Uso de assinaturas espectrais e veículos aéreos não tripulados para o diagnóstico automático de doenças de eucaliptos

Arthur Avelar Chaves

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Arthur Avelar Chaves

Uso de assinaturas espectrais e veículos aéreos não tripulados para o diagnóstico automático de doenças de eucaliptos

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Mestre em Ciências – Ciências de Computação e Matemática Computacional. *VERSÃO REVISADA*

Área de Concentração: Ciências de Computação e Matemática Computacional

Orientadora: Profa. Dra. Kalinka Regina Lucas Jaquie Castelo Branco

Coorientadora: Profa. Dra. Cristina Dutra de Aguiar Ciferri

USP – São Carlos
Abril de 2017

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados fornecidos pelo(a) autor(a)

C512u Chaves, Arthur Avelar
 Uso de assinaturas espectrais e veículos
 aéreos não tripulados para o diagnóstico
 automático de doenças de eucaliptos / Arthur
 Avelar Chaves; orientadora Kalinka Regina Lucas
 Jaquie Castelo Branco; coorientadora Cristina Dutra
 de Aguiar Ciferri. - São Carlos - SP, 2017.
 94 p.

 Dissertação (Mestrado - Programa de Pós-Graduação
 em Ciências de Computação e Matemática Computacional)
 - Instituto de Ciências Matemáticas e de Computação,
 Universidade de São Paulo, 2017.

 1. VANTs. 2. ADDSIGN. 3. Diagnóstico.
 4. Patologias. 5. Eucalipto. I. Branco, Kalinka
 Regina Lucas Jaquie Castelo, orient. II. Ciferri,
 Cristina Dutra de Aguiar, coorient. III. Título.

Arthur Avelar Chaves

Using spectral signatures and unmanned aerial vehicles to
automatically diagnose eucalyptus diseases

Master dissertation submitted to the Instituto de
Ciências Matemáticas e de Computação – ICMC-
USP, in partial fulfillment of the requirements for the
degree of the Master Program in Computer Science
and Computational Mathematics. *FINAL VERSION*

Concentration Area: Computer Science and
Computational Mathematics

Advisor: Profa. Dra. Kalinka Regina Lucas Jaquie
Castelo Branco

Co-advisor: Profa. Dra. Cristina Dutra de
Aguiar Ciferri

USP – São Carlos
April 2017

AGRADECIMENTOS

Agradeço à minha família, por sempre estar ao meu lado, por toda a educação, investimento, conselhos, amor e carinho que me foram dados ao longo da vida.

À professora Kalinka, pelo apoio, confiança, conselhos, motivação e por sua orientação ao longo de todo o desenvolvimento deste trabalho.

Aos colegas do LSEC, pelo ambiente de trabalho agradável e por estarem sempre dispostos a ajudar e contribuir.

Ao professor Edson, pela ajuda com os trabalhos em campo.

À Embrapa Instrumentação, por contribuir com o uso dos equipamentos

Ao CNPq, pela bolsa de estudos.

Por fim, agradeço a todas as pessoas que contribuíram direta ou indiretamente com o desenvolvimento deste projeto.

RESUMO

CHAVES, A. A. Uso de assinaturas espectrais e veículos aéreos não tripulados para o diagnóstico automático de doenças de eucaliptos. 2017. 94 p. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2017.

Apresentando um papel de destaque no cenário nacional e internacional, o eucalipto possui rápido crescimento, alta produtividade, ampla diversidade de espécies, grande capacidade de adaptação e é aplicado em diferentes processos industriais, como por exemplo, produção de madeira, celulose e papel. No Brasil existem extensas áreas plantadas, principalmente nos estados de Minas Gerais, São Paulo e Paraná. Entretanto, eucaliptos são suscetíveis a doenças e pragas, o que pode trazer grandes prejuízos aos produtores. Tendo em vista esse contexto, surge a necessidade de detectar e diagnosticar doenças prematuramente, permitindo um combate mais eficaz e preciso a essas patologias. Visto que as plantações de eucalipto cobrem áreas muito extensas, o uso de VANTs (Veículos Aéreos Não-Tripulados) pode agilizar o processo de monitoramento, uma vez que podem sobrevoar grandes distâncias em pouco tempo. Sendo assim, esse trabalho desenvolveu um sistema de diagnóstico automático de doenças de eucalipto. Baseando-se em técnicas de detecção de ataques digitais, o diagnóstico é feito comparando assinaturas espectrais de plantas doentes com assinaturas conhecidas armazenadas em uma base de dados seguindo um modelo de assinaturas espectrais inspirado em um modelo de assinaturas de ataque. O sistema foi desenvolvido e validado utilizando dados de espectroradiômetros, apresentando precisão de até 96% em alguns casos.

Palavras-chave: VANTs, ADDSIGN, Diagnóstico, Patologias, Eucalipto.

ABSTRACT

CHAVES, A. A. Using spectral signatures and unmanned aerial vehicles to automatically diagnose eucalyptus diseases. 2017. 94 p. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2017.

Eucalyptus has played an important economic roll worldwide. It has rapid growth, high yield, wide species diversity, great adaptability and it is used in different industrial processes such as cellulose and paper production. However, Eucalyptus is susceptible to diseases and plagues, which could bring heavy damage to the plantations. In view of the importance of the production of Eucalyptus, the dimensions of the planted areas and of the possibility to increase yield, there is a need to detect and identify the pathologies affecting the trees. Since Eucalyptus plantations can cover a very extensive area, the use of UAVs (Unmanned Aerial Vehicles) can drastically speed up the process of monitoring the crop, as they can survey very large areas in very little time. Thus, this project aims to develop a system that automatically diagnoses eucalyptus diseases. Using techniques of digital intrusion detection, the diagnostic is made by comparing the spectral signature of diseased plants with known signatures stored on a database following a signature model also proposed in this project. The system was developed and validated by using data from spectroradiometers, showing a accuracies as high as 96% in some cases.

Keywords: UAVs, ADDSIGN, Diagnose, Pathologies, Eucalyptus.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de regra escrita no Snort para identificação de assinaturas	28
Figura 2 – IDMEF	29
Figura 3 – Comparação entre um caule sadio e um caule infectado com Murcha de <i>Ceratocystis</i>	36
Figura 4 – Dano causado pela murcha de <i>Ceratocystis</i> nas folhas das árvores.	36
Figura 5 – Dano causado pela seca de ponteiros em um eucalipto jovem.	38
Figura 6 – Dano causado pela ferrugem em uma folha de eucalipto	39
Figura 7 – Espectro eletromagnético	39
Figura 8 – Assinatura espectral de coníferas, solo e água	40
Figura 9 – Reflectância de folhas de trigo saudáveis e doentes	41
Figura 10 – Assinaturas espectrais de diferentes doenças em folhas de beterraba	41
Figura 11 – Aeronave eBee	50
Figura 12 – Processo de diagnóstico de doenças	52
Figura 13 – Arquitetura do ADDSIGN	57
Figura 14 – Planejamento de missão para aquisição de imagens de Ferrugem em Itatinga-SP.	61
Figura 15 – Sistema para medir a reflectância de uma folha em laboratório	61
Figura 16 – Mosaicos de uma plantação de eucaliptos em Lençóis Paulista em NIR e a representação em pseudo-cores do NDVI.	63
Figura 17 – Algoritmo de quantificação de áreas de solo, baixa biomassa e alta biomassa	64
Figura 18 – Área de estudo, NDVI em escala de cinza e NDVI em pseudo-cores	65
Figura 19 – Resultado do fatiamento das cores para (a) solo, (b) baixa biomassa e (c) alta biomassa, ambos com a utilização do filtro de mediana.	65
Figura 20 – Primeiro estágio do método de contagem, onde as árvores são separadas umas das outras.	67
Figura 21 – Segundo estágio do método de contagem, onde é feita uma estimativa da quantidade de árvores em um agrupamento.	67
Figura 22 – (a) Imagem original contendo os canais verde, vermelho e NIR; (b) Posição das árvores marcadas; (c) Posição das árvores marcadas vistas na imagem original.	68
Figura 23 – Resultados da conversão em reflectância usando LLS	69
Figura 24 – Resultados da conversão em reflectância usando LSS	69
Figura 25 – Resultados da conversão de regiões da imagem em reflectância usando LSS	70
Figura 26 – Artigos encontrados nas bases de dados.	93

Figura 27 – Artigos aceitos após a primeira seleção. 94

Figura 28 – Quantidade de artigos aceitos em cada base após a seleção final 94

LISTA DE TABELAS

Tabela 1 – Taxonomia dos princípios de detecção de intrusão.	26
Tabela 2 – Mensagem de Alerta do IDMEF	30
Tabela 3 – AISF - Módulo de identificação da assinatura	30
Tabela 4 – AISF - Módulo de informação sobre a assinatura	30
Tabela 5 – AISF - Módulo de informação sobre o payload	31
Tabela 6 – Exemplo de equalização da assinatura espectral	53
Tabela 7 – Módulo de identificação da assinatura	54
Tabela 8 – Módulo de informações sobre a assinatura	55
Tabela 9 – Módulo de informações sobre o patógeno	55
Tabela 10 – Módulo de informações espectrais	56
Tabela 11 – Experimentos realizados	60
Tabela 12 – Número de amostras de assinatura espectral obtidas para a realização do experimento	62
Tabela 13 – Resultado da contagem de píxeis obtidos pelo algoritmo empregado e a conversão em unidades de medida m^2 e ha por classe.	66
Tabela 14 – Porcentagem de verdadeiros positivos obtidos por cada um dos algoritmos de classificação utilizados.	71

LISTA DE ABREVIATURAS E SIGLAS

ADDSIGN	Automatic Disease Diagnostic SIGNature
AISF	ACME Intrusion Signature Format
ANAC	Agência Nacional de Aviação Civil
HSV	Hue, Saturation, Value
IBÁ	Indústria Brasileira de Árvores
IDMEF	Intrusion Detection Message Exchange Format
IDS	Intrusion Detection System
JSON	JavaScript Object Notation
LAI	Leaf Area Index
LLS	Least Slope Squared
LLS	Linear Least Squares
NDVI	Normalized Difference Vegetation Index
NGRDI	Normalized Green-Red Difference Index
NIR	Near Infrared
PRI	Photochemical Reflectance Index
RGB	Red, Green, Blue
SAM	Spectral Angle Mapper
SCM	Spectral Correlation Mapper
StArt	State of the Art through Systematic Review
UAVs	Unmanned Aerial Vehicles
VANTs	Veículos Aéreos Não-Tripulados
XML	eXtensible Markup Language

SUMÁRIO

1	INTRODUÇÃO	21
1.1	Contextualização	21
1.2	Motivação e caracterização do problema	22
1.3	Objetivos	24
1.4	Estrutura do texto	24
2	SISTEMAS DE DETECÇÃO DE INTRUSÃO	25
2.1	Considerações iniciais	25
2.2	Definições e conceitos	25
2.2.1	Sistemas baseados em anomalias	26
2.2.2	Sistemas baseados em assinaturas	27
2.2.3	Sistemas inspirados em assinaturas	27
2.3	Assinaturas de ataque	27
2.3.1	Identificação e descrição de assinaturas de ataque	28
2.3.1.1	XML vs. JSON	31
2.3.1.2	Armazenamento das assinaturas	32
2.4	Considerações finais	33
3	PATOLOGIAS DE EUCALIPTO E ASSINATURAS ESPECTRAIS	35
3.1	Considerações iniciais	35
3.2	Doenças e pragas de eucalipto	35
3.2.1	Murcha de Ceratocystis	35
3.2.2	Seca de Ponteiros	37
3.2.3	Ferrugem	37
3.3	Espectro eletromagnético e assinaturas espectrais	39
3.4	Considerações finais	42
4	USO DE VANTS NA DETECÇÃO DE DOENÇAS EM PLANTAÇÕES	43
4.1	Considerações iniciais	43
4.2	Trabalhos relacionados	43
4.3	Considerações finais	47
5	ADDSIGN - AUTOMATIC DISEASE DIAGNOSTIC SIGNATURE	49
5.1	Considerações iniciais	49

5.2	Assinaturas espectrais vs. Assinaturas de ataque	49
5.3	Uso de VANTs e aquisição de dados	50
5.4	Diagnóstico automático de doenças	51
5.4.1	Normalização e equalização de curvas espectrais	51
5.4.2	Algoritmos de classificação	52
5.4.2.1	Naive	53
5.4.2.2	Distância Euclidiana	53
5.4.2.3	Distância Manhattan	53
5.4.2.4	SAM	53
5.4.2.5	SCM	54
5.4.3	Modelagem das assinaturas de doenças	54
5.5	Arquitetura do ADDSIGN	56
5.6	Considerações Finais	56
6	EXPERIMENTOS REALIZADOS E RESULTADOS OBTIDOS	59
6.1	Considerações Iniciais	59
6.2	Definição dos experimentos	59
6.3	Aquisição dos dados	59
6.4	Tratamento de Imagens	61
6.4.0.1	NDVI	62
6.4.0.2	Segmentação de solo e quantificação de áreas	63
6.4.1	Localização e contagem de eucaliptos	66
6.5	Extração das assinaturas espectrais	68
6.6	Resultados Obtidos	70
6.7	Considerações Finais	71
7	CONCLUSÃO	73
7.1	Dificuldades Encontradas	74
7.2	Contribuições	74
7.3	Produção intelectual	75
7.3.1	Publicações	75
7.3.2	Participações em eventos	76
7.4	Sugestões de trabalhos futuros	76
REFERÊNCIAS		79
APÊNDICE A REVISÃO SISTEMÁTICA		89
A.1	Planejamento	89
A.1.1	Objetivos	89
A.1.2	Questões	89

A.1.3	Seleção das fontes	90
A.1.4	Seleção dos estudos	90
A.1.4.1	Palavras-chave	90
A.1.4.2	Critérios de inclusão	91
A.1.4.3	Critérios de exclusão	91
A.1.4.4	Procedimentos para selecionar os estudos	91
A.2	Execução	92
A.2.1	Construção das strings de busca	92
A.2.2	Resultados das buscas	93

INTRODUÇÃO

1.1 Contextualização

Um sistema de detecção de intrusão (*Intrusion Detection System* (IDS)) é um dispositivo ou um software que monitora as atividades de redes e/ou sistemas em busca de atividades maliciosas ou violações de políticas e produz relatórios dos resultados encontrados ([SCARFONE; MELL, 2007](#)). Segundo [Rehman \(2003\)](#), uma das principais categorias de IDSs são os baseados em assinatura, que realizam a detecção de ataques reconhecendo determinados padrões pré-definidos, ou seja, analisando a assinatura do ataque e comparando com assinaturas presentes em uma base de dados.

Por sua vez, agentes patogênicos, causadores de pragas e doenças em plantas, podem ser quantificados por métodos diretos, como por meio de avaliação dos sintomas e sinais, a incidência e a severidade, ou por métodos indiretos, como a determinação da população do patógeno, sua distribuição espacial, seus efeitos na produção (dano e/ou perda) e a desfolha causada. Alguns métodos não exigem o contato com as plantas doentes como, por exemplo, o sensoriamento remoto baseado em imagens aéreas. A quantificação da doença pode ser feita em diversos comprimentos de onda, dentre os quais se destaca o infravermelho próximo (NIR) ([MORAES, 2007](#)).

Diversas pesquisas ([REID; RAMOS; SUKKARIEH, 2011](#); [HUNG; SUKKARIEH, 2011](#); [GHIASI; AMIRFATTAHI, 2013](#); [MORANDUZZO; MELGANI, 2014](#); [DIAZ-VARELA et al., 2014](#)) têm mostrado que o uso do sensoriamento remoto, como anteriormente mencionado, permite obter informações de forma eficiente, assemelhando-se ao levantamento efetuado diretamente em campo. Entretanto, com o sensoriamento remoto tem-se a possibilidade de obter amostras de áreas mais rapidamente. Uma das vantagens do sensoriamento remoto na agricultura é a capacidade de mapeamento de grandes áreas em curtos espaços de tempo. Outra vantagem é a possibilidade de uma visão aérea da cultura, que pode revelar detalhes não observáveis pela

visão no nível do solo.

O sensoriamento remoto consiste na “utilização conjunta de sensores, equipamentos, aeronaves, espaçonaves entre outros, com objetivo de estudar o ambiente terrestre por meio do registro e da análise das interações entre a radiação eletromagnética e as substâncias componentes do planeta Terra em suas mais diversas manifestações” (NOVO, 1989). No caso de monitoramento de áreas de vegetação, as curvas de reflectância, também chamadas de assinaturas espectrais, podem ser obtidas por meio de sensoriamento remoto e utilizadas de forma eficiente para identificar e mapear a incidência de um número grande de patógenos de plantas.

Os sensores utilizados para o sensoriamento remoto, como por exemplo, câmeras, espectrômetros e radiômetros, podem ser considerados multiespectrais, que fazem medições nos canais Red, Green, Blue (RGB) e Near Infrared (NIR), ou hiperespectrais, que fazem medições com maior resolução radiométrica e abrangem mais canais, como ultravioleta e ondas de rádio. O sensoriamento remoto é uma ferramenta que pode ser utilizada para detectar plantas doentes de forma rápida e eficiente em pequenas e grandes áreas (NAUE et al., 2010).

Tendo em vista que patologias em plantas podem ser identificadas por meio de sua assinatura espectral, isto é, cada patologia possui um padrão pré-definido, pode-se fazer uma analogia entre assinaturas espectrais e assinaturas de ataque, e assim aplicar técnicas de IDSs baseados em assinaturas para realizar o diagnóstico de doenças em plantas a partir de imagens obtidas por meio de sensoriamento remoto.

Neste trabalho, para a obtenção das assinaturas espectrais será empregado o uso de Veículos Aéreos Não-Tripulados (VANTs) ou Unmanned Aerial Vehicles (UAVs)¹, uma vez que acredita-se que nos próximos 10 anos, VANTs devem popular uma boa parte do espaço aéreo para a realização de diferentes missões, desde agrícolas passando por inspeção de fronteiras e chegando até ao monitoramento para garantir maior segurança (BRANCO, 2012).

1.2 Motivação e caracterização do problema

O eucalipto foi introduzido no Brasil em 1904 com o objetivo de suprir as necessidades de lenha, postes e dormentes das estradas de ferro na região Sudeste. Na década de 50 passou a ser produzido como matéria prima para o abastecimento das fábricas de papel e celulose. Apresenta-se como uma espécie vegetal de crescimento rápido e adaptado para as situações bioclimáticas brasileira. O marco da silvicultura brasileira se deu durante o período dos incentivos fiscais, na década de 60. Esses incentivos perduraram até meados dos anos 80. A partir do término dos incentivos fiscais houve um crescimento marginal negativo no plantio de eucaliptos. Exceção

¹ “Veículos aéreos que não carregam operador humano, utilizam forças aerodinâmicas para se elevar, podem voar autonomamente ou pilotados remotamente, podem ser descartáveis ou recuperáveis e podem transportar cargas bélicas ou não bélicas. Excluem-se desta definição, veículos balísticos e semi-balísticos como mísseis de cruzeiro, e projéteis.” (DOD, 2002).

disso ocorreu naqueles feitos independentes dos investimentos das indústrias de papel e celulose, siderúrgicas e carvão vegetal (DOSSA et al., 2002).

