

**UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT
PROGRAMA DE MESTRADO PROFISSIONAL EM ENGENHARIA ELÉTRICA**

RICARDO NOGUEIRA CAVALIERI

**MÉTODOS DE INTELIGÊNCIA ARTIFICIAL PARA A CARACTERIZAÇÃO DE
TECIDOS BIOLÓGICOS USANDO A ESPECTROSCOPIA DE IMPEDÂNCIA
ELÉTRICA.**

JOINVILLE

2022

RICARDO NOGUEIRA CAVALIERI

**MÉTODOS DE INTELIGÊNCIA ARTIFICIAL PARA A CARACTERIZAÇÃO DE
TECIDOS BIOLÓGICOS USANDO A ESPECTROSCOPIA DE IMPEDÂNCIA
ELÉTRICA.**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do grau de Mestre em Engenharia Elétrica.

Orientador: Pedro Bertemes-Filho

JOINVILLE

2022

Nogueira Cavalieri, Ricardo
MÉTODOS DE INTELIGÊNCIA ARTIFICIAL PARA A
CARACTERIZAÇÃO DE TECIDOS BIOLÓGICOS USANDO A
ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA. / Ricardo
Nogueira Cavalieri. - Joinville, 2022.
63 p. : il. ; 30 cm.

Orientador: Pedro Bertemes-Filho.

Dissertação (Mestrado) - Universidade do Estado
de Santa Catarina, Centro de Ciências Tecnológicas,
Programa de Pós-Graduação em Engenharia Elétrica,
Joinville, 2022.

1. Espectroscopia de impedância elétrica. 2.
Machine Learning. 3. Bioimpedância. 4. Redução de
dimensionalidade. 5. Inteligência Artificial. I.
Bertemes-Filho, Pedro . II. Universidade do Estado
de Santa Catarina, Centro de Ciências Tecnológicas,
Programa de Pós-Graduação em Engenharia Elétrica. III.
Métodos de Inteligência Artificial para a Caracterização
de Tecidos Biológicos usando a Espectroscopia de
Impedância Elétrica.

RICARDO NOGUEIRA CAVALIERI

**MÉTODOS DE INTELIGÊNCIA ARTIFICIAL PARA A CARACTERIZAÇÃO DE
TECIDOS BIOLÓGICOS USANDO A ESPECTROSCOPIA DE IMPEDÂNCIA
ELÉTRICA.**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do grau de Mestre em Engenharia Elétrica.

Orientador: Pedro Bertemes-Filho

BANCA EXAMINADORA:

Prof. Dr. Pedro Bertemes-Filho
Universidade do Estado de Santa Catarina
(presidente/orientador)

Membros:

Prof. Dr. Marco Aurélio Benedetti Rodrigues
Universidade Federal de Pernambuco

Prof. Dr. Rodolfo Lauro Weinert
Universidade do Estado de Santa Catarina

Joinville, 28 de Janeiro de 2022

À minha parceira Heloiza de Castro, que me ensinou o que é estudar de verdade.

AGRADECIMENTOS

Agradeço ao meu orientador por sua interminável paciência em me orientar do início ao fim desta pesquisa, considerando sempre as condições não usuais que passamos juntos por nestes últimos anos. Agradeço a Universidade do Estado de Santa Catarina pela qualidade de seus professores, instalações e alunos. O aprendizado que me foi oferecido por esta instituição foi transformativo para mim tanto intelectualmente como pessoalmente.

Agradeço minha parceira Heloiza, por me apoiar a todos os momentos. À minha mãe por estar sempre presente e minha família que nunca desistiu de mim apesar dos meus hábitos e ideias estranhas.

If you sell your soul to brighten your role
You might be disappointed in the lights
We all need a fix at a time like this
But doesn't it feel good to stay alive?
(Gene Clark - 1974)

RESUMO

Este trabalho foi desenvolvido com a finalidade de demonstrar a funcionalidade de métodos computacionais inteligentes assim como Redes Neurais Profundas e Support Vector Machines para realizar a diferenciação de tecidos biológicos com base em dados de espectroscopia de Impedância Elétrica, incluindo o dimensionamento e confecção de protótipo de um eletrodo invasivo projetado especialmente para a aquisição de dados de impedância em tecidos biológicos. Experimentos de comprovação utilizaram de tecidos biológicos de origem vegetal de diferentes espécies. Os resultados obtidos nesta dissertação demonstram a viabilidade da utilização conjunta das tecnologias de machine learning com as técnicas de espectroscopia de impedância elétrica, em primeiro experimento realizando a diferenciação de tecidos de espécies diferentes e em segundo teste realizando a identificação de estágio de maturação em um tecido vegetal específico. Além destes resultados, são apresentados nesta dissertação um relatório de performance de alguns dos métodos mais utilizados para redução de dimensionalidade de amostras aplicados à espectroscopia de impedância elétrica (sendo estes PCA, Isomaps, LLE e mMDS). Os resultados indicam o método mais efetivo para este tipo de procedimento, além de indicar a viabilidade da utilização da espectroscopia de impedância elétrica aliada a métodos de machine learning em equipamentos de baixa potência computacional. Este resultado aponta à viabilidade da aplicação da tecnologia desenvolvida em aplicações modernas na engenharia biomédica, como equipamentos vestíveis de monitoramento ou equipamentos portáteis em geral. **Palavras-chave:** Espectroscopia de Impedância Elétrica. Machine Learning. Redução de Dimensionalidade. Classificação de dados biológicos. Vestíveis.

ABSTRACT

This dissertation has been developed with the objective to demonstrate the utility of intelligent computational methods such as deep neural networks (and other mathematical methods that could be classified as machine learning methods) in the application of differentiation of biological tissues using electrical impedance spectroscopy. This work shows results in the field of differentiation between tissues of different species, but in a second experiment shows that the system can detect the maturation stage of a given vegetable. Besides these results, this dissertation also presents a comparison between the most popular methods of dimensionality reduction, and their relationship to electrical impedance spectroscopy and biological data, this study's objective is to reduce the processing power required to do needed calculations and to enable new technologies such as wearables or health equipments of low physical dimensions.

Keywords: Electrical Impedance Spectroscopy. Machine Learning. Deep Learning. Dimensionality Reduction. Biological data. Wearable

LISTA DE ILUSTRAÇÕES

Figura 1 – Processo metodológico utilizado.	16
Figura 2 – (a) Representação do circuito equivalente de Randles para impedância observada numa superfície entre um eletrodo planar e a referência; (b) Gráfico de impedância observado no qual R_c representa a resistência da solução entre o eletrodo e a referência, R_{ct} é a resistência à transferência de carga e C_d representa a capacitância entre as camadas.	19
Figura 3 – Exemplo de um diagrama de Cole-Cole.	20
Figura 4 – Exemplo de um diagrama de impedância de Smith.	20
Figura 5 – Representação gráfica da Impedância.	21
Figura 6 – Representação gráfica da Impedância.	22
Figura 7 – Linhas de campo passando por materiais biológicos.	25
Figura 8 – Linhas de corrente penetram na pele humana com praticamente metade da distância entre os eletrodos.	26
Figura 9 – Gráfico de Permissividade vs Frequência marcando os pontos onde ocorrem as dispersões α , β e γ	26
Figura 10 – Modelo de impedância de uma célula de origem biológica, representação simbólica da estrutura da célula (a) e representação em circuito equivalente, onde I_a é a fonte de corrente e V_m é o medidor de tensão (b).	27
Figura 11 – Esquemático da configuração bipolar, onde a linha preta representa a interface eletrodo-amostra, o elemento em vermelho representa a injeção em corrente enquanto o elemento azul representa a medição em tensão.	29
Figura 12 – Sistema tetrapolar em uma amostra in-vivo, linhas equipotenciais são tracejadas. As posições de R e R' determinam a extensão da medição do tecido, enquanto os eletrodos M e M' adquirem as medidas de impedância.	30
Figura 13 – Configuração de eletrodos para medição de composição corporal.	31
Figura 14 – Disposição dos eletrodos de injeção e medição em um tomógrafo de impedância elétrica ao longo de um volume alvo (a) e a imagem reconstruída de um objeto no interior do volume (b).	32
Figura 15 – Disposição dos eletrodos de injeção e medição para a detecção de tumores malignos.	33
Figura 16 – Analisador de Impedância Zurich HF2.	38
Figura 17 – Eletrodo invasivo utilizado para medições de espectroscopia de impedância elétrica em tecidos vegetais.	40
Figura 18 – (A) região extraída para medição na batata inglesa (zona perimedular) - a esquerda e (B) região extraída para medição na maçã comum (região do mesocarpo) - a direita	41

Figura 19 – Gráfico com base no método de Von-Loesecke para determinação de estágios de maturação de uma banana, sendo estes: A) Estágio 1, B) Estágio 4 e C) Estágio 6.	42
Figura 20 – Rede Neural Profunda desenvolvida para o experimento de diferenciação entre as duas dferentes espécies de vegetais.	43
Figura 21 – Curva de aprendizado obtida durante o treinamento da rede neural classificadora.	46
Figura 22 – Matriz confusão do processo de classificação por rede neural, mostrando em A) o dataset separado apenas para o treino, em B) o dataset separado apenas para teste e em C) o dataset completo.	47
Figura 23 – A) valores de Módulo de impedância $ Z $ para os três estágios de maturação. B)valores de ângulo Phi para os três estágios de maturação.	48
Figura 24 – A) Matriz confusão para o SVM com kernel linear, com e sem normalização (cima e baixo). B)Matriz confusão para o SVM com kernel polinomial, com e sem normalização (cima e baixo).	49
Figura 25 – Representação tridimensional dos dados de espectroscopia de impedância elétrica convertidos por PCA.	50
Figura 26 – Representação tridimensional dos dados de espectroscopia de impedância elétrica convertidos por LLE.	51
Figura 27 – Representação tridimensional dos dados de espectroscopia de impedância elétrica convertidos por mMDS.	51
Figura 28 – Representação tridimensional dos dados de espectroscopia de impedância elétrica convertidos por Isomap.	52

LISTA DE TABELAS

Tabela 1 – Configurações gerais de cada método de redução de dimensionalidade aplicado.	45
Tabela 2 – Resultados obtidos a partir dos métodos de redução de dimensionalidade. . .	50

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVOS	15
1.1.1	Objetivo Geral	15
1.1.2	Objetivos Específicos	15
1.2	PROCESSO METODOLÓGICO	16
1.3	ESTRUTURA DA DISSERTAÇÃO	17
2	ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA	19
2.1	REVISÃO HISTÓRICA	19
2.2	FUNDAMENTOS DE IMPEDÂNCIA ELÉTRICA	21
2.3	INTRODUÇÃO A MATERIAIS ELÉTRICOS	23
2.4	FUNDAMENTOS DE ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA E MODELAGEM DE TECIDOS BIOLÓGICO	24
2.5	CONFIGURAÇÕES DE ELETRODOS	28
2.5.1	Método Bipolar	28
2.5.2	Método tetrapolar	29
2.6	EXEMPLOS DE APLICAÇÕES DE ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA EM MATERIAIS BIOLÓGICOS	30
3	CLASSIFICAÇÃO DE TECIDOS BIOLÓGICOS A PARTIR DA ES- PECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA E MÉTODOS DE REDUÇÃO DE DIMENSIONALIDADE	34
3.1	APLICAÇÕES DE MÉTODOS DE MACHINE LEARNING COM DADOS DE ESPECTROSCOPIA DE IMPEDÂNCIA EM MEDICINA, TECIDOS ANIMAIS E VEGETAIS.	34
3.2	FUNDAMENTOS DE MÉTODOS DE MACHINE LEARNING	35
3.3	<i>PRINCIPAL COMPONENT ANALYSIS</i> (PCA)	36
3.4	<i>LOCALLY LINEAR EMBEDDING</i> (LLE)	36
4	TRABALHOS DESENVOLVIDOS	38
4.1	AQUISIÇÃO DE DADOS DE ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA.	38
4.2	ELETRODOS	39
4.3	COLETA DE AMOSTRAS PARA CLASSIFICAÇÃO ENTRE ESPÉCIES .	40
4.4	COLETA DE AMOSTRAS PARA CLASSIFICAÇÃO INTRA ESPÉCIES .	42
4.5	SISTEMA DE CLASSIFICAÇÃO POR MACHINE LEARNING	43
4.5.1	Rede Neural profunda	43
4.5.2	<i>Support Vector Machine</i>	44
4.6	MÉTODOS PARA REDUÇÃO DE DIMENSIONALIDADE	44

5	RESULTADOS E DISCUSSÕES	46
5.1	DIFERENCIAÇÃO DE ESTRUTURAS BIOLÓGICAS DE DIFERENTES ESPÉCIES	46
5.1.1	Resultados	46
5.1.2	Discussões	47
5.2	CLASSIFICAÇÃO DE ESTÁGIO DE MATURAÇÃO INTRA ESPÉCIES .	47
5.2.1	Resultados	48
5.2.2	Discussões	49
5.3	COMPARAÇÃO DE MÉTODOS DE REDUÇÃO DE DIMENSIONALI- DADE APLICADOS ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA DE TECIDOS BIOLÓGICOS	49
5.3.1	Resultados	50
5.3.2	Discussões	52
5.4	DISCUSSÃO GERAL	53
6	CONCLUSÕES E FUTUROS TRABALHOS	54
	REFERÊNCIAS	55
	APÊNDICE A – PUBLICAÇÃO 1	60
	APÊNDICE B – PUBLICAÇÃO 2	61
	APÊNDICE C – PUBLICAÇÃO 3	62
	ANEXO A – CÓDIGO PYTHON PARA AUTOMATIZAÇÃO DAS MÚLTIPLAS LEITURAS DOS ARQUIVOS .CSV GE- RADOS PELO ANALISADOR DE IMPEDÂNCIA. . . .	63

1 INTRODUÇÃO

A espectroscopia de impedância elétrica (EIE) é um método testado e confiável na aquisição de dados sobre a composição de estruturas de materiais que apresentam estruturas complexas (MACDONALD, 1987). O constante desenvolvimento tecnológico possibilitou que este tipo de análise não se limitasse apenas a estudos dentro da engenharia elétricas, mas que fosse empregada em estudos em áreas como a biomédica, onde a espectroscopia de impedância elétrica é capaz de detectar anomalias em tecidos biológicos, sejam estes animais (DEAN et al., 2008) ou vegetais (WU; OGAWA; TAGAWA, 2008).

Esta tecnologia encontrou na biomedicina uma aplicação muito oportuna, uma vez que possui como possibilidade ter caráter não invasivo com seus eletrodos, realizando medições complexas sem perfurar a amostra biológica, mantendo-a intacta. Tal características torna a espectroscopia de impedância elétrica uma alternativa muito viável para estudos como a monitoração de diabetes (CADUFF et al., 2006), saúde óssea (AFSARIMANESH et al., 2016) e até mesmo aplicações de imagem (conhecidas como tomógrafos de impedância elétrica) (CHENEY; ISAACSON; NEWELL, 1999) e até a detecção de diferenciados tipos de neoplasias como câncer de mama (KIM et al., 2007), próstata (HALTER et al., 2007) e melanomas (ABERG; NICANCER; OLLMAR, 2003).

Com o advento e popularização de métodos de inteligência computacional, começaram a ser propostos sistemas que apresentavam alternativas aos métodos clássicos de análise dos resultados obtidos por espectrômetros de impedância elétrica (MARWALA, 2012). Desde a utilização de lógicas difusas (conhecidas como fuzzy) (GUERMAZI; DERBEL; KANOUN, 2016), passando por redes neurais artificiais (JR et al., 2004) e métodos estatísticos (CIUCCI, 2019). Alguns métodos se mostraram úteis para a finalidade de automatizar o processo da análise por espectroscopia de impedância elétrica de elementos biológicos (KUMAR; BUCHHEIT, 2008; LEDERMAN et al., 2011).

Nesta dissertação os temas expostos acima serão utilizados para verificar a possibilidade da utilização de redes neurais e outros métodos de classificação computacional como substituto dos métodos clássicos utilizados na literatura. Sendo assim este trabalho desenvolverá experimentos de classificação de tecidos biológicos diversos, a fim de determinar qual método demonstra maior aptidão para a aplicação. Além disso, o último experimento realizado é dedicado para a redução de dimensionalidade de um resultado de espectroscopia de impedância elétrica de materiais biológicos, este experimento tem como função buscar através de métodos matemáticos reduzir a demanda computacional para a solução da classificação. Buscando viabilizar no futuro tecnologias dos tipos vestíveis.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Desenvolvimento de um sistema confiável para medição de dados de espectroscopia de impedância elétrica em amostras de origem vegetal, incluindo a especificação e dimensionamento de eletrodos, faixas ideais de frequência de excitação da amostra, processamento de dados e classificação automática com dados de machine learning.

