

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**MATHEUS OLIVEIRA SOUZA**

**PROPOSTA DE UM MÉTODO DE  
SUPERFÍCIE DE BIOIMPEDÂNCIA  
PARA AVALIAR A SAÚDE DE  
CULTIVOS**

Porto Alegre  
2024

**MATHEUS OLIVEIRA SOUZA**

**PROPOSTA DE UM MÉTODO DE  
SUPERFÍCIE DE BIOIMPEDÂNCIA  
PARA AVALIAR A SAÚDE DE  
CULTIVOS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Rio Grande do Sul como parte dos requisitos para a obtenção do título de Doutor em Engenharia Elétrica.

Área de concentração: Controle e Automação

ORIENTADOR: Prof. Dr. Valner João Brusamarello

Porto Alegre  
2024

**MATHEUS OLIVEIRA SOUZA**

**PROPOSTA DE UM MÉTODO DE  
SUPERFÍCIE DE BIOIMPEDÂNCIA  
PARA AVALIAR A SAÚDE DE  
CULTIVOS**

Esta tese foi julgada adequada para a obtenção do título de Doutor em Engenharia Elétrica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: \_\_\_\_\_

Prof. Dr. Valner João Brusamarello, UFRGS

Doutor pela Universidade Federal de Santa Catarina - Florianópolis, Brasil

Banca Examinadora:

Prof. Dr. Alexandre Balbinot, UFRGS

Doutor pela Universidade Federal do Rio Grande do Sul - Porto Alegre, Brasil

Prof. Dr. Raimundo Carlos Silvério Freire, UFCG

Doutor pelo *Institut National Polytechnique de Lorraine* - Nancy, França

Prof. Dr. Sebastian Yuri Cavalcanti Catunda, UFRN

Doutor pela Universidade Federal de Campina Grande - Campina Grande, Brasil

Coordenador do PPGEE: \_\_\_\_\_

Prof. Dr. Jeferson Vieira Flores, UFRGS

Porto Alegre, setembro de 2024.

## **DEDICATÓRIA**

Dedico este trabalho a Deus, por tudo que Ele é e pelo amor incondicional que Ele tem por mim.

## AGRADECIMENTOS

Em primeiro lugar, sou grato a Deus por toda a ajuda que Ele me concedeu durante a realização deste trabalho. Sem Ele, seria impossível concluir esta tese.

Agradeço à minha esposa Karine, que me apoiou e acompanhou durante toda essa trajetória e renunciou a muitas coisas para que, juntos, alcançássemos essa conquista. Agradeço também aos meus pais (Geraldo e Mariene) e ao meu irmão (Geraldo Júnior), que sempre me apoiaram em tudo. Essa conquista não é minha, ela é nossa! Agradeço às minhas sobrinhas, Clarice e Melinda, por toda a alegria que nos proporcionaram em diversos momentos difíceis. Agradeço também à mamãe delas, minha cunhada Andreza, pelo apoio concedido. Sou grato também aos meus sogros (Luiz e Selma) e cunhados (Fernando e Kálita) por todo apoio e pelo tempo que deixei Karine distante de vocês.

Agradeço ao meu orientador por todo o apoio, dedicação e paciência durante o desenvolvimento deste trabalho. Sou grato ao PPGEE da UFRGS pela oportunidade de realizar o doutorado. Agradeço também à Miriam, secretária do PPGEE, por toda a dedicação e disponibilidade.

Expresso também minha gratidão aos professores membros da banca examinadora pelas valiosas contribuições.

Gostaria de registrar um agradecimento especial ao professor Dr. Elyson Carvalho, por todo o auxílio e coorientação em todas as etapas deste trabalho. Expresso também minha gratidão ao professor Dr. Frederico de Oliveira, por todo o auxílio e coorientação no desenvolvimento deste trabalho e na condução dos experimentos.

Sou grato aos amigos do LSI - UFRGS, do LABIM - UFS e do DEL - UFS. Agradeço também aos professores do Departamento de Engenharia Elétrica da UFS pela permissão para utilizar as instalações e recursos do departamento, que foram fundamentais para a realização desta pesquisa, especialmente ao professor Dr. Oscar Sotomayor.

Agradeço também à CAPES, pois o presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

## RESUMO

As doenças e pragas em plantas têm implicado em perdas consideráveis na produção agrícola mundial. Isso tem impulsionado o desenvolvimento de ferramentas capazes de detectar previamente a presença de agentes nocivos à saúde das plantas. Apesar dos avanços significativos no desenvolvimento de sistemas para avaliar o estado de saúde das plantas, observa-se que existem algumas limitações que dificultam o emprego desses sistemas em campo. Em particular, uma abordagem promissora para a detecção precoce de doenças em plantas é a medição da bioimpedância dos tecidos vegetais, que permite identificar sinais de estresse nas fases iniciais da infecção. Embora alguns autores considerem a bioimpedância como a abordagem com maior potencial para a detecção precoce de doenças e estresses em plantas, a sensibilidade dessa técnica às variáveis ambientais tem dificultado sua aplicação prática em campo. Esta tese apresenta uma nova abordagem, denominada Superfície de Impedância, que consiste em avaliar parâmetros em situações onde as informações espaciais são importantes. A aplicação da Superfície de Impedância em plantações permite avaliar o perfil de bioimpedância em todo o cultivo, possibilitando a classificação de cada planta através da comparação da bioimpedância medida na planta com o perfil de bioimpedância do cultivo. Em contraste com a abordagem clássica, que avalia as plantas individualmente, a abordagem proposta realiza a coleta de dados considerando a distribuição espacial do cultivo. O objetivo é analisar a evolução das variáveis associadas ao estresse das plantas em um contexto mais amplo e integrado. Essa abordagem é implementada com base na distribuição de uma rede de nós sensores ao longo do cultivo. A primeira etapa experimental na elaboração desta tese consistiu em investigar se a medição da bioimpedância em uma única frequência e a análise de um único parâmetro, como fase, módulo, componente real ou componente imaginário, seriam suficientes para detectar a presença de fatores estressores em plantas. As análises dos resultados indicam que tal abordagem é, de fato, viável. Para a avaliação da Superfície de Impedância, foram construídas três bases de dados. A primeira foi obtida a partir de simulações, a segunda e a terceira foram formadas a partir de dados coletados através de experimentos. Para isso, foi construído ao longo deste trabalho um modelo baseado em indivíduos (IBM) que

permite simular a propagação da doença Huanglongbing em um cultivo de citrus considerando o comportamento da bioimpedância das plantas. Foi implementado também um arranjo experimental para a realização dos experimentos. A Superfície de Impedância foi aplicada às três bases de dados e os resultados demonstram que é possível fazer a detecção da presença de estresses em regiões do cultivo sem a necessidade de controlar o ambiente.

**Palavras-chave: Superfície de Impedância, Saúde de Plantas, Bioimpedância, Detecção Precoce de Doenças.**

## ABSTRACT

Diseases and pests in plants have led to considerable losses in global agricultural production. This has driven the development of tools capable of early detection of harmful agents affecting plant health. Despite significant advances in systems for assessing plant health, some limitations persist, hindering the practical application of these systems in the field. In particular, a promising approach for early disease detection in plants is the measurement of bioimpedance in plant tissues, which allows for the identification of stress signals in the early stages of infection. Although some researchers consider bioimpedance to have the greatest potential for early detection of diseases and stress in plants, the sensitivity of this technique to environmental variables has complicated its practical field application. This thesis presents a novel approach, termed Impedance Surface, which involves evaluating parameters in contexts where spatial information is important. The application of the Impedance Surface in crop fields allows for the assessment of bioimpedance profiles across the entire cultivation area, enabling the classification of each plant by comparing the measured bioimpedance with the cultivation's bioimpedance profile. In contrast to the classical approach, which evaluates plants individually, the proposed method collects data considering the spatial distribution of the crop. The objective is to analyze the evolution of stress-related variables in a broader and more integrated context. This approach is implemented based on the distribution of a network of sensor nodes throughout the cultivation area. The first experimental step in this thesis involved investigating whether measuring bioimpedance at a single frequency and analyzing a single parameter, such as phase, magnitude, real component, or imaginary component, would be sufficient to detect the presence of stressors in plants. The results indicate that this approach is indeed feasible. For the evaluation of the Impedance Surface, three datasets were constructed. The first was obtained from simulations, while the second and third were formed from data collected through experiments. To this end, a model based on individuals (IBM) was developed to simulate the spread of Huanglongbing disease in a citrus crop, considering the behavior of plant bioimpedance. An experimental setup was also implemented for conducting the experiments. The Impedance Surface was applied



to the three datasets, and the results demonstrate that it is possible to detect stress in regions of the crop without the need to control the environment.

**Keywords: Impedance Surface, Plant Health, Bioimpedance, Early Disease Detection.**

## LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de uma imagem hiperespectral, formada por uma matriz tridimensional. Duas dimensões são espaciais e uma é espectral. . . . .	30
Figura 2 – Ilustração de como a corrente elétrica percorre o tecido biológico para baixas e altas frequências. . . . .	42
Figura 3 – Ilustração com os três tipos de dispersões para os tecidos biológicos e células em suspensão proposto por Schwan. Sendo $\sigma$ a condutividade e $\varepsilon'$ a permissividade. . . . .	42
Figura 4 – Ilustração do modelo elétrico do tecido biológico. . . . .	44
Figura 5 – Modelo elétrico do tecido biológico desenvolvido por Hugo Fricke. . . . .	44
Figura 6 – Modelo elétrico do tecido biológico apresentado por Philipppson. . . . .	45
Figura 7 – Modelo elétrico do tecido biológico apresentado por Cole. Esse modelo já inclui o elemento de fase constante (CPE). . . . .	46
Figura 8 – Modelo modificado de Fricke. . . . .	46
Figura 9 – Representa o modelo elétrico da interação entre os eletrodos e o tecido da planta. $C_E$ está relacionado com a capacitância das paredes dos vasos, $R_E$ com a resistência de contato entre o eletrodo e os vasos e $R_{CC}$ representa a resistência à passagem de corrente contínua. . . . .	47
Figura 10 – Ilustração da configuração com eletrodos de superfície apresentada por WU; OGAWA; TAGAWA (2008). Sendo, 1, a amostra a ser medida, 2, os eletrodos de superfície e 3, o analisador de impedância. . . . .	48
Figura 11 – Aplicação dos eletrodos invasivos em posição diamétrica (a) e posição vertical (b). . . . .	48
Figura 12 – Gráfico de Cole-Cole, conhecido como <i>Cole-Cole plot</i> . É utilizado para ajustar a equação de Cole-Cole aos dados de um experimento. . . . .	51
Figura 13 – Principais configurações de circuitos para a medição de impedância em sistemas de EIS. Sendo (a), (b) e (c) os arranjos a dois, a três e a quatro eletrodos, respectivamente. Os eletrodos WE, CE, RE e WSE são designados por eletrodo de trabalho, contra eletrodo, eletrodo de referência e eletrodo de medição, respectivamente. . . . .	52

Figura 14 – Ilustração da reboleira. Resultado da simulação da propagação da doença <i>Huanglongbing</i> em Citros através do inseto vetor <i>Diaphorina citri</i> (KOBORI; TAKASU; OHTO, 2012). Os pontos azuis representam plantas saudáveis e os pontos vermelhos plantas doentes. A doença inicia no centro do cultivo, primeira imagem à esquerda, e vai se propagando em função do tempo. A evolução da doença no tempo segue a ordem da esquerda para a direita. . . . .	57
Figura 15 – Representação do modelo SIR. . . . .	58
Figura 16 – Curvas de bioimpedância medidas para frequências distintas. As frequências de excitação para os gráficos (a), (b) e (c) são 10 kHz, 50 kHz e 100 kHz, respectivamente. . . . .	62
Figura 17 – Ilustração da área do cultivo com a rede de sensores de bioimpedância. . . . .	65
Figura 18 – Ilustração da Superfície de Impedância. Os eixos X e Y representam as dimensões espaciais que indicam as posições dos nós da rede de sensores e o eixo Z representa os valores das impedâncias medidas para uma frequência $f_N$ . . . . .	65
Figura 19 – Ilustração da influência exercida na Superfície de Impedância por alterações nas variáveis ambientais. Nesta representação, são ilustradas três situações distintas para as variáveis ambientais. . . . .	66
Figura 20 – Ilustração da deformação causada na Superfície de Impedância pela ação de um agente estressor. Perceptível no ponto em que $X = 3$ e $Y = 2$ . . . . .	66
Figura 21 – Ilustração de plano ajustado a uma nuvem de pontos através do método dos Mínimos Quadrados. . . . .	69
Figura 22 – Ilustração de como os nós sensores se comunicam, apresentando as três situações possíveis. . . . .	70
Figura 23 – Diagrama esquemático do Nó Sensor 01. Os nós sensores 02 a 10 têm o mesmo esquemático, com a exceção do sensor AM2301, que está presente apenas no Nó 01. . . . .	81
Figura 24 – Nó sensor utilizado na RSSF empregada nos experimentos. . . . .	82
Figura 25 – Primeiro arranjo experimental, formado por 10 nós sensores, um sensor AM2301, um <i>raspberrypi 4</i> , uma fonte de tensão e 10 tomateiros. . . . .	83
Figura 26 – Tipo de eletrodo utilizado. São agulhas de acupuntura com diâmetro da secção transversal de 0,25 mm. . . . .	84
Figura 27 – Disposição dos eletrodos e do sensor de temperatura LM35. . . . .	84
Figura 28 – Segundo arranjo experimental. Neste arranjo foi inserida a iluminação artificial e um <i>nobreak</i> . . . . .	85
Figura 29 – Posição dos nós sensores no arranjo da terceira bateria de experimentos. . . . .	86
Figura 30 – Posição dos nós sensores no arranjo da quarta bateria de experimentos. . . . .	87
Figura 31 – Amostras dos solos para demonstrar a dinâmica da secagem do solo ao longo dos experimentos. . . . .	87
Figura 32 – Gráfico com curvas que representam a sensibilidade dos parâmetros da bioimpedância ao estresse causado por 2 níveis distintos de concentração de nitrogênio. . . . .	89

Figura 33 – Gráfico com curvas que representam as medições para cada nível de concentração de nitrogênio. As medições foram realizadas variando a frequência de 1 kHz a 50 kHz, com passo de 1 kHz. . . . .	90
Figura 34 – Gráfico com a representação das médias e desvios padrões das medições exibidas na Tabela 3. O gráfico exibe o valor medido da bioimpedância em função do nível de concentração, e os desvios padrões são representados pelas barras em cada ponto. . . . .	92
Figura 35 – Medições realizadas conforme a abordagem clássica, considerando uma única planta. Em (a) as variáveis ambientais foram mantidas constantes e em (b) essas variáveis não foram mantidas constantes. . . . .	93
Figura 36 – Tempo de infecção em todas as plantas do cultivo. São apresentados gráficos para quatro tempos de simulação específicos. . . . .	94
Figura 37 – Superfície de Impedância baseada no módulo da bioimpedância. São apresentados gráficos para quatro tempos de simulação específicos. . . . .	95
Figura 38 – Superfície de Impedância baseada na fase. São apresentados gráficos para quatro tempos de simulação específicos. . . . .	96
Figura 39 – Superfície de Impedância para quatro temperaturas distintas. Os quatro gráficos foram obtidos para o mesmo tempo de simulação, $ts = 3$ . . . . .	97
Figura 40 – Representação do plano do Nó $N_{1,2}$ e da nuvem de dados para o instante inicial da classificação. Os pontos azuis representam plantas saudáveis classificadas como saudáveis. . . . .	98
Figura 41 – Representação do plano do Nó $N_{5,4}$ e da nuvem de dados para o instante inicial da classificação. Os pontos azuis representam plantas saudáveis classificadas como saudáveis. . . . .	98
Figura 42 – Representação do plano do Nó $N_{1,1}$ e da nuvem de dados para o primeiro ciclo após o período de estabilização. O 'x' preto representa planta doente classificada como saudável. Os pontos azuis representam plantas saudáveis classificadas como saudáveis. . . . .	99
Figura 43 – Representação do plano do Nó $N_{5,3}$ e da nuvem de dados para o primeiro ciclo após o período de estabilização. O 'x' preto representa planta doente classificada como saudável. Os pontos azuis representam plantas saudáveis classificadas como saudáveis. . . . .	99
Figura 44 – Representação do plano do Nó $N_{1,1}$ e da nuvem de dados para o primeiro ciclo após o período de estabilização, obtido por outro ângulo de visão. Observa-se duas plantas contaminadas que ainda não foram classificadas ('x' pretos). . . . .	100
Figura 45 – Representação do plano do nó $N_{4,1}$ e da nuvem de dados para o segundo ciclo após o período de estabilização. Observa-se que as duas plantas contaminadas no ciclo anterior foram classificadas como doentes (asteriscos verdes). . . . .	100
Figura 46 – Representa a Superfície de Impedância e a nuvem de dados. Gerado três meses após o gráfico da Figura 45, permitindo visualizar a evolução das plantas doentes. O asterisco verde representa planta doente classificada como doente. . . . .	100
Figura 47 – Sensibilidade dos parâmetros para o Nó 4 da terceira bateria de experimentos. . . . .	104

Figura 48 – Sensibilidade dos parâmetros para o Nó 7 da terceira bateria de experimentos. . . . .	104
Figura 49 – Sensibilidade dos parâmetros para o Nó 1 da quarta bateria de experimentos. . . . .	104
Figura 50 – Sensibilidade dos parâmetros para o Nó 2 da quarta bateria de experimentos. . . . .	104
Figura 51 – Representação do plano do Nó 3 e da nuvem de dados para o instante inicial da classificação. Os pontos azuis representam plantas saudáveis classificadas como saudáveis. . . . .	107
Figura 52 – Representação do plano do Nó 7 e da nuvem de dados para o instante inicial da classificação. Os pontos azuis representam plantas saudáveis classificadas como saudáveis. . . . .	107
Figura 53 – Representação do plano do Nó 7 e da nuvem de dados para o primeiro ciclo após o período de estabilização. . . . .	108
Figura 54 – Representação do plano do Nó 10 e da nuvem de dados para o primeiro ciclo após o período de estabilização. . . . .	108
Figura 55 – Representação da Superfície de Impedância e dos dados. Planta do Nó 7 está sob estresse mas ainda não foi classificada como doente ('x' preto). . . . .	108
Figura 56 – Representação da Superfície de Impedância e dos dados. Planta do Nó 7 classificada corretamente como doente (asterisco verde). . . . .	108
Figura 57 – Representa a Superfície de Impedância e a nuvem de dados após agravamento do estresse. O asterisco verde representa planta doente classificada como doente. . . . .	109
Figura 58 – Gráfico com os valores da bioimpedância normalizada para os 10 nós da terceira bateria de experimentos. No instante em que o nó é classificado como doente a curva no gráfico muda para a cor vermelha. . . . .	110
Figura 59 – Gráfico com os valores da bioimpedância normalizada para os 10 nós da quarta bateria de experimentos. No instante em que o nó é classificado como doente a curva no gráfico muda para a cor vermelha. . . . .	112

## LISTA DE TABELAS

Tabela 1 – Índices de correlação entre os dados dos gráficos apresentados na Figura 16. . . . .	63
Tabela 2 – Valores dos parâmetros do modelo de Fricke para cada nível de nitrogênio (MEIQING <i>et al.</i> , 2017). . . . .	74
Tabela 3 – Medições realizadas para os 5 níveis de concentração de nitrogênio utilizando a frequência de 12 kHz. Foram coletadas 10 amostras para cada nível. . . . .	91
Tabela 4 – Dados para os experimentos com a componente reativa. . . . .	102
Tabela 5 – Dados para os experimentos com a componente resistiva. . . . .	102
Tabela 6 – Correlação das grandezas com o módulo da bioimpedância para a frequência de 1 kHz. Para cada variável, a tabela contém o valor médio da correlação calculada para 3 nós escolhido aleatoriamente.	105
Tabela 7 – Correlação das grandezas com o módulo da bioimpedância para a frequência de 100 kHz. Para cada variável, a tabela contém o valor médio da correlação calculada para 3 nós escolhido aleatoriamente.	105
Tabela 8 – Correlação das grandezas com a fase da bioimpedância para a frequência de 1 kHz. Para cada variável, a tabela contém o valor médio da correlação calculada para 3 nós escolhido aleatoriamente.	105
Tabela 9 – Correlação das grandezas com a fase da bioimpedância para a frequência de 100 kHz. Para cada variável, a tabela contém o valor médio da correlação calculada para 3 nós escolhido aleatoriamente.	105
Tabela 10 – Dados estatísticos para a classificação baseada em Superfície de Impedância na terceira bateria experimental. . . . .	109
Tabela 11 – Dados estatísticos para a classificação baseada em Superfície de Impedância na quarta bateria experimental. . . . .	111

## LISTA DE ABREVIATURAS

ANOVA	<i>Analysis of Variance</i> (Análise de Variância)
CE	<i>Counter Electrode</i> (Contra Eletrodo)
CGMMV	<i>Bromoviridae and Cucumber Green Mottle Mosaic Virus</i> (Vírus do Mosaico da Mancha Verde do Pepino)
CI	Circuito Integrado
CIR	<i>Colour Infrared</i> (Infravermelho Colorido)
CMV	<i>Cucumber Mosaic Virus</i> (Vírus do Mosaico do Pepino)
CPE	<i>Constant Phase Element</i> (Elemento de Fase Constante)
CTV	<i>Citrus Tristeza Virus</i> (Vírus da Tristeza dos Citros)
DNA	<i>Desoxyribonucleic Acid</i> (Ácido Desoxirribonucleico)
EIS	<i>Electrical Impedance Spectroscopy</i> (Espectroscopia de Impedância Eléctrica)
ELISA	<i>Enzyme-Linked Immunosorbent Assay</i> (Ensaio de Imunoabsorção Enzimática)
E-NOSE	<i>Electronic Nose</i> (Nariz Eletrônico)
GPS	<i>Global Positioning System</i> (Sistema de Posicionamento Global)
I2C	<i>Inter-Integrated Circuit</i> (Circuito Inter-Integrado)
MLP-ARD	<i>Multilayer Perceptron with Automated Relevance Determination</i> (Perceptron Multicamadas com Determinação Automática de Relevância)
MTD	<i>Maximum Temperature Difference</i> (Diferença Máxima de Temperatura)
NBI	<i>N Balance Index</i> (Índice de Balanço de Nitrogênio)
NCA	<i>Neighborhood Component Analysis</i> (Análise de Componentes de Vizinhaça)

NIR	<i>Near Infrared</i> (Infravermelho Próximo)
ONU	Organização das Nações Unidas
PCA	<i>Principal Component Analysis</i> (Análise de Componentes Principais)
PCR	<i>Polymerase Chain Reaction</i> (Reação em Cadeia da Polimerase)
PIC	<i>Programmable Interface Controller</i> (Controlador de Interface Programável)
RE	<i>Reference Electrode</i> (Eletrodo de Referência)
RGB	<i>Red, Green and Blue</i> (Vermelhor, Verde e Azul)
RIP	<i>Routing Information Protocol</i> (Protocolo de Informação de Roteamento)
SVM	<i>Support Vector Machine</i> (Máquina de Vetores de Suporte)
TIE	Tomografia de Impedância Elétrica
ToCV	<i>Tomato Chlorosis Virus</i> (Vírus da Clorose do Tomate)
TSWV	<i>Tomato Spotted Wil Virus</i> (Vírus da Murcha Manchada do Tomate)
UAV	<i>Unmanned Aerial Vehicle</i> (Veículo Aéreo Não Tripulado)
VOC	<i>Volatile Organic Compounds</i> (Compostos Orgânicos Voláteis)
WE	<i>Working Electrode</i> (Eletrodo de Trabalho)
WSE	<i>Working Sensing Electrode</i> (Eletrodo Sensor de Trabalho)
XY-F	<i>XY-Fusion Network</i> (Método de Aprendizado de Máquina com Fusão de Dados)



## LISTA DE SÍMBOLOS

$C_m$	Capacitância da membrana celular do tecido biológico
$I(t)$	Corrente elétrica
$ImZ$	Parte imaginária da impedância
$\mathbf{M}_{AP}$	Representa o resultado de uma medição realizada com o sistema da abordagem proposta
$\mathbf{M}_{EIS}$	Representa o resultado de uma medição de EIS
$R_e$	Resistência elétrica do fluido extracelular do tecido biológico
$ReZ$	Parte real da impedância
$R_i$	Resistência elétrica do fluido intracelular do tecido biológico
$R_m$	Resistência elétrica da membrana celular do tecido biológico
$R_0$	Resistência do tecido biológico medida em corrente contínua
$R_\infty$	Resistência do tecido biológico medida com a frequência tendendo ao infinito
$V(t)$	Tensão elétrica
$\mathbf{Z}$	Impedância elétrica
$\mathbf{Z}_{CPE}$	Impedância do elemento de fase constante
$\alpha$	Índice adimensional do elemento de fase constante
$\epsilon$	Permissividade
$\theta$	Ângulo que determina o valor de $\alpha$ a partir do <i>Cole-Cole plot</i>
$\sigma$	Condutividade elétrica
$\tau$	Constante de tempo
$\omega$	Velocidade angular

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	19
1.1	Motivação	22
1.2	Objetivos	22
1.2.1	Objetivos Específicos	22
1.3	Principais Contribuições Científicas desta Tese	23
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	25
2.1	Métodos Diretos para a Detecção de Doenças em Plantas	26
2.2	Métodos Indiretos para a Detecção de Doenças em Plantas	27
2.2.1	Métodos Indiretos para a Detecção no Estágio Inicial da Doença	28
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	38
3.1	Contextualização Histórica da Medição de Bioimpedância	39
3.2	Composição Elétrica do Tecido Biológico	40
3.3	Dispersões Dielétricas em Sistemas Biológicos	41
3.4	Modelos Elétricos para os Tecidos Biológicos	43
3.4.1	Tipos de Eletrodos Usados para Medições em Plantas	47
3.5	Ajuste do Modelo	49
3.6	Espectroscopia de Impedância Elétrica	51
3.6.1	Abordagem Clássica	53
3.7	Propagação das Doenças em Cultivos	54
3.8	Modelos Matemáticos para o Estudo de Propagação de Doenças	57
3.8.1	O Modelo SIR	57
3.8.2	Modelagem Baseada em Indivíduos	59
<b>4</b>	<b>MEDIÇÃO BASEADA EM SUPERFÍCIE DE IMPEDÂNCIA</b>	61
4.1	Superfície de Impedância	64
4.2	Classificação com a Superfície de Impedância	67

<b>5</b>	<b>ARRANJOS EXPERIMENTAIS E DESCRIÇÕES METODOLÓGICAS</b>	<b>73</b>
5.1	Metodologia para Analisar a Detecção Utilizando Apenas uma Frequência e um Parâmetro da Bioimpedância . . . . .	73
5.2	Metodologia para a Construção da Base de Dados Sintéticos . . . . .	75
5.3	Metodologia para a Construção das Bases de Dados Experimentais . .	79
<b>6</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>88</b>
6.1	Resultados da Análise da Detecção Utilizando Apenas uma Frequência e um Parâmetro da Bioimpedância . . . . .	88
6.2	Resultados da Aplicação da Superfície de Impedância à Base de Dados Sintéticos . . . . .	91
6.2.1	Análise da Medição com o Método Clássico . . . . .	92
6.2.2	Análise da Superfície de Impedância . . . . .	93
6.2.3	Análise da Classificação Baseada em Superfície de Impedância . . . .	96
6.3	Resultados da Aplicação da Superfície de Impedância às Bases de Dados Experimentais . . . . .	103
6.3.1	Aplicação da Medição Baseada em Superfície de Impedância aos Dados Experimentais . . . . .	106
<b>7</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS</b>	<b>113</b>
	<b>REFERÊNCIAS</b>	<b>115</b>
	<b>ANEXO A . MÍNIMOS QUADRADOS RECURSIVO.</b>	<b>126</b>
A.1	Método dos Mínimos Quadrados Clássico . . . . .	126
A.2	Método dos Mínimos Quadrados Recursivo . . . . .	127

# 1 INTRODUÇÃO

A demanda global por alimentos tem aumentado ao longo do tempo como um reflexo do crescimento da população mundial que, segundo estimativa da ONU, no ano de 2019 foi de aproximadamente 82 milhões de pessoas (GANIVET, 2020). Alguns estudos realizados por GAO *et al.* (2023) apontam que até o ano de 2030 o crescimento anual da população global será de aproximadamente 113 milhões de pessoas. Apesar da produção mundial de alimentos ser suficiente para suprir a demanda global, visto que a fome está relacionada à má distribuição dos alimentos devido a problemas políticos-sociais, entende-se que o desenvolvimento de sistemas que possam favorecer os pequenos agricultores, principalmente na agricultura familiar, facilita a provisão para as populações mais carentes. Outro problema relevante está relacionado com as infestações por pragas e doenças, sendo que as perdas na produção agrícola mundial são expressivas, ultrapassando os 40% para os cultivos de arroz e milho (SAVARY *et al.*, 2019). Essa realidade tem impulsionado vários pesquisadores a estudar e desenvolver novas técnicas agrícolas.

Com as práticas agrícolas atuais, o meio ambiente vem sendo agredido de maneira descontrolada. Pois, em muitos casos, os fitopatógenos e pragas são controlados através da pulverização de agroquímicos em toda a área do cultivo, mesmo nos locais em que não se faz necessário. Isso leva a uma agressão desnecessária ao meio ambiente, sendo que esses produtos são os que mais contaminam o lençol freático (BRAVO *et al.*, 2003), tornando a produção agrícola insustentável. O uso em demasia e de forma descontrolada dos agroquímicos também implica no custo da produção, pois esses produtos têm alto custo monetário (MAHLEIN, 2016).

A técnica mais utilizada na detecção de doenças em plantas é por meio de inspeção visual. Esse tipo de diagnóstico é realizado por profissionais qualificados, pois é necessário um amplo conhecimento para que resultados confiáveis sejam obtidos (ALI *et al.*, 2019). Entretanto, essa abordagem frequentemente não permite o diagnóstico da doença em sua fase inicial, quando os sintomas ainda não são visíveis a olho nu. Assim, esse atraso na detecção pode favorecer o rápido aumento da incidência da doença na área de cultivo e, conseqüentemente, levar ao uso intensivo de

agrotóxicos para o controle ou à destruição de toda a área afetada e das regiões vizinhas. Isso implica em poluição ambiental, perdas na produção e, em alguns casos, desmatamento. (BORGES *et al.*, 2014).

Nesse contexto, a detecção de doenças em plantas tem como foco principal a identificação no estágio inicial da doença, pois isso possibilita a aplicação dos agroquímicos de forma localizada, reduzindo a contaminação do ambiente e do lençol freático, o custo monetário da produção, o desmatamento e as perdas na produtividade da cultura (BRAVO *et al.*, 2003; MAHLEIN, 2016).

As tecnologias que estão sendo desenvolvidas para o diagnóstico no estágio inicial envolvem sensores ópticos, de gás e conversores de bioimpedância. Dentre os métodos que utilizam os sensores ópticos se destacam a termografia, imagem por fluorescência e a reflexão multi e hiperespectral (MAHLEIN, 2016). As imagens termográficas medem a variação de temperatura das plantas, assim é possível acessar informações sobre a quantidade de água e transpiração das plantas que estão relacionadas com algumas patologias. Mas, essa tecnologia é sensível a alguns fatores ambientais (*e.g.*, umidade, temperatura e luminosidade), e tem alto custo monetário (MAHLEIN, 2016; MAHLEIN *et al.*, 2019). A imagem por fluorescência é utilizada para acompanhar a atividade fotossintética da planta. Como a clorofila tem propriedade fluorescente, é possível detectar alguns estresses bióticos e abióticos através da fluorescência. Em contrapartida, medir a fluorescência da clorofila em campo é uma tarefa árdua, pois, para isso é necessário adaptar um ambiente escuro e fazer um tratamento criterioso nas amostras antes das medições (MAHLEIN *et al.*, 2019). A análise multi e hiperespectral faz a medição da reflexão das ondas eletromagnéticas, na faixa de 400 nm a 2500 nm, nas plantas. Essa reflexão está relacionada com características biofísicas e bioquímicas das plantas que sofrem alterações à medida em que as mesmas são expostas a algum tipo de estresse. Apesar do potencial na detecção das doenças no estágio inicial, essa tecnologia ainda possui um custo monetário alto e é sensível às condições climáticas (THOMAS *et al.*, 2018; MAHLEIN *et al.*, 2019).

Os sensores de gás têm a vantagem de medir os compostos orgânicos voláteis (VOCs - *volatile organic compounds*) que são emitidos pelas plantas, pois os VOCs fornecem informações importantes sobre o estado de saúde delas, inclusive em relação a danos mecânicos e infestações de insetos (CUI *et al.*, 2018). O principal desafio da aplicação desses sensores está relacionado à quantidade dos VOCs emitidos pelas plantas que é pequena, dificultando a aplicação dessa tecnologia em campo (CUI *et al.*, 2018).

A espectroscopia de impedância elétrica (EIS - *electrical impedance spectroscopy*) mede a impedância de uma amostra para uma determinada faixa de frequência. Os primeiros sintomas que surgem nas plantas, após o início da ação estressora, são

variações nas células e nas características do meio extracelular (AMORIM, 2018). Por sua vez, a impedância do tecido das plantas está diretamente relacionada com esses fluidos (COLE, 1928; HAYDEN *et al.*, 1969) e com as membranas afetadas pelas doenças. Assim, é possível deduzir que pode-se avaliar o estado de saúde das plantas utilizando EIS. A definição de bioimpedância está relacionada com a impedância de um tecido biológico, seja de origem vegetal ou animal.

A medição da bioimpedância é considerada a abordagem com maior potencial para detectar doenças em plantas, no estágio inicial do estresse (MEIQING *et al.*, 2017; TANG *et al.*, 2023). Embora existam alguns circuitos integrados que realizam a medição da bioimpedância, facilitando a aplicação em campo, a bioimpedância é sensível às oscilações nas variáveis ambientais (*e.g.*, temperatura, umidade e irradiação solar), e isso dificulta a aplicação dessa abordagem em ambientes não controlados (HORSFALL, 2012; BORGES *et al.*, 2014; BAR-ON; SHACHAM-DIAMAND, 2021; NOUAZE *et al.*, 2022). Portanto, o principal enfoque do sistema apresentado neste documento é contornar os problemas relacionados à sensibilidade que a bioimpedância tem aos fatores ambientais, impulsionando a sua aplicação em ambientes não controlados.

A medição baseada em Superfície de Impedância, sistema proposto nesta tese, tem três diferenças principais da abordagem clássica. A primeira está relacionada à inclusão da dimensão espacial (longitudinal e transversal). Pois, enquanto a abordagem clássica faz a medição da planta individualmente, o sistema proposto considera as dimensões espaciais coletando dados ao longo de toda a área cultivada. A segunda está associada à forma como a medição é realizada, pois o sistema proposto utiliza apenas um parâmetro da bioimpedância, seja a fase, o módulo, a componente real ou a componente imaginária, e realiza a medição aplicando uma única frequência. Em contraste, a abordagem clássica emprega a espectroscopia de impedância elétrica para uma ampla faixa de frequência e realiza as análises combinando os parâmetros da bioimpedância. A terceira está vinculada ao objetivo da aplicação. A abordagem clássica foca na classificação individual de diferentes tipos de doenças ou estresses em plantas, tratando cada planta de forma isolada. Em contraste, a abordagem proposta visa monitorar toda a área de cultivo, identificando e localizando a presença de estresses ou doenças, bem como determinando a localização exata dos possíveis focos de infecção.

O sistema de medição baseado em Superfície de Impedância foi construído considerando uma rede de sensores de bioimpedância instalada ao longo da região do plantio, originando um novo método de medição que está descrito no Capítulo 4 e é denominado por Superfície de Impedância. A medição baseada em Superfície de Impedância foi aplicada em três bases de dados. Uma base de dados foi gerada por simulação, enquanto as outras foram construídos através de experimentos. No

Capítulo 5 está descrito como cada base de dados foi construída. Os resultados, apresentados no Capítulo 6, demonstram que usando a medição baseada em Superfície de Impedância é possível fazer a detecção de estresses no cultivo em ambientes não controlados.

## 1.1 Motivação

As doenças e pragas têm causado danos expressivos na produção agrícola mundial. A prática mais comum na detecção dessas pragas e doenças tem sido a avaliação visual que, na maioria dos casos, traz o diagnóstico quando a doença já está em estágios avançados. Assim, o controle é realizado aplicando agroquímicos em grandes áreas e, em alguns casos, destruindo a área infectada e as regiões vizinhas. Isso resulta no uso demasiado de agroquímicos, em perdas acentuadas na produção e também em desmatamentos. Aliado a isso, os agroquímicos podem atingir até 90% do custo da produção e são os principais responsáveis pela contaminação do lençol freático (BRAVO *et al.*, 2003; BORGES *et al.*, 2014; MAHLEIN, 2016).

Essa realidade traz como consequência a necessidade do desenvolvimento de sistemas aptos a detectar doenças em plantas, no estágio inicial da infecção, acessíveis aos médios e pequenos agricultores. Embora existam trabalhos propondo sistemas para a detecção de agentes nocivos a plantas no estágio inicial da ação estressora (MAHLEIN, 2016; GOLD *et al.*, 2020; TANG *et al.*, 2023), algumas fronteiras têm dificultado a aplicação deles em campo. Isso tem motivado o estudo deste trabalho, que visa utilizar a potencialidade da técnica de bioimpedância na detecção de estresses no estágio inicial.

## 1.2 Objetivos

O objetivo geral desta tese é propor e testar um sistema que permita detectar doenças ou estresses em uma plantação através da medição de bioimpedância. Para tanto, é proposto nesta tese um método denominado de Superfície de Impedância, no qual, a posição espacial e as medições de amostras de plantas são feitas periodicamente e relacionadas com os resultados da vizinhança, com o intuito de conseguir realizar a detecção em ambientes não controlados.

### 1.2.1 Objetivos Específicos

Os objetivos específicos são:

- i) Implementar um modelo para simular e construir uma base de dados com medições sintéticas da bioimpedância;

- ii) Construir um arranjo experimental que permita medir a bioimpedância, a temperatura do ambiente, a umidade relativa do ar e a temperatura do solo;
- iii) Realizar experimentos, utilizando o arranjo experimental, para a construção de bases de dados com medições reais;
- iv) Desenvolver a abordagem proposta, Superfície de Impedância, e a ferramenta de classificação com a Superfície de Impedância;
- v) Analisar a sensibilidade dos parâmetros da bioimpedância ao estresse da planta;
- vi) Analisar a viabilidade da detecção de doenças e estresses medindo a bioimpedância com apenas uma frequência e realizando a classificação com apenas um parâmetro da bioimpedância;
- vii) Analisar a medição baseada em Superfície de Impedância, aplicando-a na base de dados gerada por simulação e nas bases de dados construídas a partir dos experimentos reais.