As plantações florestais brasileiras apresentam um destaque fundamental no cenário nacional e internacional. Segundo a Indústria Brasileira de Árvores (IBÁ), a área ocupada pelas florestas plantadas no Brasil de pinus e eucalipto totalizaram 7,8 milhões de hectares em 2015, sendo que 5,8 milhões de hectares correspondem a áreas de plantio de eucalipto e 1,6 milhão de hectares correspondem a plantios de pinus (IBÁ, 2016).

O gênero *Eucaliptus* pertence à família *Myrtaceae*, com cerca de 650 espécies, apresenta uma ampla dispersão mundial, crescendo satisfatoriamente em diferentes situações edafoclimáticas, extrapolando àquelas das regiões de origem (SANTOS; AUER; JÚNIOR, 2001). Possui como centro de origem a Austrália e regiões próximas como Timor, Indonésia, Papua Nova Guiné e sul das Filipinas (ELDRIDGE; DAVIDSON; HARWOOD, 1994).

Diversas doenças podem ocorrer em todas as fases do desenvolvimento do eucalipto e podem atacar e matar a maioria das culturas em vários locais e épocas do ano. Dadas as grandes áreas de plantio de eucalipto, faz-se necessário o conhecimento e o controle dessas doenças e pragas com objetivo de minimizar perdas financeiras.

Doenças e pragas causam grandes prejuízos em plantações de diversas espécies. Uma das maneiras mais simples de lidar com esse problema é o uso de agrotóxicos em toda a lavoura. Entretanto, o uso desenfreado dessas substâncias pode contaminar rios, lagos e lençóis freáticos, além de trazer possíveis riscos à saúde do ser humano e da fauna local. Portanto, surge a necessidade de se detectar as plantas infectadas e aplicar o tratamento somente nas mesmas, sem que o resto da produção seja afetada. Além disso, é interessante identificar qual é a doença ou praga, permitindo que seja feito o controle adequado do patógeno, sem a necessidade de se ter um especialista em campo.

O uso de VANTs permite uma identificação mais eficaz das árvores infectadas, visto que, quando comparados com satélites, possuem um custo menor e as imagens podem ser obtidas a qualquer momento e ainda possuem alta resolução espacial. Por outro lado, a escolha do uso de VANTs e não somente métodos terrestres reside no fato das plantações serem extensas. Uma pessoa andando a 2km/h durante 8 horas por dia só consegue fazer amostragem em 1000 hectares. O uso de maquinários muitas vezes é impeditivo por causa dos corredores entre as plantas serem pequenos e devido ao risco de danos à lavoura.

Sendo assim, é possível vislumbrar:

- **Problema:** Existe uma maneira fazendo uso de VANTs de permitir uma melhor detecção de patologias em plantações de eucalipto?
- **Hipótese:** Com o uso de técnicas semelhantes às de IDSs será possível efetuar a detecção de patologias em plantações de eucaliptos de forma mais eficiente que o método tradicional

com significativa acurácia.

1.3 Objetivos

Tendo em vista o cenário descrito, este trabalho tem como objetivo desenvolver um método de detecção e diagnóstico de patologias em plantas. Tendo como estudo de caso o eucalipto, são consideradas *a priori* as patologias Seca de Ponteiro, Ferrugem e Murcha de *Ceratocystis*, visto que são as patologias mais comumente encontradas nestas plantações e podem causar danos severos.

Mais especificamente, é desenvolvido um sistema que extrai assinaturas espectrais de plantas em imagens obtidas por um VANT e as compara com assinaturas conhecidas de plantas doentes presentes em uma base de dados construída a partir de um modelo padronizado de assinaturas, de modo que se tenha uma interface padrão para o acesso aos dados das assinaturas.

1.4 Estrutura do texto

Este texto está estruturado da seguinte maneira: o Capítulo 2 apresenta os conceitos de sistemas de detecção de intrusão e de assinaturas de ataque. O Capítulo 3 apresenta uma revisão sobre as principais doenças de eucalipto e sobre assinaturas espectrais. Estes dois capítulos são necessários para o entendimento do cenário de aplicação do trabalho. O Capítulo 4 apresenta uma revisão sistemática da literatura sobre o uso de VANTs na agricultura, mais especificamente na detecção de doenças. O Capítulo 5 apresenta em detalhes o sistema desenvolvido neste trabalho. O Capítulo 6 apresenta os resultados obtidos. Por fim, o Capítulo 7 apresenta a conclusão do trabalho, sugestões de trabalhos futuros e a produção intelectual.

SISTEMAS DE DETECÇÃO DE INTRUSÃO

2.1 Considerações iniciais

Este capítulo apresenta conceitos de sistemas de detecção de intrusão, mais especificamente, apresenta as definições fundamentais relacionadas a esse tema. Além disso, é discutido o tópico assinaturas de ataque, como descrevê-las de forma padronizada e como identificá-las. Por fim é apresentada uma comparação entre o **eXtensible Markup Language** (XML) e o **JavaScript Object Notation** (JSON), dois formatos muito utilizados na computação para trocar dados de forma padronizada. Por fim, é apresentada uma breve introdução sobre bases de dados não-relacionais. A necessidade deste capítulo se deve à natureza deste trabalho que é multidisciplinar.

2.2 Definições e conceitos

Intrusão é definida como qualquer conjunto de ações que tentam comprometer a integridade, confidencialidade ou disponibilidade de um recurso computacional. Por sua vez, o ato de detectar estas ações é definido como detecção de intrusão ([ZAMBONI, 2001](#)). Já um sistema de detecção de intrusão (IDS - **Intrusion Detection System**) é um dispositivo ou um software que monitora as atividades de redes e/ou sistemas em busca de atividades maliciosas ou violações de políticas e produz relatórios dos resultados encontrados ([SCARFONE; MELL, 2007](#)). Existem diversos IDSs disponíveis no mercado, como por exemplo o Snort ([CISCO, 2014](#)), OSSEC ([HARGRAVE, 2013](#)), ACARM-ng ([WCSS, 2010](#)), AIDE ([LEHTI; HABER; BERG, 2013](#)) e Samhain ([WICHMANN, 2011](#)).

Segundo [Rehman \(2003\)](#), os IDSs são divididos em duas categorias básicas: baseados em assinatura, que realizam a classificação reconhecendo determinados padrões pré-definidos, e baseados em anomalia, que fazem a classificação baseando-se em variações no funcionamento

normal do sistema. Já [Axelsson \(2000\)](#) define uma terceira categoria: sistemas inspirados em assinaturas, que fazem a classificação baseando-se tanto no reconhecimento de assinaturas quanto na detecção de anomalias. Na Tabela 1 são apresentados os elementos da taxonomia de IDSs proposta por [Axelsson \(2000\)](#).

Tabela 1 – Taxonomia dos princípios de detecção de intrusão.

Categoria	Tomada de decisão	
	Adaptativo	Séries temporais
Baseado em Anomalias	Programado	Estatística descritiva
		“Default Deny”
Baseado em Assinaturas	Programado	Modelagem de estados
		Sistemas especialistas
		Casamento de strings
Inspirado em Assinaturas	Adaptativo	Seleção e extração de características

Fonte: Adaptado de [Axelsson \(2000\)](#)

Neste trabalho é utilizado um IDS para identificar doenças de eucaliptos a partir de assinaturas espectrais, as quais são utilizadas para caracterizar uma determinada doença e são apresentadas com mais detalhes na Seção 3.3. Sendo assim, optou-se por utilizar um sistema baseado em assinaturas cuja tomada de decisão é feita de forma especializada, ou seja, um sistema especialista.

2.2.1 Sistemas baseados em anomalias

Os IDSs baseados em anomalias monitoram o comportamento do sistema e se houver alguma variação do funcionamento normal, como um aumento significativo no número de conexões de rede ou na quantidade de comandos executados, significa que provavelmente está ocorrendo alguma atividade intrusiva e que merece ser investigada ([REHMAN, 2003](#)).

Esses sistemas podem ter um mecanismo de tomada de decisão adaptativo ou programado. Sistemas adaptativos utilizam séries temporais e algoritmos de aprendizado de máquina para analisar o comportamento do sistema ao longo de um certo tempo e constroem modelos de comportamentos normais e anômalos que são atualizados com o passar do tempo ([AXELSSON, 2000](#)).

Por outro lado, um mecanismo de tomada de decisão programado, ou estático, precisa que algum usuário defina modelos de comportamento anômalo, como por exemplo definir um número máximo de tentativas de login ou de conexões de rede. Uma outra opção é a abordagem “default deny”, na qual consiste em explicitar as ações permitidas por determinado usuário ou sistema e tratar qualquer variação como uma atividade intrusiva ([AXELSSON, 2000](#)).

2.2.2 Sistemas baseados em assinaturas

Em IDSs baseados em assinaturas, a identificação de ataques é feita baseando-se em modelos pré-definidos do comportamento de vírus ou intrusões. Também chamados de assinaturas de ataque, esses modelos definem padrões, como por exemplo, uma sequência de instruções ou o conteúdo de determinados pacotes de rede que caracterizam um determinado vírus ou tipo de ataque (AXELSSON, 2000; REHMAN, 2003).

Nesse tipo de IDS a tomada de decisão é programada, isto é, as assinaturas são pré-definidas por um usuário e não são atualizadas automaticamente. A identificação de assinaturas pode ser feita de diversas maneiras, dependendo do formato no qual a assinatura foi descrita. Dentre as opções tem-se (AXELSSON, 2000):

- **Modelagem por estados:** a intrusão é definida como uma sequência de estados e transições de um autômato, uma máquina de estado ou uma rede de Petri;
- **Sistemas especialistas:** a intrusão é definida por meio de regras que são fornecidas a um sistema especialista que faz a tomada de decisão.
- **Casamento de strings:** o casamento de strings consiste em buscar substrings de caracteres em textos transmitidos entre sistemas, como por exemplo o conteúdo de pacotes de rede.

2.2.3 Sistemas inspirados em assinaturas

Sistemas inspirados em assinaturas realizam a tomada de decisão baseando-se tanto em anomalias quanto em assinaturas. Esse tipo de IDS detecta a intrusão dado um comportamento normal do sistema, enquanto um sistema baseado em assinaturas não utiliza nenhuma informação do comportamento normal do sistema e um sistema baseado em anomalias não possui nenhuma informação específica sobre os ataques (AXELSSON, 2000).

O mecanismo de tomada de decisão de IDSs inspirados em assinaturas é adaptativo. O IDS aprende automaticamente o que constitui comportamentos normais e intrusivos a partir de características extraídas do próprio sistema que está sendo monitorado (AXELSSON, 2000).

2.3 Assinaturas de ataque

Uma assinatura de ataque é um arranjo único de informação que pode ser usado para identificar uma tentativa de explorar a vulnerabilidade de um sistema operacional ou aplicação (SYMANTEC, 2014). Pode ser uma porção de código, um padrão de comportamento, uma sequência de chamadas ao sistema ou um determinado conjunto de pacotes. Uma boa assinatura deve ser suficientemente restrita para capturar precisamente os aspectos característicos do ataque e, ao mesmo tempo, deve ser flexível o suficiente para capturar variações do ataque. Sendo assim,

assinaturas ruins podem ocasionar em um alto número de falsos positivos ou falsos negativos (DAGDEE; THAKAR, 2008).

Na Figura 1 é ilustrada uma assinatura escrita no IDS Snort. Ela tem como objetivo emitir um alerta se houver a presença de “root.exe” em uma requisição HTTP para uma máquina na porta TCP 80. Mais especificamente, permite a detecção da propagação do Code Red, um worm que explora vulnerabilidades de servidores Microsoft IIS para se propagar e lançar ataques de negação de serviço distribuída contra um determinado alvo (DANYLIW; HOUSEHOLDER, 2002; MORIN; Mé, 2007).

Figura 1 – Exemplo de regra escrita no Snort para identificação de assinaturas

```
alert tcp $EXTERNAL_NET any -> $HTTP_SERVERS $HTTP_PORTS
(msg: "WEB-IIS CodeRed v2 root.exe access";
 flow:to_server,established; uricontent: "/root.exe"; nocase;
 reference:url,www.cert.org/advisories/CA-2001-19.html;
 classtype:web-application-attack;)
```

Fonte: Morin e Mé (2007).

2.3.1 Identificação e descrição de assinaturas de ataque

A maioria dos trabalhos encontrados na literatura que tratam de assinaturas de ataque têm como foco principal a melhoria do processo de identificação das mesmas, fazendo uso, por exemplo, desde técnicas mais simples (WU; ZHANG, 2011; ZHANG et al., 2012) até métodos mais complexos, como aprendizado de máquina (OWEZARSKI; MAZEL; LABIT, 2010), mineração de dados (ZONG; MAO; WU, 2008; YU; CHEN; ZHU, 2005), e algoritmos genéticos (HOQUE; MUKIT; BIKAS, 2012). Entretanto, pode-se encontrar alguns trabalhos que tratam de modelos e técnicas para descrever uma assinatura de ataque (YANG-BO; MING-GUANGZHOU, 2003; LASKOV, 2007; FILIOL, 2008; TSAI; HUANG, 2009). Sendo assim, uma das formas mais simples de se detectar um ataque é manter uma base de assinaturas e para cada pacote ou conjunto de pacotes recebidos, comparar com as assinaturas presentes nessa base até que seja encontrado um padrão igual ou muito semelhante.

O Intrusion Detection Message Exchange Format (IDMEF) (DEBAR; CURRY; FEINSTEIN, 2007) é um modelo cujo propósito é definir formatos de dados e procedimentos de troca para compartilhar informações de interesse de IDSs e sistemas de gerenciamento que possam interagir com eles. Na Figura 2 pode-se observar os dois tipos de mensagem IDMEF: Alerta e Heartbeat.

Mensagens do tipo Heartbeat servem para informar se um determinado analisador, isto é, um sistema ou sensor que detecta ataques, continua ativo. Já mensagens do tipo Alerta servem para indicar um ataque e contém informações do mesmo, como o processo de origem e uma avaliação do impacto do ataque. Os campos e descrições da mensagem de alerta podem ser observados na Tabela 2.

Figura 2 – IDMEF

Fonte: Adaptado de Debar, Curry e Feinstein (2007).

Cansian, Silva e Souza (2002) propõe um modelo de descrição de assinaturas em XML (eXtensible Markup Language) denominado ACME Intrusion Signature Format (AISF). Mais especificamente, são definidos diversos módulos que, dependendo do tipo de assinatura que está sendo descrita, podem ser inseridos ou não. Esse modelo tem a vantagem de possuir interoperabilidade devido ao XML e também de ser modular, ou seja, se determinados módulos não são essenciais para a descrição de uma assinatura, eles podem ser removidos sem comprometer a assinatura.

Tabela 2 – Mensagem de Alerta do IDMEF

Alerta	
Campo	Descrição
Analizador	Sensor/Módulo/Programa que detectou o ataque
Hora de criação	Data e hora que o alerta foi criado
Hora de detecção	Data e hora que o ataque foi detectado pelo analisador
Hora do analisador	Data e hora que o alerta foi enviado pelo analisador
Origem	Informações sobre a origem do ataque
Alvo	Informações sobre o alvo do ataque
Classificação	Nome do ataque e referências
Avaliação	Avaliação da severidade do ataque
Dados adicionais	Informações adicionais sobre o ataque

Fonte: Adaptado de [Debar, Curry e Feinstein \(2007\)](#).

Nas Tabelas 3 e 4 são ilustrados os campos e suas descrições referentes, respectivamente, aos módulos de identificação e informação da assinatura. Há ainda módulos destinados exclusivamente a descrever informações do tráfego da rede em nível de enlace (e.g., endereços MAC de origem e destino), rede (e.g., endereços IPv4 de origem e destino, ~~time-to-live~~) e transporte (e.g., portas de origem e destino, número de sequência). Por fim, há o módulo com informações sobre o **payload**, cujos campos e suas descrições podem ser observados na Tabela 5.

Tabela 3 – AISF - Módulo de identificação de assinatura.

Campo	Descrição
Versão	Campo destinado à identificação da versão do modelo AISF
ID	Número único que identifica o ataque. Fornecido pelo administrador do modelo
Nome	Nome do evento de intrusão
Número de Série	Campo destinado à identificação da versão da assinatura
Créditos	Autor(es) da assinatura
Próximo Módulo	Identifica o próximo módulo desta assinatura

Fonte: Adaptado de [Cansian, Silva e Souza \(2002\)](#).

Tabela 4 – AISF - Módulo de informação sobre a assinatura.

Campo	Descrição
Tamanho do módulo	Descreve quantos campos estão presentes neste módulo
Nível de segurança	Valor de 0 a 100 descrevendo o quão perigoso é este ataque
Categoria	Tipo de ataque (e.g., DoS, scan, e outros)
Descrição	Descrição deste ataque
Outros IDs	Referências para este ataque
Impacto	Qual a consequência deste ataque
Cenário de ataque	O que é necessário para que este ataque ocorra
Sistema alvo	Sistemas que são afetados
Próximo Módulo	Identifica o próximo módulo desta assinatura

Fonte: Adaptado de [Cansian, Silva e Souza \(2002\)](#).

Tabela 5 – AISF - Módulo de informação sobre o **payload**.

Campo	Descrição
Tamanho do cabeçalho	Número de campos do cabeçalho
Tamanho	Tamanho do payload
Offset	Offset no payload para começar o reconhecimento de padrões
Profundidade	Quão longe se deve procurar dentro do pacotes
Conteúdo	Conteúdo do payload
Próximo Módulo	Identifica o próximo módulo desta assinatura

Fonte: Adaptado de [Cansian, Silva e Souza \(2002\)](#)

Tanto o IDMEF quanto o AISF fornecem dados importantes para a classificação de um ataque. Contudo, o AISF fornece mais detalhes sobre o ataque, como por exemplo, pré-condições para que o ataque aconteça e informações do **payload** daquele ataque. Além disso, ele permite uma maior flexibilidade devido a sua estrutura modular. Sendo assim, neste trabalho optou-se por construir um modelo de assinatura espectral baseado no AISF.

Com o modelo definido, é necessário definir as tecnologias usadas para representar as assinaturas e como deve ser feito o armazenamento delas, de forma a criar uma base de dados que permita que o diagnóstico seja feito de modo eficiente.

