UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

Projeto de Sensores de Micro-ondas para Predição e Classificação de Contaminantes Críticos em Água Usando o Método Baseado em Decision-Tree Support Vector Machine

Bruno Matias de Sousa

Orientador: Prof. Dr. Valdemir Praxedes da Silva Neto

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação da UFRN (área de concentração: Telecomunicações) como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica e de Computação.

Número de ordem PPgEEC: M699
Natal, RN, Outubro de 2025

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Sousa, Bruno Matias de.
Projeto de sensores de micro-ondas para predição e classificação de contaminantes críticos em água usando o método baseado em Decision-Tree Support Vector Machine / Bruno Matias de Sousa. - 2025.
155 f.: il.

Dissertação (mestrado) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Programa de Pós-graduação em Engenharia Elétrica e de Computação.
Orientação: Prof. Dr. Valdemir Praxedes da Silva Neto.

1. Sensor planar de micro-ondas - Dissertação. 2. Aprendizado de maquina - Dissertação. 3. Permissividade relativa de líquidos - Dissertação. 4. Sensoriamento de qualidade da água - Dissertação. I. Silva Neto, Valdemir Praxedes da. II. Título.

RN/UF/BCZM CDU 621

Elaborado por Jackeline dos Santos Pinheiro da Silva Maia Cavalcanti - CRB-15/317

Somewhere, something incredible is waiting to be known. - Carl Sagan

Agradecimentos

Em primeiro lugar agradeço a Deus pela força, sabedoria e orientação que me acompanharam ao longo desta jornada.

Aos meus pais, pelo incentivo, apoio e amor incondicional em toda minha vida acadêmica, tornando este trabalho um reflexo dos valores que me ensinaram. Obrigado por estarem sempre ao meu lado.

Um agradecimento especial ao meu orientador Valdemir Praxedes da Silva Neto, por seus conselhos, sua empatia e sua preciosa ajuda nos momentos mais difíceis deste trabalho. Um grande professor e orientador por compartilhar suas enormes habilidades técnicas e seu conhecimento do assunto, o que me incentivou a continuar e desbloqueou problemas que pareciam intransponíveis.

Um enorme agradecimento aos meus queridos amigos Levy, Vinicius, Edmilson, Itamar, Zé Lucas e Youssef, meus grandes incentivadores na vida e com quem passei momentos incríveis e mágicos no Brasil ou na França. Eu os admiro não apenas por suas habilidades técnicas, mas, acima de tudo, por suas qualidades humanas.

Agradecimento aos professores Adaildo D'Assunção por todo o apoio e ensinamentos passados ao longo da pós-graduação, os quais foram bastante construtivos, e aos demais doutores e mestres pelos conhecimentos repassados.

Aos colegas de laboratório José Garibaldi, Raquel Nunes, Maria Elizabeth e Sid pelo apoio e colaboração durante este período de aluno de PPgEEC.

Agradecimento as instituições da UFRN, CNPq e Capes as quais proporcionaram apoio financeiro e suporte físico, tornando possível a realização deste trabalho.

Por fim, todos professores que passaram na vida que foram essenciais até chegar aqui sou grato por cada aprendizado e por todo o apoio recebido.

Resumo

Este trabalho investiga o uso sensores planares de micro-ondas desenvolvidos em tecnologia de microfita, empregando topologias com Defect Ground Structure (DGS). Foram projetados e fabricados quatro dispositivos operando na faixa de 1 a 3 GHz, avaliados por meio de modelos de circuito equivalente, simulações eletromagnéticas no software ANSYS HFSS® e experimentos laboratoriais. São propostas duas novas topologias de sensores de micro-ondas para o sensoriamento de contaminantes críticos, como nitratos, fosfatos, amônio, glicose e condutividade em água. O sensor 01 atua na faixa ISM (Industrial, Scientific and Medical) na frequência de 2,45 GHz para concentrações de glicose acima de 50 mg/dL e na faixa de 2,22 a 2,24 GHz para concentrações de glicose de até 20 mg/dL. Já os modelos 02 e 03 realizam uma comparação com sensores de micro-ondas com estruturas Complementary Split-Ring Ressonator (CSRR) comumente encontradas na literatura, operando na faixa de comunicações móveis, com frequência de 1,5 GHz. O sensor 04 utiliza como estrutura DGS um capacitor interdigital (IDC), operando na frequência de ressonância de 2,0 GHz, dentro da banda S, utilizada para circuitos de radiofrequência. As propriedades dielétricas das amostras foram comparadas através da caracterização pelo método Nicolson-Ross-Weir (NRW), possibilitando a construção de um dataset a partir da resposta em frequência dos sensores. Com base nesses dados, foram aplicadas técnicas de aprendizado de máquina supervisionado em duas frentes: (i) regressão, para aproximar a permissividade relativa real em função da frequência, utilizando modelos como Regressão Linear, Regressão Polinomial, Multi-Layer Perceptron (MLP), Decision Tree e Random Forest; e (ii) classificação, para identificar contaminantes em diferentes concentrações de água destilada, nitrato e fosfato, empregando Regressão Logística, Decision Tree, Random Forest, Support Vector Machine (SVM), MLP, K-Nearest Neighbors (KNN) e Naive Bayes. A avaliação dos classificadores foi realizada por curvas Receiver Operating Characteristic (ROC), matriz de confusão e métricas como acurácia, precisão, F1-score e recall, com a validação cruzada pelos métodos Leave-One-Out, Stratified K-Fold e Repeated Stratified K-Fold. Os resultados mostraram boa concordância entre simulação e medições experimentais, além de elevada performance dos modelos de aprendizado de máquina, acima de 90%, na predição da permissividade e na classificação dos contaminantes. Além disso, a eficácia dos sensores foi comparada com trabalhos anteriores, evidenciando a confiabilidade e a eficiência dos dispositivos desenvolvidos. Por fim, este trabalho contribui significativamente para o avanço no estudo do monitoramento móvel de contaminantes em água na faixa de 1-3 GHz.

Palavras-chave: Sensor planar de micro-ondas, Aprendizado de maquina, Permissividade relativa de líquidos, Sensoriamento de qualidade da água.

Abstract

This work investigates the use of planar microwave sensors developed using microstrip technology and employing topologies based on Defect Ground Structure (DGS). Four devices operating in the 1-3 GHz frequency range were designed and fabricated, evaluated through equivalent circuit models, full-wave electromagnetic simulations using ANSYS HFSS®, and laboratory experiments. Two new microwave sensor topologies are proposed for the detection of critical contaminants such as nitrates, phosphates, ammonium, glucose, and electrical conductivity in water. Sensor 01 operates in the ISM (Industrial, Scientific, and Medical) band at 2.45 GHz for glucose concentrations above 50 mg/dL, and in the 2.22-2.24 GHz range for glucose concentrations up to 20 mg/dL. Sensors 02 and 03 provide a comparative study with microwave sensors based on Complementary Split-Ring Resonator (CSRR) structures commonly found in the literature, operating in the mobile communication band around 1.5 GHz. Sensor 04 employs an interdigital capacitor (IDC) as a DGS structure, resonating at 2.0 GHz within the S-band, typically used for radiofrequency circuits. The dielectric properties of the samples were characterized using the Nicolson-Ross-Weir (NRW) method, enabling the construction of a dataset derived from the sensors' frequency responses. Based on these data, supervised machine learning techniques were applied in two main approaches: (i) regression, to approximate the real part of the relative permittivity as a function of frequency, using models such as Linear Regression, Polynomial Regression, Multi-Layer Perceptron (MLP), Decision Tree, and Random Forest; and (ii) classification, to identify contaminants in different concentrations of distilled water, nitrate, and phosphate, employing Logistic Regression, Decision Tree, Random Forest, Support Vector Machine (SVM), MLP, K-Nearest Neighbors (KNN), and Naive Bayes algorithms. The classifiers were evaluated using Receiver Operating Characteristic (ROC) curves, confusion matrices, and performance metrics such as accuracy, precision, F1-score, and recall, with cross-validation performed through Leave-One-Out, Stratified K-Fold, and Repeated Stratified K-Fold methods. The results demonstrated strong agreement between simulation and experimental measurements, as well as high performance of the machine learning models exceeding 90% in both permittivity prediction and contaminant classification. Furthermore, the effectiveness of the proposed sensors was compared with previous studies, confirming the reliability and efficiency of the developed devices. Overall, this work makes a significant contribution to the advancement of mobile water contaminant monitoring in the 1-3 GHz frequency range.

Keywords: Planar microwave sensor, Machine learning, Relative permittivity of liquids, Water quality sensing.