### 1.3 Principais Contribuições Científicas desta Tese

A seguir são descritas as principais contribuições deste trabalho:

- As medições com a abordagem clássica quase sempre são realizadas em ambientes controlados, devido à sensibilidade que a bioimpedância das plantas tem às variáveis ambientais. Isso tem dificultado a aplicação dessa abordagem em ambientes abertos. A principal contribuição desta tese é a proposição, construção e análise de um novo método de medição, denominado Superfície de Impedância, onde as informações espaciais são cruciais para a medição de um conjunto de parâmetros, como em uma plantação, e sua aplicação na detecção de estresses em cultivos. A medição baseada em Superfície de Impedância permite a detecção de estresses em ambientes não controlados, possibilitando sua aplicação em ambientes abertos. A teoria da medição baseada em Superfície de Impedância está descrita no Capítulo 4;
- Na abordagem clássica as medições são realizadas considerando as plantas individualmente, enquanto que no sistema proposto as dimensões espaciais também são consideradas;
- A abordagem clássica realiza a medição através da espectroscopia de impedância elétrica, com o objetivo de coletar dados em uma larga faixa de frequência. Nela, a classificação é realizada combinando os parâmetros da bioimpedância, resultando em uma grande quantidade de dados. Neste trabalho, é realizado



um estudo experimental cujos resultados mostram que a medição com uma única frequência, juntamente com a classificação utilizando apenas um parâmetro da bioimpedância, é suficiente para realizar a detecção de estresses em plantas. Esses resultados são apresentados na Seção 6.1;

- A abordagem clássica utiliza o índice de impedância para reduzir a influência dos eletrodos nas medições. Isso reduz significativamente a sensibilidade da medição aos estresses. Na abordagem proposta, o índice de impedância é substituído por uma supressão do nível DC da bioimpedância ao longo do tempo, preservando a sensibilidade da medição;
- Na comunidade acadêmica não são encontradas bases de dados com medições de bioimpedância em experimentos com plantas. Após a publicação dos artigos, as bases de dados construídas neste trabalho serão disponibilizadas para acesso livre;
- A abordagem proposta neste trabalho permite coletar informações que norteiem novos trabalhos voltados ao desenvolvimento de um sistema de previsão que auxilie os profissionais na tomada de decisão.

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo são abordados vários métodos empregados na detecção de doenças, pragas e outros fatores que estressam as plantas. Conhecer e analisar os sintomas das doenças é de grande utilidade na diagnose. O ramo da ciência que estuda os sintomas das doenças é denominado por sintomatologia e é de grande importância para o desenvolvimento de tecnologias que podem ser empregadas na detecção dessas doenças. Os sintomas são manifestações das reações da planta a um agente nocivo que surgem em uma determinada sequência ao longo do desenvolvimento da doença. Essa sequência completa é denominada de quadro sintomatológico (AMORIM, 2018). Os sintomas de doenças nas plantas podem ser classificados de acordo com as alterações causadas na estrutura e/ou nos processos afetados. Os sintomas exteriorizados e visíveis a olho nu são classificados como sintomas morfológicos, os que acontecem a nível celular são os histológicos e os que alteram a fisiologia do hospedeiro são os fisiológicos (AMORIM, 2018).

Para o manejo eficiente da doença na cultura é fundamental a detecção no estágio inicial da contaminação ou infecção. Portanto, é importante saber que os primeiros sintomas que surgem após o contato da planta com um agente nocivo são os histológicos e os fisiológicos, sendo que os morfológicos surgem em estágios mais avançados das doenças (AMORIM, 2018; BOCK *et al.*, 2020; BUJA *et al.*, 2021).

A avaliação do *status* de saúde das plantas existe desde que o homem dominou a arte do cultivo, no período neolítico (FELDENS, 2018). O diagnóstico era realizado através da observação das plantas e se baseava nos sintomas visíveis a olho nu, como mudança na coloração, manchas, entre outros. Essa forma de avaliação foi evoluindo ao longo dos séculos, por meio do acúmulo das experiências dos lavradores, e ainda é, atualmente, a técnica mais comum na detecção de pragas e doenças em plantas (AHMAD; SARASWAT; EL GAMAL, 2023). Porém, como discutido no Capítulo 1, essa abordagem limita a detecção precoce de doenças. Portanto, há a necessidade de desenvolver sistemas capazes de identificar a presença de doenças em plantas ainda nos estágios iniciais da contaminação. Além disso, é importante que esses sistemas sejam acessíveis aos pequenos e médios agricultores.

Existem diversos métodos utilizados para realizar o diagnóstico da saúde de plantas. Os quais são classificados em diretos e indiretos. Os métodos diretos realizam a análise, geralmente em laboratório, de parte ou toda a estrutura da planta, enquanto que os métodos indiretos avaliam variações em algumas características das plantas como temperatura, coloração, formato das folhas, bioimpedância, taxa de transpiração, emissões de compostos orgânicos voláteis, dentre outros aspectos morfológicos e fisiológicos (CUI *et al.*, 2018; BOCK *et al.*, 2020).

## 2.1 Métodos Diretos para a Detecção de Doenças em Plantas

Os métodos diretos mais utilizados para um diagnóstico preciso do *status* de saúde de plantas são os baseados em DNA e os sorológicos (CUI *et al.*, 2018). A detecção de doenças baseada no DNA é realizada através da comparação do genoma dos fitopatógenos, que são os causadores das doenças em plantas, com os genomas encontrados na amostra coletada. Algumas técnicas, a exemplo da Reação em Cadeia da Polimerase (PCR), são aplicadas para esse fim (KULABHUSAN; TRIPATHI; KANT, 2022). O PCR é um processo que requer algumas etapas de processamento que são realizadas em laboratório, o que demanda equipamento de alto custo monetário e muito tempo para a realização do diagnóstico (RAY *et al.*, 2017; CUI *et al.*, 2018). DEGANI; BECHER; GORDANI (2023) utilizaram um sistema PCR para realizar o rastreamento em tempo real do DNA do patógeno *Macrophomina phaseolina* em raízes de plantas de algodão. O objetivo foi avaliar as mudanças na presença do DNA do patógeno após o tratamento com diferentes isolados de *Trichoderma* e determinar a eficácia dos agentes bio-protetores na redução da infecção do patógeno nas plantas. Os resultados indicam uma redução significativa nos níveis de DNA do patógeno nas plantas tratadas com os isolados *T. longibrachiatum* (T7407) e *T. asperellum*. DREADEN *et al.* (2014) desenvolveram um método de PCR baseado na amplificação das pequenas subunidades dos ribossomos que é compatível com o PCR tradicional. O objetivo do trabalho foi reduzir o tempo de realização do diagnóstico e possibilitar a aplicação do sistema em tempo real. Durante a fase experimental foram realizados testes em 4 laboratórios para validar a técnica e ficou comprovado que o método proposto reduz o tempo do diagnóstico de uma semana para um dia.

Enquanto que para o diagnóstico baseado em DNA o interesse está no genoma dos fitopatógenos, na sorologia o que importa é conhecer e caracterizar os perfis de isoenzimas que estão relacionados com os fitopatógenos de interesse. Para fazer a detecção de isolados conhecidos, através da sorologia, a técnica mais utilizada é a ELISA (*Enzyme Linked ImmunoSorbent Assay*) que consiste em expor as isoenzimas extraídas da amostra a anticorpos específicos. Esse procedimento é feito em conjunto com um substrato para reação colorimétrica e o resultado é lido por um espectro-

fotômetro (GONÇALVES, 2009; FARBER *et al.*, 2019). (HARTATI *et al.*, 2020) utilizaram o método sorológico *Double Antibody Sandwich-Enzyme-Linked Immunosorbent Assay* (DAS-ELISA) com o objetivo de detectar o *Papaya ringspot virus* (PRSV-P) em mamoeiros na região norte de Sumatra. Os resultados indicam a presença de vários tipos de sintomas da doença, incluindo manchas em forma de anel, listras, mosaicos e malformações foliares, bem como listras e manchas escuras nas hastes e caules. LAN *et al.* (2019) desenvolveram um ensaio imunoenzimático, baseado na ELISA, para a detecção simultânea do carbofuran e seu metabólito 3-hidroxicarbofuran (3-OH-CBF). Eles utilizaram um anticorpo monoclonal de amplo espectro (mAb), designado como 2E3, que reconhece tanto o carbofuran quanto o 3-OH-CBF. O método desenvolvido foi validado usando cromatografia líquida de ultra performance acoplada à espectrometria de massa (UPLC-MS/MS), e os autores afirmam que essa abordagem é adequada para a detecção rápida e simultânea de carbofuran e 3-OH-CBF em frutas e vegetais.

Apesar dos métodos baseados em DNA e na sorologia produzirem resultados precisos e serem os mais confiáveis para o diagnóstico de fungos e vírus, eles têm pouco potencial para a detecção no estágio inicial da doença, pois o tempo entre a coleta da amostra e o resultado final pode ser de até 2 dias (RAY *et al.*, 2017; CUI *et al.*, 2018). Além disso, os respectivos métodos geralmente são empregados após a detecção, através da avaliação visual, de sintomas e/ou sinal de doença na planta. Isso gera mais atraso no diagnóstico, pois, nesses casos, parte do tecido vegetal já foi comprometido com a colonização e desenvolvimento do agente etiológico (BOCK *et al.*, 2010).

## 2.2 Métodos Indiretos para a Detecção de Doenças em Plantas

Os métodos indiretos encontrados na literatura englobam a utilização de sensores ópticos, sensores de gás e a espectroscopia de impedância elétrica (CUI *et al.*, 2018; BOCK *et al.*, 2020; VAN HAEVERBEKE; DE BAETS; STOCK, 2023). As principais abordagens que utilizam os sensores ópticos são: captura de imagens RGB, NIR (*near infrared*), reflexão multi e hiperespectral, imagem térmica e imagem por fluorescência.

O processamento de imagens RGB tem sido uma ferramenta importante na construção de sistemas para avaliar a saúde de plantas. O acesso a imagens fotográficas digitais tem aumentado com a construção de câmeras cada vez mais portáteis, com alta resolução e integradas aos telefones celulares. Isso tem impulsionado os pesquisadores a desenvolverem técnicas de processamento de imagens voltadas para a detecção de doenças em plantas e várias ferramentas têm sido construídas com base na detecção de características das imagens. Entre essas características destacam-se

texturas, formas, níveis de cor, bordas, entre outras. Também são utilizados vários tipos de transformações, aplicadas aos canais RGB, que servem como índices na detecção de doenças (BOCK *et al.*, 2020). HALLAU *et al.* (2018) construíram um algoritmo baseado em imagens RGB coletadas por *smartphones* para identificar, de forma automática, doenças no cultivo da beterraba sacarina. No sistema desenvolvido a aquisição e segmentação das imagens foram realizadas por *smartphones*, enquanto que o processamento avançado dos dados aconteceu em um servidor. O processamento foi baseado em características de textura, cor, intensidade e valores de gradiente. A classificação foi realizada utilizando máquina de vetor de suporte (SVM). Para a realização dos experimentos foram utilizados 5 patógenos distintos, sendo cada folha contaminada com apenas 1 patógeno. A acurácia da classificação entre as 5 doenças foi de 82%, maior que a da classificação realizada por profissionais experientes através de imagens. SHRIVASTAVA; PRADHAN (2020) desenvolveram um sistema para detectar 3 tipos de doenças no cultivo de arroz. A abordagem foi construída usando apenas características baseadas em cor, foram explorados 14 espaços de cores diferentes e extraídas 172 características. A classificação foi realizada utilizando máquina de vetor de suporte (SVM) e a acurácia da classificação foi de 94,65%.

A principal desvantagem dos métodos que utilizam as imagens RGB é a mesma da avaliação visual, pois os sintomas capturados pelas imagens RGB, que são os mesmos visíveis a olho nu, surgem apenas nos estágios mais avançados das doenças. Essas abordagens também são sensíveis aos fatores ambientais, como chuvas e variação na iluminação (BOCK *et al.*, 2020). Devido à importância da detecção no estágio inicial dos estresses e doenças nas plantas, como explanado na introdução, a Subseção 2.2.1 foi dedicada à apresentação das tecnologias com maior potencial para a detecção no estágio inicial. Elas são baseadas na termografia, imagem por fluorescência, reflexão multi e hiperespectral, NIR (*near infrared*), sensores de gás e espectroscopia de impedância elétrica (BORGES *et al.*, 2014; BOCK *et al.*, 2020; MORELLOS *et al.*, 2020; YOU *et al.*, 2022).

### 2.2.1 Métodos Indiretos para a Detecção no Estágio Inicial da Doença

Como descrito no início deste capítulo, os sintomas histológicos e os fisiológicos surgem em estágios iniciais das doenças, seguidos dos morfológicos em estágios mais avançados. Partindo do interesse na detecção da doença em estágios iniciais, é fundamental o uso de tecnologias potenciais na detecção de alterações histológicas e/ou fisiológicas nas plantas. Nesse tipo de abordagem, alguns trabalhos têm-se destacado.

Uma característica fisiológica importante das plantas é a taxa de transpiração que é correlacionada com a temperatura. ZHAO *et al.* (2022) mostraram que a taxa de


transpiração está correlacionada negativamente com a temperatura da folha. Como um dos efeitos patológicos das doenças é a alteração na taxa de transpiração das plantas, medindo a temperatura é possível acessar informações sobre a saúde delas (DOMINGUES; BRANDÃO; FERREIRA, 2022). MASTRODIMOS *et al.* (2019) desenvolveram uma metodologia baseada em termografia para a detecção de infecção fúngica em uvas de mesa sob condições controladas (temperatura e umidade do ar). A avaliação foi realizada através da temperatura média e da máxima diferença de temperatura na superfície do fruto. Os resultados indicam que o sistema faz a detecção das uvas infectadas nas primeiras horas após a contaminação, antes do surgimento dos sintomas visíveis a olho nu. OERKE; FRÖHLING; STEINER (2011) aplicaram a termografia para avaliar o desenvolvimento do fungo *Venturia Inaequalis* em folhas de macieira, a partir da inoculação. As análises foram realizadas através da diferença máxima de temperatura (MTD - *maximum temperature difference*) no tecido foliar. Os resultados ilustram que o índice MTD diminui com o desenvolvimento do fungo e tem forte correlação com a severidade da infecção. Isso indica que ele é adequado tanto para diferenciar as plantas saudáveis das doentes quanto para quantificar a severidade da doença. O autor ressalta que a técnica precisa ser avaliada em condições de campo. É importante notar que a temperatura de uma folha é sensível a diversos fatores como irradiação, quantidade de água na planta, temperatura do ar, umidade relativa, velocidade do vento e taxa de transpiração. Isso dificulta a aplicação dessa abordagem em campo (OERKE; FRÖHLING; STEINER, 2011; ZHAO *et al.*, 2022).

Outra abordagem utilizada para avaliar o estado de saúde das plantas é baseada na medição da fluorescência associada à clorofila. Essa substância possui a característica de emitir luz quando estimulada por ondas eletromagnéticas em faixas específicas de frequências (HUANG *et al.*, 2019). Como a clorofila contém informações relacionadas ao estado fisiológico das plantas, a imagem por fluorescência pode ser aplicada para detectar variações na composição da clorofila e avaliar a saúde das plantas (MAHLEIN, 2016). LEI *et al.* (2019) implementaram um sistema baseado em um detector de fluorescência para avaliar a presença dos fungos *Leptosphaeria maculans* e *Leptosphaeria biglobosa* no cultivo de canola. Os resultados indicam que o sistema tem potencial para a detecção dos fungos, além de ser mais simples, rápido e de menor custo monetário quando comparado com o PCR. Porém, o PCR é considerado um método mais confiável e, em alguns casos, demonstrou-se superior à do sistema desenvolvido. Outra desvantagem é que o sistema requer um tratamento específico na amostra antes de realizar a medição, dificultando a aplicação em campo. HUANG *et al.* (2019) fizeram uma análise do potencial do sensor Multiplex®3, especializado na medição da autofluorescência, para monitorar o *status* de nitrogênio em plantas. Os experimentos foram realizados aplicando 5 taxas distintas

de nitrogênio no cultivo de arroz. Os resultados foram analisados aplicando vários índices de fluorescência e o melhor foi obtido com o índice NBI (*N balance index*) alcançando 90% de acurácia na classificação. Para obter esse resultado, antes de realizar as medições, as amostras coletadas das plantas passaram por um tratamento específico. O principal desafio para aplicar essa tecnologia em campo tem sido a necessidade de preparar a amostra, antes da medição, seguindo protocolos rigorosos (MAHLEIN, 2016; WANG *et al.*, 2022).

Alguns pesquisadores consideram que os métodos que utilizam a reflexão hiperespectral são os que têm maior potencial para detectar e distinguir diferentes tipos de patologias (BERDUGO *et al.*, 2014; MAHLEIN, 2016; TERENCEV *et al.*, 2022). O princípio de funcionamento da reflexão hiperespectral é semelhante ao de uma câmera RGB. O sensor mensura a quantidade de luz refletida na planta, geralmente nas folhas, para diferentes faixas de comprimento de onda que podem variar no intervalo de 400 nm a 2500 nm. O resultado da medição, como ilustrado na Figura 1, é uma matriz tridimensional, composta por duas dimensões espaciais e uma dimensão espectral, referida como assinatura espectral (TERENCEV *et al.*, 2022).

Figura 1 – Exemplo de uma imagem hiperespectral, formada por uma matriz tridimensional. Duas dimensões são espaciais e uma é espectral.



Fonte: Adaptado de MANOLAKIS *et al.* (2003).

A intensidade das reflexões tem relação com a pigmentação, estrutura interna e composição química das folhas (TERENCEV *et al.*, 2022). Essas características sofrem variações quando a planta é estressada tanto por fatores bióticos quanto por abióticos. Como consequência, a assinatura espectral da medição traz informações sobre o estado fisiológico da planta (MAHLEIN, 2016). WANG *et al.* (2019) desenvolveram um novo método para detecção, no estágio inicial, de doenças em plantas baseado em imagem hiperespectral. A principal contribuição do trabalho é a implementação de um sistema de tratamento de *outliers*, com potencial para aumentar o desempenho dos sistemas que utilizam o método clássico de seleção de banda de

espectro. Os experimentos foram realizados para detectar a infecção pelo TSWV (*tomato spotted wil virus*) em folhas de tomateiro (*Solanum lycopersicum L.*) e os resultados apresentaram classificação com taxa média de acertos de 96,25%. GOLD *et al.* (2020) usaram a reflexão hiperespectral para detectar e fazer a distinção entre as doenças requeima (*Phytophthora infestans*) e a pinta preta (*Alternaria solani*) à medida que progrediam nas folhas do cultivo de batata (*Solanum tuberosum L.*). A taxa de acertos na distinção entre as duas doenças foi de 80%, para amostras coletadas entre 2 e 4 dias antes do surgimento dos sintomas visíveis a olho nu. No diagnóstico das doenças, de forma individual, a taxa de acertos foi de 89%. Os autores ressaltam que algumas características espectrais importantes para a detecção da requeima sofrem variações durante a evolução da infecção, enquanto que para a pinta preta as principais características se mantêm consistentes.

Apesar dos resultados promissores, a reflexão hiperespectral é sensível às condições climáticas, gera uma quantidade enorme de dados dificultando o processamento e tem alto custo monetário. Esses são os principais desafios para que essa tecnologia seja utilizada em campo de forma plena (THOMAS *et al.*, 2018; HEIM *et al.*, 2019; TERENCEV *et al.*, 2022). Uma opção à reflexão hiperespectral com um custo monetário menor, porém ainda alto, é a reflexão multiespectral. Esta funciona da mesma forma que a primeira, sendo que a diferença está na quantidade de faixas de frequências medidas que é consideravelmente menor (MAHLEIN, 2016). HEIM *et al.* (2019) construíram um sistema formado por um veículo aéreo não tripulado e um sensor multiespectral para detectar a doença *Myrtle Rust* (*Austropuccinia psidii*) no cultivo de murta limão (*Backhousia citriodora*). Foram coletadas imagens aéreas multiespectrais de dois cultivos, um infectado com *Austropuccinia psidii* (*Myrtle Rust*) e o outro saudável. Um classificador, baseado em *Random Forest*, foi treinado com índices espectrais de vegetação e com bandas espectrais únicas. A classificação entre plantas doentes e saudáveis teve uma taxa de acertos de 95%. Para alcançar esse resultado foi assumido que as plantas ou estavam saudáveis ou infectadas com o fungo. A possibilidade de um segundo fator estressor foi descartada. O autor ressalta que, apesar dos resultados promissores, os sensores hiperespectrais são mais indicados para esse tipo de análise. KERKECH; HAFIANE; CANALS (2020) implementaram um sistema baseado em imagens multiespectrais para a detecção automática dos sintomas do míldio em videiras (*Plasmopara viticola*). O objetivo do trabalho foi mapear áreas infectadas em vinhedos para permitir um tratamento rápido e preciso. O método desenvolvido combina imagens nos espectros visível e infravermelho, obtidas por dois sensores distintos acoplados a um veículo aéreo não tripulado (UAV). Os autores propuseram um novo método baseado no registro de imagem otimizado e os dados foram processados através de uma rede neural convolucional com treinamento baseado na técnica de aprendizado profundo (*deep learning*). O sistema enquadra



cada pixel em uma das 4 classes possíveis que são: sombra, solo, planta saudável e planta com sintomas da doença. As classes sombra e solo são parte dos dados cujas informações são descartadas. Apenas as classes planta saudável e planta com sintomas da doença indicam o *status* de saúde das plantas. O método proposto alcançou mais de 92% de detecção em toda a planta e 87% em folha. A reflexão multiespectral possui as mesmas limitações que a hiperespectral. Sendo que, como a quantidade de faixas de frequências medidas é menor, a quantidade de dados gerado é menor e o potencial para a realização do diagnóstico também é inferior (MAHLEIN, 2016; HEIM *et al.*, 2019).

Dentro da reflexão hiperespectral também estão as abordagens que usam o NIR (*near infrared*). O princípio de funcionamento é o mesmo da reflexão hiperespectral, a diferença está na faixa de comprimento de ondas ou frequências utilizadas. Enquanto a reflexão hiperespectral trabalha na faixa de 400 nm a 2500 nm, o NIR fica entre 700 nm e 2500 nm. MORELLOS *et al.* (2020) desenvolveram um sistema para a detecção da virose *Tomato Chlorosis Virus* (ToCV) em tomateiro. O objetivo do trabalho foi diagnosticar o vírus no estágio inicial da doença e o nível de severidade da infecção, através da reflexão espectral na faixa de comprimento de ondas do NIR e também no espectro visível. As medições foram realizadas em laboratório com um espectrômetro. Na etapa de processamento dos dados inicialmente foi aplicada a ferramenta NCA (análise por componente de vizinhança) para selecionar quais os comprimentos de onda mais efetivos e quais os índices de vegetação mais importantes dentre os 24 que foram testados. Para fazer a detecção da doença e quantificar a carga viral foram utilizados dois métodos de *machine learning*, o XY-F (*XY-fusion network*) e o MLP-ARD (*multilayer perceptron with automated relevance determination*). Os resultados foram analisados antes e depois da eliminação dos *outliers*. Antes de remover os *outliers* a classificação alcançou taxas de acertos de 92,1% e 88,3% para o MLP-ARD e o XY-F, respectivamente. Após a eliminação, a classificação atingiu os 100% para os dois métodos. Os números são promissores, mas o texto não deixou claro para quanto tempo antes do surgimento dos sintomas visíveis a olho nu esses resultados foram obtidos. É importante ressaltar que, segundo os autores, os índices de vegetação performaram um pouco melhor quando comparados com os comprimentos de onda que foram escolhidos pelo NCA. BROWN; POOLE (2023) utilizaram algoritmos de aprendizagem de máquina aplicados a imagens RGB e multiespectrais, tanto na faixa visível quanto no infravermelho próximo, para a detecção de desidratação de plantas no estágio inicial do estresse. Após investigarem as frequências adequadas a serem medidas, foram realizadas duas sessões de coleta de dados, capturando imagens RGB e imagens de múltiplos espectros (VIS-IR) de seis espécies de plantas. As medições foram conduzidas ao longo do ciclo das plantas, desde os estágios saudáveis até os estágios de desidratação. Foi reali-

zada uma comparação entre os resultados obtidos com as imagens multiespectrais (VIS-IR) e com as imagens RGB. Nos testes foram empregadas três arquiteturas de aprendizado profundo. O melhor resultado foi alcançado com o modelo ResNet-44 aplicado às imagens multiespectrais, com 92,5% de acurácia na detecção precoce de desidratação. Para as imagens RGB a acurácia foi de 77,5%.

Para o NIR, as fronteiras são semelhantes às da reflexão multi e hiperespectral. No entanto, existem fatores que dificultam a aplicação dessas tecnologias em campo como a sensibilidade aos fatores ambientais (chuva, sombra e posição da luz solar), a grande quantidade de dados gerados, o alto custo monetário, a dificuldade em detectar padrões de assinaturas espectrais que não mudem ao longo do desenvolvimento do cultivo, a perda de desempenho na generalização, entre outros (MAHLEIN, 2016; ABDELGHAFOR *et al.*, 2023).

Alguns autores também trazem a fusão de dados em sistemas multissensores como uma abordagem promissora. Eles afirmam que dessa forma é possível aumentar a taxa de acertos da classificação (SAMARAS *et al.*, 2019; REYANA *et al.*, 2023). BERDUGO *et al.* (2014) desenvolveram uma abordagem utilizando fusão de dados que combina a termografia por infravermelho com a fluorescência da clorofila e imagens hiperespectrais. Os dados foram coletados por uma câmera infravermelho, um fluorômetro e um *scanner* hiperespectral. O trabalho faz a análise individual para as 3 abordagens utilizadas e compara com os resultados obtidos através da fusão dos dados. A avaliação da temperatura das folhas foi realizada através do método da máxima diferença de temperatura (MTD), a fluorescência da clorofila foi avaliada através do rendimento quântico efetivo do PS II, os dados da reflexão hiperespectral foram avaliados através da refletância média e alguns índices de vegetação espectrais, e a avaliação por fusão dos dados foi desenvolvida por uma abordagem multissensor baseada em análise discriminante.

Os experimentos foram realizados com 4 tratamentos, sendo eles: planta saudável, infectadas com o *Sphaerotheca fuliginea* (*Powdery Mildew*), *Cucumber Mosaic Virus* (CMV) e *Cucumber Green Mottle Mosaic Virus* (CGMMV). Para cada tratamento foram coletados dados usando as 3 abordagens. Os resultados indicam que a reflexão hiperespectral tem mais potencial para a detecção no estágio inicial da doença, bem como para distinguir diferentes tipos de doenças. Porém, com a fusão dos dados foi possível distinguir as doenças de forma antecipada, comparando com os resultados obtidos apenas com a reflexão hiperespectral. Mas, é preciso evoluir a técnica de fusão de dados utilizada, pois para algumas situações ela perde desempenho na classificação. REYANA *et al.* (2023) apresentaram uma abordagem chamada *Multisensor Machine-Learning Approach* (MMLA) para classificar dados de múltiplos sensores. Os dados processados contêm informações sobre o solo, tipo do cultivo e padrões climáticos. As informações relacionadas ao tipo do cultivo são coletadas

através de um sensor infravermelho que mede as dimensões das plantas. Também são mensuradas a temperatura e a umidade tanto do solo quanto do ar. Com base nessas grandezas o sistema proposto classifica oito tipos de culturas usando três algoritmos de aprendizado de máquina (*J48 Decision Tree*, *Hoeffding Tree* e *Random Forest*). A avaliação do desempenho do classificador considera métricas como precisão, *recall*, *F-measure*, MCC, ROC Area e PRC Area. Os resultados são comparados com classificadores do estado da arte, e o algoritmo Random Forest apresentou o melhor desempenho. Os autores afirmam que essa abordagem de fusão de dados melhora a precisão na previsão, resultando em um aumento significativo no rendimento das colheitas.

Outra abordagem promissora para o diagnóstico, no estágio inicial, de doenças e pragas em plantas é através dos compostos orgânicos voláteis (VOCs - *Volatile organic compounds*) emitidos pelas plantas. Os VOCs fornecem informações importantes sobre o estado fisiológico das plantas (YOU *et al.*, 2022). Eles também carregam informações sobre infestação de insetos e danos mecânicos (CUI *et al.*, 2018). A tecnologia mais utilizada para medir os VOCs é a matriz de sensores de gás, denominada por nariz eletrônico (*E-Nose - electronic nose*). HAZARIKA *et al.* (2020) construíram uma matriz de sensores de gás para detectar o vírus da tristeza do *citrus* no cultivo de tangerina. O protótipo foi desenvolvido com base em dados de simulação e em experimentos realizados com um *E-Nose* comercial. Os resultados são promissores, os dados foram processados através da ferramenta matemática *k-nearest neighbors*, alcançando uma taxa de acertos de 99,36%. CUI *et al.* (2019) desenvolveram um nariz eletrônico para a detecção, no estágio inicial, de infestação de áfidos (pulgões), no cultivo de tomate em estufas. Os experimentos foram realizados utilizando o sistema desenvolvido e um sensor comercial baseado em espectrometria de massa por cromatografia em fase gasosa. Os resultados obtidos por ambos foram condizentes e a classificação feita pelo sistema proposto, utilizando a ferramenta PCA (*principal component analysis*), atingiu 86,7% de precisão. Os sensores de gás são sensíveis às variáveis fluxo de ar, temperatura e umidade, o que dificulta a aplicação desses sistemas em campo. Porém, a principal limitação dessa tecnologia é que, como a quantidade de VOCs emitidos pelas plantas é pequena, é necessário que a planta esteja em uma câmara, ou algum outro dispositivo fechado, para que os VOCs sejam acumulados e a medição seja realizada (CUI *et al.*, 2018).

Outro destaque é a espectroscopia de impedância elétrica (EIS - *electrical impedance spectroscopy*). A impedância dos tecidos biológicos é formada por três componentes principais: os fluidos intra e extracelulares, com efeito resistivo, e as membranas celulares, com efeito capacitivo. Esses componentes sofrem alterações quando as plantas são infectadas por algum agente estressor. Assim, medindo-se a bioimpedância é possível acessar o estado de saúde das plantas (BAR-ON; SHACHAM-

DIAMAND, 2021; TANG *et al.*, 2023). NOUAZE *et al.* (2022) avaliaram a aplicação da EIS para detectar mudanças fisiológicas em folhas de alface quando submetidas ao estresse hídrico. O experimento foi conduzido em ambiente controlado ao longo de 16 horas, com as medições sendo realizadas a um período de amostragem de 12 minutos. Para a coleta dos dados foram utilizados um analisador de impedância comercial e eletrodos de superfície. As análises foram realizadas usando o modelo *double-shell* (DSM). Durante a absorção de água foi observado um aumento rápido no valor das componentes resistivas do modelo e uma redução no valor das componentes capacitivas. Por outro lado, uma diminuição gradual nas componentes resistivas e um aumento nas capacitivas foram observadas com a luz de LED ligada. Segundo os autores, os resultados indicam que a EIS tem potencial para a detecção precoce de estresse hídrico, doenças e falta de nutrientes em plantas.

BORGES *et al.* (2014) desenvolveram um sistema de EIS para avaliar o estado fisiológico de plantas. Apesar da EIS ser muito utilizada em diversas áreas, o trabalho é o primeiro a aplicá-la no monitoramento das principais condições fisiológicas das plantas (estado saudável, nível de estresse hídrico e doença). Os experimentos foram realizados utilizando três espécies de plantas, parte das plantas foi submetida ao estresse hídrico e outra parte foi inoculada com nematoides. Os dados foram analisados utilizando alguns índices específicos e os resultados são promissores, o sistema fez a distinção entre as plantas saudáveis, as inoculadas com os nematoides e as com estresse hídrico. O sistema é robusto e fácil de implementar, no entanto, os experimentos foram realizados em condições controladas. ALEJNIKOV; CHESHKOVA; MINEEV (2020) desenvolveram um estudo para analisar quais parâmetros da espectroscopia de impedância elétrica são relevantes na detecção de infecções por fungos no cultivo de morango. Os dados foram obtidos através de um analisador de impedância comercial, em laboratório e em condições controladas (temperatura e umidade). Os experimentos foram realizados para detectar e diferenciar a presença de manchas brancas, marrons e angulares nos morangos. Os resultados experimentais foram analisados com a finalidade de determinar os parâmetros de EIS mais relevantes para a aplicação do trabalho. Observou-se que o parâmetro mais relevante é a reatância elétrica e na região de baixas frequências (200 Hz a 10 kHz), possibilitando distinguir as 4 classes (saudável, manchas brancas, marrons e angulares). MEIQING *et al.* (2017) investigaram a sensibilidade da EIS à variação do nível de nutrição de nitrogênio (N) no cultivo do tomate, com o objetivo de detectar o estresse no estágio inicial. Os experimentos foram realizados aplicando 5 níveis de nitrogênio. Os dados foram processados utilizando análise de componentes principais (PCA) e observou-se a formação de 5 *clusters*, sendo cada um correspondente a um nível de concentração de nitrogênio. Com a mesma abordagem, em (MEIQING *et al.*, 2016), os autores avaliaram a aplicação da EIS na detecção de 5 níveis de con-

centração de potássio no cultivo de tomate e o resultado da classificação foi similar ao obtido para os 5 níveis de nitrogênio. Os resultados são animadores, porém, os experimentos foram realizados em condições controladas.

BAR-ON; SHACHAM-DIAMAND (2021) apresentaram um estudo avaliando a aplicação da EIS no monitoramento de ciclos de hidratação/desidratação em tabaco, *Nicotiana Tabacum*. Os experimentos foram realizados em ambiente controlado, mantendo uma sequência de 3 dias com irrigação padrão, seguido por 48 horas sem irrigação. Os dados foram coletados através de um analisador de impedância comercial, utilizando eletrodos invasivos. Os resultados foram comparados com as tradicionais medições por gravimetria, indicando que a bioimpedância elétrica depende do estado de saúde da planta. É importante ressaltar que os melhores resultados foram obtidos com as medições realizadas em baixas frequências. TANG *et al.* (2023) analisaram a relação entre o teor de umidade nas folhas (LMC) de tomateiros e a bioimpedância. O experimento foi conduzido com vinte e cinco vasos de tomateiros irrigados com quantidades diferentes de água antes do experimento, resultando em diferentes teores iniciais de umidade nas plantas. Durante os testes subsequentes, as amostras não foram mais regadas. As medições foram realizadas utilizando eletrodos invasivos e um analisador de impedância comercial. Alguns algoritmos de regressão foram utilizados para estimar o teor de umidade na folha (LMC). O melhor resultado foi obtido utilizando o método *random forest* (RF). Os resultados indicam que a EIS combinada com o RF tem potencial para prever o LMC.

Como mencionado na introdução, a principal limitação comum aos trabalhos citados no parágrafo anterior é a sensibilidade às variáveis ambientais. E, apesar da medição da bioimpedância ser considerada a abordagem com maior potencial para a detecção da doença, no estágio inicial (MEIQING *et al.*, 2017; TANG *et al.*, 2023), os trabalhos têm destacado a dificuldade de implementar essa abordagem em ambientes não controlados.

Outra característica marcante nos trabalhos que envolvem a medição de bioimpedância é a busca intensa por dados, levando os pesquisadores à busca da aplicação da EIS na maior largura de frequência possível. Além disso, tenta-se usar a maior quantidade de parâmetros possível, como fase, módulo, parte real e imaginária da bioimpedância, bem como a combinação entre eles, no processamento de dados para a classificação (BAR-ON; SHACHAM-DIAMAND, 2021; TANG *et al.*, 2023). Isso gera bases de dados extensas, dificultando o processamento (BAR-ON; SHACHAM-DIAMAND, 2021). Como parte desta tese, foi analisado experimentalmente que é possível alcançar resultados similares ao estado da arte medindo a bioimpedância para uma única frequência e usando apenas um parâmetro da bioimpedância. No Capítulo 4 é apresentada uma discussão detalhada sobre esses aspectos, além disso,

resultados parciais desta tese estão publicados (CARVALHO *et al.*, 2022).

No próximo capítulo, serão apresentados alguns fundamentos teóricos importantes para a compreensão dos aspectos relacionados à aplicação da bioimpedância na detecção de estresses e doenças em plantas, bem como os fundamentos que embasam a abordagem proposta.

### 3 FUNDAMENTAÇÃO TEÓRICA

O sistema apresentado nesta tese trabalha com a impedância elétrica,  $Z(\omega)$ . A impedância representa a oposição à passagem de corrente elétrica em circuitos que são alimentados por fontes de tensão ou corrente elétrica alternadas, sendo  $\omega$  a frequência do sinal de alimentação. Os fenômenos físicos que compõem a impedância elétrica estão relacionados com resistências elétricas, reatâncias capacitivas e reatâncias indutivas. Os componentes elétricos que provocam esses fenômenos são os resistores, capacitores e indutores, respectivamente. Esses elementos são utilizados para modelar o tecido das plantas, como descrito na Seção 3.2. É importante ratificar que a impedância dos tecidos biológicos, tanto para vegetais quanto para animais, é denominada por bioimpedância.

Existem alguns conceitos importantes relacionados à bioimpedância, necessárias para descrever o comportamento elétrico e também para a construção de modelos elétricos que representem o tecido biológico tanto para plantas quanto para animais. Nas seções 3.2, 3.3, 3.4 e 3.5 são apresentados os conceitos básicos para o estudo da bioimpedância em tecidos biológicos. O estado da arte no estudo de tecidos vegetais e animais está baseado na aplicação da espectroscopia de impedância elétrica (EIS) para a aquisição dos dados. Apesar do sistema apresentado nesta tese medir a bioimpedância com apenas uma única frequência, na Seção 3.6 está descrito como a EIS é aplicada para realizar medições em tecidos biológicos.

Além dos aspectos teóricos relacionados à bioimpedância e à modelagem do tecido elétrico das plantas, neste capítulo também são abordados conceitos sobre a dinâmica da propagação de doenças em cultivos, importante para descrever como as doenças surgem e se espalham ao longo da área cultivada. São apresentados também os fundamentos das rede de sensores sem fio e finalmente, a medição baseada em Superfície de Impedância com os detalhes de sua implementação.