2.3.1.1 XML vs. JSON

XML (eXtensible Markup Language) é um padrão de formatação de texto especificado pela W3C ([W3C, 2008](#)), utilizado em vários contextos, e provê informações em um formato estruturado, padronizado, flexível e extensível. Ele é independente de plataforma, possui um formato de dados universal e é autodescritivo. Assim, qualquer aplicação pode entender uma mensagem XML ([ROSENBERG; REMY, 2004](#)). No Código-fonte 1 é ilustrado um exemplo de como é descrito o nome de uma pessoa em XML.

Código-fonte 1 – Definição de um nome em XML

```

1: <nome>
2:   <nome>Arthur</nome>
3:   <sobrenome>Chaves</sobrenome>
4: </nome>

```

JSON (JavaScript Object Notation) ([ECMA, 2013](#)) foi desenvolvido para ser uma linguagem de troca de dados que seja legível por humanos e fácil de ser analisada e usada por computadores ([NURSEITOV et al., 2009](#)). É um formato de troca de dados leve, baseado em texto e independente de linguagem. Foi derivado da linguagem de programação ECMAScript. JSON define um pequeno conjunto de regras de estrutura para a representação portátil de dados ([ECMA, 2013](#)). Na Figura 2 é ilustrado um exemplo de como é descrito o nome de uma pessoa em JSON.

Código-fonte 2 – Definição de um nome em JSON

```
1: {  
2:   "nome": "Arthur",  
3:   "sobrenome": "Chaves"  
4: }
```

Com relação ao desempenho, a literatura aponta que o JSON é superior ao XML em termos de tempo de processamento e quantidade de recursos utilizados. Em (NURSEITOV et al., 2009) é feita uma comparação entre XML e JSON em uma aplicação cliente-servidor e os resultados obtidos mostraram que o JSON é mais rápido e usa menos recursos que o XML. Já Sumaray e Makki (2012) fizeram uma comparação entre JSON, XML, ProtoBuf (Google, 2014) e Apache Thrift (Apache Software Foundation, 2014), dois formatos mais novos de serialização binária, em um ambiente *mobile*. Seus resultados mostraram que o JSON é mais rápido que o XML, mas é mais lento que os formatos de serialização binária. Entretanto, JSON e XML são legíveis por humanos, enquanto ProtoBuf e Thrift não são.

Uma vantagem do XML em relação ao JSON é a robustez. No XML é possível definir *namespaces* (W3C, 2009), que provêm um método para evitar ambiguidades e/ou conflitos de nomes das *tags*. Além disso, o XML provê suporte para validação de dados e da estrutura do documento. Contudo, essa responsabilidade pode ser transferida para a aplicação, e visto que o JSON é mais leve que o XML, optou-se por utilizar JSON neste trabalho.

2.3.1.2 Armazenamento das assinaturas

Os IDSs baseados em assinatura normalmente mantêm uma base de dados relacional com as assinaturas conhecidas para que possam ser comparadas com novos eventos. Bases de dados relacionais possuem recursos para garantir que operações sejam realizadas de forma atômica e que os dados sempre estejam disponíveis. No entanto, algumas aplicações permitem uma menor confiabilidade e disponibilidade em troca de maior flexibilidade e escalabilidade, e por isso, optam por utilizar bases de dados não-relacionais (NoSQL) (AMAZON, 2016), como MongoDB (MONGODB, 2016), Cassandra (APACHE, 2016) e Redis (SANFILIPPO, 2016).

Bases NoSQL possuem ainda a vantagem de não precisarem seguir um *schema*, ou seja, não necessitam atender a um modelo de dados pré-definido, um item no banco pode ter dados que outro item da mesma coleção não possui, o que o torna ideal para certas aplicações não-críticas.

O MongoDB é uma base de dados *open-source* orientado a documentos JSON, possui suporte a índices para otimização de *queries*, uma linguagem de *queries* que suporta operações de escrita e leitura, assim como agregação de dados. Ele também provê suporte nativo a replicação de dados, transferência em caso de falhas, e particionamento de dados (MONGODB, 2016).

Neste trabalho, visando o desempenho e flexibilidade, optou-se por utilizar o MongoDB

para armazenar as assinaturas, visto que ele utiliza um modelo de dados baseado em documentos JSON, o que permite uma representação bastante intuitiva do modelo modular de assinaturas apresentado nas Tabelas 3, 4 e 5.

2.4 Considerações finais

Este capítulo apresentou uma introdução sobre sistemas de detecção de intrusão e diferentes maneiras de detectar ataques, além de descrever discutidas assinaturas de ataque e modelos de descrição das mesmas. Então foi feita uma discussão sobre tecnologias para representar e armazenar assinaturas de forma a permitir a identificação de ataques a partir de uma base de dados.

Com isso, foi possível observar que essas técnicas e conceitos podem ser aplicadas ao diagnóstico de patologias de plantas. Assim, o próximo capítulo apresenta algumas dessas patologias e como normalmente é feito o diagnóstico das mesmas.

PATOLOGIAS DE EUCALIPTO E ASSINATURAS ESPECTRAIS

3.1 Considerações iniciais

Este capítulo tem como objetivo apresentar algumas das principais patologias de eucalipto: Murcha de *Ceratocystis*, Ferrugem e Seca de Ponteiros. São apresentados também os patógenos responsáveis por essas doenças, os sintomas e os danos por elas causados. Adicionalmente, é apresentada uma seção sobre assinaturas espectrais, visto que o uso dessas é uma das formas de diagnóstico de doenças em diferentes tipos de culturas.

3.2 Doenças e pragas de eucalipto

3.2.1 Murcha de *Ceratocystis*

Causada pelo fungo *Ceratocystis fimbriata* Ellis e Halsted, a murcha de *Ceratocystis* é uma doença constatada no Brasil a partir de dezembro de 1997 nos reflorestamentos clonais de eucalipto no sudeste da Bahia ([FERREIRA et al., 1999](#)).

É uma enfermidade sistêmica em planta lenhosa, caracterizada por estrias radiais escuras nas secções transversais de órgãos lenhosos, ou manchas escuras, do tipo cunha, em geral da periferia para a medula ([FERREIRA; MILANI, 2002](#)). Os danos causados pela doença ao caule e às folhas podem ser ilustrados nas Figuras 3 e 4, respectivamente.

O fungo *Ceratocystis fimbriata* Ellis e Halsted atualmente afeta plantas de eucalipto em plantações nos Estados da Bahia (sudeste e Recôncavo baiano), de Minas Gerais (Vale do Jequitinhonha e região oeste), São Paulo (região central) e Mato Grosso do Sul (sul) ([FERREIRA et al., 2006](#)). Ele pode causar mais de 40% de mortalidade em talhões monoclonais, afetando plantações clonais com 4 meses a 5 anos de idade, em brotações de tocos, em estacas de

enraizamento e em mudas clonais em viveiro. Além do eucalipto, esse fungo pode afetar muitas plantas lenhosas e algumas herbáceas de importância econômica como a acácia negra, batata doce, cacau, figo, mangueira e seringueira (FERREIRA; MAFFIA; FERREIRA, 2005)

Figura 3 – Comparação entre (a) um caule sadio e (b) um caule infectado com Murcha de *Ceratocystis*.

Fonte: arquivos do LSEC.

Figura 4 – Dano causado pela murcha de *Ceratocystis* nas folhas das árvores.

Fonte: arquivos do LSEC.

3.2.2 Seca de Ponteiros

A seca de ponteiros é causada pelo fungo *Dothiorella* sp., cuja forma perfeita corresponde a *Botryosphaeria ribis*. Este fungo apresenta uma ampla gama de hospedeiros e geralmente ataca plantas debilitadas por outros fatores como danos por insetos, estresse hídrico, entre outros (HETZEL, 2002; FERREIRA, 1989).

Os sintomas surgem nos terços da copa da árvore. Trata-se de lesões nas extremidades da haste principal, nos pontos de inserções de seus galhos e ramos; nos galhos, nos pontos de inserções de seus ramos e pecíolos; nos ramos, nos pontos de inserções de seus pecíolos. Com o passar do tempo, algumas dessas lesões podem anelar o órgão, causando a morte ou secamento daquela porção, a partir do local anelado. Caso não haja anelamento no local lesionado, observa-se um cancro, sendo este caracterizado por uma lesão ladeada por calos, onde mais tarde poderá surgir uma brotação (FERREIRA, 1989).

O anelamento de galhos e ramos é mais comum em suas porções mais finas, algumas vezes, porém, uma ou outra lesão consegue anelar o órgão em local de diâmetro relativamente elevado, ocasionando morte ou secamento. A severidade da doença é determinada pela quantidade de lesões que consegue anelar esses órgãos. Essa severidade varia com o local topográfico, com a época de inspeção da doença e com a espécie, procedência e clone do eucalipto (FERREIRA, 1989). Na Figura 5 é ilustrado o dano causado pela seca de ponteiros, podendo-se observar que as folhas mais próximas ao topo da árvore secam e morrem devido ao anelamento daquela porção.

3.2.3 Ferrugem

A ferrugem do eucalipto (*Puccinia psidii* Winter) possui um agente causal que apresenta uma distribuição geográfica ampla, abrangendo a América do Sul, América Central, ilhas no Caribe e Flórida (COUTINHO et al., 1998; ALFENAS et al., 2004). É uma doença causada por fungos que podem se manifestar em diversos hospedeiros nativos, silvestres ou cultivados, sob a forma de diferentes espécies (FIGUEIREDO, 2001). Estes organismos são ditos parasitas obrigatórios ou biotróficos, ou seja, dependem das células vivas do hospedeiro para a sua sobrevivência (FERREIRA, 1989).

P. psidii é um dos principais agentes responsáveis por danos nos reflorestamentos de eucalipto do Estado de São Paulo, passando a ser considerada importante em meados de 1990 em plantios jovens de eucaliptos da região de Itapetininga e Vale do Paraíba (CAMARGO et al., 1997).

Em mudas nos viveiros e em plantas no campo, o ataque da ferrugem restringe-se aos órgãos tenros das plantas como primórdios foliares, terminais de galhos e haste principal (FIGUEIREDO, 2001). Os sintomas são pequenas pontuações na parte inferior das folhas, levemente salientes e de coloração verde clara ou vermelho amarelada. Após duas semanas as pontuações se transformam em pústulas que aumentam de tamanho e em seguida ocorre

Figura 5 – Dano causado pela seca de ponteiros em um eucalipto jovem.

Fonte: arquivos do LSEC.

a esporulação nos órgãos atacados, que ficam tomados pela infecção. Estas pústulas podem se juntar, recobrando a superfície das brotações do eucalipto quando o ataque é intenso. Em consequência, os tecidos afetados morrem e secam, adquirindo coloração negra, como se fossem queimados. Dependendo das condições ambientais a planta pode reagir emitindo novas brotações. Com o desenvolvimento das folhas e do caule, a massa amarela de esporos desaparece, dando lugar a lesões salientes, rugosas e de coloração marrom (SANTOS; AUER; JÚNIOR, 2001). Na Figura 6 é ilustrado o dano causado pela ferrugem em uma folha de eucalipto.

Uma vez que existem diferentes tipos de doenças e pragas que afetam as plantações de eucaliptos, uma medida para reduzir as perdas financeiras com a infestação ou ataque dessas doenças é a identificação por meio do monitoramento das plantações, permitindo seu controle. Além do uso do monitoramento a partir de análises efetuadas em campo por especialistas, um outro meio pelo qual esse monitoramento tem sido feito é pela identificação dessas doenças por meio de assinaturas espectrais.

Figura 6 – Dano causado pela ferrugem em uma folha de eucalipto.

Fonte: arquivos do LSEC.

3.3 Espectro eletromagnético e assinaturas espectrais

O espectro eletromagnético é uma faixa contendo todas as frequências das ondas de radiação eletromagnética. A luz visível pelo olho humano representa uma pequena parte do espectro eletromagnético (SMITH, 2012). Na Figura 7 é ilustrado todo o espectro eletromagnético, com destaque para a luz visível, que se encontra entre 400nm e 700nm.

Figura 7 – Espectro eletromagnético.

Fonte: Gonzalez e Woods (2010).

Quando a radiação eletromagnética atinge um determinado objeto, dependendo do material do qual ele é feito, uma parte da radiação é absorvida, uma parte é transmitida e uma parte é refletida. Sensores óticos como espectrômetros e câmeras multiespectrais medem a quantidade de radiação refletida (reflectância) de um objeto.

Ao traçar um gráfico dos valores de reflectância de um objeto, ao longo de diferentes comprimentos de onda, pode-se identificar o material do qual aquele objeto é feito. A curva de reflectância VS comprimento de onda é conhecida como assinatura espectral e é muito utilizada em sensoriamento remoto para identificar por exemplo, regiões de solo, vegetação ou áreas urbanas (FIGUEIREDO, 2005; SMITH, 2012). Na Figura 8 é ilustrada a diferença entre as assinaturas espectrais de solo, água e árvores coníferas.

Figura 8 – Assinatura espectral de coníferas, solo e água.

Fonte: Adaptado de EUMeTrain (2010).

O sensoriamento remoto é baseado na radiação refletida das folhagens. As diferenças de reflectância podem ser obtidas e utilizadas de forma eficiente para mapear a incidência de um número grande de patógenos de plantas. Os sensores normalmente utilizados são multiespectrais (normalmente RGB e NIR) e mais recentemente hiperespectrais. O sensoriamento remoto é uma ferramenta que pode ser utilizada pra detectar plantas doentes de forma rápida e eficiente em pequenas e grandes áreas (NAUE et al., 2010).

Na literatura podem ser encontrados trabalhos que fazem a análise de assinaturas espectrais para detectar doenças em plantas. Em (BRAVO et al., 2003), foi utilizado um espectrômetro de campo em uma plantação de trigo a fim de verificar a diferença entre as reflectâncias de indivíduos saudáveis e de infectados com ferrugem. Na Figura 9 são ilustradas as assinaturas espectrais das plantas saudáveis (linha contínua) e das plantas doentes (linha pontilhada), sendo muito similares na região do visível (400 – 750nm), mas bem diferentes na região do infravermelho (700 – 900nm).

Em (MAHLEIN et al., 2012), os autores utilizaram imagens hiperespectrais para avaliar como algumas patologias afetam a reflectância da planta em baixa escala. O experimento foi realizado com folhas de beterraba infectadas com diferentes doenças. Na Figura 10 são ilustradas as assinaturas espectrais extraídas de folhas saudáveis e de folhas infectadas por diferentes

Figura 9 – Reflectância de folhas de trigo saudáveis e infectadas com ferrugem.

Fonte: Adaptado de [Bravo et al. \(2003\)](#).

doenças. É possível observar ainda que as assinaturas de plantas doentes variam de acordo com a doença que está afetando a planta.

Figura 10 – Assinaturas espectrais de diferentes doenças em folhas de beterraba.

Fonte: Adaptado de [Mahlein et al. \(2012\)](#).

Na literatura é possível encontrar diversos trabalhos que utilizam assinaturas espectrais para outros fins além de identificar doenças, como por exemplo: reconhecer espécies de eucalipto ([GOODWIN; TURNER; MERTON, 2005](#)); estimar a concentração de clorofila na planta

(GITELSON; MERZLYAK, 1996); estimar concentração de água, troca de gases e fluxo de seiva (MARINO *et al.*, 2014); estimar níveis de proteínas nas plantas (YAN *et al.*, 2014); estimar níveis de nitrogênio (LI *et al.*, 2014); identificar minerais presentes no solo (OTT; KOLLERSBERGER; TASSARA, 2006) e inclusive descobrir a composição de planetas (IZENBERG *et al.*, 2014).

3.4 Considerações finais

Este capítulo apresentou uma introdução sobre algumas das principais patologias que afetam o eucalipto. Também foram descritos os conceitos de reflectância e assinaturas espectrais, além de alguns trabalhos relacionados.

Com isso, foi possível observar a necessidade de se averiguar meios mais eficientes de se prover o monitoramento dessa cultura, permitindo assim que medidas para detectar e conter essas doenças possam ser realizadas de forma mais eficaz.

Assim, o próximo capítulo apresenta uma revisão sistemática que tem por objetivo investigar o estado da arte do uso de VANTs na detecção de doenças em plantações.

USO DE VANTS NA DETECÇÃO DE DOENÇAS EM PLANTAÇÕES

4.1 Considerações iniciais

O uso de VANTS para detectar doenças em plantas deve empregar técnicas de sensoriamento remoto e processamento de imagens que permitam a identificação precisa dos indivíduos infectados. Sendo assim, é necessário realizar um levantamento do estado da arte para descobrir trabalhos que apresentem esforços nessa área para identificar as melhores técnicas aplicadas na solução dos problemas permitindo formular um método de diagnóstico automático de doenças em plantações.

A revisão sistemática da literatura é uma forma de identificar, avaliar e interpretar as pesquisas relevantes de uma área em torno de uma questão científica ou área do conhecimento. Por meio dela é possível identificar lacunas de pesquisa e ainda esclarecer o estado da arte ([KITCHENHAM; CHARTERS, 2007](#)). A descrição do planejamento e execução da revisão sistemática podem ser encontrados no Apêndice A, sendo que neste capítulo são apresentados os trabalhos resultantes da última etapa da revisão sistemática.

4.2 Trabalhos relacionados

Os VANTS são uma ferramenta importante de sensoriamento remoto e que vêm ganhando espaço nos últimos anos, sendo uma de suas funções monitorar plantações a fim de encontrar problemas como falhas no plantio, doenças e pragas. Sendo assim, esta Seção elenca alguns trabalhos nessa área de pesquisa e que foram aceitos na última seleção da revisão sistemática.

Em um estudo com imagens hiperespectrais de satélite, ([APAN et al., 2004](#)) utilizou assinaturas espectrais e diversos índices de vegetação para identificar plantações de cana-de-

açúcar infectadas com um tipo de ferrugem. Por usarem imagens de satélite, a resolução espacial das imagens é baixa e portanto só foi possível detectar a doença em um talhão quando a maior parte das plantas já haviam sido afetadas. Nesse sentido, o uso de VANTs possibilita a detecção precoce de doenças, permitindo um tratamento de precisão no início da doença, onde tem-se apenas algumas plantas afetadas, reduzindo assim, os prejuízos causados.