Sumário

Sumário i

Lista de Figuras iv

Lista de Tabelas x

1 Introdução 1
- 1.1 Objetivos . . . 3
  - 1.1.1 Objetivo Geral . . . 3
  - 1.1.2 Objetivos Específicos . . . 3
- 1.2 Impacto Social . . . 4
- 1.3 Organização do texto . . . 4

Lista de Símbolos e Abreviaturas 1

2 Revisão de Literatura 5
- 2.1 Procedimentos Metodológicos . . . 5
- 2.2 Análise Bibliométrica . . . 7
- 2.3 Trabalhos Relacionados . . . 9
  - 2.3.1 Uma abordagem integrada para a detecção de nitrato e fosfato usando o ressoador de micro-ondas quadrado SRR . . . 9
  - 2.3.2 Detecção da concentração de açúcar e sal na água empregando um sensor de micro-ondas metamaterial ENZ . . . 11
  - 2.3.3 Aprimoramento da detecção de nitrogênio amoniacal em aplicações de qualidade da água usando ressoadores de anel dividido complementares: Uma comparação entre as configurações retangular e circular . . . 11
  - 2.3.4 Sensor de micro-ondas compacto baseado em CSRR para o controle do teor de água do solo . . . 12
  - 2.3.5 Sensor de micro-ondas não intrusivo multirressonante para identificação de líquidos . . . 13
  - 2.3.6 Sensores de Micro-ondas para Monitoramento In Situ de Metais Traço em Água Poluída . . . 14
  - 2.3.7 Sensor de Micro-ondas Inspirado em Metamaterial para Detectar a Concentração de Fosfato e Nitrato Mistos na Água . . . 16

2.3.8 Sensoriamento de Micro-ondas da Concentração de Amônia e Ferro na Água com Base em Resistor de Anel Duplo Complementar 17
2.3.9 1.3.9. Sensor Planar de Micro-ondas Sem Contato para Detecção de Água de Alta Salinidade Contendo NaCl, KCl, CaCl2, MgCl2 e Na2CO3 18
2.3.10 Sensoriamento de Micro-ondas da Qualidade da Água 19
2.3.11 Considerações Gerais 22

3 Referêncial Teórico **23**
3.1 Regressão vs Classificação 23
3.2 Pré-processamento de Dados 23
3.3 Modelos de Regressão 24
3.3.1 Regressão Linear 24
3.3.2 Regressão Polinomial 25
3.3.3 SGD Regressor 25
3.3.4 MLP Regressor 26
3.3.5 Decision Tree 26
3.3.6 Random Forest 27
3.3.7 Support Vector Regressor (SVR) 28
3.4 Modelos de Classificação 28
3.4.1 Regressão Logística 28
3.4.2 Decision Tree Classifier 29
3.4.3 Random Forest Classifier 29
3.4.4 K-Nearest Neighbors (KNN) 29
3.4.5 Gaussian Naive Bayes 30
3.4.6 MLP Classifier 31
3.4.7 Support Vector Machine (SVM) 31
3.5 Métricas de Avaliação 32
3.6 Validação cruzada 34
3.7 Síntese final 35

4 Metodologia **36**
4.1 Projeto dos Sensores 38
4.1.1 Sensor de micro-ondas baseado em CSRR para avaliar a qualidade da água e evitar a contaminação indesejada por açúcar . . . 38
4.1.2 Comparação de sensores de micro-ondas baseados CSRR para monitoramento de contaminantes críticos (nitrato, fosfato e amônio) em ambientes aquosos 43
4.1.3 Projeto sensor planar de micro-ondas baseado IDC para monitoramento de contaminantes críticos (Nitrato e Fosfato) em ambientes aquosos 52

5 Resultados e Discussões **56**
5.1 Projeto 01 56
5.1.1 Modelo de Circuito Equivalente e Sensibilidade 56

5.1.2 Resultados experimentais e comparações 62
5.2 Projeto 02 66
5.2.1 Modelo de Circuito Equivalente e Sensibilidade 66
5.2.2 Resultados experimentais e comparações 71
5.3 Projeto 03 78
5.3.1 Modelo de Circuito Equivalente e Sensibilidade 78
5.3.2 Resultados experimentais e comparações 81
5.4 Detecção dos contaminantes por aprendizado de máquina 82
5.4.1 Coleta das amostras e montagem do Dataset 83
5.4.2 Etapa de pré-processamento dos dados 85
5.4.3 Regressão 88
5.4.4 Classificação 89
5.4.5 Resultados alcançados 90
5.4.6 Analise final dos resultados obtidos 126

6 Conclusão **129**
6.1 Conclusão 129
6.2 Proposta de Continuidade 130
6.3 Trabalhos Produzidos Relacionados ao Tema 130

Referências bibliográficas **132**

Lista de Figuras

2.1 Principais Palavras-Chaves apresentadas no artigos presentes na análise do estudo. Fonte: Autor, 2024. 7
2.2 Quantidade de artigos selecionados por ano de publicação. Fonte: Autor, 2024. 8
2.3 Palavras-chave mais citados nos artigos. Fonte: Autor, 2024. 9
2.4 Design sensor micro-ondas SSRR. Fonte: (SYED et al. 2024). 10
2.5 Configuração de medição proposto. Fonte: (SYED et al. 2024). 10
2.6 Design sensor micro-ondas ENZ com antena Vivaldi. Fonte: (EL-NADY et al. 2024). 11
2.7 Design sensores micro-ondas propostos (a) Circular e (b) Quadrado. Fonte: (ANAR et al. 2024*a*). 12
2.8 Configuração de medição e design sensor micro-ondas. Fonte: (LIRA et al. 2024). 13
2.9 Design sensor micro-ondas e configuração de medição. Fonte: (YONG et al. 2024). 14
2.10 Configuração de medidas: em laboratório e em In Situ. Fonte: (FRAU et al. 2021*a*). 15
2.11 Design sensor IDE proposto. Fonte: (FRAU et al. 2021*b*). 15
2.12 Design sensor micro-ondas SCSRR proposto. Fonte: (HARNSOONGNOEN et al. 2019). 16
2.13 Configuração do setup de medição mostrando o sensor e seus principais componentes. Fonte: (HARNSOONGNOEN et al. 2019). 17
2.14 Design sensor micro-ondas DSRR proposto. Fonte: (YEE et al. 2021). . . 17
2.15 Design sensor micro-ondas proposto. Fonte: (HARNSOONGNOEN & WANTHONG 2021). 18
2.16 Configuração do setup de medição mostrando o sensor e seus principais componentes. Fonte: (HARNSOONGNOEN & WANTHONG 2021). . . 19
2.17 Design do array de sensores micro-ondas proposto. Fonte: (ZHANG et al. 2019). 20

3.1 Regressão linear. Fonte: Autor, 2025. 24
3.2 Regressão Polinomial. Fonte: Autor, 2025. 25
3.3 Regressão SGD. Fonte: Neri Otten, 2024. 25
3.4 Exemplo Árvore de Decisão. Fonte: Al-Absi et, al., 2024. 26
3.5 Exemplo Random Forest. Fonte: Al-Absi et, al., 2025. 27
3.6 Exemplo Classificador por Regressão Logística. Fonte: Whitfield, 2025. . 28

3.7 Exemplo Classificador por KNN. Fonte: Whitfield, 2025. 29
3.8 Exemplo Classificador por GNB. Fonte: Whitfield, 2025. 30
3.9 Exemplo Classificador por MLP. Fonte: Autor, 2025. 31
3.10 Exemplo Classificador por SVM. Fonte: Agarap, 2017. 32
3.11 Exemplo curva ROC AUC. Fonte: Mesuga, 2022. 33

4.1 Fluxograma dos procedimentos que compõem a metodologia adotada nesta pesquisa para desenvolvimento dos sensores. Fonte: Autor, 2025. 36
4.2 Geometria proposta do sensor de micro-ondas baseado em CSRR (L = 35 mm, W = 20 mm, W1 = 0,5 mm, W2 = 3 mm, r1 = 3,9 mm, r2 = 4,4 mm, r3 = 4,9 mm, r4 = 5,4 mm) (a) Vista isométrica (b) Vista superior e inferior. Fonte: Autor, 2025. 39
4.3 Evolução do projeto de sensor baseado em CSRR proposto. (a) Projetos de sensores (b) Avaliação $|S_{21}|$ dos projetos propostos. Fonte: Autor, 2025. 40
4.4 Distribuição simulada do campo elétrico. Fonte: Autor, 2025. 41
4.5 Simulação mostrando o campo elétrico de interação na LUT. Fonte: Autor, 2025. 42
4.6 Plano de terra com CSRR (esquerda) e linha de transmissão (direita) do protótipo construído. Fonte: Autor, 2025. 42
4.7 Preparar a configuração de medição e as amostras de glicose e água para diferentes concentrações. Fonte: Autor, 2025. 43
4.8 Tipos de ressoadores CSRR estudados. Fonte: Autor, 2025. 46
4.9 Sensor de micro-ondas baseado em DR-CSRR proposto: (a) estrutura. (b) distribuição de corrente de superfície a 1,5 GHz. (c) características do parâmetros-S. Fonte: Autor, 2025. 47
4.10 Sensor de micro-ondas baseado em SR-CSRR proposto: (a) estrutura. (b) distribuição de corrente de superfície a 1,5 GHz. (c) características do parâmetros-S. Fonte: Autor, 2025. 48
4.11 Sensor de micro-ondas baseado em S-CSRR proposto: (a) estrutura. (b) distribuição de corrente de superfície a 1,5 GHz. (c) características do parâmetros-S. Fonte: Autor, 2025. 49
4.12 Sensor de micro-ondas baseado em C-CSRR proposto: (a) estrutura. (b) distribuição de corrente de superfície a 1,5 GHz. (c) características do parâmetros-S. Fonte: Autor, 2025. 50
4.13 Sensores propostos fabricados. Fonte: Autor, 2025. 51
4.14 Recipiente de acrílico com LUT (Liquid under test) e sensores baseados em CSRR propostos. Fonte: Autor, 2025. 51
4.15 Configuração da medição e preparação da amostra para medições. Fonte: Autor, 2025. 52
4.16 Geometria proposta do sensor de micro-ondas baseado em IDC (a) Vista inferior (plano de terra) (b) Vista superior. Fonte: Autor, 2025. 53
4.17 Protótipo fabricado do sensor IDC. Fonte: Autor, 2025. 54
4.18 Distribuição de campo elétrica na superfície do sensor na frequência de 1.86 GHz. Fonte: Autor, 2025. 54
4.19 Configuração da medição. Fonte: Autor, 2025. 55