### 3.1 Contextualização Histórica da Medição de Bioimpedância

As medições de impedância elétrica em sistemas físicos iniciaram em 1894 pelo físico-químico alemão Walther Nernst. Nos trabalhos realizados ele aplicou a ponte de Wheatstone para medir constantes dielétricas de eletrólitos aquosos e de fluidos orgânicos (SANTORO, 2014). A espectroscopia de impedância elétrica (EIS) foi originalmente aplicada em trabalhos envolvendo sistemas eletroquímicos, e a sua utilização em sistemas biológicos iniciou na década de 1920 (ZHAO *et al.*, 2017). Isso possibilitou estudos mais criteriosos sobre as características elétricas do tecido biológico e, no ano de 1928, Kenneth Cole construiu o primeiro modelo analítico para a impedância de tecidos biológicos, como também analisou dois circuitos elétricos equivalentes para o modelo (COLE, 1928). Porém, antes do modelo analítico de Cole, M. Philippon já havia apresentado um modelo elétrico para o tecido biológico em um artigo publicado no ano de 1921, e o físico dinamarquês Hugo Fricke também já tinha desenvolvido outro modelo elétrico para o tecido biológico. O modelo de Fricke foi desenvolvido em trabalhos publicados entre os anos de 1924 e 1926, baseando-se no modelo de esferas em suspensão, onde as esferas representam as células do tecido, e a fase líquida da suspensão emula o meio extracelular. Durante a fase experimental Fricke realizou vários ensaios com algumas misturas derivadas do leite (FRICKE, 1931). Ao longo dos anos, outros modelos foram construídos, incluindo o proposto por HAYDEN *et al.* (1969), que realizaram experimentos com batatas e alfafa, a fim de construir um modelo que representasse o tecido biológico. Apesar de já existirem os modelos elétricos de Philippon, Fricke e Cole, havia a necessidade de aprofundar o conhecimento do comportamento dos tecidos biológicos quando percorridos por correntes elétricas em diferentes faixas de frequências. Nesse contexto, SCHWAN (1957) apresentou a teoria das dispersões elétricas, conhecida como teoria das dispersões de Schwan, fortalecendo os estudos da EIS na caracterização de sistemas biológicos.

A atenção dos pesquisadores se voltou para a aplicação da EIS no controle de qualidade de frutas e vegetais na década de 1990 (EL KHALED *et al.*, 2017), e a maior parte dos trabalhos que utilizam a EIS na detecção de doenças em plantas é ainda mais recente (BORGES *et al.*, 2014). Nas últimas décadas a EIS tem sido aplicada em diversos sistemas. Vários trabalhos utilizam a EIS na caracterização de sólidos, líquidos e suspensões, como na caracterização de camadas de polímeros eletroativos (YANG *et al.*, 2022), no estudo de resistência de materiais quando expostos a algum tipo de solução química (CARANGELO *et al.*, 2016), entre outras aplicações. Nas aplicações em tecidos biológicos, destacam-se a caracterização de alimentos, a área médica e a botânica. Com o crescente interesse no controle de qualidade dos alimentos, a EIS tem sido aplicada para avaliar a qualidade e frescor



da carne proveniente de alguns animais (HUH *et al.*, 2021), a EIS também tem sido aplicada na avaliação da qualidade de vinhos e leite (LOPES *et al.*, 2018; CETÓ *et al.*, 2024).

Na medicina a EIS é aplicada em analisadores de sangue para determinar o hematócrito (CHAKRABORTY *et al.*, 2020), na estimação do volume relativo de diferentes líquidos ou tecidos (*e.g.*, usado para avaliar a quantidade de gordura e de outras substâncias do corpo) (NEVES; SOUZA, 2000), na detecção de câncer e caracterização do tecido, visto que diferentes tecidos apresentam diferentes parâmetros de condutância (JUNG *et al.*, 2021), e a EIS ainda é utilizada na tomografia de impedância elétrica (TIE) (BASAK; WAHID, 2022). No campo veterinário a EIS é aplicada na detecção de vírus e doenças (CORDEIRO *et al.*, 2019).

A EIS vem sendo aplicada na botânica em duas linhas principais, no estudo da maturidade e qualidade de frutas e legumes e na avaliação do *status* de saúde das plantas. IBBA *et al.* (2018) utilizaram a EIS para estudar o padrão da variação de impedância no amadurecimento da banana, IBBA *et al.* (2020) aplicaram a EIS para caracterizar a qualidade de frutas. MEIQING *et al.* (2017) utilizaram a EIS para o diagnóstico precoce e monitoramento do estresse nutricional de nitrogênio em folhas de tomate, TANG *et al.* (2023) analisaram a relação entre a bioimpedância e o teor de umidade nas folhas de tomateiros (LMC - *leaf moisture content*).

Em particular, a EIS tem se destacado na avaliação do *status* de saúde das plantas pelo potencial que tem em obter informações de forma antecipada, quando comparada com a refletância multi e hiperespectral, imagem RGB e NIR, que são outras abordagens aplicadas na detecção de doenças em plantas (MEIQING *et al.*, 2017). As primeiras alterações nas plantas, devido às doenças, geralmente ocorrem nas células e nos fluidos intra e extracelulares. Esses fatores estão diretamente correlacionados com a bioimpedância da planta, como explanado na Seção 3.2 (AMORIM, 2018; TANG *et al.*, 2023).

### 3.2 Composição Elétrica do Tecido Biológico

A unidade básica do tecido é a célula, e a bioimpedância é determinada pela estrutura de um conjunto de células (HAYDEN *et al.*, 1969). Os principais fatores que constituem a bioimpedância de um tecido biológico são os fluidos intra e extracelulares e as membranas celulares (BORGES *et al.*, 2014). Para o modelo elétrico, o fluido extracelular é considerado como uma solução iônica onde as propriedades elétricas do meio são determinadas por parâmetros físico-químicos. Desse modo, o fluido extracelular pode ser representado eletricamente por um resistor (IVORRA CANO, 2005).

A parte interior das células também é considerada como uma solução iônica. Po-

rém, nela existem algumas estruturas envolvidas por membranas que são formadas por materiais dielétricos com baixa condutividade. Assim, o modelo elétrico do fluido intracelular é formado por componentes resistivos e capacitivos (IVORRA CANO, 2005). No entanto, o modelo pode ser simplificado desprezando-se a parte capacitiva. Assim, o fluido intracelular é representado eletricamente por um resistor (IVORRA CANO, 2005; BORGES *et al.*, 2014). Enquanto que os fluidos intra e extracelulares são meios iônicos com baixa resistividade, as membranas celulares são formadas por moléculas lipídicas com alta resistividade. Assim, o arranjo formado pelo fluido extracelular, membrana celular e fluido intracelular é modelado por um capacitor (IVORRA CANO, 2005).


Devido à composição elétrica do tecido biológico, o fluxo de corrente elétrica nele é dependente da frequência, como ilustrado na Figura 2. Para baixas frequências considera-se que a corrente circula apenas pelo fluido extracelular, pois o dielétrico da membrana celular em conjunto com os fluidos intra e extracelulares oferecem uma reatância capacitiva muito alta e a corrente que circula no meio intracelular é desprezível (ANDO; MIZUTANI; WAKATSUKI, 2014). Nesse caso, a bioimpedância é predominantemente resistiva. Para frequências maiores, a reatância capacitiva diminui e a corrente passa a circular no meio intracelular. Para esse segundo caso, a bioimpedância tem componentes resistivos e capacitivos significativos (ANDO; MIZUTANI; WAKATSUKI, 2014). E quando a frequência atinge valores muito altos a reatância capacitiva assume valores muito pequenos e a bioimpedância volta a ser predominantemente resistiva, mas nesse último caso a corrente percorre tanto o meio extra quanto o intracelular (ZHAO *et al.*, 2017). Na Seção 3.4 são apresentados alguns modelos elétricos para o tecido biológico. O estudo desses modelos complementa o que está descrito neste parágrafo. E na Seção 3.3 é apresentado como as dispersões dielétricas ocorrem nos tecidos biológicos para diferentes faixas de frequências.

### 3.3 Dispersões Dielétricas em Sistemas Biológicos

Para trabalhar com a espectroscopia de impedância elétrica é fundamental conhecer a teoria das dispersões dielétricas nos sistemas biológicos. Com essa teoria é possível saber como a corrente elétrica se propaga pelo tecido em faixas de frequências distintas. Segundo a teoria das dispersões dielétricas apresentada por SCHWAN (1957) as propriedades elétricas de materiais biológicos variam em função da frequência.

SCHWAN (1957) apresentou um estudo que traz três tipos principais de dispersões para os tecidos biológicos e células em suspensão, a dispersão- $\alpha$ , a dispersão- $\beta$  e a dispersão- $\gamma$ , que acontecem em três bandas de frequências distintas. Na Fi-

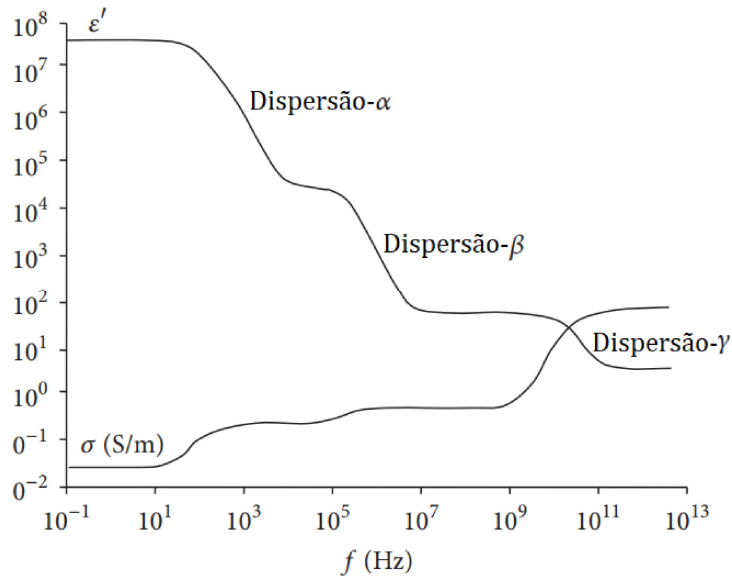
Figura 2 – Ilustração de como a corrente elétrica percorre o tecido biológico para baixas e altas frequências.



Fonte: Traduzido de: ANDO; MIZUTANI; WAKATSUKI (2014).

Figura 3 são ilustradas as três regiões de dispersão para a condutividade  $\sigma$  e para a permissividade  $\epsilon'$  em sistemas biológicos.

Figura 3 – Ilustração com os três tipos de dispersões para os tecidos biológicos e células em suspensão proposto por Schwan. Sendo  $\sigma$  a condutividade e  $\epsilon'$  a permissividade.



Fonte: Traduzido de: ZHAO *et al.* (2017).

É importante ressaltar que, para tecidos biológicos diferentes, as bandas de frequências das dispersões sofrem variações, então é impossível determinar o valor dessas bandas de forma geral. A dispersão- $\alpha$  acontece no intervalo de mHz a poucos kHz. Ela ocorre devido ao fenômeno de polarização da dupla camada do tecido (PETHIG; KELL, 1987). O fluxo de corrente acontece apenas no meio extracelular devido à difusão e ao movimento lateral dos íons ao longo da membrana

celular (GUERMAZI; KANOUN; DERBEL, 2014). As medições de bioimpedância nessa faixa de frequência contêm informações importantes sobre o meio extracelular.

A dispersão- $\beta$  acontece na faixa de alguns kHz a poucos MHz, devido principalmente ao efeito capacitivo da interação entre a membrana celular (dielétrico) e os fluidos intra e extracelulares. Essa dispersão é associada com as propriedades dielétricas das membranas celulares. As medições de bioimpedância nessa faixa de frequência trazem informações importantes sobre o comportamento da membrana celular e da interação dela com os meios intra e extracelulares. E o fluxo de corrente acontece tanto no meio extracelular quanto no intracelular (GUERMAZI; KANOUN; DERBEL, 2014; ZHAO *et al.*, 2017).

A dispersão- $\gamma$  acontece apenas para altas frequências, na faixa das micro-ondas. Ela acontece devido à relaxação de dipolos permanentes em moléculas pequenas que, para os tecidos biológicos, são na maioria moléculas de água. Para essa dispersão o fluxo de corrente acontece tanto no meio extracelular quanto no intracelular. Nessa faixa de frequência a bioimpedância têm alta correlação com a quantidade de moléculas de água no tecido (GUERMAZI; KANOUN; DERBEL, 2014).

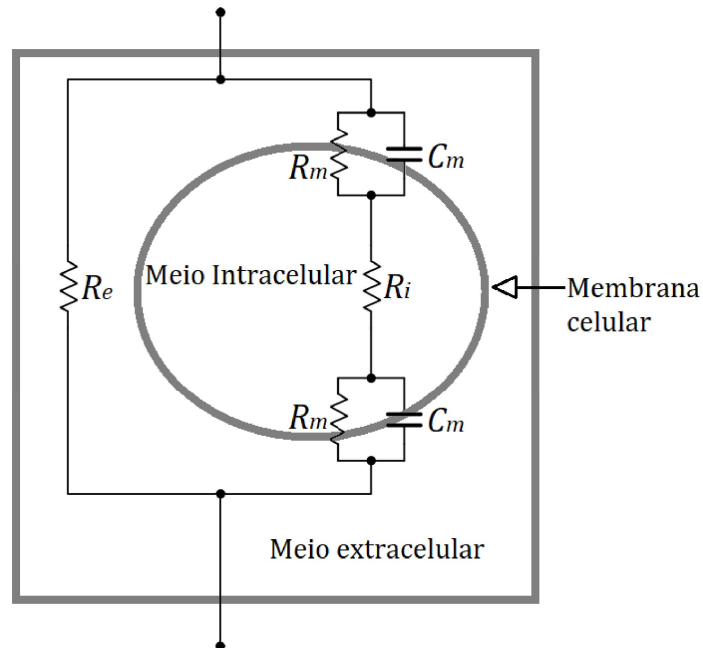
Observa-se que, cada tipo de dispersão está relacionado com características diferentes do tecido biológico. Assim, para diferentes aplicações da espectroscopia de impedância elétrica, as faixas de frequências de interesse podem variar. Inclusive, até para aplicações no mesmo tecido biológico as frequências de interesse variam quando há a necessidade de analisar diferentes características do tecido (BORGES *et al.*, 2014). Para melhor estudar e compreender os tecidos biológicos alguns modelos elétricos, que representam esses tecidos, foram desenvolvidos ao longo do século 20. Alguns desses modelos são apresentados na Seção 3.4.

### 3.4 Modelos Elétricos para os Tecidos Biológicos

As principais estruturas que compõem o modelo elétrico do tecido biológico são os meios intra e extracelulares e a membrana celular. Essas estruturas podem ser modeladas como ilustrado na Figura 4, em que os fluidos intra e extracelulares são representados por resistores,  $R_i$  e  $R_e$ , respectivamente, e a membrana celular por um capacitor em paralelo com um resistor,  $C_m$  e  $R_m$ , respectivamente, como discutido na Seção 3.2.

A membrana celular tem uma parcela resistiva,  $R_m$ , devido a canais de íons presentes nela. Porém, o valor de  $R_m$  é relativamente alto comparado à reatância capacitiva da membrana. Assim,  $R_m$  pode ser desprezado, simplificando o modelo (IVORRA CANO, 2005). Os capacitores podem ser representados por um capacitor equivalente, deixando o circuito ainda mais simples, como ilustrado na Figura 5. O modelo simplificado apresentado na Figura 5 foi desenvolvido pelo físico dinamarquês


Figura 4: Ilustração do modelo elétrico do tecido biológico.



Fonte: Adaptado de: IVORRA CANO (2005).

Hugo Fricke (FRICKE, 1931).

Figura 5: Modelo elétrico do tecido biológico desenvolvido por Hugo Fricke.




Fonte: Autor.

O modelo de Fricke é considerado por vários autores como um modelo elétrico elementar e com um excelente desempenho para simular sistemas biológicos em escala microscópica (ZHAO *et al.*, 2017). O modelo considera o tecido biológico como uma suspensão de células em um meio líquido ionizante. Como ilustrado na Figura 5, os fluidos intra e extracelulares são representados pelos resistores  $R_i$  e  $R_e$ , respectivamente, e a capacitância formada pela interação entre os fluidos internos, fluidos externos e a membrana celular é representada pelo capacitor  $C_m$ . Esse modelo foi construído baseado na modelagem de esferas em suspensão, sendo que a fase líquida da suspensão representa os fluidos extracelular e as esferas representam as células (FRICKE, 1931). Durante os ensaios, Fricke realizou vários experimentos com fluidos de diferentes concentrações derivados do leite.

Em 1928, cerca de dois anos após os trabalhos de Fricke, Kenneth S. Cole publicou o primeiro trabalho com um modelo analítico para a impedância de tecidos biológicos através de um modelo de esferas em suspensão. Nesse modelo, as esferas também representam as células, e a fase líquida o meio extracelular. O modelo considera o interior da esfera puramente resistivo, representando os fluidos intracelulares, e a membrana celular é representada por uma camada com propriedades capacitivas na superfície da esfera (COLE, 1928). No trabalho, Cole também discutiu o modelo elétrico ilustrado na Figura 6, que também representa o tecido biológico. Nesse modelo,  $R_2$  e  $C$  representam as resistências e capacitâncias das membranas celulares e  $R_1$  representa as resistências do protoplasma das células para um volume de 1 centímetro cúbico de tecido (COLE, 1928). Esse modelo foi apresentado por M. Philippon em 1921 (PHILIPPSON, 1921).

Figura 6: Modelo elétrico do tecido biológico apresentado por Philippon.



Fonte: Autor.


Os modelos de Fricke e Philippon apresentados nas figuras 5 e 6, respectivamente, são equivalentes (ZOBEL, 1923). Esses modelos representam com exatidão os experimentos com células em suspensão. Porém, a impedância dos tecidos biológicos é mais complexa e envolve reações e transformações desconhecidas (ZHAO *et al.*, 2017), e alguns trabalhos demonstram que a resistência do tecido e a capacitância da superfície celular variam com a frequência (COLE, 1932). Observando que, para vários experimentos, o ângulo de fase dessa combinação variável resistência-capacitância permanecia próximo a um valor constante para largas faixas de variação de frequência, COLE (1932) apresentou uma nova variação do modelo de Philippon. A alteração proposta por Cole consiste em substituir o capacitor do circuito apresentado na Figura 6 por um elemento de fase constante (CPE), como ilustrado na Figura 7. Esse elemento é irrealizável fisicamente e pode ser descrito como

$$\mathbf{Z}_{CPE} = \frac{1}{(j\omega C)^\alpha}, \quad (1)$$

sendo  $\alpha$  um parâmetro adimensional exponencial usado para corrigir o comportamento não estritamente capacitivo da membrana celular (ZHAO *et al.*, 2017).  $\alpha$  pode variar entre 0 e 1, para  $\alpha = 1$ ,  $\mathbf{Z}_{CPE}$  tem o comportamento de um capacitor e para  $\alpha = 0$ ,  $\mathbf{Z}_{CPE}$  tem o comportamento de um resistor. Apesar de vários trabalhos abordarem esse problema, o sentido físico de  $\mathbf{Z}_{CPE}$  ainda não está totalmente

compreendido.


Figura 7 – Modelo elétrico do tecido biológico apresentado por Cole. Esse modelo já inclui o elemento de fase constante (CPE).



Fonte: Autor.

Dentre os modelos elétricos apresentados nesta seção o mais clássico é o modelo modificado de Fricke, ilustrado na Figura 8. Esse modelo apenas substitui o capacitor presente no modelo de Fricke por um elemento de fase constante. Ele é utilizado em diversos trabalhos e apresenta bom desempenho na representação dos dados (ZHAO *et al.*, 2017). Outros modelos foram propostos, a exemplo dos modelos desenvolvidos por HAYDEN *et al.* (1969) e por (ZHANG; WILLISON, 1991), no entanto, o mais utilizado ainda é o modelo modificado de Fricke. Um aspecto importante para a utilização desses modelos é o ajuste dos parâmetros, realizado através do *Cole-Cole plot*, apresentado na Seção 3.5. Outro aspecto importante é entender como os eletrodos interagem com o tecido vegetal e como essa interação pode ser modelada.

Figura 8: Modelo modificado de Fricke.



Fonte: Autor.


Os eletrodos são terminais elétricos que conectam a amostra a ser mensurada ao instrumento de medição. Nas medições realizadas neste trabalho os eletrodos foram inserido no caule da planta, em uma região próxima ao solo. Portanto, para estudar a interação elétrica entre os eletrodos e o tecido da planta é necessário conhecer os tipos de tecido que formam o caule e como eles se comportam eletricamente.

Para analisar a condução de sinais elétricos, o tecido do caule pode ser dividido em dois grupos, que são os tecidos fundamentais e os tecidos vasculares. Os tecidos fundamentais compõem as regiões da medula, ou seja, a região central do caule e do córtex, que representa a região mais próxima à camada externa do caule. A condução

elétrica nesses tecidos ocorre através das membranas celulares, que possuem comportamento dielétrico, apresentando alta resistência à passagem de corrente elétrica (VOLKOV, 2006). Enquanto que os tecidos vasculares possuem dois comportamentos elétricos. As paredes dos vasos são formadas por membranas com comportamento dielétrico, possuindo alta resistência à passagem de corrente elétrica, enquanto que os fluidos internos aos vasos possuem baixa resistência à passagem de corrente elétrica. Assim, os fluidos vasculares são os principais condutores de corrente elétrica (BAR-ON *et al.*, 2021).

Conhecendo o comportamento elétrico do tecido do caule, é possível analisar a interação elétrica entre os eletrodos e o tecido da planta. Como a condução elétrica acontece majoritariamente através dos fluidos vasculares, e assumindo que os eletrodos têm o diâmetro da seção transversal pequeno, por volta de 0,3 mm, conclui-se que os eletrodos ficam em contato indireto com a maioria dos vasos. Sabendo-se que a parede dos vasos são formadas por membranas com comportamento dielétrico, a interação entre os eletrodos e o tecido da planta pode ser modelado por um capacitor (BAR-ON *et al.*, 2021). A rigor, a modelagem é dada pelo circuito apresentado na Figura 9, sendo que  $R_E$  representa a resistência de contato entre o eletrodo e os vasos,  $C_E$  representa a capacitância relacionada com as membranas dos vasos e  $R_{CC}$  representa a resistência à passagem de corrente contínua. Para medições em corrente alternada o resistor  $R_{CC}$  pode ser desconsiderado (GROSSI; RICCÒ, 2017). Bem como, para baixas frequências (Hz a centenas de kHz), a resistência  $R_E$  também pode ser desconsiderada (BAR-ON *et al.*, 2021). É importante ressaltar que esse modelo considera o uso de eletrodos invasivos.

Figura 9 – Representa o modelo elétrico da interação entre os eletrodos e o tecido da planta.  $C_E$  está relacionado com a capacitância das paredes dos vasos,  $R_E$  com a resistência de contato entre o eletrodo e os vasos e  $R_{CC}$  representa a resistência à passagem de corrente contínua.



Fonte: Autor.

### 3.4.1 Tipos de Eletrodos Usados para Medições em Plantas


Na medição de bioimpedância em plantas, existem duas classes principais de eletrodos utilizados. Uma classe é a dos eletrodos de superfície e a outra é a dos eletrodos invasivos. Enquanto os eletrodos de superfície ficam em contato superficial



com a região a ser mensurada, os eletrodos invasivos penetram a planta, geralmente no caule. Na Figura 10 está ilustrada a configuração usada por WU; OGAWA; TAGAWA (2008), com eletrodos de superfície. Esses eletrodos geralmente são anéis ou garras, são conectados um acima do outro e com um espaçamento predeterminado, como ilustrado na Figura 10. A vantagem desses eletrodos está na característica não invasiva, e a desvantagem é a necessidade de maior potência no circuito de excitação (KYLE *et al.*, 2004).

Geralmente, os eletrodos adotam a forma de anéis ou garras e são conectados em série, com um espaçamento predefinido, conforme ilustrado na Figura 10.

Figura 10 – Ilustração da configuração com eletrodos de superfície apresentada por WU; OGAWA; TAGAWA (2008). Sendo, 1, a amostra a ser medida, 2, os eletrodos de superfície e 3, o analisador de impedância.



Fonte: Adaptado de: WU; OGAWA; TAGAWA (2008).

Os eletrodos invasivos podem ser conectados na amostra em posição diamétrica, ilustrado na Figura 11 (a), ou em posição vertical, ilustrado na Figura 11 (b). Geralmente esses eletrodos são agulhas construídas com materiais de baixa resistividade e inerte ao meio (EL KHALED *et al.*, 2017).

Figura 11 – Aplicação dos eletrodos invasivos em posição diamétrica (a) e posição vertical (b).



Fonte: Autor.

Alguns cuidados devem ser tomados com o uso de eletrodos invasivos, pois a planta pode sofrer danos com a penetração dos eletrodos (ALI *et al.*, 2019). Assim, o eletrodo deve ser fino o suficiente e a penetração tem que ser a mínima possível. É comum encontrar eletrodos com diâmetros que variam entre 0,2 mm e 1 mm, e a profundidade de penetração pode variar de 1 mm a 11 mm. Esses números podem oscilar de acordo com a aplicação (BORGES *et al.*, 2014; ANDO; MIZUTANI; WAKATSUKI, 2014; EL KHALED *et al.*, 2017). Essa é a principal desvantagem desse tipo de eletrodo, a vantagem é que a potência necessária no circuito de excitação é menor, quando comparado aos eletrodos de superfície. Por essa razão, o sistema aplicado nos experimentos deste trabalho utiliza eletrodos invasivos.

Os eletrodos também podem influenciar no resultado das medições devido à resistência de contato (EL KHALED *et al.*, 2017). Uma solução para esse problema é apresentada na Seção 3.6, que consiste na medição com 3 ou 4 eletrodos. Outra forma de lidar com isso é fazendo a compensação da influência da resistência de contato através da calibração do sistema. Uma terceira abordagem para reduzir esse problema consiste no uso dos índices de quocientes entre impedâncias, conforme HAYASHI *et al.* (1992). Esses índices são calculados através do quociente entre impedâncias medidas em frequências distintas. O índice  $\frac{Z_A}{Z_B}$  equivale à divisão da impedância medida na frequência de  $A$  kHz pela impedância medida na frequência de  $B$  kHz (*e.g.*, o índice  $\frac{Z_1}{Z_{50}}$  representa o quociente entre as impedâncias medidas em 1 kHz e 50 kHz). Usando esses índices é possível atenuar a interferência dos eletrodos nos resultados (HAYASHI *et al.*, 1992).

Outro fator que pode influenciar nas medições são os cabos que ligam os eletrodos ao instrumento analisador de impedância. Esses cabos oferecem reatância e resistência à passagem do sinal elétrico, e também podem influenciar na relação sinal-ruído da medição. Quanto maior o comprimento deles, a presença dessas grandezas são mais acentuadas. A solução mais simples seria eliminar esses cabos ou reduzi-los. Porém, existem outros recursos para resolver esse problema, como a blindagem ativa e a compensação dessas grandezas usando modelos matemáticos (BORGES *et al.*, 2014).

### 3.5 Ajuste do Modelo

Os parâmetros da bioimpedância de um tecido biológico são ajustados através do modelo de Cole-Cole, que foi desenvolvido a partir da observação de diversos experimentos realizados por vários pesquisadores (COLE, 1932). A equação de Cole-Cole, utilizada para descrever a bioimpedância do tecido, é descrita por

$$\mathbf{Z}(\omega) = R_\infty + \frac{R_0 - R_\infty}{1 + (j\omega\tau)^\alpha}, \quad (2)$$

sendo  $\mathbf{Z}(\omega)$  a impedância complexa do tecido biológico,  $R_0$  a impedância do tecido medida com corrente contínua,  $R_\infty$  a impedância do tecido medida com "frequência infinita",  $\omega$  a velocidade angular,  $\tau$  a constante de tempo do modelo elétrico equivalente ou o tempo de relaxamento do sistema, e  $\alpha$  um índice adimensional usado para compensar o comportamento não estritamente capacitivo das membranas celulares (ZHAO *et al.*, 2017). A equação de Cole-Cole é derivada da equação que descreve os fenômenos de absorção de dispersão em materiais dielétricos, que é discutida em detalhe por COLE (1941).

Para ajustar a equação de Cole-Cole usando o modelo de Fricke, ilustrado na Figura 5, basta observar as equações

$$\tau = (R_i + R_e)C_m, \quad (3)$$

$$R_0 = R_e, \quad (4)$$

$$R_\infty = \frac{R_e R_i}{R_e + R_i}, \quad (5)$$

sendo  $C_m$  o capacitor que representa a interação entre a membrana celular e os meios internos e externos,  $R_i$  a resistência que representa os fluidos intracelulares e  $R_e$  a resistência que representa os fluidos extracelulares. É importante enfatizar que, apenas com as equações (3), (4) e (5) não é possível ajustar o  $\alpha$  da equação de Cole-Cole, pois elas são equivalentes ao modelo com dois resistores e um capacitor, como ilustrado na Figura 5, e não representam o elemento de fase constante com o qual o  $\alpha$  está relacionado, como descrito na equação (1). Também não é possível calcular o  $R_\infty$ , pois é impossível atingir a frequência infinita.

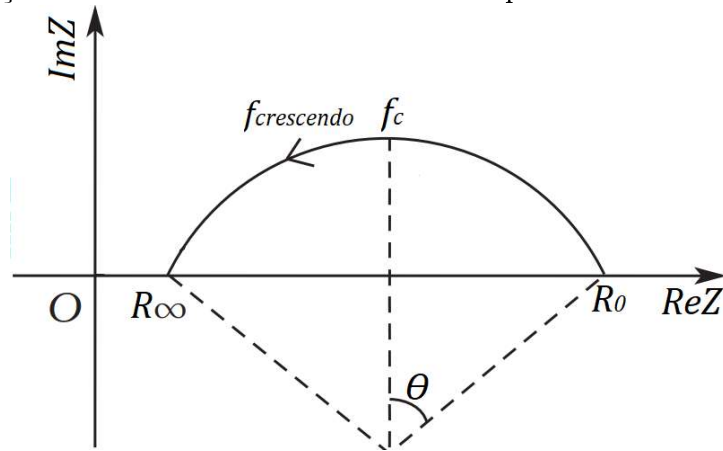
Para encontrar os valores de  $\alpha$  e  $R_\infty$  é preciso desenhar o gráfico de Cole-Cole, conhecido como *Cole-Cole plot*, que consiste em ajustar um arco aos dados experimentais através da construção de um gráfico bidimensional (parte imaginário da impedância,  $ImZ$ , versus a parte real,  $ReZ$ ), como ilustrado na Figura 12. Os dados devem conter medições da impedância do tecido para frequências variando de 0 Hz até a máxima frequência atingida pelo sistema.

No *Cole-Cole plot* o valor de  $R_0$  é determinado quando o arco cruza o eixo real com a frequência igual a 0 Hz,  $R_\infty$  é definido no ponto em que o arco cruza o eixo real com o valor da frequência no "infinito", e o  $\alpha$  é calculado a partir do ângulo  $\theta$ , denotado por

$$\theta = \alpha \frac{\pi}{2}, \quad (6)$$

com o ângulo  $\theta$  em radianos. Quando  $\alpha$  é 1 o elemento de fase constante vira um

Figura 12 – Gráfico de Cole-Cole, conhecido como *Cole-Cole plot*. É utilizado para ajustar a equação de Cole-Cole aos dados de um experimento.



Fonte: Adaptado de: ZHAO *et al.* (2017).

capacitor e o modelo fica igual ao de Fricke. Sendo  $f_c$  a frequência característica, nela a parte imaginária da impedância atinge o maior valor quando comparada com as outras frequências. A frequência característica é descrita por

$$f_c = \frac{1}{2\pi\tau}, \quad (7)$$

em que  $\tau$  é a constante de tempo do modelo elétrico equivalente ou o tempo de relaxamento do sistema (COLE; COLE, 1941; MCADAMS; JOSSINET, 1996; ZHAO *et al.*, 2017). Vale ressaltar que, para ajustar os parâmetros do modelo elétrico do tecido biológico por meio do *Cole-Cole plot*, é necessário realizar a EIS, assunto que é detalhadamente explorado na Seção 3.6.

Nas seções 3.2 a 3.5 foram abordados temas fundamentais para a compreensão da composição do tecido biológico e como esses tecidos podem ser representados eletricamente. Esses conhecimentos fornecem uma base teórica essencial para o desenvolvimento deste trabalho.

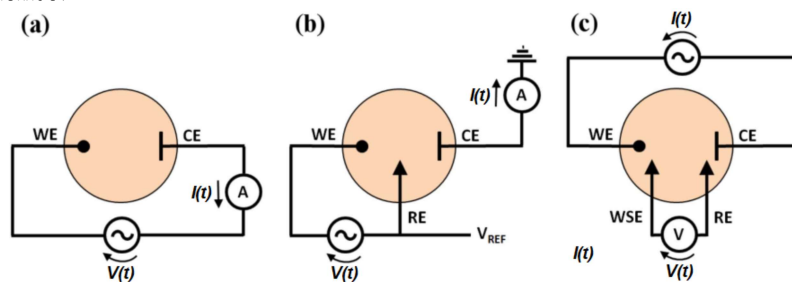
### 3.6 Espectroscopia de Impedância Elétrica

A espectroscopia de impedância elétrica (EIS) consiste na medição da impedância de um material para diferentes frequências de excitação. Ela vem sendo utilizada para analisar propriedades elétricas de materiais e sistemas em diversos campos. Nos experimentos com plantas, a EIS vem sendo empregada no campo da eletrofisiologia, que consiste no estudo das propriedades elétricas em células e tecidos biológicos.

A EIS é realizada através de circuitos que medem a impedância elétrica. Esses circuitos são controlados, geralmente por dispositivos programáveis, de forma a medirem a impedância para várias frequências dentro de um intervalo preestabelecido

(AL-ALI; MAUNDY; ELWAKIL, 2019). As abordagens clássicas para medir resistências e impedâncias são baseadas em circuitos em ponte, e a ponte de Wheatstone é a configuração mais utilizada (BALBINOT; BRUSAMARELLO, 2019). Porém, as formas mais comuns de medição de impedância aplicadas na EIS são a potenciostática e a galvanostática. No modo potenciostático uma tensão  $V(t)$  é aplicada e a corrente  $I(t)$  é medida. Já no modo galvanostático uma corrente  $I(t)$  é aplicada e a tensão  $V(t)$  é medida. Nos dois modos a impedância é calculada através da lei de Ohm (AL-ALI; MAUNDY; ELWAKIL, 2019). As principais configurações de circuitos para fazer essas medições estão ilustradas na Figura 13. Sendo os circuitos das figuras 13a, 13b e 13c denominados por implementação a dois, a três e a quatro eletrodos, respectivamente (GROSSI; RICCÒ, 2017).

Figura 13 – Principais configurações de circuitos para a medição de impedância em sistemas de EIS. Sendo (a), (b) e (c) os arranjos a dois, a três e a quatro eletrodos, respectivamente. Os eletrodos WE, CE, RE e WSE são designados por eletrodo de trabalho, contra eletrodo, eletrodo de referência e eletrodo de medição, respectivamente.



Fonte: GROSSI; RICCÒ (2017).

A configuração com dois eletrodos é a mais simples, composta pelo eletrodo de trabalho, WE (*working electrode*), e pelo contra eletrodo, CE (*counter electrode*), e pode operar tanto no modo potenciostático quanto no galvanostático. Nessa implementação, a excitação e a medição são realizadas pelos mesmos eletrodos. Assim, a impedância medida é influenciada pela resistência dos eletrodos (GROSSI; RICCÒ, 2017). O circuito com três eletrodos inclui um eletrodo de referência, RE (*reference electrode*), e a medição é feita pelo eletrodo CE. Como não há corrente sendo drenada por RE, a influência dos eletrodos no valor medido da impedância é reduzida (AL-ALI; MAUNDY; ELWAKIL, 2019). Porém, a configuração com três eletrodos só funciona no modo potenciostático, pois a variável medida é obrigatoriamente a corrente, através do eletrodo CE (MARCOS, 2019). Para o modo galvanostático existe uma variação do circuito com três eletrodos que é a implementação com quatro eletrodos. Na medição com quatro eletrodos é adicionado o eletrodo de medição, WSE (*working sensing electrode*), assim, a corrente é aplicada pelos eletrodos WE e CE, enquanto a tensão é medida pelos eletrodos WSE e RE. Como a corrente que vai percorrer WSE e RE tende a zero, a impedância medida torna-se insensível à

resistência dos eletrodos (GROSSI; RICCÒ, 2017).

Como a EIS consiste na medição da impedância para diversas frequências, os circuitos apresentados na Figura 13 necessitam de um sistema de controle. Esse sistema atua controlando a frequência de excitação do circuito, variando-a dentro de um intervalo preestabelecido e armazenando o valor medido da impedância para cada frequência. Sendo  $Z(j\omega_i)$  a impedância medida para a frequência  $f_i$ , onde  $\omega_i = 2\pi f_i$ , o resultado da espectroscopia de impedância elétrica para uma faixa de frequência de  $f_1$  a  $f_N$  é descrito por

$$\mathbf{M}_{EIS} = Z(j\omega_1), Z(j\omega_2), Z(j\omega_3), \dots, Z(j\omega_N), \quad (8)$$

sendo  $\mathbf{M}_{EIS}$  um vetor com os valores medidos das impedâncias para todas as frequências dentro do intervalo preestabelecido. Na Subseção 3.6.1 é apresentado como a EIS tem sido aplicada para avaliar o *status* de saúde de plantas.

### 3.6.1 Abordagem Clássica

Alguns pesquisadores têm aplicado a EIS na avaliação do *status* de saúde de plantas. ALEJNIKOV; CHESHKOVA; MINEEV (2020) utilizaram a EIS para detectar infestações por fungos no cultivo de morango. NOUAZE *et al.* (2022) avaliaram a aplicação da EIS na detecção de mudanças fisiológicas em folhas de alface, quando submetidas ao estresse hídrico. MEIQING *et al.* (2017) aplicaram a EIS na avaliação do nível de nutrição de nitrogênio no cultivo de tomate. TANG *et al.* (2023) apresentaram um estudo correlacionando a bioimpedância com o teor de umidade interno das folhas. BAR-ON; SHACHAM-DIAMAND (2021) utilizaram a EIS no monitoramento do ciclo de hidratação/desidratação no cultivo de *Nicotiana Tabacum*. BORGES *et al.* (2014) estudaram o estado fisiológico de plantas na presença de estresse hídrico e infestação por nematoides, através da EIS, e os experimentos foram realizados com três espécies de plantas. HAMED; ZORRIG; HAMZAOU (2016) aplicaram a EIS para estudar a resistência de plantas halófitas a diferentes condições de estresse salino. MEIQING *et al.* (2016) utilizaram a EIS na avaliação do nível de concentração de fósforo no cultivo de tomate.