Em (JR et al., 2005), foi utilizado um aeromodelo controlado remotamente para monitorar plantações de milho, soja e alfafa. Mais especificamente, a partir de imagens de uma câmera RGB comercial foram obtidos alguns índices de vegetação a fim de monitorar o **status** de nitrogênio, índice de área foliar (**Leaf Area Index (LAI)**) e biomassa das plantas. Também foram feitas calibrações radiométricas das imagens para extrair a reflectância dos indivíduos observados. Com isso, os autores construíram assinaturas espectrais de folhas de milho e conseguiram estimar a quantidade de nitrogênio e o LAI a partir da reflectância. Além disso, foi verificado que o índice de vegetação **Normalized Green-Red Difference Index (NGRDI)** possui um elevado coeficiente de correlação com a biomassa e o LAI das três culturas observadas. Os autores concluem que esses resultados são importantes para a agricultura de precisão, principalmente em superar limitações encontradas com o uso de satélites. O uso do aeromodelo e uma câmera comercial apresentou novos desafios, como o borramento das imagens. Os autores esperavam que com o desenvolvimento de tecnologias pelos militares traria grandes avanços em plataformas de sensoriamento remoto para a agricultura. O desenvolvimento de VANTs vem nessa linha, e traz com ele novos desafios que são abordados no escopo dessa dissertação.

Já em (SUGIURA; NOGUCHI; ISHII, 2005), os autores utilizaram um helicóptero não tripulado a fim de criar um mapa georreferenciado contendo informações sobre o **status** de uma plantação de milho, mais especificamente LAI e **Normalized Difference Vegetation Index (NDVI)**. Utilizando sensores de direção geomagnética, inerciais e GPS de alta precisão, foi possível medir a posição e o ângulo do VANT (**row, pitch e yaw**) no momento em que cada foto foi tirada e então transformar as coordenadas da imagem em coordenadas globais. Ao calcular o NDVI e o LAI no mapa gerado, foi possível obter a posição das plantas que possuíam algum tipo de problema com um erro de até 38 centímetros. Esse resultado pode não ser tão preciso a ponto de identificar exatamente cada planta, mas quando comparado ao tamanho do talhão plantado, é um resultado muito bom, visto que a área usada no experimento possuía cerca de 1900 m², e em grandes propriedades é comum encontrar talhões com mais de 100 ha (1000000 m²). Os sensores e os índices apresentados pelos autores foram utilizados no escopo desta dissertação, mas focando a cultura de eucalipto, sendo que ao invés de fazer uso de um helicóptero foi utilizado um VANT de asa fixa.

Em (MUHAMMED, 2005), é feito um estudo com assinaturas espectrais para estimar a severidade de uma doença de trigo causada por fungos. Utilizando-se de um espectroradiômetro a uma distância de cerca de 2 metros das plantas, foram obtidas assinaturas espectrais de plantas com diferentes níveis de severidade de sintomas. Foram selecionadas aleatoriamente algumas

assinaturas para formar um conjunto de referência, e então foi realizado um cálculo de distância entre assinaturas utilizando um classificador de vizinho mais próximo baseando-se no coeficiente de determinação R^2 . Assim, foi possível inferir o estágio da doença em uma planta a partir da assinatura espectral. Contudo, nesse trabalho, as assinaturas não foram utilizadas para identificar doenças diferentes, apenas para identificar plantas saudáveis e infectadas com diferentes níveis da mesma doença, o que diferencia o trabalho apresentado nesta dissertação é o uso para identificar diferentes doenças.

Em (BERNI et al., 2009), foi realizado um estudo com objetivo de avaliar o uso de VANTs para a detecção de doenças em pomares de laranja. O principal objetivo desse artigo foi demonstrar que é possível combinar uma plataforma aérea não tripulada, sensores termais e multiespectrais, cumprindo-se as calibrações apropriadas para aplicações na agricultura. Foram estimados alguns parâmetros biofísicos como o índice de área foliar (LAI), quantidade de clorofila, e indicadores de **stress** baseados no índice de reflectância fotoquímica (Photochemical Reflectance Index (PRI)). A partir desses parâmetros, foi possível detectar as plantas doentes com uma precisão muito boa, comparável à precisão obtida pelos sensores embarcados em aeronaves tripuladas. Entretanto, neste artigo, apesar do uso de sensores multiespectrais e termais, não foi realizada uma detecção de doença por meio das assinaturas espectrais.

O trabalho de Laliberte et al. (2011) apresenta vantagens, desvantagens e limitações de metodologias e técnicas de sensoriamento remoto aplicadas a VANTs. Os autores apresentam métodos de processamento de imagem, ortorretificação, construção de mosaicos, calibração radiométrica e análise espectral, além de comparações entre assinaturas espectrais da vegetação e do solo obtidas pelo satélite **WorldView-2** e por um VANT. As curvas de reflectância obtidas pelo satélite e pelo VANT foram similares, com coeficientes de determinação R^2 variando de 0.86 a 0.97, dependendo da espécie de planta. Sendo assim, foi possível utilizar um VANT para identificar espécies de plantas a partir da reflectância com uma precisão de cerca de 87%. Esse estudo mostra o potencial do uso de VANTs para monitorar grandes áreas, visto que, mesmo com o **WorldView-2** possuindo uma boa resolução espacial (de 50cm a 2m, dependendo da banda), ele possui um custo muito alto e há a chance de nuvens bloquearem a visão da área.

Zhang e Kovacs (2012) apresentam uma revisão bibliográfica sobre o uso de VANTs na agricultura de precisão. Nos últimos anos houve um aumento no número de exemplos de aplicações de VANTs no monitoramento ambiental e agricultura de precisão, como por exemplo, mapeamento de produção e saúde das plantas, monitoramento de **stress** na vegetação e avaliação dos impactos do uso de fertilizantes no crescimento da plantação. Contudo, entre as desvantagens do uso de VANTs pode-se destacar o alto custo inicial, limitações do sensor e uma falta de procedimentos padronizados para processar grandes volumes de dados. Os autores esperavam, na época, que com o avanço das tecnologias de plataformas aéreas não tripuladas, novos modelos de câmeras, custos reduzidos, técnicas melhoradas de processamento de imagens e o aumento no número de pesquisas na área, que o uso de VANTs na agricultura se tornasse algo comum nas

fazendas e áreas de preservação ambiental. Atualmente esses equipamentos já apresentam um custo mais acessível quando comparado com a data de publicação do artigo. Isso tem permitido um avanço e um uso mais efetivo dessas aeronaves em diversas áreas de aplicação, apesar do seu uso ainda ser restrito (devendo seguir a legislação vigente apresentadas pela Agência Nacional de Aviação Civil (ANAC)).

Mahlein et al. (2012) apresenta uma revisão bibliográfica sobre avanços recentes em sensores não invasivos para detectar, identificar e quantificar doenças em plantas em diferentes escalas. Os autores indicam que os sensores mais promissores são os termais, sensores de fluorescência e hiperespectrais, além disso, também foram apresentados trabalhos que utilizaram assinaturas espectrais para detectar certas doenças e pragas: Mahlein et al. (2010) obtiveram assinaturas espectrais de diversas folhas de beterraba infectadas com Crestamento Foliar de *Cercospora*, Míldio e Ferrugem. As assinaturas obtidas foram significativamente diferentes e únicas para cada doença. Outros autores também conseguiram utilizar com sucesso dados espectrais para detectar *Magnaporthe grisea* em arroz (KOBAYASHI et al., 2001), *Phytophthora infestans* em tomates (ZHANG et al., 2003), *Venturia inaequalis* em árvores de maçãs (DELALIEUX et al., 2007). Danos causados a plantações por doenças virais (NAIDU et al., 2009), ou insetos (CARROLL et al., 2008) também puderam ser detectados usando sensores espectrais. Esses trabalhos, portanto, demonstram a viabilidade do uso de assinaturas espectrais, mas agora com uma maior abrangência, uma vez que elas podem ser obtidas a partir de sensores acoplados aos VANTs.

O estudo de Calderón et al. (2013) avaliou o uso de imagens aéreas para detectar a murcha de *Verticillium* em pomares de oliva. Os autores aplicaram técnicas baseadas na detecção dos efeitos da infecção e transmissão da doença que puderam ser observados com sensores termais, multiespectrais e hiperespectrais. Foi demonstrado ainda que a temperatura das copas e índices hiperespectrais como PRI e fluorescência de clorofila são mais adequados para indicar danos fisiológicos, enquanto índices como o NDVI são mais adequados para indicar danos estruturais causados pelo fungo. Assim como em (CALDERÓN et al., 2014), a metodologia proposta apenas detecta as plantas doentes, sem diagnosticar a patologia. Neste trabalho de mestrado realiza-se o diagnóstico de patologias de forma automática, ou seja, sem conhecimento de qual patógeno está afetando determinada plantação.

Em (GARCIA-RUIZ et al., 2013), os autores apresentaram uma nova abordagem para detectar HLB (Huanglongbing ou greening) em plantações de citrus. Os autores utilizaram imagens multiespectrais para detectar a doença. Inicialmente foram aplicados métodos de processamento de imagens para segmentar as árvores e extrair características. Também foram extraídas assinaturas espectrais (em solo e com o VANT) das árvores saudáveis e doentes. Ao aplicar as características de cada árvore em um classificador de aprendizado de máquina, foi possível classificar plantas doentes e saudáveis com uma acurácia de até 85% com o uso do VANT, e de até 74% com o uso de um avião tripulado. Esse trabalho é o mais próximo do

realizado neste trabalho de mestrado, visto que foram obtidas assinaturas espectrais com o uso de VANTs. Entretanto, não foi construído e nem proposto um sistema que faça o diagnóstico automático de patologias em plantas.

Em (SHASHIKANT; SHARIFF; NOURQOLIPOUR, 2013), os autores utilizaram uma câmera, com lentes modificadas para obter apenas os canais vermelho e azul, embarcada em um VANT para monitorar **stress** em plantações de *Elaeis guineensis*. Com o uso dessas lentes, os autores conseguiram detectar nas imagens as plantas com algum tipo de **stress**, entretanto, com esse método não foi possível identificar o que causou o **stress** propriamente dito, se uma doença ou outro fator.

Já o trabalho de Calderón et al. (2014) visava detectar o míldio, uma doença em plantações de papoulas (*Papaver somniferum*), utilizando câmeras multiespectrais e termais embarcadas em um VANT. A partir das imagens obtidas pelos sensores foram extraídos a razão verde/vermelho para detectar a concentração de clorofila; o NDVI para detectar mudanças na biomassa nas folhas; e a temperatura da copa para indicar níveis de transpiração. Os resultados mostraram que esses parâmetros estão relacionados com o **stress** fisiológico causado pelo míldio e é possível utilizá-los para detectar a doença, tanto em casos sintomáticos quanto assintomáticos. Entretanto, com essa metodologia não é possível diagnosticar a doença a partir de sensoriamento remoto, isto é, se não houver um conhecimento prévio de qual patologia está presente naquela área, o método apenas indica que há uma doença e é necessário um especialista ir até as plantas infectadas para que seja feito o diagnóstico.

4.3 Considerações finais

Este capítulo apresentou uma revisão bibliográfica sobre o uso de VANTs na detecção de doenças em plantações. O objetivo principal era a identificação de trabalhos iguais ou muito similares ao desenvolvido neste trabalho. Como nenhum trabalho exatamente igual foi encontrado, a síntese de resultados apresentada elencou os principais trabalhos e propostas relacionados às partes mais fundamentais deste mestrado.

Com base neste levantamento foi possível especificar a ADDSIGN (Automatic Disease Diagnostic SIGNature), desenvolvida e implementada nesta dissertação de mestrado.

ADDSIGN - AUTOMATIC DISEASE DIAGNOSTIC SIGNATURE

5.1 Considerações iniciais

Este capítulo apresenta os conceitos e fatores que contribuíram para a concepção de um sistema de diagnóstico automatizado de doenças de plantas denominado **Automatic Disease Diagnostic SIGNature** (ADDSIGN), tendo como estudo de caso inicial doenças de eucaliptos. São ainda apresentados os detalhes do sistema, os algoritmos de classificação utilizados e o modelo de assinaturas proposto neste trabalho.

5.2 Assinaturas espectrais vs. Assinaturas de ataque

Como apresentado nos Capítulos 2 e 3, assinaturas de ataque descrevem um determinado padrão de um ataque malicioso ou vírus de computador e são utilizadas por IDSs e antivírus para detectar e/ou identificar o ataque. Já as assinaturas espectrais são usadas para identificar doenças em plantas.

Ao comparar uma patologia de plantas com um ataque digital é possível observar algumas semelhanças:

- Afetam espécies ou sistemas específicos;
- Alteram o funcionamento ou a estrutura do alvo;
- É possível descrevê-los por meio de uma assinatura única;
- É possível comparar diferentes assinaturas para identificar um ataque ou patologia.

Tendo em vista as semelhanças entre assinaturas espectrais e assinaturas de ataque é viável desenvolver um sistema de diagnóstico de doenças de plantas que utiliza técnicas de detecção de ataques e, ainda, combiná-lo com o uso de VANTs para aumentar sua eficiência. Sendo assim, esse trabalho apresenta o desenvolvimento de tal sistema, que será apresentado com mais detalhes nas Seções 5.3 e 5.4.

5.3 Uso de VANTs e aquisição de dados

Uma vez que o objetivo deste trabalho é utilizar sensoriamento remoto para diagnosticar doenças em plantas, existe a opção de usar imagens de satélite ou imagens de VANTs. Contudo, satélites não são adequados para o tipo de aplicação aqui proposto, pois os satélites civis possuem uma resolução espacial muito baixa, da ordem de quilômetros por pixel. Os VANTs, entretanto, são capazes de obter imagens de resolução espacial da ordem de centímetros por pixel. Sendo assim, optou-se por utilizar imagens obtidas por VANTs em detrimento a imagens obtidas por satélites.

Para a aquisição das imagens aéreas foi utilizado o eBee (Figura 11), um VANT de pequeno porte produzido pela Sensefly¹, no qual são embarcadas duas câmeras Canon modelos IXUS (captura os canais R-G-B) e ELPH 110HS (captura os canais R-G-NIR), e que são adaptadas para que possam ser controladas pelo piloto automático do eBee (SENSEFLY, 2014).

Figura 11 – Aeronave eBee.

Fonte: Arquivos do LSEC.

As imagens obtidas pelo eBee são usadas para extrair a assinatura espectral das plantas a serem diagnosticadas. Entretanto, as condições de luz podem variar dependendo do local, horário e época do ano. Para tal, é necessário que seja feita uma calibração do sensor para ajustá-lo às condições do ambiente. Normalmente, essa calibração é feita colocando objetos no local

¹ www.sensefly.com

cujas reflectâncias são conhecidas. Assim, é possível ajustar os níveis de reflectância da área observada e obter somente a reflectância oriunda do material observado e que, portanto, pode ser comparada com outras medidas de reflectância.

5.4 Diagnóstico automático de doenças

Conforme discutido na Seção 3.3, a assinatura espectral de uma planta infectada pode ser utilizada para identificar a doença que está afetando aquela planta. Além disso, conforme discutido na Seção 5.2, as assinaturas espectrais, assim como assinaturas de ataque, podem ser entendidas como um padrão que identifica um determinado evento (um ataque ou uma doença). Sendo assim, o algoritmo proposto para o diagnóstico de doenças funciona de maneira análoga a um IDS baseado em assinaturas, isto é, o padrão que está sendo analisado é comparado com padrões já conhecidos presentes em uma base de dados para que o diagnóstico seja obtido.

Na Figura 12 é ilustrado o algoritmo de diagnóstico de doenças desenvolvido neste trabalho. A partir de uma imagem multiespectral de entrada são extraídas as informações de reflectância e então é construída a assinatura espectral. Posteriormente é feita uma busca por assinaturas semelhantes contidas em uma base de dados. Se for encontrada uma assinatura de planta infectada semelhante à assinatura buscada então a planta que está sendo observada é diagnosticada com aquela doença. Caso a assinatura observada seja semelhante à assinatura da planta saudável, então ela é classificada como saudável.

Esse método, assim como IDSs puramente baseados em assinaturas, possui a desvantagem de não conseguir identificar assinaturas desconhecidas. Entretanto, serve como prova de conceito para um sistema de diagnóstico automático de doenças e que, futuramente, pode ser melhorado com técnicas mais avançadas de reconhecimento de padrões, como redes neurais, mineração de dados e aprendizado de máquina.

5.4.1 Normalização e equalização de curvas espectrais

Visto que as assinaturas espectrais são obtidas por sensores diferentes, elas podem variar em escala e resolução. Portanto, para poder compará-las, é necessário normalizá-las para que fiquem em um mesmo intervalo. A normalização é feita subtraindo todos os pontos pelo menor valor, e então dividindo todos pelo maior valor. Como mostra a Equação 5.1.

$$\eta_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (5.1)$$

Mesmo após a normalização, as assinaturas ainda possuem resoluções espectrais diferentes, inviabilizando comparações ponto-a-ponto. Para contornar esse problema, é feita uma equalização das assinaturas onde, para cada parte inteira do comprimento de onda é calculada

Figura 12 – Processo de diagnóstico de doenças de plantas utilizando assinaturas espectrais

Fonte: Produzido pelo autor.

uma média das reflectâncias correspondentes a todos os comprimentos de onda daquela parte inteira. Isso é ilustrado por meio do exemplo da Tabela 6

Com a garantia de que todas as assinaturas estão na mesma escala, e possuem dados referentes aos mesmos comprimentos de onda, é possível aplicar algum algoritmo de classificação para compará-las.

5.4.2 Algoritmos de classificação

Para que o diagnóstico automático seja possível, alguns algoritmos de comparação e classificação de assinaturas foram implementados.

Tabela 6 – Exemplo de equalização da assinatura espectral

Assinatura espectral original		Assinatura espectral equalizada	
Comprimento de onda (nm)	Reflectância	Comprimento de onda (nm)	Reflectância
400.3	0.8	400	0.81
400.7	0.82		
401.1	0.7	401	0.705
401.5	0.71		
401.9	0.7		
402.3	0.6	402	0.6

Fonte: Produzido pelo autor.

5.4.2.1 Naive

O primeiro, chamado de **Naive**, é um algoritmo simples para comparar duas curvas de reflectância **P** e **Q**. Seu funcionamento se dá da seguinte forma: para cada comprimento de onda i é feita uma comparação direta entre as reflectâncias q_i e p_i . Se a reflectância q_i estiver em um intervalo de $\pm 50\%$ de p_i , é contabilizado um acerto. Por fim, a assinatura com mais acertos é considerada igual a **Q**.

5.4.2.2 Distância Euclidiana

A distância Euclidiana é uma medida bastante popular da menor distância entre dois vetores. Ela é dada pela Equação 5.2

$$d(p;q) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (5.2)$$

O diagnóstico é feito baseando-se na assinatura **P** com a menor distância de **Q**.