5.1 Comparação do $|S_{21}|$ do sensor proposto para ECM, HFSS e experimental com (Lm=0,38nH, C=1,547pF, L=0,348nH, Cc=10,466pF e R=370Ω). Fonte: Autor, 2025. 57
5.2 Simulação Coeficiente de transmissão, $|S_{21}|$, para diferentes valores de permissividade relativa. Fonte: Autor, 2025. 59
5.3 Resposta $|S_{21}|$ simulada do sensor CSRR proposto para a tangente de perda de $0,00$ a $0,03$ com intervalos de $0,003$. Fonte: Autor, 2025. 59
5.4 Os resultados da investigação dos principais parâmetros de sensibilidade do sensor baseado em CSRR proposto: (a) deslocamento ressonante (Δf_r); deslocamento de frequência relativa percentual (PRFS); (c) aprimoramento do deslocamento de frequência ressonante percentual (PRFSE). Fonte: Autor, 2025. 60
5.5 Curvas simuladas e ajustadas com frequência ressonante em diferentes valores de permissividade. Fonte: Autor, 2025. 61
5.6 Raio de abertura do CSRR em diferentes frequências de ressonância. Fonte: Autor, 2025. 62
5.7 Resposta $|S_{21}|$ (em dB) medindo a mistura de água e glicose para diferentes frações de volume. (a) 10% a 100%. (b) 1% a 20%. Fonte: Autor, 2025. 63
5.8 Concentração de água na LUT como uma função do desempenho da frequência (em GHz). Fonte: Autor, 2025. 63
5.9 Efeitos da concentração de glicose na água sobre os parâmetros de transmissão $|S_{21}|$. Fonte: Autor, 2025. 64
5.10 Comparação da sensibilidade do sensor proposto neste artigo com a de outros sensores avançados. Fonte: Autor, 2025. 64
5.11 O erro percentual das medições de água e glicose de cada amostra em relação aos valores estimados (em mililitros). Fonte: Autor, 2025. 65
5.12 Comparação do $|S_{21}|$ do sensor proposto ECM, simulação ANSYS- HFSS. (a) DR-CSRR e SR-CSRR. (b) S-CSRR e C-CSRR. Fonte: Autor, 2025. . 66
5.13 Estrutura dos sensores proposto com o contêiner de acrílico e LUT (líquido sob teste). Fonte: Autor, 2025. 67
5.14 Simulação do parâmetro $|S_{21}|$ para diferentes permissividade relativas (1-100). (a) DR-CSRR. (b) SR-CSRR. (c) S-CSRR. (d) C-CSRR. Fonte: Autor, 2025. 67
5.15 Simulação do parâmetro $|S_{21}|$ para diversas tangentes de perdas elétricas $tan\delta$ (0-0,03). (a) DR-CSRR. (b) SR-CSRR. (c) S-CSRR. (d) C-CSRR. Fonte: Autor, 2025. 68
5.16 Comparação da sensibilidade simulada dos quatro sensores propostos: (a) Deslocamento de frequência (Δf_r (GHz)). (b)deslocamento de frequência relativa percentual (PRFS). (c) Aprimoramento percentual do deslocamento da frequência ressonante (PRFSE) em comparação com o sensor baseado em DR-CSRR. (d) Aprimoramento da sensibilidade percentual. Fonte: Autor, 2025. 69

5.17 Curvas simuladas e ajustadas com frequência ressonante em diferentes valores de permissividade. (a) S-CSRR. (b) C-CSRR. Fonte: Autor, 2025. 70
5.18 Curvas simuladas e ajustadas com amplitude de $|S_{21}|$,em dB, em diferentes valores de permissividade. (a) S-CSRR. (b) C-CSRR. Fonte: Autor, 2025. 70
5.19 Comparação dos parâmetros S_{21} simulados e medidos. (a) DR-CSRR. (b) SR-CSRR. (c) S-CSRR. (d) C-CSRR. Fonte: Autor, 2025. 71
5.20 Medida $|S_{21}|$ realizada para diferentes amostras aquosas + contaminantes. (a) S-CSRR. (b) C-CSRR. Fonte: Autor, 2025. 72
5.21 Configuração de medição do método NRW utilizada para medir as amostras. Fonte: Autor, 2025. 73
5.22 Variação da permissividade relativa real imaginária versus a frequência pelo método NRW para nitrato, fosfato e amônio. (a) ε'_r. (b) ε''_r. Fonte: Autor, 2025. 73
5.23 Variação da permissividade relativa versus a frequência pelo método NRW para NaCl 5000 e NaCl 40000. (a) ε'_r. (b) ε''_r. Fonte: Autor, 2025. 74
5.24 Alterações de resposta devido a soluções de água com duas concentrações para as soluções testadas para deslocamento da frequência. Fonte: Autor, 2025. 75
5.25 Alterações de resposta devido a soluções de água com duas concentrações para as soluções testadas para Deslocamento da amplitude. Fonte: Autor, 2025. 76
5.26 Comparação da sensibilidade em relação dos sensores S-CSRR e C-CSRR a sensores presente na literatura: (a) Deslocamento de frequência (Δf_r (GHz)). (b)deslocamento de frequência relativa percentual (PRFS). (c) Aprimoramento percentual do deslocamento da frequência ressonante (PRFSE) em comparação com o sensor baseado em DR-CSRR. (d) Aprimoramento da sensibilidade percentual. Fonte: Autor, 2025. 77
5.27 Comparação do $|S_{21}|$ do sensor proposto para ECM, HFSS e experimental com ($L = 17.7\,nH$, $L_{int} = 9.5\,nH$, $C_{int} = 26.4\,pF$, $R_{int} = 210\,\Omega$ e $C_p = 0.4\,nF$). Fonte: Autor, 2025. 78
5.28 Simulação Coeficiente de transmissão, $|S_{21}|$, para diferentes valores de permissividade relativa. Fonte: Autor, 2025. 79
5.29 Resposta $|S_{21}|$ simulada do sensor CSRR proposto para a tangente de perda de $0,00$ a $0,03$ com intervalos de $0,003$. Fonte: Autor, 2025. 79
5.30 Os resultados da investigação dos principais parâmetros de sensibilidade do sensores proposto nesse trabalho comparando com IDC: (a) deslocamento ressonante (Δf_r); deslocamento de frequência relativa percentual (PRFS); (c) aprimoramento do deslocamento de frequência ressonante percentual (PRFSE). Fonte: Autor, 2025. 80
5.31 Curvas simuladas e ajustadas com frequência ressonante em diferentes valores de permissividade. Fonte: Autor, 2025. 81
5.32 Medida $|S_{21}|$ realizada para o sensor sem carga e com os contaminantes nitrato e fosfato. Fonte: Autor, 2025. 82

5.33 Fluxograma de aplicação ML. Fonte: Autor, 2025. 83
5.34 Setup de preparação e medição das amostras. Fonte: Autor, 2025. 84
5.35 Estrutura do Dataset. Fonte: Autor, 2025. 84
5.36 Dendograma da classificação baseada em árvore de decisão. Fonte: Autor, 2025. 85
5.37 Box-plots dos parâmetros do dataset para o sensor 1. Fonte: Autor, 2025. 86
5.38 Box-plots dos parâmetros do dataset para o sensor 2. Fonte: Autor, 2025. 86
5.39 Box-plots dos parâmetros do dataset para o sensor 3. Fonte: Autor, 2025. 87
5.40 Box-plots dos parâmetros do dataset para o sensor 4. Fonte: Autor, 2025. 87
5.41 Comparação da curva de regressão para os diversos modelos estudados e os pontos reais obtidos para permissividade relativa em função da frequência sensor 1. Fonte: Autor, 2025. 91
5.42 Comparação da curva de regressão para os diversos modelos estudados e os pontos reais obtidos para permissividade relativa em função da frequência para o sensor 2. Fonte: Autor, 2025. 92
5.43 Comparação da curva de regressão para os diversos modelos estudados e os pontos reais obtidos para permissividade relativa em função da frequência para o sensor 3. Fonte: Autor, 2025. 93
5.44 Comparação da curva de regressão para os diversos modelos estudados e os pontos reais obtidos para permissividade relativa em função da frequência para o sensor 4. Fonte: Autor, 2025. 94
5.45 Matriz de confusão validação por separação das amostras (20:80) para sensor 1 cada modelo classificador. Fonte: Autor, 2025. 95
5.46 Curva ROC da validação por separação das amostras (20:80) para sensor 1 cada modelo classificador. Fonte: Autor, 2025. 96
5.47 Matriz de confusão validação por separação das amostras (20:80) para sensor 2 cada modelo classificador. Fonte: Autor, 2025. 97
5.48 Curva ROC da validação por separação das amostras (20:80) para sensor 2 cada modelo classificador. Fonte: Autor, 2025. 98
5.49 Matriz de confusão validação por separação das amostras (20:80) para sensor 3 cada modelo classificador. Fonte: Autor, 2025. 99
5.50 Curva ROC da validação por separação das amostras (20:80) para sensor 3 cada modelo classificador. Fonte: Autor, 2025. 100
5.51 Matriz de confusão validação por separação das amostras (20:80) para sensor 4 cada modelo classificador. Fonte: Autor, 2025. 101
5.52 Curva ROC da validação por separação das amostras (20:80) para sensor 4 cada modelo classificador. Fonte: Autor, 2025. 102
5.53 Matriz de confusão validação por LOO para sensor 1 cada modelo classificador. Fonte: Autor, 2025. 103
5.54 Curva ROC da validação por LOO para sensor 1 cada modelo classificador. Fonte: Autor, 2025. 104
5.55 Matriz de confusão validação por LOO para sensor 2 cada modelo classificador. Fonte: Autor, 2025. 105