Esses trabalhos, entre outros, têm apresentado resultados que demonstram o potencial da EIS em detectar a presença de agentes nocivos às plantas no estágio inicial do estresse. Entretanto, a abordagem utilizada para essas medições, denominada neste trabalho como abordagem clássica, consiste em aplicar o sistema de medição individualmente a cada planta que se deseja examinar. E os resultados também são processados de forma individual para cada planta. Como a bioimpedância é sensível às variáveis ambientais, como temperatura, umidade, irradiação solar, entre outras, e também ao crescimento natural das plantas, a equação (8) pode ser reescrita por

$$\mathbf{M}_{EIS} = Z(j\omega_1, ru), Z(j\omega_2, ru), Z(j\omega_3, ru), \dots, Z(j\omega_N, ru), \quad (9)$$

sendo  $ru$  uma variável que representa as oscilações nos fatores ambientais e as variações no crescimento natural das plantas. É pertinente ressaltar que, as oscilações nas variáveis ambientais representadas por  $ru$  se referem a mudanças naturais, que ocorrem em todo o cultivo de forma semelhante (*e.g.*, variações ambientais). Sendo que, mudanças na temperatura, umidade ou alguma outra variável, que ocorram por uma interferência externa em uma região pontual do cultivo, são consideradas agentes nocivos ou fatores estressores.

A equação (9) deixa evidente que a abordagem clássica da EIS na medição da bioimpedância das plantas traz tanto informações que estão relacionadas com o *status* de saúde das plantas, concernente à presença ou não de algum agente nocivo, quanto as que estão relacionadas com as variáveis ambientais e com o crescimento natural da planta. Dessa forma, como a bioimpedância do tecido vegetal tem essa forte relação com os fatores ambientais, como temperatura, umidade e luminosidade, não é possível determinar se alguma mudança nos padrões de bioimpedância medidos é devido à presença de algum agente nocivo, ou a oscilações nas variáveis do ambiente. Para solucionar esse problema, os pesquisadores conduzem os experimentos em ambientes controlados, mantendo as variáveis ambientais sob condições específicas. Com isso, é possível determinar quais variações nos padrões de bioimpedância medidos estão relacionadas com a presença de algum agente nocivo (BAR-ON; SHACHAM-DIAMAND, 2021; VAN HAEVERBEKE; DE BAETS; STOCK, 2023). Porém, isso aumenta o custo monetário do método, geralmente inviabilizando sua aplicação em larga escala e principalmente em campo, onde é impossível controlar as variáveis ambientais.

### 3.7 Propagação das Doenças em Cultivos

Como o desenvolvimento da abordagem proposta, denominada Superfície de Impedância, tem como um dos pilares a forma em que as doenças se propagam através da área cultivada, é de grande valia entender como esse processo acontece.

Uma planta é considerada doente quando as suas células e tecidos não estão funcionando corretamente devido a algum estímulo contínuo causada por um ou mais fatores bióticos e/ou abióticos (AGRIOS, 2005). Dessa forma, para que ocorra a doença é necessária a presença do patógeno, hospedeiro e ambiente.

As doenças infecciosas ou bióticas e as não infecciosas ou abióticas são causadas por organismos patogênicos que podem ser transmitidos de uma planta para outra, como vírus, fungos, bactérias e nematoides. As doenças não infecciosas ou abióticas são causadas por fatores ambientais desfavoráveis, como deficiência hídrica, altas e

baixas temperaturas, excesso de umidade, desequilíbrios nutricionais e deficiência na iluminação. As doenças abióticas não são transmissíveis de planta para planta (AMORIM, 2018), ou seja, a região do cultivo atingida por algum fator abiótico desfavorável fica limitada à área sob a ação do mesmo e não se propaga ao longo do cultivo como a maioria das doenças bióticas propagadas via foliar.

A disseminação ou propagação das doenças infecciosas em cultivos envolvem três etapas principais, a liberação, a dispersão e a deposição do patógeno. A liberação refere-se ao momento em que os agentes patogênicos são removidos do local de origem. A dispersão envolve o movimento ou transporte dos agentes patogênicos desde o local em que foi removido ou liberado até o local onde será depositado. A última etapa, a deposição, corresponde ao assentamento do patógeno em uma nova planta. Se a planta for suscetível ao agente etiológico, vai ocorrer o processo de infecção, colonização e reprodução do patógeno. Portanto, conhecer o progresso da doença no espaço e no tempo possibilita o manejo eficiente da doença.

As dimensões espacial e temporal correspondem com o progresso espacial da doença no campo, com o passar do tempo. Elas dependem da velocidade de disseminação da doença, quantidade de inóculo inicial e arranjo espacial das plantas na área de cultivo (BERGAMIN FILHO; KIMATI; AMORIM, 1995; ALVES *et al.*, 2006). De toda forma, a redução do progresso da doença vai depender do diagnóstico precoce e controle do patógeno no início do ciclo da doença. Em plantas individuais o progresso de uma doença ao longo do tempo e do espaço também pode ser estudado.

A dispersão ou transporte dos agentes patológicos, que compõe uma das etapas da disseminação, podem acontecer de forma ativa, quando o próprio patógeno tem autonomia para movimentar-se, ou de maneira passiva, quando o deslocamento é realizado com o auxílio de um agente de dispersão. Na dispersão ativa é possível alcançar apenas regiões vizinhas ao hospedeiro, pois os microrganismos com autonomia de mobilidade deslocam-se apenas em curtas distâncias, a exemplo de algumas bactérias e nematoides de solo. Enquanto que na dispersão passiva os patógenos podem se dispersar para partes mais distantes na área de cultivo, alcançar outras cidades ou até países (AMORIM, 2018). Nesse último caso, existem quatro agentes de disseminação ou agentes de dispersão principais, o ar, a água, o homem e os insetos.

A dispersão de esporos fúngicos e bactérias pelo ar podem atingir pequenas distâncias, quando liberados. Os quais podem ser transportados para regiões mais distantes, devido à presença de ventos e pequenos redemoinhos. A depender do tipo de corrente de ar os esporos podem viajar centenas de quilômetros, esse é um caso raro e acontece apenas com alguns patógenos. Quando a água é o agente de disseminação, os propágulos de fungos e bactérias alcançam curtas distâncias, pois




a dispersão ocorre principalmente pelos respingos de chuva, atingindo distâncias máximas na faixa dos 2 m, quando há a presença de ventos.

A disseminação através do homem pode atingir curtas e longas distâncias e pode acontecer de diversas maneiras. A dispersão em curtas distâncias pode acontecer através da contaminação entre plantas durante os tratos culturais. Nesse caso, a contaminação é realizada durante as podas, colheita, capina, dentre outras ações de manejo alternado entre plantas infectadas e sadias. Já a dispersão em longas distâncias acontece principalmente através do transporte de mudas infectadas. Assim como o homem, os insetos e aves atuam nas três fases da disseminação da doença. Eles removem o patógeno do hospedeiro, transportam e fazem a deposição em outra planta. Por essa razão, são considerados agentes de disseminação eficientes. As aves podem alçar voos longos, possibilitando a contaminação de plantas em outras regiões, enquanto os insetos se deslocam em voos de curta distância, contaminando as plantas vizinhas ao hospedeiro (KOBORI; TAKASU; OHTO, 2012; AMORIM, 2018).

Após a análise de como as doenças são disseminadas nos cultivos, é importante ressaltar que, no geral, a doença surge em um ponto da área cultivada e vai se propagando pelas regiões vizinhas. Essa é a principal forma de propagação de doenças em cultivos e é denominada por reboleira (KOBORI; TAKASU; OHTO, 2012; PRADO, 2023). Isso se deve à forma em que o patógeno é transportado que, na maioria dos casos, permite alcançar somente curtas distâncias infectando apenas as plantas situadas em regiões vizinhas ao hospedeiro. A Figura 14 ilustra a reboleira, sendo os pontos azuis a representação das plantas saudáveis e os pontos vermelhos a representação das plantas infectadas. A doença inicia no centro do cultivo, primeira imagem à esquerda, e vai se propagando em função do tempo. Na Figura 14, a evolução da doença no tempo segue a ordem da esquerda para a direita.

Estudar a dinâmica espaço-temporal da doença e como ela se propaga ao longo do cultivo é muito importante para entender a dinâmica de cada doença e desenvolver medidas de controle. Porém, algumas doenças se desenvolvem de forma muito lenta, dificultando os estudos, bem como alguns testes são inviáveis devido ao perigo de contaminar a região com o patógeno a ser experimentado. Uma forma de acelerar esse processo, evitando a contaminação de regiões indesejáveis e reduzindo o custo, é a realização de experimentos utilizando modelos matemáticos. Na Seção 3.8 são apresentados os modelos matemáticos mais utilizados para esses estudos (NEPOMUCENO, 2005).

Figura 14 – Ilustração da reboleira. Resultado da simulação da propagação da doença *Huanglongbing* em Citros através do inseto vetor *Diaphorina citri* (KOBORI; TAKASU; OHTO, 2012). Os pontos azuis representam plantas saudáveis e os pontos vermelhos plantas doentes. A doença inicia no centro do cultivo, primeira imagem à esquerda, e vai se propagando em função do tempo. A evolução da doença no tempo segue a ordem da esquerda para a direita.



Fonte: Autor.

### 3.8 Modelos Matemáticos para o Estudo de Propagação de Doenças

Um dos objetivos específicos desta tese é implementar um modelo matemático que permita criar uma base de dados com medições sintéticas da bioimpedância de plantas em uma região cultivada. Para isso, é necessário entender os modelos matemáticos utilizados em estudos sobre a propagação de doenças.

Nesta seção são apresentados o SIR (Suscetíveis-Infetados-Recuperados) e o IBM (*Individual-based Modeling*), os modelos matemáticos mais utilizados para os estudos de propagação ou disseminação de doenças. Esses modelos são aplicados tanto nos estudos em vegetais quanto em animais (NEPOMUCENO, 2005; RAILSBACK; GRIMM, 2019). Nas simulações realizadas neste trabalho foi utilizado um modelo IBM, considerado a forma mais adequada para modelar a propagação de doenças, como discutido na Subseção 3.8.2.

#### 3.8.1 O Modelo SIR

O modelo SIR é fundamentado em três compartimentos que representam os estados das plantas ou indivíduos, os quais estão inter-relacionados com a dinâmica de interação entre planta e patógenos. O primeiro é o estado suscetível, o qual ocorre quando a planta não está infectada mas pode ser contaminada e desenvolver a infecção. O segundo, designado por infectado, é quando a planta está com a doença e tem o potencial de transmitir o agente patogênico para outros indivíduos. O último é o estado recuperado, formado por indivíduos recuperados ou imunes ao contágio (POSTNIKOV; SOKOLOV, 2007). Para facilitar a compreensão, na Figura 15 encontra-se um esquemático do modelo SIR. Sendo  $b$  a taxa de natalidade,  $d$  a taxa de mortalidade,  $\alpha$  uma taxa adicional à mortalidade,  $1/\gamma$  o tempo médio

de permanência no estado infectado,  $1/\nu$  o tempo médio de permanência no estado recuperado,  $\beta$  o coeficiente de transmissão,  $\mu$  a taxa de novos suscetíveis,  $S(t)$  a quantidade de indivíduos suscetíveis,  $I(t)$  a quantidade de indivíduos infectados,  $R(t)$  a quantidade de indivíduos recuperados ou imunes ao contágio e  $N$  o número total de indivíduos (NEPOMUCENO, 2005).

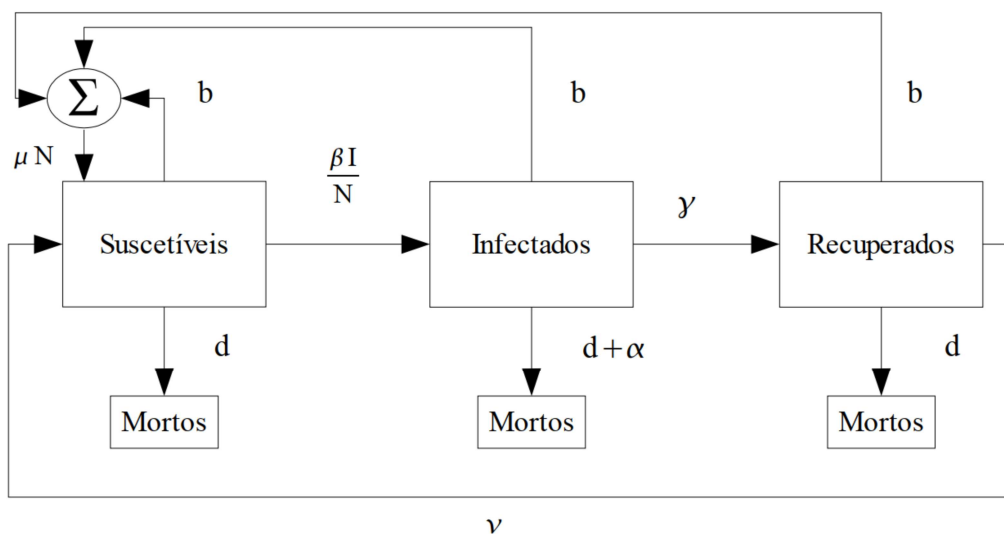
O conjunto de equações diferenciais que representa o modelo SIR é obtido assumindo que  $N$  é constante e  $\alpha$  é igual a 0. Assim, o modelo SIR pode ser descrito por (10), (11) e (12), sendo  $S(0) \geq 0$ ,  $I(0) \geq 0$  e  $R(0) \geq 0$  (NEPOMUCENO, 2005).

$$dS/dt = \mu N - \mu S(t) - \frac{\beta IS}{N}. \quad (10)$$

$$dI/dt = \frac{\beta IS}{N} - \gamma I - \mu I. \quad (11)$$

$$dR/dt = \gamma I - \mu R. \quad (12)$$

Figura 15: Representação do modelo SIR.



Fonte: NEPOMUCENO (2005).

Existem outros modelos que utilizam a estratégia de dividir a população em compartimentos e funcionam de maneira semelhante ao SIR. Alguns exemplos incluem o SI (suscetível e infectado), o SIS (suscetível, infectado e suscetível), o SIRS (suscetível, infectado, recuperado e suscetível), o SVI (suscetível, vacinado e infectado), dentre outros. A principal vantagem desses modelos é que eles são descritos por equações diferenciais, permitindo a análise através de técnicas bem conhecidas e consolidadas. Por essa razão que esses modelos são bastante utilizados na análise da dinâmica de diversas doenças, incluindo o comportamento na aplicação das

medidas de controle (NEPOMUCENO, 2005). Porém, para modelar a propagação de doenças esses modelos não são os mais adequados, pois eles utilizam parâmetros com base em valores médios, assumindo que os indivíduos são uniformemente distribuídos e que as interações também acontecem de maneira uniforme. Isso pode não representar as complexidades reais, onde as interações individuais e a distribuição populacional podem ser bastante heterogêneas (KOBORI; TAKASU; OHTO, 2012). Uma alternativa aos modelos baseados em compartimentos é a modelagem baseada em indivíduos IBM (*Individual-based Modeling*), apresentada na Subseção 3.8.2.

### 3.8.2 Modelagem Baseada em Indivíduos

Os sistemas ecológicos englobam organismos vivos, tanto de origem vegetal quanto animal, denominados indivíduos. Eles participam de interações complexas, dando origem a populações, comunidades e ecossistemas. Portanto, os indivíduos são os blocos de construção para qualquer sistema ecológico e as propriedades dos indivíduos determinam as propriedades desses sistemas. Além disso, em ecologia os indivíduos crescem e se desenvolvem passando por várias mudanças durante o seu ciclo de vida. Nesse contexto, os indivíduos, mesmo dentro da mesma espécie e faixa etária, são diferentes e interagem com o seu ambiente de maneira única. Pelas razões mencionadas, muitos pesquisadores consideram a Modelagem Baseada em Indivíduos (IBM) como a abordagem mais apropriada para o estudo da propagação de doenças (DEANGELIS; GRIMM, 2014; RAILSBACK; GRIMM, 2019).

Os modelos baseados em indivíduos são estocásticos, destacando-se pela característica de considerar cada indivíduo como uma entidade única. Na construção de um modelo baseado em indivíduos, é necessário inicialmente entender as premissas epidemiológicas envolvidas. Existem seis premissas básicas. A primeira é o tamanho da população, que pode ser constante ou variável. A segunda é a quantidade de características do indivíduo. A terceira está associada às categorias de indivíduos, como a planta saudável, a planta infectada e a planta morta. A quantidade de categorias pode ser ajustada conforme a necessidade específica de cada situação. A quarta premissa está ligada às mudanças de categoria, que podem ser realizadas por meio de distribuições de probabilidades ou em função do tempo de contaminação. A quinta consiste na determinação de distribuições de probabilidades para auxiliar nas transições entre as categorias. A última consiste em modelar o processo de infecção que geralmente é implementado por meio de uma distribuição de probabilidade. Definidas as premissas epidemiológicas com base no problema a ser modelado, é importante entender como construir a formulação matemática (NEPOMUCENO, 2005; KOBORI; TAKASU; OHTO, 2012).

O modelo é construído com base nas características de cada indivíduo. Assim, o indivíduo  $i$  pode ser representado por

$$I_{i,t} = [C_1 C_2 C_3 \dots C_n], \quad (13)$$

sendo  $C_n$  a  $n$ -ésima característica do indivíduo  $i$  no instante  $t$ . A principal característica é o estado, que pode ser saudável, infectado, morto, dentre outros. Outras características comuns são idade, tempo de infecção, posição espacial e tempo de vida após contaminação. É comum que o tempo  $t$  seja discreto. Assim, cada iteração do algoritmo que representa o modelo pode ser equivalente ao intervalo de uma hora, um dia, uma semana ou até um mês. É importante ressaltar que, a cada iteração, uma ou mais características de cada indivíduo podem ser alteradas fazendo com que o indivíduo mude de estado. As mudanças nas características ocorrem com base em distribuições de probabilidades e/ou em função de algum parâmetro relacionado ao tempo, através da interação de cada indivíduo com o ambiente e/ou com outros indivíduos.

A representação de uma população de indivíduos pode ser dada por

$$P_t = [I_{1,t} I_{2,t} I_{3,t} \dots I_{m,t}]^T, \quad (14)$$

sendo  $P_t$  uma matriz  $m \times n$  contendo as características de todos os indivíduos para o tempo  $t$ ,  $m$  o número de indivíduos ou a população e  $n$  a quantidade de características de cada indivíduo (NEPOMUCENO, 2005).

## 4 MEDIÇÃO BASEADA EM SUPERFÍCIE DE IMPEDÂNCIA


Neste capítulo, antes de apresentar a medição baseada em Superfície de Impedância, serão discutidos a eficiência da EIS na detecção de doenças e estresses em plantas e as limitações da bioimpedância.

A bioimpedância tem sido empregada na avaliação da saúde das plantas com o objetivo de coletar a máxima quantidade de dados possível. Os pesquisadores têm investido em realizar a espectroscopia de impedância elétrica com a maior largura de frequência possível e as análises dos dados vêm sendo realizadas considerando a fase, módulo, parte real e imaginária da impedância, bem como combinações entre essas variáveis, gerando enormes massas de dados. A ideia dos pesquisadores é usar a maior quantidade de informação possível para implementar sistemas que distingam diferentes tipos de doenças ou estresses nas plantas. TANG *et al.* (2023) mediram a bioimpedância para uma faixa de frequência de 100 Hz a 5 MHz e as análises foram realizadas utilizando fase, módulo, parte real e imaginária da bioimpedância. BARON; SHACHAM-DIAMAND (2021) realizaram as medições variando a frequência entre 40 Hz e 2 MHz. As variáveis utilizadas nas análises foram a fase e o módulo da bioimpedância. NOUAZE *et al.* (2022) exploraram uma faixa de frequência entre 500 Hz e 300 KHz e conduziram as análises utilizando cinco variáveis do modelo elétrico empregado no estudo. Essa enorme quantidade de dados gerados tem implicado em desafios para representar e interpretar essas informações (BARON; SHACHAM-DIAMAND, 2021), como também os sistemas de medição que realizam a espectroscopia em largas faixas de frequência são complexos, de alto custo monetário, volumosos e difíceis de reproduzir (CARVALHO *et al.*, 2022).


Retornando aos modelos elétricos do tecido biológico, apresentados na Seção 3.4, observa-se que todos eles podem ser simplificados a um circuito contendo apenas três componentes elétricos, sendo dois resistores e um capacitor, como apresentado nas figuras 5 e 6. Observando a simplicidade desse modelo surgiu a seguinte hipótese: é possível detectar estresses em plantas medindo a bioimpedância apenas para uma única frequência? A semelhança entre as informações contidas nas curvas de

bioimpedância medidas para frequências distintas corrobora com essa hipótese. Isso pode ser observado nas figuras 16 (a), (b) e (c).


Figura 16 – Curvas de bioimpedância medidas para frequências distintas. As frequências de excitação para os gráficos (a), (b) e (c) são 10 kHz, 50 kHz e 100 kHz, respectivamente.



(a)



(b)



(c)

Fonte: Autor.

Os gráficos apresentados na Figura 16 contêm dados provenientes de medições reais realizadas em tomateiros durante a fase experimental deste trabalho. Cada gráfico contém a medição do módulo da bioimpedância, em Ohm, ao longo de 28 dias para uma frequência de excitação diferente. As frequências de excitação para os gráficos (a), (b) e (c) são 10 kHz, 50 kHz e 100 kHz, respectivamente. Observa-se que as informações contidas nos três gráficos são semelhantes, visualmente isso já é perceptível, no entanto, foram calculados os coeficientes de correlação entre os dados dos gráficos, os quais estão apresentados na Tabela 1.

Tabela 1 – Índices de correlação entre os dados dos gráficos apresentados na Figura 16.

Gráficos correlacionados	Índices de correlação
(a) e (b)	0,99
(a) e (c)	0,97
(b) e (c)	0,99

Os altos índices de correlação apresentados na Tabela 1 indicam que fazer a medição para diversas frequências, através da EIS, aumenta o volume de dados, mas esse aumento não é refletido na quantidade de informação. Isso fortalece a hipótese de que, é possível detectar estresses nas plantas medindo a impedância apenas para uma frequência.

Essa hipótese foi avaliada em laboratório, através da reprodução dos experimentos realizados por MEIQING *et al.* (2017), que aplicaram a EIS para detectar 5 níveis de nitrogênio (N) no cultivo de tomateiros, obtendo sucesso na detecção. Durante o desenvolvimento desta tese, esses experimentos foram replicados em laboratório, através dos modelos elétricos disponibilizados por MEIQING *et al.* (2017). Esses experimentos foram conduzidos medindo a impedância apenas em uma única frequência. Os resultados permitiram a distinção entre os 5 níveis de nutrição de N, fortalecendo a hipótese de que medindo com apenas uma frequência é possível fazer a detecção dos estresses nas plantas. Esses resultados preliminares foram publicados em (CARVALHO *et al.*, 2022).

Devido à simplicidade do modelo elétrico do tecido biológico surgiu também a hipótese de que seria possível fazer a detecção de estresses em plantas utilizando apenas uma variável, fase ou módulo, ou então parte real ou imaginária da impedância. Observou-se que, para a espécie utilizada nos experimentos realizados por MEIQING *et al.* (2017), a fase e a parte imaginária da bioimpedância são mais sensíveis aos diferentes níveis de nitrogênio. Para analisar essa segunda hipótese foram realizados experimentos em laboratório medindo-se apenas a fase para uma única frequência. Esses testes foram conduzidos repetindo o experimento realizado por MEIQING *et al.* (2017), como descrito no parágrafo anterior. Os resultados mostraram que medindo apenas a fase para uma única frequência é possível alcançar a



mesma classificação obtida em (MEIQING *et al.*, 2017). Sendo que, MEIQING *et al.* (2017) utilizaram a espectroscopia em uma faixa de frequência de 1 Hz a 1 MHz e realizaram as análises utilizando múltiplas variáveis. Esses resultados preliminares também foram publicados em (CARVALHO *et al.*, 2022) e serão detalhados no Capítulo 6. Eles são importantes, uma vez que a medição baseada em Superfície de Impedância, apresentada nas seções 4.1 e 4.2, é construída com base nas medições de apenas uma variável da bioimpedância e utiliza uma única frequência.

## 4.1 Superfície de Impedância

Sabendo que a principal limitação da aplicação da bioimpedância na detecção de estresses e doenças em plantas é a sua sensibilidade às variáveis ambientais e ao crescimento natural das plantas como descrito na Subseção 3.6.1, a proposta da Superfície de Impedância traz uma solução para tratar esse problema. A concepção dessa abordagem é baseada em dois fundamentos, que são:

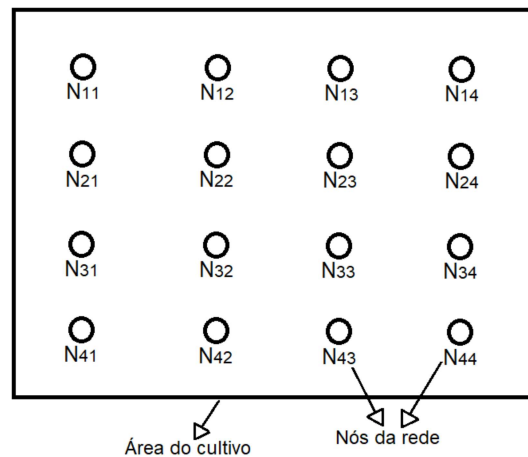
1. As oscilações nas variáveis ambientais acontecem de maneira similar em regiões vizinhas do cultivo. Da mesma forma, o crescimento natural das plantas é aproximadamente homogêneo, considerando o mesmo tipo de cultivo, o mesmo tempo desde o plantio e condições de solo semelhantes;
2. As doenças em cultivos geralmente surgem em um ponto específico da área cultivada e se propagam para as regiões vizinhas, como analisado na Seção 3.7. Esse padrão de propagação é denominado como reboleira.

Com base nesses dois fundamentos, se um local específico da plantação estiver sofrendo a ação de algum agente estressor, as medições realizadas nessa área serão diferentes das demais, visto que as condições ambientais influenciam de maneira semelhante as regiões vizinhas do cultivo, conforme descrito no primeiro fundamento. Dessa forma, ao posicionar uma rede de sensores de bioimpedância ao longo da plantação, como apresentado na Figura 17, é possível criar uma superfície com os valores medidos ao longo da área cultivada, conforme ilustrado na Figura 18. É pertinente ressaltar que cada nó sensor  $N_{x,y}$  pode representar uma região do cultivo ou apenas uma planta, de acordo com algumas técnicas de amostragem que são aplicadas para a detecção de doenças em campo (WULFSOHN, 2010). Essas técnicas de amostragem vêm sendo estudadas e bem definidas pelos pesquisadores da engenharia agrônômica e não é objeto de estudo deste trabalho.

A superfície ilustrada na Figura 18, denominada como Superfície de Impedância, é formada pela interpolação linear de pontos tridimensionais, cada ponto representa a medição do sensor e as coordenadas espaciais que determinam a posição do sensor na área cultivada. É importante ressaltar que, no cenário ideal, onde não há erros


de medição, o crescimento é homogêneo, as variáveis ambientais são exatamente iguais em toda a área cultivada, o solo tem as mesmas concentrações de nutrientes e as características fisiológicas das plantas são exatamente as mesmas, a superfície apresentada na Figura 18 seria um plano. Porém, considerando as imperfeições, a superfície fica com algumas ondulações.

Figura 17: Ilustração da área do cultivo com a rede de sensores de bioimpedância.



Fonte: Autor.

Figura 18 – Ilustração da Superfície de Impedância. Os eixos X e Y representam as dimensões espaciais que indicam as posições dos nós da rede de sensores e o eixo Z representa os valores das impedâncias medidas para uma frequência  $f_N$ .




Fonte: Autor.

A partir da Superfície de Impedância, observa-se que oscilações nas variáveis ambientais causam deslocamentos em toda a superfície, sem provocar deformações significativas na sua forma, como ilustrado na Figura 19. Isso é uma consequência do primeiro fundamento, citado no início desta seção. É essa característica da Superfície de Impedância que trata a sensibilidade da bioimpedância às variáveis ambientais. Observa-se que a bioimpedância continua sensível às variáveis ambientais, porém, a forma da Superfície de Impedância não é alterada significativamente com as mudanças nas variáveis ambientais. Por outro lado, o surgimento de do-


enças causa alterações na forma da superfície. Pois, como as doenças surgem em regiões pontuais do cultivo, a Superfície de Impedância sofre deformações significativas indicando a região que está sendo afetada, como ilustrado na Figura 20. Alguns resultados parciais deste trabalho, sobre o comportamento da Superfície de Impedância, foram publicados em (SOUZA *et al.*, 2022) e serão detalhados na Seção 6.

Figura 19 – Ilustração da influência exercida na Superfície de Impedância por alterações nas variáveis ambientais. Nesta representação, são ilustradas três situações distintas para as variáveis ambientais.



Fonte: Autor.

Figura 20 – Ilustração da deformação causada na Superfície de Impedância pela ação de um agente estressor. Perceptível no ponto em que  $X = 3$  e  $Y = 2$ .



Fonte: Autor.

Considerando os dois fundamentos descritos no início desta seção e as ilustrações apresentadas nas figuras 18, 19 e 20, fica evidente que, através da Superfície de Impedância, é possível realizar a detecção de estresses em cultivos sem a necessidade de controlar as variáveis ambientais. Vale ressaltar que, nos trabalhos que empregam a abordagem clássica, as variáveis ambientais são mantidas controladas durante os experimentos (BORGES *et al.*, 2014; BAR-ON; SHACHAM-DIAMAND, 2021; TANG *et al.*, 2023).

A medição baseada em Superfície de Impedância também tem a vantagem de utilizar dados de apenas uma variável da bioimpedância e para uma única frequência. Isso possibilita reduzir a massa de dados e simplificar o sistema de medição. Porém, a contribuição mais importante da Superfície de Impedância está em permitir tratar a principal limitação da bioimpedância, que é a sensibilidade às variáveis ambientais, como já discutido. Neste trabalho, é analisado detalhadamente a aplicação da medição baseada em Superfície de Impedância para a detecção de estresse em cultivos, sem a necessidade de controlar as variáveis ambientais.

## 4.2 Classificação com a Superfície de Impedância

Antes de detalhar como a classificação das plantas é realizada, é importante entender como uma medição baseada em Superfície de Impedância pode ser expressa matematicamente.

Na abordagem clássica, a medição é representada matematicamente por um vetor que contém os valores das impedâncias medidos para cada frequência, dentro de um intervalo de frequência predefinido, conforme descrito por (8), na Seção 3.6. Já na medição baseada em Superfície de Impedância, considerando a rede de sensores apresentada na Figura 17, uma amostra é representada por

$$\mathbf{M}_Z(t) = \begin{bmatrix} Z_{11}(t) & Z_{12}(t) & Z_{13}(t) & Z_{14}(t) \\ Z_{21}(t) & Z_{22}(t) & Z_{23}(t) & Z_{24}(t) \\ Z_{31}(t) & Z_{32}(t) & Z_{33}(t) & Z_{34}(t) \\ Z_{41}(t) & Z_{42}(t) & Z_{43}(t) & Z_{44}(t) \end{bmatrix}, \quad (15)$$

sendo  $\mathbf{M}_Z(t)$  uma matriz que contém as medições  $Z_{x,y}(t)$  de cada nó da rede de sensores no instante  $t$  e os índices  $x$  e  $y$  de  $Z_{x,y}(t)$  representam as coordenadas espaciais do nó. Vale ressaltar que as impedâncias são medidas apenas para uma única frequência e é considerada apenas uma variável da bioimpedância.

Através da interpolação linear dos elementos da matriz  $\mathbf{M}_Z(t)$ , considerando os índices de cada elemento como a dimensão espacial, representando a posição do respectivo nó sensor na área do cultivo, pode-se reconstruir a Superfície de Impedância, como ilustrado na Figura 18. Assim, tanto a forma gráfica quanto a notação matricial  $\mathbf{M}_Z(t)$ , são maneiras equivalentes de representar a medição baseada em Superfície de Impedância. A seguir será discutido como funciona a classificação.

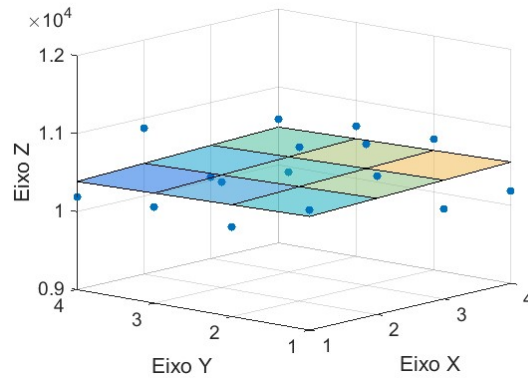
Como já explanado na Seção 4.1, a Superfície de Impedância é baseada na distribuição de uma rede de sensores ao longo do cultivo. Com isso, o sistema de medição inclui toda a região cultivada, diferente da abordagem clássica que considera a medição da planta individualmente. Para isso, a ferramenta de processamento dos dados foi implementada de forma que a classificação considere a dinâmica de todo o cul-

tivo, permitindo que cada nó sensor possa comparar a sua bioimpedância com uma Superfície de Impedância que representa toda a área do plantio. O problema agora está em como construir a Superfície de Impedância na rede de sensores, visto que o processamento e a classificação são realizados na própria rede, sem a necessidade de processamento em nuvem. O primeiro desafio no uso das redes de sensores, considerando a forma mais comum que são as redes de sensores sem fio (RSSF) está relacionado com a transmissão de dados ao longo da rede, limitada pelo *hardware* dos nós sensores, que geralmente são de baixa capacidade de processamento e armazenamento. Mas o principal fator que limita a transmissão de dados em uma RSSF é o consumo de energia (SOHRABY; MINOLI; ZNATI, 2007). Como solução à essa limitação, a ferramenta matemática para a classificação, baseada na Superfície de Impedância, foi construída através do método dos Mínimos Quadrados Recursivo (MQR) com fator de esquecimento, permitindo que a quantidade de dados trocada entre os nós sensores seja pequena, independentemente do tamanho da rede de sensores.

É importante ressaltar que, a aplicação dos Mínimos Quadrados Recursivo (MQR) ponderado aproxima a Superfície de Impedância a um plano, conforme ilustrado na Figura 21, onde estão representados os pontos que definem a Superfície de Impedância, conforme (15), e o plano que representa a Superfície de Impedância. Isso é uma vantagem, pois, conhecendo que, devido a ruídos no sistema de medição, os valores medidos apresentam um erro aleatório. Como consequência, a Superfície de Impedância formada diretamente pelos valores medidos não seria uma opção robusta para ser usada na classificação. Assim, como o método dos Mínimos Quadrados tem a característica de ser robusto a ruídos, como descrito na Subseção A.1 Método dos Mínimos Quadrados Clássico, essa aproximação da Superfície de Impedância a um plano é uma solução robusta aos erros aleatórios de medição. Outra característica importante é que o método dos Mínimos Quadrados Recursivo ponderado permite que os parâmetros sejam alterados ao longo do tempo, devido ao fator de esquecimento. Isso é importante, pois a bioimpedância das plantas oscila ao longo do dia. Além disso, o MQR ponderado não necessita que toda a massa de dados esteja disponível para estimar os parâmetros do plano, permitindo que o sistema seja aplicado de forma *online*.

Outro desafio na construção das redes de sensores sem fio é a comunicação entre nós distantes, que é limitada pelo alcance de transmissão dos nós sensores. Para contornar esse problema, o processamento dos dados na rede considera que cada nó sensor se comunica apenas com os seus vizinhos. Na Figura 22 estão ilustradas as três situações possíveis de comunicação entre um nó e seus vizinhos. Quando um nó está em um canto, ele se comunica com 3 vizinhos, conforme apresentado na Figura 22 (a). Se o nó estiver em uma linha superior, inferior ou lateral e não estiver em

Figura 21 – Ilustração de plano ajustado a uma nuvem de pontos através do método dos Mínimos Quadrados.



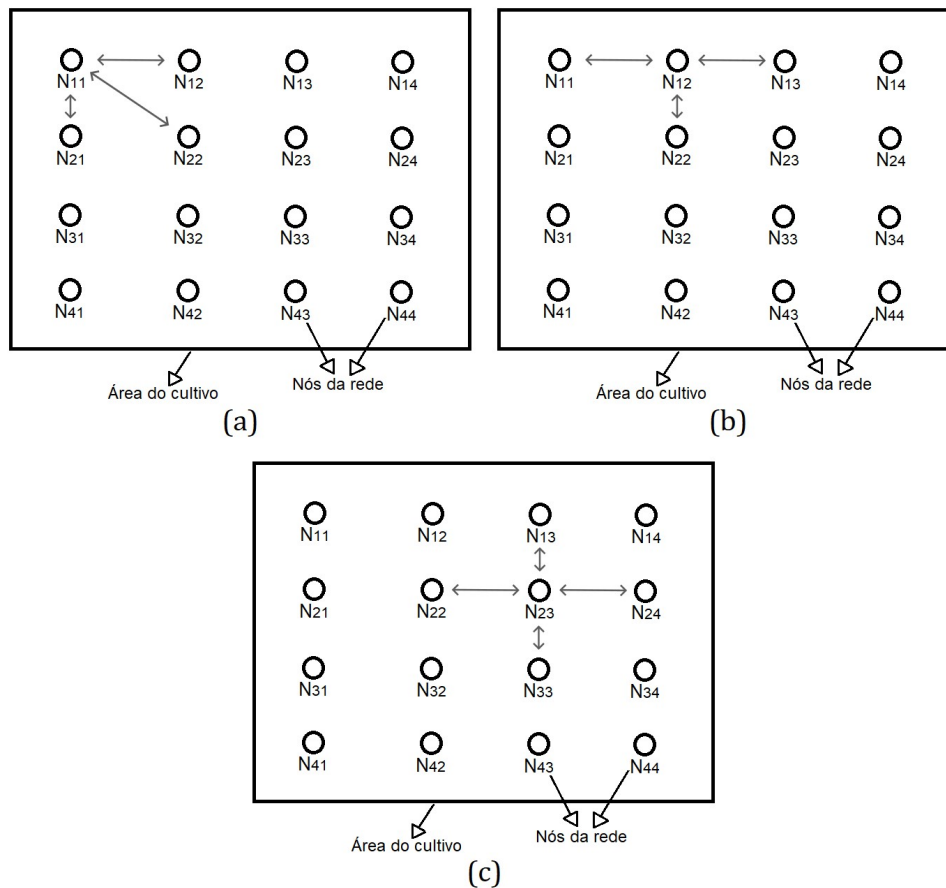
Fonte: Autor.

um canto, ele também se comunica com 3 vizinhos, como ilustrado na Figura 22 (b). E, para qualquer posição distinta das apresentadas nas figuras 22 (a) e (b), o nó se comunica com quatro vizinhos, conforme exibido na Figura 22 (c). A seguir, está descrito como a ferramenta matemática de classificação funciona.