5.4.2.3 Distância Manhattan

A distância Manhattan ([KRAUSE, 1975](#)) se dá pela soma das diferenças absolutas das coordenadas cartesianas de dois pontos, como mostra a Equação 5.3.

$$d(p;q) = \sum_{i=1}^n |q_i - p_i| \quad (5.3)$$

O diagnóstico é feito baseando-se na assinatura **P** com a menor distância de **Q**.

5.4.2.4 SAM

Spectral Angle Mapper (SAM) ([KRUSE et al., 1993](#)) é um algoritmo de comparação de curvas de reflectância baseado no ângulo α entre as reflectâncias **P** e **Q**. Quanto menor o ângulo, mais parecidas são as curvas. Ele é dado pela Equação 5.4.

$$\alpha = \arccos \frac{\sum_{i=1}^n p_i q_i}{\sqrt{\sum_{i=1}^n p_i^2} \sqrt{\sum_{i=1}^n q_i^2}} \quad (5.4)$$

5.4.2.5 SCM

O Spectral Correlation Mapper (SCM) (CARVALHO; MENESES, 2000) tenta aprimorar o SAM utilizando o Coeficiente de Pearson, dado pela Equação 5.5, que faz uma normalização pela média.

$$R = \frac{\sum_{i=1}^n (p_i - \bar{p})(q_i - \bar{q})}{\sqrt{\sum_{i=1}^n (p_i - \bar{p})^2 \sum_{i=1}^n (q_i - \bar{q})^2}} \quad (5.5)$$

5.4.3 Modelagem das assinaturas de doenças

Tomando como base o modelo de Cansian, Silva e Souza (2002) de assinaturas de ataque (detalhado na Seção 2.3.1), foi feita a especificação de um modelo de assinaturas de patologias de plantas que contém as informações necessárias para diagnosticar uma determinada doença em uma determinada planta. A partir deste modelo é possível construir bases de dados de doenças, auxiliando no processo de identificação das mesmas. Ele é composto por quatro módulos: identificação da assinatura, informações sobre a assinatura, informações sobre o patógeno e informações espectrais.

O módulo de identificação da assinatura (Tabela 7) possui os campos necessários para identificar unicamente uma assinatura. Há um número identificador único (Id) para a assinatura, o nome da doença que está sendo descrita, os nomes comum e científico da planta infectada, o autor ou autores da assinatura e ainda uma referência para o próximo módulo.

Tabela 7 – Módulo de identificação da assinatura

Identificação da assinatura	
Campo	Descrição
Id	Número único que identifica a assinatura
Nome	Nome da doença
Planta (comum)	Nome da planta infectada
Planta (científico)	Nome científico da planta infectada
Créditos	Autor(es) desta assinatura
Próximo módulo	Identifica o próximo módulo desta assinatura

Fonte: Produzido pelo autor.

O módulo de informações sobre a assinatura (Tabela 8) possui informações que não são relacionadas à doença, mas que são importantes para se ter uma ideia sobre a qualidade e o nível de acurácia da assinatura. Há os campos de versão da assinatura, os níveis de falsos positivos e negativos, qual o sensor utilizado para obter a reflectância da planta e também uma referência para o próximo módulo.

O módulo de informações sobre o patógeno (Tabela 9) traz informações que não necessariamente são utilizadas para diagnosticar uma determinada patologia. Entretanto, traz informações importantes que podem, por exemplo, ser mostradas ao usuário para confirmação do

Tabela 8 – Módulo de informações sobre a assinatura

Informações sobre a assinatura	
Campo	Descrição
Versão	Identificação da versão desta assinatura
Nível de falsos positivos	Porcentagem aproximada de falsos positivos obtidos por esta assinatura
Nível de falsos negativos	Porcentagem aproximada de falsos negativos obtidos por esta assinatura
Sensor	Tipo de sensor usado para obter a reflectância (e.g., câmera, espectrômetro)
Próximo módulo	Identifica o próximo módulo desta assinatura

Fonte: Produzido pelo autor.

diagnóstico ou para informá-lo dos danos que podem ocorrer e como deve ser feito o tratamento. Os campos neste módulo são: os nomes comum e científico do patógeno; o tipo de patógeno, ou seja, se é um fungo, uma bactéria ou um inseto; quais espécies são vulneráveis a ele; os sintomas característicos; o dano causado na planta em longo prazo; as condições favoráveis para a ocorrência e reprodução do patógeno, por exemplo, condições climáticas ou ferimentos nas plantas; características particulares do patógeno, como forma de disseminação ou regiões onde é encontrado; métodos de prevenção; tratamento recomendado e por fim uma referência para o próximo módulo.

Tabela 9 – Módulo de informações sobre o patógeno

Informações sobre o patógeno	
Campo	Descrição
Nome	Nome comum do patógeno
Nome científico	Nome científico do patógeno
Tipo	Tipo do patógeno (e.g., fungo, inseto)
Plantas vulneráveis	Plantas suscetíveis ao patógeno
Sintomas	Sintomas característicos deste patógeno
Dano	Dano causado na planta
Condições favoráveis	Lista de condições propícias à ocorrência do patógeno
Outras características	Outras características particulares do patógeno (e.g., forma de disseminação, regiões onde é encontrado, etc.)
Prevenção	Ações recomendadas para prevenir a ocorrência do patógeno
Tratamento recomendado	Ações recomendadas para eliminar o patógeno da plantação
Próximo módulo	Identifica o próximo módulo desta assinatura

Fonte: Produzido pelo autor.

Por último tem-se o módulo de informações espectrais (Tabela 10), que contém a curva de reflectância usada no diagnóstico da doença. Este módulo possui: o tamanho da curva; a resolução espectral, isto é, qual a precisão da escala do eixo do comprimento de onda; o *offset*, isto é, o ponto inicial na curva para iniciar o reconhecimento do padrão; a profundidade, ou seja,

quão “longe” se deve percorrer a curva para encontrar o padrão; e por fim, a assinatura espectral, isto é, o nível de reflectância Vs. comprimento de onda.

Tabela 10 – Módulo de informações espectrais

Informações espectrais	
Campo	Descrição
Tamanho	Tamanho da curva de reflectância (i.e., comprimentos de onda inicial e final)
Resolução	Resolução espectral da curva (i.e., nível de precisão do eixo do comprimento de onda)
Offset	Ponto para iniciar o reconhecimento de padrões
Profundidade	Quão longe se deve buscar padrões
Assinatura espectral	Tabela com os valores de reflectância VS. comprimento de onda

Fonte: Produzido pelo autor.

5.5 Arquitetura do ADDSIGN

O ADDSIGN é dividido em quatro módulos principais: o de processamento de imagens, o de classificação e o de diagnóstico, além do banco de dados de assinaturas, como pode ser observado na Figura 13.

O módulo de processamento de imagens é responsável por tratar as imagens de entrada e extrair as assinaturas. Sendo assim, é feito um pré-processamento das imagens, o que reduz ruídos e encontra as posições de cada árvore na imagem. Então, a assinatura espectral de cada árvore é obtida com a maior precisão possível.

O módulo de diagnóstico é responsável por se comunicar com o banco de dados e obter as assinaturas espectrais conhecidas, normalizar e equalizar as assinaturas para que elas possam ser comparadas corretamente, e então repassá-las ao módulo de classificação e ao final, realizar o diagnóstico propriamente dito.

O módulo de classificação tem como função receber uma assinatura desconhecida e um conjunto de assinaturas conhecidas, aplicar algoritmos de comparação como os que foram apresentados na Seção 5.4.2, e retornar qual assinatura é a mais similar àquela que se quer diagnosticar.

Já o banco de dados de assinaturas armazena as assinaturas conhecidas de acordo com o formato apresentado na Seção 5.4.3.

5.6 Considerações Finais

Este capítulo apresentou o ADDSIGN e sua arquitetura, bem como os algoritmos de classificação que foram implementados. Também foram discutidos a aquisição de dados e

Figura 13 – Arquitetura do ADDSIGN.

Fonte: Produzido pelo autor.

o modelo de assinaturas utilizado no trabalho. O próximo capítulo mostra como foi feita a validação, descreve os experimentos realizados e os resultados obtidos.

EXPERIMENTOS REALIZADOS E RESULTADOS OBTIDOS

6.1 Considerações Iniciais

Neste capítulo são apresentados os cenários de experimentação para validar o sistema desenvolvido, como foram realizadas as aquisições de dados em campo e em laboratório e por fim, a validação do ADDSIGN.

6.2 Definição dos experimentos

Para uma melhor avaliação dos resultados, cenários de testes e experimentação foram definidos. Uma relação dos cenários avaliados pode ser observada na Tabela 11.

Foi avaliada a acurácia do diagnóstico de diferentes doenças feito pelo ADDSIGN com cada um dos diferentes algoritmos de classificação (Naive, Distância Euclidiana, Distância Manhattan, SAM e SCM).

As patologias consideradas foram Murcha de *Ceratocystis*, Seca de Ponteiros e Ferrugem, sendo que no caso da Ferrugem, considerou-se 3 níveis distintos da doença. Além destas, também foi avaliada a acurácia no diagnóstico de dois indivíduos eucaliptos saudáveis.

6.3 Aquisição dos dados

Foram feitos diversos voos em diferentes plantações de eucalipto no Estado de São Paulo. Para tal, foi utilizado o VANT eBee com câmeras RGB e NIR, conforme descrito na Seção 5.3. Na Figura 14 pode-se observar o planejamento da rota feita pelo eBee em uma plantação de eucaliptos em Itatinga-SP. Além disso, em cada plantação também foram colhidas amostras de

Tabela 11 – Experimentos realizados.

Patologia	Níveis da doença	Diferentes indivíduos	Algoritmos de classificação
Ferrugem	1, 2 e 3	Não	Naive
			Dist. Euclidiana
			Dist. Manhattan
			SAM
			SCM
Seca de Ponteiros	Sem distinção	Não	Naive
			Dist. Euclidiana
			Dist. Manhattan
			SAM
			SCM
Murcha de Ceratocystis	Sem distinção	Não	Naive
			Dist. Euclidiana
			Dist. Manhattan
			SAM
			SCM
Saudável	Sem distinção	2	Naive
			Dist. Euclidiana
			Dist. Manhattan
			SAM
			SCM

Fonte: Produzido pelo autor.

folhas de indivíduos saudáveis e doentes para serem analisadas em laboratório.

Com isso, foi possível obter imagens aéreas de plantações infectadas com Ferrugem, Seca de Ponteiros e Murcha de *Ceratocystis*, além de imagens de plantas saudáveis. Já as amostras colhidas são de árvores com Seca de Ponteiros, Murcha de *Ceratocystis*, três diferentes níveis de Ferrugem e de indivíduos saudáveis de duas plantações diferentes.

As imagens servem de entrada no processo do ADDSIGN, onde são tratadas para obtenção das assinaturas espectrais, de acordo com o que foi apresentado na Seção 5.5.

As amostras de folhas colhidas nas plantações foram levadas ao laboratório da EM-BRAPA Instrumentação, em São Carlos-SP para obtenção das reflectâncias por meio de um espectralradiômetro, conforme ilustrado na Figura 15.

Fazendo-se uso do espectralradiômetro, foram obtidas diversas amostras de assinaturas espectrais de indivíduos com as patologias ilustradas na Tabela 12. Para cada um desses indivíduos, foi armazenada uma assinatura seguindo o modelo apresentado na Seção 5.4.3, em uma base de dados MongoDB.

Essas amostras foram então submetidas aos algoritmos de classificação apresentados na Seção 5.4

Figura 14 – Planejamento de missão para aquisição de imagens de Ferrugem em Itatinga-SP.

Fonte: Arquivos do LSEC.

Figura 15 – Sistema para medir a reflectância de uma folha em laboratório.

Fonte: Arquivos do LSEC.

6.4 Tratamento de Imagens

O tratamento das imagens objetiva melhorar a discriminação dos objetos presentes na imagem, sendo que para isso foram utilizadas alguns índices e técnicas que serão descritos nesta seção.

Tabela 12 – Número de amostras de assinatura espectral obtidas para a realização do experimento.

Indivíduos	Total de amostras
Ferrugem Nível 1	41
Ferrugem Nível 2	37
Ferrugem Nível 3	33
Seca de Ponteiros	36
Murcha de <i>Ceratocystis</i>	30
Saudável (indivíduo 1)	34
Saudável (indivíduo 2)	22

Fonte: Produzido pelo autor.

6.4.0.1 NDVI

O NDVI (Normalized Difference Vegetation Index) é um índice de vegetação proposto por [Rouse Jr. et al. \(1974\)](#) que visa medir, por meio de sensoriamento remoto, a quantidade de biomassa em uma determinada área ou local e é amplamente utilizado para detectar problemas em plantações, como falta de água, falta de nutrientes ou ainda falhas no plantio. É calculado pela diferença do nível de reflectância entre as regiões do vermelho e do infravermelho próximo (NIR - Near infrared) no espectro eletromagnético. O valor do NDVI varia de -1 a 1, sendo que valores mais altos representam maior biomassa, enquanto valores mais baixos representam pouca ou nenhuma biomassa ([PONZONI; SHIMABUKURO, 2007](#)). Sendo assim, para verificar seu potencial para a detecção de doenças, foi implementado um programa para calcular o NDVI de imagens aéreas de plantações de eucalipto.

Sendo Nir e Red, respectivamente, as intensidades dos canais NIR e vermelho de um determinado pixel, o valor do NDVI para tal pixel é calculado de acordo com a Equação 6.1.

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (6.1)$$

Essa fórmula é aplicada para cada pixel na imagem, que são pintados de acordo com o valor do NDVI. Para melhor visualização foi utilizado o modelo Hue, Saturation, Value (HSV), no qual os valores de S e V foram fixados em 100% e o valor de H varia de acordo com o NDVI, ou seja, valores baixos de NDVI são representados em vermelho, enquanto valores altos são representados em magenta.

Na Figura 16 pode-se observar o mosaico em NIR de uma plantação de eucaliptos em Lençóis Paulista, SP, que possui árvores infectadas com Murcha de *Ceratocystis*, e a imagem em pseudo-cores resultante do cálculo do NDVI, sendo as regiões de solo (quase nenhuma biomassa) pintadas de vermelho, e as áreas de vegetação (alta biomassa) pintadas de verde. O uso do NDVI destacou apenas árvores que já estavam muito secas (pontos amarelos na imagem). Entretanto, as regiões de solo ficaram muito destacadas (regiões vermelhas na imagem), o que facilita o processo de segmentação das mesmas.

Figura 16 – Mosaicos de uma plantação de eucaliptos em Lençóis Paulista nos canais NIR-R-G (a) e a representação em pseudocores do NDVI (b).

Fonte: Produzido pelo autor.

6.4.0.2 Segmentação de solo e quantificação de áreas

Para extrair assinaturas espectrais com maior precisão, é interessante remover elementos indesejáveis da imagem, como regiões de solo, permitindo assim uma melhor identificação dos indivíduos. Com a segmentação de solo, é possível ainda calcular a área real de diferentes regiões da imagem, visto que os mosaicos são georreferenciados e que se conhece a resolução espacial das imagens, isto é, a área de cada pixel.

O cálculo de área de uma propriedade é importante para que impostos sejam cobrados corretamente, verificar se houve invasão de outras propriedades ou áreas de preservação, estimar a quantidade de água necessária para irrigação e também estimar a quantidade de plantas presentes ou áreas de falhas naquela região.

O NDVI, como descrito anteriormente, pode auxiliar na segmentação de áreas de solo e de vegetação, ou seja, a partir de uma imagem NIR de entrada, é possível dividi-la em imagens binárias representando somente as regiões de solo ou de vegetação. Por outro lado, os mosaicos obtidos pelo eBee são georreferenciados, isto é, possuem informação de coordenadas GPS e o tamanho dos pixels, e portanto podem ser utilizados para calcular áreas na imagem.

Para realizar a quantificação de áreas de solo e de vegetação, foi proposto o algoritmo ilustrado na Figura 17 (CHAVES et al., 2015). A primeira etapa é a aquisição das imagens, isto é, sobrevoar a área que se deseja medir e construir o mosaico, este é feito pelo software proprietário Postflight Terra 3D¹. A partir do mosaico NIR, é calculado o NDVI e é gerada uma imagem em pseudo-cores no modelo HSV de acordo com o método explicado anteriormente. A área utilizada para testar esse algoritmo foi um recorte do mosaico da Figura 16 e pode ser observada

¹ <https://www.sensefly.com/drones/postflight-terra-3d.html>

na Figura 18 juntamente com a imagem do NDVI em escala de cinza e em escala HSV.

Figura 17 – Algoritmo de quantificação de áreas de solo, baixa biomassa e alta biomassa

Fonte: Chaves et al. (2015).

Uma vez obtida a imagem HSV e dado que o valor de H é proporcional ao valor do NDVI, é feito um fatiamento das cores dessa imagem, sendo pixels vermelhos e amarelos representam solo, pixels verdes e cianos representam vegetação com baixa biomassa (e.g. grama ou vegetação rasteira), e pixels azuis e magentas representam vegetação com alta biomassa (e.g. árvores sadias). Este processo resulta em três imagens binárias representando áreas de: solo, baixa e alta biomassa. Contudo, há a ocorrência de certo ruído nessas imagens binárias e para removê-lo é utilizado um filtro da mediana 9x9. O resultado deste processo pode ser observado na Figura 19.

Figura 18 – (a) Área de estudo, (b) NDVI em escala de cinza e (c) NDVI em pseudo-cores

Fonte: [Chaves et al. \(2015\)](#).

Figura 19 – Resultado do fatiamento das cores para (a) solo, (b) baixa biomassa e (c) alta biomassa, ambos com a utilização do filtro de mediana.

Fonte: [Chaves et al. \(2015\)](#).

Finalmente, com as regiões de interesse já separadas e, uma vez que o tamanho do pixel é conhecido (no caso do eBee é um valor definido durante o planejamento da missão), o processo

de quantificação de áreas se torna simples: basta contar os pixels brancos em cada uma das três imagens e multiplicar pela resolução espacial. Assim, obtém-se uma estimativa do tamanho da área de solo, vegetação de baixa e de alta biomassa. Dado que a área de cada pixel é de 4 cm^2 , o resultado da quantificação de áreas para as Figuras 19(a), 19(b) e 19(c) podem ser observadas na Tabela 13.

Tabela 13 – Resultado da contagem de píxeis obtidos pelo algoritmo empregado e a conversão em unidades de medida m^2 e ha por classe.

Unidades	Solo	Baixa biomassa	Alta biomassa	Total
Pixel	799559	1920186	3773618	649363
m^2	1279.29	3072.3	6037.79	10389.38
ha	0.12	0.3	0.6	1.02

Fonte: Chaves et al. (2015).