5.56 Curva ROC da validação por LOO para sensor 2 cada modelo classificador. Fonte: Autor, 2025. 106
5.57 Matriz de confusão validação por LOO para sensor 3 cada modelo classificador. Fonte: Autor, 2025. 107
5.58 Curva ROC da validação por LOO para sensor 3 cada modelo classificador. Fonte: Autor, 2025. 108
5.59 Matriz de confusão validação por LOO para sensor 4 cada modelo classificador. Fonte: Autor, 2025. 109
5.60 Curva ROC da validação por LOO para sensor 4 cada modelo classificador. Fonte: Autor, 2025. 110
5.61 Matriz de confusão validação por SKF para sensor 1 cada modelo classificador. Fonte: Autor, 2025. 111
5.62 Curva ROC da validação por SKF para sensor 1 cada modelo classificador. Fonte: Autor, 2025. 112
5.63 Matriz de confusão validação por SKF para sensor 2 cada modelo classificador. Fonte: Autor, 2025. 113
5.64 Curva ROC da validação por SKF para sensor 2 cada modelo classificador. Fonte: Autor, 2025. 114
5.65 Matriz de confusão validação por SKF para sensor 3 cada modelo classificador. Fonte: Autor, 2025. 115
5.66 Curva ROC da validação por SKF para sensor 3 cada modelo classificador. Fonte: Autor, 2025. 116
5.67 Matriz de confusão validação por SKF para sensor 4 cada modelo classificador. Fonte: Autor, 2025. 117
5.68 Curva ROC da validação por SKF para sensor 4 cada modelo classificador. Fonte: Autor, 2025. 118
5.69 Matriz de confusão validação por RSKF para sensor 1 cada modelo classificador. Fonte: Autor, 2025. 119
5.70 Curva ROC da validação por RSKF para sensor 1 cada modelo classificador. Fonte: Autor, 2025. 120
5.71 Matriz de confusão validação por RSKF para sensor 2 cada modelo classificador. Fonte: Autor, 2025. 121
5.72 Curva ROC da validação por RSKF para sensor 2 cada modelo classificador. Fonte: Autor, 2025. 122
5.73 Matriz de confusão validação por RSKF para sensor 3 cada modelo classificador. Fonte: Autor, 2025. 123
5.74 Curva ROC da validação por RSKF para sensor 3 cada modelo classificador. Fonte: Autor, 2025. 124
5.75 Matriz de confusão validação por RSKF para sensor 4 cada modelo classificador. Fonte: Autor, 2025. 125
5.76 Curva ROC da validação por RSKF para sensor 4 cada modelo classificador. Fonte: Autor, 2025. 126
5.77 Curva da comparação acurácia máxima por sensor com a validação utilizada. Fonte: Autor, 2025. 128

Lista de Tabelas

2.1 Resultados numéricos dos mecanismos de busca utilizados. Fonte: Scopus, 2024. 5
2.2 Periódico e fator de impacto dos artigos selecionados. Fonte: Autor, 2024. 8
2.3 Resumo dos artigos que contribuíram para a pesquisa de projetos de sensores para o monitoramento de qualidade da água. Fonte: Autor, 2024. . . 21

4.1 Etapas da metodologia empregada na pesquisa. Fonte: Autor, 2025. . . . 37

5.1 Comparação do sensor proposto com projetos anteriores da literatura. Fonte: Autor, 2025. 65
5.2 Erro de cálculo de água e glicose com valores estimados. Fonte: Autor, 2025. 65
5.3 Concentração das amostras usadas para obter a resposta de ressonância dos sensores propostos. Fonte: Autor, 2025. 72
5.4 Valores de f_r e $|S_{21}|$ medidos para cada sensor proposto. Fonte: Autor, 2025. 72
5.5 Comparação da permissividade relativa real e imaginária em diferentes métodos para o sensor S-CSRR. Fonte: Autor, 2025. 74
5.6 Comparação da permissividade relativa real e imaginária em diferentes métodos para o sensor C-CSRR. Fonte: Autor, 2025. 75
5.7 O erro percentual e desvio padrão das medições dos reagentes químicos utilizados em cada amostra em relação aos valores estimados (em micrograma). Fonte: Autor, 2025. 76
5.8 Comparação dos sensores micro-ondas proposto com sensores presente na literatura. Fonte: Autor, 2025. 77
5.9 Resultados obtidos para o sensor 1 da classificação por split (20% : 80%) em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 96
5.10 Resultados obtidos para o sensor 2 da classificação por split (20% : 80%) em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 98
5.11 Resultados obtidos para o sensor 3 da classificação por split (20% : 80%) em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 100
5.12 Resultados obtidos para o sensor 4 da classificação por split (20% : 80%) em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 102

5.13 Resultados obtidos para o sensor 1 da classificação utilizando validação LOO em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 104
5.14 Resultados obtidos para o sensor 2 da classificação utilizando validação LOO em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 106
5.15 Resultados obtidos para o sensor 3 da classificação utilizando validação LOO em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 108
5.16 Resultados obtidos para o sensor 4 da classificação utilizando validação LOO em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 110
5.17 Resultados obtidos para o sensor 1 da classificação utilizando validação SKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 112
5.18 Resultados obtidos para o sensor 2 da classificação utilizando validação SKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 114
5.19 Resultados obtidos para o sensor 3 da classificação utilizando validação SKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 116
5.20 Resultados obtidos para o sensor 4 da classificação utilizando validação SKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 118
5.21 Resultados obtidos para o sensor 1 da classificação utilizando validação RSKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 120
5.22 Resultados obtidos para o sensor 2 da classificação utilizando validação RSKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 122
5.23 Resultados obtidos para o sensor 3 da classificação utilizando validação RSKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 124
5.24 Resultados obtidos para o sensor 4 da classificação utilizando validação RSKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025. 126
5.25 Tabela de comparação dos principais sensores produzidos. Fonte: Autor, 2025. 127

Capítulo 1

Introdução

Com o avanço da tecnologia, novos sistemas de monitoramento móvel, compactos e de fácil uso têm ganhado destaque. Paralelamente, a crescente preocupação com a qualidade da água, intensificada pela escassez hídrica e pela contaminação ambiental resultante do uso excessivo de recursos industriais, tem impulsionado pesquisas voltadas ao desenvolvimento de tecnologias inovadoras para o monitoramento de recursos hídricos (ADJOVU et al. 2023). A qualidade da água, analisada a partir de parâmetros químicos, físicos e biológicos, sofre um processo contínuo de deterioração ao longo de sua distribuição e utilização. Assegurar a preservação dessa qualidade é essencial para a manutenção da vida e o bem-estar dos organismos vivos (ALSHALTONE et al. 2023). O uso indevido de recursos hídricos, principalmente de rios, mares e lagos pela população humana em grandes e médias cidades vem atualmente gerando poluição imprópria de fontes primordiais da água nessas regiões, devido principalmente às atividades relacionadas à agricultura, às indústrias, ao comércio e a geração de energia (ANAR et al. 2024*b*). O crescimento populacional alavancou esse processo se tornando cada vez a necessidade de preservar os recursos através do monitoramento acessível em todos os níveis ao longo dessas fontes hídricas, principalmente águas potáveis para consumo e lazer (ABRAHAMYAN et al. 2019). Nesse contexto, os sensores planares de micro-ondas emergem como uma solução promissora, oferecendo a capacidade de detectar e quantificar contaminantes em tempo real, além de serem econômicos e altamente compactos (HARNSOONGNOEN 2021).

De um modo geral, o princípio de funcionamento dos sensores de micro-ondas baseia-se na emissão de ondas eletromagnéticas que interagem tanto com as moléculas de água quanto com os contaminantes presentes para medir sua permissividade relativa (HANIF et al. 2024). Essa interação possibilita a análise de diversos parâmetros importantes para análise da qualidade da água, como turbidez, pH, condutividade e detecção de substâncias prejudiciais, como substâncias químicas (nitrato, fosfato, amônia e a glicose) proveniente da atividade agrícola e industrial, além de metais pesados (Mércurio e Chumbo) provenientes de atividades de industriais de mineração (TANGUY et al. 2020). A utilização de frequências específicas não apenas assegura a conformidade com as regulamentações nacionais, mas também aumenta a eficiência dos sensores na identificação de poluentes, como microplásticos e pesticidas, cujas concentrações nas fontes de água têm se elevado consideravelmente (COSTANZO 2024).