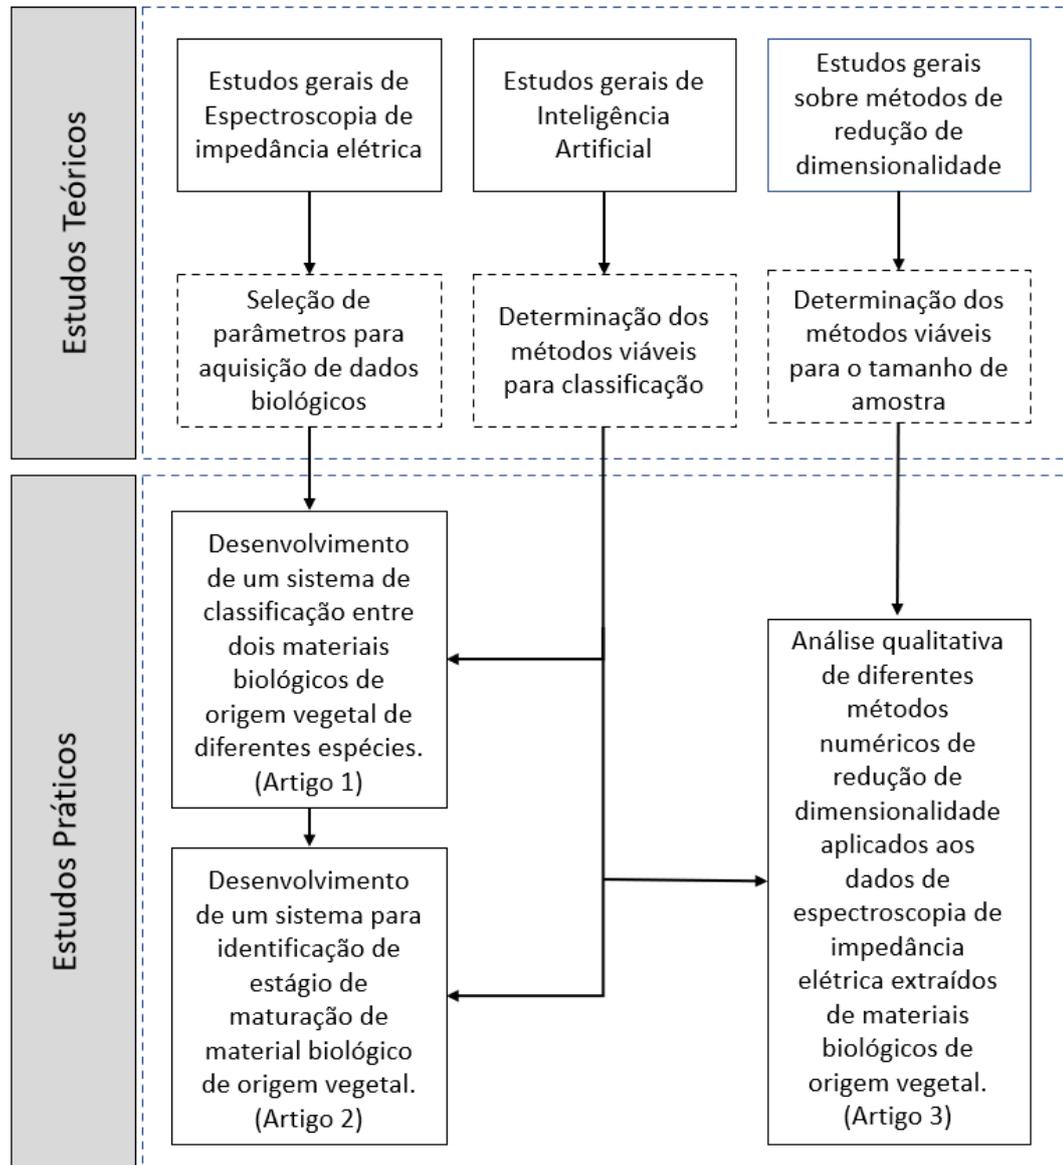
1.1.2 Objetivos Específicos

- Otimizar a geometria de eletrodos invasivos para a leitura de espectroscopia de impedância elétrica de tecidos de origem vegetal.
- Medir e classificar tecidos vegetais distintos usando Redes Neurais e SVMs.
- Investigar a classificação do tecido vegetal para diferentes estágios de maturação, por meio de machine learning.
- Investigar a redução de dimensionalidade em classificadores de dados biológicos utilizando espectroscopia de impedância elétrica e inteligência computacional.

1.2 PROCESSO METODOLÓGICO

O processo metodológico utilizado no desenvolvimento deste projeto de pesquisa é representado na Figura 1, conforme abaixo:

Figura 1 – Processo metodológico utilizado.



Fonte: Elaborada pelo autor (2021)

- **Estudos gerais de Espectroscopia de Impedância Elétrica:** esta etapa serviu de como aquisição de conhecimento sobre a tecnologia e suas diversas aplicações. Naturalmente os objetos de estudo foram voltados para aplicação a espectroscopia em materiais biológicos. Aqui foram estudadas as dispersões classicamente conhecidas, as faixas de frequência mais usuais, os métodos de varredura em frequência, a gama de eletrodos a serem utilizados para a pesquisa e os equipamentos que seriam mais viáveis para a pesquisa em questão.

- **Estudos gerais de Inteligência** : nesta etapa de estudos, foi feita uma revisão sobre os métodos mais modernos utilizados, com função de encontrar o que poderia ser aplicado com mais fidelidade ao objetivo proposto. Diversos tipos de métodos de classificação computacional foram estudados, entre eles: máquinas de vetores de suporte (SVM), redes neurais artificiais (ANN), método Naive Bayes (NB), entre outros.
- **Estudos gerais sobre métodos de redução de dimensionalidade**: esta etapa consistiu de estudo profundo sobre métodos computacionais matemáticos que buscam reduzir a dimensionalidade de bancos de dados de grande escala. Isto teve por objetivo aplicar aos experimentos seguintes métodos que os tornassem computacionalmente eficientes. Alguns dos métodos estudados foram: Principal Component Analysis (PCA), Locally Linear Embedding (LLE), Metric Multidimensional Scalings (mMDS) e Isomap.
- **Artigo 1**: nesta produção foram utilizados os conhecimentos de espectroscopia de impedância elétrica aliados a inteligência computacional com função de criar uma prova de conceito que delimitasse um protocolo confiável para a classificação de materiais biológicos de origem vegetal observados pela espectroscopia de impedância elétrica. O objetivo era mostrar que estas tecnologias unidas podiam realizar a diferenciação com facilidade, mesmo utilizando relativamente um tamanho de amostra relativamente pequeno e demandando relativamente pouco tempo e pouca potência computacional.
- **Artigo 2**: esta produção buscou expandir as ideias apresentadas no Artigo 1, buscando desta vez realizar a diferenciação entre materiais biológicos da mesma espécie em diferentes estágios de maturação. Observou-se uma necessidade de ajuste de parâmetros ao lidar com uma tarefa mais refinada.
- **Artigo 3**: esta produção buscou determinar entre os métodos de redução de dimensionalidade estudados (PCA, LLE, mMDS e Isomap) qual o método que maior beneficiaria a aplicação da classificação de materiais biológicos de origem vegetal, visando ainda maior eficiência computacional, minimizando erros de classificação.

1.3 ESTRUTURA DA DISSERTAÇÃO

As próximas duas seções contarão com uma revisão a fundo sobre os três temas que regem esta dissertação: a espectroscopia de impedância elétrica, inteligência computacional e o processo de redução de dimensionalidade.

No Capítulo 2, serão apresentados os conceitos básicos da espectroscopia de impedância elétrica, suas aplicações mais comuns (dando ênfase às diversas aplicações biomédicas), sua variada gama de parâmetros tanto em questão elétrica (tratando-se de faixa de frequência, intensidade da tensão de excitação e métodos de compensação para impedâncias indesejáveis na medição) quanto os parâmetros físicos como seleção de eletrodos, quantidade de posicionamento

para diferentes aplicações. Finalmente serão contemplados os métodos clássicos de interpretação dos resultados obtidos pela EIA.

No Capítulo 3, serão visto alguns métodos conhecidos como inteligência artificial assim como métodos redução de dimensionalidade. Este tema será discutido inicialmente de maneira abrangente, mas tornará a focar nos métodos úteis ao objetivo da dissertação. Serão apresentados uma gama de métodos populares no panorama científico contemporâneo e seus prós e contras serão discutidos em relação a esta específica aplicação.

O capítulo 4 trará a descrição dos trabalhos desenvolvidos no curso desta dissertação, incluindo os métodos, equipamentos, técnicas numéricas e computacionais utilizadas.

Capítulo 5 será dedicado a exposição de resultados assim como as discussões específicas referentes a cada experimento desenvolvido.

No capítulo 6, será desenvolvida a conclusão da dissertação como um todo e a apresentação de trabalhos futuros relevantes ao tema.

2 ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA

2.1 REVISÃO HISTÓRICA

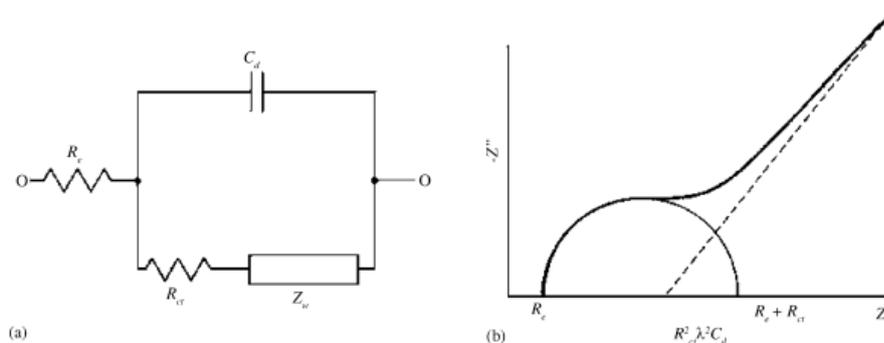
Os estudos de técnicas de análise de impedância elétrica se iniciam muito antes da possibilidade da aplicações de tensão em frequências variáveis. É possível afirmar que desde os primeiros experimentos que dizem respeito ao fenômeno elétrico, como os conduzidos por Thomas Browne (1646) e Luigi Galvani (1791), manifesta-se o interesse em conhecer as propriedades de um material quando exposto a uma diferença de potencial elétrico. O conceito da resistência elétrica em sua forma atual foi cunhado por Georg Simon Ohm (1827).

A grandeza real conhecida como resistência passou a ser vista como apenas uma componente do fenômeno de reação a circulação de corrente elétrica. O objeto de estudo passa a ser, portanto, a grandeza complexa conhecida como impedância. A definição do conceito de impedância foi apresentada pela primeira vez por Olivier Heaviside em 1888 (HEAVISIDE, 1888).

A partir do conhecimento do fenômeno da impedância, o estudo de suas características começam a ser refinado por teorias matemáticas envolvendo grandes nomes da área como Pierre-Simon Laplace e Joseph Fourier. Estes desenvolvimentos habilitaram a manipulação dos dados obtidos através de análises em domínio de frequência (REEVES, 1973).

A popularização de fontes chaveadas e a ampla disponibilidade de equipamentos de medição de impedância impulsionaram o estudo da impedância elétrica em diferentes áreas da engenharia elétrica. O famoso experimento de Warburg sobre impedância em difusão (ZWANZIG, 1965), a consideração de eletrodos porosos por deLevie (LEVIE, 1989) e finalmente o uso de circuitos equivalentes como descritores das características impedimétricas de materiais (ROBERTSON, 1953; RANGLES, 1947). Um exemplo de circuito equivalente pode ser observado na Figura 2.

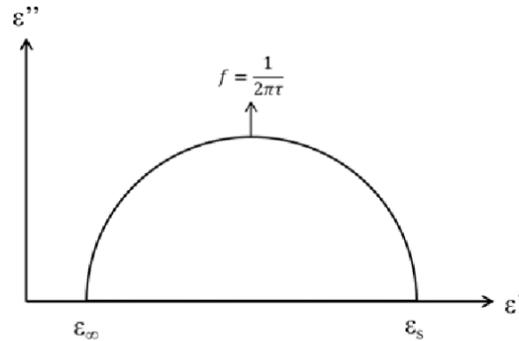
Figura 2 – (a) Representação do circuito equivalente de Randles para impedância observada numa superfície entre um eletrodo planar e a referência; (b) Gráfico de impedância observado no qual R_c representa a resistência da solução entre o eletrodo e a referência, R_{ct} é a resistência à transferência de carga e C_d representa a capacitância entre as camadas.



Fonte: Adaptado de (MACDONALD; JOHNSON, 2005))

Apesar da metodologia de variar frequência aplicada a uma mostra seja constante desde a invenção da eletrônica analógica, podemos dizer que a Espectroscopia de Impedância Elétrica em sua forma moderna possui seu marco histórico mais importante com o diagrama de Cole e Cole em 1941 (COLE; COLE, 1941), exemplificado na Figura 3.

Figura 3 – Exemplo de um diagrama de Cole-Cole.

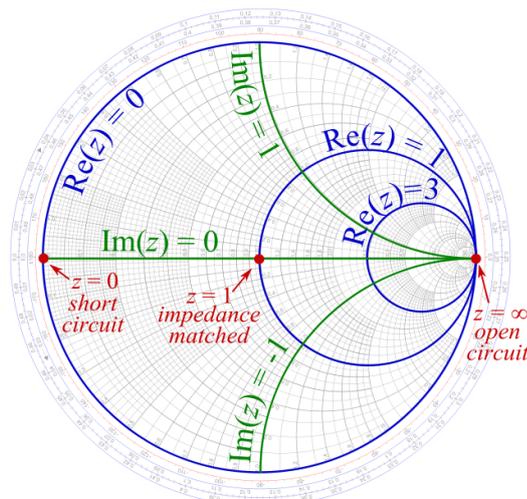


Fonte: Adaptado de (VARADE et al., 2013))

Como é possível observar na Figura 3, a formação de um círculo com o valor da frequência em seu ponto máximo, entre e a permissividade no infinito .

Outra grande contribuição pioneira para a popularização de estudos utilizando a Espectroscopia de Impedância elétrica veio com a criação do diagrama de impedância de Smith, criado em 1944 (SMITH, 1939). O diagrama foi de grande utilidade para a análise de redes de transmissão, utilizando o diagrama para encontrar eventuais problemas com a rede (como pontos de curto-circuito).

Figura 4 – Exemplo de um diagrama de impedância de Smith.



Fonte: Acessado em <http://www.medium.com>

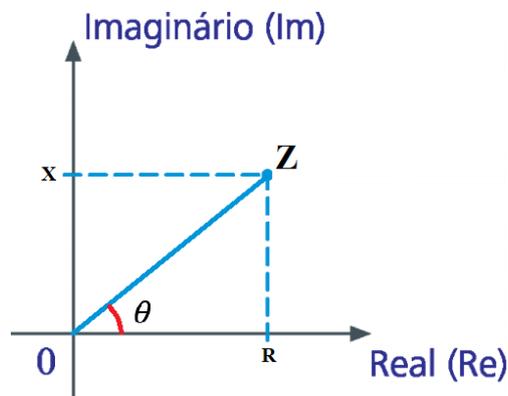
Conforme é possível observar o diagrama de impedância de Smith serve como uma forma de ábaco para facilitar a identificação as grandezas de $Re z$ e $Im(z)$.

2.2 FUNDAMENTOS DE IMPEDÂNCIA ELÉTRICA

Em sua definição fundamental, a impedância elétrica de um material mede o nível de oposição que este apresenta à circulação de uma corrente elétrica. O termo inclui tanto a resistência quanto a reatância.

Em nível microscópico, pode-se dizer que a resistência é ocasionada pela colisão entre partículas que carregam carga elétrica com outras particular estruturais do material. Já o componente chamado de reatância se ocasiona pela força eletromagnética gerada pelos campos elétricos e magnéticos variáveis que difusamente circulam o material (BRITANNICA, 2004).

Figura 5 – Representação gráfica da Impedância.



Fonte: Criado pelo Autor

A impedância elétrica, simbolizada por $Z[\Omega]$, trata-se, portanto de uma medida complexa composta por duas componentes: a componente real chamada de resistência, $R[\Omega]$, e a componente imaginária chamada reatância, $X[\Omega]$. A interpretação gráfica do valor complexo da impedância elétrica pode ser observada na Figura 5. No gráfico observa-se que os valores reais e imaginários contribuem uma parcela para o módulo de Z .

Pode-se observar que o ângulo que o vetor Z faz com o o eixo Real é chamado de θ . Isso possibilita que esta grandeza seja representada de duas maneiras diferentes chamadas: forma retangular e forma polar. Considerando o operador imaginário $i = \sqrt{-1}$, portanto escrevemos Z em sua forma retangular na Equação 1.

$$Z = R + iX \quad (1)$$

Para representar Z em sua forma polar, usamos seu módulo e o ângulo θ , sendo que $|Z| = \sqrt{R^2 + X^2}$ e $\theta = \text{arcotangente}(X/R)$. Desta maneira a forma polar de Z pode ser observada na Equação 2.

$$Z = |Z|e^{i\theta} = |Z|\angle\theta \quad (2)$$

Uma das características mais importantes sobre a medição da impedância é o fato de que esta é altamente sensível à variações em frequência de excitação. Esse fenômeno ocorre devido ao componente da reatância $X[\Omega]$. Observa-se que para o estudo lidando com materiais biológicos, a reatância tem uma condição muito particular que de certa maneira simplificará as considerações, mas a título de revisar o tema impedância da maneira mais fundamental possível, consideraremos suas duas possíveis respostas.

