Global terem sido reduzidos em relação aos processamentos referentes ao mês de setembro, foram categorizados como “Muito boa” para os três algoritmos supracitados. Neste cenário, são demonstradas na Tabela 15 as notas de campo conforme levantamento realizado por especialista na identificação e quantificação da sigatoka-amarela. Ainda na Tabela 8 são apresentados os valores percentuais da classe “Folha Anormal”, para comparação com os levantamentos em campo.

Tabela 15 – Avaliações de campo e classificações da assertividade dos algoritmos para os processamentos referentes à 10/10/2017.


Nota de campo		Algoritmo	Classe "Folha Anormal"	Índice de Kappa	Exatidão Global
Grau de Sintoma	2,1	Maximum Likelihood	10,97%	79,61%	89,77%
Severidade	1,7	Mahalanobis Distance	22,10%	66,99%	82,74%
		Minimum Distance	5,27%	75,76%	87,71%

O fechamento natural das folhas ocasionado pelo horário do voo e temperatura média do dia, ocasionou em uma maior exposição do solo, causando provavelmente uma maior confusão aos algoritmos classificadores, reduzindo os índices de assertividade. Conforme se observa na Tabela 8, o algoritmo Minimum Distance (Distância Euclidiana) quantificou em 5,27% o valor percentual de folhas provavelmente afetadas pela sigatoka-amarela, de acordo com a classe “Folha Anormal”, muito se aproximando do levantamento em campo, no qual a nota de severidade (1,7) representa níveis de infecção entre 1% e 5%, ilustrado na Figura 28. No quesito “Grau de Sintoma”, as notas de campo indicaram que a evolução da doença encontrava-se entre os estádios 2 e 3.

Figura 28 – Grau de Sintoma e Severidade do ataque da sigatoka-amarela, descritos por Meredith (1970) e Stover (1971), modificada por Gauhl *et al.* (1994) levantamento dia 10/10/2017

Grau de Sintoma



Estádio 2



Estádio 3



Escala de Severidade



Fonte: Adaptado de Gauhl *et al.* (1994).

Visando uma análise específica da maneira como os algoritmos classificaram os pixels do ortomosaico, apresenta-se na Tabela 16 as Exatidões Específicas de cada processamento supracitado.


Tabela 16 – Exatidões Específicas das classes referentes aos mapeamentos realizados em plantio de bananeiras. 10/10/2017, Frutacor, Russas, Ceará, Brasil, 2018.

Classe	Maximum Likelihood	Mahalanobis Distance	Minimum Distance
Solo	81,94%	94,63%	91,04%
Folha Sadia	98,05%	58,09%	99,62%
Folha Anormal	90,77%	43,71%	85,33%
Nervura Central	88,16%	72,37%	87,72%
Sombra	-	-	99,65%

No processamento realizado no dia 10/10/2017 foi necessário a criação da classe de sombras para o algoritmo Minimum Distance, uma vez que nesta data maior parte do solo estava mais visível devido ao déficit hídrico e temperaturas elevadas, conforme citado anteriormente. Para os demais algoritmos, a classe de sombras foi automaticamente classificada dentro da classe de “Solo”, não afetando o processamento e interpretação dos dados da classe “Folha Anormal”, que é o foco deste estudo.

Na Figura 29 são exibidos recortes ampliados das três classificações para uma averiguação mais detalhada da maneira como os algoritmos alocaram os pixels em cada processamento.

Figura 29 – Recorte ampliado da área de estudos para voo no dia 10/10/2017, de acordo com A) Ortomosaico RGB; B) Classificação com algoritmo Maximum Likelihood; C) Classificação com algoritmo Mahalanobis Distance e; D) Classificação com algoritmo Minimum Distance



Fonte: Elaboração do autor, 2018.

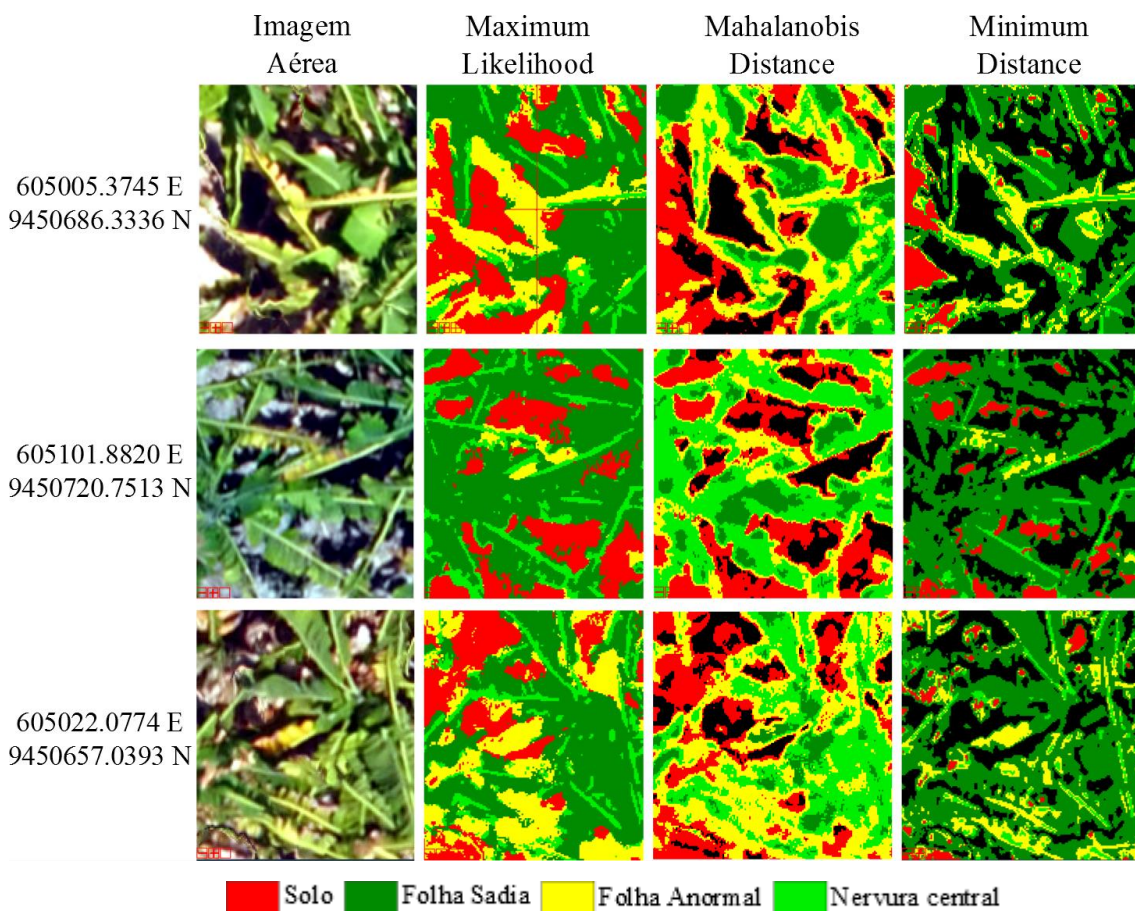
Utilizando métodos classificadores K-means e Redes Neurais Artificiais, Bashish, Braik e Bani-Ahmad (2010) realizaram a classificação de cinco doenças foliares, alcançando

acurácias de 93%. Gurjar e Gulhane (2012), em outra vertente, a partir de método PCA, obtiveram 90% de acerto e precisão para a identificação de três doenças foliares na cultura do algodão, utilizando câmera digital comum, se aproximando dos valores obtidos no atual trabalho, apesar dos algoritmos classificadores serem considerados mais avançados.

Singh e Misra (2017) apresentaram algoritmo para uma automática detecção e classificação de doenças foliares na cultura da bananeira, feijoeiro, roseira e limoeiro, utilizando imagens RGB, alcançando uma acurácia geral (todas as classificações juntas) de 97,6%. No caso específico, para a cultura da bananeira, os resultados obtidos com o novo algoritmo proposto, atingiu o patamar de 90% de acurácia, muito se aproximando dos valores obtidos no atual trabalho, principalmente para os meses de setembro e outubro. Os autores concluíram dissertando sobre as perspectivas futuras, com a utilização do algoritmo em consórcio a métodos mais avançados de ML, como Redes Neurais Artificiais e Lógica Fuzzy.

Na Figura 30 são exibidos maiores detalhes ampliados dos processamentos, evidenciando a maneira de categorização em classes dos mesmos.

Figura 30 – Recortes ampliados da área de estudos para voo no dia 10/10/2017



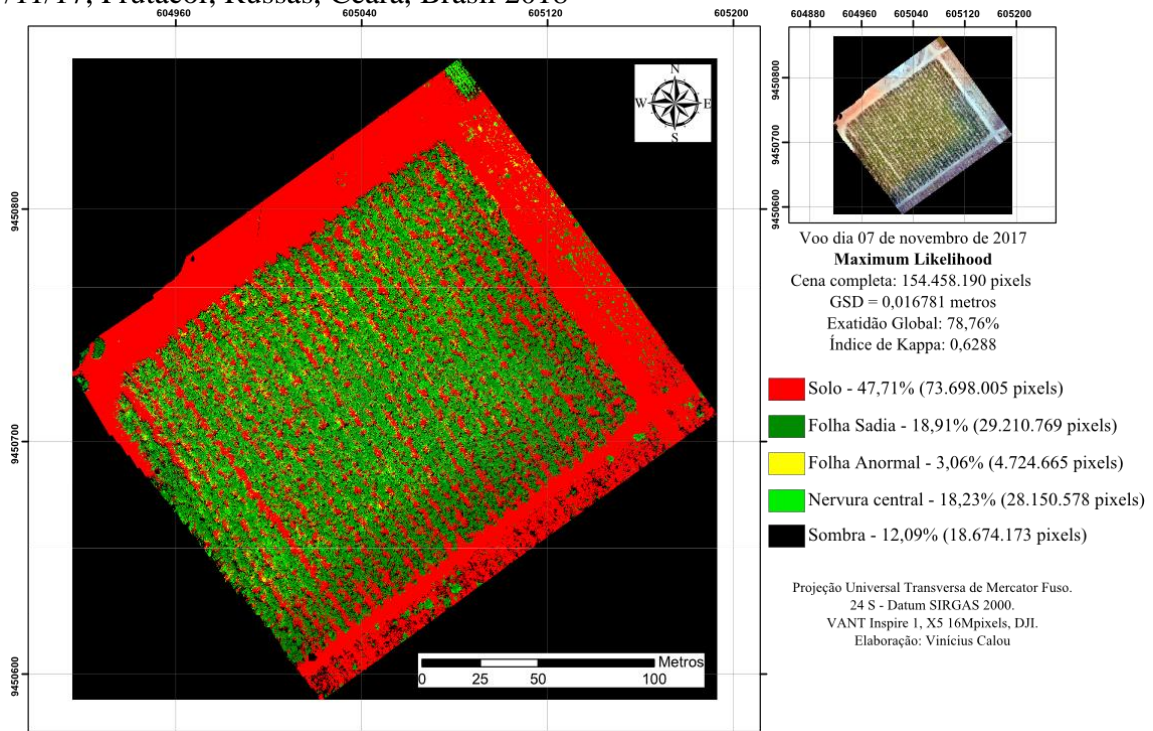
Fonte: Elaboração do autor, 2018.

Visualmente, o algoritmo classificador Mahalanobis Distance apresentou em seus resultados gráficos uma maior confusão na distinção entre as classes “Nervura Central”, “Folha Sadia” e “Folha Anormal”. Por outro lado, o algoritmo Distância Euclidiana (Minimum Distance) e Maximum Likelihood (Máxima Verossimilhança), foram efetivos na classificação principalmente das áreas amarelecidas causadas, provavelmente, por ataque da sigatoka-amarela.

4.2.3 Classificações de novembro – 3ª missão de campo

Nas Figuras 31, 32 e 33 são expostos os resultados das classificações realizadas a partir da missão de campo realizada no dia 07 de novembro de 2017, expondo o percentual de cada classe, bem como a Exatidão Global e o Índice de Kappa. Nas Tabelas 17, 18 e 19 são apresentadas as matrizes de confusão para cada um dos processamentos, auxiliando no entendimento da maneira como cada algoritmo categorizou os pixels.

Figura 31 – Mapa temático da classificação com algoritmo Maximum Likelihood no dia 07/11/17, Frutacor, Russas, Ceará, Brasil 2018




Fonte: Elaboração do autor, 2018.

Tabela 17 – Matriz de confusão da classificação realizada com o algoritmo Maximum Likelihood no dia 07/11/2017.

		Verdade de campo (%)				
		Solo	Folha Sadia	Folha Anormal	Nervura Central	Sombra
Classificação	Solo	96,37	0	0,74	0	0
	Folha Sadia	0	90,96	0	0	0
	Folha Anormal	0,04	0	74,13	5,14	0
	Nervura Central	0	9,04	25,13	94,86	0
	Sombra	0	0	0	0	100
Total		100	100	100	100	100

Pode ser observado uma confusão recorrente principalmente no que diz respeito às classes “Folha Anormal” e “Nervura Central”. Tal fenômeno pode ser explicado pela semelhança entre o comportamento espectral captado pela câmera X5, embarcada no VANT, entre os números digitais dos pixels inerentes aos alvos, como discutido adiante.

Figura 32 – Mapa temático da classificação com algoritmo Mahalanobis Distance no dia 07/11/17, Frutacor, Russas, Ceará, Brasil 2018




Fonte: Elaboração do autor, 2018.