Algumas estrategias de sensores micro-ondas baseadas métodos como Ressoadores

de Anel divido Complementar (do inglês CSRR – Complementar Split Ring Ressonator) para caracterizar líquidos de alta dispersividade necessita-se novos tipos ressoadores capazes de produzir alto campo elétrico concentrado para medição das característica do liquido sem impactar no seu tamanho (VELEZ et al. 2019). Para perpassar essas dificuldades de performance e tamanho, sensores de micro-ondas utilizam estruturas baseadas Defect Ground Structure – DGS, principalmente estruturas altamente periódicas, localizadas geralmente no plano de terra do sensor (HAN et al. 2024).

Diversos contaminantes químicos são frequentemente detectados em amostras de água coletadas para avaliação de sua qualidade. Para esse propósito, é essencial determinar se os níveis desses contaminantes estão dentro de concentrações específicas. Entre eles, destacam-se o nitrogênio (N_2), presente na forma de nitrato (NO_3), o fósforo, encontrado como fosfato (PO_4), e metais pesados como mercúrio (Hg) e chumbo (Pb) (HONG et al. 2021). Além disso, parâmetros como salinidade, condutividade, nível de açúcares e pH da água também são analisados (ABBASI & DANESHMAND 2018). Esses fatores são fundamentais para medir a permissividade relativa complexa dos reagentes em corpos hídricos, contribuindo para uma avaliação mais abrangente da qualidade da água.

Pesquisas recentes têm mostrado que os sensores micro-ondas capazes para detecção da qualidade da água e seu monitoramento, como o sensor micro-ondas ressonador semicircular mostrado em (JAFARI & RAD MALEKSHAHI 2024) que utiliza uma técnica de rede neural capaz da detecção da pureza de pequenas quantidades de líquidos. Já o estudo em (DING et al. 2024) apresenta um sensor baseado em ressonador circular Complementary Split Ring Resonator (CSRR) para avaliação da qualidade do leite, focando na detecção de mudanças de pH e sólidos totais dissolvidos (TDS) mostrando uma maior sensibilidade na medição de pH em comparação com outros sensores CSRR recentemente descritos na literatura científica. (SINGH et al. 2024) explora o aumento de sensibilidade de ressonadores Complementary Split-Ring Resonators (CSRR) para detecção de nitrogênio amoniacal (NH3-N) em aplicações de qualidade da água. Por fim, em (YE et al. 2022) apresenta um sensor de micro-ondas baseado em ressonadores de anel dividido (SRRs) com uma estrutura interdigital projetada para aumentar a área de detecção e aprimorar a sensibilidade e com múltiplas frequências de ressonância, o sensor mapeia a dispersão dos líquidos em uma ampla faixa de frequência, garantindo medições precisas.

Outros sensores planares de micro-ondas têm se mostrado promissores para a medição da qualidade da água devido à sua capacidade de fornecer dados em tempo real e de forma não intrusiva (YAROSHENKO et al. 2020). Diversas tecnologias e técnicas têm sido desenvolvidas para aprimorar a detecção de contaminantes em diferentes contextos. Por exemplo, sensores de micro-ondas baseados em arrays de ressonadores, operando em uma ampla faixa de frequência de 1 GHz a 10 GHz, permitem a coleta de informações detalhadas sobre os poluentes presentes na água (ZHANG et al. 2019). Além disso, a utilização de arrays não uniformes de sensores de micro-ondas, combinados com algoritmos de aprendizado de máquina, tem demonstrado eficácia na identificação de poluentes específicos como fosfato, chumbo, mercúrio e cromo (AMINEH et al. 2023). Sensores de micro-ondas planos também foram testados in situ em áreas de mineração poluídas, mostrando uma resposta imediata na detecção de metais tóxicos (FRAU et al. 2021*a*). Outra abordagem inovadora envolve o uso de substratos flexíveis para os sensores, au-

mentando sua durabilidade e aplicabilidade em diferentes ambientes aquáticos. Sensor micro-ondas que utiliza outros tipos de materiais condutores como ouro ou prata, que medem as propriedades dielétricas da água, oferecem uma solução contínua e econômica para o monitoramento da qualidade da água (MOHAMMADI et al. 2020). Um biossensor microfluídico compacto foi projetado com base em um ressonador elétrico-LC complementar acoplado a uma linha de microfita para a determinação da concentração de glicose na água foi proposto em (KAI BOON et al. 2021). Essas tecnologias demonstram o potencial dos sensores de micro-ondas para fornecer medições precisas e em tempo real, essenciais para a gestão sustentável dos recursos hídricos.

Este estudo visa explorar o potencial das tecnologias de sensores planares de micro-ondas, utilizando uma estrutura DGS, para medir a permissividade relativa de contaminantes em água na faixa de frequência de 1 a 3 GHz. A pesquisa ainda destacará as vantagens desses sensores em relação aos métodos convencionais de laboratório, enfatizando seu impacto na melhoria da qualidade da água destinada ao consumo humano e ao uso agrícola.

1.1 Objetivos

1.1.1 Objetivo Geral

Desenvolver e analisar dispositivos planares de micro-ondas com estruturas DGS nas suas topologias, visando otimizar sua sensibilidade e precisão na detecção de contaminantes críticos em água (nitrato, fosfato, amônia e glicose) por meio de técnicas de ressonância e caracterização dielétrica, integrando métodos de aprendizado de máquina para prever e classificar a resposta dos contaminantes, aprimorando o monitoramento inteligente da qualidade da água.

1.1.2 Objetivos Específicos

Já como objetivos específicos teremos que:

1. Avaliar o elemento e técnica mais adequadas para os tipos contaminante (nitrato, fosfato, amônia, glicose, metais pesados entre outros).
2. A modelagem e o estudo da geometria e inclusão do método do circuito equivalente.
3. Analisar os parâmetros dispersão do sensor, incluindo as características das técnicas utilizadas, e seu impacto na sensibilidade e precisão do dispositivo para cada aplicação.
4. Desenvolver uma curva de calibração que valide os sensores propostos, garantindo sua eficiência na detecção dos contaminantes.
5. Simular utilizando o ANSYS-HFSS o sensor para determinar a curva que descreve a variação de concentração dos contaminantes em função dos parâmetros de espalhamento.
6. Fabricar o sensor e fazer medidas experimentais com os compostos em laboratório e In Situ. Analisar os resultados obtidos via medição experimental sob os modelos construídos comprovaram um bom funcionamento dos protótipos.

7. Avaliar o desempenho dos sensores em relação às amostras de água de corpos hídricos, examinando sua capacidade de identificar e medir com precisão a permissividade e os parâmetros de dispersão dos contaminantes.

1.2 Impacto Social

A proposta de desenvolvimento de um sensor de micro-ondas para detecção e classificação de contaminantes críticos em meio hídricos utilizando aprendizagem de máquina tem um impacto socioambiental significativo. Ao permitir a detecção precisa e acessível de poluentes críticos, como nitratos, fosfatos, amônia e níveis de sais minerais em água, este projeto visa contribui diretamente para a preservação dos recursos hídricos locais, fundamentais para a saúde pública e a sustentabilidade ambiental. Além disso, sua aplicação em larga escala pode mitigar os efeitos da poluição industrial, agrícola e urbana, promovendo o uso consciente da água e reduzindo os riscos associados à contaminação. Ao oferecer uma alternativa viável aos métodos convencionais, a tecnologia proposta facilita a democratização do monitoramento ambiental, capacitando comunidades locais e gestores ambientais a tomar decisões mais informadas em prol do desenvolvimento sustentável.

Além disso, este trabalho aborda questões de grande relevância social ao explorar campos científicos que trazem benefícios diretos e indiretos para a sociedade. Por meio do estudo de tecnologias planares de micro-ondas, ele contribui para o desenvolvimento de soluções inovadoras e desenvolvimento cientifico nacional através desse tipo de pesquisa, com aplicações que podem melhorar significativamente a qualidade estudos voltados a essa área de pesquisa. Além de propor uma automação para o processo e promover o melhor reconhecimento dos contaminantes estudados. Por fim, este projeto abre caminhos para avanços na área da ambiental, promovendo avaliação precisas e tratamentos mais eficazes na presença de contaminantes em água. Assim, a pesquisa reafirma o papel transformador da ciência no enfrentamento de desafios socio-ambientais propostos.

1.3 Organização do texto

O capítulo 2 aborda uma revisão sistemática da literatura oferecendo uma análise sobre os estudos relacionados aos temas correlacionados com a proposta desta dissertação de Mestrado. O capítulo 4 apresenta a metodologia de projeto de sensores micro-ondas propostos. São estudadas estruturas e comparadas diferentes geometrias baseada em Complementary Split Ring Resonator (CSRR) e Capacitor Interdigital (IDC) como estrutura DGS para medição da permissividade relativa de contaminantes em água. O capítulo 5 ressalta as principais resultados encontrados e contribuições deste trabalho. Por fim, o capítulo 6 apresenta as principais conclusões, perspectivas futuras e contribuições deste trabalho.