Em uma primeira hipótese, é possível dizer que a reatância possui comportamento capacitivo e a chamaremos de X_C , possuirá valor negativo na forma retangular de Z e seu valor tenderá a ser muito baixo (tendendo a 0) para frequências altas e muito alto (tendendo ao infinito) para frequências baixas. Essas condições podem ser verificadas aplicando as duas situações de limite na Equação 3, que descreve X_C .

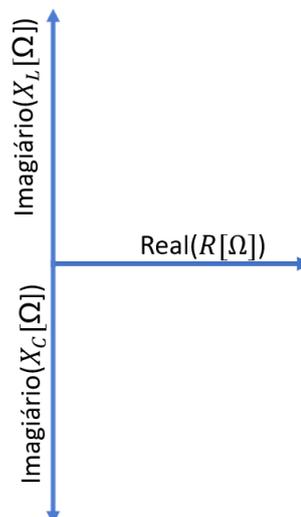
$$X_C = \frac{1}{2\pi fL} \quad (3)$$

Em uma segunda hipótese, considera-se a reatância com comportamento indutivo chamada X_L . A lógica neste caso é invertida em relação a reatância capacitiva, esta tenderá à zero em frequências baixas e ao infinito quando submetidas a frequências muito altas. Isso pode ser confirmado observando a Equação 4.

$$X_L = 2\pi fL \quad (4)$$

Uma maneira mais conveniente de compreender A reatância capacitiva e a reatância indutiva é colocá-las em um gráfico assim como a Figura 5, mas desta vez discernindo os lugares das reatâncias capacitivas e indutivas como na Figura 6.

Figura 6 – Representação gráfica da Impedância.



Fonte: Criado pelo Autor

A partir destas características da reatância, pode-se compreender a utilidade de aplicar diferentes faixas de frequência a um mesmo tecido. Sabendo desta relação entre reatância e frequência, ao variarmos a faixa de frequência para uma mesma amostra, extra-se mais informação sobre a amostra, se comparado a uma única medição em frequência fixa. A técnica de aplicar excitação à amostra em diferentes faixas de frequência é chamada de espectroscopia de impedância elétrica.

2.3 INTRODUÇÃO A MATERIAIS ELÉTRICOS

Conforme os termos definidos na seção anterior, pode-se concluir que materiais diferentes possuirão uma resposta singular à passagem de corrente elétrica.

A classificação mais básica dada em relação a passagem de corrente elétrica são: condutores, isolantes, e semicondutores. Uma definição simplificada para esta classificação é de que um material possui baixa resistividade, enquanto um material isolante demonstrará alta resistência; entretanto, para que seja possível definir fenômenos mais complexos relacionados a passagem de corrente elétrica por materiais, precisamos considerar outras grandezas.

A condutividade elétrica (σ), descrita na Equação 5, define o comportamento de um material em relação a seu comportamento quando submetido a correntes elétricas em função da configuração eletrônica do material.

$$\sigma = n \cdot e \cdot \mu_n + p \cdot e \cdot \mu_p \quad (5)$$

onde condutividade elétrica σ é medida em S/m , n é a concentração de elétrons livres no material (m^{-3}), p representa a concentração de íons positivos (ou lacunas) no material (m^{-3}), e representa a constante de carga de um elétron (de valor igual a $1,6022 \cdot 10^{-19}$ C), enquanto μ_n e μ_p representam, respectivamente, a mobilidade de elementos eletricamente carregados dentro do material ($m^2/V.s$).

A partir desta definição passa a ser possível definir a resistividade elétrica de um material, descrita na Equação 6, que é, como o nome sugere, o inverso da condutividade apresentada anteriormente.

$$\rho = \frac{1}{\sigma} \quad (6)$$

Outro termo importante para a compreensão da interação do campo elétrico com diversas estruturas (especialmente as de origem biológica) é a permissividade elétrica (ϵ). Este descreve a capacidade de um material ou meio a ser polarizado por um campo elétrico que o transpassa.

Usualmente os valores utilizados são relações com a permissividade elétrica no vácuo μ_u (que apresenta valor constante de $8,85 \cdot 10^{-12} F/m$). Além da sua permissividade relativa, a

facilidade de polarização de um material depende também de fatores específicos que dizem respeito a sua estrutura como rigidez dielétrica e perdas por polarização.

2.4 FUNDAMENTOS DE ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA E MODELAGEM DE TECIDOS BIOLÓGICO

Um fenômeno fundamental para a compreensão da espectroscopia de impedância elétrica em materiais biológicos e tem como base o conceito da permissividade elétrica, conforme apresentada na seção anterior, é conhecido como dispersão ou relaxação elétrica. Uma vez que os dipolos associados ao material não são capazes de alinharem-se a tempo ao campo elétrico aos quais estão submetidos, observa-se a queda da polarização total (α_T). O que ocorre neste caso é uma redução da permissividade elétrica do material e a este conjunto de fenômenos é chamado dispersão ou relaxação dielétrica (BERTEMES-FILHO, 2002).

A teoria estabelecida na Seção 2.2 possui completa aplicabilidade neste tema, lidando com a espectroscopia de impedância elétrica de forma aplicada. Vale lembrar que agora, trabalhando com sistemas biológicos, deve-se fazer a consideração de que toda reatância encontrada deve ser considerada capacitiva. Isso não significa que uma estrutura biológica com comportamento indutivo é inexistente, mas que a grande maioria tem comportamento capacitivo. Esta é uma afirmação importante para simplificar as análises observadas (PLIQUETT, 2010).

De maneira geral a resposta em impedância de uma amostra biológica se dá pelas características de dois meios distintos: extracelulares e intracelulares.

A existência de íons em diferentes concentrações nestes dois meios e as barreiras que separam o meio intracelular do meio extracelular (chamadas membranas) causam respostas características em impedância, sendo estas primariamente respostas capacitivas.

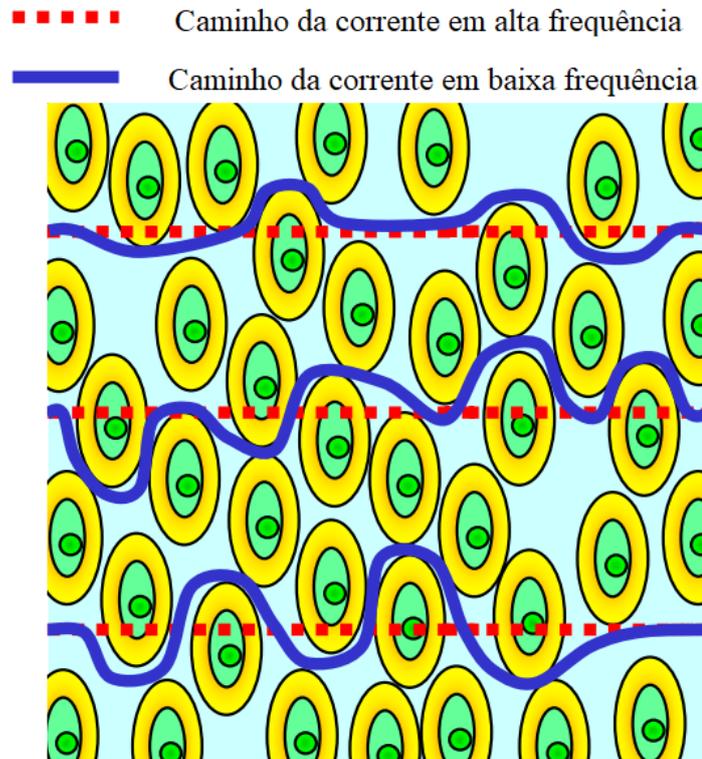
Considerando que membranas celulares são compostas primariamente por lipídios insolúveis em água, demonstram alta resistividade (condutividade aproximada de $10^{-2} S/m$) e capacitância típica de $10^{-2} F/m$. Desta maneira o campo elétrico encontra maior resistência destes elementos ao ser aplicado em baixas frequências. É também importante considerar que além das membranas, o meio intracelular também possui resistividade típica (variando de 0,7 a $11 m\Omega$).

Por outro lado, o meio extracelular não demonstra comportamento capacitivo, mas uma resistividade comparável ao fluido intracelular. Observa-se, por este motivo, que não existem grandes variações no comportamento do campo elétrico neste meio mediante a variação de frequência.

Tendo estes sistemas bem definidos, é possível descrever de maneira geral o comportamento do campo elétrico que atravessa uma amostra de origem biológica: em baixas frequências, as linhas de campo confrontadas pela alta capacitância das membranas celulares são desviadas de seu caminho retilíneo, sem conseguir transpassá-las, já com um aumento da frequência aplicada, de acordo com a Equação 3, a reatância capacitiva observada nas membranas decai

drasticamente e as linhas de campo conseguem penetrar essas estruturas, passando livremente pelo meio intracelular. Este fenômeno é claramente explicado na Figura 7.

Figura 7 – Linhas de campo passando por materiais biológicos.

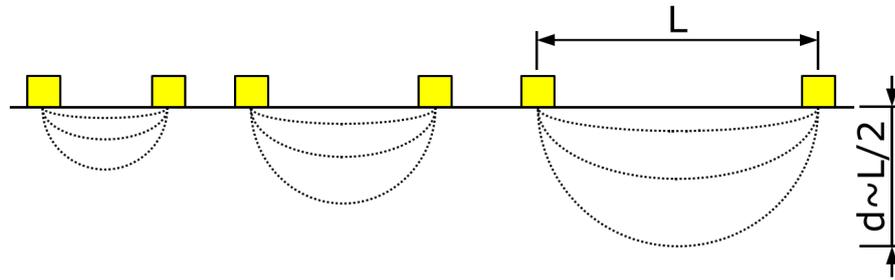


Fonte: (ABERG; NICANCER; OLLMAR, 2003)

Esta variação de dificuldade que o campo elétrico enfrenta ao transpassar a amostra biológica é justamente o que torna a espectroscopia de impedância elétrica tão informativa quanto a estrutura da amostra. Esta informação é tão precisa que é possível inferir, a partir do gráfico de permissividade por frequência os fenômenos que estão ocorrendo com as linhas de campo elétrico percorrendo a amostra biológica.

Outra questão importante sobre a espectroscopia da impedância e suas características é que a profundidade na qual as linhas de campo são capazes de interagir com a amostra, esta é dependente do posicionamento dos eletrodos usados para a medição. Aqui será utilizado um exemplo simples de uma medição a dois eletrodos para explicar a proporção de penetração do campo elétrico, vide que haverá uma seção futura falando apenas das diversas opções de configurações de eletrodos.

Figura 8 – Linhas de corrente penetram na pele humana com praticamente metade da distância entre os eletrodos.



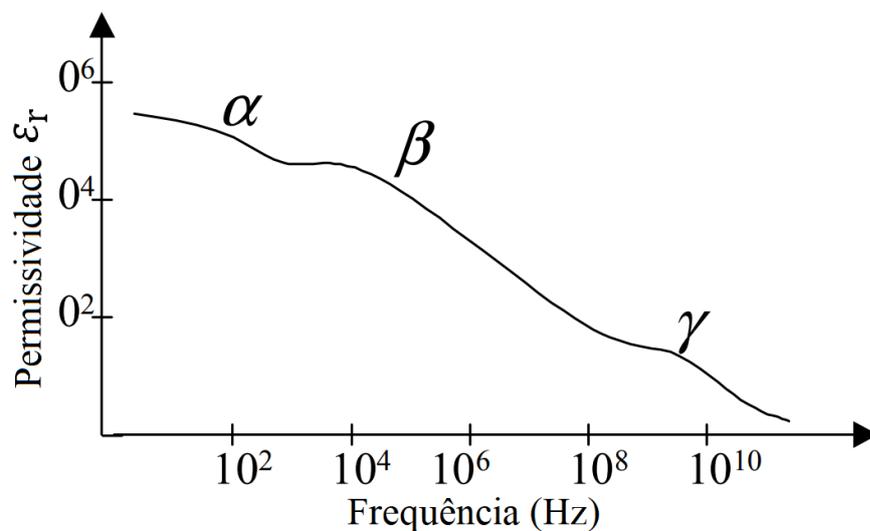
Fonte: (ÅBERG, 2004)

Como é possível observar na Figura 8, a profundidade de penetração das linhas de campo dado pela variável d pode ser aproximada em relação ao distanciamento dos eletrodo, a relação é descrita aproximadamente na Equação 7.

$$d \approx \frac{L}{2} \quad (7)$$

As três dispersões demonstradas na Figura 9 são conhecidas como dispersão α , β e γ . Estas não são as únicas instancias de relaxamento do dielétrico observados com a variação de frequência aplicada a uma amostra biológica, mas certamente são as mais importantes.

Figura 9 – Gráfico de Permissividade vs Frequência marcando os pontos onde ocorrem as dispersões α , β e γ .



Fonte: (BERTEMES-FILHO, 2002)

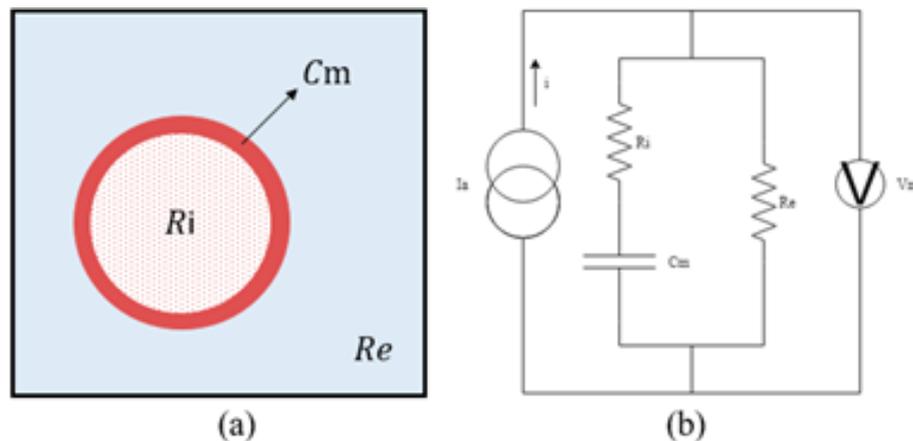
A dispersão α , que se encontra em relativa baixa frequência (na Figura 9 em torno de $10^2 kHz$, é muitas vezes associada aos processos de difusão iônicos em torno das membranas

celulares. A dispersão β , que se encontra na região entre 10^4 a $10^6 kHz$ é deriva a polarização das membranas celulares. Isto é, a dispersão β marca o momento onde o elemento capacitivo da membrana deixa de ser suficiente para contar a passagem do campo elétrico. A dispersão γ , que ocorre após os $10^8 kHz$ diz respeito a relaxação dielétrica das moléculas de água.

Modelar o comportamento de um tecido biológico significa simplificá-lo de alguma forma e criar um sistema substituto que seja não apenas capaz de recriar fielmente as características observadas no material original, mas também que este seja capaz de responder a estímulos diferentes dos aplicados a ainda ser fiel a amostra.

De modo geral, existem dois métodos clássicos utilizados pela modelagem. O método mais popular é o desenvolvimento de circuitos equivalentes que operarão da mesma maneira que o material biológico se excitados por uma corrente variável. Pode-se iniciar a compreensão deste método utilizando o exemplo mais simples possível: uma única celular na qual aplicada uma corrente e se é medida por um voltímetro. A Figura 10 mostra o exemplo descrito.

Figura 10 – Modelo de impedância de uma célula de origem biológica, representação simbólica da estrutura da célula (a) e representação em circuito equivalente, onde I_a é a fonte de corrente e V_m é o medidor de tensão (b).



Fonte: Autor

Como apresentado previamente, sabe-se que para amostras biológicas, apenas os únicos fenômenos que são relevantes para sistemas biológicos se comportam como resistores comuns ou capacitores.

Equaciona-se o circuito observado na Figura 10 para ilustrar a capacidade da espectroscopia para descrever materiais de maneira precisa.

$$Z(j\omega) = \frac{R_e(R_i + \frac{1}{j\omega C_m})}{R_e + (R_i \frac{1}{j\omega C_m})} \quad (8)$$

Vamos supor que o espectrômetro de impedância usado tem capacidades especiais e é capaz de aplicar frequências baixíssimas ($\omega \rightarrow 0$) e frequências tendendo a infinito ($\omega \rightarrow \infty$). Desta maneira teríamos as Equações 9 e 10.

$$\lim_{\omega \rightarrow \infty} Z(j\omega) = R_e \quad (9)$$

$$\lim_{\omega \rightarrow \infty} Z(j\omega) = \frac{R_e R_i}{R_e + R_i} \quad (10)$$

Observa-se que a resistência intracelular R_i praticamente não exerce influência sobre a leitura de impedância do tecido em baixas frequências. Apenas em altas frequências, no momento em que o campo elétrico é capaz de penetrar a célula, o resultado de impedância observado passa a contemplar os elementos resistivos intra e extracelulares: R_i e R_e .

2.5 CONFIGURAÇÕES DE ELETRODOS

Diferentes configurações de eletrodos podem ser utilizadas para diferentes objetivos dentro do campo da espectroscopia de impedância elétrica. Nestes capítulos serão vistos os dois métodos mais populares e os dois utilizados nas publicações envolvidas com este trabalho.