6.4.1 Localização e contagem de eucaliptos

Outro dado importante que pode ser obtido com sensoriamento remoto é a localização georreferenciada das plantas. Para isso, precisa-se identificar cada indivíduo na imagem e cruzar os dados com as coordenadas do GPS de cada pixel. Além disso, identificar a posição das plantas permite contá-las de maneira mais precisa.

O método de contagem proposto é dividido em duas etapas: a primeira visa identificar árvores que estão relativamente longes umas das outras e, portanto, têm um formato mais definido; a segunda visa estimar quantas árvores estão em uma região onde as copas se misturam, dificultando a identificação de cada planta.

Os passos da primeira etapa podem ser observados na Figura 20. A imagem de entrada é apenas a imagem do canal NIR, onde é feita uma equalização do histograma para realçar árvores e solo; então é aplicado o algoritmo de **threshold** adaptativo para separar árvores do solo, resultando em uma imagem contendo apenas as regiões das copas. Entretanto, a maioria das copas está conectada. Para separá-las, são aplicados, em sequência, os algoritmos da distância transformada, **threshold** binário e abertura morfológica. A imagem resultante contém a maior parte das copas separadas e algumas regiões maiores, contendo mais de uma árvore.

Figura 20 – Primeiro estágio do método de contagem, onde as árvores são separadas umas das outras.

Fonte: Produzido pelo autor.

Separar completamente as árvores nesses agrupamentos é uma tarefa difícil. Portanto o que é feito é uma estimativa da quantidade de indivíduos nessa região. Para isso, primeiramente é traçado um retângulo envolvendo o grupo, e uma reta é traçada no centro desse retângulo, paralela ao maior lado. Então, baseando-se na resolução espacial da imagem, e no espaçamento médio entre as árvores, estima-se o número de plantas ao longo da linha. Esse processo pode ser observado na Figura 21.

Figura 21 – Segundo estágio do método de contagem, onde é feita uma estimativa da quantidade de árvores em um agrupamento.

Fonte: Produzido pelo autor.

Segundo (WILCKEN, 2008), em uma cultura de eucaliptos, as árvores são plantadas com espaçamento de 3m x 2m, e portanto, estima-se que em uma área de 1 hectare (10000 m²) são plantadas 1667 indivíduos. A área ilustrada na Figura 22 possui 2025 m², ou seja, estima-se que nessa área tenha 337 plantas, enquanto o método aqui proposto contou 342 árvores, sendo portanto, um resultado muito próximo do esperado.

Figura 22 – (a) imagem original contendo os canais verde, vermelho e NIR; (b) posição das árvores marcadas; (c) posição das árvores marcadas vistas na imagem original.

Fonte: Produzido pelo autor.

Conhecendo a posição de cada árvore na imagem, e as coordenadas de GPS de cada pixel, é possível cruzar os dados e obter as coordenadas geográficas de cada árvore. Com isso, produtores conseguem saber exatamente onde está cada planta e realizar tratamentos de forma mais precisa.

6.5 Extração das assinaturas espectrais

Com as imagens já tratadas, é necessário obter a curva de reflectância de cada árvore. Assumindo que o sensor seja calibrado corretamente, os valores de cada pixel são diretamente proporcionais a reflectância das respectivas bandas. Entretanto, os sensores disponíveis para este trabalho possuem apenas 4 bandas (azul, verde, vermelho e infra-vermelho próximo), fornecendo uma precisão radiométrica adequada para a detecção de problemas nas plantas, mas inadequada para o diagnóstico de patologias.

Sendo assim, foram implementados dois métodos, propostos por [Burns \(2015\)](#), para estimar a curva de reflectância a partir de uma tripla RGB. O Linear Least Squares (LLS) e o Least Slope Squared (LLS).

Na Figura 23 pode-se observar a reflectância resultante do método LLS, tendo como entrada quatro pixels: um branco, um preto, um de uma planta saudável e um de uma planta com Murcha de *Ceratocystis*. Pode-se observar que essa não é uma boa estimativa, visto que a reflectância do pixel branco não é máxima, e ainda foi gerado um gráfico de reflectância negativa, o que não é fisicamente possível.

Figura 23 – Resultados da conversão em reflectância usando LLS.

Fonte: Produzido pelo autor.

Já o método LSS se mostrou mais promissor, visto que a reflectância gerada para o pixel branco é máxima, e a parte negativa está muito próxima de zero. As curvas obtidas podem ser observadas na Figura 24.

Figura 24 – Resultados da conversão em reflectância usando LSS.

Fonte: Produzido pelo autor.

Em um outro teste, foi feita a conversão de determinadas regiões de interesse de imagens aéreas, sendo dois eucaliptos com *Ceratocystis*, dois eucaliptos saudáveis, uma região de solo e

grama, e uma região de sombra. Os resultados podem ser observados na Figura 25. É possível ver que há uma certa inconsistência, visto que a reflectância da região de solo se assemelha à reflectância de um dos indivíduos doentes.

Figura 25 – Resultados da conversão de regiões da imagem em reflectância usando LSS.

Fonte: Produzido pelo autor.

Com esse experimento, foi possível constatar que esses métodos de conversão de pixels em reflectância não são adequados para esse trabalho, visto que o diagnóstico de patologias necessita de uma maior precisão radiométrica. É possível também observar que para que as reflectâncias possam ser obtidas de forma efetiva, faz-se necessário o uso de uma câmera multi ou hiper-espectral.

6.6 Resultados Obtidos

Como não foi possível extrair, de forma precisa, as assinaturas espectrais das imagens para validar o ADDSIGN, foram utilizadas as reflectâncias obtidas pelo espectroradiômetro a partir das amostras de folhas colhidas em campo (uma vez que se possa então obter as informações a partir das imagens aéreas, o processo não se altera). Essas assinaturas foram então inseridas no processo do ADDSIGN como saída do módulo de processamento de imagens para serem diagnosticadas. Na Tabela 14 é possível observar a acurácia do diagnóstico para cada cenário definido na Seção 6.2

Pode-se observar que, com exceção de um caso, o algoritmo com maior índice de acertos foi o SCM, com o SAM ligeiramente pior. Enquanto na classificação de Ferrugem Nível 1, as melhores acurácias foram obtidas pelas distâncias Euclidiana e Manhattan e na classificação da classe Saudável (indivíduo 1), todos obtiveram os mesmos resultados.

Além disso, pode-se observar que na classificação de Ferrugem, quanto mais avançado o estágio da doença, mais correta foi a classificação. Isto é esperado, visto que quanto mais

Tabela 14 – Porcentagem de verdadeiros positivos obtidos por cada um dos algoritmos de classificação utilizados.

Patologia	Naive	Dist. Euclidiana	Dist. Manhattan	SAM	SCM
Saudável (indivíduo 1)	85.29%	85.29%	85.29%	85.29%	85.29%
Saudável (indivíduo 2)	68.18%	63.63%	63.63%	95.23%	95.23%
Ferrugem Nível 1	39.02%	58.53%	58.53%	48.78%	53.65%
Ferrugem Nível 2	62.16%	40.54%	51.35%	78.37%	78.37%
Ferrugem Nível 3	78.78%	81.81%	84.84%	96.96%	96.96%
Seca de Ponteiros	66.67%	50.00%	55.56%	77.78%	80.56%
Murcha de <i>Ceratocystis</i>	66.67%	86.67%	80.00%	100%	100%

Fonte: Produzido pelo autor

avançada, mais a Ferrugem altera a estrutura da planta, enquanto nos estágios mais iniciais, a Ferrugem não apresenta sintomas muito aparentes.

Esses resultados indicam que alguns algoritmos conseguem uma boa confiabilidade no diagnóstico de doenças de plantas, principalmente quando os sintomas estão mais aparentes.

6.7 Considerações Finais

Este capítulo apresentou a validação do ADDSIGN, o planejamento dos experimentos realizados, a coleta de dados e uma análise dos resultados obtidos em diferentes etapas do processo do ADDSIGN. Sendo assim, o próximo capítulo apresenta as conclusões obtidas bem como os trabalhos futuros.

CONCLUSÃO

O cultivo de eucalipto representa uma parte importante da economia nacional com extensas áreas plantadas. Entretanto, como qualquer planta, o eucalipto está suscetível a doenças que podem causar grandes prejuízos aos produtores. Para minimizar as perdas, produtores muitas vezes recorrem ao uso de defensivos agrícolas de forma desenfreada, causando danos ao meio ambiente. Sendo assim, é importante desenvolver métodos de detecção e diagnóstico precoce de doenças, permitindo um tratamento mais preciso e localizado.

Sistemas de detecção de intrusões vêm sendo utilizado há muitos anos para identificar ataques cibernéticos e programas maliciosos. Eles realizam o diagnóstico ao comparar um determinado evento com padrões conhecidos armazenados em uma base de dados.

Sendo assim, este trabalho teve como objetivo desenvolver um sistema de diagnóstico automático de doenças de eucaliptos. Para tal, foi desenvolvido o ADDSIGN, cujo funcionamento é baseado em sistemas de detecção de intrusões, realizando o diagnóstico comparando assinaturas espectrais obtidas por um VANT com assinaturas conhecidas.

Contudo, não foi possível validar o sistema utilizando imagens aéreas devido à baixa resolução espectral dos sensores disponíveis para o VANT. A validação foi então feita utilizando assinaturas obtidas por espectroradiômetros. Os resultados mostraram uma boa precisão no diagnóstico, com acurácias de até 96% em alguns casos. O que demonstra a viabilidade do método proposto.

Tendo em vista os resultados obtidos pelo método aqui proposto, em conjunto com os algoritmos de processamento de imagens desenvolvidos para filtrar elementos indesejados e evidenciar a localização geográfica das árvores. Acredita-se que o método pode ser aplicado em imagens de VANTs desde que os sensores sejam adequados.

Sendo assim, os objetivos iniciais foram cumpridos e o sistema desenvolvido serve de base para vários trabalhos, visando diagnósticos mais precisos e eficientes e que podendo ser

expandido para outras espécies.

7.1 Dificuldades Encontradas

A primeira dificuldade foi na obtenção das imagens aéreas. Visto que era necessário encontrar plantações de eucalipto contendo plantas doentes, conseguir permissão do proprietário para imagear a área, viajar até o local para fazer o trabalho de campo, analisar o melhor ponto para decolagem e pouso, realizar o voo, e, por fim, processar as imagens obtidas.

Outra dificuldade foi a falta de sensores adequados. As câmeras disponíveis para uso neste trabalho capturavam imagens em 3 ou 4 canais, enquanto espectrômetros de laboratório capturam 2048 canais. Visto que os recursos financeiros eram limitados, inviabilizando a obtenção de novos sensores hiperespectrais, foi feita uma tentativa de converter as imagens obtidas em reflectância, entretanto, para tal é preciso alguns dados do sensor que, muitas vezes, não são divulgados pelo fabricante. Portanto, não foi possível fazer essa conversão.

Uma dificuldade encontrada durante a implementação do projeto foi fazer a comparação de assinaturas com diferentes resoluções espectrais. É inviável fazer uma comparação ponto a ponto entre duas curvas de reflectância, uma vez que elas podem ter tamanhos diferentes. Sendo assim, foi desenvolvido um algoritmo para normalizar os tamanhos das assinaturas.

7.2 Contribuições

A principal contribuição deste trabalho é a especificação da arquitetura e desenvolvimento do ADDSIGN, um sistema de diagnóstico automático de doenças em eucaliptos baseado em sistemas de detecção de intrusões, além da especificação de um modelo de assinaturas espectrais. Assim, abre-se um caminho para realizar o diagnóstico de doenças de plantas de forma automatizada. Sendo assim, novas pesquisas podem ser realizadas com o intuito de aprimorar o sistema, melhorando a acurácia (com melhores sensores e algoritmos de classificação) e eficiência de recursos computacionais (com algoritmos menos custosos), permitindo que no futuro, este sistema possa ser embarcado em um VANT e a classificação possa ser feita em tempo real, enquanto ele sobrevoa a lavoura.

Neste trabalho também foram desenvolvidos algoritmos de processamento de imagens para contagem de árvores e quantificação de áreas de solo e vegetação, permitindo que agricultores tenham maiores informações sobre sua cultura. Esses algoritmos podem ainda ser usados para ajudar o diagnóstico de doenças, visto que podem ser utilizados para remover ruídos como o solo e outras plantas que podem ter crescido na área.

Além disso, este trabalho está inserido em um grupo de pesquisas que desenvolve arquiteturas, sistemas de controle e de comunicação para VANTs e serve como cenário de

aplicação para outros projetos do grupo, permitindo que esses trabalhos possam ser validados com uma aplicação real.

7.3 Produção intelectual

7.3.1 Publicações

Nesta seção serão listados os artigos produzidos e publicados durante este primeiro período do mestrado.

- Trabalhos publicados em periódicos:
 - PONTI, M.; CHAVES, ARTHUR A.; JORGE, FABIO R.; COSTA, GABRIEL B.P.; COLTURATO, ADIMARA; BRANCO, KALINKA R.L.J.C.. Precision Agriculture: Using Low-Cost Systems to Acquire Low-Altitude Images. *IEEE Computer Graphics and Applications*, v. 36, p. 14-20, 2016.
 - CHAVES, A. A.; LA SCALEA, R. A. ; COLTURATO, A. B. ; KAWABATA, C. L. O. ; FURTADO, E. L. ; BRANCO, K. R. L. J. CASTELO . Using UAVs and digital image processing to quantify areas of soil and vegetation. *Journal of Physics. Conference Series (Online)*, v. 633, p. 012112, 2015.
- Trabalhos completos publicados em anais de congressos:
 - CHAVES, A. A.; LA SCALEA, R. A. ; COLTURATO, A. B. ; KAWABATA, C. L. O. ; FURTADO, E. L. ; BRANCO, K. R. L. J. C. . Uso de VANTs e processamento digital de imagens para a quantificação de áreas de solo e de vegetação. In: XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2015, João Pessoa. Anais do XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR. São José dos Campos: INPE, 2015. p. 5642-5649.
 - CHAVES, A. A. ; COLTURATO, A. B. ; SOUZA, J. R. ; WOLF, D. F. ; FURTADO, E. L. ; BRANCO, K. R. L. J. C. . Índices de vegetação para detecção de murcha de *Ceratocystis* em eucaliptos - Um estudo utilizando vants. In: Simpósio Nacional de Instrumentação Agropecuária, 2014, São Carlos. SIAGRO - Ciência, Inovação e Mercado 2014. São Carlos: Embrapa Instrumentação, 2014. v. 1. p. 1-738.
 - PIRES, R. M. ; CHAVES, A. A. ; BRANCO, K. R. L. J. C. . Smart Sensor Protocol - a new standard for UAV and payload integration. In: International Conference on Unmanned Aircraft Systems (ICUAS), 2014, Orlando, FL. Proceedings of 2014 International Conference on Unmanned Aircraft Systems (ICUAS'14), 2014. p. 1300-1311.

- RODRIGUES, DOUGLAS ; CHAVES, ARTHUR A. ; BRANCO, KALINKA R. L. J. C. ; RAMDHANY, RAJIV ; COULSON, GEOFF . Knowledge Based Framework: A Case Study on Fast, Reliable, and Secure Web Services in UAVs. In: 2014 Eleventh International Conference on Information Technology: New Generations (ITNG), 2014, Las Vegas. 2014 11th International Conference on Information Technology: New Generations, 2014. p. 103-108.
- MARCONATO, E. A. ; RODRIGUES, D. ; CHAVES, A. A. ; BRANCO, K. R. L. J. C. ; RAMDHANY, R. ; COULSON, G. . Unmanned Aerial Vehicles & Service-Oriented Architecture: LARISSA and Knowledge Based Framework's First Study. In: The Tenth International Conference on Autonomic and Autonomous Systems (ICAS), 2014, Chamonix, France. Proceedings of the Tenth International Conference on Autonomic and Autonomous Systems (ICAS), 2014. p. 5-10.
- Resumos publicados em anais de congressos
 - COLTURATO, A. B. ; CHAVES, A. A. ; SOUZA, J. R. ; WOLF, D. F. ; FURTADO, E. L. ; BRANCO, K. R. L. J. C. . Uso de índices de vegetação para detecção de murcha de *Ceratocystis* em eucalipto.. In: 47º Congresso Brasileiro de Fitopatologia, 2014, Londrina. Anais do 47º Congresso Brasileiro de Fitopatologia, 2014. v. 47.

7.3.2 Participações em eventos

- Simpósio Nacional de Instrumentação Agropecuária - SIAGRO. Índices de vegetação para detecção de murcha de *Ceratocystis* em eucaliptos - Um estudo utilizando VANTS. 2014.

7.4 Sugestões de trabalhos futuros

Como complemento a este trabalho e suas contribuições, pode-se elencar alguns trabalhos futuros:

- Aplicar o método desenvolvido em imagens de VANTs obtidas por sensores de alta resolução espectral;
- Realizar análises de desempenho de diferentes bases de dados e dos algoritmos utilizados, além de analisar diferentes estratégias de busca das assinaturas, a fim de aumentar a eficiência da aplicação, para que no futuro, o diagnóstico possa ser feito em tempo real;
- Aplicar algoritmos de classificação mais modernos e eficientes, buscando uma maior precisão no diagnóstico;

- Ampliar o número de espécies, incluindo e aumentando o tamanho da base de dados de modo que seja possível o diagnóstico de uma diversidade maior de patologias em diferentes plantas.

REFERÊNCIAS

ALFENAS, A. C.; ZAUZA, E. A. V.; MAFIA, R. G.; ASSIS, T. F. d. Clonagem e doenças do eucalipto. Viçosa: Editora UFV, 2004. Citado na página 37.

AMAZON. What is NoSQL ? 2016. Acessado em 29/08/2016. Disponível em: <<https://aws.amazon.com/nosql/>>. Citado na página 32.

APACHE. What is Cassandra? 2016. Acessado em 29/08/2016. Disponível em: <<http://cassandra.apache.org/>>. Citado na página 32.

Apache Software Foundation. Thrift. 2014. Acessado em 04/02/2015. Disponível em: <<http://thrift.apache.org/>>. Citado na página 32.

APAN, a.; HELD, a.; PHINN, S.; MARKLEY, J. Detecting sugarcane ‘orange rust’ disease using EO-1 Hyperion hyperspectral imagery. *International Journal of Remote Sensing*, v. 25, n. January 2015, p. 489–498, 2004. ISSN 0143-1161. Citado na página 43.

AXELSSON, S. *Intrusion Detection Systems: A Survey and Taxonomy*. [S.l.], 2000. Citado nas páginas 26 e 27.

BERNI, J.; ZARCO-TEJADA, P.; SUAREZ, L.; FERERES, E. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. *Geoscience and Remote Sensing, IEEE Transactions on*, v. 47, n. 3, p. 722–738, March 2009. ISSN 0196-2892. Citado na página 45.