Capítulo 2

Revisão de Literatura

2.1 Procedimentos Metodológicos

O levantamento bibliográfico com intuito de selecionar os trabalhos relacionados ao tema proposto para análise bibliográfica. Com auxílio da ferramenta de pesquisa do Portal de Periódicos da CAPES foi utilizada a base de dados do Scopus e auxiliado pelo software de análise bibliométrica VOSviewer. Através da pesquisa avançada foi utilizada para fins de trucamento os filtros de seleção de artigos na área de estudos da engenharia, como critério de inclusão foi escolhido a lingua inglesa e foi delimitado um período de tempo entre 2019 à 2024 que compreende 5 anos de dados. A definição dos termos de busca se usou o campo de palavras-chave disponível na plataforma do Scopus e foi escolhido palavras-chave que englobam o tema relacionado, como “microwave sensor”, “water quality”, “water pollutants”, “machine learning” e “DGS” foi empregado os operadores booleanos AND e OR para delimitar as palavras-chave ao tema proposto. A Tabela 1 mostra os resultados numérico de artigos encontrados nessa pesquisa inciais na plataforma.

Palavras-chaves	**Resultados**
microwave sensor	7712
microwave sensor AND *water quality*	182
microwave sensor AND *water pollutants*	48
microwave sensor AND *machine learning*	39
microwave sensor AND *DGS*	37
microwave sensor AND (*Machine learning* OR *water pollutants*)	87

Tabela 2.1: Resultados numéricos dos mecanismos de busca utilizados. Fonte: Scopus, 2024.

Para cada configuração de busca realizada, foi feita uma análise preliminar dos títulos e resumos dos documentos recuperados. Quando um resumo indicava relevância para o tema da pesquisa, o artigo completo era acessado para verificar a ocorrência de termos específicos como "*microwave sensor*", "*water quality*", “*water pollutants*”, "*machine learning*"ou “*DGS*”. Após confirmar a relevância do conteúdo e eliminar as duplicatas, o artigo era lido. Ao final do processo de busca, foram encontrados 41 artigos que atenderam aos critérios de seleção do estudo.

A Tabela 1 mostra uma disparidade significativa entre o volume total de publicações sobre sensores micro-ondas publicados e o número mais restrito de estudos focados na técnica empregada defeito no plano de terra do sensor DGS. Também, observa-se uma redução nas pesquisas que tratam do monitoramento da qualidade da água. Essa constatação evidencia uma lacuna na literatura acadêmica referente à integração de sensores de micro-ondas, técnicas de vanguarda como DGS, monitoramento da qualidade da água em aplicações voltadas a área de segurança na qualidade da água. Esses resultados ressaltam a necessidade de novas pesquisas e abordagens inovadoras para o avanço desse campo de estudo.

A Figura 2.1 representa um rede de palavras das distribuição anuais de 2018 à 2024 das palavras-chaves apresentadas nos artigos apresentados na tabela 1 dentro do banco de dados do Scopus. Além de apresentar uma rede de co-ocorrência de palavras-chave, revelando as tendências e a evolução temática dos artigos relacionados a sensores de micro-ondas publicados entre 2018 e 2024, conforme dados do Scopus. O gráfico gerado pelo VOSviewer ilustra claramente a proeminência do termo "microwave sensor"como o núcleo central da pesquisa, denotado pelo seu maior tamanho e maior número de conexões. Observa-se a formação de clusters temáticos distintos, como o que agrupa "remote sensing", "soil moisture"e "water quality", indicando uma forte ligação entre sensores de micro-ondas e aplicações ambientais e agrícolas. Outro cluster relevante inclui "carbon dots"e "fluorescence", sugerindo o uso de nanomateriais e técnicas ópticas complementares. As linhas de conexão, com suas diferentes espessuras e cores (representando o ano médio de publicação), demonstram a intensidade das relações entre as palavras-chave e a cronologia do desenvolvimento das pesquisas. A evolução temporal visível na legenda indica que temas como "microwave sensors"e suas aplicações têm mantido ou aumentado sua relevância ao longo dos anos, consolidando a área como um campo de pesquisa dinâmico e multifacetado.

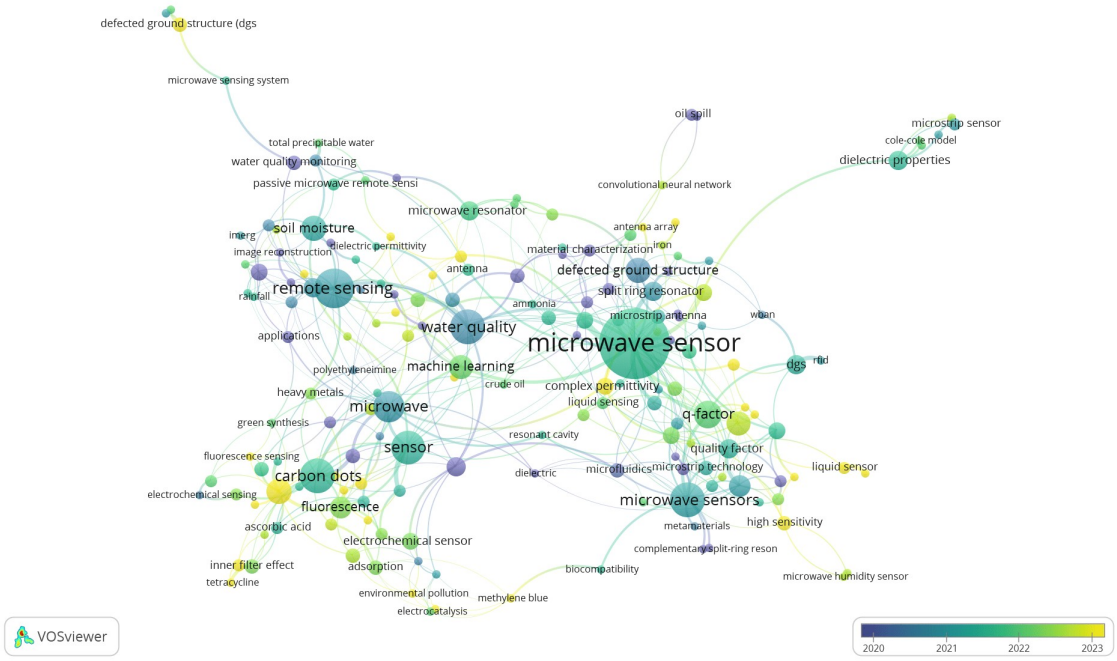


Figura 2.1: Principais Palavras-Chaves apresentadas no artigos presentes na análise do estudo. Fonte: Autor, 2024.

Com base nos estudos encontrados estabeleceram uma base de estudos, servindo como alicerce para a criação do dispositivo de sensoriamento voltados ao Monitoramento de Contaminantes Críticos (Nitrato, Fosfato, Amônia, Glicose e Metais Pesados) em Corpos Hídricos de Natal/RN e região metropolitana. Esses trabalhos foram fundamentais para orientar o desenvolvimento das soluções tecnológicas de vanguarda, permitindo a aplicação prática dos conceitos abordados na literatura.

2.2 Análise Bibliométrica

A análise detalhada dos 41 artigos selecionados para o melhor entendimento dos resultados presentes desses trabalho é fundamental para entender como a pesquisa tem evoluído ao longo do tempo e para identificar os periódicos mais importantes onde os artigos estão sendo publicados. Para mostrar a relevância do tema, podemos usar uma abordagem estatística para ilustrar as principais tendências encontradas na revisão sistemática, levando em conta aspectos importantes. Para organizar as publicações selecionadas, elas foram divididas com base em quatro critérios principais: (i) ano de publicação, (ii) periódico, (iii) fator de impacto e (iv) palavras-chave.

A Figura 2.2 abaixo mostra o total de artigos selecionados separados por ano de publicação. É possível notar uma oscilação dos resultados selecionados, possuindo uma grande maioria nos anos 2022, 2023 e 2024 respectivamente.

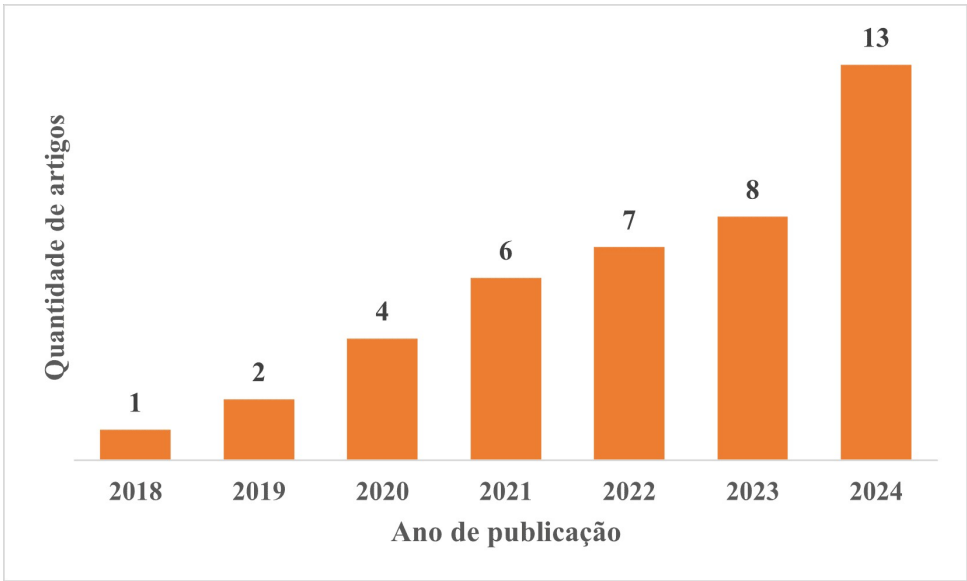


Figura 2.2: Quantidade de artigos selecionados por ano de publicação. Fonte: Autor, 2024.