O trabalho de Espectroscopia de Impedância Elétrica é um que demanda muita precisão e uma grande atenção para a correção de erros causados pelo funcionamento do equipamento em altas frequências. Problemas de queda de tensão em eletrodos podem significativamente danificar uma leitura correta de bioimpedância. Isso ocorre devido a capacitâncias parasitas associadas ao sistema devido às altas frequências.

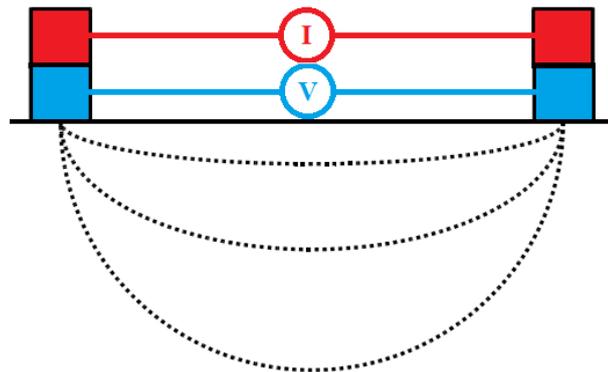
2.5.1 Método Bipolar

Utilizando o método bipolar (também conhecido como método a dois fios) obtemos uma leitura um tanto rudimentar da EIE de um tecido biológico, uma vez que a leitura obtida pelo espectrômetro de impedância será originada não apenas da impedância da amostra (Z_a), mas também contará com as impedâncias geradas nas interfaces de conexão dos eletrodos com o material, sendo que o resultado final observado pode ser descrito como a soma da impedância do tecido com a soma das duas interfaces ($Z_{(i1)}$ e $Z_{(i2)}$), originando na equação da impedância total medida (Z_{total}):

$$Z_{total} = Z_a + Z_{(i1)} + Z_{(i2)} \quad (11)$$

Um modelo esquemático de ligação bipolar pode ser observado na Figura 11, é possível verificar que, devido ao compartilhamento do mesmo eletrodo pela medição em tensão e da injeção em corrente, ocorre a associação em série das impedâncias de interface e da impedância da amostra, conforme descrito na Equação 11 (BRAGOS et al., 2006).

Figura 11 – Esquemático da configuração bipolar, onde a linha preta representa a interface eletrodo-amostra, o elemento em vermelho representa a injeção em corrente enquanto o elemento azul representa a medição em tensão.



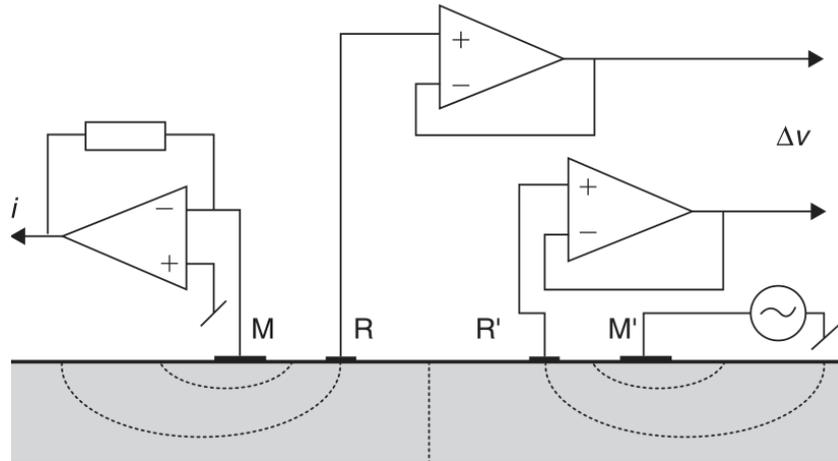
Fonte: Autor

Deve-se lembrar que este é o método mais simples para a aquisição de dados de espectroscopia de impedância elétrica e possui sérios comprometimentos quanto a qualidade do resultado obtido devido a resistividade relativamente alta dos eletrodos usado e a impossibilidade de utilizar um circuito compensador. (ÅBERG, 2004) Apesar destes pontos negativos, existem situações onde o método bipolar pode ser utilizado com sucesso: no caso da amostra possuir garantidamente alta impedância (se comparado com a impedância dos cabos) e quando se pode garantir uma interface altamente condutiva (normalmente através da aplicação de géis condutivos em abundância).

2.5.2 Método tetrapolar

A medição a 4 fios (ou tetrapolar) praticamente anula todos os defeitos observados no método a dois fios apresentado anteriormente, uma vez que faz uso de mais dois eletrodos que serão utilizados como elementos compensadores, subtraindo com precisão as medições indesejadas obtidas nas interfaces e originadas dos condutores internos do equipamento.

Figura 12 – Sistema tetrapolar em uma amostra in-vivo, linhas equipotenciais são tracejadas. As posições de R e R' determinam a extensão da medição do tecido, enquanto os eletrodos M e M' adquirem as medidas de impedância.



Fonte: (GRIMNES; MARTINSEN, 2006)

Pode-se observar que na Figura 12, que os dois elementos R' e R passam por amplificação e juntos constituem uma Δv . Enquanto isso, a aplicação de corrente é feita pelo eletrodo M' e a leitura é feita por M.

Ao utilizar um par de eletrodos para injeção de corrente e outro par para a medição de tensão, a impedância medida está diretamente, e tão somente, relacionada com a amostra em estudo (BRAGOS et al., 2006). Para isso, a fonte de corrente deve ser balanceada com altíssima impedância de saída e o medidor de tensão deve ter uma impedância de entrada extremamente alta na faixa de frequência de operação (MORCELLES et al., 2017).

Este método é especialmente vantajoso quando aplicado na medição de tecidos biológicos, uma vez que estes tecidos tendem a apresentar alto grau de variação de impedância dependendo da frequência de excitação aplicada. Por este motivo, os experimentos realizados nesta dissertação se utilizaram do método tetrapolar para realizar todas as medições. De maneira geral é possível dizer que o método tetrapolar é superior ao método bipolar apresentado em todos os sentidos, exceto em situações excepcionais onde a simplicidade da eletrônica é um fator de grande importância para o projeto.

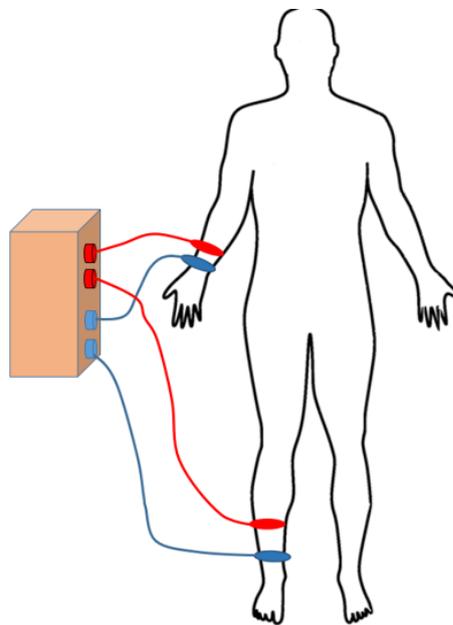
2.6 EXEMPLOS DE APLICAÇÕES DE ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA EM MATERIAIS BIOLÓGICOS

A técnica da Espectroscopia de Impedância Elétrica apresenta tamanha versatilidade em áreas como a medicina, pois o seu objetivo final é descrever e caracterizar uma dada amostra e, por vezes, comparará-la com uma amostra saudável (ou um padrão ouro). A espectroscopia de impedância elétrica ao trabalhar com uma larga faixa de frequências é capaz de investigar as características estruturais de uma amostra com precisão (MCDONALD et al., 1987).

Além destas características, a espectroscopia de impedância elétrica é comumente não invasiva ou minimamente invasiva, esta característica é relevante nos estudos de amostras sensíveis ou para estudos *in-vivo* onde a prioridade é a conservação da integridade da amostra biológica (RAMASAMY et al., 2009).

Uma das aplicações mais comuns relacionadas a EIE é a análise de composição corporal (BERA, 2014). Eletrodos nas mãos e pés garantem que a corrente inserida percorre todo o corpo do paciente. Este tipo de análise quando multi-frequencial é capaz de analisar o corpo do indivíduo separando o mesmo em percentuais de minerais, gorduras, proteínas, carboidratos e água (ARMSTRONG et al., 1997). Na Figura 13 é possível observar a configuração a 4 vias mais utilizada para a aplicação.

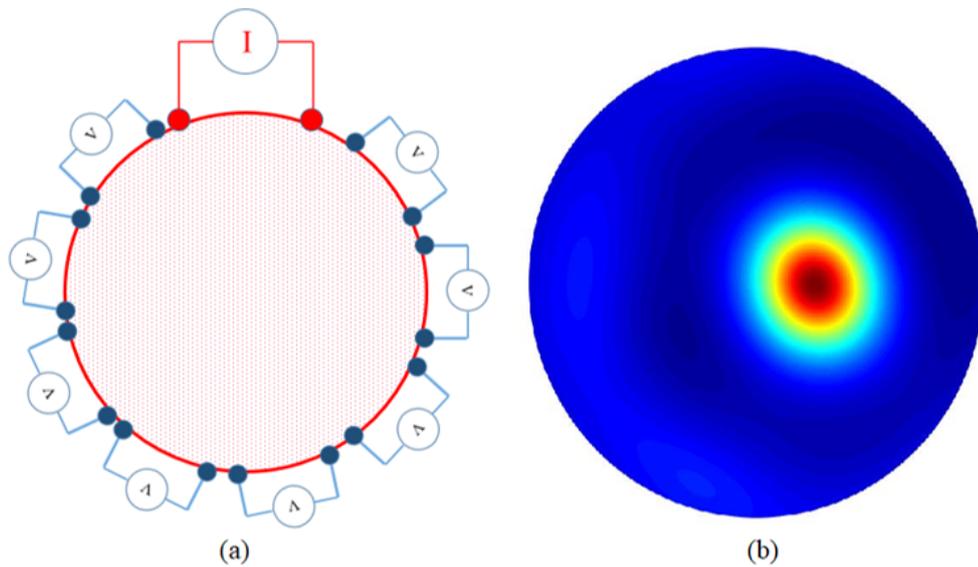
Figura 13 – Configuração de eletrodos para medição de composição corporal.



Fonte: Autor

Outra aplicação popular para esta tecnologia é o desenvolvimento de equipamentos de diagnóstico por imagem, como é o caso do Tomógrafo por Impedância Elétrica (TIE). Este tipo de tomógrafo oferece uma alternativa àqueles que usam raio-X e ressonância magnética, muito comuns nos hospitais e clínicas. O TIE apresenta um menor custo e uma menor resolução de imagem comparado ao modelo por ressonância. No entanto, é o único equipamento de imageamento incorporado a uma unidade de tratamento intensivo (BROWN, 2003).

Figura 14 – Disposição dos eletrodos de injeção e medição em um tomógrafo de impedância elétrica ao longo de um volume alvo (a) e a imagem reconstruída de um objeto no interior do volume (b).

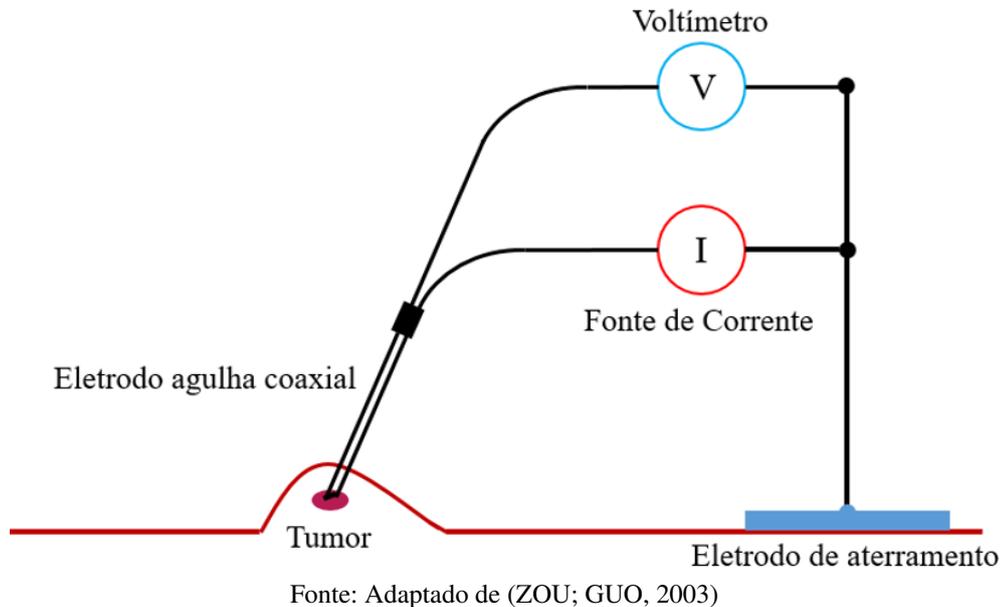


Fonte: Adaptado de (HAMILTON et al., 2019).

Este opera injetando-se uma corrente elétrica em vários canais de eletrodos para que várias tensões sejam medidas e, assim, uma imagem de reconstrução possa ser gerada, como mostra a Figura 14, item a. Em outras palavras, o sistema TIE é multiplexado de maneira a alternar os pontos de injeção de corrente, criando uma matriz com as leituras de impedância do interior do material sob estudo (GRANOT et al., 2009). A matriz é processada digitalmente a fim de apresentar os resultados obtidos em forma de imagem, utilizando uma escala de cores para representar a densidade do material encontrado no seu interior, como mostrado na Figura 14, item b (RABBANI; KABIR, 1991).

A detecção de diferentes tipos de tumores malignos também podem ser feitos por meio de equipamentos Espectroscopia de Impedância Elétrica. Através da análise da lesão com eletrodos localizados na superfície da amostra, o espectro de impedância elétrica do tecido possibilita a diferenciação de um tecido sadio (ou sejam sem células neoplásicas) do tecido tumoral (ZOU; GUO, 2003).

Figura 15 – Disposição dos eletrodos de injeção e medição para a detecção de tumores malignos.



A detecção de tumores malignos, exemplificado na Figura 15, é apresentado como uma alternativa ao método da biópsia. A utilização de um eletrodo tipo agulha coaxial, por exemplo, permite que a medição seja realizada de maneira minimamente invasiva, evitando o trauma da coleta de amostra para biópsia (MANKIN; MANKIN; SIMON, 1996). A normalização de potencial é realizada através de um eletrodo do tipo placa, fazendo conexão elétrica com a superfície da pele do paciente.

Dispositivos como estes também são usados no auxílio a detecção de câncer de mama (CHOI et al., 2007), colo de útero (BARROW; WU, 2007) e melanomas de pele (ÅBERG, 2004) em tempo real, agilizando o diagnóstico e tratamento da doença.

Outras aplicações que tem ganho popularidade nos últimos anos são a detecção de fraturas ósseas (DELL'OSA; FELICE; SIMINI, 2019), monitoramento de sinais fisiológicos (tais como, ciclo cardíaco e respiratório) (MIN; OLLMAR; GERSING, 2003), monitoramento de culturas bacterianas (SENEZ; VLANDAS; FOLLET, 2004) e o reconhecimento de movimentos físico corporais (ZHANG; XIAO; HARRISON, 2016).

3 CLASSIFICAÇÃO DE TECIDOS BIOLÓGICOS A PARTIR DA ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA E MÉTODOS DE REDUÇÃO DE DIMENSIONALIDADE

Métodos de classificação de medições de impedância elétrica em tecidos biológicos tem como função obter uma relação entre os valores numéricos do espectro de impedância da amostra e algum fator anatômico ou químico (sendo este dependente da análise em questão). Por exemplo, considerando a aplicação da identificação de lesões cancerosas em tecidos epiteliais, dados de espectroscopia são correlacionados com diferentes tipos de lesões, o resultado é a transformação da análise quantitativa dos dados de impedância em um resultado qualitativo, facilitando a interpretação dos dados (ÅBERG, 2004).

Métodos como LDA (*Linear Discriminant Analysis*), SIMCA (*Soft Independent Modeling of Class Analogy*) e ROC (*Receiver Operating Characteristics*) são alguns dos métodos mais bem reconhecidos e testados para classificação de dados biológicos a partir de dados obtidos por EIE (ABERG; NICANCER; OLLMAR, 2003).

A utilização de novos métodos computacionais como machine learning tem como função apresentar uma alternativa a estes métodos semi-empíricos. Os métodos mais comumente encontrados na bibliografia relevante são: Redes Neurais (ou redes neurais profundas, também chamadas de *Deep Learning Method*), SVMs (*Support Vector Machines*), *Random Decision Forests*, entre outros. Os métodos citados por nome neste parágrafo serão explorados detalhadamente ainda neste capítulo.

3.1 APLICAÇÕES DE MÉTODOS DE MACHINE LEARNING COM DADOS DE ESPECTROSCOPIA DE IMPEDÂNCIA EM MEDICINA, TECIDOS ANIMAIS E VEGETAIS.

Com a popularização de dispositivos computacionais com grande capacidade de lidar com quantidades massivas de informação, tornaram-se viáveis métodos computacionais que utilizavam de dados para alcançar respostas através de ajustes internos feitos pelo próprio algoritmo (MILLER; BLOTT et al., 1992). Tornou-se possível encontrar soluções mais precisas para problemas extremamente complexos, sendo um desses a detecção de anomalias em tecidos biológicos complexos através do uso de técnicas de Machine Learning em análises de padrão de imagem e outros métodos de descrição do tecido biológico, sendo um destes métodos a espectroscopia de impedância elétrica (RAHMAN et al., 2019).