Tabela 18 – Matriz de confusão da classificação realizada com o algoritmo Mahalanobis Distance no dia 07/11/2017.

		Verdade de campo (%)				
		Solo	Folha Sadia	Folha Anormal	Nervura Central	Sombra
Classificação	Solo	95,15	0	4,24	0,21	0,05
	Folha Sadia	0	62,21	34,04	22,27	0

Folha Anormal	0	0,37	33,3	4,07	0
Nervura Central	0	37,42	28,31	73,45	0
Sombra	4,85	0	0,11	0	99,95
Total	100	100	100	100	100

Figura 33 – Mapa temático da classificação com algoritmo Minimum Distance no dia 07/11/17, Frutacor, Russas, Ceará, Brasil 2018



Fonte: Elaboração do autor, 2018.

Tabela 19 – Matriz de confusão da classificação realizada com o algoritmo Minimum Distance no dia 07/11/2017.

		Verdade de campo (percentagem)				
		Solo	Folha Sadia	Folha Anormal	Nervura Central	Sombra
Classificação	Solo	73,78	0	0,11	7,71	0
	Folha Sadia	10,76	90,07	1,52	1,71	2,42
	Folha Anormal	12,47	0	69,14	3,85	0
	Nervura Central	0	0	26,41	86,51	0
	Sombra	3,00	9,93	2,82	0,22	97,58
Total		100	100	100	100	100

Apesar dos valores do índice de Kappa e Exatidão Global terem sido reduzidos em relação às duas séries classificativas anteriores, a assertividade dos algoritmos foi categorizada como “Muito boa”. Neste cenário, são demonstradas na Tabela 20 as notas de campo conforme levantamento realizado por especialista na identificação e quantificação da

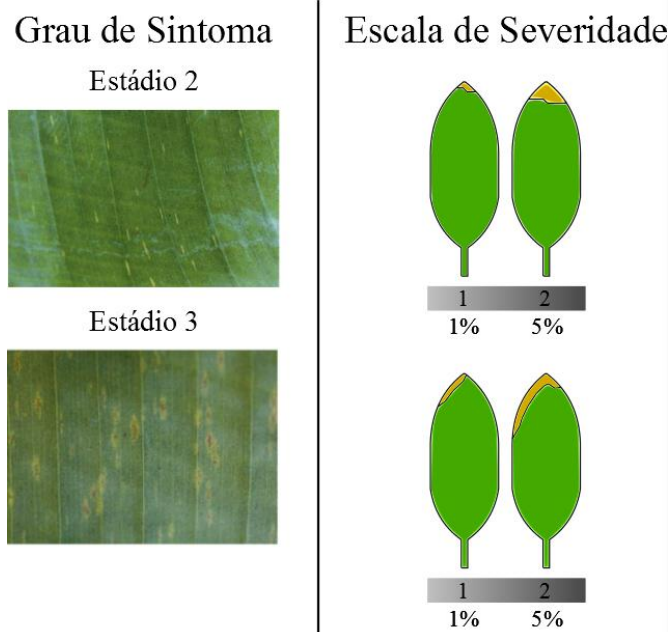
sigatoka-amarela, bem como os valores percentuais da classe “Folha Anormal”, para comparação com os levantamentos em campo.

Tabela 20 – Avaliações de campo e classificações da assertividade dos algoritmos para os processamentos referentes à 07/11/2017.

Nota de campo		Algoritmo	Classe "Folha Anormal"	Índice de Kappa	Exatidão Global
Grau de Sintoma	2,1	Maximum Likelihood	3,06%	62,88%	78,76%
Severidade	1,8	Mahalanobis Distance	1,29%	50,87%	70,36%
		Minimum Distance	0,34%	51,12%	70,66%

Conforme se observa na Tabela 20, as assertividades dos algoritmos foram reduzidas principalmente devido ao fato das estruturas foliares se apresentarem menos expostas, dificultando a fase de treinamento dos algoritmos. No entanto, o algoritmo Maximum Likelihood (Máxima Verossimilhança) apresentou resultados de folhas provavelmente afetadas pela sigatoka-amarela, de acordo com a classe “Folha Anormal”, de 3,06%, muito se aproximando do levantamento em campo, no qual a nota de severidade (1,8) representa níveis de infecção entre 1% e 5%, ilustrado na Figura 34. No quesito “Grau de Sintoma”, as notas de campo indicaram que a evolução da doença se encontrava entre os estádios 2 e 3.

Figura 34 – Grau de Sintoma e Severidade do ataque da sigatoka-amarela, descritos por Meredith (1970) e Stover (1971), modificada por Gauhl *et al.* (1994), levantamento dia 07/11/2017



Fonte: Elaboração do autor, 2018.

Nos processamentos referentes ao mês de novembro, portanto, o algoritmo Maximum Likelihood obteve um desempenho melhor que os demais, demonstrando maior robustez no caso de processamentos com dados de entrada mais difusos, corroborando com Phadikar, Sil e Das (2012), que buscaram a identificação de manchas foliares ocasionadas por doenças fúngicas na cultura do arroz.

Para uma análise mais detalhada do poder classificador dos algoritmos, apresenta-se na Tabela 21 as Exatidões Específicas de cada processamento supracitado.


Tabela 21 – Exatidões Específicas das classes referentes aos mapeamentos realizados em plantio de bananeiras. 07/11/2017, Frutacor, Russas, Ceará, Brasil, 2018.

Classe	Maximum Likelihood	Mahalanobis Distance	Minimum Distance
Solo	96,37%	95,15%	73,78%
Folha Sadia	99,96%	62,21%	90,07%
Folha Anormal	74,13%	33,30%	69,14%
Nervura Central	94,86%	73,45%	86,51%
Sombra	100%	99,95%	97,58%

Pode-se observar a partir da Tabela 21 que o algoritmo Maximum Likelihood obteve excelentes níveis de acertos, com exceção da classe “Folha Anormal”, que levou a exatidão global do processamento para patamares mais baixos. Neste cenário, a confusão se deu principalmente entre feições da “Nervura Central” das estruturas foliares da bananeira e sintomas característicos da sigatoka-amarela.

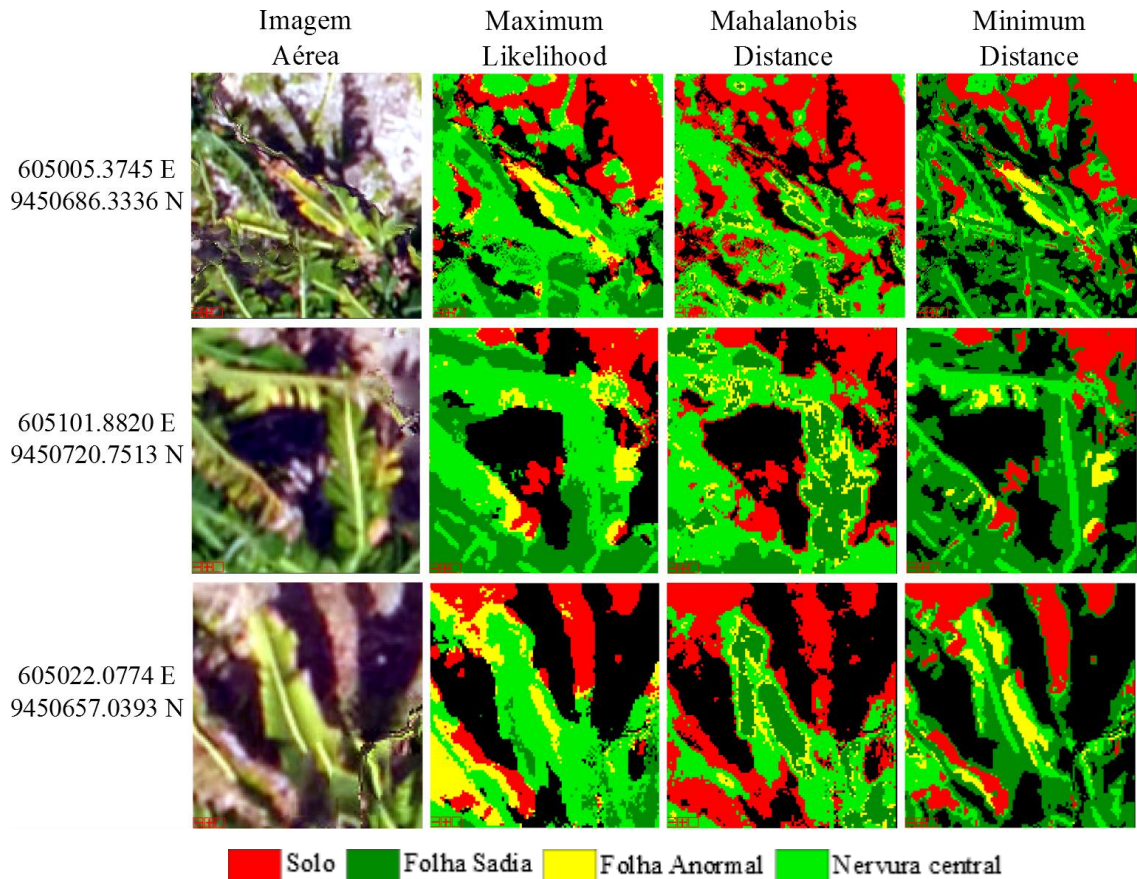
Nas Figuras 35 e 36 são exibidos recortes ampliados das três classificações para uma averiguação mais detalhada da maneira como os algoritmos alocaram os pixels em cada processamento.

Figura 35 – Recorte ampliado da área de estudos para voo no dia 07/11/2017, de acordo com A) Ortomosaico RGB; B) Classificação com algoritmo Maximum Likelihood; C) Classificação com algoritmo Mahalanobis Distance e; D) Classificação com algoritmo Minimum Distance



Fonte: Elaboração do autor, 2018.

Figura 36 – Recorte ampliado da área de estudos para voo no dia 07/11/2017



Fonte: Elaboração do autor, 2018.

Phadikar, Sil e Das (2012), utilizaram os classificadores Maximum Likelihood e SVM para identificar doenças fúngicas foliares na cultura do arroz (mancha parda e brusone do arroz) através de câmera comum (Nikon Coolpix p4, 8,1 megapixels). O fato das estruturas foliares da cultura do arroz serem naturalmente delgadas com certeza colaborou para a acurácia dos métodos alcançarem patamares de 79,5% e 68,1%, para os respectivos algoritmos. A comparação com os métodos expostos no atual trabalho se dá principalmente nas acurácias obtidas no mês de novembro. A principal limitação ao método, neste caso, deveu-se ao fato das estruturas foliares da cultura da bananeira estarem menos abertas e expostas, por conta do estresse hídrico e de temperatura. Phadikar, Sil e Das (2012) elucidam que os níveis de infecção e estágio de evolução da brusone do arroz foram responsáveis por gerar uma maior dificuldade de identificação e classificação da doença.

Deste modo, uma das principais problemáticas deste trabalho foi o fato da pouca exposição das estruturas foliares da bananeira ao sensor embarcado ao VANT, devido principalmente às condições climáticas de temperatura no momento do voo (normalmente realizado entre 10 horas da manhã e 14 horas da tarde) e do estresse hídrico. Assim, os dados

de entrada para o treinamento dos algoritmos para o mês de novembro reduziram a exatidão e a assertividade dos processamentos.

A confusão gerada pelos algoritmos é recorrente na literatura e, em grande parcela das pesquisas, os autores a explicam, citando a qualidade dos dados de entrada, o ruído que o fundo das imagens gera (devido a fundos despadronizados para as imagens em avaliação) e a iluminação não controlada. A grande variedade dos sensores promove uma vasta quantidade de resoluções espaciais em cada levantamento, deliberando uma mistura de informações dos pixels, sendo recorrente quando se utilizam plataformas orbitais, tais como satélites. Este fato foi aos poucos sendo contornado conforme a utilização de sensores in situ (câmeras digitais comuns) e o uso de aeronaves não tripuladas, gerando produtos de alta resolução espacial (GSDs < 1metro), conforme discutido previamente.

4.3 Classificações de fotografias individuais

Nesta seção serão apresentados os resultados obtidos a partir das classificações das imagens aéreas individuais em sobrevoo com altura de 30 metros em relação ao nível do solo, sem a composição dos ortomosaicos, para efeito de comparação com os resultados dos voos com composição de ortomosaicos.

4.3.1 Imagem 01 (605.006,937869 E, 9450660.51551 N, Zona 24 S – Sirgas 2000)

Na Tabela 22 são apresentados os resultados da Exatidão Global e Índice de Kappa dos processamentos referentes à imagem 01. Na categorização do Índice de Kappa, ambos os processos apresentaram resultados em níveis “Excelentes”, conforme metodologia de Landis e Kock (1977).

Tabela 22 – Exatidão Global, Índice de Kappa e classe "Folha Anormal" dos processamentos para a imagem central à cena, com coordenadas 605.006,937869 E, 9450660.51551 N, Zona 24 S – Sirgas 2000.

	Exatidão Global	Índice de Kappa	"Folha Anormal"
Maximum Likelihood	98,71%	97,60%	5,63%
Mahalanobis Distance	99,44%	98,96%	6,08%
Minimum Distance	88,63%	80,90%	9,12%

Nestes processamentos, os três algoritmos superestimaram as áreas amarelecidas provavelmente pelo ataque da sigatoka-amarela, com ênfase ao algoritmo Minimum Distance,

enquanto os classificadores Maximum Likelihood e Mahalanobis Distance muito se aproximaram dos valores levantados em campo pela metodologia convencional (Gauhl, 1994), em que foram observados valores entre 1 e 5%.