Periódico	**Quantidade de artigos**	**Fator de impacto**
IEEE Sensors Journal	21	4.325
Sensors	4	3.847
Sensors and Actuators A: Physical	3	4.291
Sensors and Actuators, B: Chemical	1	9.221
Science of the Total Environment	1	17.600
Sensors and Actuators Reports	1	9.600
Journal of Contemporary Physics (Armenian Academy of Sciences)	1	0.500
Electronics	1	2.600
Environments	1	3.500
Journal of Electronic Voltage and Application	1	0.500
Remote Sensing	1	4.200
Mine Water and the Environment	1	2.100
International Journal of Environmental Science and Technology	1	3.000
ACS Applied Materials Interfaces	1	8.300
Hydrological Sciences Journal	1	2.800
URSI Atlantic Radio Science Meeting	1	0.500

Tabela 2.2: Periódico e fator de impacto dos artigos selecionados. Fonte: Autor, 2024.

Na Tabela 2.2, estão apresentados os periódicos e seus respectivos fatores de impacto dos artigos selecionados. Optou-se pelo fator de impacto como critério para avaliar os periódicos e os autores devido à sua capacidade de refletir o impacto real que esses têm em uma área de pesquisa específica. Esse indicador nos ajuda a ter uma visão mais clara sobre o alcance e a relevância acadêmica, levando em conta tanto a quantidade de publicações quanto a repercussão delas na comunidade científica. Possível notar ainda que a maioria dos artigos é proveniente da IEEE Sensor Journal como indicado na tabela abaixo.

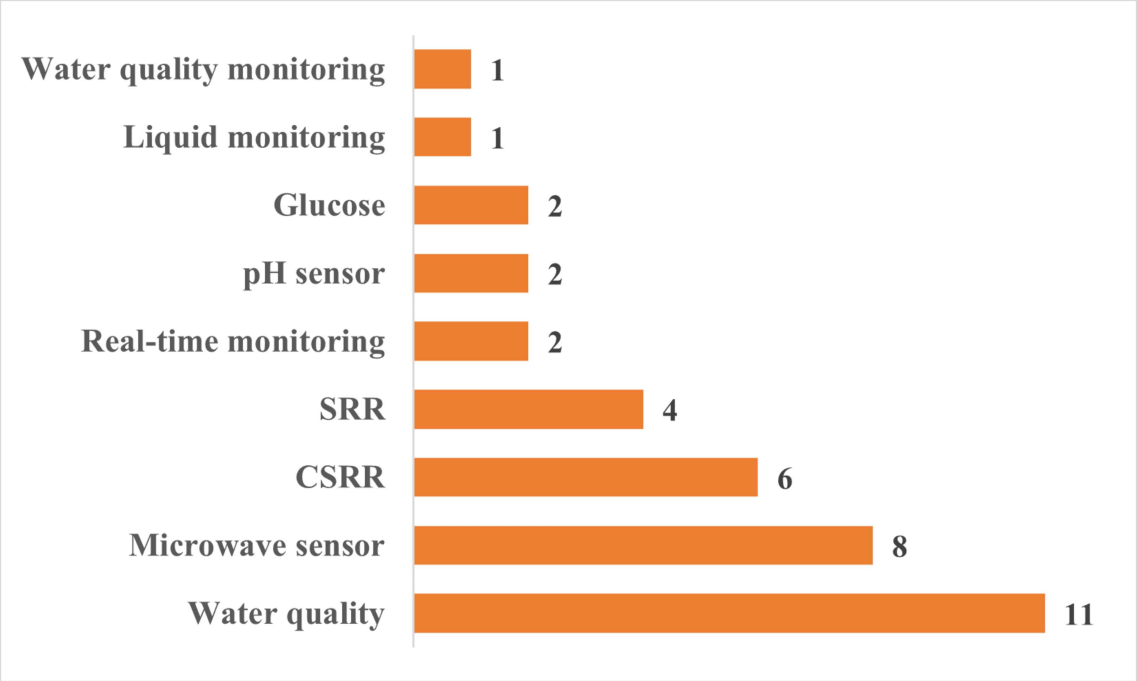


Figura 2.3: Palavras-chave mais citados nos artigos. Fonte: Autor, 2024.

Na Figura 2.3 mostra as palavras-chave mais citadas nos 41 artigos selecionados. Nota-se que os termos mais citados são "*water quality*", "*microwave sensor*", "*CSRR*" e "*SRR*"como indica a figura abaixo, nota-se que nos artigos selecionados mostra relevância com tema proposto.

2.3 Trabalhos Relacionados

2.3.1 Uma abordagem integrada para a detecção de nitrato e fosfato usando o ressoador de micro-ondas quadrado SRR

O estudo proposto por (SYED et al. 2024) apresenta um sensor de micro-ondas inovador para detectar nutrientes, especificamente fosfato e nitrato, em água potável. O sensor proposto baseia-se em um ressonador de anel partido quadrado (SSRR), com uma extremidade aberta afilada para aprimorar a sensibilidade como se pode ver na figura 2.4.

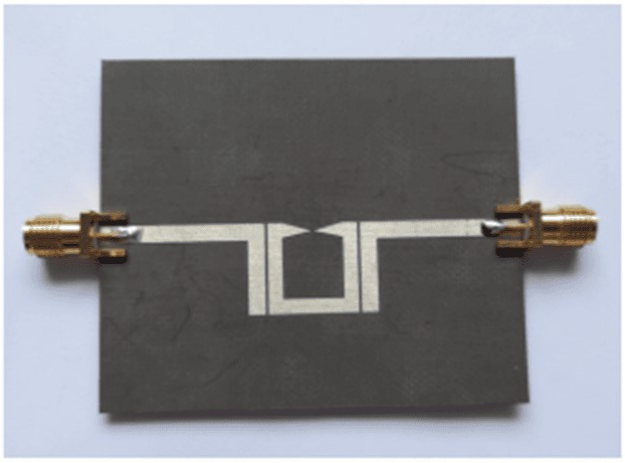


Figura 2.4: Design sensor micro-ondas SSRR. Fonte: (SYED et al. 2024).

O método de estudo envolveu simulações para diversas permissividades relativas de amostras posicionadas na região ativa do SSRR, seguidas por medições experimentais do coeficiente de transmissão (S_{21}) e da frequência ressonante (f_r) para soluções líquidas com diferentes concentrações de fosfato e nitrato. Para a classificação das amostras líquidas com base nos resultados obtidos, aplicou-se a análise de componentes principais (PCA), como podemos ver a configuração de medida na figura 2.5.



Figura 2.5: Configuração de medição proposto. Fonte: (SYED et al. 2024).

Os resultados indicaram que o sensor é capaz de diferenciar e quantificar concentrações variadas de fosfato e nitrato em soluções aquosas, demonstrando variações mensuráveis no coeficiente de transmissão e na frequência ressonante conforme as concentrações dos analitos. A aplicação da PCA permitiu uma classificação eficaz das amostras, evidenciando a capacidade do sensor em distinguir entre diferentes níveis de concentração dos nutrientes.

2.3.2 Detecção da concentração de açúcar e sal na água empregando um sensor de micro-ondas metamaterial ENZ

O estudo proposto por (EL-NADY et al. 2024) e desenvolveu um sensor de micro-ondas baseado em metamateriais epsilon-near-zero (ENZ) para a detecção de concentrações de açúcar e sal em soluções aquosas. O método utilizado combinou simulações numéricas e experimentos para validar a eficácia do sensor. O projeto do dispositivo inclui a integração de células ENZ e modificações na antena Vivaldi, otimizando a sensibilidade e a resposta em termos de variação de fase nos coeficientes de reflexão S_{11}. Essa abordagem permitiu explorar os efeitos específicos das propriedades de permissividade elétrica em frequências de micro-ondas, especialmente em ambientes líquidos.

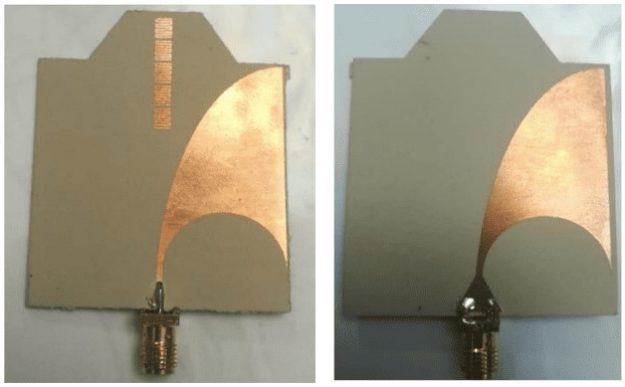


Figura 2.6: Design sensor micro-ondas ENZ com antena Vivaldi. Fonte: (EL-NADY et al. 2024).