Aplicações como a detecção de câncer de mama são relatadas em diversos artigos com resultados positivos (LEDERMAN et al., 2011; HELWAN; IDOKO; ABIYEV, 2017; DALIRI, 2015).

Aplicações clássicas como a tomografia por impedância elétrica que acarreta baixos custos ao hospital e funcionalidade elevada, tem sido popularizadas, enquanto os pesquisadores da área utilizam técnicas de Machine Learning para aperfeiçoar o diagnóstico por imagem conduzido através da EIS (MCDERMOTT et al., 2020; KŁOSOWSKI; RYMARCZYK, 2017;

SILTANEN; IDE, 2020).

Observando os tecidos vegetais, encontram-se aplicações como a estimativa de clorofila em algas (BASAK; WAHID; DINH, 2021), monitoramento de desidratação em diferentes espécies de plantas (BAR-ON; SHACHAM-DIAMAND, 2021), determinação de quantidade de nitrogênio em folhas (BASAK; WAHID; DINH, 2020), medição dos danos causados por congelamento em tubérculos (ZHANG; WILLISON, 1992), entre outros.

Já com tecidos biológicos animais se encontram concentradas no campo de qualidade de alimentos ou monitoramento veterinário. Observam-se aplicações para a determinação da qualidade de carnes (RIVOLA et al., 2021; ZHAO et al., 2017), a medição de biomassa associada a tipos de anelídeos parasitas (ANDERSON et al., 1999) e monitoramento de saúde canina (BRUGAROLAS et al., 2014).

3.2 FUNDAMENTOS DE MÉTODOS DE MACHINE LEARNING

Um sistema baseado em *machine learning* se trata, fundamentalmente, de uma sistema que tem a capacidade de mudar suas características internas de acordo com os dados que nele forem inseridos. Como o nome sugere, a aprendizagem é realizada pela própria estrutura do software (GOODFELLOW; BENGIO; COURVILLE, 2016).

A grande diferença entre *machine learning* e algoritmos comuns é que o primeiro é construído de maneira a ser capaz de compreender e aprender a realizar uma tarefa mudando suas características internas, enquanto o segundo é construído já sabendo realizar tal tarefa e uma vez que seu projeto é finalizado, este permanece sem mudanças até que em um segundo momento seja necessário fazer alterações no projeto original (NILSSON, 1996).

As duas tecnologias citadas possuem seus benefícios. Na maioria dos casos, não é necessário ou vantajoso utilizar métodos de *machine learning* para resolver uma grande parte dos problemas de engenharia. Mas em outros casos justifica-se a utilização do método.

Em tarefas onde não é claro quais partes dos dados de entrada são relevantes para a análise e até mesmo como estes dados se relacionam entre si. Métodos de *machine learning* são capazes de ajustar suas características internas para correlacionar dados que muitas vezes não são claros até mesmo para o autor do algoritmo, sendo muitas vezes este o ponto principal no emprego desta tecnologia (HAYKIN, 2004).

Considerando que o conceito de um equipamento moderno de medição de espectroscopia de impedância elétrica se baseia naturalmente na análise de dimensões elevadas (no que diz respeito às frequências de corrente aplicada a amostra), é natural que métodos de redução de dimensionalidade sejam de grande utilidade quando se faz necessária a simplificação ou redução de tempo de processamento deste tipo de informação.

3.3 PRINCIPAL COMPONENT ANALYSIS (PCA)

O método PCA é uma transformação linear ortogonal tal que seu resultado gera uma representação dos dados originais em um novo sistema de coordenadas. Será tratada neste capítulo a PCA com função de obter uma dimensionalidade reduzida dos dados originais, visto que existem outras aplicações para este método.

Portanto observando o objeto de estudo desta dissertação, o objetivo do PCA é reduzir a dimensionalidade e garantir no processo que o mínimo de informação seja perdida. O conceito básico desse método é a separação do dataset em duas partes: a parte estrutural e a parte residual. Na primeira estão contidas as informações enquanto na segunda encontram-se informações não contudentes à aplicação, que pela teoria seria chamado de ruído.

O algoritmo encontra componentes principais ou *Principal Components* (PCs) que descreve algum comportamento importante do dataset original. Cada PC consiste de alguns elementos básicos: um set de pontuações (scores), representados por t_a , e carregamentos (loadings), representados por p_a .

De maneira que a decomposição formal da PCA é:

$$X = 1\bar{x} \sum_{a=1}^A t_a p'_a + E = 1\bar{x} + TP' + E \quad (12)$$

3.4 LOCALLY LINEAR EMBEDDING (LLE)

Este método, inicialmente proposto como uma alternativa em relação a métodos de PCA e mMDS, opera com base no mapeamento de dados de elevada dimensionalidade para vetores com baixa dimensionalidade. Sua operação se baseia na identificação de setores nos dados de entrada que possuam comportamento linear, apesar da operação não-linear do sistema como um todo.

Descrevendo as operações realizadas para a aplicação do LLE:

- Computação dos pontos vizinhos de cada valor na matriz de entrada X_i .
- Computação dos pesos W_{ij} atribuídos à reconstrução de cada ponto de X_i , minimizando a equação de custo:

$$\Phi(Y) = \sum_i |Y_i - \sum W_{ij} Y_j|^2 \quad (13)$$

- Computação do vetor de saída Y_i , conforme reconstruído a partir dos pesos W com base nos menores valores diferentes de zero encontrados.

De maneira compreensiva, o método busca a incorporação de elementos não lineares uma vez que não se faz necessário a estimar a distância de objetos distantes (falando em distância

euclidiana). A partir disto o método busca reestruturar uma matriz não linear utilizando ajustes lineares locais.

4 TRABALHOS DESENVOLVIDOS

Neste capítulo serão apresentados os materiais e métodos utilizados ou criados para realizar a aquisição dos dados de EIE dos tecidos biológicos, padronização e automatização da coleta dos dados brutos para o software que organiza e armazena as informações que serão levadas para classificação ou redução de dimensionalidade.

4.1 AQUISIÇÃO DE DADOS DE ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA.

A aquisição dos dados de EIE para todos os experimentos desenvolvidos durante a pesquisa foi realizada através do analisador de espectro HF2LI fabricado pela Zurich Instruments, contando com um amplificador de corrente auxiliar HF2. Aquisição foi feita através do mesmo eletrodo invasivo, desenvolvido com a finalidade de padronizar a aquisição de dados de EIE em tecidos biológicos (as especificações deste serão descritas em detalhe na próxima seção deste capítulo).

Figura 16 – Analisador de Impedância Zurich HF2.



Fonte: Zurich Instruments

Apesar do modelo do analisador de impedância possibilitar excitação do tecido em frequências de até 50MHz , a faixa de frequência analisada para análise das amostras foi definida de 400Hz até 1MHz . Esta faixa foi definida com base nos seguintes argumentos:

- Publicações com objetos de estudo similares relatam maior densidade de informação dos dados obtidos em faixas de frequência similares para amostras biológicas.
- Foi observado tanto na bibliografia relevante quanto experimentalmente que esta faixa de frequência evita problemas com indutâncias e capacitâncias introduzidas pelo cabeamento que liga o sistema às amostras.
- A faixa utilizada evita comportamento capacitivo associado à dificuldade de aterramento da amostra.
- Considerando que o objetivo final da pesquisa seria desenvolver um sistema de baixo custo, que fosse adaptável a aplicações móveis, a faixa de impedância ideal foi determi-

nada com função de evitar o maior número de problemas sem adicionar dificuldades ao operador quanto a montagem da amostra.

A aquisição dos dados escala em frequência em progressão logarítmica, gravando 200 pontos na varredura dos 400Hz a 1MHz . Este valor se mostrou experimentalmente suficiente, representando as variações de impedância de maneira contínua, com mínima perda de detalhes do comportamento de impedância complexa dos tecidos analisados. A quantidade de pontos analisados também viabilizou a coleta de uma maior quantidade de dados e, por consequência, a utilização de métodos de classificação como *Deep Learning* que se beneficia da coleta de dados em larga escala.

Excitação do tecido foi realizado em tensão, com valor pico-a-pico igual a 1V . Foi optado pela não utilização do filtro de remoção da componente harmônica da alimentação da eletrônica, uma vez que o equipamento traz um filtro projetado para alimentação em 50Hz , não sendo ideal para filtragem de harmônico da rede elétrica local.

Utilizou-se o sistema tetrapolar de aquisição, de modo a evitar a contribuição do cabeamento e problemas de conectividade. Considerando a possibilidade de amostras contendo líquidos ricos em eletrólitos livres e, portanto, resultantes de alta condutividade, concluiu-se que a contribuição de impedância da conectividade do equipamento poderia afetar significativamente a medição de algumas amostras, optando-se pela conexão tetrapolar.

4.2 ELETRODOS

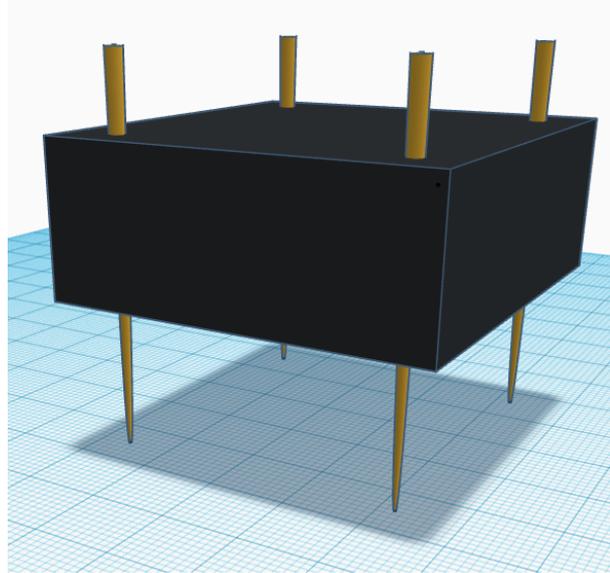
A conectividade do sistema de eletrodos tetrapolar foi feita através de cabos coaxiais com os contatos banhados a ouro.

Todos os quatro cabos foram conectados via *clamp* modelo jacaré aos eletrodos invasivos, com 4 agulhas de material condutivo banhado a ouro, dispostas formando um quadrado de forma equidistante.

Os quatro eletrodos a serem inseridos nas amostras possuem separação de 2 centímetros entre cada um. Os condutores são inseridos dentro do tecido da amostra, até que a parte plástica (feita do poliéster PLA) isolante encoste na amostra. Cada eletrodo garante uma inserção com 2 centímetros de profundidade. Tal dimensão foi escolhida para minimizar as contribuições do tecido externo da amostra (como as cascas dos vegetais utilizados no experimento).

A profundidade escolhida garante que as linhas de campo se concentrem no cerne do vegetal, garantindo consistência na repetição das leituras, um fator importante para as muitas aquisições necessárias para a utilização dos métodos de classificação escolhidos.

Figura 17 – Eletrodo invasivo utilizado para medições de espectroscopia de impedância elétrica em tecidos vegetais.



Fonte: Autoral

O gabarito plástico construído em PLA foi criado utilizando o software Autodesk Inventor e executado pela impressora 3D 3DMark (SIBAI, 2007). Este pode ser observado na Fig 17. Assim como as cavidades que acomodam os eletrodos feitos após a impressão, com função de maximizar a aderência dos eletrodos, dispensando a utilização de outros mecanismos de fixação.

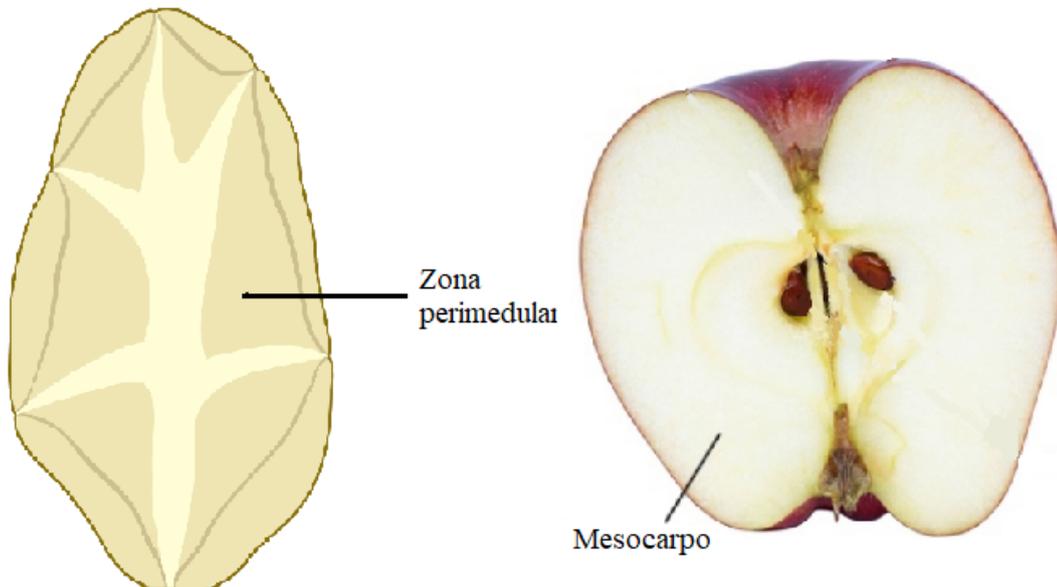
4.3 COLETA DE AMOSTRAS PARA CLASSIFICAÇÃO ENTRE ESPÉCIES

Utilizando duas espécies diferentes de vegetais, uma maçã comum (flor provinda de *Malus domestica*) e uma batata inglesa (*Solnnum tuberosum L.*). Extraiu-se das amostras, respectivamente, as regiões do mesocarpo e perimedulares, visto que estas regiões são embriologicamente similares (JANSSEN et al., 2008; CUTTER, 1978) e por serem as estruturas predominantes em ambas espécies, possibilitaram a coleta de um número suficiente de amostras para o treino da rede neural classificadora. Estas estruturas são demonstradas na Figura 18.

As amostras foram cortadas de maneira a acomodar apropriadamente os eletrodos (dimensionados de forma quadrada com 2cm de distância entre os polos) e de maneira a minimizar a dispersão das linhas de campo pelas beiradas do vegetal. Desta maneira o tamanho das amostras seguiu o padrão quadrado dos eletrodos, excedendo a distância entre os pontos de cada polo do eletrodo por duas vezes seu comprimento total. A amostra resultante dessa separação tem formato cúbico de no mínimo 4cm de largura, espessura e profundidade.

Amostras são mantidas em ambiente refrigerado de aproximadamente 7°C e retiradas apenas no momento da medição, evitando o ressecamento das faces externas das estruturas. Tempo de retirada do armazenamento refrigerado a medição é estimado em no máximo 30 minutos.

Figura 18 – (A) região extraída para medição na batata inglesa (zona perimedular) - a esquerda e (B) região extraída para medição na maçã comum (região do mesocarpo) - a direita



Fonte: Autoral

Utilizando duas espécies diferentes de vegetais, uma maçã comum (flor provinda de *Malus domestica*) e uma batata inglesa (*Solnnum tuberosum L.*). Extraiu-se das amostras, respectivamente, as regiões do mesocarpo e perimedulares, visto que estas regiões são embriologicamente similares (JANSSEN et al., 2008; CUTTER, 1978) e por serem as estruturas predominantes em ambas espécies, possibilitaram a coleta de um número suficiente de amostras para o treino da rede neural classificadora. Estas estruturas são demonstradas na Figura 18.

Ao total foram medidas 49 amostras retiradas da zona perimedular do tubérculo *Solnnum tuberosum L.* e mais 51 amostras da região do mesocarpo do fruto *Malus domestica*. As amostras foram medidas pelo analisador de impedância Zurich enquanto frescas, logo após cortadas, para garantir que não houvesse processo de ressecamento do vegetal exposto, buscando assim uma leitura de espectroscopia de impedância que fosse condizente com o vegetal em sua forma natural.

A medição realizada a 4 vias, utilizando o amplificador HF2TA, com tensão de excitação fixada em $10V_{pk}$ varrendo em frequência de $400Hz$ a $1MHz$. Utilizando o software proprietário da Zurich, salvou-se cada uma das 100 medições em formato *.csv*. Foi então escrito um código em Python para automatizar a leitura das 100 leituras, e organizá-las de modo que estivessem formatadas para o processo de treinamento da rede neural. Foram utilizadas as bibliotecas Pandas, Glob e Numpy. O código completo pode ser observado no Anexo A.