A ferramenta de classificação pode ser explanada considerando uma rede de sensores, como a ilustrada na Figura 22, onde os nós sensores são representados por  $N_{x,y}$ , sendo  $x$  e  $y$  as coordenadas espaciais que determinam a posição. Cada nó,  $N_{x,y}$ , contém armazenados o vetor  $\hat{\theta}_k$ , com os três parâmetros do plano que representa a Superfície de Impedância, a matriz de covariância  $P_k$  e a quantidade de iterações,  $n_{it}$ , realizadas no plano  $\hat{\theta}_k$ . O plano  $\hat{\theta}_k$  e a matriz  $P_k$  são calculados conforme (70) e (72), respectivamente. Os passos para a construção da Superfície de Impedância na rede de sensores são:

1. Cada nó sensor,  $N_{x,y}$ , faz a medição da bioimpedância em suas respectivas plantas;
2. Cada nó sensor calcula o seu plano  $\hat{\theta}_k$  através das equações (73), (70) e (72), conforme descrito na Subseção A.2 Método dos Mínimos Quadrados Recursivo. Em seguida, atualiza os valores armazenados de  $\hat{\theta}_k$  e  $P_k$  com os valores recém-calculados. Vale ressaltar que, a matriz  $P_k$  inicial, utilizada na primeira vez em que o plano de cada nó sensor é calculado, tem valores na ordem de  $10^2$  nos elementos da diagonal principal, e os outros elementos são iguais a zero. O valor dos elementos da diagonal principal foram escolhidos empiricamente analisando a convergência dos planos;
3. Cada nó sensor atualiza  $n_{it}$ , que é a variável que contém a quantidade de iterações realizadas no plano atual do nó, envia  $n_{it}$  para os seus vizinhos e recebe também o número de iterações realizadas no plano atual de cada um

Figura 22 – Ilustração de como os nós sensores se comunicam, apresentando as três situações possíveis.



Fonte: Autor.

- dos seus vizinhos. É importante enfatizar que, cada nó sabe a sua posição  $x,y$  e envia para os seus vizinhos junto com  $n_{it}$ ;
4. Cada nó sensor escolhe o vizinho cujo plano tem maior número de iterações. Caso haja empate, a escolha é feita aleatoriamente. Essa etapa é realizada para garantir que cada nó sensor vai escolher o vizinho com o plano mais atualizado;
  5. Cada nó sensor toma o plano  $\hat{\theta}_k$  e a matriz de covariância  $P_k$  do vizinho escolhido. Em seguida repetem-se os passos de 1 a 5. É importante ressaltar que, no passo 2, o plano será atualizado considerando o valor atual medido pelo nó sensor e os parâmetros  $\hat{\theta}_k$  e  $P_k$  tomados do vizinho escolhido.

Os passos descritos anteriormente vão se repetindo ciclicamente e, como consequência, os planos atualizados por cada nó sensor vão se propagando pela rede enquanto são mutuamente atualizados pelos outros nós da rede. Dessa forma, os planos armazenados em todos os nós sensores convergem gradualmente para um

plano comum, o qual representa a Superfície de Impedância.

Após os planos de todos os nós convergirem para a Superfície de Impedância, inicia-se a fase de classificação. Na fase de classificação, os planos continuam sendo atualizados repetindo-se os 5 passos ciclicamente. Porém, a cada ciclo, após a realização do quinto passo, cada nó realiza a classificação da sua respectiva planta. Para essa classificação, primeiro é calculada a diferença entre o valor da bioimpedância medido na planta,  $Z_{x,y}(t)$ , e o valor estimado pela Superfície de Impedância,  $\hat{Z}_{x,y}(t)$ . Em seguida, o módulo dessa diferença é comparado com um limiar,  $l_s$ , como descrito em (16) e (17). Se o módulo da diferença for maior que  $l_s$  a planta é classificada como doente, senão, permanece no conjunto das saudáveis.

$$\text{Diferença} = |Z_{x,y}(t) - \hat{Z}_{x,y}(t)| \quad (16)$$

$$\text{Estado} = \begin{cases} \text{Saudável,} & \text{se Diferença} \leq l_s \\ \text{Doente,} & \text{se Diferença} > l_s \end{cases} \quad (17)$$

Quando uma planta é classificada como doente, as medições realizadas pelo nó sensor conectado a essa planta não são mais utilizadas para a atualização do plano.

Uma característica importante da ferramenta de classificação desenvolvida está relacionada à escalabilidade da rede de sensores. Pode-se observar que as informações trocadas entre os nós são apenas o plano  $\hat{\theta}_k$ , a matriz de covariância  $P_k$ , a quantidade de iterações realizadas no plano atual do nó  $n_{it}$  e a posição do nó. E, a dimensão dessas informações não dependem da quantidade de nós sensores da rede. Assim, ampliando a quantidade de sensores da rede, a quantidade de dados trocada entre os nós sensores permanece a mesma. Pode-se notar também que, como os nós sensores se comunicam apenas com os seus vizinhos, a ampliação da rede de sensores não implica em longas distâncias para a comunicação entre os nós. Devido a essas duas particularidades mencionadas, a rede de sensores pode ser ampliada facilmente. Isso atribui à medição baseada em Superfície de Impedância a característica da escalabilidade.

Outro aspecto importante da ferramenta de classificação é a estabilidade da Superfície de Impedância. Como os planos dos nós sensores vão sendo propagados pela rede enquanto são mutuamente atualizados até convergirem para a Superfície de Impedância, é necessário que haja uma quantidade mínima de iterações até que a Superfície de Impedância fique estável ao longo de toda rede. Com base nos dados processados neste trabalho, o valor para a quantidade mínima de iterações foi escolhido empiricamente e estabelecido como 20. Existem três fatores que influenciam na estabilidade, o tamanho da rede, a matriz de covariância,  $P_k$ , inicial e o fator de esquecimento,  $\lambda$ , aplicado em (72). Sendo  $P_k$  inicial igual a



$$\begin{bmatrix} 10^2 & 0 & 0 \\ 0 & 10^2 & 0 \\ 0 & 0 & 10^2 \end{bmatrix},$$

e  $\lambda$  igual a 0,988. Tanto  $P_k$  quanto  $\lambda$  foram escolhidos empiricamente. É importante registrar que, quanto maior a rede de sensores, maior será a quantidade de iterações até que haja a estabilização da Superfície de Impedância ao longo da rede.

Todo o ferramental matemático para a classificação foi desenvolvido para trabalhar em uma rede de sensores e realizar a classificação de forma *online*. Porém, durante os experimentos realizados neste trabalho, os dados foram coletados através de uma rede de sensores e armazenados, formando bases de dados. Portanto, todas as classificações foram realizadas executando o sistema de forma *offline*. Para isso, os dados foram organizados para alimentar o sistema de maneira sequencial, emulando a rede de sensores.

## 5 ARRANJOS EXPERIMENTAIS E DESCRIÇÕES METODOLÓGICAS

Durante o desenvolvimento deste trabalho foram realizados três grupos principais de experimentos. No primeiro, foram conduzidos testes com o intuito de analisar se medindo a bioimpedância apenas para uma única frequência, ao invés de fazer a espectroscopia, seria possível fazer a detecção de doenças. Aqui também foi analisado a possibilidade de fazer a detecção usando apenas uma variável, dentre a fase, módulo, parte real ou imaginária da impedância. No segundo, foram realizados experimentos com o objetivo de analisar a medição baseada em Superfície de Impedância aplicando-a a dados gerados a partir de simulações. No terceiro, a medição baseada em Superfície de Impedância foi aplicada em dados reais. Os arranjos experimentais do primeiro, segundo e terceiro grupo de experimentos estão apresentados nas seções 5.1, 5.2 e 5.3, respectivamente.

### 5.1 Metodologia para Analisar a Detecção Utilizando Apenas uma Frequência e um Parâmetro da Bioimpedância

O objetivo dos procedimentos descritos nesta seção é de analisar a viabilidade da detecção de doenças usando apenas uma única frequência e uma única variável. Como discutido no início do Capítulo 4, a simplicidade do modelo levou à hipótese de que é possível detectar estresses em plantas medindo apenas em uma única frequência e utilizando um único parâmetro da bioimpedância.

Os experimentos foram realizados de forma a permitir a comparação dos resultados com o trabalho desenvolvido em (MEIQING *et al.*, 2017). Para isso, as medições foram realizadas implementando o circuito elétrico do modelo de Hugo Fricke, apresentado na Figura 5, usando os valores apresentados na Tabela 2. Esses valores foram obtidos através dos experimentos realizados por MEIQING *et al.* (2017) em tomateiros. Eles conduziram os testes aplicando cinco níveis distintos de Nitrogênio, 25%, 50%, 75%, 100% e 125% da fórmula de Yamazaki. Essas concentrações foram administradas através da solução utilizada para irrigar os tomateiros. Nós replica-

mos esses experimento em laboratório medindo apenas a fase da impedância, e a análise foi realizada considerando apenas uma única frequência. A inovação nesta primeira parte está em realizar a detecção medindo a bioimpedância apenas em uma frequência e utilizando apenas um parâmetro.

Tabela 2 – Valores dos parâmetros do modelo de Fricke para cada nível de nitrogênio (MEIQING *et al.*, 2017).

$R_e$	$R_i$	$C_m$	Níveis de Nitrogênio Medidos nas Folhas
65 k $\Omega$	3,3 k $\Omega$	125 pF	2,5%
94 k $\Omega$	2,5 k $\Omega$	222 pF	3%
114,2 k $\Omega$	2 k $\Omega$	200 pF	3,5%
120 k $\Omega$	1,5 k $\Omega$	267 pF	4%
140 k $\Omega$	680 $\Omega$	320 pF	4,5%

A escolha da fase foi realizada através de um teste de sensibilidade entre as variáveis comumente utilizadas nos experimentos com bioimpedância. Foram analisadas a fase, módulo, parte real e imaginária da impedância. Esse teste foi realizado por simulação, utilizando o modelo de Hugo Fricke, sendo  $R(\omega)$  a componente resistiva e  $X(\omega)$  a componente reativa do modelo, dadas por

$$R(\omega) = \frac{R_e R_i (R_e + R_i) C_m^2 \omega^2 + R_e}{(R_e + R_i)^2 C_m^2 \omega^2 + 1}, \quad (18)$$

e

$$X(\omega) = \frac{-R_e^2 C_m \omega}{(R_e + R_i)^2 C_m^2 \omega^2 + 1}, \quad (19)$$

assim, a fase  $\theta(\omega)$  e a magnitude da impedância  $Z(\omega)$  são descritas por

$$\theta(\omega) = \text{tg}^{-1} \left( \frac{X(\omega)}{R(\omega)} \right), \quad (20)$$

e

$$Z(\omega) = \sqrt{R(\omega)^2 + X(\omega)^2}. \quad (21)$$

Com esse modelo, foram realizados testes variando a frequência de 1 kHz a 100 MHz, com passo de 1 kHz. Para cada frequência, dentro desse intervalo, foram calculados os valores de  $\theta(\omega)$ ,  $Z(\omega)$ ,  $R(\omega)$  e  $X(\omega)$ , para os dois níveis extremos de concentração de nitrogênio (2,5% e 4,5%). A sensibilidade, para cada parâmetro, foi analisada através do valor relativo das medições em cada frequência. Esse valor relativo foi obtido através do quociente do valor encontrado para o nível 4,5% pelo valor encontrado para o nível 2,5%. Os resultados para o primeiro grupo de experimentos estão apresentados na Seção 6.1.

## 5.2 Metodologia para a Construção da Base de Dados Sintéticos

Nesta seção, são descritos os procedimentos para a construção da base de dados sintéticos. O objetivo dessa construção é analisar a medição baseada em Superfície de Impedância antes de obter os dados com os experimentos reais. Para isso, foi implementado um sistema que simula a propagação de uma doença em um cultivo e a medição da bioimpedância das plantas ao longo do tempo. Essa simulação é realizada em dois estágios. No primeiro estágio, foi implementado um Modelo Baseado em Indivíduos (IBM) para gerar uma base de dados com a propagação da doença Huanglongbing, conhecida como Amarelão dos Citrus, por meio do inseto vetor *Diaphorina citri*, no cultivo de citros. No segundo estágio foi realizada a simulação da medição da bioimpedância das plantas, com base nos dados gerados no primeiro estágio da simulação. Os aspectos teóricos que fundamentam o primeiro e o segundo estágio da simulação estão apresentados nas seções 3.7, 3.8 e 3.4.

O primeiro estágio foi baseado no modelo apresentado por KOBORI; TAKASU; OHTO (2012), que foi construído através de estudos e observações realizadas na região do Delta do Mekong, no Vietnã. Alguns parâmetros do modelo foram ajustados com base na literatura e outros com base nas próprias observações dos autores na região estudada.

A simulação apresentada foi implementada para um cultivo com um arranjo em forma de uma matriz 40 x 40, considerando que cada elemento  $i,j$  da matriz representa uma árvore. A distância entre as árvores foi assumida como 2,5 m. A progressão discreta do tempo  $\Delta t$  foi definida com base no tempo de desenvolvimento do inseto vetor, da reprodução até chegar na fase adulta. Assim, cada passo na simulação é equivalente a um período temporal  $\Delta t$  de um mês.

Na simulação, foram considerados dois tipos de indivíduos, que são as árvores e os insetos vetores. As árvores podem assumir 4 estados (H - saudável, LP - latente, IP - infectada e D - morta). No estado H, a árvore está saudável e pode ser infectada. Se o estado for LP, a árvore foi infectada, mas ainda não tem capacidade infecciosa. Quando o estado é IP, a árvore está infectada e tem capacidade infecciosa. Se o estado for D, a árvore está morta. Quando uma árvore é infectada, ela passa 3 meses em LP, depois muda seu estado para IP, passa 45 meses em IP e, em seguida, morre. Na simulação é considerado que, a transição entre os estados das árvores é irreversível, cada árvore pode hospedar no máximo 100 insetos vetores e, quando uma árvore morre, outra não cresce em seu lugar.

Os insetos vetores podem assumir 2 estados, virulento e não virulento. A probabilidade de um inseto virulento infectar uma árvore saudável é  $P1_{in, fec} = 0,3$ , e a probabilidade de uma árvore IP infectar um inseto vetor é  $P2_{in, fec} = 0,9$ . Um inseto vetor produz uma média de 10 indivíduos para a próxima geração, nesse processo

há uma probabilidade  $Dl = 0,9$  de o inseto reprodutor morrer.

Um inseto vetor pode voar em qualquer direção, e a distância de um determinado movimento é modelada por uma distribuição de probabilidade exponencial. Essa distribuição foi determinada a partir de observações experimentais em campo e pode ser expressa por

$$f(x) = \lambda e^{-\lambda x}, \quad (22)$$

sendo  $f(x)$  a distribuição de probabilidade exponencial,  $x$  a distância de um determinado movimento e  $\lambda$  uma constante igual a 0,8 que representa a média da distribuição (KOBORI *et al.*, 2011). A direção do voo é determinada por uma distribuição uniforme, variando de  $0^\circ$  a  $360^\circ$ , dada por

$$\theta_{dir} = 2\pi \cdot VA, \quad (23)$$

onde  $\theta_{dir}$  é o ângulo que determina a direção do movimento, em radianos, e  $VA$  é uma variável aleatória distribuída uniformemente no intervalo  $[0, 1]$ . A árvore considerada como destino do voo é a mais próxima do ponto final da trajetória do movimento. Um inseto vetor pode trocar de árvore apenas uma vez em todo o seu ciclo de vida, e há uma probabilidade  $Dm = 0,7$  de o indivíduo morrer durante o voo.

A sequência do algoritmo de simulação é a seguinte:

1. É gerada uma matriz  $40 \times 40$ , sendo cada elemento da matriz uma árvore saudável;
2. São inseridos 100 insetos vetores infectados na árvore localizada na posição  $(20,20)$ , em seguida, é verificado se a árvore foi infectada, calculando a probabilidade  $P1_{infec}$  para cada inseto;
3. É calculado o movimento de cada inseto vetor, através de (22) e (23), e se ele morre durante o voo, de acordo com a probabilidade  $Dm = 0,7$ . Em seguida, atualiza-se a nova posição do inseto na área do cultivo;
4. São calculadas quais árvores saudáveis foram infectadas, de acordo com a nova posição dos insetos vetores infectados e a probabilidade  $P1_{infec}$ , e quais insetos não virulentos foram infectados, aplicando a probabilidade  $P2_{infec}$  quando o inseto está em uma árvore IP;
5. Calcula-se a reprodução dos insetos, considerando que um inseto vetor produz em média 10 indivíduos para a próxima geração e que a probabilidade de morte na reprodução é  $Dl$ . Se o novo inseto é reproduzido em uma árvore IP, é realizado o cálculo se ele foi infectado considerando a probabilidade  $P2_{infec}$ ;

6. São atualizados o tempo de simulação e o tempo de infecção  $ti$  de cada árvore. Em seguida, o algoritmo é repetido a partir do terceiro passo, até que o final do período de simulação seja atingido.

Como resultado da simulação, a variável  $ti$ , tempo desde a infecção, de todas as árvores foram coletados e armazenados mensalmente, dando origem a uma base de dados. Essa base de dados, que retém as informações sobre a dinâmica de propagação da doença, é utilizada na segunda etapa da simulação.

O segundo estágio foi construído tomando o modelo de Hugo Fricke, apresentado na Figura 5, para representar o comportamento elétrico do tecido de cada planta. O modelo foi ajustado com  $R_e = 20 k\Omega$ ,  $R_i = 10 k\Omega$  e  $C_m = 11,5 pF$ , parâmetros retirados de (BORGES *et al.*, 2012), obtidos a partir de experimentos realizados em uma espécie de pinho. O modelo de Hugo Fricke pode ser representado pelas equações (20) e (21). Para representar cada planta essas equações podem ser adaptadas e descritas por

$$\theta_{i,j}(\omega) = tg^{-1} \left( \frac{X_{i,j}(\omega)}{R_{i,j}(\omega)} \right), \quad (24)$$

e

$$Z_{i,j}(\omega) = \sqrt{R_{i,j}(\omega)^2 + X_{i,j}(\omega)^2}, \quad (25)$$

onde  $\theta_{i,j}(\omega)$  e  $Z_{i,j}(\omega)$  são a fase e o módulo da bioimpedância medida na planta  $i,j$ , respectivamente. Sendo  $R_{i,j}(\omega)$  e  $X_{i,j}(\omega)$  dados por (18) e (19), respectivamente.

As equações (18) e (19) permitem a realização de simulações considerando situações ideais, onde as variáveis ambientais e o desenvolvimento natural da planta não vão interferir na bioimpedância medida. Porém, como explanado na Subseção 3.6.1, a bioimpedância do tecido das plantas é sensível à temperatura, umidade, irradiação solar, entre outras. Assim, para construir um modelo que se aproxime da realidade é necessário considerar esse fatores. Para isso, foram considerados 3 parâmetros,  $ru_1$ ,  $ru_2$  e  $ru_3$ .  $ru_1$  representa a influência do crescimento desigual do cultivo na bioimpedância do tecido da planta,  $ru_2$  representa o erro de medição e  $ru_3$  representa pequenas variações climáticas que podem ocorrer em diferentes áreas do cultivo.

O parâmetro  $ru_1$  é dado por uma distribuição normal de probabilidade com  $\mu = 0$  e  $\sigma = 0,75\%$  do valor da impedância do tecido.  $ru_1$  é calculado para cada planta apenas uma vez no início da simulação. O parâmetro  $ru_2$  também é representado por uma distribuição normal de probabilidade com  $\mu = 0$  e  $\sigma = 0,5\%$  do valor da impedância do tecido.  $ru_2$  é calculado para cada medição realizada na simulação. O parâmetro  $ru_3$  também é dado por uma distribuição normal de probabilidade com  $\mu = 0$  e  $\sigma = 0,5\%$  do valor da impedância do tecido.  $ru_3$  é calculado a cada

progressão no tempo de simulação  $\Delta t$ . As variáveis  $ru_1$ ,  $ru_2$  e  $ru_3$  foram ajustadas com base nos resultados apresentados em (HAYDEN *et al.*, 1969), (HAYASHI *et al.*, 1992), (TOMKIEWICZ; PISKIER, 2012) e (BORGES *et al.*, 2014). Um quarto parâmetro,  $ru_4$ , foi utilizado para simular a influência de variações climáticas em todo o cultivo.  $ru_4$  é representado por uma distribuição normal de probabilidade com  $\mu = 0$  e  $\sigma = 10\%$  do valor da impedância do tecido, que é equivalente a uma variação de 5 °C na temperatura ambiente (HAYDEN *et al.*, 1969).

É importante salientar que, os parâmetros  $ru_1$ ,  $ru_3$  e  $ru_4$  modificam diretamente os parâmetros do modelo elétrico do tecido das plantas. Porém, as distribuições de probabilidade desses parâmetros foram apresentadas em função do valor da impedância do tecido, facilitando a percepção do quanto cada parâmetro influencia no valor da bioimpedância medida. Já o parâmetro  $ru_2$  modifica diretamente o valor medido da impedância, representando um erro de medição.

Para finalizar o modelo completo da simulação, é necessário acoplar o primeiro estágio, simulação da propagação da doença ao longo do cultivo, com o segundo estágio, simulação do modelo elétrico do tecido. O primeiro estágio da simulação fornece o tempo de infecção,  $ti$ , para cada árvore a cada progressão discreta de tempo  $\Delta t$ .  $ti$  varia de 0 a 48 meses, onde  $ti = 0$  indica que a planta está saudável, e  $ti = 48$  indica que a planta está morta. Para plantas saudáveis, quando  $ti = 0$ , os parâmetros do modelo elétrico do tecido de cada planta são  $Re = 20 \text{ k}\Omega$ ,  $Ri = 10 \text{ k}\Omega$  e  $Cm = 11,5 \text{ pF}$ . Quando a planta morre, com  $ti = 48$ , os parâmetros são  $Re = 53 \text{ k}\Omega$ ,  $Ri = 2,3 \text{ k}\Omega$  e  $Cm = 25,8 \text{ pF}$ . Esses valores foram obtidos com base nos resultados apresentados por (JINYANG *et al.*, 2016) e (BORGES *et al.*, 2014), e a transição entre os estados saudável e morto ocorre de forma linear e diretamente proporcional à evolução de  $ti$ .

É importante ressaltar que o primeiro estágio da simulação foi implementado com base no modelo apresentado em (KOBORI; TAKASU; OHTO, 2012), e o segundo estágio com base no modelo de Hugo Fricke (ZHAO *et al.*, 2017). A integração desses dois estágios e a introdução dos parâmetros  $ru_1$ ,  $ru_2$ ,  $ru_3$  e  $ru_4$  para a construção de uma base de dados sintéticos representam uma contribuição original desta tese. Isso permite a simulação da propagação de doenças em cultivos, fornecendo como resultado os valores de bioimpedância medidos ao longo da área cultivada, possibilitando a implementação de diversos cenários, que levariam meses ou até anos de experimentos, em poucos minutos de simulação.

Para simular as medições da bioimpedância na planta  $i,j$ , ao longo do tempo, basta incluir os parâmetros  $ru_1$ ,  $ru_2$ ,  $ru_3$ ,  $ru_4$  e  $ti$  nas equações (24) e (25). Assim, o modelo da simulação é descrito por

$$\theta_{i,j}(\omega, ti) = tg^{-1} \left( \frac{X_{i,j}(\omega, ru_1, ru_3, ru_4, ti)}{R_{i,j}(\omega, ru_1, ru_3, ru_4, ti)} \right) \cdot (1 + ru_2), \quad (26)$$

e

$$Z_{i,j}(\omega, ti) = \frac{\left( \sqrt{R_{i,j}(\omega, ru_1, ru_3, ru_4, ti)^2 + X_{i,j}(\omega, ru_1, ru_3, ru_4, ti)^2} \right)}{(1 + ru_2)}. \quad (27)$$

### 5.3 Metodologia para a Construção das Bases de Dados Experimentais

Os sistemas utilizados para realizar a espectroscopia de impedância elétrica são denominados analisadores de impedância. Existem alguns modelos de analisadores de impedância disponíveis comercialmente, como o N4L PSM 1735, fabricado pela Newtons4th. Esse instrumento opera na faixa de frequência de 10  $\mu$ Hz a 35 MHz, pode ser utilizado para medir impedâncias entre 10 m $\Omega$  e 100 M $\Omega$ . Outro modelo disponível é o BAS-Zahner IM6, fabricado pela Zahner. Esse dispositivo faz medições para frequências de 10  $\mu$ Hz a 8 MHz e impedâncias de 30  $\mu\Omega$  a 1 G $\Omega$ , com incerteza de 3%. Esses dois modelos citados são instrumentos para bancada, além de não serem portáteis, eles são de alto custo monetário. Porém, existem analisadores de impedância comerciais portáteis, como o PalmSens4, fabricado pela PalmSens, que faz medições para uma faixa de frequência de 10  $\mu$ Hz a 1 MHz. Apesar de portátil, esse instrumento também possui um custo monetário elevado (AL-ALI, 2018).

A falta de instrumentos analisadores de impedância comerciais que possam ser aplicados *in vivo* e *in situ*, e com um custo monetário acessível a pequenos e médios agricultores, tem levado os pesquisadores a desenvolverem seus próprios instrumentos de medição (BORGES *et al.*, 2014; MARCOS, 2019; BAR-ON; JOG; SHACHAM-DIAMAND, 2019). A maior parte dos analisadores de impedância portáteis desenvolvidos usam o CI AD5933 da *Analog Devices* (DEVICES, 2017a). O AD5933 contém um sistema de medição de impedância integrado que é controlado através de uma interface I2C. Ele faz medições de impedâncias entre 1 k $\Omega$  e 10 M $\Omega$ , para uma faixa de frequência de 1 kHz a 100 kHz, com resolução menor que 0,1 Hz. A precisão do sistema é de 0,5%. MARCOS (2019) desenvolveu um analisador de impedância utilizando o CI AD5933 para ser aplicado no diagnóstico de doenças em plantas. Outros sistemas analisadores de impedância também têm sido desenvolvidos com base no AD5933 (AL-ALI, 2018). O AFE4300, da *Texas Instruments*, é outro CI que pode ser utilizado na construção de um analisador de impedância. Esse CI é especializado na medição de escalas de peso, através de células de cargas configuradas em ponte, e na análise de composição corporal, através da medição da bioimpedância (INSTRUMENTS, 2012). Porém, o AFE4300 não possui a função de



varredura em frequência, como o AD5933, e a faixa de valores de impedância que podem ser medidos é pequena. Isso limita a aplicação dele na construção de analisadores de impedância. No entanto, alguns autores têm desenvolvido sistemas de espectroscopia de impedância elétrica utilizando o CI AFE4300 (SANCHEZ *et al.*, 2013; DAHLMANN *et al.*, 2019).

O circuito que está sendo utilizado nos experimentos deste trabalho tem como base o CI AD5934 da *Analog Devices*. Essa escolha foi determinada pelo custo monetário mais acessível, quando comparado ao AD5933, considerando que as especificações do AD5934 atendem às necessidades do sistema de medição desenvolvido. O CI AD5934 faz medições de impedâncias entre 1 k $\Omega$  a 10 M $\Omega$ , para um *range* de frequência de 1 kHz a 100 kHz, com resolução menor que 0,1 Hz e também permite fazer varredura em frequência. A precisão na medição é de 0,5% (DEVICES, 2017b).

O sistema de medição utilizado neste trabalho foi construído com o objetivo de mensurar algumas variáveis e armazená-las, formando bases de dados para a realização de testes *offline*. As variáveis medidas foram a temperatura ambiente, a umidade relativa do ar, a temperatura do solo em cada vaso com as plantas e a bioimpedância do tecido de cada planta. É importante ressaltar que esse sistema foi projetado e desenvolvido integralmente ao longo deste trabalho.

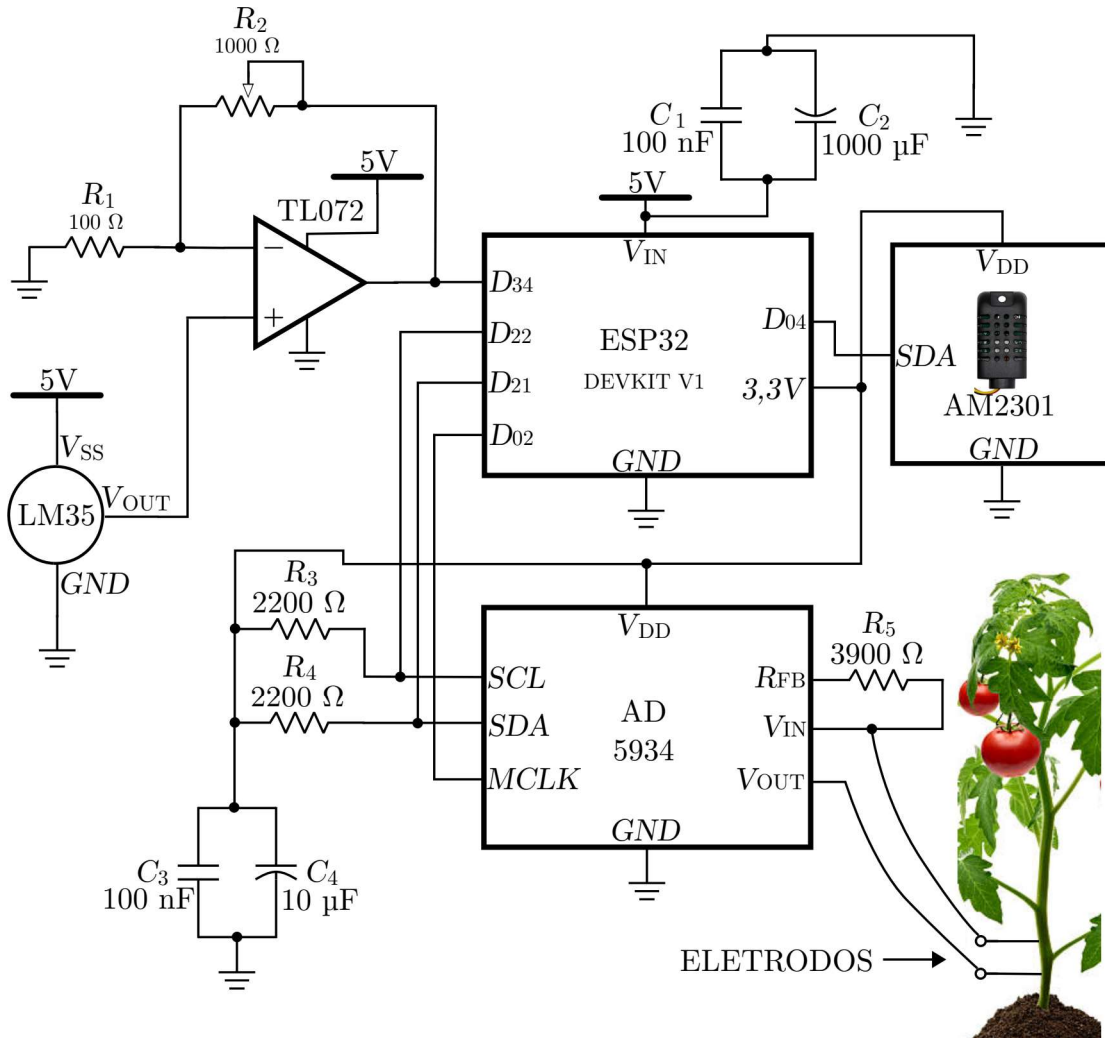
O arranjo experimental é formado por uma bancada com dimensões de 150 cm x 60,5 cm, sobre ela são acomodados 10 vasos com tomateiros. Sendo que, para cada bateria de experimentos os tomateiros foram substituídos. A decisão de usar tomateiros nos experimentos foi devido ao nível de sensibilidade que esse tipo de planta tem aos estresses e ao seu alto custo de produção.

O arranjo também é composto por 10 nós sensores, um sensor AM2301, um *raspberry pi 4* e uma fonte de tensão. Cada nó sensor é formado por um microcontrolador ESP32 da *Espressif*, um CI AD5934 da *Analog Devices*, que é um conversor de impedância, e um sensor de temperatura LM35 com encapsulamento de silicone. Os componentes de cada nó sensor são acomodados em um gabinete resistente a respingos de água, conforme apresentado na Figura 24, e o esquemático dos nós sensores está apresentado na Figura 23. O arranjo experimental está apresentado na Figura 25.

O esquemático do Nó 01 é apresentado na Figura 23 e é composto por um microcontrolador ESP32 da *Espressif*, um sensor de temperatura LM35 conectado a um amplificador não inversor com ganho ajustado para 4,2 V/V, e a seguir conectado ao conversor A/D da porta  $D_{34}$  do ESP32. O Nó 01 também inclui um sensor AM2301 conectado à entrada  $D_{04}$  do ESP32, além de um conversor de impedância AD5934 que se comunica com o ESP32 através do protocolo I<sup>2</sup>C. Os nós sensores 02 a 10 têm o mesmo esquemático, com a exceção do sensor AM2301, que está presente apenas no Nó 01. A faixa de medição de temperatura considerada para o LM35 é

de 15°C a 60°C. Com um ganho de 4,2 V/V, a tensão na entrada do conversor A/D do ESP32 varia entre 0,63 V e 2,52 V, que está em uma região linear do ADC.

Figura 23 – Diagrama esquemático do Nó Sensor 01. Os nós sensores 02 a 10 têm o mesmo esquemático, com a exceção do sensor AM2301, que está presente apenas no Nó 01.



Fonte: Autor.

Cada conversor de impedância AD5934, controlado pelo ESP32 do seu respectivo nó, faz a medição da bioimpedância da planta pelo método potenciostático, aplicando uma tensão elétrica alternada com valor pico a pico de 1,98 V no tecido da planta e medindo a corrente que o percorre, como explicado na Seção 3.6. Essa medição é realizada para as frequências de 1 kHz, 10 kHz, 20 kHz, 30 kHz, 40 kHz, 50 kHz, 60 kHz, 70 kHz, 80 kHz, 90 kHz e 100 kHz. O conversor de impedância é conectado à planta através de dois eletrodos, conforme ilustrado na Figura 27. Esses eletrodos, ilustrados na Figura 26, são agulhas de acupuntura, adequadas para essa finalidade por serem estéreis, construídas de material inerte e possuírem o diâmetro da secção transversal pequeno, entre 0,16 mm e 0,3 mm. As agulhas que foram

Figura 24: Nó sensor utilizado na RSSF empregada nos experimentos.



Fonte: Autor.

usadas neste trabalho possuem comprimento de 30 mm e diâmetro da seção transversal de 0,25 mm. Os eletrodos foram posicionados no caule das plantas próximos ao solo, como apresentado na Figura 27. A distância entre os eletrodos é de 15,5 mm e a profundidade de penetração no caule de 6 mm.

Os sensores de temperatura LM35 foram encapsulados com silicone e são usados para medir a temperatura do substrato (solo). Eles ficam inseridos nos vasos, como ilustrado na Figura 27. O sistema também possui um sensor AM2301 posicionado no centro do arranjo experimental. Esse sensor mede a temperatura ambiente e a umidade relativa do ar, e é conectado diretamente ao Nó 01. Na Figura 25 é possível observar a posição do sensor AM2301 no arranjo experimental.

Os 10 nós sensores formam uma rede sem fio do tipo estrela, onde o Nó 01 é o nó *sink* e os outros nós se comunicam apenas com o Nó 01. A comunicação é realizada via Wi-Fi, através do protocolo ESP-NOW desenvolvido pela *ESPRESSIF*. A sequência para a medição em rede inicia com o Nó 01 enviando um *broadcast* solicitando que todos os nós da rede iniciem a medição. Em seguida, cada nó mede a temperatura do solo no respectivo vaso, incluindo o Nó 01. Na sequência, cada nó faz a medição da bioimpedância, para todas as frequências especificadas anteriormente, e armazena em uma matriz na memória volátil do ESP32, incluindo também o Nó 01. Por fim, o Nó 01 faz a medição da umidade relativa do ar e da temperatura do ambiente através do sensor AM2301. Todo esse processo de medição dura aproximadamente 25 segundos. Após a etapa de medição, o Nó 01 coleta os dados de todos os sensores e, através de uma comunicação serial, envia para o *raspberrypi*. Através de um programa desenvolvido na linguagem *Python 3*, esses dados são armazenados em um arquivo de texto, formando uma base de dados no *raspberrypi*.

Figura 25 – Primeiro arranjo experimental, formado por 10 nós sensores, um sensor AM2301, um *raspberry pi 4*, uma fonte de tensão e 10 tomateiros.



Fonte: Autor.

*pi* para análise posterior. A cada 2 minutos esse processo de medição e armazenamento é repetido, assim, o período de amostragem é de 2 minutos. Vale ressaltar que o projeto e a construção dos nós sensores e de todo o sistema de medição foram realizados ao longo deste trabalho.

Este terceiro grupo de experimentos é composto por 4 baterias experimentais. Cada bateria consiste em preparar as mudas, transplantar as mudas para os vasos, instalar os nós sensores e, por fim, conduzir os testes. O tempo desde a preparação das mudas até o final dos testes, para cada bateria, variou entre 2,5 a 3 meses, com exceção da primeira bateria, que foi mais curta. O plantio foi realizado com sementes de tomate, *Solanum lycopersicum*, da variedade San Marzano. O tempo do semeio até o transplântio foi em média 20 dias e o tempo do transplântio até o início dos experimentos foi de aproximadamente 30 dias.


A primeira bateria foi realizada apenas para testar e ajustar os nós sensores. A segunda e a terceira foram conduzidas no arranjo experimental apresentado na Fi-

Figura 26 – Tipo de eletrodo utilizado. São agulhas de acupuntura com diâmetro da secção transversal de 0,25 mm.



Fonte: Retirada de <https://www.goldlifesp.com.br/p-3479064-Agulhas-Acupuntura> (acessado em 11 de setembro de 2024).