BRANCO, K. R. L. J. C. Contribuições na área de Sistemas Distribuídos e Redes de Computadores e suas aplicações em Sistemas Embarcados Críticos. Tese (Livre Docência em Redes de Computadores) — Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2012. Acessado em 04/02/2015. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/livredocencia/55/tde-10102012-103142/>>. Citado na página 22.

BRAVO, C.; MOSHOU, D.; WEST, J.; MCCARTNEY, A.; RAMON, H. Early disease detection in wheat fields using spectral reflectance. *Biosystems Engineering*, v. 84, n. 2, p. 137 – 145, 2003. ISSN 1537-5110. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1537511002002696>>. Citado nas páginas 40 e 41.

BURNS, S. A. *Generating Reflectance Curves from sRGB Triplets*. 2015. Acessado em 27/11/2016. Disponível em: <<http://scottburns.us/reflectance-curves-from-srgb/>>. Citado na página 68.

CALDERÓN, R.; MONTES-BORREGO, M.; LANDA, B. B.; NAVAS-CORTÉS, J. A.; ZARCO-TEJADA, P. J. Detection of downy mildew of opium poppy using high-resolution multi-spectral and thermal imagery acquired with an unmanned aerial vehicle. *Precision Agriculture*, p. 1–23, abr. 2014. ISSN 1385-2256, 1573-1618. Disponível em: <<http://link.springer.com/article/10.1007/s11119-014-9360-y>>. Citado nas páginas 46 e 47.

- CALDERÓN, R.; NAVAS-CORTÉS, J.; LUCENA, C.; ZARCO-TEJADA, P. 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. Cited By (since 1996)1. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84883497539&partnerID=40&md5=c6481e9b0f7cd1bf843b89218b2ae29d>>. Citado na página 46.
- CAMARGO, F. R. A.; TAKAHASHI, S. S.; FURTADO, E. L.; VALLE, C. F.; BONINE, C. A. v. Ocorrência e evolução da ferrugem do eucalipto em duas regiões do estado de são paulo. *Fitopatologia Brasileira*, v. 22, p. 254, 1997. Citado na página 37.
- CANSIAN, A.; SILVA, A. da; SOUZA, M. de. An attack signature model to computer security intrusion detection. In: *MILCOM 2002. Proceedings*. [S.l.: s.n.], 2002. v. 2, p. 1368–1373 vol.2. Citado nas páginas 29, 30, 31 e 54.
- CARROLL, M. W.; GLASER, J. A.; HELLMICH, R. L.; HUNT, T. E.; SAPPINGTON, T. W.; CALVIN, D.; COPENHAVER, K.; FRIDGEN, J. Use of spectral vegetation indices derived from airborne hyperspectral imagery for detection of european corn borer infestation in iowa corn plots. *Journal of Economic Entomology*, v. 101, n. 5, p. 1614–1623, 2008. Disponível em: <<http://www.ingentaconnect.com/content/esa/jee/2008/00000101/00000005/art00014>>. Citado na página 46.
- CARVALHO, O. D.; MENESES, P. Spectral correlation mapper (scm); an improvement on the spectral angle mapper (sam). In: *Summaries of the 9th JPL Airborne Earth Science Workshop*, JPL, Publication 00-18. [S.l.: s.n.], 2000. p. 9. Citado na página 54.
- CHAVES, A. A.; SCALEA, R. A. L.; COLTURATO, A. B.; KAWABATA, C. L. O.; FURTADO, E. L.; BRANCO, K. R. L. J. C. Uso de vants e processamento digital de imagens para a quantificação de áreas de solo e de vegetação. In: *São JOSé DOS CAMPOS - INPE. Anais do XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR*. João Pessoa, 2015. p. 5642–5649. Citado nas páginas 63, 64, 65 e 66.
- CISCO. *SNORT® Users Manual 2.9.7*. 2014. Acessado em 04/02/2015. Disponível em: <https://s3.amazonaws.com/snort-org-site/production/document_files/files/000/000/051/original/snort_manual.pdf>. Citado na página 25.
- COUTINHO, T. A.; WINGFIELD, M. J.; ALFENAS, A. C.; CROUS, P. W. Eucalyptus rust: A disease with the potential for serious international implications. *Plant Disease*, v. 82, p. 819–825, 1998. Citado na página 37.
- DAGDEE, N.; THAKAR, U. Intrusion attack pattern analysis and signature extraction for web services using honeypots. In: *Emerging Trends in Engineering and Technology*, 2008. ICETET '08. First International Conference on. [S.l.: s.n.], 2008. p. 1232–1237. Citado na página 28.
- DANYLIW, R.; HOUSEHOLDER, A. “Code Red” Worm Exploiting Buffer Overflow In IIS Indexing Service DLL. 2002. Artigo em hipertexto. Acessado em 22/10/2014. Disponível em: <<http://www.cert.org/historical/advisories/CA-2001-19.cfm>>. Citado na página 28.
- DEBAR, H.; CURRY, D.; FEINSTEIN, B. The Intrusion Detection Message Exchange Format (IDMEF). RFC 4765. 2007. Acessado em 19/11/2016. Disponível em: <<https://www.ietf.org/rfc/rfc4765.txt>>. Citado nas páginas 28, 29 e 30.

- DELALIEUX, S.; AARDT, J. van; KEULEMANS, W.; SCHREVE, E.; COPPIN, P. Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data: Non-parametric statistical approaches and physiological implications. *European Journal of Agronomy*, v. 27, n. 1, p. 130 – 143, 2007. ISSN 1161-0301. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1161030107000287>>. Citado na página 46.
- DIAZ-VARELA, R.; ZARCO-TEJADA, P.; ANGILERI, V.; LOUDJANI, P. Automatic identification of agricultural terraces through object-oriented analysis of very high resolution {DSMs} and multispectral imagery obtained from an unmanned aerial vehicle. *Journal of Environmental Management*, v. 134, n. 0, p. 117 – 126, 2014. ISSN 0301-4797. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0301479714000097>>. Citado na página 21.
- DOD. Unmanned Aerial Vehicles (UAV) Roadmap 2002-2027. Washington, DC, 2002. Citado na página 22.
- DOSSA, D.; SILVA, H. D. da; BELLOTE, A. F. J.; RODIGHIERI, H. R. *Produção e Rentabilidade do Eucalipto em Empresas Florestais*. Colombo, 2002. Citado na página 23.
- ECMA. The JSON Data Interchange Format. Rue du Rhône 114, Genebra, Suíça, 2013. Citado na página 31.
- ELDRIDGE, K.; DAVIDSON, J.; HARWOOD, C. *Eucalyptus domestication and breeding*. New York: Oxford University Press, 1994. P.288. Citado na página 23.
- EUMETRAIN. Monitoring Vegetation From Space. 2010. Acessado em 04/12/2014. Disponível em: <<http://www.eumetrain.org/data/3/36/print.htm>>. Citado na página 40.
- FERREIRA, F.; DEMUNER, A.; DEMUNER, M.; PIGATO, S. Murcha de ceratocystis em eucalipto no Brasil. *Fitopatologia Brasileira*, v. 24, p. 284, 1999. Citado na página 35.
- FERREIRA, F.; MAFFIA, L. A.; DEMUNER, N. L.; PIGATTO, S. Sintomatologia da murcha de ceratocystis fimbriata em eucalipto. *Revista Árvore*, Viçosa, MG, v. 30, p. 155–162, 2006. Citado na página 35.
- FERREIRA, F.; MAFFIA, L. A.; FERREIRA, E. A. Detecção rápida de ceratocystis fimbriata em lenho infestado de eucalipto, mangueira e outros hospedeiros lenhosos. *Fitopatologia Brasileira*, Brasília, v. 30, p. 543–545, 2005. Citado na página 36.
- FERREIRA, F. A. *Patologia florestal principais doenças florestais do Brasil*. Viçosa: Sociedade de Investigações Florestais, 1989. Citado na página 37.
- FERREIRA, F. A.; MILANI, D. *Diagnose visual e controle de doenças abióticas e bióticas do eucalipto no Brasil*. Mogi-Guaçu: International Paper, 2002. Citado na página 35.
- FIGUEIREDO, D. *Conceitos Básicos de Sensoriamento Remoto*. 1. ed. Brasília, DF, 2005. Acessado em 05/02/2015. Disponível em: <http://www.conab.gov.br/conabweb/download/SIGABRASIL/manuais/conceitos_sm.pdf>. Citado na página 40.
- FIGUEIREDO, M. B. Doenças fúngicas emergentes em grandes culturas. o biológico. *O Biológico*, v. 63, p. 29–32, 2001. Citado na página 37.
- FILIOL, G. J. D. Behavioral detection of malware: from a survey towards an established taxonomy. *Journal in Computer Virology*, v. 4, 2008. Citado na página 28.

- GARCIA-RUIZ, F.; SANKARAN, S.; MAJA, J.; LEE, W.; RASMUSSEN, J.; EHSANI, R. Comparison of two aerial imaging platforms for identification of huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture*, v. 91, p. 106–115, 2013. Cited By (since 1996)6. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84872461875&partnerID=40&md5=998977b6e531246f33bf9803a71ee4cb>>. Citado na página 46.
- GHIASI, M.; AMIRFATTAHI, R. Fast semantic segmentation of aerial images based on color and texture. In: *Machine Vision and Image Processing (MVIP), 2013 8th Iranian Conference on*. [S.l.: s.n.], 2013. p. 324–327. ISSN 2166-6776. Citado na página 21.
- GITELSON, A. A.; MERZLYAK, M. N. Signature analysis of leaf reflectance spectra: Algorithm development for remote sensing of chlorophyll. *Journal of Plant Physiology*, v. 148, n. 3–4, p. 494 – 500, 1996. ISSN 0176-1617. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0176161796802847>>. Citado na página 42.
- GONZALEZ, R.; WOODS, R. *Processamento de Imagens Digitais*. 3. ed. [S.l.]: Pearson, 2010. Citado na página 39.
- GOODWIN, N.; TURNER, R.; MERTON, R. Classifying eucalyptus forests with high spatial and spectral resolution imagery: an investigation of individual species and vegetation communities. *Australian Journal of Botany*, v. 53, p. 337=345, 2005. Citado na página 41.
- Google. Protocol Buffers. 2014. Acessado em 04/02/2015. Disponível em: <<https://developers.google.com/protocol-buffers/docs/overview>>. Citado na página 32.
- HARGRAVE, V. OSSEC in a Nutshell. 2013. Acessado em 04/02/2015. Disponível em: <http://vichargrave.com/securing-hadoop-with-ossec/#OSSEC_in_a_Nutshell>. Citado na página 25.
- HERNANDES, E.; ZAMBONI, A.; FABBRI, S.; THOMMAZO, A. A. D. Using GQM and TAM to evaluate StArt - a tool that supports Systematic Review. *CLEI Electronic Journal, scielouy*, v. 15, p. 3 – 3, 04 2012. ISSN 0717-5000. Disponível em: <http://www.scielo.edu.uy/scielo.php?script=sci_arttext&pid=S0717-50002012000100003&nrm=iso>. Citado na página 89.
- HETZEL, C. *Botryosphaeria*. 2002. Acessado em 09/10/2014. Disponível em: <<http://www.upenn.edu/paflora/plantclinic/botryosphaeria.htm>>. Citado na página 37.
- HOQUE, M. S.; MUKIT, M. A.; BIKAS, M. A. N. An implementation of intrusion detection system using genetic algorithm. *CoRR*, abs/1204.1336, 2012. Disponível em: <<http://arxiv.org/abs/1204.1336>>. Citado na página 28.
- HUNG, M. B. C.; SUKKARIEH, S. Vision-based shadow-aided tree crown detection and classification algorithm using imagery from an unmanned airborne vehicle. In: *34th International Symposium for Remote Sensing of the Environment*. [S.l.: s.n.], 2011. Citado na página 21.
- IBÁ. Relatório Anual 2016. São Paulo, SP, 2016. Citado na página 23.
- IZENBERG, N. R.; KLIMA, R. L.; MURCHIE, S. L.; BLEWETT, D. T.; HOLSCLAW, G. M.; MCCLINTOCK, W. E.; MALARET, E.; MAUCERI, C.; VILAS, F.; SPRAGUE, A. L.; HELBERT, J.; DOMINGUE, D. L.; III, J. W. H.; GOUDGE, T. A.; SOLOMON, S. C.; HIBBITTS, C. A.; DYAR, M. D. The low-iron, reduced surface of mercury as seen in spectral reflectance by {MESSENGER}. *Icarus*, v. 228, n. 0, p. 364 – 374, 2014. ISSN 0019-1035. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0019103513004521>>. Citado na página 42.

JR, E. R. H.; CAVIGELLI, M.; DAUGHTRY, C. S. T.; III, J. E. M.; WALTHALL, C. L. 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, ago. 2005. ISSN 1385-2256, 1573-1618. Disponível em: <<http://link.springer.com/article/10.1007/s11119-005-2324-5>>. Citado na página 44.

KITCHENHAM, B.; CHARTERS, S. Guidelines for performing Systematic Literature Reviews in Software Engineering. [S.l.], 2007. Disponível em: <<http://www.dur.ac.uk/ebse/resources/Systematic-reviews-5-8.pdf>>. Citado nas páginas 43, 89 e 90.

KOBAYASHI, T.; KANDA, E.; KITADA, K.; ISHIGURO, K.; TORIGOE, Y. Detection of rice panicle blast with multispectral radiometer and the potential of using airborne multispectral scanners. *Phytopathology*, Scientific Societies, v. 91, p. 316–323, 2001. ISSN 0031-949X. Disponível em: <<http://dx.doi.org/10.1094/PHYTO.2001.91.3.316>>. Citado na página 46.

KRAUSE, E. *Taxicab Geometry: An Adventure in Non-Euclidean Geometry*. Dover Publications, 1975. (Dover Books on Mathematics Series). ISBN 9780486252025. Disponível em: <<https://books.google.com.br/books?id=IW7ICV0QXWwC>>. Citado na página 53.

KRUSE, F.; LEFKOFF, A.; BOARDMAN, J.; HEIDEBRECHT, K.; SHAPIRO, A.; BARLOON, P.; GOETZ, A. The spectral image processing system (sips)—interactive visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment*, v. 44, n. 2, p. 145 – 163, 1993. ISSN 0034-4257. Citado na página 53.

LALIBERTE, A. S.; GOFORTH, M. A.; STEELE, C. M.; RANGO, A. Multispectral remote sensing from unmanned aircraft: Image processing workflows and applications for rangeland environments. *Remote Sensing*, v. 3, n. 11, p. 2529–2551, 2011. ISSN 2072-4292. Disponível em: <<http://www.mdpi.com/2072-4292/3/11/2529>>. Citado na página 45.

LASKOV, K. R. Language models for detection of unknown attacks in network traffic. *Journal in Computer Virology*, v. 2, 2007. Citado na página 28.

LEHTI, R.; HABER, M.; BERG, R. van den. The AIDE manual. 2013. Acessado em 04/02/2015. Disponível em: <<http://aide.sourceforge.net/stable/manual.html>>. Citado na página 25.

LI, F.; MISTELE, B.; HU, Y.; CHEN, X.; SCHMIDHALTER, U. Reflectance estimation of canopy nitrogen content in winter wheat using optimised hyperspectral spectral indices and partial least squares regression. *European Journal of Agronomy*, v. 52, Part B, n. 0, p. 198 – 209, 2014. ISSN 1161-0301. Citado na página 42.

MAHLEIN, A.-K.; OERKE, E.-C.; STEINER, U.; DEHNE, H.-W. Recent advances in sensing plant diseases for precision crop protection. *European Journal of Plant Pathology*, v. 133, n. 1, p. 197–209, maio 2012. ISSN 0929-1873, 1573-8469. Disponível em: <<http://link.springer.com/article/10.1007/s10658-011-9878-z>>. Citado na página 46.

MAHLEIN, A.-K.; STEINER, U.; DEHNE, H.-W.; OERKE, E.-C. Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. *Precision Agriculture*, Springer US, v. 11, n. 4, p. 413–431, 2010. ISSN 1385-2256. Disponível em: <<http://dx.doi.org/10.1007/s11119-010-9180-7>>. Citado na página 46.

- MAHLEIN, A.-K.; STEINER, U.; HILLNHUTTER, C.; DEHNE, H.-W.; OERKE, E.-C. Hyperspectral imaging for small-scale analysis of symptoms caused by different sugar beet diseases. *Plant Methods*, v. 8, n. 1, p. 3, 2012. ISSN 1746-4811. Disponível em: <<http://www.plantmethods.com/content/8/1/3>>. Citado nas páginas 40 e 41.
- MARINO, G.; PALLOZZI, E.; COCOZZA, C.; TOGNETTI, R.; GIOVANNELLI, A.; CANTINI, C.; CENTRITTO, M. Assessing gas exchange, sap flow and water relations using tree canopy spectral reflectance indices in irrigated and rainfed olea europaea l. *Environmental and Experimental Botany*, v. 99, n. 0, p. 43 – 52, 2014. ISSN 0098-8472. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S009884721300155X>>. Citado na página 42.
- Mendeley Ltd. What is Mendeley? 2015. Acessado em 04/02/2015. Disponível em: <<http://www.mendeley.com/features/>>. Citado na página 89.
- MONGODB, I. Introduction to MongoDB. 2016. Acessado em 29/08/2016. Disponível em: <<https://docs.mongodb.com/manual/introduction/>>. Citado na página 32.
- MORAES, S. A. de. Quantificação de doenças de plantas. 2007. Artigo em Hypertexto. 2007. Acessado em 26/09/2014. Disponível em: <http://www.infobibos.com/Artigos/2007_1/doencas/index.htm>. Citado na página 21.
- MORANDUZZO, T.; MELGANI, F. Automatic car counting method for unmanned aerial vehicle images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 52, n. 3, p. 1635–1647, March 2014. ISSN 0196-2892. Citado na página 21.
- MORIN, B.; Mé, L. Intrusion detection and virology: an analysis of differences, similarities and complementariness. *Journal in Computer Virology*, Springer-Verlag, v. 3, n. 1, p. 39–49, 2007. ISSN 1772-9890. Disponível em: <<http://dx.doi.org/10.1007/s11416-007-0036-2>>. Citado na página 28.
- MUHAMMED, H. H. Hyperspectral crop reflectance data for characterising and estimating fungal disease severity in wheat. *Biosystems Engineering*, v. 91, p. 9–20, 2005. ISSN 15375110. Citado na página 44.
- NAIDU, R. A.; PERRY, E. M.; PIERCE, F. J.; MEKURIA, T. The potential of spectral reflectance technique for the detection of grapevine leafroll-associated virus-3 in two red-berried wine grape cultivars. *Computers and Electronics in Agriculture*, v. 66, n. 1, p. 38 – 45, 2009. ISSN 0168-1699. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0168169908002299>>. Citado na página 46.
- NAUE, C.; MARQUES, M.; LIMA, N.; GALVINCIO, J. Sensoriamento remoto como ferramenta aos estudos de doenças de plantas agrícolas: uma revisão. *Revista Brasileira de Geografia Física*, v. 03, p. 190–195, 2010. Citado nas páginas 22 e 40.
- NOVO, E. d. M. *Sensoriamento remoto: princípios e aplicações*. São Paulo: Edgard Blucher, 1989. 308p. Citado na página 22.
- NURSEITOV, N.; PAULSON, M.; REYNOLDS, R.; IZURIETA, C. Comparison of json and xml data interchange formats: A case study. In: *CAINE'09*. [S.l.: s.n.], 2009. p. 157–162. Citado nas páginas 31 e 32.