A rede neural (ou rede neural profunda) foi construída na linguagem Python, utilizando a biblioteca scikit-learn, formada por uma camada de entrada de 200 (número de pontos obtido para cada medição de EIE), 5 camadas ocultas de processamento e apenas duas saídas na última camada. O solver utilizado para otimização dos pesos associados aos neurônios individuais

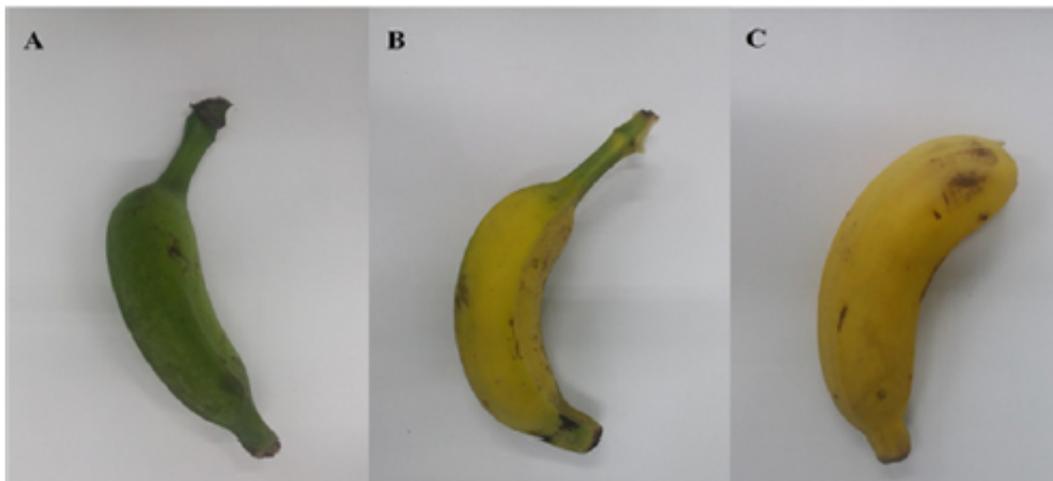
foi o L-BFGS(em português, algoritmo de Broyden–Fletcher–Goldfarb–Shanno de memória limitada),enquanto para a função de ativação dos neurons se usou a ReLU (em português, unidade linear retificada). A taxa de aprendizagem por ciclo ficou determinada em 0,0001. Cada ciclo de treinamento foi determinado a passar por 200 iterações nos sets de treinamento.

4.4 COLETA DE AMOSTRAS PARA CLASSIFICAÇÃO INTRA ESPÉCIES

A coleta das amostras utilizadas nesta publicação se realizou de maneira menos metódica que a primeira. Uma vez que o objetivo do projeto era realizar a medição em amostras não preparadas, estocadas em padrão comercial e não armazenadas em condições refrigeradas de forma a substituir a inspeção visual normalmente aplicada para a determinação do grau de maturidade do vegetal.

Conforme citado, o eletrodo desenvolvido e descrito anteriormente foi reutilizado para este experimento. Medições utilizando eletrodos mais profundos e com geometria aparentemente mais adequadas para a espécie de vegetal da amostra foram testadas, mas não resultaram em diferenças significativas de leitura de EIE. Portanto, optou-se pela utilização do eletrodo especialmente desenvolvido ao decorrer deste trabalho de dissertação, com função de estabelecer uma padronização do processo de aquisição de sinais.

Figura 19 – Gráfico com base no método de Von-Loesecke para determinação de estágios de maturação de uma banana, sendo estes: A) Estágio 1, B) Estágio 4 e C) Estágio 6.



Fonte: Autoral

Comparando com o teste descrito previamente (referente a Publicação 1), é possível listar pontos que facilitariam a inspeção e alguns que a tornariam mais difícil do ponto de vista computacional:

- O fato de que a inspeção é baseada em vegetais de mesma espécie garante que a estrutura de um modo geral seja igual para todas as amostras, mudanças observadas são ocasionadas pela transferência de açúcares presentes na casca, que aos poucos vai sendo transferido

para o cerne do vegetal (acompanhado de água e eletrólitos livres) e gerando, portanto, leituras de EIE diferentes para cada estágio de maturação. Vale lembrar que por mais que essa diferença seja perceptível, não chega a ser a diferença entre duas espécies completamente diferentes.

- Pelos itens terem de ser testados imediatamente, com função de preservar a condição temporal de estágio de maturação, essa condição inviabiliza a retirada de um grande número de amostras em pouco tempo. Este fato por si próprio torna inviável a utilização de redes neurais profundas com treinamento supervisionado padrão, conforme utilizado no primeiro experimento descrito neste documento.

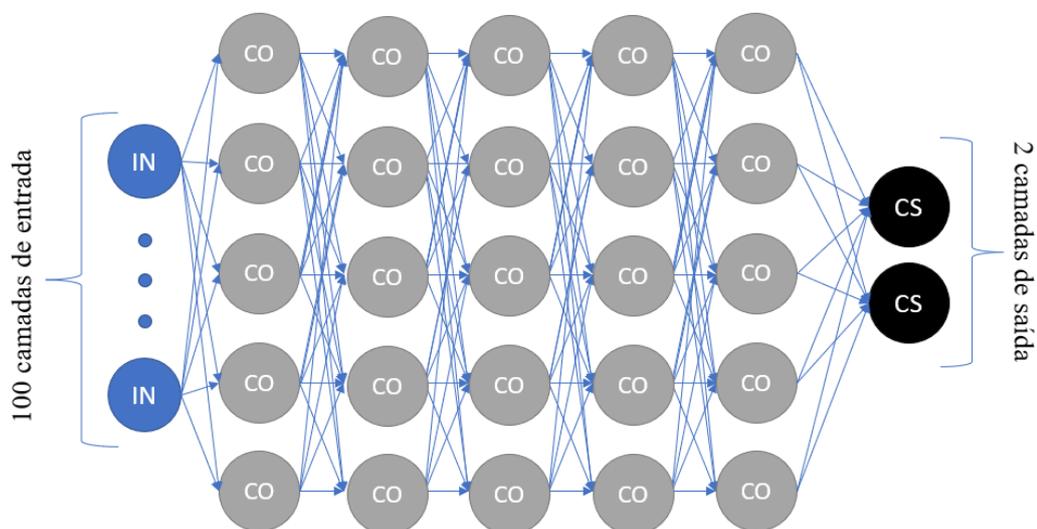
A coleta das amostras já possibilitou definir o método que será utilizado para fazer a classificação, uma vez que lidando com diferenças tão pequenas entre espécies e o fator tempo sendo de grande sensibilidade para leituras confiáveis, se optou por métodos menos completos, mas mais ágeis de classificação.

4.5 SISTEMA DE CLASSIFICAÇÃO POR MACHINE LEARNING

4.5.1 Rede Neural profunda

Rede neural foi dimensionada com auxílio da biblioteca *sci – kitlearn* dedicada ao emprego de técnicas de machine learning na linguagem Python (versão 3.x). Considerando as limitações em respeito a quantidade de amostras utilizadas no processo e número de pontos utilizados na aquisição de espectroscopia de impedância elétrica, a rede foi dimensionada de maneira a priorizar o aprendizado utilizando um número de amostras que poderiam ser adquiridas no tempo hábil de desenvolvimento desta dissertação.

Figura 20 – Rede Neural Profunda desenvolvida para o experimento de diferenciação entre as duas diferentes espécies de vegetais.



Fonte: Autoral

Considerando os limitantes descritos acima, observa-se a rede desenvolvida na Fig. 20, que conta com uma camada de entrada de 100 pontos (considerando a retirada da mesma quantidade de pontos na faixa de 400Hz a 1MHz de frequência de aplicação de corrente), 5 camadas ocultas de processamento totalmente interconectadas e apenas duas saídas (configurando formato de classificação binária).

Solver utilizado na otimização e ajuste dos pesos atribuídos a cada neurônio foi *L-BFGS*, aplicando função de ativação de unidade linear retificada (*ReLU*) com taxa de aprendizagem α determinado em 0,0001. Número máximo de iterações é limitado em 200 passadas.

4.5.2 *Support Vector Machine*

Dois tipos de classificadores SVM foram aplicados aos dados de espectroscopia de impedância elétrica, o primeiro por kernel linear, o segundo por kernel polinomial de terceiro grau.

O código utilizando a linguagem python para realizar a leitura e organização dos códigos em treinamento e teste são reaproveitados dos Artigos 1 e 2. Podendo ser conferido no Anexo A.

Pre processamento é realizado ainda em python com auxílio da biblioteca Pandas. Para este caso foi utilizado simplesmente um processo de normalização dos dados de entrada (forçando as variações a ficarem entre -1 e 1).

Esta etapa se mostrou importante para o bom resultado do SVM, uma vez que este pode classificar erroneamente caso existirem dados de espectroscopia que ocorram em valores muito altos ou muito baixos.

4.6 MÉTODOS PARA REDUÇÃO DE DIMENSIONALIDADE

Este experimento considera que com ajustes, os dados adquiridos em tecidos biológicos vegetais através da EIE deverão se beneficiar dos mesmos métodos algébricos que experimentos conduzidos em tecidos biológicos animais (especificamente humanos).

Deste modo, as matrizes de informação que são utilizadas para realizar o *benchmark* dos métodos abaixo expostos, são reutilizadas da Publicação 1. Desta maneira é possível comparar se os elementos pós

Os métodos definidos por popularidade em aplicações biológicas foram: *PCA - Principal Component Analysis*, *LLE - Locally Linear Embedding*, *mMDS - Metric Multidimensional Scaling* e *Isomaps*.

O algoritmo de PCA é aplicado à matriz armazenada utilizando decomposição de valores singulares e se utiliza o *solver* LAPACK (*Linear Algebra Package* através da biblioteca *sci-kit learn* em Python. A partir desta análise são mantidas dois espaços vetoriais distintos: um de 10 valores para validação da rede neural e outra com 3 vetores, para representação tridimensional.

Local Linear Embedding é treinado, novamente, para 10 e 3 componentes (o primeiro usado no *benchmarking* do método e o segundo para representação tridimensional). Considera-se

5 valores vizinhos, *solver* de autovalores é escolhido como denso junto com o LAPACK *solver* (via sci-kit learn).

Metric Multidimensional Scaling é aplicada para dois *outputs* de 10 e 3 componentes. Verbosidade é considerada 0 e roda a um máximo de 300 iterações. Convergência do algoritmo é estipulada quando o parâmetro de estresse chega a 0.001.

A configuração do método *Isomap* é similar à usada no método LLE. O termo de vizinhança é selecionado em 5, utilizando o *solver* do autovalor como denso e, novamente, o algoritmo LAPACK de *solver*.

Método	Componentes	Vizinhança	<i>solver</i>	Máx. Iter.
PCA	10,3	15	LAPACK	500
LLE	10,3	5	LAPACK (<i>dense</i>)	300
mMDS	10,3	5	LAPACK (<i>dense</i>)	300
Isomap	10,3	5	LAPACK (<i>dense</i>)	300

Tabela 1 – Configurações gerais de cada método de redução de dimensionalidade aplicado.

A Tabela 1 resume as configurações de cada método aplicado neste experimento. Lembrando que as componentes 10 e 3 são aplicadas paralelamente, sendo a primeira o modelo de referência, onde os testes de velocidade e *benchmarks* de precisão são executados para determinação do ranking de métodos. O segundo valor será utilizado na seção de resultados para realizar a representação gráfica de cada método e ilustrar o funcionamento do método numérico.

5 RESULTADOS E DISCUSSÕES

5.1 DIFERENCIAÇÃO DE ESTRUTURAS BIOLÓGICAS DE DIFERENTES ESPÉCIES

O objetivo do primeiro trabalho realizado ao longo dos anos desta dissertação tem como função básica confirmar a viabilidade de métodos de machine learning na substituição dos métodos empíricos e semi-empíricos usualmente aplicados à tarefa de classificação de tecidos biológicos.

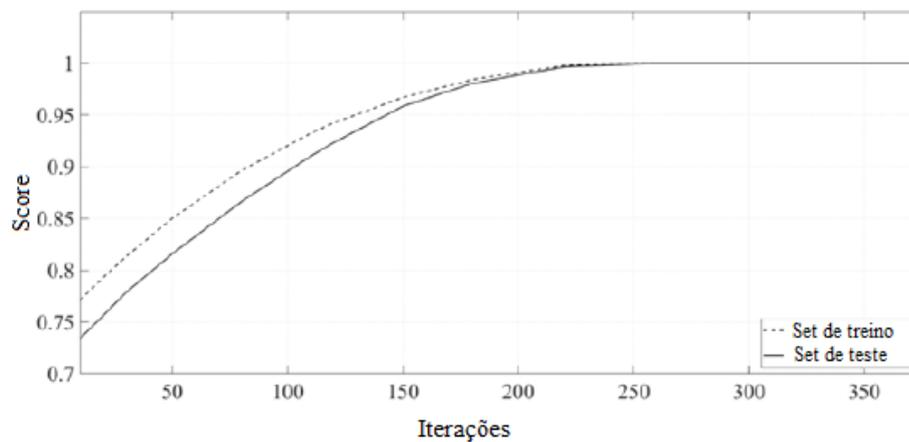
É evidente que a escolha dos vegetais utilizados na comparação são diferenciáveis até ao olho nu, até mesmo considerando que foram escolhidos a serem os mais semelhantes em aparência. O caso observado com as medidas de espectroscopia de impedância elétrica é que estas amostras, apesar de visualmente similares, possuem estruturas bastante diferentes.

5.1.1 Resultados

A rede neural de baixa complexidade foi treinada com os 80 dados de treinamento (separando 80 para o primeiro *set* de teste).

No segundo ciclo de treinamento, que consiste de 200 iterações cada, a rede neural atinge 100% de precisão tanto no dataset de treinamento quanto no dataset de teste. O processo de treinamento foi completado em $223 \pm 12ms$ e é parado exatamente na iteração 250, como demonstrado na Figura 21.

Figura 21 – Curva de aprendizado obtida durante o treinamento da rede neural classificadora.



Fonte: Autoral

Figura 22 – Matriz confusão do processo de classificação por rede neural, mostrando em A) o dataset separado apenas para o treino, em B) o dataset separado apenas para teste e em C) o dataset completo.

		a) Dados de Treinamento		b) Dados de Teste		c) Dataset completo	
		Maçã	Batata	Maçã	Batata	Maçã	Batata
Maçã	Maçã	38	0	13	0	51	0
	Batata	0	37	0	12	0	49

Fonte: Autoral

É possível observar este resultado através da matriz confusão, apresentada na Figura 22. A rede não resulta em nenhum erro na tarefa de classificação

5.1.2 Discussões

Como prova de conceito, é possível dizer que o projeto demonstrou com sucesso o objetivo proposto: redes neurais são capazes de realizar satisfatoriamente a tarefa de diferenciar ou classificar dados de espectroscopia de impedância elétrica, tarefa normalmente delegada aos métodos empíricos ou semi empíricos discutidos previamente.

Alguns elementos do projeto apontam para a validade desta configuração para aplicações ainda mais complexas. Considerando que a rede neural projetada seria facilmente expansível (adicionando mais camadas interconectadas), que não houve normalização dos dados inseridos na rede, que esta obteve 100% de precisão em sua segunda rodada de treinamento (podendo até dizer que o tempo de treinamento foi mínimo) e que o número de amostras (50 de cada tecido) é um valor considerável, mas está longe do ideal ao se tratar do treinamento de redes neurais.

Deste modo, segue-se para a aplicação 2, que buscará forçar um pouco mais a tecnologia, introduzindo alguns elementos mais complexos de serem reconhecidos.

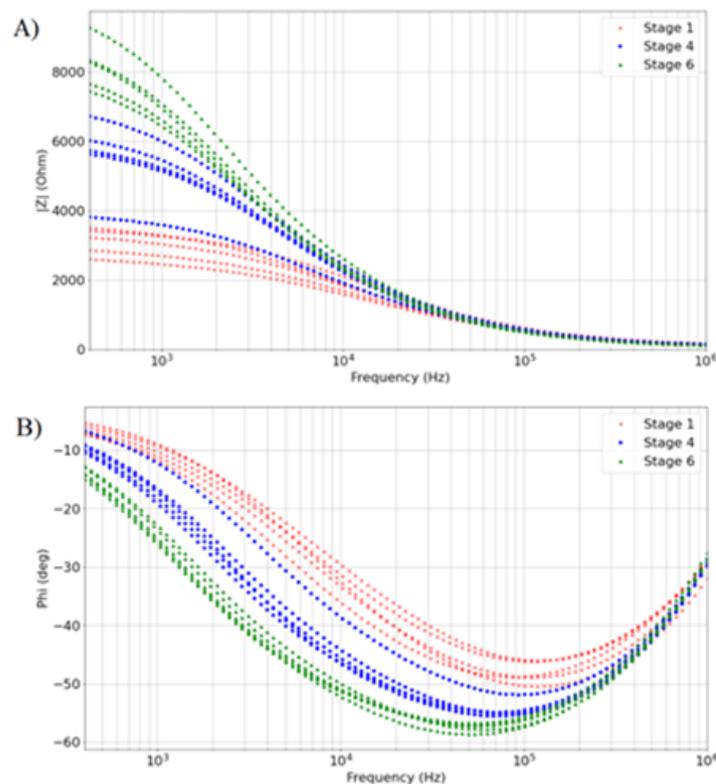
5.2 CLASSIFICAÇÃO DE ESTÁGIO DE MATURAÇÃO INTRA ESPÉCIES

Nesta publicação, foi buscada uma aplicação mais difícil de classificação a ser realizada pela ferramenta de machine learning. Conforme comentado, aqui optou-se pelo uso de um SVM e não uma rede neural. As explicações sobre isso já estão presentes na seção de metodologia. Como explicado nos capítulos de embase teórico, a utilização de uma menor quantidade de amostras poderia dificultar o processo de aprendizagem de uma rede neural, neste sentido foi optado por utilizar um SVM classificador para a tarefa.