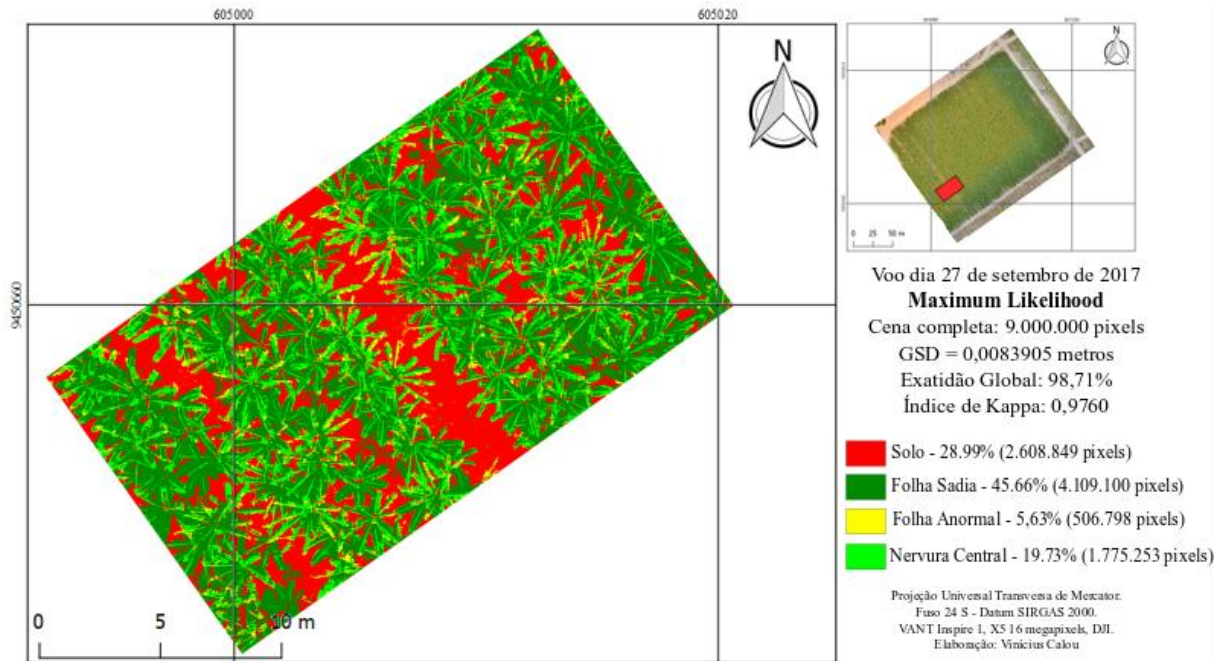
Na Figura 37 é apresentada a imagem aérea obtida por meio do VANT Inspire 1 adquirida a 30 metros de altura em relação ao nível do solo. A imagem foi submetida a classificações com os algoritmos supracitados, resultando em mapas temáticos apresentados nas Figuras 38, 39 e 40, bem como suas matrizes de confusão nas Tabelas 23, 24 e 25 respectivamente.

Figura 37 – Imagem aérea obtida por meio de VANT Inspire 1 a 30 metros de altura em relação ao nível do solo. Frutacor, Russas, Ceará, Brasil, 2018



Fonte: Elaboração do autor, 2018.

Figura 38 – Mapa temático da classificação de imagem individual com algoritmo Maximum Likelihood no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018



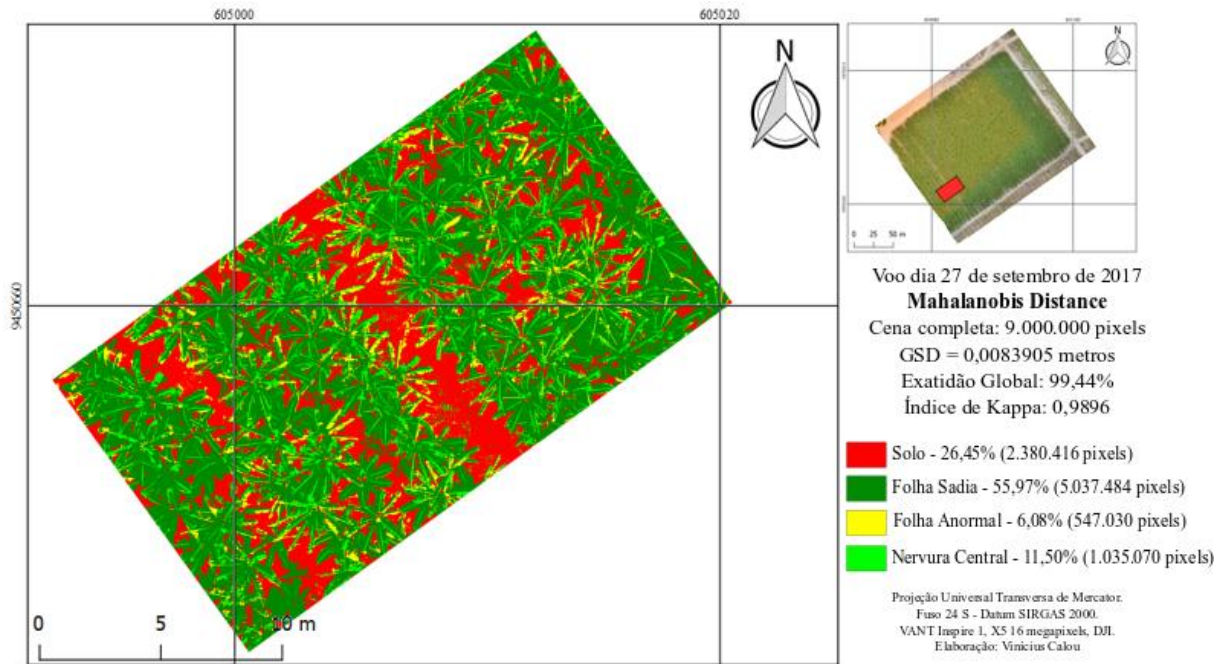
Fonte: Elaboração do autor, 2018.

Tabela 23 – Matriz de confusão da classificação realizada com o algoritmo Maximum Likelihood no dia 27/09/2017 em imagem individual.

		Verdade de campo (%)			
		Folha Anormal	Folha Sadia	Solo	Nervura Central
Classificação	Folha Anormal	96,08	0	0	22,57
	Folha Sadia	0	99,36	0	0
	Solo	2,32	0	100	0
	Nervura Central	1,6	0,64	0	77,43
Total		100	100	100	100

Apesar do processamento realizado com o algoritmo Maximum Likelihood ter se aproximado dos valores de severidade do ataque da sigatoka-amarela levantados em campo pela metodologia convencional, percebe-se pela sua matriz de confusão uma grande parcela da classe “Nervura Central” que foi categorizada como “Folha Anormal”. Este fenômeno é recorrente na literatura, principalmente em se tratando de trabalhos com imagens pancromáticas onde os algoritmos realizam a categorização dos pixels com base na informação de cor e textura, conforme citam Singh *et al.* (2016) e Tetila *et al.* (2017).

Figura 39 – Mapa temático da classificação de imagem individual com algoritmo Mahalanobis Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018

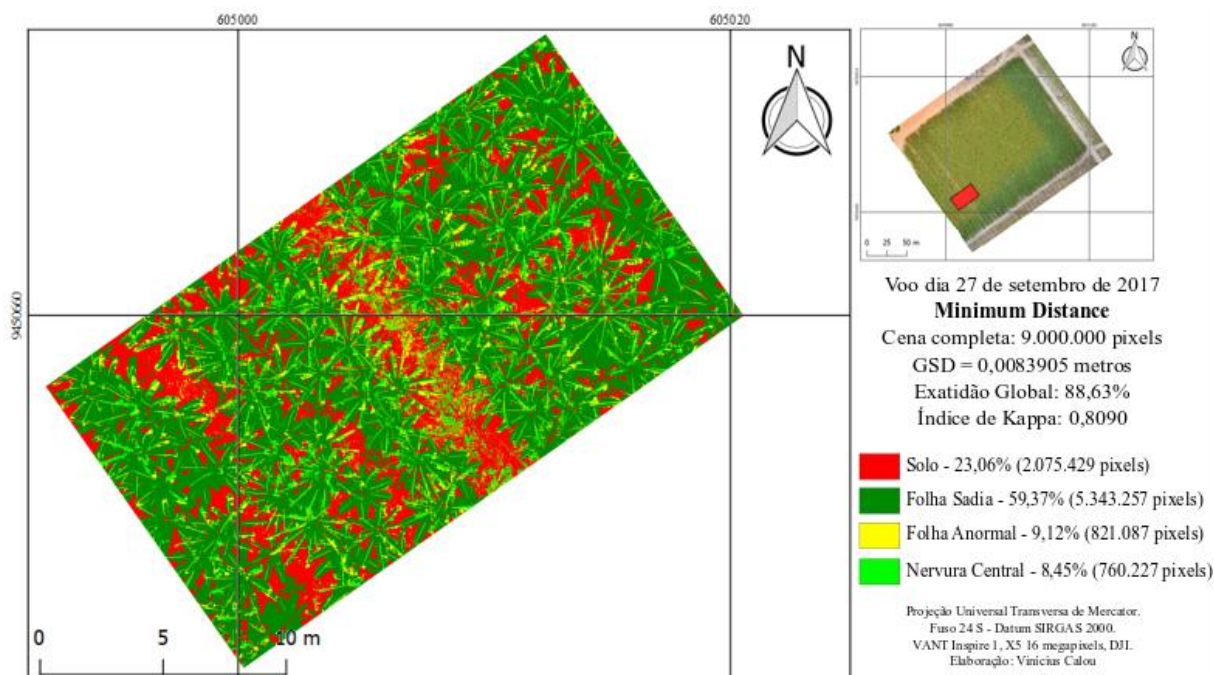


Fonte: Elaboração do autor, 2018.

Tabela 24 – Matriz de confusão da classificação realizada com o algoritmo Mahalanobis Distance no dia 27/09/2017 em imagem individual.

		Verdade de campo (%)			
		Folha Anormal	Folha Sadia	Solo	Nervura Central
Classificação	Folha Anormal	97,28	0	0	8,26
	Folha Sadia	0	100	0	1,28
	Solo	0,32	0	100	0
	Nervura Central	2,4	0	0	90,46
Total		100	100	100	100

Figura 40 – Mapa temático da classificação de imagem individual com algoritmo Minimum Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018



Fonte: Elaboração do autor, 2018.

Tabela 25 – Matriz de confusão da classificação realizada com o algoritmo Minimum Distance no dia 27/09/2017 em imagem individual.

		Verdade de campo (%)			
		Folha Anormal	Folha Sadia	Solo	Nervura Central
Classificação	Folha Anormal	94,8	0,02	2,51	27,34
	Folha Sadia	0	99,98	0	1,47
	Solo	0,08	0	83,99	0
	Nervura Central	5,12	0	13,5	71,19
Total		100	100	100	100

Corroborando com Tetila *et al.* (2017), o nível de detalhamento das imagens foi fator crucial para uma melhor distinção entre alvos. No entanto, diferente das classificações do ortomosaico a partir de fotografias a 60 metros de altura em relação ao nível do solo, os algoritmos Mahalanobis Distance e Maximum Likelihood foram os que mais se aproximaram dos valores de severidade do ataque da sigatoka-amarela levantados em campo pela metodologia convencional. No entanto, a análise da matriz de confusão permite indicar que o algoritmo Mahalanobis Distance obteve melhores resultados principalmente na distinção entre a classe “Folha Anormal” e as demais classes.

4.3.2 Imagem 02 (605034.679601 E, 9450721.9709 N, Zona 24 S – Sirgas 2000)

Na Tabela 23 são apresentados os resultados da Exatidão Global e Índice de Kappa dos processamentos referentes à imagem 02, categorizadas com padrão “Excelente”, apresentando valores acima de 80% de acurácia. É apresentada também a classe de “Folha Anormal” para uma comparação entre os valores levantados em campo, a partir da metodologia convencional de Gauhl (1994).