Figura 27: Disposição dos eletrodos e do sensor de temperatura LM35.



Fonte: Autor.

gura 25. A quarta bateria de experimentos foi conduzida no arranjo apresentado na Figura 28. A mudança principal, em relação ao arranjo anterior, foi o acréscimo da iluminação artificial, implementada através de lâmpadas incandescentes com potência de 40 W. Foram posicionadas 10 lâmpadas, uma acima de cada planta. Também foi adicionado ao sistema um *nobreak*, o ATTIV 1500 VA da *Intelbras*, para evitar a perda de dados na ocorrência de falta de energia.

É importante descrever algumas características que estão relacionadas à medição dos sensores utilizados. As incertezas associadas ao sensor AM2301 são  $\pm 0,5^{\circ}\text{C}$ , para a medição da temperatura do ambiente, e  $\pm 3\%$ , para a umidade relativa do ar. Para o sensor LM35, a incerteza é de  $\pm 0,5^{\circ}\text{C}$ . Esses dados foram retirados dos respectivos *datasheets* dos sensores. A incerteza associada à medição da bioimpedância foi calculada a partir do desvio padrão. Foram coletadas 20 amostras para

Figura 28 – Segundo arranjo experimental. Neste arranjo foi inserida a iluminação artificial e um *nobreak*.



Fonte: Autor.

3 frequências, 1 kHz, 50 kHz e 100 kHz, totalizando 60 amostras. A incerteza calculada foi de 0,82%, considerando um intervalo de confiança de 95%. Apesar da incerteza associada à medição da bioimpedância está dentro de uma faixa aceitável, o sistema foi programado para realizar 10 repetições para a medição realizada em cada frequência, permitindo o tratamento de erros aleatórios. De forma semelhante, para cada amostra da temperatura do solo através do sensor LM35, o sistema considera o valor médio de 20 medições. Como o sensor AM2301 já faz o tratamento dos dados e os envia na forma digital para o ESP32, para cada coleta com esse sensor o sistema realiza apenas uma medição.

Outro aspecto importante é a forma em que o conversor de impedância AD5934 é calibrado. Para isso, são realizadas duas etapas, uma para calibrar o módulo da impedância e outra para calibrar a fase. O módulo é ajustado medindo-se uma resistência com valor conhecido e calculado um fator de ganho, que é utilizado para compensar o valor medido. No *datasheet* do AD5934 tem descrito de forma detalhada como realizar esse procedimento. A medição da fase é ajustada medindo-se uma fase conhecida. A diferença entre o valor real dessa fase e o valor medido é calculada e utilizada para compensar a medição diretamente. As duas etapas de calibração foram realizadas para cada frequência de interesse, evitando desvios nas medições devido a mudanças na frequência de excitação. Tanto as medições realizadas para o ajuste do módulo quanto da fase foram efetuadas em um resistor com resistência de


18130  $\Omega$ .

Essa forma de calibração, para cada frequência de interesse, que para este trabalho foram as frequências de 1 kHz, 10 kHz, 20 kHz, 30 kHz, 40 kHz, 50 kHz, 60 kHz, 70 kHz, 80 kHz, 90 kHz e 100 kHz, permite compensar a influência dos cabos que conduzem o sinal elétrico até os eletrodos, que é um problema comum na aplicação da EIS. Por outro lado, o próprio método de medição baseada em Superfície de Impedância, proposto nesta tese, já compensa a influência dos cabos, por ser uma forma de medição relativa. Mas, para que essa compensação aconteça, os cabos devem ser iguais. Na sequência são apresentados detalhes sobre os procedimentos experimentais empregados na terceira e na quarta baterias de experimentos.

Os resultados apresentados na Seção 6.3 são referentes à terceira e à quarta bateria de experimentos, visto que, ao longo da segunda bateria foi detectado um problema no arranjo experimental que estava inserindo muito ruído nas medições. Por essa razão, os resultados obtidos na segunda bateria não foram analisados neste trabalho.

A posição dos nós sensores nos arranjos da terceira e da quarta baterias de experimentos estão ilustrados nas figuras 29 e 30, respectivamente. Para evitar a necessidade de regar diariamente, em ambas foi utilizada a irrigação por capilaridade, onde a água sobe através dos poros do solo até chegar às raízes. Isso foi implementado colocando uma pequena bandeja abaixo de cada vaso, como pode ser visto na Figura 28, e a irrigação era realizada depositando água diretamente nas bandejas.


Figura 29 – Posição dos nós sensores no arranjo da terceira bateria de experimentos.



Fonte: Autor.

Para submeter algumas plantas à condição de estresse, realizou-se o corte da irrigação via bandejas. Esse tipo de tratamento foi escolhido porque, na avaliação do estado fisiológico das plantas, o estresse hídrico é um dos principais parâmetros. Visto que, tanto para as condições de doenças bióticas quanto para as abióticas, a absorção de água pelas plantas é um dos primeiros processos fisiológicos a serem afetados (BORGES *et al.*, 2014; PIRZAD *et al.*, 2011). Outro fator é a capacidade da planta sinalizar o estresse hídrico de forma precoce por meio do fechamento dos estômatos. Nessa condição, a transpiração é reduzida, comprometendo a movimen-

Figura 30: Posição dos nós sensores no arranjo da quarta bateria de experimentos.




Fonte: Autor.

tação e o uso mais eficiente da água pela planta e, conseqüentemente, levando a baixa taxa fotossintética.

Durante os experimentos da terceira bateria, a primeira planta a ter o fornecimento de água cortado foi a do Nó 7. Em seguida, o fornecimento foi cortado para as plantas dos nós 4, 10 e 1, com um intervalo de 3 dias entre cada corte. Para os experimentos da quarta bateria, o fornecimento de água foi inicialmente interrompido para a planta do Nó 1, seguida pelas plantas dos nós 2, 6, 5 e 3. Houve um intervalo de 2 dias entre esses cortes, exceto para a planta do Nó 10, cujo corte ocorreu 1 dia após o da planta do Nó 03. O tempo médio decorrido desde o corte até a sinalização do estresse, indicado pelo fechamento dos estômatos, foi de 7,25 dias para a terceira bateria e 7,33 dias para a quarta bateria. Analisando a Figura 31, que contém amostras do solo dos vasos em dias distintos após o corte do fornecimento de água, observa-se que o solo seca entre o sexto e o oitavo dia após o corte, estando em conformidade com o período médio do fechamento dos estômatos. Os resultados obtidos com os arranjos experimentais apresentados nesta seção são exibidos e analisados no Capítulo 6.

Figura 31 – Amostras dos solos para demonstrar a dinâmica da secagem do solo ao longo dos experimentos.



Fonte: Autor.



## 6 RESULTADOS E DISCUSSÕES

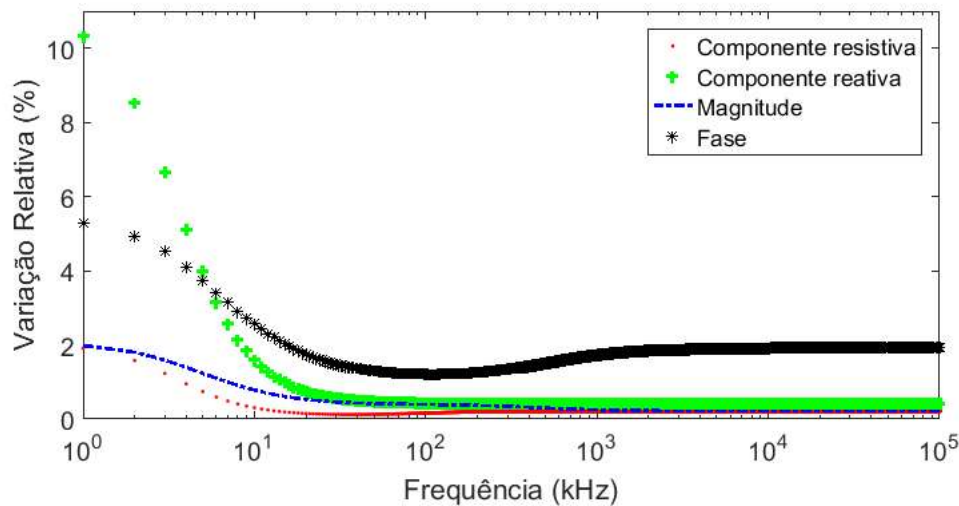
Neste capítulo são apresentados os resultados obtidos a partir dos três grupos de experimentos descritos no Capítulo 5. Para facilitar a compreensão, os resultados serão exibidos em três seções. Na Seção 6.1 os resultados são apresentados com o objetivo de analisar se é possível detectar doenças e estresses em plantas usando apenas uma única frequência e um único parâmetro da bioimpedância medida. Na Seção 6.2 são apresentados e analisados os resultados da aplicação da medição baseada em Superfície de Impedância aos dados obtidos através das simulações descritas na Seção 5.2. Por fim, a medição baseada em Superfície de Impedância é aplicada aos dados reais, que foram coletados utilizando os arranjos experimentais descritos na Seção 5.3, e os resultados estão apresentados na Seção 6.3.

### 6.1 Resultados da Análise da Detecção Utilizando Apenas uma Frequência e um Parâmetro da Bioimpedância

Nesta seção os resultados são exibidos em três etapas. Na primeira, são apresentados os resultados da análise da sensibilidade dos parâmetros da bioimpedância à ação de agentes estressores nas plantas. Os parâmetros analisados são a fase, o módulo, a componente real e a imaginária da bioimpedância. Esses testes foram realizados por simulação, através do modelo elétrico que representa o tecido da planta. Para esse teste de sensibilidade foram utilizados dois modelos representando o tecido da planta para dois níveis de concentração de nitrogênio distintos, 2,5% e 4,5%, como descrito detalhadamente na Seção 5.1. Os resultados estão apresentados na Figura 32, onde cada curva representa o quociente do valor medido para o nível de 4,5 pelo valor medido para o nível de 2,5, expressando a sensibilidade relativa dos parâmetros em função da variação do nível de concentração de nitrogênio. As medições foram realizadas variando a frequência de 1 kHz a 100 MHz, com passo de 1 kHz.

Analisando as curvas apresentadas no gráfico da Figura 32, observa-se que a magnitude e as componente resistiva e reativa da bioimpedância possuem sensibilidades

Figura 32 – Gráfico com curvas que representam a sensibilidade dos parâmetros da bioimpedância ao estresse causado por 2 níveis distintos de concentração de nitrogênio.



Fonte: Autor.

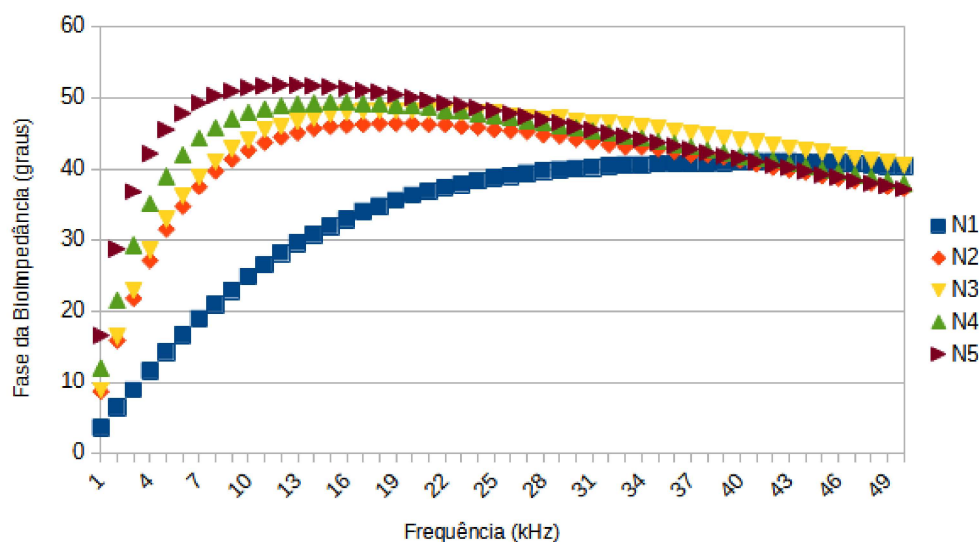
semelhantes, a partir de 20 kHz, e significativamente menores que a da fase. A componente reativa se destaca pela alta sensibilidade para baixas frequências, porém, a variável escolhida para os testes subsequentes, realizados neste primeiro grupo de experimentos, foi a fase. Essa escolha foi embasada no fato de que a fase possui uma sensibilidade significativamente maior em toda a faixa de frequência analisada, sendo menor que a da componente reativa apenas para a faixa de 0 a 6 kHz.

Na segunda etapa foi realizada uma espectroscopia de impedância elétrica, variando a frequência de 1 kHz a 50 kHz com passo de 1 kHz, medindo apenas a fase. As medições foram realizadas para 5 níveis de concentração de nitrogênio (N), N1, N2, N3, N4 e N5, conforme descrito na Tabela 2. Essas medições foram realizadas em laboratório e, para representar o tecido da planta, foram implementados cinco circuitos elétricos, conforme o modelo elétrico apresentado na Figura 5, proposto por Hugo Fricke. Os valores dos componentes utilizados para cada circuito estão descritos na Tabela 2, os quais foram obtidos através de experimentos reais conduzidos por MEIQING *et al.* (2017) em tomateiros, conforme explanado na Seção 5.1.

Esses testes em laboratório foram realizados para analisar qual frequência seria mais adequada para distinguir os 5 níveis de concentração de nitrogênio e os resultados estão ilustrados na Figura 33. O projeto desse experimento considera dois fatores, que são a frequência e a concentração de nitrogênio. A frequência com 50 níveis e a concentração de N com 5 níveis, como descrito no início deste parágrafo. Com base nos conhecimentos relatados em artigos especializados, a temperatura é um fator externo que afeta significativamente esse tipo de experimento (HAYDEN *et al.*, 1969; HAYASHI *et al.*, 1992). Portanto, os experimentos foram cuidadosa-

mente realizados em um ambiente fechado e controlado, evitando a influência significativa desse fator externo. Isso permitiu a coleta de dados de forma sequencial, sendo realizada a espectroscopia para cada nível, um após o outro.

Figura 33 – Gráfico com curvas que representam as medições para cada nível de concentração de nitrogênio. As medições foram realizadas variando a frequência de 1 kHz a 50 kHz, com passo de 1 kHz.



Fonte: Autor.

No gráfico ilustrado na Figura 33 estão traçadas cinco curvas, cada curva representa as medições realizadas para um nível de concentração de nitrogênio. Analisando a disposição das curvas, observa-se que a faixa entre 10 kHz e 15 kHz é a que possui maior diferença entre os valores medidos para os 5 níveis de N, sendo a mais adequada para fazer a distinção entre eles através de limiares. Assim, para o último experimento desse grupo será utilizada a frequência de 12 kHz. Vale ressaltar que, para os resultados apresentados na Figura 33, e somente para esses, as medições foram realizadas com um circuito de medição de fase que foi projetado e implementado ao longo deste trabalho e publicado em (CARVALHO *et al.*, 2022), sendo que todas as outras medições reais foram realizadas com os sensores apresentados na Seção 5.3.

Na terceira etapa foram realizadas medições aplicando apenas a frequência de 12 kHz. Aqui, as medições foram realizadas com o conversor de impedância AD5934, apresentado na Seção 5.3. As medições foram realizadas em laboratório utilizando o circuito elétrico do modelo de Hugo Fricke para representar o tecido da planta para cada nível de concentração de N, como descrito na Seção 5.1, e o experimento foi conduzido coletando 10 amostras para cada nível.

O projeto desse experimento considerou apenas um fator, que foi a concentração de nitrogênio, com 5 níveis, conforme descrito na Tabela 2. Sabendo-se que a tempe-

ratura é o fator externo que mais influencia nesse tipo de experimento, as medições foram realizadas em ambiente controlado, tomando inicialmente a primeira amostra de cada nível, em seguida, partiu-se para a coleta da segunda amostra de cada nível, seguindo essa ordem até chegar na décima amostra. Os resultados estão exibidos na Tabela 3 e o valor médio com os respectivos desvios padrões, para cada nível N, estão apresentados na Figura 34. Analisando o gráfico exibido na Figura 34, que apresenta o valor medido da fase da bioimpedância em função do nível de concentração de N, observa-se que utilizando a forma mais simples de classificação, que é a definição de limiares, é possível classificar os 5 níveis de N. Esses resultados mostram que é possível fazer a detecção de estresses em plantas utilizando apenas um parâmetro da bioimpedância e realizando a medição aplicando apenas uma frequência.

É importante ressaltar que os resultados obtidos nos experimentos desta tese foram semelhantes e compatíveis com os resultados obtidos por MEIQING *et al.* (2017). Porém, os resultados obtidos em (MEIQING *et al.*, 2017) consideram a medição para uma larga faixa de frequência e a classificação é realizada considerando vários parâmetros, enquanto que os resultados apresentados nesta seção foram obtidos medindo a bioimpedância apenas em uma única frequência e as análises foram realizadas utilizando apenas um parâmetro da bioimpedância.


Tabela 3 – Medições realizadas para os 5 níveis de concentração de nitrogênio utilizando a frequência de 12 kHz. Foram coletadas 10 amostras para cada nível.

Amostra	N1	N2	N3	N4	N5
1	-33,75	-50,04	-54,71	-56,82	-59,91
2	-33,67	-50,13	-54,86	-56,94	-60,21
3	-33,96	-49,89	-54,46	-56,72	-59,95
4	-33,95	-49,07	-54,89	-56,86	-59,97
5	-33,82	-50,27	-54,82	-56,92	-59,92
6	-33,91	-50,18	-54,83	-56,88	-60,00
7	-33,98	-50,09	-54,77	-56,86	-60,02
8	-34,12	-50,04	-54,79	-56,83	-60,01
9	-33,82	-50,06	-54,85	-57,11	-60,00
10	-34,11	-50,21	-54,85	-56,97	-60,06

## 6.2 Resultados da Aplicação da Superfície de Impedância à Base de Dados Sintéticos

Os resultados apresentados nesta seção foram obtidos a partir das simulações descritas na Seção 5.2 e estão exibidos em três etapas. A primeira etapa é apresentada na Subseção 6.2.1, onde é descrita uma análise da medição com o método clássico, considerando cada planta individualmente. A Subseção 6.2.2 traz a segunda etapa, onde é feita uma análise da Superfície de Impedância. A terceira etapa é exibida na Subseção 6.2.3, apresentando uma análise da classificação baseada em Superfície de

Figura 34 – Gráfico com a representação das médias e desvios padrões das medições exibidas na Tabela 3. O gráfico exibe o valor medido da bioimpedância em função do nível de concentração, e os desvios padrões são representados pelas barras em cada ponto.



Fonte: Autor.

Impedância.

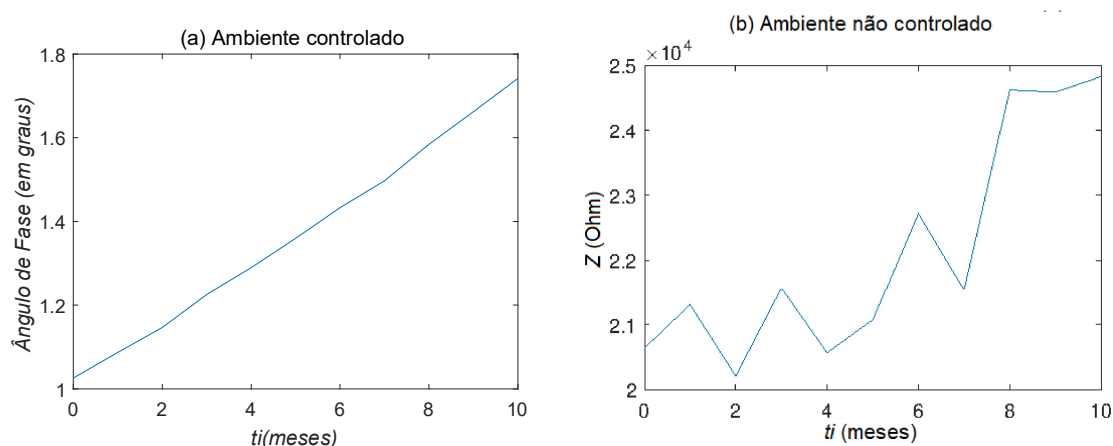
### 6.2.1 Análise da Medição com o Método Clássico

Nesta subseção são apresentados resultados obtidos através do método clássico de medição que, ao contrário do método baseado na Superfície de Impedância proposto nesta tese, considera as plantas individualmente, como explanado na Subseção 3.6.1. Para avaliar a abordagem clássica foram conduzidos experimentos simulando o modelo descrito pelas equações (26) e (27), apresentado na Seção 5.2. Foram conduzidos testes em duas condições distintas. Para a primeira condição, o parâmetro  $ru4$ , que representa mudanças nas variáveis ambientais, foi mantido igual a 0. Ou seja, as variáveis ambientais são mantidas constantes. Para a segunda condição, as variáveis ambientais não foram mantidas constantes. Os resultados para a primeira e para a segunda condição são exibidos na Figura 35 (a) e (b), respectivamente. É exibido nos gráficos contidos na Figura 35 o valor da fase da bioimpedância em função do tempo de infecção,  $t_i$ , obtido a partir da simulação descrita na Seção 5.2, o qual varia de 0 a 10 meses. As medições são realizadas em uma única planta, conforme a abordagem clássica. A frequência utilizada para essas medições também foi de 12 kHz, como na Seção 6.1.

Analisando os resultados apresentados na Figura 35 (a), observa-se que entre a bioimpedância do tecido da planta e o tempo de infecção  $t_i$  existe uma forte correlação, indicando que a abordagem clássica funciona bem em ambientes controlados,

corroborando com os resultados dos trabalhos apresentados na revisão bibliográfica, que demonstram a eficácia da abordagem clássica em ambientes controlados. Por outro lado, os resultados expostos na Figura 35 (b) demonstram uma fraca correlação entre essas variáveis, indicando que, para ambientes não controlados, a abordagem clássica não se mostra eficaz. Analisando o gráfico na Figura 35 (b) observa-se que entre o início da infecção e o sétimo mês os valores medidos oscilam mantendo uma fraca correlação com o tempo de infecção. Assim, somente entre o oitavo e o décimo mês os resultados apresentam uma tendência que permitiria detectar a infecção na planta. Contudo, ainda assim não seria possível afirmar se a variação medida na bioimpedância foi devido à presença de algum agente estressor, ou a variações nas condições ambientais, ou até mesmo devido ao próprio desenvolvimento natural da planta.

Figura 35 – Medições realizadas conforme a abordagem clássica, considerando uma única planta. Em (a) as variáveis ambientais foram mantidas constantes e em (b) essas variáveis não foram mantidas constantes.



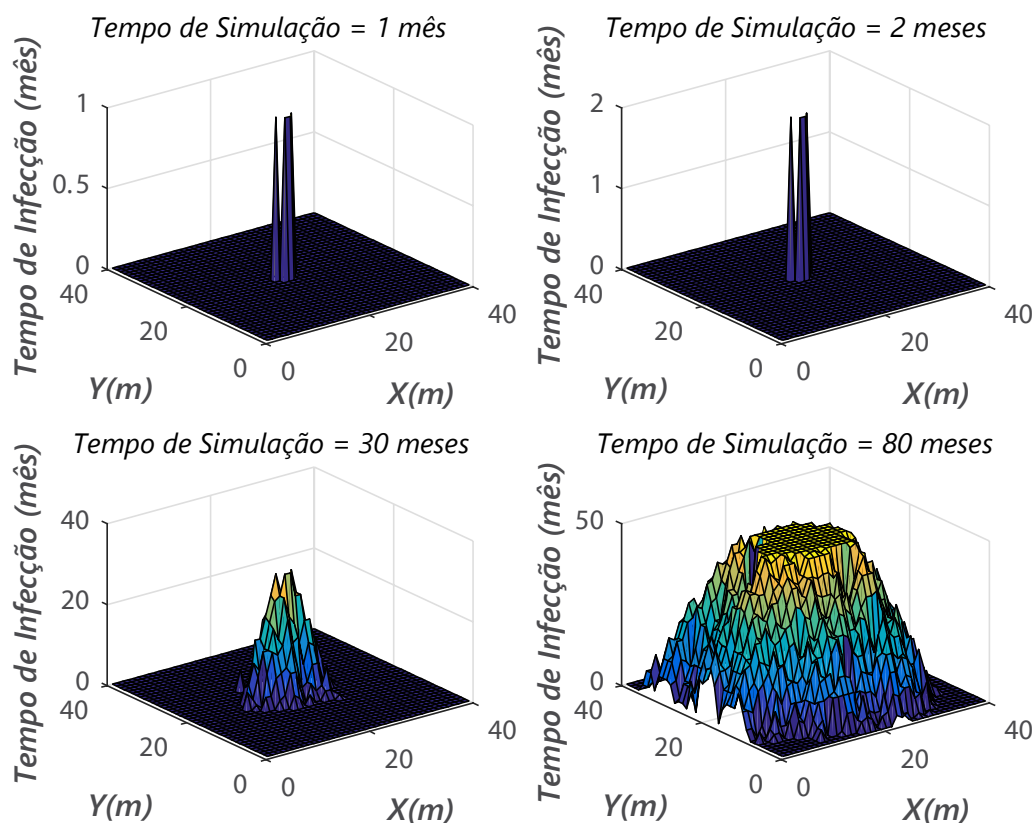
Fonte: Autor.

### 6.2.2 Análise da Superfície de Impedância

Nesta subseção são apresentadas algumas análises da Superfície de Impedância, método de medição proposto nesta tese. É importante enfatizar que os resultados apresentados nesta subseção foram obtidos através de simulação, através do modelo apresentado na Seção 5.2, baseado na propagação da doença *Huanglongbing* através do inseto vetor *Diaphorina citri*, no cultivo de citros. Para facilitar as análises dos resultados exibidos nesta subseção, na Figura 36 é apresentado a dinâmica de propagação da doença, considerando que o início da contaminação ocorreu no tempo de simulação  $ts = 0$  mês. Nela são expostos quatro gráficos ilustrando o tempo de infecção de cada planta, para quatro tempos de simulação distintos,  $ts = 1$ ,  $ts = 2$ ,  $ts = 30$  e  $ts = 80$  meses, sendo  $X$  e  $Y$  as coordenadas que representam a dimensão

espacial da área cultivada. Esses tempos de simulação são os mesmo utilizados para as análises dos resultados apresentados nas figuras 37, 38 e 39.

Figura 36 – Tempo de infecção em todas as plantas do cultivo. São apresentados gráficos para quatro tempos de simulação específicos.



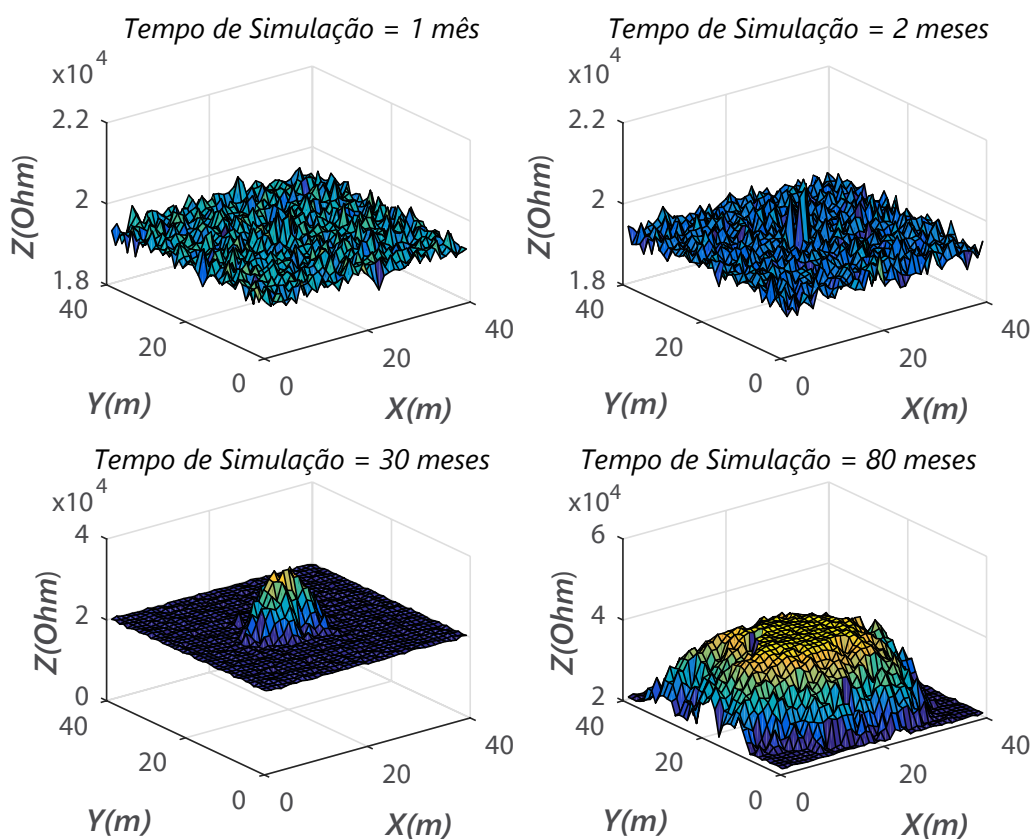
Fonte: Autor.

Nas figuras 37 e 38 são apresentadas as medições realizadas com o método proposto neste trabalho, considerando os mesmos tempos de simulação apresentados na Figura 36. Na Figura 37 a Superfície de Impedância é representada com base na medição do módulo da bioimpedância e na Figura 38 com base na medição da fase. Sendo que, para as duas figuras,  $X$  e  $Y$  representam as coordenadas espaciais da área do cultivo.

Analisando as figuras 37 e 38, observa-se que a Superfície de Impedância segue a dinâmica de propagação da doença apresentada na Figura 36. Além disso, fazendo uma análise visual mais cuidadosa, é possível perceber que a partir do segundo mês a região no centro do cultivo, local onde a infecção iniciou, destaca-se das outras regiões do cultivo. Isso acontece tanto para a Superfície de Impedância baseada no módulo da bioimpedância quanto para a baseada fase. Esses resultados indicam que a medição baseada em Superfície de Impedância tem potencial para a detecção no estágio inicial dos estresses em plantas, visto que, para a doença considerada nessa simulação, a planta só morre quatro anos após o início da infecção. É impor-

tante ressaltar que a dificuldade em detectar a infecção no primeiro mês é devido aos ruídos na Superfície de Impedância, que são consequências da influência dos parâmetros  $ru1$ ,  $ru2$  e  $ru3$ , explanados detalhadamente na Seção 5.2. Portanto, é possível melhorar o tempo de detecção da infecção reduzindo a interferência desses parâmetros, que podem ser influenciados por erros de medição, oscilações pontuais nas variáveis ambientais, crescimento desigual do cultivo e diferenças na composição do solo. Mas, é importante enfatizar que, para todos os experimentos realizados por simulação aplicando a Superfície de Impedância, os parâmetros  $ru1$ ,  $ru2$  e  $ru3$  foram devidamente considerados, como descrito na Seção 5.2.

Figura 37 – Superfície de Impedância baseada no módulo da bioimpedância. São apresentados gráficos para quatro tempos de simulação específicos.

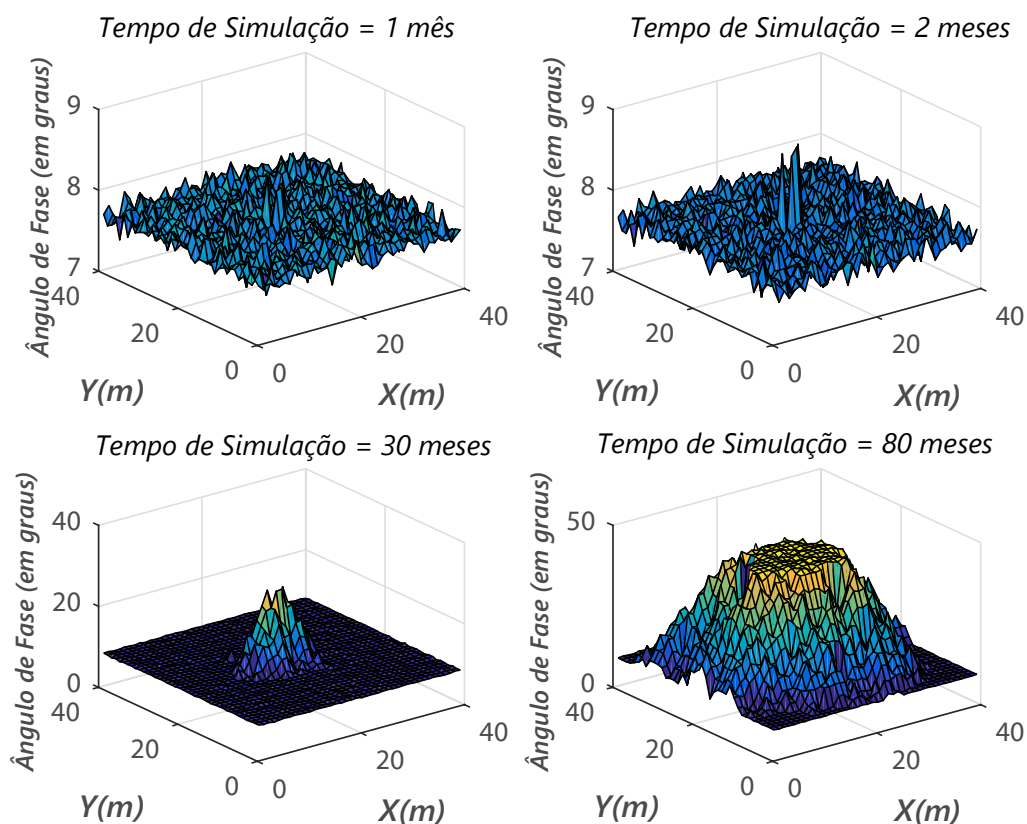


Fonte: Autor.

Nos resultados apresentados na Subseção 6.2.1, observou-se que a abordagem clássica não é adequada para realizar medição em ambientes não controlados. Em contraste, os resultados expostos nas figuras 37 e 38, realizados com a abordagem proposta nesta tese, foram obtidos em condições ambientais não controladas. Isso indica que a medição baseada em Superfície de Impedância tem potencial para ser aplicada em campo, onde as condições ambientais não são controladas. Para fazer uma análise mais detalhada da influência das variáveis ambientais na Superfície



Figura 38 – Superfície de Impedância baseada na fase. São apresentados gráficos para quatro tempos de simulação específicos.



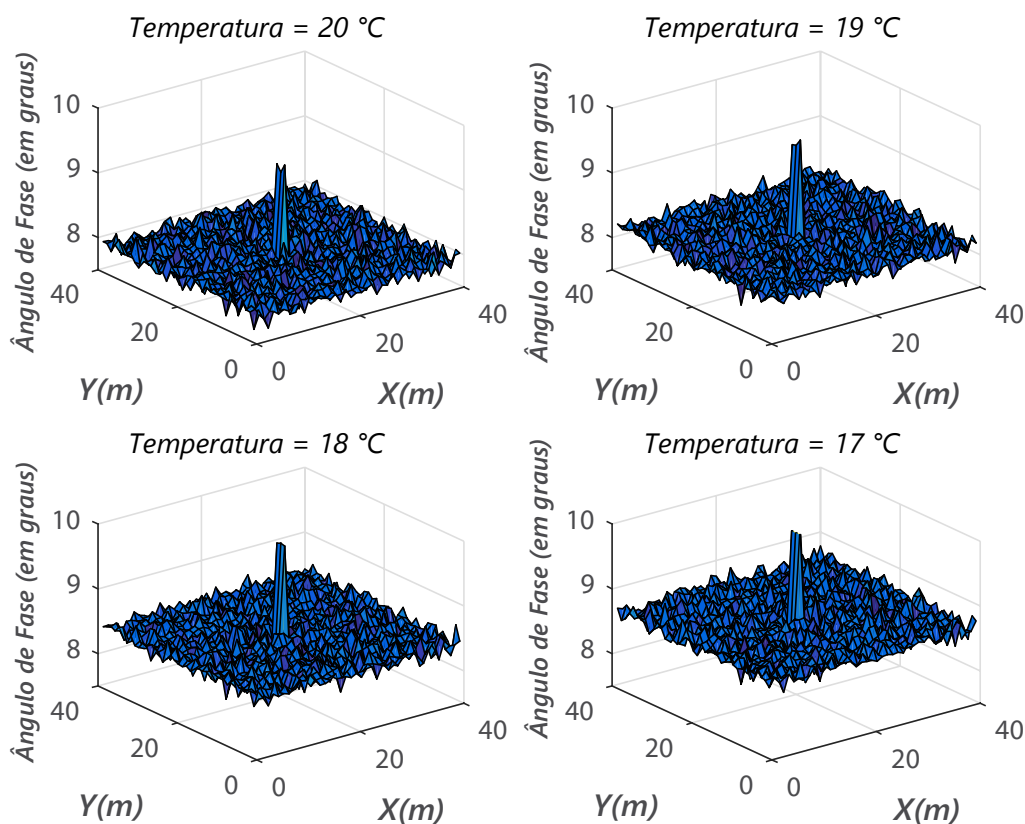
Fonte: Autor.

de Impedância, foram realizadas quatro simulações. Neste teste, cada simulação foi realizada considerando uma temperatura ambiente diferente. As temperaturas consideradas foram 20 °C, 19 °C, 18 °C e 17 °C. O tempo de simulação foi mantido constante e igual a 3 meses. Os gráficos para as quatro temperaturas estão exibidos na Figura 39. Analisando esses resultados nota-se que, as mudanças na temperatura apenas deslocam a Superfície de Impedância ao longo do eixo vertical que representa a fase, no entanto, a forma da superfície é preservada. É por isso que, ao contrário da abordagem clássica, a medição baseada em Superfície de Impedância tem potencial para detectar estresses no cultivo em ambientes não controlados. Vale ressaltar que, observando a Figura 39 é possível visualizar a presença do estresse no centro do cultivo independentemente da temperatura do ambiente.

### 6.2.3 Análise da Classificação Baseada em Superfície de Impedância

Nesta subseção são descritas algumas análises da medição baseada em Superfície de Impedância, abordagem proposta nesta tese. Para isso, a classificação com a Superfície de Impedância, apresentada na Seção 4.2, foi aplicada aos dados obtidos através de medições simuladas, como descrita na Seção 5.2. A única diferença é que

Figura 39 – Superfície de Impedância para quatro temperaturas distintas. Os quatro gráficos foram obtidos para o mesmo tempo de simulação,  $t_s = 3$ .