5.2.1 Resultados

É possível observar Diretamente nas Figuras 23 A e B que é possível verificar visualmente as curvas com comportamentos diferentes (atribuídas a estágios de maturação diferentes). Novamente, este tipo de resultado sugere que o SVM que será utilizado para realizar a classificação terá pouca dificuldade em diferenciar um estágio do outro.

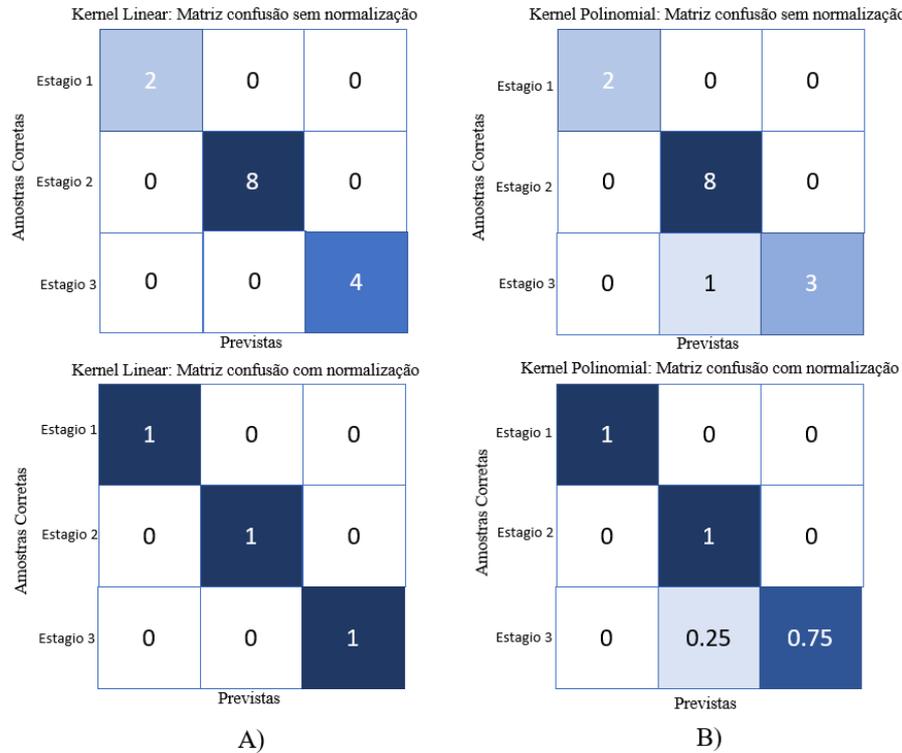
Figura 23 – A) valores de Módulo de impedância $|Z|$ para os três estágios de maturação. B) valores de ângulo Phi para os três estágios de maturação.



Fonte: Autoral

Dois tipos de SVMs foram treinados para realizar a classificação, um SVM com kernel linear e outro SVM com kernel polinomial. Os resultados dos dois testes podem ser observados na Figura 24.

Figura 24 – A) Matriz confusão para o SVM com kernel linear, com e sem normalização (cima e baixo). B) Matriz confusão para o SVM com kernel polinomial, com e sem normalização (cima e baixo).



Fonte: Autoral

Classificação por SVM de kernel polinomial alcança 92,85% de precisão enquanto o SVM de kernel linear alcança a marca dos 100%.

5.2.2 Discussões

A alta confiabilidade dos métodos aplicados, aliados ao limitado acesso a grandes quantidades de amostras pode identificar uma possibilidade de que esta tecnologia seja viável para ambientes industriais alimentícios. O erro observado pelo SVM de kernel polinomial indica uma possível confusão entre duas frutas que estão muito próximas na própria escala Von Loescke. Isto é, há a possibilidade de que o único erro observado pelo sistema desenvolvido seja originado pela escala visual (que por natureza possui baixa confiabilidade).

5.3 COMPARAÇÃO DE MÉTODOS DE REDUÇÃO DE DIMENSIONALIDADE APLICADOS ESPECTROSCOPIA DE IMPEDÂNCIA ELÉTRICA DE TECIDOS BIOLÓGICOS

O objetivo desta publicação foi finalizar os estudos de espectroscopia de impedância elétrica em tecidos vegetais viabilizando seu uso em hardwares menos potentes (como vestíveis). Desta maneira foram elencados os métodos mais populares de redução de dimensionalidade segundo bibliografia, observando os que demonstraram maior capacidade de simplificar a fase

de processamento e treinamento de grandes quantidades de registros de espectroscopia de impedância elétrica preparando-os para processadores alinhados com as tecnologias emergentes de monitores de saúde vestível.

Para tal, como visto na seção de métodos, aplicaram-se os seguintes métodos de redução de dimensionalidade: PCA, LLE, mMDS, e Isomap.

5.3.1 Resultados

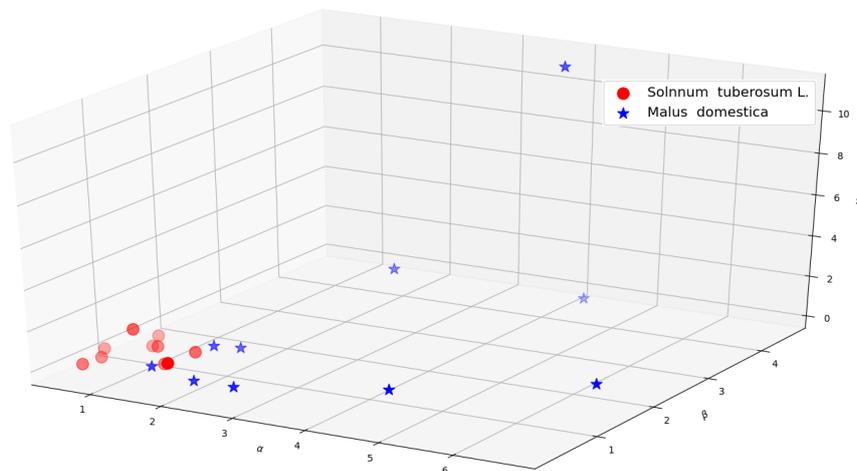
Os métodos são colocados em *ranking* para determinar o mais apropriado para a aplicação. Lembrando que a precisão demonstrada na tabela é relacionada a rede neural apresentada no artigo 1, ou seja, com precisão de 100% na classificação.

Método	Tempo de processamento [ms]	Score de classificação [%]
PCA	36,01	98,6
Isomap	64,01	89,8
LLE	73,01	88,2
mMDS	882,19	77,9
Sem aplicação de métodos	223	100

Tabela 2 – Resultados obtidos a partir dos métodos de redução de dimensionalidade.

Inicia-se a apresentação dos resultados pelo PCA, este foi testado com 1 dimensões, mas é representado na Figura 25 em três dimensões (conforme explicado na sessão de métodos), cada um dos modelos foi repetido para três dimensões para representação gráfica com função de visualização dos dados obtidos. Esta transformação é consideravelmente mais difícil de se observar a linearidade, mas pelo menos nesse caso podemos observar o alto *score* de classificação demonstrado pelo método PCA. As características do sinal original transformadas ficaram concentradas em uma pequena região do espaço tridimensional.

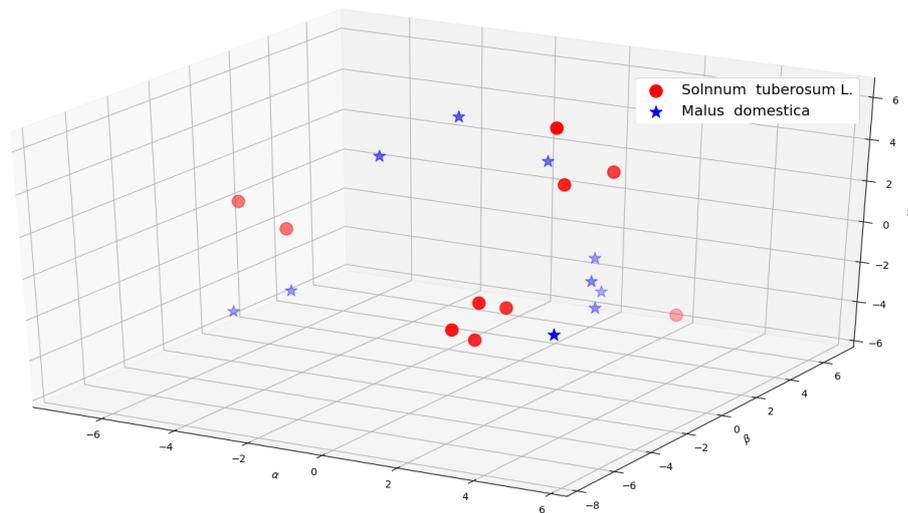
Figura 25 – Representação tridimensional dos dados de espectroscopia de impedância elétrica convertidos por PCA.



Fonte: Autoral

A representação de redução de dimensionalidade tridimensional pelo método LLE (Figura 26 também reafirma o resultado na classificação, pode-se observar que os dois modelos de amostra ficam bastante espalhados em seu plano tridimensional, informação que pode explicar a baixa performance do método.

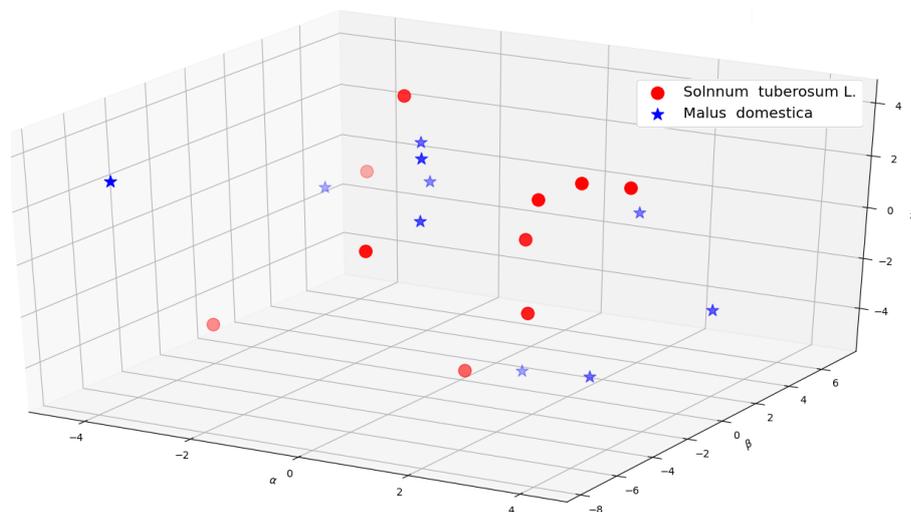
Figura 26 – Representação tridimensional dos dados de espectroscopia de impedância elétrica convertidos por LLE.



Fonte: Autoral

Na Figura 27, pode-se observar que há grande confusão na separação dos dois tecidos, não havendo aparentemente qualquer diferenciação em nenhum dos eixos. Apesar disso, o sistema garantiu boa separabilidade entre as coordenadas das amostras. Aqui há a possibilidade de implantar uma rede classificadora mais complexa em futuros trabalhos, mas claramente haverá problemas na classificação pela rede 'peso leve' que foi utilizada na aplicação.

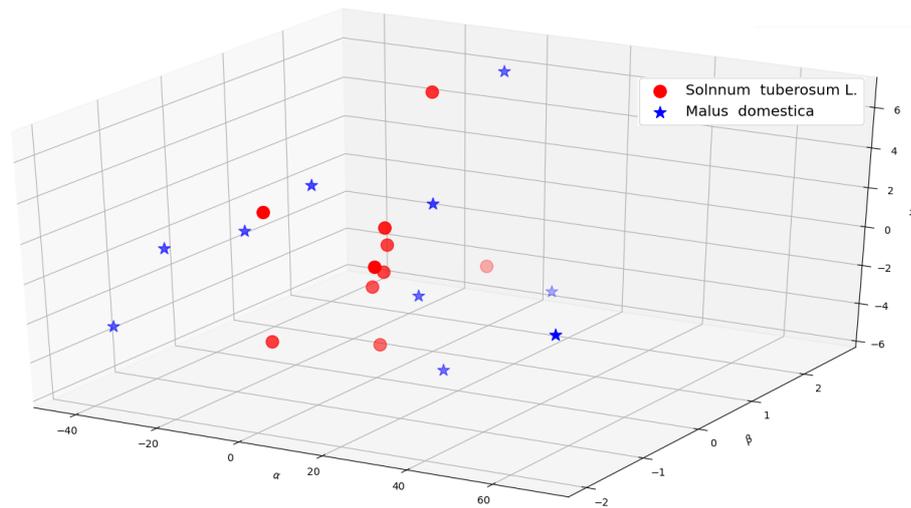
Figura 27 – Representação tridimensional dos dados de espectroscopia de impedância elétrica convertidos por mMDS.



Fonte: Autoral

Como se pode observar na Figura 28 e se esperava de acordo com a teoria por trás do método de Isomap, o sistema tem sucesso em identificar o centro de concentração de uma das amostras, enquanto as outras ficam dispersas em seu redor (com algumas classificações incorretas, evidentemente). Entretanto, continua havendo boa separabilidade.

Figura 28 – Representação tridimensional dos dados de espectroscopia de impedância elétrica convertidos por Isomap.



Fonte: Autoral

Pelas imagens tridimensionais representadas é possível ter algumas ideias sobre onde o algoritmo utilizado erra em sua redução de dimensionalidade. Fica claro que o PCA é o mais indicado para esta aplicação, visto que seu tempo de processamento é de longe o mais baixo e sua taxa de classificação é muito alta.

5.3.2 Discussões

A determinação do PCA como melhor método para essa situação pode se dizer que é em grande parte um trabalho de confirmação. Este método é utilizado praticamente em consenso na redução de dimensionalidade de dados não lineares (e muitas vezes relacionados a amostras de origem biológica).

A discrepância entre as imagens tridimensionais apresentadas em relação a concentração de amostras em uma região do gráfico e a separação dos demais exemplos indica que entre os métodos utilizados, apenas dois conseguiram extrair características relevantes das amostras: PCA e Isomaps.

Enquanto o método do LLE realizou uma separação de maneira parcialmente satisfatória, continuou muito atrás dos outros métodos testados. Podemos dizer que, com base nestes testes, o método de mMDS deve ser evitado para este tipo de aplicação.

5.4 DISCUSSÃO GERAL

Juntando os três artigos publicados e experimentos feitos, obtem-se um caminho claro de intenção com essa dissertação: em primeiro lugar buscou-se a tecnologia de inteligência artificial para realizar uma simples diferenciação entre tecidos biológicos bem distintos, validando este sistema como uma alternativa aos métodos clássicos empíricos e semi empíricos utilizados.

O segundo experimento levou essa ideia básica e a tornou aplicável ao ramo industrial, demonstrando que a espectroscopia de impedância aliada ao machine learning é um equipamento útil não apenas para sentidos científicos, mas também industrialmente. Este fator aumenta de grande maneira o interesse no desenvolvimento da tecnologia e possibilita recebimento de verba de uma gama de investidores para dar continuidade ao projeto.

O terceiro artigo publicado traz estes experimentos para uma situação aplicável a vestíveis, uma vez que viabiliza a utilização de métodos de machine learning em processadores destinados a tecnologias vestíveis.

Estes trabalhos em conjunto demonstra que existem alternativas que podem ser muito benéficas à classificação de espectroscopia de impedância elétrica e que atendem os seguintes pontos chave:

- Realização de testes sem a necessidade da interpretação de um operador por meio da elaboração de gráficos e esquemas de medição;
- Identificação de estruturas muito complexas ou diferenciação entre dois tecidos muito semelhantes, uma vez que o sistema de classificação por deep learning é expansível;
- A viabilidade da implantação de métodos que transformam este sistema que requer alto desempenho e grande poder de processamento para um sistema menor, rápido e leve, observando as tendências dos equipamentos wearable em biomédica.
- A possibilidade de reutilizar as estruturas estabelecidas nesta dissertação para testar também tecidos animais.

6 CONCLUSÕES E FUTUROS TRABALHOS

O projeto foi bem sucedido em cumprir os objetivos propostos: se formaram alternativas concretas e funcionais que possuem benefícios evidentes aos cientistas que as desenvolverão mais e principalmente para o usuário final que poderá fazer uso da imensa capacidade de sistemas que utilizam a espectroscopia de impedância elétrica como fonte de dados.

A ideia contemplada neste projeto fica principalmente na criação de padrões que poderão ser replicados em novos trabalhos, quando for possível utilizar medições mais longas (coleta de mais amostras) e até mesmo em situações onde o poder de processamento não for limitado (sendo possível a criação de uma rede neural mais robusta). Apesar das limitações de tempo e disponibilidade de tipos de amostras, o objetivo sempre foi buscar algo facilmente expansível para os próximos pesquisadores.

O trabalho futuro principal relacionado a esta dissertação é reutilizar os métodos já desenvolvidos para tecidos biológicos humanos específicos, realizando a detecção de tecidos reais que já seriam relevantes a aplicações médicas.