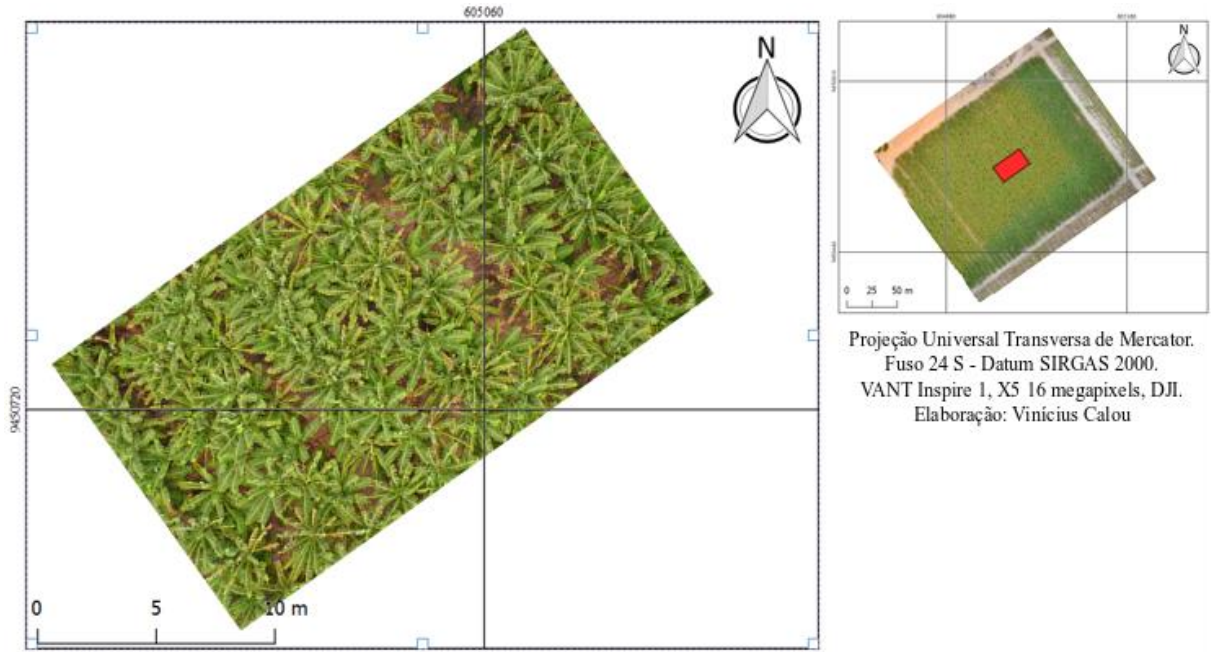
Tabela 26 – Exatidão Global, Índice de Kappa e classe "Folha Anormal" dos processamentos para a imagem central à cena, com coordenadas 605034.679601 E, 9450721.9709 N, Zona 24 S – Sirgas 2000.

	Exatidão Global	Índice de Kappa	"Folha Anormal"
Maximum Likelihood	94,61%	92,01%	14,20%
Mahalanobis Distance	96,58%	94,87%	4,97%
Minimum Distance	92,22%	88,30%	7,54%

Novamente, como observado nos processamentos anteriores, houve uma superestimação dos valores da classe “Folha Anormal” em comparação aos valores levantados em campo pela metodologia de Gauhl (1994), com exceção do algoritmo Mahalanobis Distance, que apresentou resultados entre 1% e 5%, conforme levantamento pela metodologia convencional.

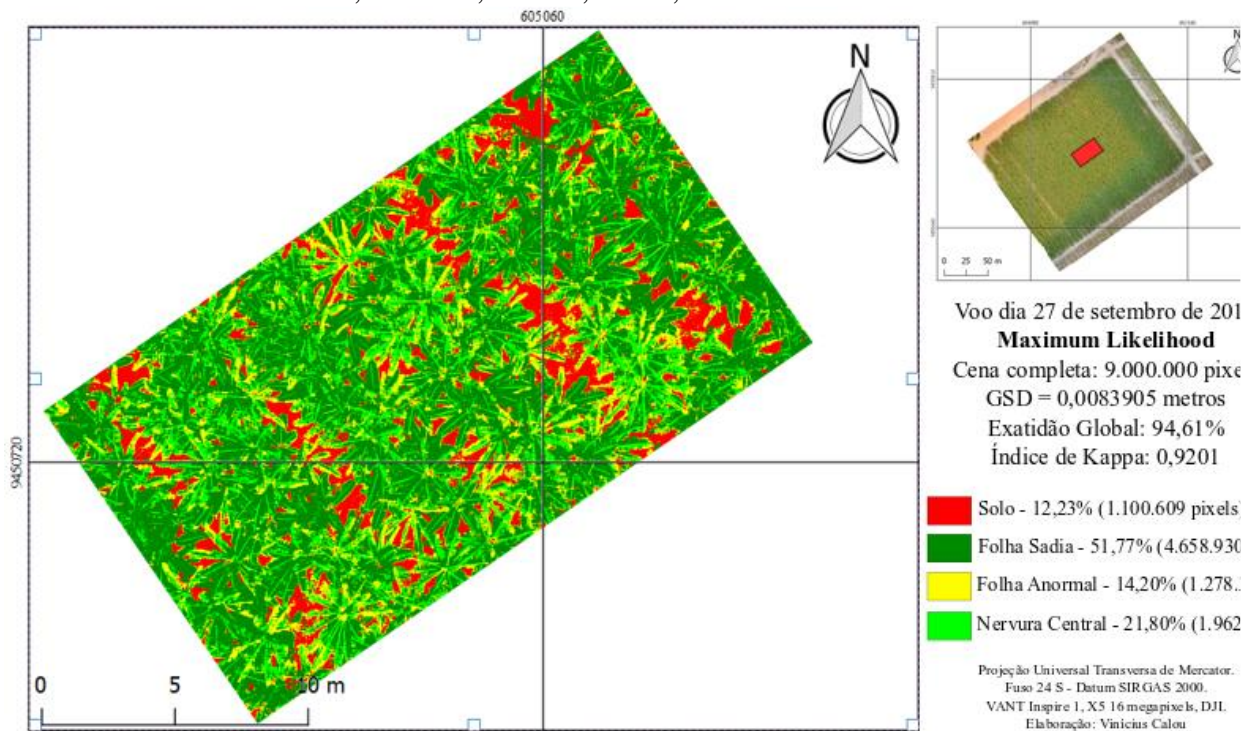
Na Figura 41 é apresentada a imagem aérea de posição central à área de estudos, em sobrevoo realizado no dia 27/09/2017 a 30 metros de altura em relação ao nível do solo. Nas Figuras 42, 43 e 44 são demonstrados os resultados das classificações desta imagem, bem como o percentual de cada classe composta pelos algoritmos avaliados neste trabalho. Nas Tabelas 27, 28 e 29 são expostas as matrizes de confusão, indicando a maneira de categorização dos pixels em cada processamento.

Figura 41 – Imagem aérea obtida por meio de VANT Inspire 1 a 30 metros de altura em relação ao nível do solo. Frutacor, Russas, Ceará, Brasil, 2018



Fonte: Elaboração do autor, 2018.

Figura 42 – Mapa temático da classificação de imagem individual com algoritmo Maximum Likelihood no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018



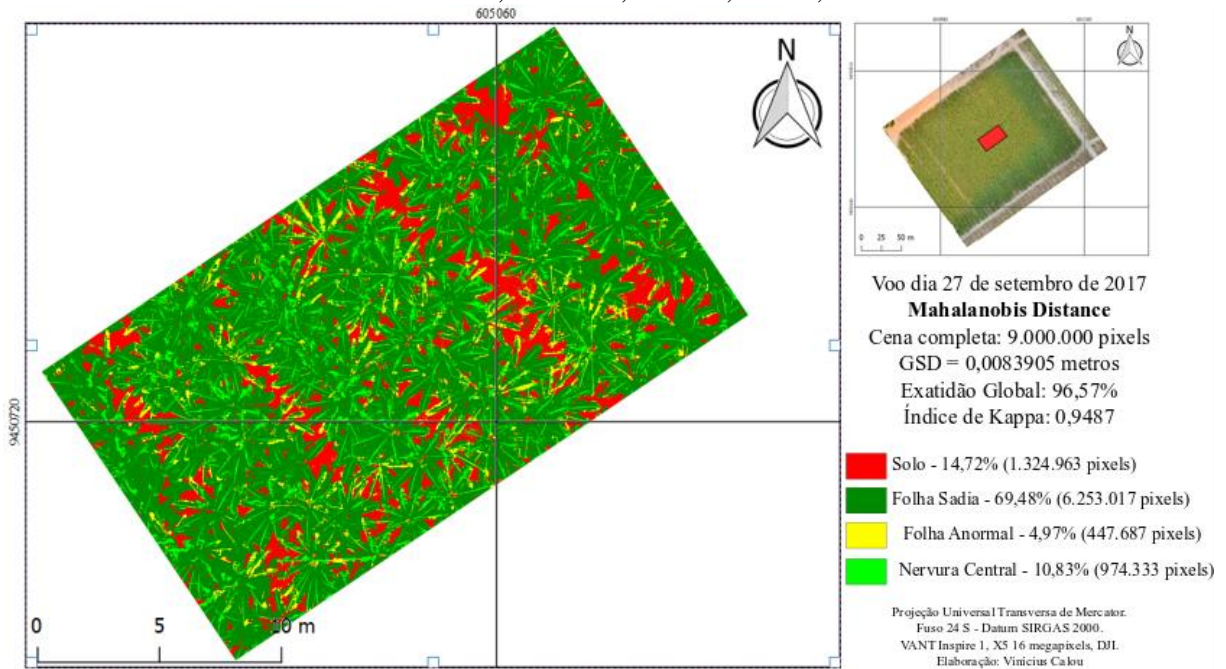
Fonte: Elaboração do autor, 2018.

Tabela 27 – Matriz de confusão da classificação realizada com o algoritmo Maximum Likelihood no dia 27/09/2017 em imagem individual.

	Verdade de campo (%)			
	Folha Anormal	Folha Sadia	Solo	Nervura Central

Classificação	Folha Anormal	97,88	0	0	22,3
	Folha Sadia	0	95,35	0	7,38
	Solo	1,46	0	100	0
	Nervura Central	0,66	4,65	0	70,33
Total	100	100	100	100	100

Figura 43 – Mapa temático da classificação da imagem individual com algoritmo Mahalanobis Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018

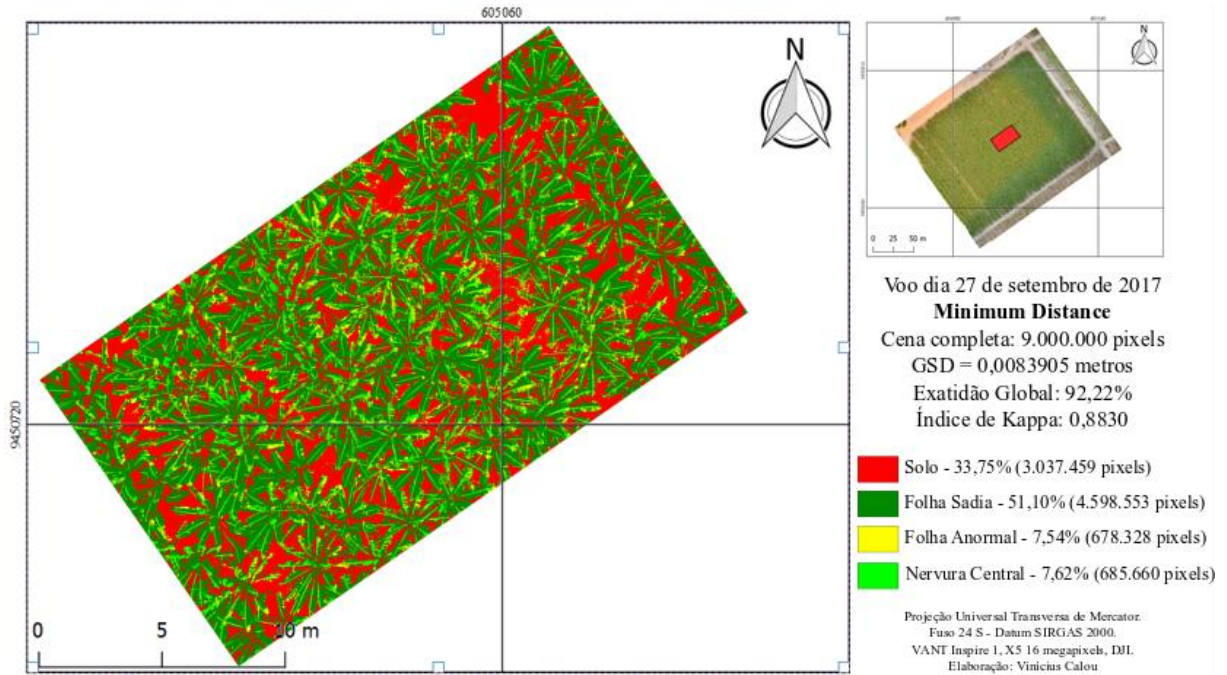


Fonte: Elaboração do autor, 2018.

Tabela 28 – Matriz de confusão da classificação realizada com o algoritmo Mahalanobis Distance no dia 27/09/2017 em imagem individual.

Classificação	Verdade de campo (%)			
	Folha Anormal	Folha Sadia	Solo	Nervura Central
Folha Anormal	90,57	0	0	10
Folha Sadia	0	99,31	0	8,52
Solo	3,45	0	99,95	0
Nervura Central	5,98	0,69	0,05	81,48
Total	100	100	100	100

Figura 44 – Mapa temático da classificação da imagem individual com algoritmo Minimum Distance Distance no dia 27/09/17, Frutacor, Russas, Ceará, Brasil 2018



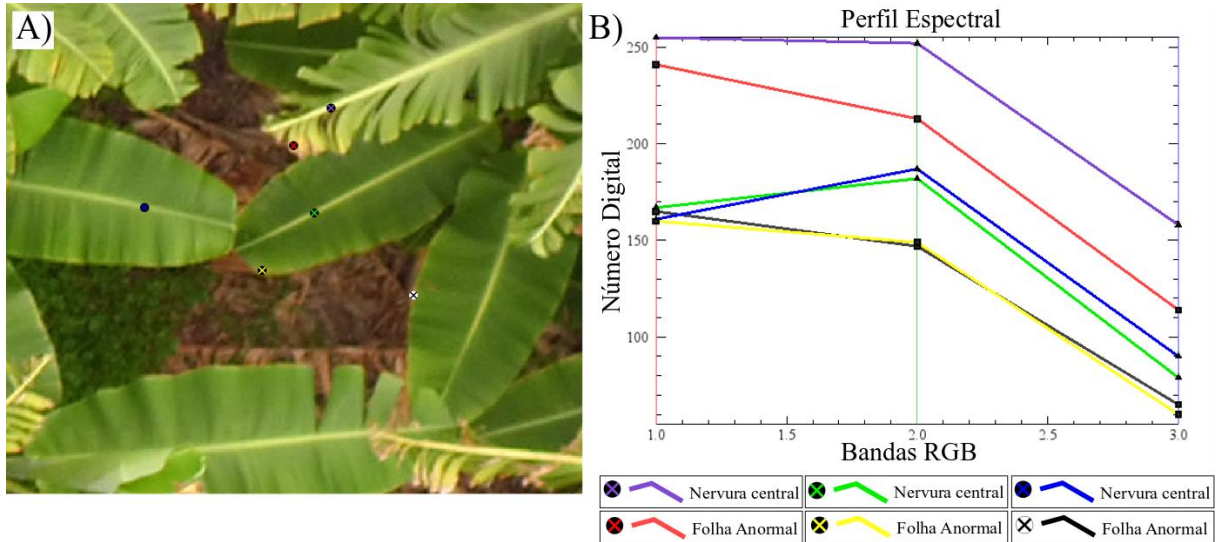
Fonte: Elaboração do autor, 2018.