Fonte: Autor.

ao invés do cultivo ter sido representado por uma matriz 40 x 40, ele foi representado por uma matriz 5 x 5, totalizando 25 plantas. Isso facilita as análises visuais que serão apresentadas nesta subseção. Os dados foram gerados aplicando a frequência de 12 kHz para as medições. Para facilitar a compreensão das figuras 40, 41, 42, 43, 44, 45 e 46, os gráficos contidos nelas exibem o plano, que representa a Superfície de Impedância, e a nuvem de pontos, que representa os dados medidos. Os pontos azuis representam medições em plantas saudáveis classificadas como saudáveis, os 'x', na cor preta, representam medições em plantas doentes classificadas como saudáveis, os asteriscos verdes representam medições em plantas doentes classificadas como doentes e os '+', na cor vermelha, representam medições em plantas saudáveis classificadas como doentes.

Como discutido na Seção 4.2, a Superfície de Impedância utilizada para a classificação das plantas é representada por um plano que é ajustado aos dados através dos Mínimos Quadrados Recursivo. E a classificação é realizada comparando a medição da planta com o valor estimado por esse plano. A forma em que esse plano é ajustado gera uma instabilidade nos primeiros ciclos do algoritmo de classificação,

sendo necessário uma quantidade mínima de ciclos para que o plano se estabilize. A primeira característica da classificação com a Superfície de Impedância a ser avaliada é a estabilidade. Nas figuras 40 e 41 estão ilustrados a nuvem de dados com as medições no instante inicial da simulação e o plano que representa a Superfície de Impedância. Na Figura 40 está o plano atual do Nó  $N_{1,2}$  e na Figura 41 o plano atual do Nó  $N_{5,4}$ . Analisando essas figuras, observa-se que há uma diferença muito grande entre os planos dos referidos nós, implicando em uma instabilidade que é característica da inicialização da classificação com a Superfície de Impedância. Nota-se também que os planos não estão ajustados corretamente aos dados, essa é uma característica dos Mínimos Quadrados Recursivo que realiza o ajuste de forma iterativa, à medida em que as medições vão sendo disponibilizadas sequencialmente.

Figura 40 – Representação do plano do Nó  $N_{1,2}$  e da nuvem de dados para o instante inicial da classificação. Os pontos azuis representam plantas saudáveis classificadas como saudáveis.





Figura 41 – Representação do plano do Nó  $N_{5,4}$  e da nuvem de dados para o instante inicial da classificação. Os pontos azuis representam plantas saudáveis classificadas como saudáveis.



Fonte: Autor.

Para os resultados apresentados nesta subseção foi utilizado um período de estabilização de 25 ciclos. Esse período foi escolhido empiricamente, comparando o comportamento da Superfície de Impedância entre os nós. Os gráficos apresentados nas figuras 42 e 43 possuem as mesmas variáveis exibidas nas figuras 40 e 41. A diferença é que eles foram tomados logo após o período de estabilização. Observa-se que, após os 25 ciclos, os planos apresentados nas figuras 42 e 43, que representam os planos atuais dos nós  $N_{1,1}$  e  $N_{5,3}$ , são bastante próximos, indicando que os planos dos nós convergiram para a Superfície de Impedância. Nota-se também que os planos, após o período de estabilização, representam bem a nuvem de dados.

Figura 42 – Representação do plano do Nó  $N_{1,1}$  e da nuvem de dados para o primeiro ciclo após o período de estabilização. O 'x' preto representa planta doente classificada como saudável. Os pontos azuis representam plantas saudáveis classificadas como saudáveis.





Figura 43 – Representação do plano do Nó  $N_{5,3}$  e da nuvem de dados para o primeiro ciclo após o período de estabilização. O 'x' preto representa planta doente classificada como saudável. Os pontos azuis representam plantas saudáveis classificadas como saudáveis.



Fonte: Autor.

É importante enfatizar que os 25 ciclos do período de estabilização da Superfície de Impedância são realizados antes do início da contaminação. No vigésimo sexto ciclo, que é o instante inicial da contaminação, são depositados 100 insetos vetores na planta  $N_{2,2}$ . Observa-se nas figuras 42 e 43, tomadas no primeiro ciclo após a inserção dos insetos, que as plantas  $N_{2,2}$  e  $N_{2,3}$  estão contaminadas. Quando uma planta é contaminada e ainda não foi classificada como doente ela é representada no gráfico por um 'x' na cor preta. Na Figura 44, gerada para o mesmo ciclo de simulação a partir de outro ângulo de visão, fica mais fácil perceber as duas plantas que foram contaminadas e ainda não foram classificadas. A Figura 45 foi tomada no ciclo de simulação seguinte, nela observa-se que as duas plantas  $N_{2,2}$  e  $N_{2,3}$  foram classificadas como doentes. Os asteriscos verdes na Figura 45 representam plantas doentes que foram classificadas como doentes. Outra característica importante, que pode ser observada na Figura 46, é que a Superfície de Impedância não considera as medições de plantas classificadas como doentes, dessa forma, ela se mantém representando bem as plantas saudáveis do cultivo. Observa-se também nas figuras 45 e 46, que à medida em que a intensidade da infecção vai aumentando em uma planta, as medições realizadas nela vão se afastando da Superfície de Impedância. A Figura 46 foi gerada três meses após a Figura 45.

Figura 44 – Representação do plano do Nó  $N_{1,1}$  e da nuvem de dados para o primeiro ciclo após o período de estabilização, obtido por outro ângulo de visão. Observa-se duas plantas contaminadas que ainda não foram classificadas ('x' pretos).






Figura 45 – Representação do plano do nó  $N_{4,1}$  e da nuvem de dados para o segundo ciclo após o período de estabilização. Observa-se que as duas plantas contaminadas no ciclo anterior foram classificadas como doentes (asteriscos verdes).



Fonte: Autor.

Figura 46 – Representa a Superfície de Impedância e a nuvem de dados. Gerado três meses após o gráfico da Figura 45, permitindo visualizar a evolução das plantas doentes. O asterisco verde representa planta doente classificada como doente.



Fonte: Autor.

Os detalhes da classificação com a Superfície de Impedância estão explanados a seguir, através de dados estatísticos. É importante notar que, os gráficos apresentados nesta subseção, até aqui, foram exibidos com o módulo da bioimpedância. Porém, para enriquecer a análise estatística, foram considerados os parâmetros com maior e menor sensibilidade. Conforme a análise exibida na Figura 32, o parâmetro

com maior sensibilidade é a componente reativa, para baixas frequências, e o parâmetro com menor sensibilidade é a componente resistiva, para frequências entre 11 kHz e 16 kHz. Considerando essas informações, as análises estatísticas foram realizadas através das componentes reativa e resistiva da bioimpedância, com as medições sendo realizadas aplicando a frequência de 12 kHz.

Para realizar as análises estatísticas, a simulação foi rodada até o oitavo mês após o início da infecção. Os dados para cada parâmetro analisado estão apresentados nas tabelas 4 e 5. É importante notar que, para evitar uma análise tendenciosa, tanto para a componente reativa quanto para a resistiva, os dados foram coletados rodando a simulação 10 vezes seguidas sem quebrar a sequência. Os limiares de classificação foram escolhidos empiricamente observando o comportamento dos dados. Para a classificação através da componente reativa, o limiar foi de 22  $\Omega$  e para a componente resistiva o limiar foi de 360  $\Omega$ . Em trabalhos que envolvem classificações, algumas das métricas estatísticas mais utilizadas são *Recall*, *Precision* e *Accuracy* (KUMAR *et al.*, 2023; ALGHAMDI; TURKI, 2023). Essas métricas são específicas para classificações, diferindo das definições clássicas de precisão e exatidão. Portanto, serão mantidas em inglês. Elas são definidas por

$$Recall = \frac{TP}{TP + FN}, \quad (28)$$

$$Precision = \frac{TP}{FP + TP}, \text{ e} \quad (29)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}, \quad (30)$$

sendo  $TP$  os verdadeiros positivos,  $TN$  os verdadeiros negativos,  $FP$  os falsos positivos e  $FN$  os falsos negativos.

Essas métricas são importantes para a análise dos resultados deste trabalho. *Recall* indica a porcentagem de acerto na detecção do estresse, *Precision* indica a porcentagem de acertos quando a planta é classificada como doente e *Accuracy* indica a porcentagem de acertos na classificação como doentes e saudáveis.

Na Tabela 4 são exibidos os resultados para a componente reativa e na Tabela 5 para a componente resistiva.

Para os resultados com a componente reativa, exibidos na Tabela 4, as métricas estatísticas foram:

$$Recall = 98,52\%, \quad (31)$$

$$Precision = 100\%, \text{ e} \quad (32)$$

Tabela 4: Dados para os experimentos com a componente reativa.

Sequência de Simulações	<i>TP</i>	<i>TN</i>	<i>FP</i>	<i>FN</i>
1	9	16	0	0
2	1	24	0	0
3	12	12	0	1
4	7	18	0	0
5	5	20	0	0
6	8	17	0	0
7	13	12	0	0
8	1	24	0	0
9	6	19	0	0
10	5	20	0	0

Tabela 5: Dados para os experimentos com a componente resistiva.

Sequência de Simulações	<i>TP</i>	<i>TN</i>	<i>FP</i>	<i>FN</i>
1	1	24	0	0
2	6	19	0	0
3	5	20	0	0
4	9	15	0	1
5	6	19	0	0
6	3	22	0	0
7	8	17	0	0
8	6	19	0	0
9	5	20	0	0
10	9	16	0	0

$$Accuracy = 99,60\%, \quad (33)$$

e, para os resultados com a componente resistiva, exibidos na Tabela 5, as métricas estatísticas foram:

$$Recall = 98,30\%, \quad (34)$$

$$Precision = 100\%, \text{ e} \quad (35)$$

$$Accuracy = 99,60\%. \quad (36)$$

É pertinente ressaltar que, tanto para a componente reativa quanto para a resistiva, a classificação com a Superfície de Impedância falhou apenas apresentando um falso negativo. E, nas duas situações, o falso negativo foi para uma planta que estava no início da infecção, estando ainda no primeiro mês após a contaminação. É importante também enfatizar que, durante as 20 simulações, cujos resultados estão exibidos nas tabelas 4 e 5, todas as detecções foram realizadas com as plantas ainda no primeiro mês após a contaminação. Esse resultado é relevante, pois, como apresentado na Figura 35, a aplicação da abordagem clássica nas mesmas condições

experimentais só permitiria fazer a detecção da doença a partir do oitavo mês, ainda assim, com a incerteza se a variação na medida da bioimpedância foi devido a um agente estressor, ou a variações climáticas ou até mesmo à própria evolução natural da planta. Na Seção 6.3 é analisado a aplicação a medição baseada em Superfície de Impedância aos dados obtidos através de experimentos reais.

### **6.3 Resultados da Aplicação da Superfície de Impedância às Bases de Dados Experimentais**

Os resultados exibidos nesta seção foram todos obtidos a partir de experimentos reais, através dos arranjos experimentais descritos na Seção 5.3. Apesar da medição baseada em Superfície de Impedância utilizar apenas uma frequência e um parâmetro da bioimpedância, os dados foram coletados medindo a bioimpedância para as frequências de 1 kHz, 10 kHz, 20 kHz, 30 kHz, 40 kHz, 50 kHz, 60 kHz, 70 kHz, 80 kHz, 90 kHz e 100 kHz.

Ao longo do trabalho foram realizadas quatro baterias de experimentos, como descrito na Seção 5.3. A primeira bateria foi conduzida com o objetivo de testar e ajustar o sistema de medição e o arranjo experimental. Durante a segunda bateria, realizada já com o intuito de construir a primeira base de dados, observou-se que havia um problema no arranjo experimental que estava introduzindo muito ruído no sistema de medição. Portanto, os resultados apresentados nesta seção são baseados na terceira e na quarta bateria de experimentos. A terceira bateria de experimentos foi realizada com o arranjo ilustrado na Figura 25 e os dados foram coletados entre os dias 28 de julho de 2023 a 25 de agosto de 2023. Enquanto que a quarta bateria de experimentos foi conduzida com o arranjo ilustrado na Figura 28 e os dados foram coletados entre os dias 14 de setembro de 2023 a 17 outubro de 2023. É pertinente ressaltar que, para todos os dados coletados, o período de amostragem foi de 2 minutos.

Antes de entrar nas análises voltadas para a aplicação da classificação baseada na Superfície de Impedância, serão apresentadas algumas avaliações pertinentes ao desenvolvimento deste trabalho. Primeiro, será avaliado a sensibilidade dos parâmetros da bioimpedância ao estresse hídrico. Para isso, foi coletada uma amostra representativa da bioimpedância para a planta sadia e outra para a planta sob estresse hídrico. E, para cada parâmetro, foi calculado o valor relativo da sua variação através do quociente do valor coletado com a planta sob estresse pelo valor coletado com a planta sadia. Esse cálculo foi realizado para as 11 frequências citadas no primeiro parágrafo desta seção. Os resultados são apresentados nas figuras 47, 48, 49 e 50, para os nós 4 e 7 da terceira bateria de experimentos e para os nós 1 e 2 da quarta bateria de experimentos, respectivamente.



Figura 47 – Sensibilidade dos parâmetros para o Nó 4 da terceira bateria de experimentos.

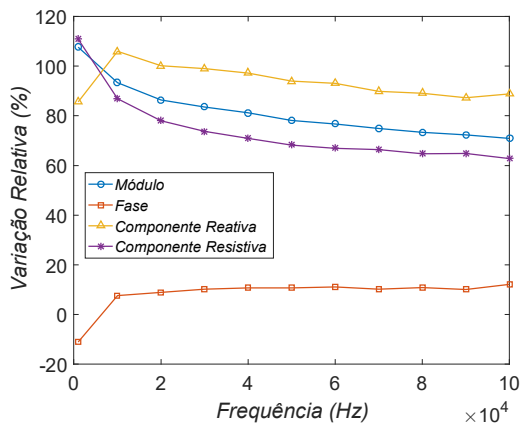



Figura 48 – Sensibilidade dos parâmetros para o Nó 7 da terceira bateria de experimentos.



Fonte: Autor.

Figura 49 – Sensibilidade dos parâmetros para o Nó 1 da quarta bateria de experimentos.


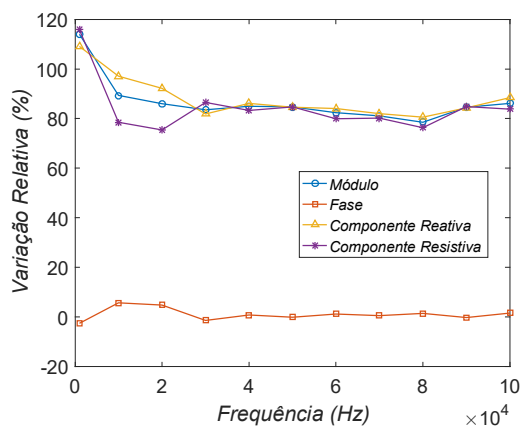


Figura 50 – Sensibilidade dos parâmetros para o Nó 2 da quarta bateria de experimentos.



Fonte: Autor.

Analisando as figuras 47, 48, 49 e 50, observa-se que, para a espécie de tomateiro utilizado, os parâmetros com maior sensibilidade são o módulo, a componente resistiva e a componente reativa. Nota-se também que, à medida em que a frequência diminui, a sensibilidade aumenta. E, para a frequência de 1 kHz, a sensibilidade desses parâmetros é bastante semelhante.

Durante a etapa de avaliação dos dados foram calculadas as correlações entre cada grandeza medida e a bioimpedância. Para esse estudo, foram utilizados os dados da quarta bateria de experimentos. A correlação, para cada grandeza, foi calculada tomando 3 nós de forma aleatória e considerando as frequências de 1 kHz e 100 kHz.

Nas tabelas 6, 7, 8 e 9 são apresentados os valores médio para a correlação de cada grandeza com os 3 nós selecionados. As correlações foram calculadas considerando o módulo, tabelas 6 e 7, e a fase, tabelas 8 e 9.

Tabela 6 – Correlação das grandezas com o módulo da bioimpedância para a frequência de 1 kHz. Para cada variável, a tabela contém o valor médio da correlação calculada para 3 nós escolhido aleatoriamente.

Grandeza Correlacionada com o Módulo	Média do Coeficiente de Correlação	Desvio Padrão
<i>Temperatura do Solo</i>	-0,208	0,069
<i>Temperatura Ambiente</i>	-0,278	0,133
<i>Umidade Relativa do Ar</i>	-0,445	0,186

Tabela 7 – Correlação das grandezas com o módulo da bioimpedância para a frequência de 100 kHz. Para cada variável, a tabela contém o valor médio da correlação calculada para 3 nós escolhido aleatoriamente.

Grandeza Correlacionada com o Módulo	Média do Coeficiente de Correlação	Desvio Padrão
<i>Temperatura do Solo</i>	-0,388	0,019
<i>Temperatura Ambiente</i>	-0,302	0,147
<i>Umidade Relativa do Ar</i>	-0,216	0,252

Tabela 8 – Correlação das grandezas com a fase da bioimpedância para a frequência de 1 kHz. Para cada variável, a tabela contém o valor médio da correlação calculada para 3 nós escolhido aleatoriamente.

Grandeza Correlacionada com a Fase	Média do Coeficiente de Correlação	Desvio Padrão
<i>Temperatura do Solo</i>	-0,079	0,184
<i>Temperatura Ambiente</i>	0,144	0,134
<i>Umidade Relativa do Ar</i>	0,447	0,268

Tabela 9 – Correlação das grandezas com a fase da bioimpedância para a frequência de 100 kHz. Para cada variável, a tabela contém o valor médio da correlação calculada para 3 nós escolhido aleatoriamente.

Grandeza Correlacionada com a Fase	Média do Coeficiente de Correlação	Desvio Padrão
<i>Temperatura do Solo</i>	-0,182	0,06
<i>Temperatura Ambiente</i>	-0,125	0,123
<i>Umidade Relativa do Ar</i>	0,285	0,235

Considerando os dados apresentados nas tabelas 6, 7, 8 e 9, nota-se que, independentemente da frequência aplicada, a bioimpedância tem uma correlação fraca com as três variáveis estudadas: temperatura do solo, temperatura ambiente e umidade relativa do ar. Essa é uma característica importante e que deve ser considerada ao se trabalhar com a bioimpedância, pois isso dificulta a construção de modelos que considerem a influência dessas grandezas.

Outra característica importante, e negligenciada pelos trabalhos que vem sendo publicados, é o tempo de cicatrização que leva após a inserção dos eletrodos. Nas

quatro baterias experimentais, realizadas ao longo deste trabalho, observou-se que ao penetrar os eletrodos no caule das plantas, a impedância assume valores consideravelmente maiores que o normal e só estabiliza entre 2 ou 3 dias após a penetração.

Existe ainda uma peculiaridade importante relacionada à medição de bioimpedância, que é a interação entre os eletrodos e o tecido da planta. Devido a pequenas diferenças nas posições dos eletrodos em relação à fixação no caule, como também a variações nas dimensões e estrutura do caule, como explanado no final da Seção 3.4, as medições são influenciadas e podem sofrer variações para diferentes plantas. A abordagem clássica utiliza os índices de impedância para reduzir esse efeito, como descrito na Subseção 3.4.1. Porém, a utilização desses índices reduz a sensibilidade para a detecção. Aplicando os índices nos dados coletados neste trabalho, essa redução chegou a ultrapassar os 80% quando comparado à sensibilidade sem a utilização do índice.

Como alternativa à utilização dos índices, este trabalho empregou uma forma de retirar o valor médio do sinal medido utilizando a média de dois dias seguidos após o período de cicatrização. Assim, a medição considerada para cada nó é dada por

$$Z'_n(i) = Z_n(i) - M_{Z_n}, \quad (37)$$

sendo  $Z'_n(i)$  a medição considerada para o Nó  $n$  no instante  $i$ ,  $Z_n(i)$  a bioimpedância medida no Nó  $n$  no instante  $i$  e  $M_{Z_n}$  o valor médio do sinal para o Nó  $n$  considerando dois dias de medição após o período de cicatrização. Dessa forma, a sensibilidade dos dados não é alterada, conservando as características da bioimpedância medida. Na Subseção 6.3.1 são apresentadas as análises da aplicação da medição baseada em Superfície de Impedância.

### **6.3.1 Aplicação da Medição Baseada em Superfície de Impedância aos Dados Experimentais**

Nesta subseção, a abordagem proposta é aplicada aos dados reais. Como descrito no Capítulo 4, a medição baseada em Superfície de Impedância utilizada apenas um parâmetro da bioimpedância e uma única frequência. Com base nas figuras 47, 48, 49 e 50, a frequência que proporciona maior sensibilidade é 1 kHz e, para essa frequência, a sensibilidade do módulo, da componente reativa e da componente resistiva são semelhantes. Assim, por conveniência, o parâmetro utilizado para as análises seguintes é o módulo, visto que os dados estão originalmente em coordenadas polares.

A primeira característica a ser analisada é a estabilidade do plano que representa a Superfície de Impedância. Como já discutido na Seção 4.2 e na Subseção 6.2.3, a forma em que esse plano é construído entre os nós sensores gera uma instabilidade nos

primeiros ciclos do algoritmo de classificação. Nas figuras 51 e 52 são apresentados as medições, pontos azuis, e o plano que representa a Superfície de Impedância. Na Figura 51 é exibido o plano atual do Nó 3 e na Figura 52 o plano atual do Nó 7, ambos tomados no primeiro ciclo do algoritmo de classificação. É possível observar nas figuras 51 e 52 que existe uma grande diferença nos planos dos respectivos nós, indicando a instabilidade no início da classificação, característica intrínseca à classificação com a Superfície de Impedância. Nota-se também que os planos não representam bem os dados, devido ao ajuste pelo método dos Mínimos Quadrados Recursivo. Na Subseção 6.2.3 também são observadas essas características.

Figura 51 – Representação do plano do Nó 3 e da nuvem de dados para o instante inicial da classificação. Os pontos azuis representam plantas saudáveis classificadas como saudáveis.





Figura 52 – Representação do plano do Nó 7 e da nuvem de dados para o instante inicial da classificação. Os pontos azuis representam plantas saudáveis classificadas como saudáveis.



Fonte: Autor.

O período de estabilização adotado para a classificação dos dados reais foi de 20 ciclos. A escolha desse período foi realizada empiricamente, como descrito na Subseção 6.2.3. Os dados exibidos nas figuras 53 e 54 são semelhantes aos apresentados nas figuras 51 e 52, a diferença está no ciclo em que eles foram tomados. Os planos apresentados nas figuras 53 e 54, que são os planos atuais dos Nós 7 e 10, respectivamente, foram tomados no primeiro ciclo após o período de estabilização. Observando esses planos, nota-se que eles são quase idênticos, indicando que os planos dos nós convergiram para o plano que representa a Superfície de Impedância. Observa-se também que, após o período de estabilização, os planos representam bem os dados. É importante ressaltar que os 20 ciclos do período de estabilização são realizados antes da aplicação do estresse hídrico.

Observa-se na Figura 55 que a planta do Nó 7 está sob estresse e ainda não foi classificada como doente. Já na Figura 56 a planta do Nó 7 aparece classificada como doente, a classificação foi dada 5h após o início do estresse. Na Figura 57 é possível observar o efeito do agravamento do estresse na planta do Nó 7. Nota-se que, à

Figura 53 – Representação do plano do Nó 7 e da nuvem de dados para o primeiro ciclo após o período de estabilização.





Figura 54 – Representação do plano do Nó 10 e da nuvem de dados para o primeiro ciclo após o período de estabilização.



Fonte: Autor.

medida em que o estresse vai se agravando, a bioimpedância medida na planta vai se afastando do plano. Vale ressaltar também que, como a Superfície de Impedância não considera as medições realizadas em plantas classificadas como doentes, ela se mantém representando bem as medições das plantas saudáveis. Isso também pode ser observado na Figura 57.

Figura 55 – Representação da Superfície de Impedância e dos dados. Planta do Nó 7 está sob estresse mas ainda não foi classificada como doente ('x' preto).






Figura 56 – Representação da Superfície de Impedância e dos dados. Planta do Nó 7 classificada corretamente como doente (asterisco verde).



Fonte: Autor.

Para evitar a repetição de gráficos contendo as mesmas informações, nesta subseção, as análises realizadas até aqui foram baseadas apenas nos dados da terceira bateria experimental. Porém, para as análises estatísticas apresentadas a seguir, são utilizados os dados da terceira e da quarta baterias de experimentos. As métricas estatísticas utilizadas são *Recall*, *Precision* e *Accuracy*, definidas na Subseção 6.2.3.

Figura 57 – Representa a Superfície de Impedância e a nuvem de dados após agravamento do estresse. O asterisco verde representa planta doente classificada como doente.



Fonte: Autor.

Essas são as métricas comumente utilizadas em trabalhos que envolvem classificação. Nas tabelas 10 e 11 estão exibidos os resultados para a terceira e a quarta baterias de experimentos, respectivamente.

Nos resultados contidos nas tabelas 10 e 11, estão exibidos dados para 10 rodadas seguidas da classificação baseada em Superfície de Impedância para a terceira e quarta baterias de experimentos, respectivamente. Observa-se nos gráficos exibidos na Figura 16 que a bioimpedância das plantas apresentam um padrão cíclico de 24 horas. Com isso, os planos dos nós, que representam a Superfície de Impedância para a classificação, vão se ajustar ao longo do tempo. Isso pode causar uma instabilidade na classificação, caso o fator de esquecimento do MQR e o limiar de classificação não sejam ajustados adequadamente. Por essa razão, é importante analisar as 10 rodadas seguidas da classificação para cada bateria de experimento.

Tabela 10 – Dados estatísticos para a classificação baseada em Superfície de Impedância na terceira bateria experimental.

Sequência de Simulações	<i>TP</i>	<i>TN</i>	<i>FP</i>	<i>FN</i>
1	4	6	0	0
2	3	5	2	0
3	4	6	0	0
4	4	6	0	0
5	4	6	0	0
6	4	6	0	0
7	4	6	0	0
8	4	6	0	0
9	4	6	0	0
10	4	6	0	0

Para os dados apresentados na Tabela 10, a classificação foi realizada aplicando um limiar igual a 9800. Os detalhes sobre a base de dados utilizada e como as plantas

foram estressadas estão apresentados na Seção 5.3. Os valores para as métricas estatísticas foram:


$$Recall = 100\%, \quad (38)$$

$$Precision = 95,12\%, \text{ e} \quad (39)$$

$$Accuracy = 98,00\%. \quad (40)$$

Na Figura 58 está ilustrado o valor normalizado da bioimpedância para cada nó. Para facilitar a visualização do momento exato da classificação, no instante em que cada nó é classificado como doente, a curva no gráfico muda para a cor vermelha. Observa-se que, a escolha de um limiar relativamente grande implica em um atraso na detecção do estresse. A escolha de um limiar grande é devido a alguns fatores. Os principais são: a pequena quantidade de nós sensores que faz com que a Superfície de Impedância seja muito sensível a variações que ocorram em um único nó ou em poucos nós; a diferença entre os níveis de bioimpedância medidos em plantas diferentes, devido à interação entre os eletrodos e o tecido das plantas; e os erros de medição. Todas essas variáveis introduzem oscilações significativas nos padrões de bioimpedância medido, exigindo a escolha de um limiar grande para evitar falsos positivos.

Figura 58 – Gráfico com os valores da bioimpedância normalizada para os 10 nós da terceira bateria de experimentos. No instante em que o nó é classificado como doente a curva no gráfico muda para a cor vermelha.



Fonte: Autor.

Para os dados apresentados na Tabela 11, a classificação foi realizada utilizando

Tabela 11 – Dados estatísticos para a classificação baseada em Superfície de Impedância na quarta bateria experimental.

Sequência de Simulações	<i>TP</i>	<i>TN</i>	<i>FP</i>	<i>FN</i>
1	3	7	0	0
2	3	7	0	0
3	3	7	0	0
4	3	7	0	0
5	3	7	0	0
6	3	7	0	0
7	2	7	1	0
8	3	7	0	0
9	3	7	0	0
10	3	7	0	0

um limiar igual a 15000. Os detalhes da base de dados utilizada estão descritos na Seção 5.3. No qual, 6 das 10 plantas foram estressadas em momentos distintos. No entanto, para os dados apresentados na Tabela 11, a classificação foi efetuada levando em consideração o estresse até a terceira planta, seguindo a sequência apresentada na Seção 5.3. A classificação foi realizada dessa forma devido à pouca quantidade de nós sensores. Pois, à medida em que as plantas vão sendo classificadas como doentes, a Superfície de Impedância vai sendo formada com dados apenas das plantas saudáveis e, devido à quantidade limitada de nós, ela passa a não representar bem todas as regiões.

Os valores calculados para as métricas estatísticas, com base na Tabela 11, foram:

$$Recall = 96,66\%, \quad (41)$$

$$Precision = 96,66\%, \text{ e} \quad (42)$$


$$Accuracy = 98,00\%. \quad (43)$$

Na Figura 59 são apresentados os valores normalizados da bioimpedância para todos os nós. Para facilitar a visualização, no momento em que uma planta é classificada como doente, a sua respectiva curva de medição é alterada para a cor vermelha. Nota-se que, a escolha de um limiar relativamente grande resulta em um atraso na detecção do estresse. Os fatores que influenciam nessa escolha são os mesmos explicados nas análises da Figura 58.

É importante destacar que a abordagem proposta não permite uma comparação direta com os estudos que utilizam a bioimpedância para a detecção de doenças em plantas, por dois motivos. O primeiro é que os estudos com a abordagem clássica visam detectar uma determinada doença ou níveis de estresse em uma planta, enquanto a medição com a Superfície de Impedância busca identificar regiões do



Figura 59 – Gráfico com os valores da bioimpedância normalizada para os 10 nós da quarta bateria de experimentos. No instante em que o nó é classificado como doente a curva no gráfico muda para a cor vermelha.



Fonte: Autor.

cultivo sob a ação de algum tipo de estresse. O segundo motivo é que a maioria dos estudos com a abordagem clássica analisam a relação entre a bioimpedância e os níveis de um determinado estresse sem realizar classificações, enquanto a Superfície de Impedância tem o objetivo de classificar regiões sob a ação de algum agente estressor.

As formas mais comuns para avaliar os resultados nos trabalhos que utilizam bioimpedância são o índice de determinação ( $R^2$ ), que geralmente varia entre 85% e 98% (MEIQING *et al.*, 2016, 2017; TANG *et al.*, 2023), e a análise visual de gráficos (BORGES *et al.*, 2014; BAR-ON; SHACHAM-DIAMAND, 2021). Os resultados apresentados por esses trabalhos são promissores. No entanto, é importante ressaltar que eles foram obtidos em condições controladas.

Existem estudos, envolvendo outros tipos de tecnologia (*e.g.*: imagens RGB, multi e hiperespectrais), que empregam a classificação utilizando as métricas aplicadas neste trabalho. Os valores alcançados para *Recall*, *Precision* e *Accuracy* estão entre 85% a 99%, 86% a 98%, e 86% a 99%, respectivamente (ALGHAMDI; TURKI, 2023; GOEL; NAGPAL, 2023; KUMAR *et al.*, 2023). Os valores obtidos nesta tese estão próximos aos dos trabalhos citados. No entanto, ainda não se trata de uma comparação direta, pois os trabalhos citados classificam doenças ou estresses em plantas individuais, enquanto a classificação com a Superfície de Impedância detecta regiões do cultivo sob a ação de agentes estressores.

## 7 CONCLUSÕES E TRABALHOS FUTUROS

Nesta tese, é apresentada uma nova abordagem (Superfície de Impedância) para a medição de parâmetros em situações cujas informações espaciais são importantes, como em uma plantação. A Superfície de Impedância é aplicada neste trabalho com o principal objetivo de viabilizar a detecção de doenças e estresses por meio da medição da bioimpedância das plantas, sem a necessidade de controlar as variáveis ambientais. Isso se diferencia da abordagem clássica, que demanda o controle dessas variáveis.

Durante o desenvolvimento do trabalho foram observados alguns resultados relevantes. Observou-se que utilizando apenas uma frequência e um parâmetro da bioimpedância é possível fazer a detecção de doenças e estresses nas plantas. Esse resultado é importante porque a abordagem clássica visa coletar a maior quantidade de dados possível, sendo que aumentar a quantidade de dados não significa aumentar a quantidade de informação. Outra conclusão importante é que, para as condições em que os dados reais foram coletados, a bioimpedância tem fraca correlação com a temperatura do solo, com a temperatura ambiente e com a umidade relativa do ar. Também foi observado nos resultados que, para diferentes tipos de cultivos, a sensibilidade dos parâmetros da bioimpedância pode mudar significativamente.

A classificação com a Superfície de Impedância foi empregada em três bases de dados. A primeira foi gerada a partir de simulações, como descrito na Seção 5.2, a segunda e a terceira através da condução de experimentos reais, como descrito na Seção 5.3. As métricas estatísticas analisadas foram *Recall*, *Precisão* e *Acurácia*. Para os resultados com a primeira base de dados os valores dessas métricas foram 98,52%, 100,00% e 99,60%, respectivamente. Para a segunda base de dados os valores foram 100,00%, 95,12% e 98,00%, respectivamente. E para a terceira os valores foram 96,66%, 96,66% e 98,00%, respectivamente.

É importante ressaltar que a classificação utilizando a Superfície de Impedância possibilitou a detecção do estresse sem a necessidade de controlar as variáveis ambientais. Esse resultado era esperado, uma vez que a Superfície de Impedância permite uma comparação indireta da medição realizada na planta com aquelas fei-

tas em plantas de regiões vizinhas. Isso cria um efeito de autocompensação para as oscilações nas variáveis ambientais, viabilizando a detecção em ambientes não controlados.

Embora as detecções tenham ocorrido na fase inicial do estresse, os resultados obtidos com a segunda e terceira bases de dados permitiram observar que, devido à quantidade reduzida de nós sensores e a outros fatores mencionados na Subseção 6.3.1, o limiar de classificação utilizado foi grande. Isso resultou em um atraso na detecção do estresse.

Para trabalhos que possam decorrer desta tese indica-se a condução de experimentos e análises com o objetivo de mitigar a influência dos fatores que contribuem para o aumento do limiar (*e.g.*: ruídos, fixação dos eletrodos e aumento da quantidade de nós sensores), visando assim reduzir o tempo de detecção dos estresses. Além disso, recomenda-se o desenvolvimento de estudos voltados à produção de um circuito integrado (CI) que desempenhe a função completa do nó sensor.

## REFERÊNCIAS

- ABDELGHAFOR, F. *et al.* Including measurement effects and temporal variations in VIS-NIRS models to improve early detection of plant disease: application to alternaria solani in potatoes. **Computers and Electronics in Agriculture**, [S.l.], v.211, p. 107947, 2023.
- AGRIOS, G. N. **Plant pathology**. [S.l.]: Elsevier, 2005.
- AGUIRRE, L. A. **Introdução à identificação de sistemas—Técnicas lineares e não-lineares aplicadas a sistemas reais**. [S.l.]: Editora UFMG, 2004.
- AHMAD, A.; SARASWAT, D.; EL GAMAL, A. A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools. **Smart Agricultural Technology**, [S.l.], v.3, p. 100083, 2023.
- AL-ALI, A. A. A. **Design and Implementation of a Magnitude Only Bio-Impedance Analyzer**. — Dissertação (Mestrado em engenharia elétrica e computação) - Univ. Calgary, Calgary, AB, Canada, 2018.
- AL-ALI, A. A.; MAUNDY, B. J.; ELWAKIL, A. S. **Design and implementation of portable impedance analyzers**. [S.l.]: Springer, 2019.
- ALEJNIKOV, A.; CHESHKOVA, A.; MINEEV, V. Choice of impedance parameter of strawberry tissue for detection of fungal diseases. In: IOP CONFERENCE SERIES: EARTH AND ENVIRONMENTAL SCIENCE, 2020. **Proceedings...** [S.l.: s.n.], 2020. v.548, n.3, p. 032005.
- ALGHAMDI, H.; TURKI, T. PDD-Net: plant disease diagnoses using multilevel and multiscale convolutional neural network features. **Agriculture**, [S.l.], v.13, n.5, p. 1072, 2023.
- ALI, M. M. *et al.* Non-destructive techniques of detecting plant diseases: a review. **Physiological and Molecular Plant Pathology**, [S.l.], v.108, p. 101426, 2019.

- ALVES, M. C. *et al.* Geoestatística como metodologia para estudar a dinâmica espaço-temporal de doenças associadas a *Colletotrichum* spp. transmitidos por sementes. **Fitopatologia Brasileira**, [S.l.], v.31, p. 557–563, 2006.
- AMORIM, L. **Manual de Fitopatologia, vol. 1: princípios e conceitos**. [S.l.]: São, 2018.
- ANDO, Y.; MIZUTANI, K.; WAKATSUKI, N. Electrical impedance analysis of potato tissues during drying. **Journal of Food Engineering**, [S.l.], v.121, p. 24–31, 2014.
- BALBINOT, A.; BRUSAMARELLO, V. J. **Instrumentação e fundamentos de medidas–vol. 1**. [S.l.]: Livros Técnico E Científicos Editora, 2019.
- BAR-ON, L.; JOG, A.; SHACHAM-DIAMAND, Y. Four point probe electrical spectroscopy based system for plant monitoring. In: IEEE INTERNATIONAL SYMPOSIUM ON CIRCUITS AND SYSTEMS (ISCAS), 2019., 2019. **Proceedings...** [S.l.: s.n.], 2019. p. 1–5.
- BAR-ON, L.; SHACHAM-DIAMAND, Y. On the interpretation of four point impedance spectroscopy of plant dehydration monitoring. **IEEE Journal on Emerging and Selected Topics in Circuits and Systems**, [S.l.], v.11, n.3, p. 482–492, 2021.
- BAR-ON, L. *et al.* Electrical modelling of in-vivo impedance spectroscopy of nicotiana tabacum plants. **Frontiers in Electronics**, [S.l.], v.2, p. 753145, 2021.
- BASAK, R.; WAHID, K. A. A rapid, low-cost, and high-precision multifrequency electrical impedance tomography data acquisition system for plant phenotyping. **Remote Sensing**, [S.l.], v.14, n.13, p. 3214, 2022.
- BERDUGO, C. *et al.* Fusion of sensor data for the detection and differentiation of plant diseases in cucumber. **Plant Pathology**, [S.l.], v.63, n.6, p. 1344–1356, 2014.
- BERGAMIN FILHO, A.; KIMATI, H.; AMORIM, L. **Manual de fitopatologia: princípios e conceitos**. [S.l.]: Editora Agronômica Seres, 1995.
- BOCK, C. H. *et al.* From visual estimates to fully automated sensor-based measurements of plant disease severity: status and challenges for improving accuracy. **Phytopathology Research**, [S.l.], v.2, n.1, p. 1–30, 2020.
- BOCK, C. *et al.* Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. **Critical Reviews in Plant Sciences**, [S.l.], v.29, n.2, p. 59–107, 2010.