- OTT, N.; KOLLERSBERGER, T.; TASSARA, A. Gis analyses and favorability mapping of optimized satellite data in northern chile to improve exploration for copper mineral deposits. *Geosphere*, v. 2, n. 4, p. 236–252, 2006. Disponível em: <<http://geosphere.gsapubs.org/content/2/4/236.abstract>>. Citado na página 42.
- OWEZARSKI, P.; MAZEL, J.; LABIT, Y. Oday anomaly detection made possible thanks to machine learning. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, v. 6074 LNCS, p. 327–338, 2010. Cited By (since 1996)0. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-77953764785&partnerID=40&md5=497ab591b31b45d0b7d2d95649d8f0f2>>. Citado na página 28.
- PONZONI, F.; SHIMABUKURO, Y. *Sensoriamento Remoto no Estudo da Vegetação*. São José dos Campos, SP: Editora Parêntese, 2007. Citado na página 62.
- REHMAN, R. U. *Intrusion Detection with SNORT: Advanced IDS Techniques Using SNORT, Apache, MySQL, PHP, and ACID*. [S.l.]: Prentice Hall, 2003. (Bruce Perens' Open Source Series). ISBN 0-13-140733-3. Citado nas páginas 21, 25, 26 e 27.
- REID, A.; RAMOS, F.; SUKKARIEH, S. Multi-class classification of vegetation in natural environments using an unmanned aerial system. In: *2011 IEEE International Conference on Robotics and Automation (ICRA)*. [S.l.: s.n.], 2011. p. 2953–2959. ISSN 1050-4729. Citado na página 21.
- ROSENBERG, J.; REMY, D. *Securing web services with ws-security: Demystifying ws-security, ws-policy, saml, xml signature, and xml encryption*. [S.l.]: Pearson Higher Education, 2004. Citado na página 31.
- Rouse JR., J. W.; Haas, R. H.; Schell, J. A.; Deering, D. W. Monitoring Vegetation Systems in the Great Plains with Ert. *NASA Special Publication*, v. 351, p. 309, 1974. Citado na página 62.
- SANFILIPPO, S. *Introduction to Redis*. 2016. Acessado em 29/08/2016. Disponível em: <<http://redis.io/topics/introduction>>. Citado na página 32.
- SANTOS, A. F.; AUER, C. G.; JÚNIOR, A. G. *Doenças do eucalipto no sul do Brasil: identificação e controle*. Colombo, 2001. Citado nas páginas 23 e 38.
- SCARFONE, K. A.; MELL, P. M. *Guide to Intrusion Detection and Prevention Systems (IDPS)*. [S.l.], 2007. Acessado em 20/10/2014. Disponível em: <http://www.nist.gov/manuscript-publication-search.cfm?pub_id=50951>. Citado nas páginas 21 e 25.
- SENSEFLY. *Browse our camera payloads & accessories*. 2014. Acessado em 10/12/2014. Disponível em: <<https://www.sensefly.com/drones/accessories.html>>. Citado na página 50.
- SHASHIKANT, V.; SHARIFF, A. b.; NOURQOLIPOUR, R. Integration of uav with stress detection lens for oil palm plantation stress monitoring. In: . [s.n.], 2013. v. 4, p. 2874–2877. Cited By (since 1996)0. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84903449840&partnerID=40&md5=0c1324496fa0f46185df8e48c0d26003>>. Citado na página 47.
- SMITH, R. B. *Introduction to Remote Sensing of Environment (RSE)*. 2012. Acessado em 19/01/2015. Disponível em: <<http://www.microimages.com/documentation/Tutorials/introrse.pdf>>. Citado nas páginas 39 e 40.

- SUGIURA, R.; NOGUCHI, N.; ISHII, K. Remote-sensing technology for vegetation monitoring using an unmanned helicopter. *Biosystems Engineering*, v. 90, n. 4, p. 369 – 379, 2005. ISSN 1537-5110. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1537511004002296>>. Citado na página 44.
- SUMARAY, A.; MAKKI, S. K. A comparison of data serialization formats for optimal efficiency on a mobile platform. In: *Proceedings of the 6th International Conference on Ubiquitous Information Management and Communication*. New York, NY, USA: ACM, 2012. (ICUIMC '12), p. 48:1–48:6. ISBN 978-1-4503-1172-4. Disponível em: <<http://doi.acm.org/10.1145/2184751.2184810>>. Citado na página 32.
- SYMANTEC. *Attack Signatures*. 2014. Acessado em 21/10/2014. Disponível em: <http://www.symantec.com/security/_response/attacksignatures/>. Citado na página 27.
- TSAI, D.-R.; HUANG, C.-N. A signature exchange model for heterogeneous intrusion detection systems. In: *Security Technology, 2009. 43rd Annual 2009 International Carnahan Conference on*. [S.l.: s.n.], 2009. p. 253–256. Citado na página 28.
- W3C. *Extensible markup language (xml)*. 2008. Acessado em 22/10/2014. Disponível em: <<http://www.w3.org/XML/>>. Citado na página 31.
- _____. *Namespaces in XML 1.0 (Third Edition)*. 2009. Acessado em 22/10/2014. Disponível em: <<http://www.w3.org/TR/REC-xml-names/>>. Citado na página 32.
- WCSS. *Alert Correlation, Assessment and Reaction Module - next generation*. 2010. Acessado em 04/02/2015. Disponível em: <<http://www.acarm.wcss.wroc.pl/index.php>>. Citado na página 25.
- WICHMANN, R. *The Samhain HIDS - Overview of available features*. 2011. Acessado em 04/02/2015. Disponível em: <http://la-samhna.de/samhain/samhain_leaf.pdf>. Citado na página 25.
- WILCKEN, C. F. *Percevejo bronzeado do eucalipto (Thaumastocoris peregrinus) (Hemiptera: Thaumastocoridae): ameaça às florestas de eucalipto brasileiras*. [S.l.], 2008. Acessado em 10/10/2014. Disponível em: <<http://www.ipef.br/protecao/alerta-percevejo.pdf>>. Citado na página 67.
- WU, L.; ZHANG, Y. Automatic detection model of malware signature for anti-virus cloud computing. In: *Computer and Information Science (ICIS), 2011 IEEE/ACIS 10th International Conference on*. [S.l.: s.n.], 2011. p. 73–75. Citado na página 28.
- YAN, X.; SHI, W.; ZHAO, W.; LUO, N. Estimation of protein content in plant leaves using spectral reflectance: A case study in euonymus japonica. *Analytical Letters*, v. 47, n. 3, p. 517–530, 2014. Citado na página 42.
- YANG-BO; MING-GUANGZHOU, O. Y. Isdtm: An intrusion signatures description temporal model. *Wuhan University Journal of Natural Sciences*, v. 8, 2003. Citado na página 28.
- YU, Z.-X.; CHEN, J.-R.; ZHU, T.-Q. A novel adaptive intrusion detection system based on data mining. In: *Machine Learning and Cybernetics, 2005. Proceedings of 2005 International Conference on*. [S.l.: s.n.], 2005. v. 4, p. 2390–2395 Vol. 4. Citado na página 28.

ZAMBONI, D. Using Internal Sensors for Computer Intrusion Detection. Tese (Doutorado) — Purdue University, West Lafayette, IN, August 2001. Disponível em: <<https://www.cerias.purdue.edu/papers/archive/2001-42.pdf>>. Citado na página 25.

ZHANG, B.; YANG, J.-H.; WU, J.-P.; ZHU, Y.-W. Diagnosing traffic anomalies using a two-phase model. *Journal of Computer Science and Technology*, Springer US, v. 27, n. 2, p. 313–327, 2012. ISSN 1000-9000. Disponível em: <<http://dx.doi.org/10.1007/s11390-012-1225-0>>. Citado na página 28.

ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture*, v. 13, n. 6, p. 693–712, dez. 2012. ISSN 1385-2256, 1573-1618. Disponível em: <<http://link.springer.com/article/10.1007/s11119-012-9274-5>>. Citado na página 45.

ZHANG, M.; QIN, Z.; LIU, X.; USTIN, S. L. Detection of stress in tomatoes induced by late blight disease in California, USA, using hyperspectral remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, v. 4, n. 4, p. 295–310, nov. 2003. ISSN 03032434. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-1342309628&partnerID=tZOtx3y1>>. Citado na página 46.

ZONG, D.; MAO, G.; WU, X. An intrusion detection model based on mining data streams. In: . [s.n.], 2008. p. 398–403. Cited By (since 1996)0. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-62649088010&partnerID=40&md5=d3a8e3ca51f007625a869dc38d0d6b5e>>. Citado na página 28.

REVISÃO SISTEMÁTICA

A.1 Planejamento

Neste projeto, o processo de revisão sistemática foi realizado com o auxílio das ferramentas [Mendeley](#) ([Mendeley Ltd, 2015](#)) e [State of the Art through Systematic Review](#) (StArt) ([HERNANDES et al., 2012](#)). A primeira é um gerenciador de referências enquanto a segunda é uma ferramenta que oferece todo o suporte necessário para se executar uma revisão sistemática.

A primeira etapa de uma revisão sistemática é o planejamento. Nela são definidos os objetivos, as questões, as fontes de busca e os critérios de seleção. A etapa de planejamento é importante para reduzir a possibilidade do investigador que está realizando a revisão sistemática ser tendencioso ([KITCHENHAM; CHARTERS, 2007](#)).

A.1.1 Objetivos

Os principais objetivos desta revisão sistemática são:

- Identificar trabalhos que fazem a detecção de patologias em plantas por meio de sensoriamento remoto utilizando VANTs;
- Identificar trabalhos que utilizam informações de reflectância para identificar diferentes patologias;
- Identificar trabalhos que fazem o diagnóstico automático de doenças de plantas.

A.1.2 Questões

Uma das atividades mais importantes da etapa de planejamento é a formulação das questões que se pretende responder com a execução da revisão sistemática ([KITCHENHAM;](#)

CHARTERS, 2007). Essas respostas ajudam a analisar o foco da pesquisa e tirar conclusões sobre o tema em questão. As questões levantadas nesta revisão sistemática foram:

1. Existem trabalhos que fazem uso de VANTs para detecção e/ou identificação de patologias em plantas?
2. Existem trabalhos que fazem algum processo automático de identificação dessas doenças?

A.1.3 Seleção das fontes

Para definir as fontes de busca da revisão sistemática foram estabelecidos alguns critérios: Cobertura (fontes que abranjam um grande número de revistas e conferências), conteúdo atualizado (fontes que retornam trabalhos recentes) e disponibilidade (fontes que permitam o acesso de forma íntegra). Sendo assim, foram escolhidas as seguintes bases de busca:

- IEEEExplore Digital Library;
- Scopus;
- ACM Digital Library;
- Springer.

Além dessas fontes, foram incluídos trabalhos sugeridos por especialistas que são relevantes para este projeto de mestrado. Para fins de análise e seleção de resultados, todos os trabalhos sugeridos serão tratados como provenientes de uma fonte de buscas denominada “sugestões de especialistas”.

A.1.4 Seleção dos estudos

Com as fontes de busca já definidas, inicia-se a última etapa do planejamento, a seleção de estudos, na qual são definidos as palavras-chave, critérios de inclusão e exclusão de trabalhos e como serão feitas a seleção de trabalhos e a análise de resultados.

A.1.4.1 Palavras-chave

Foram definidas as seguintes palavras-chave e respectivos sinônimos:

- Detecção: detection identification, detecting, identifying
- Doenças: disease, infection, pathology, stress
- Plantas: plant, tree, crop, plantation, vegetation, eucalyptus
- VANTs: uav, unmanned aerial vehicle, drone

A.1.4.2 Critérios de inclusão

Tendo como base os objetivos da pesquisa, foram definidos os seguintes critérios de inclusão de trabalhos, isto é, trabalhos que se enquadraram em algum desses critérios são incluídos no processo de revisão. Os critérios de inclusão definidos são:

- (I-1): Estudos que utilizam VANTs;
- (I-2): Estudos que envolvam esforços na detecção de doenças em plantas;
- (I-3): Estudos que envolvam esforços na identificação de doenças em plantas;
- (I-4): Estudos que utilizam informações de reflectância para identificar e/ou detectar doenças.

A.1.4.3 Critérios de exclusão

Tendo como base os objetivos da pesquisa, foram definidos os critérios de exclusão de trabalhos, isto é, trabalhos que se enquadraram em algum desses critérios são excluídos do processo de revisão.

Os critérios de exclusão definidos são:

- (E-1): Estudos cujo foco não estejam voltados para a detecção de doenças;
- (E-2): Estudos cujo foco não estejam voltados para a identificação de doenças;
- (E-3): Estudos em que não seja possível o acesso na íntegra do artigo;
- (E-4): Estudos que estejam em idiomas diferentes do inglês ou do português;
- (E-5): Estudos que não sejam completos (resumos).

A.1.4.4 Procedimentos para selecionar os estudos

O processo de seleção de trabalhos e análise de resultados da revisão sistemática está dividido nas seguintes etapas:

- **Processo de busca:** primeiramente, foram criadas as **strings** de busca baseando-se nas palavras-chave definidas anteriormente. Essas **strings** foram então aplicadas nas ferramentas de busca das bases de dados selecionadas.
- **Processo de seleção inicial:** Aplicou-se então uma filtragem inicial dos resultados das buscas, excluindo trabalhos duplicados e/ou que não permitem o acesso ao texto completo. Em seguida foi realizada a leitura do título e **abstract** de todos os trabalhos e verificou-se os critérios de inclusão e exclusão para esses trabalhos. Os trabalhos que passaram na seleção inicial foram submetidos à seleção final.

- **Processo de seleção final:** nesta etapa foi realizada a leitura completa dos trabalhos, permitindo assim, uma análise mais detalhada do conteúdo dos mesmos.
- **Extração dos resultados:** por fim foi elaborado uma síntese dos trabalhos que passaram na última seleção de forma a se obter uma análise crítica de cada publicação e identificar lacunas na área de detecção de doenças utilizando VANTs.

A.2 Execução

O execução da revisão sistemática está dividida em três etapas: construção das strings de busca e resultados das buscas.

A.2.1 Construção das strings de busca

As strings de busca baseadas nas palavras-chave foram executadas nas ferramentas de busca das diferentes bases escolhidas. O operador lógico AND foi utilizado para agrupar termos diferentes, enquanto o operador lógico OR foi utilizado para agrupar sinônimos.

As strings de busca correspondem a:

- **IEEEExplore Digital Library:** ((“Document Title”: plant OR “Document Title”: tree OR “Document Title”: crop OR “Document Title”: plantation OR “Document Title”: vegetation OR “Document Title”: eucalyptus) AND (“Document Title”: disease OR “Document Title”: infection OR “Document Title”: pathology OR “Document Title”: stress) AND (“Document Title”: detection OR “Document Title”: identification OR “Document Title”: monitoring) AND (“Document Title”: uav OR “Document Title”: drone OR “Document Title”: “unmanned aerial vehicle”)) OR ((“Abstract”: plant OR “Abstract”: tree OR “Abstract”: crop OR “Abstract”: plantation OR “Abstract”: vegetation OR “Abstract”: eucalyptus) AND (“Abstract”: disease OR “Abstract”: infection OR “Abstract”: pathology OR “Abstract”: stress) AND (“Abstract”: detection OR “Abstract”: identification OR “Abstract”: monitoring) AND (“Abstract”: uav OR “Abstract”: drone OR “Abstract”: “unmanned aerial vehicle”))
- **Springer:** ‘((plant OR tree OR crop OR plantation OR vegetation OR eucalyptus) AND (disease OR infection OR pathology OR stress) AND (detection OR identification OR monitoring) AND (uav OR drone OR "unmanned aerial vehicle"))’ within Agriculture Article
- **ACM Digital Library:** Title:((plant OR tree OR crop OR plantation OR vegetation OR eucalyptus) AND (disease OR infection OR pathology OR stress) AND (detection OR identification OR monitoring) AND (uav OR drone OR "unmanned aerial vehicle")) OR Abstract:((plant OR tree OR crop OR plantation OR vegetation OR eucalyptus) AND

(disease OR infection OR pathology OR stress) AND (detection OR identification OR monitoring) AND (uav OR drone OR "unmanned aerial vehicle"))

- **Scopus:** TITLE-ABS-KEY((plant OR tree OR crop OR plantation OR vegetation OR eucalyptus) AND (disease OR infection OR pathology OR stress) AND (detection OR identification OR monitoring) AND (uav OR drone OR "unmanned aerial vehicle"))

A.2.2 Resultados das buscas

As buscas foram executadas nas bases mencionadas com as respectivas **strings** de busca, os resultados foram salvos no formato **Bibtex** e importados para a ferramenta StArt. No total foram importados 85 trabalhos, incluindo os trabalhos sugeridos, entretanto, a busca na ACM Digital Library não retornou nenhum resultado. A proporção de trabalhos encontrados em cada base está ilustrada na Figura 26.

Figura 26 – Artigos encontrados nas bases de dados.

Fonte: Produzido pelo autor.

A primeira seleção se deu pela remoção de trabalhos duplicados e pela leitura do título e resumo de todos os trabalhos restantes, sendo que os trabalhos foram aceitos ou rejeitados de acordo com os critérios de inclusão e exclusão definidos na Seção A.1.4. A quantidade de artigos duplicados, aceitos e rejeitados na primeira seleção pode ser observada na Figura 27.

A segunda seleção se deu pela leitura completa dos 34 trabalhos aceitos na primeira seleção. Utilizando os mesmos critérios de inclusão e exclusão, esta etapa resultou em 12 artigos aceitos e 22 artigos rejeitados. A distribuição dos artigos aceitos de acordo com a fonte está ilustrada na Figura 28.

Figura 27 – Artigos aceitos após a primeira seleção.

Fonte: Produzido pelo autor.

Figura 28 – Quantidade de artigos aceitos em cada base após a seleção final

Fonte: Produzido pelo autor.