Tabela 29 – Matriz de confusão da classificação realizada com o algoritmo Minimum Distance no dia 27/09/2017 em imagem individual.

	Verdade de campo (%)				
	Folha Anormal	Folha Sadia	Solo	Nervura Central	
Classificação	Folha Anormal	55,91	0	0,1	7,21
	Folha Sadia	1,06	99,73	1,5	7,7
	Solo	9,83	0,27	98,4	0
	Nervura Central	33,2	0	0	85,08
Total	100	100	100	100	

Para uma melhor compreensão da assinatura espectral (em número digital) dos pixels, é apresentado na Figura 45 os perfis de amostras aleatórias de pixels correspondentes à classe “Folha Anormal” e “Nervura Central”.

Figura 45 – Perfil Espectral RGB de diferentes alvos no ortomosaico obtido a partir de processamento com VANT em 27/09/2017. A) Amostras no ortomosaico; B) Perfil Espectral das frequências RGB



Fonte: Elaboração do autor, 2018.

A partir da análise da Figura 45, é possível compreender a confusão dos algoritmos na distinção entre a classe de “Folha Anormal” e “Nervura Central”. A variabilidade entre as respostas em número digital de cada alvo supracitado possui grande semelhança. A categorização de pixels de “Nervura Central” na classe de “Folha Anormal” provavelmente foi fator determinante para a superestimação da severidade da sigatoka-amarela.

5 CONCLUSÃO

A avaliação da metodologia proposta neste trabalho pela estatística de Kappa possibilitou a confirmação acerca da assertividade dos algoritmos em identificar, classificar e quantificar as manchas foliares ocasionadas principalmente pela sigatoka-amarela

Apesar de prejudicados pelo fechamento natural das estruturas foliares ocasionado pelo estresse hídrico e temperatura, os algoritmos Minimum Distance e Maximum Likelihood se mostraram ferramentas eficazes para o monitoramento da sigatoka-amarela.

Imagens pancromáticas de alta resolução espacial, obtidas por meio de VANTs, se mostraram excelentes dados de entrada para treinamento dos algoritmos de classificação supervisionada, gerando resultados interessantes. O nível de detalhamento das imagens (com GSD apresentado de 1,7 cm nos voos a 60 metros de altura em relação ao nível do solo e 0,8 cm nos voos a 30 metros em relação ao nível do solo) foi um fator crucial para os resultados obtidos.

6 RECOMENDAÇÕES

A utilização do algoritmo Minimum Distance, em situações ideais de aporte hídrico e nutrição, pode ser recomendada como técnica de auxílio no monitoramento da sigatoka-amarela.

Outros algoritmos mais robustos podem ser testados, podendo gerar resultados mais precisos, como Redes Neurais Artificiais ou Support Vector Machine.

REFERÊNCIAS

- ABBAS, Eyad I.; SAFI, Mohammed E.; RIJAB, Khalida S. Face recognition rate using different classifier methods based on PCA. *In: Current Research in Computer Science and Information Technology (ICCIT), 2017 International Conference on*. IEEE, 2017. p. 37-40. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7965559/> Acesso em: 05 mar. 2018
- ALSALAM, Bilal. **A small autonomous UAV for detection and action in precision agriculture**. 2017. Tese (Doutorado em Engenharia Elétrica). Queensland University of Technology, Australia, 2017. Disponível em: <http://eprints.qut.edu.au/104318/>. Acesso em: 10 mar. 2018
- AL BASHISH, Dheeb; BRAIK, Malik; BANI-AHMAD, Sulieman. A framework for detection and classification of plant leaf and stem diseases. *In: Signal and Image Processing (ICSIP), 2010 International Conference on*. IEEE, 2010. p. 113-118.
- AGISOFT LLC, 2013. *AgiSoft PhotoScan User Manual*. Professional Edition, Version 1.0.0. Disponível em: http://www.AgiSoft.ru/pscan/help/en/pscan_pro.pdf. Acesso em: 20 dez. 2017.
- AMICI, S. *et al.* Volcanic Environments Monitoring by Drones Mud Volcano Case Study. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Germany, v. 1, p. W2, 2013. Disponível em: https://www.researchgate.net/profile/Stefania_Amici/publication/256615062_VOLCANIC_ENVIRONMENTS_MONITORING_BY_DRONES_MUD_VOLCANO_CASE_STUDY/link/s/00b4952cbcc47a9fc3000000.pdf. Acesso em: 12 dez. 2017.
- BALUJA, J. *et al.* Assessment of vineyard water status variability by thermal and multispectral imagery using an unmanned aerial vehicle (UAV). **Irrigation Science**, v. 30, n. 6, p. 511-522, 2012. Disponível em: <http://link.springer.com/article/10.1007/s00271-012-0382-9>. Acesso em: 15 dez. 2017.
- BELLVERT, J. *et al.* Mapping crop water stress index in a ‘Pinot-noir’ vineyard: comparing ground measurements with thermal remote sensing imagery from an unmanned aerial vehicle. **Precision agriculture**, v. 15, n. 4, p. 361-376, 2014. Disponível em: <http://link.springer.com/article/10.1007/s11119-013-9334-5#>. Acesso em: 15 dez. 2017.
- BRASIL. Ministério da Defesa. Comando da Aeronáutica. **Sistemas de aeronaves pilotadas remotamente e o acesso ao espaço aéreo brasileiro**. 2015.
- BLANCO, F. M. G.; FRANCO, D. A. D. S.; NOMURA, E. S. **Manejo das plantas daninhas na cultura da banana. Bananicultura: manejo fitossanitário e aspectos econômicos e sociais da cultura**, 2013. p. 194-203.
- BARTON, Craig VM. Advances in remote sensing of plant stress. **Plant and Soil**, v. 354, n. 1-2, p. 41-44, 2012. Disponível em: <https://link.springer.com/article/10.1007/s11104-011-1051-0>. Acesso em: 05 mar. 2018.
- BAJWA, Sreekala G.; RUPE, John C.; MASON, Johnny. Soybean disease monitoring with

leaf reflectance. **Remote Sensing**, v. 9, n. 2, p. 127, 2017. Disponível em: <https://www.mdpi.com/2072-4292/9/2/127>. Acesso em: 24 mar. 2018.

BRITO, S. S. B. *et al.* Frequency, duration and severity of drought in the Semi-arid Northeast Brazil region. **International Journal of Climatology**, v. 38, n. 2, p. 517-529, 2018. Disponível em: <https://rmets.onlinelibrary.wiley.com/doi/full/10.1002/joc.5225>. Acesso em: 24 mar. 2018.

BALUJA, J.; DIAGO, M. P.; BALDA, P.; ZORER, R.; MEGGIO, F.; MORALES, F.; & TARDAGUILA, J. Assessment of vineyard water status variability by thermal and multispectral imagery using an unmanned aerial vehicle (UAV). **Irrigation Science**, v. 30, n. 6, p. 511-522, 2012. Disponível em: <http://link.springer.com/article/10.1007/s00271-012-0382-9>. Acesso em: 15 dez. 2017.

BAUMGARDNER, Marion F. *et al.* Reflectance properties of soils. *In: Advances in agronomy*. **Academic Press**, 1986. p. 1-44. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0065211308606720>. Acesso em: 25 mar. 2018.

BELLVERT, J.; ZARCO-TEJADA, P. J.; GIRONA, J.; FERERES, E. Mapping crop water stress index in a 'Pinot-noir' vineyard: comparing ground measurements with thermal remote sensing imagery from an unmanned aerial vehicle. **Precision agriculture**, v. 15, n. 4, p. 361-376, 2014. Disponível em: <http://link.springer.com/article/10.1007/s11119-013-9334-5#>. Acesso em: 15 dez. 2017.

BENDINI, Hugo do Nascimento; MORAES, Wilson da S.; SILVA, Silvia H.M.G.; TEZUKA, Erika S.; CRUVINEL, Paulo Estevão. Análise de risco da ocorrência de Sigatoka-negra baseada em modelos polinomiais: um estudo de caso. **Tropical Plant Pathology**, vol. 38(1): p. 035-043, 2013. Disponível em: <https://repositorio.unesp.br/handle/11449/27090>. Acesso em: 15 de jun. 2018.

BENDEA, H. F.; CHIABRANDO, F.; TONOLO, F. G.; MARENCHINO, D. Mapping of archaeological areas using a low-cost UAV the Augusta Bagiennorum Test site. *In: XXI International Symposium, Athens, Greece. 2007. Anais... 2007*. Disponível em: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.222.2807&rep=rep1&type=pdf>. Acesso em: 23 out. 2017.

BRUN, J. La Cercosporiose du bananier in Guinée: etude de la phase Ascorporée du *Mycosphaerella musicola* Leach. 1963. 16 . Tese (Doctor em Science) -IFAC, Paris, (Série A. Orsay, 35). 1963. Disponível em: <http://www.sidalc.net/cgi-bin/wxis.exe/?IsisScript=UACHBC.xis&method=post&formato=2&cantidad=1&expresion=mf=030358>. Acesso em: 13 out. 2017.

CAMPBELL, James B.; WYNNE, Randolph H. Introduction to remote sensing. **Guilford Press**, 2011. Disponível em: <https://books.google.com.br/books?hl=pt-BR&lr=&id=NkLmDjSS8TsC&oi=fnd&pg=PP1&dq=CAMPBELL,+James+B.%3B+WYNNE,+Randolph+H.+Introduction+to+remote+sensing,+Guilford+Press,+2011.&ots=s1JkA4IX4B&sig=HSaIAmMhfQnPS32EmrfsZirYOyU#v=onepage&q=CAMPBELL%2C%20James%20B.%3B%20WYNNE%2C%20Randolph%20H.%20Introduction%20to%20remote%20sensing.%20Guilford%20Press%2C%202011.&f=false>. Acesso em: 10 abril 2018.

CASBEER, D. W. *et al.* Forest fire monitoring with multiple small UAVs. *In: American Control Conference, 2005. Proceedings of the 2005.* IEEE, USA, jun 2005. p. 3530-3535. Disponível em: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1470520&tag=1. Acesso em 12 dez. 2017.

COMPANHIA NACIONAL DE ABASTECIMENTO. CONAB Acompanhamento da safra 2014/2015, 2015. Disponível em: <http://www.conab.gov.br/conteudos.php?a=1253&>. Acesso em: 18 dez. 2017.

COLOMINA, Ismael; MOLINA, Pere. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79-97, 2014. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0924271614000501>. Acesso em: 20 fev. 2018.

CALOU, V B C; TEIXEIRA A S; SILVA J A; OLIVEIRA, M R R; RABELO, F D B. **Simpósio Brasileiro de Recursos Naturais do Semiárido, III.**, 2017, Fortaleza, Ceará. MODELO DIGITAL DE ELEVAÇÃO UTILIZANDO IMAGENS DE VANT EM COMPARAÇÃO À MISSÃO SRTM... [S.l.: s.n.], 2017. 56 p. v. 1. Disponível em: https://www.researchgate.net/publication/319577748_MODELO_DIGITAL_DE_ELEVACA_O_UTILIZANDO_IMAGENS_DE_VANT_EM_COMPARACAO_A_MISSAO_SRTM. Acesso em: 08 maio 2018.

CALDERÓN, R. *et al.* High-resolution airborne hyperspectral and thermal imagery for early detection of Verticillium wilt of olive using fluorescence, temperature and narrow-band spectral indices. **Remote Sensing of Environment**, v. 139, p. 231-245, 2013. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425713002435>. Acesso em: 13 abr. 2018.

CHILLET, Marc *et al.* Sigatoka disease reduces the greenlife of bananas. **Crop Protection**, v. 28, n. 1, p. 41-45, 2009. Disponível em: <https://www.sciencedirect.com/science/article/pii/S026121940800152X>. Acesso em: 25 out. 2017.

COHEN, J. A Coefficient of Agreement for Nominal Scales. **Educational and Psychological Measurement**, 20(1): 37-46. 1960. Disponível em: <https://journals.sagepub.com/doi/abs/10.1177/001316446002000104?journalCode=epma>. Acesso em: 13 de out. 2017.

CORDEIRO, Z. J. M. **Manual para identificação e controle da sigatoka-negra da bananeira.** Cruz das Almas, BA, 2005. Disponível em: <http://www.sidalc.net/cgi-bin/wxis.exe/?IsisScript=AGB.xis&method=post&formato=2&cantidad=1&expresion=mfn=241842>. Acesso em: 13 de out. 2017.