BORGES, E. *et al.* Bioimpedance Parameters as Indicators of the Physiological States of Plants in situ. **International Journal on Advances in Life Sciences**, [S.l.], v.6, p. 74–86, 2014.

BORGES, E. *et al.* Early detection and monitoring of plant diseases by Bioelectric Impedance Spectroscopy. In: IEEE 2ND PORTUGUESE MEETING IN BIOENGINEERING (ENBENG), 2012., 2012. **Proceedings...** [S.l.: s.n.], 2012. p. 1–4.

BRAVO, C. *et al.* Early disease detection in wheat fields using spectral reflectance. **Biosystems Engineering**, [S.l.], v.84, n.2, p. 137–145, 2003.

BROWN, D.; POOLE, L. Enhanced plant species and early water stress detection using visible and near-infrared spectra. In: COMPUTATIONAL VISION AND BIO-INSPIRED COMPUTING: PROCEEDINGS OF ICCVBIC 2022, 2023. **Proceedings...** [S.l.: s.n.], 2023. p. 765–779.

BUJA, I. *et al.* Advances in plant disease detection and monitoring: from traditional assays to in-field diagnostics. **Sensors**, [S.l.], v.21, n.6, p. 2129, 2021.

CARANGELO, A. *et al.* Application of EIS to in situ characterization of hydrothermal sealing of anodized aluminum alloys: comparison between hexavalent chromium-based sealing, hot water sealing and cerium-based sealing. **Journal of the Electrochemical Society**, [S.l.], v.163, n.10, p. C619, 2016.

CARVALHO, S. *et al.* Plant Health Evaluation Based on Bioimpedance Phase Measurement. In: INTERNATIONAL SYMPOSIUM ON INSTRUMENTATION SYSTEMS, CIRCUITS AND TRANSDUCERS (INSCIT), 2022., 2022. **Proceedings...** [S.l.: s.n.], 2022. p. 1–5.

CETÓ, X. *et al.* Towards the rapid detection of haze-forming proteins. **Talanta**, [S.l.], v.268, p. 125305, 2024.

CHAKRABORTY, S. *et al.* On-chip estimation of hematocrit level for diagnosing anemic conditions by Impedimetric techniques. **Biomedical Microdevices**, [S.l.], v.22, p. 1–11, 2020.

COLE, K. S. Electric impedance of suspensions of spheres. **The Journal of general physiology**, [S.l.], v.12, n.1, p. 29–36, 1928.

COLE, K. S. Electric phase angle of cell membranes. **The Journal of general physiology**, [S.l.], v.15, n.6, p. 641, 1932.

COLE, K. S.; COLE, R. H. Dispersion and absorption in dielectrics I. Alternating current characteristics. **The Journal of chemical physics**, [S.l.], v.9, n.4, p. 341–351, 1941.

CORDEIRO, T. A. *et al.* Label-free electrochemical impedance immunosensor based on modified screen-printed gold electrodes for the diagnosis of canine visceral leishmaniasis. **Talanta**, [S.l.], v.195, p. 327–332, 2019.

CUI, S. *et al.* Development of Fast E-nose System for Early-Stage Diagnosis of Aphid-Stressed Tomato Plants. **Sensors**, [S.l.], v.19, n.16, p. 3480, 2019.

CUI, S. *et al.* Plant pest detection using an artificial nose system: a review. **Sensors**, [S.l.], v.18, n.2, p. 378, 2018.

DAHLMANN, S. *et al.* Hardware Setup for Tetrapolar Bioimpedance Spectroscopy in Bandages. In: INTERNATIONAL CONFERENCE ON ELECTRICAL BIOIMPEDANCE, 2019. **Proceedings...** [S.l.: s.n.], 2019. p. 18–24.

DEANGELIS, D. L.; GRIMM, V. Individual-based models in ecology after four decades. **F1000prime reports**, [S.l.], v.6, 2014.

DEGANI, O.; BECHER, P.; GORDANI, A. Real-time PCR early detection of *Trichoderma* treatments efficiency against cotton charcoal rot disease. **Journal of Natural Pesticide Research**, [S.l.], v.4, p. 100027, 2023.

DEVICES, A. **1 MSPS, 12-Bit Impedance Converter, Network Analyzer**.

Disponível em:

<https://www.analog.com/en/products/ad5933.html#part-details>. Acesso em: 11 de set. de 2024.

DEVICES, A. **250 kSPS, 12-Bit Impedance Converter, Network Analyzer**.

Disponível em: <https://www.analog.com/media/en/technical-documentation/data-sheets/AD5934.pdf>. Acesso em: 11 de set. de 2024.

DOMINGUES, T.; BRANDÃO, T.; FERREIRA, J. C. Machine learning for detection and prediction of crop diseases and pests: a comprehensive survey. **Agriculture**, [S.l.], v.12, n.9, p. 1350, 2022.

DREADEN, T. J. *et al.* Development of multilocus PCR assays for *Raffaelea lauricola*, causal agent of laurel wilt disease. **Plant Disease**, [S.l.], v.98, n.3, p. 379–383, 2014.

EL KHALED, D. *et al.* Cleaner quality control system using bioimpedance methods: a review for fruits and vegetables. **Journal of Cleaner Production**, [S.l.], v.140, p. 1749–1762, 2017.

- FARBER, C. *et al.* Advanced spectroscopic techniques for plant disease diagnostics. A review. **TrAC Trends in Analytical Chemistry**, [S.l.], v.118, p. 43–49, 2019.
- FELDENS, F. **O Homem a Agricultura a História**. [S.l.]: 1<sup>a</sup> edição. Lajeado/RS. Editora, 2018.
- FRICKE, H. The electric conductivity and capacity of disperse systems. **Physics**, [S.l.], v.1, n.2, p. 106–115, 1931.
- GANIVET, E. Growth in human population and consumption both need to be addressed to reach an ecologically sustainable future. **Environment, Development and Sustainability**, [S.l.], v.22, n.6, p. 4979–4998, 2020.
- GAO, P. *et al.* Exploring detailed urban-rural development under intersecting population growth and food production scenarios: trajectories for china's most populous agricultural province to 2030. **Journal of Geographical Sciences**, [S.l.], v.33, n.2, p. 222–244, 2023.
- GOEL, L.; NAGPAL, J. A systematic review of recent machine learning techniques for plant disease identification and classification. **IETE Technical Review**, [S.l.], v.40, n.3, p. 423–439, 2023.
- GOLD, K. M. *et al.* Hyperspectral measurements enable pre-symptomatic detection and differentiation of contrasting physiological effects of late blight and early blight in potato. **Remote Sensing**, [S.l.], v.12, n.2, p. 286, 2020.
- GONÇALVES, R. C. Biologia Molecular Aplicada à Diagnose de Doenças de Plantas. In: GONÇALVES R. C.; OLIVEIRA, L. C. (Ed.). **Ciência e Tecnologia para o Desenvolvimento Sustentável do Sudoeste da Amazônia**. 1<sup>a</sup>.ed. [S.l.]: Rio Branco, AC: Embrapa Acre, 2009. Cap. 16. p. 317–338.
- GROSSI, M.; RICCÒ, B. Electrical impedance spectroscopy (EIS) for biological analysis and food characterization: a review. **Journal of sensors and sensor systems**, [S.l.], v.6, n.2, p. 303–325, 2017.
- GUERMAZI, M.; KANOUN, O.; DERBEL, N. Investigation of long time beef and veal meat behavior by bioimpedance spectroscopy for meat monitoring. **IEEE Sensors Journal**, [S.l.], v.14, n.10, p. 3624–3630, 2014.
- HALLAU, L. *et al.* Automated identification of sugar beet diseases using smartphones. **Plant pathology**, [S.l.], v.67, n.2, p. 399–410, 2018.



- HAMED, K. B.; ZORRIG, W.; HAMZAOU, A. H. Electrical impedance spectroscopy: a tool to investigate the responses of one halophyte to different growth and stress conditions. **Computers and Electronics in Agriculture**, [S.l.], v.123, p. 376–383, 2016.
- HARTATI, L. *et al.* Detection of virus causes papaya ringspot virus-with the DAS-Elisa (Double Antibody Sandwich-Enzyme-Linked Immunosorbent Assay) method at different levels in North Sumatra. In: IOP CONFERENCE SERIES: EARTH AND ENVIRONMENTAL SCIENCE, 2020. **Proceedings...** [S.l.: s.n.], 2020. v.454, n.1, p. 012182.
- HAYASHI, T. *et al.* Impedance measuring technique for identifying irradiated potatoes. **Bioscience, biotechnology, and biochemistry**, [S.l.], v.56, n.12, p. 1929–1932, 1992.
- HAYDEN, R. *et al.* Electrical impedance studies on potato and alfalfa tissue. **Journal of Experimental Botany**, [S.l.], v.20, n.2, p. 177–200, 1969.
- HAZARIKA, S. *et al.* Detection of Citrus Tristeza Virus in Mandarin Orange Using a Customdeveloped Electronic Nose System. **IEEE Transactions on Instrumentation and Measurement**, [S.l.], 2020.
- HEIM, R. H. *et al.* Multispectral, aerial disease detection for myrtle rust (*Austropuccinia psidii*) on a lemon myrtle plantation. **Drones**, [S.l.], v.3, n.1, p. 25, 2019.
- HORSFALL, J. G. **Plant disease: an advanced treatise: how plants suffer from disease**. [S.l.]: Elsevier, 2012.
- HUANG, S. *et al.* In-season diagnosis of rice nitrogen status using proximal fluorescence canopy sensor at different growth stages. **Remote Sensing**, [S.l.], v.11, n.16, p. 1847, 2019.
- HUH, S. *et al.* Utilization of electrical impedance spectroscopy and image classification for non-invasive early assessment of meat freshness. **Sensors**, [S.l.], v.21, n.3, p. 1001, 2021.
- IBBA, P. *et al.* Fruitmeter: an ad5933-based portable impedance analyzer for fruit quality characterization. In: IEEE INTERNATIONAL SYMPOSIUM ON CIRCUITS AND SYSTEMS (ISCAS), 2020., 2020. **Proceedings...** [S.l.: s.n.], 2020. p. 1–5.
- IBBA, P. *et al.* Low-cost bio-impedance analysis system for the evaluation of fruit ripeness. In: IEEE SENSORS, 2018., 2018. **Proceedings...** [S.l.: s.n.], 2018. p. 1–4.

- INSTRUMENTS, T. **AFE4300 Low-Cost, Integrated Analog Front-End for Weight-Scale and Body Composition Measurement**. Disponível em: <https://e2e.ti.com/support/data-converters-group/data-converters/f/data-converters-forum/411253/afe-4300>. Acesso em: 11 de set. de 2024.
- IVORRA CANO, A. **Contributions to the measurement of electrical impedance for living tissue ischemia injury monitoring**. — Tese (Doutorado em engenharia eletrônica) - Universitat Politècnica de Catalunya, Barcelona, 2005.
- JINYANG, L. *et al.* Diagnosis of potassium nutrition level in *Solanum lycopersicum* based on electrical impedance. **Biosystems Engineering**, [S.l.], v.147, p. 130–138, 2016.
- JUNG, J. M. *et al.* Emerging minimally invasive technologies for the detection of skin cancer. **Journal of Personalized Medicine**, [S.l.], v.11, n.10, p. 951, 2021.
- KERKECH, M.; HAFIANE, A.; CANALS, R. Vine disease detection in UAV multispectral images using optimized image registration and deep learning segmentation approach. **Computers and Electronics in Agriculture**, [S.l.], v.174, p. 105446, 2020.
- KOBORI, Y.; TAKASU, F.; OHTO, Y. Development of an individual-based simulation model for the spread of citrus greening disease by the vector insect *diaphorina citri*. **Zoology, Intech**, [S.l.], v.46, p. 87–102, 2012.
- KOBORI, Y. *et al.* Dispersal of adult Asian citrus psyllid, *Diaphorina citri* Kuwayama (Homoptera: psyllidae), the vector of citrus greening disease, in artificial release experiments. **Applied Entomology and Zoology**, [S.l.], v.46, p. 27–30, 2011.
- KULABHUSAN, P. K.; TRIPATHI, A.; KANT, K. Gold nanoparticles and plant pathogens: an overview and prospective for biosensing in forestry. **Sensors**, [S.l.], v.22, n.3, p. 1259, 2022.
- KUMAR, Y. *et al.* A systematic review of different categories of plant disease detection using deep learning-based approaches. **Archives of Computational Methods in Engineering**, [S.l.], v.30, n.8, p. 4757–4779, 2023.
- KYLE, U. G. *et al.* Bioelectrical impedance analysis—part I: review of principles and methods. **Clinical nutrition**, [S.l.], v.23, n.5, p. 1226–1243, 2004.
- LAN, J. *et al.* Simultaneous detection of carbofuran and 3-hydroxy-carbofuran in vegetables and fruits by broad-specific monoclonal antibody-based ELISA. **Food and Agricultural Immunology**, [S.l.], v.30, n.1, p. 1085–1096, 2019.

- LEI, R. *et al.* Rapid detection of the pathogenic fungi causing blackleg of Brassica napus using a portable real-time fluorescence detector. **Food chemistry**, [S.l.], v.288, p. 57–67, 2019.
- LOPES, A. M. *et al.* Milk characterization using electrical impedance spectroscopy and fractional models. **Food analytical methods**, [S.l.], v.11, n.3, p. 901–912, 2018.
- MAHLEIN, A.-K. Plant disease detection by imaging sensors—parallels and specific demands for precision agriculture and plant phenotyping. **Plant disease**, [S.l.], v.100, n.2, p. 241–251, 2016.
- MAHLEIN, A.-K. *et al.* Comparison and combination of thermal, fluorescence, and hyperspectral imaging for monitoring fusarium head blight of wheat on spikelet scale. **Sensors**, [S.l.], v.19, n.10, p. 2281, 2019.
- MANOLAKIS, D. *et al.* Hyperspectral image processing for automatic target detection applications. **Lincoln laboratory journal**, [S.l.], v.14, n.1, p. 79–116, 2003.
- MARCOS, H. M. C. **Low-Power Electrical Impedance Spectroscopy device to assess plants physiological state based on LoRaWAN wireless networks**. 2019. — Universidade de Coimbra.
- MASTRODIMOS, N. *et al.* Development of thermography methodology for early diagnosis of fungal infection in table grapes: the case of aspergillus carbonarius. **Computers and Electronics in Agriculture**, [S.l.], v.165, p. 104972, 2019.
- MCADAMS, E.; JOSSINET, J. Problems in equivalent circuit modelling of the electrical properties of biological tissues. **Bioelectrochemistry and bioenergetics**, [S.l.], v.40, n.2, p. 147–152, 1996.
- MEIQING, L. *et al.* Diagnosis and detection of phosphorus nutrition level for Solanum lycopersicum based on electrical impedance spectroscopy. **Biosystems Engineering**, [S.l.], v.143, p. 108–118, 2016.
- MEIQING, L. *et al.* Early diagnosis and monitoring of nitrogen nutrition stress in tomato leaves using electrical impedance spectroscopy. **International Journal of Agricultural and Biological Engineering**, [S.l.], v.10, n.3, p. 194–205, 2017.
- MORELLOS, A. *et al.* Non-Destructive Early Detection and Quantitative Severity Stage Classification of Tomato Chlorosis Virus (ToCV) Infection in Young Tomato Plants Using Vis–NIR Spectroscopy. **Remote Sensing**, [S.l.], v.12, n.12, p. 1920, 2020.

- NEPOMUCENO, E. G. **Dinâmica, Modelagem e controle de epidemias**. — Tese (Doutorado em engenharia elétrica) - Universidade Federal de Minas Gerais, Belo Horizonte, 2005.
- NEVES, C.; SOUZA, M. A method for bio-electrical impedance analysis based on a step-voltage response. **Physiological Measurement**, [S.l.], v.21, n.3, p. 395, 2000.
- NOUAZE, J. C. *et al.* Monitoring of Indoor Farming of Lettuce Leaves for 16 Hours Using Electrical Impedance Spectroscopy (EIS) and Double-Shell Model (DSM). **Sensors**, [S.l.], v.22, n.24, p. 9671, 2022.
- OERKE, E.-C.; FRÖHLING, P.; STEINER, U. Thermographic assessment of scab disease on apple leaves. **Precision agriculture**, [S.l.], v.12, n.5, p. 699–715, 2011.
- PETHIG, R.; KELL, D. B. The passive electrical properties of biological systems: their significance in physiology, biophysics and biotechnology. **Physics in Medicine & Biology**, [S.l.], v.32, n.8, p. 933, 1987.
- PHILIPPSON, M. Application des Lampes a Trois Électrodes a La Mesure de La Résistance Électrique des Cellules Et des Tissus Vivants. **Archives Internationales de Physiologie**, [S.l.], v.18, n.1, p. 161–172, 1921.
- PIRZAD, A. *et al.* Effect of water stress on leaf relative water content, chlorophyll, proline and soluble carbohydrates in *Matricaria chamomilla* L. **Journal of Medicinal Plants Research**, [S.l.], v.5, n.12, p. 2483–2488, 2011.
- POSTNIKOV, E. B.; SOKOLOV, I. M. Continuum description of a contact infection spread in a SIR model. **Mathematical biosciences**, [S.l.], v.208, n.1, p. 205–215, 2007.
- PRADO, E. V. do. Unidades de gestão diferenciada e aplicação à taxa variável de insumos na agricultura. **Revista Gestão em Foco**, [S.l.], São Paulo, v.15, p. 61–73, 2023.
- RAILSBACK, S. F.; GRIMM, V. **Agent-based and individual-based modeling: a practical introduction**. [S.l.]: Princeton university press, 2019.
- RAY, M. *et al.* Fungal disease detection in plants: traditional assays, novel diagnostic techniques and biosensors. **Biosensors and Bioelectronics**, [S.l.], v.87, p. 708–723, 2017.
- REYANA, A. *et al.* Accelerating Crop Yield: multisensor data fusion and machine learning for agriculture text classification. **IEEE Access**, [S.l.], v.11, p. 20795–20805, 2023.

- SAMARAS, S. *et al.* Deep learning on multi sensor data for counter UAV applications—A systematic review. **Sensors**, [S.l.], v.19, n.22, p. 4837, 2019.
- SANCHEZ, B. *et al.* Minimal implementation of an AFE4300-based spectrometer for electrical impedance spectroscopy measurements. In: JOURNAL OF PHYSICS: CONFERENCE SERIES, 2013. **Proceedings...** [S.l.: s.n.], 2013. v.434, n.1, p. 012014.
- SANTORO, P. A. **Uma análise de espectros de impedância utilizando o modelo de Poisson-Nernst-Planck com difusão anômala.** — Tese (Doutorado em física) - Programa de Pós-Graduação em Física, Universidade Estadual de Maringá, Maringá, 2014.
- SAVARY, S. *et al.* The global burden of pathogens and pests on major food crops. **Nature ecology & evolution**, [S.l.], v.3, n.3, p. 430–439, 2019.
- SCHWAN, H. P. Electrical properties of tissue and cell suspensions. In: **Advances in biological and medical physics**. [S.l.]: Elsevier, 1957. v.5, p. 147–209.
- SHRIVASTAVA, V. K.; PRADHAN, M. K. Rice plant disease classification using color features: a machine learning paradigm. **Journal of Plant Pathology**, [S.l.], p. 1–10, 2020.
- SOHRABY, K.; MINOLI, D.; ZNATI, T. **Wireless sensor networks: technology, protocols, and applications**. [S.l.]: John wiley & sons, 2007.
- SOUZA, M. *et al.* A Novel Approach to Assessing Crop Health by Electrical Impedance Spectroscopy. In: INTERNATIONAL SYMPOSIUM ON INSTRUMENTATION SYSTEMS, CIRCUITS AND TRANSDUCERS (INSCIT), 2022., 2022. **Proceedings...** [S.l.: s.n.], 2022. p. 1–6.
- TANG, L. *et al.* Moisture Content Detection of Tomato Leaves Based on Electrical Impedance Spectroscopy. **Communications in Soil Science and Plant Analysis**, [S.l.], p. 1–15, 2023.
- TERENTEV, A. *et al.* Current state of hyperspectral remote sensing for early plant disease detection: a review. **Sensors**, [S.l.], v.22, n.3, p. 757, 2022.
- THOMAS, S. *et al.* Benefits of hyperspectral imaging for plant disease detection and plant protection: a technical perspective. **Journal of Plant Diseases and Protection**, [S.l.], v.125, n.1, p. 5–20, 2018.
- TOMKIEWICZ, D.; PISKIER, T. A plant based sensing method for nutrition stress monitoring. **Precision agriculture**, [S.l.], v.13, n.3, p. 370–383, 2012.

- VAN HAEVERBEKE, M.; DE BAETS, B.; STOCK, M. Plant impedance spectroscopy: a review of modeling approaches and applications. **Frontiers in Plant Science**, [S.l.], v.14, p. 1187573, 2023.
- VOLKOV, A. G. **Plant electrophysiology**. [S.l.]: Springer, 2006.
- WANG, D. *et al.* Early detection of Tomato spotted wilt virus by hyperspectral imaging and Outlier Removal Auxiliary Classifier Generative Adversarial Nets (OR-AC-GAN). **Scientific reports**, [S.l.], v.9, n.1, p. 1–14, 2019.
- WANG, Y. M. *et al.* Plant viral disease detection: from molecular diagnosis to optical sensing technology—a multidisciplinary review. **Remote Sensing**, [S.l.], v.14, n.7, p. 1542, 2022.
- WU, L.; OGAWA, Y.; TAGAWA, A. Electrical impedance spectroscopy analysis of eggplant pulp and effects of drying and freezing–thawing treatments on its impedance characteristics. **Journal of Food Engineering**, [S.l.], v.87, n.2, p. 274–280, 2008.
- WULFSOHN, D. Sampling techniques for plants and soil. In: HEINRICH, J. (Ed.). **Advanced Engineering Systems for Specialty Crops: a review of precision agriculture for water, chemical, and nutrient application, and yield monitoring**. 1<sup>a</sup>.ed. [S.l.]: Thünen-Institut Braunschweig, Germany, 2010. Cap. 2. p. 3–30.
- YANG, X. *et al.* A molecularly imprinted biosensor based on water-compatible and electroactive polymeric nanoparticles for lysozyme detection. **Talanta**, [S.l.], v.236, p. 122891, 2022.
- YOU, J. *et al.* Biological control and plant growth promotion by volatile organic compounds of *Trichoderma koningiopsis* T-51. **Journal of Fungi**, [S.l.], v.8, n.2, p. 131, 2022.
- ZHANG, M.; WILLISON, J. Electrical impedance analysis in plant tissues<sup>11</sup>. **Journal of Experimental Botany**, [S.l.], v.42, n.11, p. 1465–1475, 1991.
- ZHAO, W. *et al.* Using infrared thermal imaging technology to estimate the transpiration rate of citrus trees and evaluate plant water status. **Journal of Hydrology**, [S.l.], v.615, p. 128671, 2022.
- ZHAO, X. *et al.* Electrical impedance spectroscopy for quality assessment of meat and fish: a review on basic principles, measurement methods, and recent advances. **Journal of Food Quality**, [S.l.], v.2017, 2017.
- ZOBEL, O. J. Theory and design of uniform and composite electric wave-filters. **The Bell System Technical Journal**, [S.l.], v.2, n.1, p. 1–46, 1923.

## ANEXO A MÍNIMOS QUADRADOS RECURSIVO

A Superfície de Impedância, abordagem proposta e detalhada no Capítulo 4, é construída utilizando o método dos Mínimos Quadrados Recursivo ponderado. Nesta seção, o método dos Mínimos Quadrados Recursivo ponderado é derivado a partir do método dos Mínimos Quadrados clássico.

### A.1 Método dos Mínimos Quadrados Clássico

Um modelo de regressão linear pode ser descrito por

$$\hat{z}_S = \mathbf{X}\hat{\boldsymbol{\theta}}, \quad (44)$$

sendo  $\hat{z}_S$  o vetor com os valores estimados (variável dependente),  $\mathbf{X}$  a matriz com as observações das variáveis independentes, denotadas variáveis regressoras, e  $\hat{\boldsymbol{\theta}}$  são os parâmetros do modelo. Considerando (44), os valores observados da variável independente  $z$  são expressos por

$$z = \mathbf{X}\hat{\boldsymbol{\theta}} + \boldsymbol{\xi}, \quad (45)$$

sendo  $\boldsymbol{\xi}$  o vetor que contém os erros cometidos ao tentar estimar  $z$  por meio de  $\mathbf{X}\hat{\boldsymbol{\theta}}$ . Note que a dimensão do vetor  $\hat{\boldsymbol{\theta}}$  é proporcional à quantidade de variáveis independentes do modelo. Se o modelo tem  $n$  variáveis independentes,  $\hat{\boldsymbol{\theta}}$  possui  $n + 1$  parâmetros e  $\hat{\boldsymbol{\theta}} \in \mathbb{R}^{n+1 \times 1}$ . Enquanto que a dimensão da matriz  $\mathbf{X}$  depende da quantidade de dados,  $N$ , e da quantidade de parâmetros,  $n + 1$ , sendo que  $\mathbf{X} \in \mathbb{R}^{N \times n+1}$ .

O método dos Mínimos Quadrados consiste em minimizar o somatório do quadrado dos erros,  $S_r$ , garantindo que o modelo descrito em (44) é o que melhor representa o conjunto de dados. Considerando  $N$  observações, o somatório do quadrado dos erros pode ser definido por

$$S_r = \sum_{i=1}^N \xi(i)^2 = \boldsymbol{\xi}^T \boldsymbol{\xi} = \|\boldsymbol{\xi}\|^2, \quad (46)$$

substituindo  $\boldsymbol{\xi}$  em (46), tem-se

$$S_r = \mathbf{z}^T \mathbf{z} - \mathbf{z}^T \mathbf{X}\hat{\boldsymbol{\theta}} - \hat{\boldsymbol{\theta}}^T \mathbf{X}^T \mathbf{z} + \hat{\boldsymbol{\theta}}^T \mathbf{X}^T \mathbf{X}\hat{\boldsymbol{\theta}}, \quad (47)$$

para minimizar  $S_r$  em função dos parâmetros  $\hat{\boldsymbol{\theta}}$  basta fazer  $\partial S_r / \partial \hat{\boldsymbol{\theta}} = 0$  e garantir  $\partial^2 S_r / \partial \hat{\boldsymbol{\theta}}^2 > 0$ , assim,

$$\frac{\partial S_r}{\partial \hat{\boldsymbol{\theta}}} = -2\mathbf{X}^T \mathbf{z} + 2\mathbf{X}^T \mathbf{X}\hat{\boldsymbol{\theta}}, \quad (48)$$

igualando (48) a zero encontra-se

$$\hat{\boldsymbol{\theta}} = [\mathbf{X}^T \mathbf{X}]^{-1} \mathbf{X}^T \mathbf{z}. \quad (49)$$

Para que o vetor dos parâmetros estimados,  $\hat{\boldsymbol{\theta}}$ , encontrado em (49), minimize  $S_r$  é necessário que

$$\frac{\partial^2 S_r}{\partial \hat{\boldsymbol{\theta}}^2} = 2\mathbf{X}^T \mathbf{X} > 0, \quad (50)$$

como  $2\mathbf{X}^T \mathbf{X}$  é definida positiva por construção, de fato  $\hat{\boldsymbol{\theta}}$  minimiza o somatório do quadrado dos erros (AGUIRRE, 2004).

O método dos Mínimos Quadrados (MQ) tem algumas características importantes, a seguir são destacadas duas dessas características. A primeira está baseada na forma em que o conjunto de parâmetros  $\hat{\boldsymbol{\theta}}$  é estimado, que é a partir de um sistema sobredeterminado de equações. Um sistema sobredeterminado de equações é um conjunto de equações no qual o número de equações é maior do que o número de incógnitas ou variáveis, implicando em situações cuja solução não é única. Em termos práticos, isso significa que a quantidade de dados é maior que o necessário para determinar os parâmetros do modelo. Como o MQ minimiza a soma do quadrado dos erros, essa redundância de dados favorece o tratamento de erros aleatórios, aumentando a robustez do sistema à presença de ruídos (AGUIRRE, 2004).

A segunda característica do método MQ clássico consiste na necessidade de que toda a massa de dados esteja disponível para que o algoritmo possa estimar o conjunto de parâmetros  $\hat{\boldsymbol{\theta}}$ . Dessa forma, os dados de entrada e saída do sistema são previamente coletados, e o problema numérico é resolvido de uma única vez por meio de (49). Por essa razão, para sistemas que funcionam de forma *online*, o método MQ clássico torna-se inadequado e nessas situações é comum recorrer a técnicas recursivas (AGUIRRE, 2004). A medição baseada em Superfície de Impedância foi desenvolvida para trabalhar *online*, ou seja, os dados são disponibilizados sequencialmente a cada medição. Nesse contexto, as técnicas recursivas são mais adequadas para a construção da Superfície de Impedância, uma vez que não se tem acesso à totalidade da massa de dados de uma só vez.

## A.2 Método dos Mínimos Quadrados Recursivo

O objetivo central dos métodos recursivos é representar grandezas em um instante  $k$  em função de valores obtidos em instantes anteriores. Portanto, o método dos Mínimos Quadrados Recursivo (MQR) pode ser obtido a partir do MQ clássico reescrevendo (49) da seguinte forma:

$$\hat{\boldsymbol{\theta}}_k = \left[ \sum_{i=1}^k \boldsymbol{\psi}(i-1) \boldsymbol{\psi}^T(i-1) \right]^{-1} \left[ \sum_{i=1}^k \boldsymbol{\psi}(i-1) y(i) \right], \quad (51)$$



sendo  $\psi(i-1)$  o vetor com as variáveis regressoras ou independentes na observação  $i-1$ ,  $y(i)$  a variável dependente na observação  $i$  e  $\hat{\boldsymbol{\theta}}_k$  o vetor com os parâmetros estimados. Considerando que

$$P_k = \left[ \sum_{i=1}^k \psi(i-1)\psi^T(i-1) \right]^{-1}, \quad (52)$$

a equação (51) pode ser reescrita como

$$\hat{\boldsymbol{\theta}}_k = P_k \left[ \sum_{i=1}^k \psi(i-1)y(i) \right] = P_k \left[ \sum_{i=1}^{k-1} \psi(i-1)y(i) + \psi(k-1)y(k) \right]. \quad (53)$$

Por conveniência pode-se escrever (51) para o instante  $k-1$  e reorganiza-la da seguinte forma:

$$\left[ \sum_{i=1}^{k-1} \psi(i-1)\psi^T(i-1) \right] \hat{\boldsymbol{\theta}}_{k-1} = \left[ \sum_{i=1}^{k-1} \psi(i-1)y(i) \right], \quad (54)$$

assim como (52) também pode ser reescrita como

$$\begin{aligned} P_k^{-1} &= \left[ \sum_{i=1}^{k-1} \psi(i-1)\psi^T(i-1) \right] + \psi(k-1)\psi^T(k-1) \\ &= P_{k-1}^{-1} + \psi(k-1)\psi^T(k-1). \end{aligned} \quad (55)$$

Como consequência de (55) e (54) tem-se que

$$P_{k-1}^{-1} \hat{\boldsymbol{\theta}}_{k-1} = \left[ \sum_{i=1}^{k-1} \psi(i-1)y(i) \right], \quad (56)$$

substituindo (56) em (53) obtém-se

$$\begin{aligned} \hat{\boldsymbol{\theta}}_k &= P_k \left[ P_{k-1}^{-1} \hat{\boldsymbol{\theta}}_{k-1} + \psi(k-1)y(k) \right] \\ &= \hat{\boldsymbol{\theta}}_{k-1} + P_k \psi(k-1) \left[ y(k) - \psi^T(k-1) \hat{\boldsymbol{\theta}}_{k-1} \right], \end{aligned} \quad (57)$$

fazendo  $K_k = P_k \psi(k-1)$  e  $\eta(k) = \left[ y(k) - \psi^T(k-1) \hat{\boldsymbol{\theta}}_{k-1} \right]$  chega-se a

$$\hat{\boldsymbol{\theta}}_k = \hat{\boldsymbol{\theta}}_{k-1} + K_k \eta(k). \quad (58)$$

Observando (57) fica evidente que para fazer o MQR é necessário calcular  $P_k$ . Com o objetivo de simplificar o cálculo de  $P_k$ , evitando trabalhar com a matriz

inversa em (52), utiliza-se o Lema da Inversão para se chegar à seguinte equação numérica:

$$P_k = P_{k-1} - P_{k-1}\psi(k-1)(\psi^T(k-1)P_{k-1}\psi(k-1) + 1)^{-1}\psi^T(k-1)P_{k-1}. \quad (59)$$

Em (59), para modelos com apenas uma saída, o termo a ser invertido será um escalar, simplificando a execução do algoritmo. Por fim, aplicando (59) à expressão  $K_k = P_k\psi(k-1)$  chega-se a

$$K_k = \frac{P_{k-1}\psi(K-1)}{\psi^T(k-1)P_{k-1}\psi(k-1) + 1}. \quad (60)$$

A ordem apropriada para calcular o algoritmo do MQR é aplicando as equações (60), (58) e (59). Na inicialização do algoritmo a matriz  $P_k$ , denominada por matriz de covariância, recebe valores grandes, geralmente entre  $10^3$  e  $10^7$ , nos elementos da diagonal principal e os outros elementos são iguais a zero. Enquanto que, os elementos do vetor de parâmetros,  $\hat{\theta}_k$ , geralmente inicializam iguais a zero. Se houver conhecimento prévio do sistema a ser modelado, os valores iniciais de  $P_k$  e  $\hat{\theta}_k$  são ajustados para obter uma convergência mais rápida do algoritmo (AGUIRRE, 2004).

É importante enfatizar algumas características do MQR. A primeira está relacionada ao MQR ser derivado do MQ. Pois, assim como o MQ minimiza o somatório do erro quadrático, encontrando o melhor ajuste à massa de dados, os parâmetros estimados pelo MQR também convergem para o melhor ajuste. Neste ponto há um detalhe importante, pois, a convergência para o melhor ajuste vai depender do número de iterações do algoritmo, da escolha dos valores iniciais de  $P_k$  e  $\hat{\theta}_k$  e da dinâmica do sistema que está sendo modelado.

Outra característica importante do MQR é que ele não depende de ter toda a massa de dados disponível previamente para fazer a estimativa dos parâmetros, como no MQ. Sendo adequado para sistemas em que os dados são disponibilizados sequencialmente, visto que o algoritmo vai ajustando os parâmetros estimados a cada iteração. Como consequência, o MQR torna-se adequado também para aplicações em sistemas cujos parâmetros variam em função do tempo. Porém, para que esse tipo de aplicação seja possível, é necessário que as informações mais recentes tenham uma influência maior na estimação dos parâmetros. Assim, o algoritmo do MQR precisa ser construído de forma que as observações sejam ponderadas de maneira diferenciada, com as últimas observações influenciando mais que as observações mais antigas. Para isso, a equação (61) pode ser reescrita da forma

$$\hat{\boldsymbol{\theta}}_k = \left[ \sum_{i=1}^k \omega_i(k) \psi(i-1) \psi^T(i-1) \right]^{-1} \left[ \sum_{i=1}^k \omega_i(k) \psi(i-1) y(i) \right], \quad (61)$$

sendo  $\omega_i(k)$  o peso que as observações realizadas no instante  $i$  tem na determinação do conjunto de parâmetros no instante  $k$ . Considerando que

$$P_k = \left[ \sum_{i=1}^k \omega_i(k) \psi(i-1) \psi^T(i-1) \right]^{-1}, \quad (62)$$

$$F_k = \left[ \sum_{i=1}^k \omega_i(k) \psi(i-1) y(i) \right], \quad (63)$$

$$\omega_k(k) = 1, \text{ e} \quad (64)$$

$$\omega_i(k) = \lambda \omega_i(k) \text{ para } i < k, \quad (65)$$

tem-se

$$P_k^{-1} = \lambda P_{k-1}^{-1} + \psi(k-1) \psi^T(k-1), \quad (66)$$

e

$$F_k = \lambda F_{k-1} + \psi(k-1) y(k), \quad (67)$$

sendo  $\lambda$  o fator de esquecimento, geralmente escolhido entre 0,95 e 0,99. As equações (66) e (67) foram derivadas seguindo os mesmos passos de (55). Substituindo (67) em (61) chega-se a

$$\hat{\boldsymbol{\theta}}_k = P_k [\lambda F_{k-1} + \psi(k-1) y(k)], \quad (68)$$

sabendo que  $\hat{\boldsymbol{\theta}}_k = P_k F_k$ , (68) pode ser reescrita como

$$\hat{\boldsymbol{\theta}}_k = P_k \left[ \lambda P_{k-1}^{-1} \hat{\boldsymbol{\theta}}_{k-1} + \psi(k-1) y(k) \right], \quad (69)$$

manipulando (66) e substituindo  $P_{k-1}^{-1}$  em (69) tem-se

$$\begin{aligned}\hat{\boldsymbol{\theta}}_k &= P_k \left\{ \lambda \left[ \frac{P_k^{-1} - \psi(k-1)\psi^T(k-1)}{\lambda} \right] \hat{\boldsymbol{\theta}}_{k-1} + \psi(k-1)y(k) \right\} \\ &= \hat{\boldsymbol{\theta}}_{k-1} + K_k \left[ y(k) - \psi^T(k-1)\hat{\boldsymbol{\theta}}_{k-1} \right],\end{aligned}\quad (70)$$

sendo  $K_k$  descrito por

$$K_k = P_k \psi(k-1). \quad (71)$$

Para facilitar os cálculos, como em (59), aplica-se o lema da inversão em (62) para obter

$$P_k = \frac{1}{\lambda} \left( P_{k-1} - \frac{P_{k-1}\psi(k-1)\psi^T(k-1)P_{k-1}}{\psi^T(k-1)P_{k-1}\psi(k-1) + \lambda} \right), \quad (72)$$

substituindo (72) em (71) tem-se

$$K_k = \frac{P_{k-1}\psi(k-1)}{\psi^T(k-1)P_{k-1}\psi(k-1) + \lambda}. \quad (73)$$

A ordem apropriada para calcular o algoritmo do MQR ponderado é aplicando (73), (70) e (72).