REFERÊNCIAS

- ÅBERG, Peter. **Skin cancer as seen by electrical impedance**. [S.l.]: Institutionen för laboratoriemedicin/Department of Laboratory Medicine, 2004. Citado 4 vezes nas páginas 26, 29, 33 e 34.
- ÅBERG, P; NICANCER, I; OLLMAR, S. Minimally invasive electrical impedance spectroscopy of skin exemplified by skin cancer assessments. In: IEEE. **Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE Cat. No. 03CH37439)**. [S.l.], 2003. v. 4, p. 3211–3214. Citado 3 vezes nas páginas 14, 25 e 34.
- AFSARIMANESH, Nasrin et al. Smart sensing system for the prognostic monitoring of bone health. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 16, n. 7, p. 976, 2016. Citado na página 14.
- ANDERSON, E. et al. **LAPACK Users' Guide**. Third. Philadelphia, Pennsylvania, USA: SIAM, 1999. Citado na página 35.
- ARMSTRONG, Lawrence E et al. Bioimpedance spectroscopy technique: intra-, extracellular, and total body water. **Medicine and science in sports and exercise**, v. 29, n. 12, p. 1657–1663, 1997. Citado na página 31.
- BAR-ON, Lee; SHACHAM-DIAMAND, Yosi. On the interpretation of four point impedance spectroscopy of plant dehydration monitoring. **IEEE Journal on Emerging and Selected Topics in Circuits and Systems**, IEEE, 2021. Citado na página 35.
- BARROW, Andrew J; WU, Sam M. Impedance measurements for cervical cancer diagnosis. **Gynecologic oncology**, Elsevier, v. 107, n. 1, p. S40–S43, 2007. Citado na página 33.
- BASAK, Rinku; WAHID, Khan; DINH, Anh. Determination of leaf nitrogen concentrations using electrical impedance spectroscopy in multiple crops. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 12, n. 3, p. 566, 2020. Citado na página 35.
- BASAK, Rinku; WAHID, Khan A; DINH, Anh. Estimation of the chlorophyll-a concentration of algae species using electrical impedance spectroscopy. **Water**, Multidisciplinary Digital Publishing Institute, v. 13, n. 9, p. 1223, 2021. Citado na página 35.
- BERA, Tushar Kanti. Bioelectrical impedance methods for noninvasive health monitoring: a review. **Journal of medical engineering**, Hindawi, v. 2014, 2014. Citado na página 31.
- BERTEMES-FILHO, Pedro. **Tissue characterisation using an impedance spectroscopy probe**. Tese (Doutorado) — University of Sheffield, 2002. Citado 2 vezes nas páginas 24 e 26.
- BRAGOS, R et al. Four versus two-electrode measurement strategies for cell growing and differentiation monitoring using electrical impedance spectroscopy. In: IEEE. **2006 International Conference of the IEEE Engineering in Medicine and Biology Society**. [S.l.], 2006. p. 2106–2109. Citado 2 vezes nas páginas 29 e 30.
- BRITANNICA, Encyclopædia. **Encyclopædia Britannica Online**. [S.l.]: Britannica Online, 2004. Citado na página 21.
- BROWN, Brian H. Electrical impedance tomography (eit): a review. **Journal of medical engineering & technology**, Taylor & Francis, v. 27, n. 3, p. 97–108, 2003. Citado na página 31.

BRUGAROLAS, Rita et al. Wearable wireless biophotonic and biopotential sensors for canine health monitoring. In: IEEE. **SENSORS, 2014 IEEE**. [S.l.], 2014. p. 2203–2206. Citado na página 35.

CADUFF, A et al. Non-invasive glucose monitoring in patients with diabetes: A novel system based on impedance spectroscopy. **Biosensors and Bioelectronics**, Elsevier, v. 22, n. 5, p. 598–604, 2006. Citado na página 14.

CHENEY, Margaret; ISAACSON, David; NEWELL, Jonathan C. Electrical impedance tomography. **SIAM review**, SIAM, v. 41, n. 1, p. 85–101, 1999. Citado na página 14.

CHOI, Myoung Hwan et al. A reconstruction algorithm for breast cancer imaging with electrical impedance tomography in mammography geometry. **IEEE transactions on biomedical engineering**, IEEE, v. 54, n. 4, p. 700–710, 2007. Citado na página 33.

CIUCCI, Francesco. Modeling electrochemical impedance spectroscopy. **Current Opinion in Electrochemistry**, Elsevier, v. 13, p. 132–139, 2019. Citado na página 14.

COLE, Kenneth S; COLE, Robert H. Dispersion and absorption in dielectrics i. alternating current characteristics. **The Journal of chemical physics**, American Institute of Physics, v. 9, n. 4, p. 341–351, 1941. Citado na página 20.

CUTTER, Elizabeth G. Structure and development of the potato plant. In: **The potato crop**. [S.l.]: Springer, 1978. p. 70–152. Citado 2 vezes nas páginas 40 e 41.

DALIRI, Mohammad Reza. Combining extreme learning machines using support vector machines for breast tissue classification. **Computer methods in biomechanics and biomedical engineering**, Taylor & Francis, v. 18, n. 2, p. 185–191, 2015. Citado na página 34.

DEAN, D A et al. Electrical impedance spectroscopy study of biological tissues. **Journal of electrostatics**, Elsevier, v. 66, n. 3-4, p. 165–177, 2008. ISSN 0304-3886. Citado na página 14.

DELL’OSA, Antonio Héctor; FELICE, Carmelo Jose; SIMINI, F. Bioimpedance and bone fracture detection: A state of the art. In: IOP PUBLISHING. **Journal of Physics: Conference Series**. [S.l.], 2019. v. 1272, n. 1, p. 012010. Citado na página 33.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Machine learning basics. **Deep learning**, MIT press, v. 1, p. 98–164, 2016. Citado na página 35.

GRANOT, Yair et al. In vivo imaging of irreversible electroporation by means of electrical impedance tomography. **Physics in Medicine & Biology**, IOP Publishing, v. 54, n. 16, p. 4927, 2009. Citado na página 32.

GRIMNES, Sverre; MARTINSEN, Ørjan G. Bioimpedance. **Wiley encyclopedia of biomedical engineering**, Wiley Online Library, 2006. Citado na página 30.

GUERMAZI, M; DERBEL, N; KANOUN, O. Fuzzy logic diagnosis of the in-vitro meat inspection based on impedance spectroscopy. In: IEEE. **2016 8th International Conference on Modelling, Identification and Control (ICMIC)**. [S.l.], 2016. p. 1076–1080. Citado na página 14.

HALTER, Ryan J et al. Electrical impedance spectroscopy of the human prostate. **IEEE Transactions on Biomedical Engineering**, IEEE, v. 54, n. 7, p. 1321–1327, 2007. ISSN 0018-9294. Citado na página 14.

- HAMILTON, Sarah J et al. Beltrami-net: domain-independent deep d-bar learning for absolute imaging with electrical impedance tomography (a-eit). **Physiological measurement**, IOP Publishing, v. 40, n. 7, p. 074002, 2019. Citado na página 32.
- HAYKIN, Simon. A comprehensive foundation. **Neural networks**, v. 2, n. 2004, p. 41, 2004. Citado na página 35.
- HEAVISIDE, Oliver. Xxiv. note on a paper on electromagnetic waves. **The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science**, Taylor & Francis, v. 25, n. 154, p. 202–210, 1888. Citado na página 19.
- HELWAN, Abdulkader; IDOKO, John Bush; ABIYEV, Rahib H. Machine learning techniques for classification of breast tissue. **Procedia computer science**, Elsevier, v. 120, p. 402–410, 2017. Citado na página 34.
- JANSSEN, Bart et al. Global gene expression analysis of apple fruit development from the floral bud to ripe fruit. **BMC plant biology**, v. 8, p. 16, 02 2008. Citado 2 vezes nas páginas 40 e 41.
- JR, Antonio Riul et al. Wine classification by taste sensors made from ultra-thin films and using neural networks. **Sensors and Actuators B: Chemical**, Elsevier, v. 98, n. 1, p. 77–82, 2004. Citado na página 14.
- KIM, Bong Seok et al. A method for analyzing electrical impedance spectroscopy data from breast cancer patients. **Physiological measurement**, IOP Publishing, v. 28, n. 7, p. S237, 2007. Citado na página 14.
- KŁOSOWSKI, Grzegorz; RYMARCZYK, Tomasz. Using neural networks and deep learning algorithms in electrical impedance tomography. **Informatyka, Automatyka, Pomiary w Gospodarce i Ochronie Środowiska**, v. 7, 2017. Citado 2 vezes nas páginas 34 e 35.
- KUMAR, G; BUCHHEIT, RG. Use of artificial neural network models to predict coated component life from short-term electrochemical impedance spectroscopy measurements. **Corrosion**, v. 64, n. 3, p. 241–254, 2008. Citado na página 14.
- LEDERMAN, Dror et al. Improving breast cancer risk stratification using resonance-frequency electrical impedance spectroscopy through fusion of multiple classifiers. **Annals of biomedical engineering**, Springer, v. 39, n. 3, p. 931–945, 2011. Citado 2 vezes nas páginas 14 e 34.
- LEVIE, R De. On the impedance of electrodes with rough interfaces. **Journal of electroanalytical chemistry and interfacial electrochemistry**, Elsevier, v. 261, n. 1, p. 1–9, 1989. Citado na página 19.
- MACDONALD, J Ross. **Impedance spectroscopy**. [S.l.]: Wiley New York etc, 1987. v. 41. Citado na página 14.
- MACDONALD, J Ross; JOHNSON, William B. Fundamentals of impedance spectroscopy. **Impedance spectroscopy: theory, experiment, and applications**, Wiley Online Library, p. 1–26, 2005. Citado na página 19.
- MANKIN, Henry J; MANKIN, Carole J; SIMON, Michael A. The hazards of the biopsy, revisited. for the members of the musculoskeletal tumor society. **JBJS, LWW**, v. 78, n. 5, p. 656–63, 1996. Citado na página 33.

MARWALA, Tshilidzi. **Condition monitoring using computational intelligence methods: applications in mechanical and electrical systems**. [S.l.]: Springer Science & Business Media, 2012. Citado na página 14.

MCDERMOTT, Barry et al. Multi-frequency symmetry difference electrical impedance tomography with machine learning for human stroke diagnosis. **Physiological Measurement**, IOP Publishing, v. 41, n. 7, p. 075010, 2020. Citado 2 vezes nas páginas 34 e 35.

MCDONALD, J Ross et al. Impedance spectroscopy. **Encyclopedia of Physical Science and Technology**, Academic Press, v. 1, p. 11, 1987. Citado na página 30.

MILLER, AS; BLOTT, BH et al. Review of neural network applications in medical imaging and signal processing. **Medical and Biological Engineering and Computing**, Springer, v. 30, n. 5, p. 449–464, 1992. Citado na página 34.

MIN, Mart; OLLMAR, Stig; GERSING, Eberhard. Electrical impedance and cardiac monitoring-technology, potential and applications. **International Journal of Bioelectromagnetism**, v. 5, n. 1, p. 53–56, 2003. Citado na página 33.

MORCELLES, KF et al. Howland current source for high impedance load applications. **Review of Scientific Instruments**, AIP Publishing LLC, v. 88, n. 11, p. 114705, 2017. Citado na página 30.

NILSSON, Nils J. Introduction to machine learning. an early draft of a proposed textbook. Citeseer, 1996. Citado na página 35.

PLIQUETT, Uwe. Bioimpedance: a review for food processing. **Food engineering reviews**, Springer, v. 2, n. 2, p. 74–94, 2010. Citado na página 24.

RABBANI, KS; KABIR, AMBH. Studies on the effect of the third dimension on a two-dimensional electrical impedance tomography system. **Clinical Physics and Physiological Measurement**, IOP Publishing, v. 12, n. 4, p. 393, 1991. Citado na página 32.

RAHMAN, Sam Matiur et al. Ensemble-based machine learning algorithms for classifying breast tissue based on electrical impedance spectroscopy. In: SPRINGER. **International Conference on Applied Human Factors and Ergonomics**. [S.l.], 2019. p. 260–266. Citado na página 34.

RAMASAMY, Ramaraja P et al. Impedance spectroscopy as a tool for non-intrusive detection of extracellular mediators in microbial fuel cells. **Biotechnology and bioengineering**, Wiley Online Library, v. 104, n. 5, p. 882–891, 2009. Citado na página 31.

RANDLES, John Edward Brough. Kinetics of rapid electrode reactions. **Discussions of the faraday society**, Royal Society of Chemistry, v. 1, p. 11–19, 1947. Citado na página 19.

REEVES, RM. , JS Mattson, HB Mark Jr., HC MacDonald Jr.(Eds.) **Computers in Chemistry and Instrumentation, Vol. 2, Electrochemistry**, Dekker, New York (1972). [S.l.]: Elsevier, 1973. Citado na página 19.

RIVOLA, Maria et al. Bioimpedance data statistical modelling for food quality classification and prediction. In: IEEE. **2021 IEEE International Symposium on Circuits and Systems (ISCAS)**. [S.l.], 2021. p. 1–5. Citado na página 35.

- ROBERTSON, WD. The capacity of polarized platinum electrodes in hydrochloric acid. **Journal of The Electrochemical Society**, IOP Publishing, v. 100, n. 4, p. 194, 1953. Citado na página 19.
- SENEZ, V; VLANDAS, A; FOLLET, J. Impedance analysis of waterborne parasite infectivity. In: **4th Conference on Impedance-Based Cellular Assays**. [S.l.: s.n.], 2004. v. 96, p. 24–32. Citado na página 33.
- SIBAI, Fadi N. Performance analysis and workload characterization of the 3dmark05 benchmark on modern parallel computer platforms. **ACM SIGARCH Computer Architecture News**, ACM New York, NY, USA, v. 35, n. 3, p. 44–52, 2007. Citado na página 40.
- SILTANEN, Samuli; IDE, Takanori. Electrical impedance tomography, enclosure method and machine learning. In: IEEE. **2020 IEEE 30th International Workshop on Machine Learning for Signal Processing (MLSP)**. [S.l.], 2020. p. 1–6. Citado 2 vezes nas páginas 34 e 35.
- SMITH, Phillip H. Transmission line calculator. **Electronics**, v. 12, n. 1, p. 29–31, 1939. Citado na página 20.
- VARADE, Vaibhav et al. Probing disorder and transport properties in polypyrrole thin-film devices by impedance and raman spectroscopy. **Journal of Physics D: Applied Physics**, IOP Publishing, v. 46, n. 36, p. 365306, 2013. Citado na página 20.
- WU, Long; OGAWA, Yukiharu; TAGAWA, Akio. Electrical impedance spectroscopy analysis of eggplant pulp and effects of drying and freezing–thawing treatments on its impedance characteristics. **Journal of Food Engineering**, Elsevier, v. 87, n. 2, p. 274–280, 2008. ISSN 0260-8774. Citado na página 14.
- ZHANG, M.I.N.; WILLISON, J.H. Martin. Electrical impedance analysis in plant tissues: The effect of freeze-thaw injury on the electrical properties of potato tuber and carrot root tissues. **Canadian Journal of Plant Science**, v. 72, p. 545–553, 04 1992. Citado na página 35.
- ZHANG, Yang; XIAO, Robert; HARRISON, Chris. Advancing hand gesture recognition with high resolution electrical impedance tomography. In: **Proceedings of the 29th Annual Symposium on User Interface Software and Technology**. [S.l.: s.n.], 2016. p. 843–850. Citado na página 33.
- ZHAO, Xin 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**, Hindawi, v. 2017, 2017. Citado na página 35.
- ZOU, Y; GUO, Z. A review of electrical impedance techniques for breast cancer detection. **Medical engineering & physics**, Elsevier, v. 25, n. 2, p. 79–90, 2003. Citado 2 vezes nas páginas 32 e 33.
- ZWANZIG, Robert. Time-correlation functions and transport coefficients in statistical mechanics. **Annual Review of Physical Chemistry**, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 16, n. 1, p. 67–102, 1965. Citado na página 19.

APÊNDICE A – PUBLICAÇÃO 1

APÊNDICE B – PUBLICAÇÃO 2

APÊNDICE C – PUBLICAÇÃO 3

**ANEXO A – CÓDIGO PYTHON PARA AUTOMATIZAÇÃO DAS MÚLTIPLAS
LEITURAS DOS ARQUIVOS .CSV GERADOS PELO ANALISADOR DE
IMPEDÂNCIA.**

```

import pandas as pd
import glob
import numpy as np

frame_b=pd.DataFrame()
frame_m=pd.DataFrame()

i=0
for file_name in glob.glob('C:/Users/Macas/*/'+ '*Data.csv'):
    x_st=np.hstack((np.transpose(pd.read_csv(file_name ,
    header=None, usecols =[7]).to_numpy()),
    np.transpose(pd.read_csv(file_name , header=None ,
    usecols =[8]).to_numpy()))),
    new_data=pd.DataFrame( data=x_st , index=[ i ])
    frame_b=pd.concat([ frame_b , new_data ], axis =0)
    i +=1

i=0
for file_name in glob.glob('C:/Users/Batatas/*/'+ '*Data.csv'):
    x_st=np.hstack((np.transpose(pd.read_csv(file_name ,
    header=None, usecols =[7]).to_numpy()),
    np.transpose(pd.read_csv(file_name ,
    header=None, usecols =[8]).to_numpy()))),
    new_data=pd.DataFrame( data=x_st , index=[ i ])
    frame_m=pd.concat([ frame_m , new_data ], axis =0)
    i +=1

```