CORDEIRO, Z. J. M.; MATOS, AP de; KIMATI, H. **Doenças da bananeira.** EMBRAPA-CNPMF, 1983.

KIMATI, H. Manual de Fitopatologia: Doenças das Plantas Cultivadas. 4 ed. São Paulo: **Agronômica Seres**. 2005. v 2. P 99-117.

CORDEIRO, Z. J. M. Banana: produção - aspectos técnicos. Brasília: **Embrapa** Comunicação para Transferência de Tecnologia, 2000. 143 p. Disponível em: <http://agris.fao.org/agris-search/search.do?recordID=US201300117143>. Acesso em: 12 mar. 2018.

ÇABUK, A.; DEVECI, A.; ERGINCAN, F. Improving heritage documentation. **GIM International**, v. 21, n. 9, 2007.

DE BELLAIRE, Luc de Lapeyre *et al.* Black Leaf Streak Disease is challenging the banana industry. **Fruits**, v. 65, n. 6, p. 327-342, 2010. Disponível em: <https://www.cambridge.org/core/journals/fruits/article/black-leaf-streak-disease-is-challenging-the-banana-industry/01E9748C03B6E7BB92B47CC842FC79DE>. Acesso em: 31 out. 2017.

D'OLEIRE-OLTMANN, S. *et al.* Unmanned Aerial Vehicle (UAV) for monitoring soil erosion in Morocco. **Remote Sensing**, v. 4, n. 11, p. 3390-3416, 2012. Disponível em: <http://www.mdpi.com/2072-4292/4/11/3390/htm>. Acesso em: 15 dez. 2017.

DOHERTY, P. Advanced Research with Autonomous Unmanned Aerial Vehicles. *In*: **KR**. Sweden, 2004. p. 731-732. Disponível em: <http://www.aaai.org/Papers/KR/2004/KR04-076.pdf>. Acesso em: 11 dez. 2017.

DI GENNARO, Salvatore F. *et al.* Unmanned Aerial Vehicle (UAV)-based remote sensing to monitor grapevine leaf stripe disease within a vineyard affected by esca complex. **Phytopathologia Mediterranea**, v. 55, n. 2, p. 262, 2016. Disponível em: <http://www.fupress.net/index.php/pm/article/view/18312>. Acesso em: 11 dez. 2017.

DONATO, Sérgio Luiz Rodrigues *et al.* Comportamento fitotécnico da bananeira Prata-Anã e de seus híbridos. **Pesquisa Agropecuária Brasileira**, v. 44, n. 12, p. 1608-1615, 2010. Disponível em: <http://seer.sct.embrapa.br/index.php/pab/article/view/2914>. Acesso em: 11 dez. 2017.

EMBRAPA. CORDEIRO, Zilton José Maciel (Organizador). BANANA: Fitossanidade. **Série Frutas do Brasil**. 1 ed. 121 p. 2000. Disponível em: <http://frutvasf.univasf.edu.br/images/banana1.pdf>. Acesso em: 15 de março de 2017.

EISENBEISS, H.; ZHANG, L. Comparison of DSMs generated from mini UAV imagery and terrestrial laser scanner in a cultural heritage application. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVI-5**, Switzerland, 90e96, 2006. Disponível em: http://www.isprs.org/proceedings/XXXVI/part5/paper/EISE_649.pdf. Acesso em: 11 dez. 2017.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **EMBRAPA Agência de informação**. 2015. Disponível em: <https://www.embrapa.br/agua-na-agricultura/observatorio-safra-2014-2015>. Acesso em: 18 dez. 2017.

EMBRAPA INFORMAÇÃO TECNOLÓGICA, 2006. Disponível em: <http://ainfo.cnptia.embrapa.br/digital/bitstream/item/11902/2/00079160.pdf>. Acesso em: 15

set. 2017.

FAHLSTROM, P.; GLEASON, T. **Introduction to UAV systems**. John Wiley & Sons, 2012. Disponível em:

<https://books.google.com.br/books?hl=ptBR&lr=&id=uLsNtm99IWYC&oi=fnd&pg=PT9&dq=Introduction+to+UAV+Systems&ots=IPINCb8ZIA&sig=9fCMYtNuXVeXtZtrATICWYSFUOk#v=onepage&q=Introduction%20to%20UAV%20Systems&f=false>. Acesso em: 19 dez. 2017.

FENG, Q.; LIU, J.; GONG, J.. UAV Remote sensing for urban vegetation mapping using Random Forest and texture analysis. **Remote Sensing**, v. 7, n. 1, p. 1074-1094, 2015.

Disponível em: <http://www.mdpi.com/2072-4292/7/1/1074/htm>. Acesso em: 16 dez. 2017.

FLYNN, K. F.; CHAPRA, S. C. Remote sensing of submerged aquatic vegetation in a shallow non-turbid river using an unmanned aerial vehicle. **Remote Sensing**, v. 6, n. 12, p. 12815-12836, 2014. Disponível em: <http://www.mdpi.com/2072-4292/6/12/12815/htm>. Acesso em: 14 dez. 2017.

FOOD AND AGRICULTURE ORGANIZATION. **FAO Production Year Book**. Rome, FAO, 2013. Disponível em: <http://faostat3.fao.org/browse/Q/QC/E>. Acesso em: 18 dez. 2017.

FURLANETO, F. P. B. *et al.* **Custo de produção e rentabilidade da cultura de banana “maçã” (Musa ssp.) na região do médio Paranapanema, Estado de São Paulo, 2005.**

Informações Econômicas, São Paulo, v. 35, n. 12, p. 19-25, dez. 2005. Disponível em: <http://cientifica.org.br/index.php/cientifica/article/view/198>. Acesso em: 18 maio 2018.

FREITAS, A. S., POZZA, E. A., ALVES, M. C., COELHO, G., ROCHA, H. S., & POZZA, A. A. A. Spatial distribution of Yellow Sigatoka Leaf Spot correlated with soil fertility and plant nutrition. **Precision agriculture**, v. 17, n. 1, p. 93-107, 2016. Disponível em:

<https://link.springer.com/article/10.1007/s11119-015-9409-6>. Acesso em: 30 maio 2018.

FERREIRA, Danúzia Maria Vieira; CORDEIRO, Zilton José Maciel; MATOS, Aristoteles Pires. Sistema de pré-aviso para o controle da sigatoka-amarela da bananeira no recôncavo baiano. **Rev. Bras. Frutic., Jaboticabal - SP**, v. 25, n. 3, p. 429-431, dezembro 2003.

Disponível em: <http://www.scielo.br/pdf/rbf/v25n3/18660>. Acesso em: 08 ago. 2017.

FREITAS, Aurivan Soares de. **Sigatoka-amarela da bananeira em função da nutrição mineral em solução nutritiva e da distribuição espacial da fertilidade solo**. 2013.

Dissertação (Dissertação em Agronomia/Fitopatologia) – Universidade Federal de Lavras, Lavras, 2013. Disponível em:

http://repositorio.ufla.br/bitstream/1/723/3/DISSERTACAO_Sigatoka-amarela%20da%20bananeira%20....pdf. Acesso em: 12 maio 2018.

FOURÉ, E. Leaf spot disease of banana and plantain caused by *mycosphaerella musicola* and *m. fijiensis*. *In: International network for the improvement of banana and plantain. S.l.: s.n.* p. 47–53. 1994. Disponível em:

https://www.biodiversityinternational.org/fileadmin/user_upload/online_library/publications/pdfs/282.pdf#page=35. Acesso em: 08 ago. 2017.

FOURÉ, E. Stratégies de lutte contre la cercosporiose noire des bananiers et des plantains provoquée par *Mycosphaerella fijiensis* Morelet. L'avertissement biologique au Cameroun. Evaluation des possibilités d'amélioration. **Fruits**, Paris, v. 43, n. 5, p. 269-274, mai, 1988. Disponível em: <http://www.sidalc.net/cgi-bin/wxis.exe/?IsisScript=UPEB.xis&method=post&formato=2&cantidad=1&expresion=mfn=004830>. Acesso em: 08 ago. 2017.

GAO, Na; SHI, Ren; XIE, Yao-wen. Research on Spectral Characteristics of *Mycosphaerella laricleptolepis* Ito *et al* and Correlations of Chlorophyll Concentrations [J]. **Remote Sensing Technology and Application**, v. 6, p. 007, 2007. Disponível em: http://en.cnki.com.cn/Article_en/CJFDTotal-YGJS200706007.htm. Acesso em: 08 ago. 2017.

GAUHL, F. **Epidemiology and ecology of black sigatoka (*Mycosphaerella fijiensis* Morelet) on plantain and banana (*Musa spp*) in Costa Rica, Central America**. INIBAP, Montpellier (Francia), 1994. Disponível em: <http://www.sidalc.net/cgi-bin/wxis.exe/?IsisScript=orton.xis&method=post&formato=2&cantidad=1&expresion=mfn=057167>. Acesso em: 25 abr. 2018.

GARCIA-RUIZ, Francisco *et al*. Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. **Computers and Electronics in Agriculture**, v. 91, p. 106-115, 2013. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169912002748>. Acesso em: 25 abr. 2018.

GLADE, D. **Unmanned aerial vehicles: Implications for military operations**. Air University Press Maxwell Air force base, Alabama, 2000. Disponível em: <http://www.au.af.mil/au/awc/awcgate/cst/cs16.pdf>. Acesso em: 10 dez. 2017.

GUI, Jiangsheng *et al*. A new method for soybean leaf disease detection based on modified salient regions. **International Journal of Multimedia and Ubiquitous Engineering**, v. 10, n. 6, p. 45-52, 2015. Disponível em: <https://pdfs.semanticscholar.org/08e7/cc1e99f8b7ce2e00eed0eb828d17a5778470.pdf>. Acesso em: 25 abr. 2018.

GURJAR, Ajay A.; GULHANE, Viraj A. Disease detection on cotton leaves by eigenfeature regularization and extraction technique. **International Journal of Electronics, Communication and Soft Computing Science & Engineering (IJECSCE)**, v. 1, n. 1, p. 1, 2012. Disponível em: <http://www.ijecscse.org/papers/feb2012/Disease-Detection-on-Cotton-Leaves-by-Eigenfeature-Regularization-and-Extraction-Technique.pdf>. Acesso em: 25 abr. 2018.

GANRY, J.; MEYER, J. P. La lutte contrôlée contre le cercospora aux Antilles. Bases climatiques de l'avertissement. Technique d'observation et numération de la maladie. **Fruits**, Paris, v.27, n. 11, p. 767-774, nov. 1972. Disponível em: <http://agritrop.cirad.fr/425560/>. Acesso em: 25 abr. 2018.

GANRY, J.; LAVILLE, E. Les cercosporioses du bananier et leurs traitement; evolutions des méthodes de traitement. I. Traitements fongicides 2. Avertissement. **Fruits**, Paris, v. 38, n. 1, p. 3-20, 1983. Disponível em: <http://agritrop.cirad.fr/414231/>. Acesso em: 25 abr. 2018.

HAARBRINK, R. B.; KOERS, E. Helicopter UAV for photogrammetry and rapid response. *In: International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, ISPRS Workshop of Inter-Commission WG I/V, Autonomous Navigation, Antwerp, Belgium.* 2006. Disponível em:

<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.222.4943&rep=rep1&type=pdf>. Acesso em: 11 dez. 2017.

HONKAVAARA, E. *et al.* Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. **Remote Sensing**, Finland, v. 5, n. 10, p. 5006-5039, oct 2013. Disponível em: <http://www.mdpi.com/2072-4292/5/10/5006/htm> Acesso em: 10 dez. 2017.

HUNT JR, E. R. *et al.* Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, v. 6, n. 4, p. 359-378, 2005. Disponível em: <http://link.springer.com/article/10.1007/s11119-005-2324-5#/page-1>. Acesso em: 15 dez. 2017.

HUNT, E. R. *et al.* Acquisition of NIR-green-blue digital photographs from unmanned aircraft for crop monitoring. **Remote Sensing**, v. 2, n. 1, p. 290-305, 2010. Disponível em: <http://www.mdpi.com/2072-4292/2/1/290>. Acesso em: 15 dez. 2017.

HERNÁNDEZ-RABADÁN, Deny Lizbeth; RAMOS-QUINTANA, Fernando; GUERRERO JUK, Julian. Integrating SOMs and a Bayesian classifier for segmenting diseased plants in uncontrolled environments. **The Scientific World Journal**, v. 2014, 2014. Disponível em: <https://www.hindawi.com/journals/tswj/2014/214674/abs/>. Acesso em: 25 abr. 2018.

HALL, Forrest G. *et al.* Multi-angle remote sensing of forest light use efficiency by observing PRI variation with canopy shadow fraction. **Remote Sensing of Environment**, v. 112, n. 7, p. 3201-3211, 2008. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425708001144> . Acesso em: 25 abr. 2018.

HERNÁNDEZ-RABADÁN, Deny Lizbeth; RAMOS-QUINTANA, Fernando; GUERRERO JUK, Julian. Integrating SOMs and a Bayesian classifier for segmenting diseased plants in uncontrolled environments. **The Scientific World Journal**, v. 2014, 2014. Disponível em: <https://www.hindawi.com/journals/tswj/2014/214674/abs/> . Acesso em: 25 abr. 2018.

HORCHER, A.; VISSER, R. J. M. Unmanned Aerial Vehicles: Applications for Natural Resource Management and Monitoring. *In: Council on Forest Engineering Annual Meeting, Hot Springs (AR), USA.* 2004. **Anais...** 2004. Disponível em: http://www.cofe.frec.vt.edu/documents/2004/COFE_2004_Horcher_Visser.pdf. Acesso em: 23 de out 2017.

IMMERZEEL, W. W. *et al.* High-resolution monitoring of Himalayan glacier dynamics using unmanned aerial vehicles. **Remote Sensing of Environment**, v. 150, p. 93-103, 2014. Disponível em: <http://www.sciencedirect.com/science/article/pii/S003442571400176X> Acesso em: 14 dez. 2017.

JENSEN JR. Remote sensing of the environment: an Earth Resources Perspective. 2. ed. Upper Saddle River: **Prentice-Hall**. 592p. 2007. Disponível em: http://gers.uprm.edu/geol6225/pdfs/01_rs_environment.pdf . Acesso em: 25 abr. 2018.

JOALLAND, Samuel *et al.* Aerial and Ground Based Sensing of Tolerance to Beet Cyst Nematode in Sugar Beet. **Remote Sensing**, v. 10, n. 5, p. 787, 2018. Disponível em: <https://www.mdpi.com/2072-4292/10/5/787> . Acesso em: 25 abr. 2018.

LANDIS, J. Richard; KOCH, Gary G. **The measurement of observer agreement for categorical data. biometrics**, p. 159-174, 1977. Disponível em: <https://www.jstor.org/stable/pdf/2529310.pdf> . Acesso em: 25 abr. 2018.

LANGHE, Edmond. Banana and plantain: the earliest fruit crops? *In*: INIBAP (International Network for the Improvement of Banana and Plantain). Networking banana and plantain: annual report 1995 – **focus paper 1**. Montpellier (FR): INIBAP, 1996, p. 6-8. Disponível em: http://bananas.biodiversityinternational.org/files/files/pdf/publications/an05_en.pdf. Acesso em: 15 março de 2017.

LACERDA, M. D. *et al.* Análise econômica da produção de banana-maçã na região sudeste do Estado do Pará. **Informações Econômicas**, São Paulo, v. 43, n. 4, p. 40-44, jul./ago. 2013. Disponível em: <http://www.iea.sp.gov.br/ftp/iea/publicacoes/ie/2013/tec3-0813.pdf> . Acesso em: 25 abr. 2018.

LEE, W. S. *et al.* Sensing technologies for precision specialty crop production. **Computers and electronics in agriculture**, v. 74, n. 1, p. 2-33, 2010. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169910001493> . Acesso em: 25 abr. 2018.

LELONG, C. CD *et al.* Assessment of unmanned aerial vehicles imagery for quantitative monitoring of wheat crop in small plots. **Sensors**, v. 8, n. 5, p. 3557-3585, 2008. Disponível em: <http://www.mdpi.com/1424-8220/8/5/3557/htm>. Acesso em: 15 dez. 2017.

LILLESAND T. M.; KIEFER R. W.; CHIPMAN J. W. **Remote Sensing and Image Interpretation**. John Wiley & Sons, 2008. Disponível em: https://books.google.com.br/books/about/Remote_sensing_and_image_interpretation.html?id=XaIsAQAAMAAJ&redir_esc=y. Acesso em: 19 dez. 2017.

LI, Bo *et al.* Hyperspectral identification of rice diseases and pests based on principal component analysis and probabilistic neural network. **Transactions of the Chinese Society of Agricultural Engineering**, v. 25, n. 9, p. 143-147, 2009. Disponível em: <https://www.ingentaconnect.com/content/tcsae/tcsae/2009/00000025/00000009/art00026> . Acesso em: 25 abr. 2018.

LORENZZETTI, J. A. Princípios físicos de sensoriamento remoto. São Paulo: **Blucher**, 2015. Disponível em: <https://www.blucher.com.br/livro/detalhes/principios-fisicos-de-sensoriamento-remoto-1053> . Acesso em: 25 abr. 2018.

LOUARGANT, Marine *et al.* Unsupervised Classification Algorithm for Early Weed Detection in Row-Crops by Combining Spatial and Spectral Information. **Remote Sensing**, v. 10, n. 5, p. 761, 2018. Disponível em: <https://www.mdpi.com/2072-4292/10/5/761> . Acesso

em: 25 abr. 2018.

LUCIEER, A. *et al.* HyperUAS—Imaging spectroscopy from a multirotor unmanned aircraft system. **Journal of Field Robotics**, Australia, v. 31, n. 4, p. 571-590, mar 2014. Disponível em: <http://onlinelibrary.wiley.com/doi/10.1002/rob.21508/abstract>. Acesso em: 10 dez. 2017.

MA, Zhenkui; REDMOND, Roland L. Tau coefficients for accuracy assessment of classification of remote sensing data. **Photogrammetric Engineering and Remote Sensing**, v. 61, n. 4, p. 435-439, 1995. Disponível em: https://www.asprs.org/wp-content/uploads/pers/1995journal/apr/1995_apr_435-439.pdf . Acesso em: 25 abr. 2018.

MARIN, Douglas H. *et al.* Black Sigatoka: an increasing threat to banana cultivation. **Plant disease**, v. 87, n. 3, p. 208-222, 2003. Disponível em: <https://apsjournals.apsnet.org/doi/abs/10.1094/PDIS.2003.87.3.208> . Acesso em: 25 abr. 2018.

MATSUURA, Fernando César Akira Urbano. COSTA, Jane Iara Pereira Da , FOLEGATTI, Marília Ieda Da Silveira. Marketing de banana: preferências do consumidor quanto aos atributos de qualidade dos frutos. **Rev. Bras. Frutic.**, Jaboticabal - SP, v. 26, n. 1, p. 48-52, Abril 2004. Disponível em: <http://www.scielo.br/pdf/rbf/v26n1/a14v26n1> . Acesso em: 25 abr. 2018.

MOREIRA, M.A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 2.ed. Viçosa - MG: UFV, 2003. 307 p. Disponível em: http://www.scielo.br/scielo.php?script=sci_nlinks&ref=000195&pid=S0100-6916200900030001200011&lng=pt . Acesso em: 25 abr. 2018.

MAPA - Ministério da Agricultura Pecuária e Abastecimento. **Ministra recebe demandas do setor produtivo da banana: Brasil produz anualmente 7 milhões de toneladas da fruta**. 2015. Disponível em: <http://www.agricultura.gov.br/comunicacao/noticias/2015/04/ministra-recebe-demandas-do-setor-produtivo-da-banana>. Acesso em: 11 out. 2017.

MATTIELLO, C. D. *et al.* Controle de Atitude para Veículos Aéreos Não Tripulados do Tipo Quadricóptero: PID vs Lógica Fuzzy. **Computer on the Beach**, Florianópolis, p. 111-120, mar 2015. Disponível em: <http://www6.univali.br/seer/index.php/acotb/article/view/7017> Acesso em: 10 dez. 2017.

MAZA, I. *et al.* Experimental results in multi-UAV coordination for disaster management and civil security applications. **Journal of intelligent & robotic systems**, v. 61, n. 1-4, p. 563-585, jan 2011. Disponível em: <http://link.springer.com/article/10.1007/s10846-010-9497-5#page-1>. Acesso em: 13 dez. 2017.

MEREDITH, Donald Stewart *et al.* Banana leaf spot disease (sigatoka) caused by *Mycosphaerella musicola* Leach. **Phytopathological papers**, n. 11, 1970. Disponível em: <https://www.cabdirect.org/cabdirect/abstract/19710302492> . Acesso em: 25 abr. 2018.

MERINO, L. *et al.* An unmanned aircraft system for automatic forest fire monitoring and measurement. **Journal of Intelligent & Robotic Systems**, v. 65, n. 1-4, p. 533-548, jan 2012. Disponível em: <http://link.springer.com/article/10.1007/s10846-011-9560-x>. Acesso em: 14 dez. 2017.

MCGONIGLE, A. J. S. *et al.* Unmanned aerial vehicle measurements of volcanic carbon dioxide fluxes. **Geophysical research letters**, v. 35, n. 6, 2008. Disponível em: <http://onlinelibrary.wiley.com/doi/10.1029/2007GL032508/full>. Acesso em: 12 dez. 2017.

NEBIKER, S. *et al.* A light-weight multispectral sensor for micro UAV- Opportunities for very high resolution airborne remote sensing. **The international archives of the photogrammetry, remote sensing and spatial information sciences**, v. 37, p. 1193-1200, 2008. Disponível em: http://www.isprs.org/proceedings/XXXVII/congress/1_pdf/204.pdf. Acesso em: 15 dez. 2017.

NHAMO, Luxon *et al.* Improving the Accuracy of Remotely Sensed Irrigated Areas Using Post-Classification Enhancement Through UAV Capability. **Remote Sensing**, v. 10, n. 5, p. 712, 2018. Disponível em: <https://www.mdpi.com/2072-4292/10/5/712> . Acesso em: 25 abr. 2018.

PATIAS, P.; SAATSOGLU-PALIADELI, C.; GEORGOULA, O.; PATERAKI, M.; STAMNAS, A.; KYRIAKOU, N. Photogrammetric documentation and digital representation of the Macedonian palace in Vergina-Aegeae. *In: CIPA, XXI International CIPA Symposium, Athens, Greece, 2007. Anais...* 2007. Disponível em: <http://www.isprs.org/proceedings/XXXVI/5-C53/papers/FP112.pdf>. Acesso em: 25 de out 2017.

PERUCH, Luiz Augusto Martins; MEDEIROS, André Martins; DE ALBUQUERQUE JUNIOR, Celso Lopes. Citric biomass and fungicides associated to leaf removal in Yellow Sigatoka disease control for banana “Prata”. **Journal of Agroveterinary Sciences**, v. 14, n. 3, p. 234-239, 2015. Disponível em: <http://200.19.105.203/index.php/agroveterinaria/article/view/223811711432015234> . Acesso em: 25 abr. 2018.

PIX4D. **TOOLS - GSD Calculator**. Disponível em: <https://support.pix4d.com/hc/en-us/articles/202560249-TOOLS-GSD-Calculator#gsc.tab=0>. Acesso em: 25 de out 2017.

PLOETZ, Randy C.; KEMA, Gert HJ; MA, Li-Jun. Impact of diseases on export and smallholder production of banana. **Annual Review of Phytopathology**, v. 53, p. 269-288, 2015. Disponível em: <https://www.annualreviews.org/doi/full/10.1146/annurev-phyto-080614-120305> . Acesso em: 25 abr. 2018.

POWELL, R. L.; MATZKE, N.; SOUZA Jr. C.; CLARK, M.; NUMATA, I.; HESS, L. L.; ROBERTS, D. A. Sources of error in accuracy assessment of thematic land-cover maps in the Brazilian Amazon. **Remote Sensing of Environment**, n. 90, p. 221-123. 2004. Disponível em: <https://www.sciencedirect.com/science/article/pii/S003442570300381X> . Acesso em: 25 abr. 2018.

PIX4DMAPPER, 2015. **Pix4Dmapper software manual**. Disponível em: <https://support.pix4d.com/hc/en-us/articles/202557969-Pix4Dmapper-Software-Manual-Table-View>. Acesso em: 20 dez. 2017.

PINHEIRO, A. C. M.; VILAS BOAS, E. V. B.; ALVES, A. P.; LA SELVA, M. Amadurecimento de bananas ‘maçã’ submetidas ao 1- meilciclopropeno (1-MCP). **Revista Brasileira de Fruticultura**. v. 29. n.1. p.1-4. 2007. Disponível em:

<http://www.scielo.br/pdf/0D/rbf/v29n1/a03v29n1.pdf> . Acesso em: 25 abr. 2018.

PIRES, Rillian Diello Lucas *et al.* Local descriptors for soybean disease recognition. **Computers and Electronics in Agriculture**, v. 125, p. 48-55, 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016816991630179X> . Acesso em: 25 abr. 2018.

PHADIKAR, Santanu; SIL, Jaya; DAS, Asit Kumar. Classification of Rice Leaf Diseases Based on Morphological Changes. **International Journal of Information and Electronics Engineering**, v. 2, n. 3, p. 460, 2012. Disponível em: <http://www.ijee.org/papers/137-I160.pdf> . Acesso em: 25 abr. 2018.

PURI, A.; VALAVANIS, K. P.; KONTITSIS, M. Statistical profile generation for traffic monitoring using real-time UAV based video data. *In: Control & Automation, 2007. MED'07. Mediterranean Conference on. IEEE, USA, Florida, 2007.* p. 1-6. Disponível em: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4433658&tag=1. Acesso em: 11 dez. 2017.

QI, La *et al.* Selection of optimum periods for extracting winter wheat based on multi-temporal remote sensing images. **Remote Sensing Technology and Application**, v. 23, n. 2, p. 154-160, 2008. Disponível em: http://en.cnki.com.cn/Article_en/CJFDTotol-YGJS200802005.htm . Acesso em: 25 abr. 2018.

QIAO, Hongbo *et al.* Identification of damage by diseases and insect pests in winter wheat. **Journal of Triticeae Crops**, v. 30, n. 4, p. 770-774, 2010. Disponível em: <https://www.cabdirect.org/cabdirect/abstract/20103331169>. Acesso em: 19 out. 2017.

QUAN, L. **Image-based modeling**. Springer Science & Business Media, 2010. Disponível em: https://books.google.com.br/books?hl=pt-BR&lr=&id=dQEWmHjma9sC&oi=fnd&pg=PR10&dq=QUAN,+L.+Image-based+modeling,+Springer+Science+%26+Business+Media,+2010.+&ots=WQ_Ao2kr1q&sig=_yXMWR5HSjpFb0j5Mi5UvyFPZMQ#v=onepage&q=QUAN%2C%20L.%20Image-based%20modeling.%20Springer%20Science%20%26%20Business%20Media%2C%202010.&f=false . Acesso em: 25 abr. 2018.

QUIRINO, Z. B. R., Talamini, V., da Silva Lédo, A., da Silva, A. V. C., da Silva Junior, J. F., & de Oliveira, F. D. O. A. (2014). Progresso da Sigatoka-amarela na cultivar Prata-anã em Sergipe. **Scientia Plena**, 10(10). Disponível em: <https://www.alice.cnptia.embrapa.br/bitstream/doc/998337/1/Viviane.pdf>. Acesso em: 25 abr. 2018.

REMONDINO, F. *et al.* UAV photogrammetry for mapping and 3d modeling—current status and future perspectives. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 38, n. 1, p. C22, 2011. Disponível em: <http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XXXVIII-1-C22/25/2011/isprsarchives-XXXVIII-1-C22-25-2011.pdf>. Acesso em: 15 dez. 2015.

RESTAS, A. Forest fire management supporting by UAV based air reconnaissance results of Szendro fire department, Hungary. *In: Environment Identities and Mediterranean Area, 2006. ISEIMA'06. First international Symposium on. IEEE, jul 2006.* p. 73-77. Disponível

em: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4150439. Acesso em: 13 dez. 2015.

ROBERTSON, D. P.; CIPOLLA, R. Structure from motion. Practical image processing and computer vision. **John Wiley, Hoboken**, NJ, USA, p. 49, 2009.

ROIG, H. L. *et al.* Uso de câmeras de baixo custo acopladas a veículos aéreos leves no estudo do aporte de sedimentos no Lago Paranoá. **Simpósio Brasileiro de Sensoriamento Remoto**, v. 16, p. 9332-9339, 2013. Disponível em: <http://www.dsr.inpe.br/sbsr2013/files/p1438.pdf>. Acesso em: 16 dez. 2015.

RUBIO, J. M. *et al.* Imap3d: low-cost photogrammetry for cultural heritage. *In: Proceedings of the CIPA 2005 XX International Symposium, Torino, Italy. Camera and Imaging Products Association*. Italy, Torino, 2005. Disponível em: https://www.researchgate.net/profile/Jose_Martinez-Rubio/publication. Acesso em: 12 dez. 2015.

RAMBO, José Roberto *et al.* Análise financeira e custo de produção de banana-maçã: um estudo de caso em Tangará da Serra, estado do Mato Grosso. **Informações Econômicas, São Paulo**, v. 45, n. 5, p. 29-39, 2015. Disponível em: <http://www.iea.sp.gov.br/ftp/iea/publicacoes/ie/2015/tec4-1015.pdf>. Acesso em: 25 abr. 2018.

RANGEL, A.; PENTEADO, L. A. C.; TONET, R. M. **Cultura da banana**. 2. ed. Campinas, SP: CATI, 2002, p. 91.

REN, Dong *et al.* Crop diseases and pests monitoring based on remote sensing: A survey. *In: World Automation Congress (WAC), 2012*. IEEE, 2012. p. 177-181. Disponível em: <https://ieeexplore.ieee.org/abstract/document/6321060/>. Acesso em: 25 abr. 2018.

ROBERTSON, D. P.; CIPOLLA, R. Structure from motion. Practical image processing and computer vision. **John Wiley, Hoboken**, NJ, USA, p. 49, 2009. Disponível em: https://www.researchgate.net/publication/277353684_3D_RECONSTRUCTION_OF_CULTURAL_TOURISM_ATTRACTIONS_FROM_INDOOR_TO_OUTDOOR_BASED_ON_PORTABLE_FOUR-CAMERA_STEREO_VISION_SYSTEM. Acesso em: 25 abr. 2018.

RAO, G. Anantha *et al.* Neural network classifier for continuous sign language recognition with selfie video. **Far East Journal of Electronics and Communications**, v. 17, n. 1, p. 49, 2017. Disponível em: https://www.researchgate.net/profile/D_Anil_Kumar/publication/314716032_Neural_network_classifier_for_continuous_sign_language_recognition_with_selfie_video/links/5abdbaf645851584fa6fc9af/Neural-network-classifier-for-continuous-sign-language-recognition-with-selfie-video.pdf. Acesso em: 25 abr. 2018.

REIDELSTUERZ, P.; LINK, J.; GRAEFF, S.; CLAUPEIN, W. Uav (unmanned aerial vehicles) für Präzisionslandwirtschaft. 13 Workshop Computer Bildanalyse in der Landwirtschaft & 4. Workshop Precision Farming, *In: Bornimer Agrartechnische Berichte. Anais...* 61, 75-84. 2007. Disponível em: <https://www.uni-hohenheim.de/en/organization/publication/uav-unmanned-aerial-vehicles-fuer-praezisionslandwirtschaft>. Acesso em: 20 de out de 2016.

ROCK, G.; RIES, J. B.; UDELHOVEN, T. Sensitivity Analysis of UAV Photogrammetry for Creating Digital Elevation Models (DEM). *In: International Archives of the Photogrammetry*,

Remote Sensing and Spatial Information Sciences, Zurich, Switzerland, 2011. **Anais...** v. XXXVIII-1/C22, p. 70 – 73, 2011. Disponível em: http://www.geometh.ethz.ch/uav_g/proceedings/rock . Acesso em: 25 de out 2016.

SHIMABUKURO, Yosio Edemir; MAEDA, Eduardo Eiji; FORMAGGIO, Antonio Roberto. Sensoriamento Remoto e Sistemas de Informações Geográficas aplicados ao estudo dos recursos agrônômicos e florestais. **Revista Seres**. 56(4): 399-409, 2009. Disponível em: <http://www.ceres.ufv.br/ojs/index.php/ceres/article/view/3443> . Acesso em: 25 abr. 2018.

STOVER, R. H. A peoposed international scale for estimating intensity of banana leaf spor (Mycosphaerella musicola). **Tropical Agriculture**, v. 48, 1971. P. 185 – 196. Disponível em: <https://www.cabdirect.org/cabdirect/abstract/19721101685> . Acesso em: 25 abr. 2018.

STOVER, R. H. **Banana, plantain and abaca disease**. Washington, USA, 1972. Disponível em: https://www.researchgate.net/publication/44440962_Banana_plantain_and_abaca_diseases_Robert_Harry_Stover . Acesso em: 25 abr. 2018.

SUGIURA, R., NOGUCHI, N.; ISHII, K. Remote-sensing Technology for Vegetation Monitoring using an Unmanned Helicopter. *In: Biosystems Engineering*, Nº 90, 4, 369–379, 2005. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1537511004002296> . Acesso em: 25 abr. 2018.

SHAHBAZI, M. *et al.* Development and Evaluation of a UAV-Photogrammetry System for Precise 3D Environmental Modeling. **Sensors**, v. 15, n. 11, p. 27493-27524, 2015. Disponível em: <http://www.mdpi.com/1424-8220/15/11/27493/htm>. Acesso em: 16 dez. 2015.

SIEBERT, S.; TEIZER, J.. Mobile 3D mapping for surveying earthwork projects using an Unmanned Aerial Vehicle (UAV) system. **Automation in Construction**, v. 41, p. 1-14, 2014. . Disponível em: <http://www.sciencedirect.com/science/article/pii/S0926580514000193>. Acesso em: 27 dez. 2015.

SZ DJI Technology Co., Ltd.

SILVA, M. C. A.; TARSITANO, M. A. A.; BOLIANI, A. C. Análises técnica econômica da cultura da bananeira ‘maçã’ (Musa spp.) na região noroeste do Estado de São Paulo. **Revista Brasileira de Fruticultura, Jaboticabal**, v. 27, n. 1, p. 139-42, abr. 2005. Disponível em: <http://www.scielo.br/pdf/%0D/rbf/v27n1/24586.pdf> . Acesso em: 25 abr. 2018.

SANKARAN, Sindhuja *et al.* A review of advanced techniques for detecting plant diseases. **Computers and Electronics in Agriculture**, v. 72, n. 1, p. 1-13, 2010. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169910000438> . Acesso em: 25 abr. 2018.

SINGH, Arti *et al.* Machine learning for high-throughput stress phenotyping in plants. **Trends in plant science**, v. 21, n. 2, p. 110-124, 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1360138515002630> . Acesso em: 25 abr. 2018.

SHRIVASTAVA, Sourabh; HOODA, Dhara Singh. Automatic brown spot and frog eye

detection from the image captured in the field. **American Journal of Intelligent Systems**, v. 4, n. 4, p. 131-134, 2014. Disponível em: <http://123project.ir/wp-content/uploads/2017/07/11.pdf> . Acesso em: 25 abr. 2018.

SINGH, Vijai; MISRA, A. K. Detection of plant leaf diseases using image segmentation and soft computing techniques. **Information Processing in Agriculture**, v. 4, n. 1, p. 41-49, 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214317316300154> . Acesso em: 25 abr. 2018.

THOMSON, S. J. *et al.* Potential for remote sensing from agricultural aircraft using digital video. **Applied Engineering in Agriculture**, v. 21, n. 3, p. 531-537, 2005. Disponível em: <https://elibrary.asabe.org/abstract.asp?aid=18445>. Acesso em: 25 abr. 2018.

TETILA, Everton Castelhão *et al.* Identification of Soybean Foliar Diseases Using Unmanned Aerial Vehicle Images. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 12, p. 2190-2194, 2017.

TRIMBLE R4. **Model 3 gns receiver**. Version 4.80. Revision A. 2013. Disponível em: <https://www.manualslib.com/manual/828648/Trimble-Trimble-R8.html#manual>. Acesso em: 25 de out 2017.

VALAVANIS, K. P. (Ed.). **Advances in unmanned aerial vehicles: state of the art and the road to autonomy**. Springer Science & Business Media, 2008. Disponível em: <https://books.google.com.br/books?hl=ptBR&lr=&id=EsjPyblwMdQC&oi=fnd&pg=PR11&dq=VALAVANIS,+Kimon+P.+%28Ed.%29.+Advances+in+unmanned+aerial+vehicles:+state+of+the+art+and+the+road+to+autonomy.+Springer+Science+%26+Business+Media,+2008.&ots=EPoK3avIsD&sig=Dt6if4A1VrNT5QMInYLOMCQ8w0#v=onepage&q=VALAVANIS%2C%20Kimon%20P.%20%28Ed.%29.%20Advances%20in%20unmanned%20aerial%20vehicles%3A%20state%20of%20the%20art%20and%20the%20road%20to%20autonomy.%20Springer%20Science%20%26%20Business%20Media%2C%202008.&f=false>. Acesso em: 20 dez. 2017.

WANG, Limin *et al.* Remote sensing index selection of leaf blight disease in spring maize based on hyperspectral data. **Transactions of the Chinese Society of Agricultural Engineering**, v. 33, n. 5, p. 170-177, 2017. Disponível em: <https://www.ingentaconnect.com/content/tcsae/tcsae/2017/00000033/00000005/art00025> . Acesso em: 25 abr. 2018.

YUAN, Huanhuan *et al.* Retrieving soybean leaf area index from unmanned aerial vehicle hyperspectral remote sensing: Analysis of RF, ANN, and SVM regression models. **Remote Sensing**, v. 9, n. 4, p. 309, 2017. Disponível em: <https://www.mdpi.com/2072-4292/9/4/309> . Acesso em: 25 abr. 2018.

ZARCO-TEJADA, P. J. *et al.* Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. **European journal of agronomy**, v. 55, p. 89-99, 2014. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1161030114000069>. Acesso em: 18 dez. 2015.

ZHANG, J. *et al.* New reflectance spectral vegetation indices for estimating rice nitrogen nutrition iii: development of a new vegetation index based on canopy red-edge reflectance

spectra to monitor rice canopy leaf nitrogen concentration. **Sensor Letters**, v. 9, n. 3, p. 1201-1206, 2011. Disponível em:
<http://www.ingentaconnect.com/content/asp/senlet/2011/00000009/00000003/art00041>.
Acesso em: 19 dez. 2015.

ZHANG, Yan-Cheng *et al.* Features selection of cotton disease leaves image based on fuzzy feature selection techniques. *In: Wavelet Analysis and Pattern Recognition, 2007. ICWAPR'07. International Conference on.* IEEE, 2007. p. 124-129. Disponível em:
<https://ieeexplore.ieee.org/abstract/document/4420649> . Acesso em: 20 fev. 2018.

ZHOU, Rong *et al.* Disease detection of Cercospora Leaf Spot in sugar beet by robust template matching. **Computers and electronics in agriculture**, v. 108, p. 58-70, 2014. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169914001768> . Acesso em: 25 abr. 2018.

ZARCO-TEJADA, P. J.; GONZÁLEZ-DUGO, V.; BERNI, J. AJ. Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. **Remote Sensing of Environment**, v. 117, p. 322-337, 2012. Disponível em:
<http://www.sciencedirect.com/science/article/pii/S0034425711003555>. Acesso em: 15 dez. 2015.

ZARCO-TEJADA, P. J.; DIAZ-VARELA, R.; ANGILERI, V.; & LOUDJANI, P. Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. **European journal of agronomy**, v. 55, p. 89-99, 2014. Disponível em:
<http://www.sciencedirect.com/science/article/pii/S1161030114000069>. Acesso em: 18 dez. 2015.