Os principais resultados demonstraram que o sensor apresentou alta sensibilidade na detecção de variações mínimas nas concentrações de solutos. A análise experimental corroborou as previsões simuladas, evidenciando uma resposta precisa na faixa de frequências-alvo. A utilização da fase como parâmetro de análise mostrou-se mais eficaz do que métodos tradicionais baseados em amplitude, permitindo maior precisão em aplicações práticas.

2.3.3 Aprimoramento da detecção de nitrogênio amoniacal em aplicações de qualidade da água usando ressoadores de anel dividido complementares: Uma comparação entre as configurações retangular e circular

O sensor micro-ondas proposto por (ANAR et al. 2024*b*) investiga a melhoria da sensibilidade de ressonadores de anel dividido complementar (CSRR) na detecção de nitrogênio amoniacal ($NH_3 - N$) em aplicações de qualidade da água. A detecção de $NH_3 - N$ em baixas concentrações é crucial para o monitoramento da qualidade da água, exigindo o desenvolvimento de sensores altamente sensíveis.

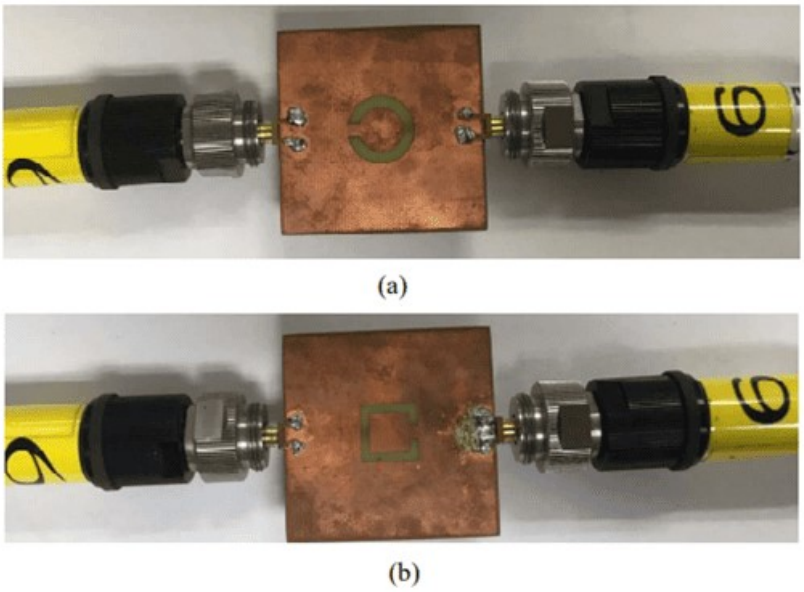


Figura 2.7: Design sensores micro-ondas propostos (a) Circular e (b) Quadrado. Fonte: (ANAR et al. 2024*a*).

O estudo compara as configurações de CSRR retangulares e circulares para avaliar sua eficácia na detecção de $NH_3 - N$. Os resultados indicaram que o CSRR circular de anel único apresentou um fator de qualidade (Q) superior em comparação com a configuração retangular. Além disso, o CSRR circular demonstrou uma maior sensibilidade na detecção de $NH_3 - N$, tornando-se uma opção mais eficaz para aplicações que requerem alta precisão na medição de concentrações de nitrogênio amoniacal.

2.3.4 Sensor de micro-ondas compacto baseado em CSRR para o controle do teor de água do solo

(LIRA et al. 2024) apresentou o desenvolvimento de um sensor de micro-ondas compacto baseado em um ressonador complementar de anel partido (CSRR) para a medição do conteúdo de água no solo. O sensor consiste em uma antena patch de microfita com CSRR inserido, projetada para detectar variações na permissividade relativa de materiais dielétricos, permitindo a determinação do teor de água em diferentes tipos de solo.

O método de estudo envolveu a simulação e fabricação de protótipos do sensor, seguidas de medições experimentais para caracterizar materiais dielétricos típicos. As simulações foram realizadas utilizando o software Ansoft HFSS medindo seus coeficientes de transmissão (S_{21}). A sensibilidade do sensor foi investigada por meio da caracterização de materiais dielétricos e da determinação do percentual de água em diferentes tipos de solo, como areia de quartzo e argila vermelha.

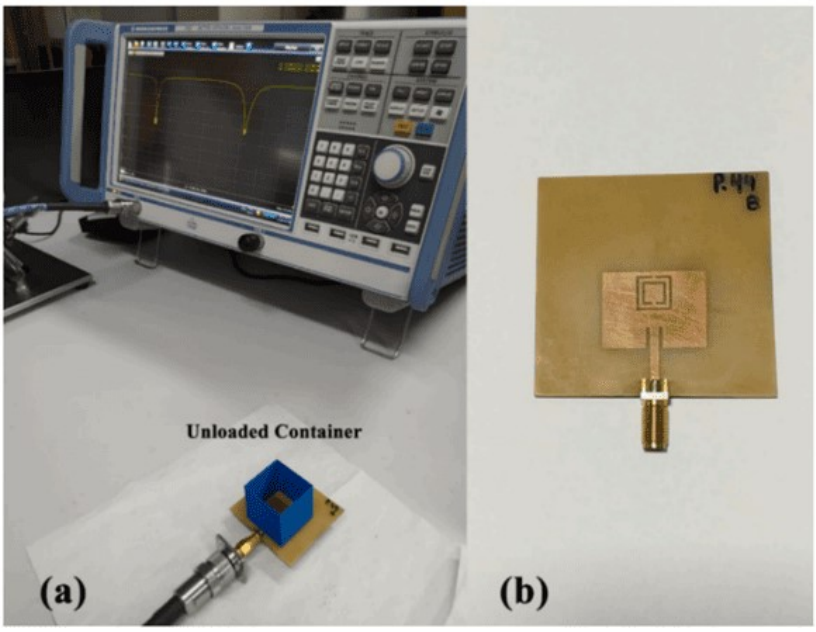


Figura 2.8: Configuração de medição e design sensor micro-ondas. Fonte: (LIRA et al. 2024).

Os resultados obtidos demonstraram que o sensor proposto é eficaz na caracterização da permissividade relativa de materiais dielétricos e na determinação do teor de água no solo. As medições mostraram que o sensor possui alta sensibilidade a pequenas variações na permissividade relativa, permitindo a detecção precisa do conteúdo de água em diferentes tipos de solo. Além disso, o sensor apresentou um fator de qualidade elevado e um tamanho compacto, facilitando sua aplicação em diversas áreas, como agricultura e monitoramento ambiental.

2.3.5 Sensor de micro-ondas não intrusivo multirressonante para identificação de líquidos

(YONG et al. 2024) mostrou o desenvolvimento de um sensor de micro-ondas não intrusivo baseado em múltiplos ressonadores de anéis divididos (SRRs) para identificação precisa de líquidos. A pesquisa propõe uma estrutura interdigital para os SRRs, ampliando a área de detecção e, consequentemente, a sensibilidade do sensor. Além disso, a integração de múltiplos SRRs com diferentes frequências de ressonância permite a medição de respostas em uma faixa de 2 a 6 GHz, aprimorando a precisão na identificação de líquidos, podemos ver na figura 2.9.

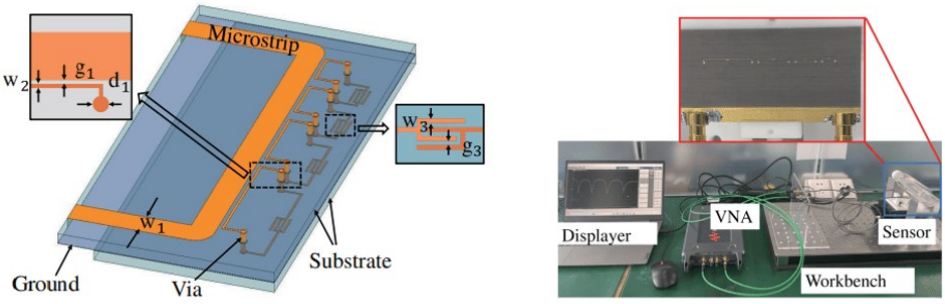


Figura 2.9: Design sensor micro-ondas e configuração de medição. Fonte: (YONG et al. 2024).

Os resultados experimentais demonstraram que o sensor desenvolvido possui alta sensibilidade e precisão na identificação de líquidos, destacando-se como uma ferramenta promissora para aplicações que requerem monitoramento não intrusivo e de alta precisão. A combinação de múltiplos SRRs com diferentes frequências de ressonância e a estrutura interdigital inovadora contribuem significativamente para o avanço na área de sensores de micro-ondas para identificação de líquidos.

2.3.6 Sensores de Micro-ondas para Monitoramento In Situ de Metais Traço em Água Poluída

O estudo investiga uma nova técnica para monitorar traços de metais em águas poluídas usando espectroscopia de micro-ondas e sensores planares. Essa abordagem inovadora tem como objetivo abordar o desafio ambiental significativo representado por metais tóxicos residuais, especialmente em áreas afetadas por atividades de mineração abandonadas. Os pesquisadores desenvolveram sensores de micro-ondas submersíveis capazes de realizar medições in situ em tempo real da qualidade da água, visando especificamente à detecção de contaminação por traços de metais.

A metodologia envolveu o teste dos sensores em quatro áreas de mineração poluídas no Reino Unido, onde eles demonstraram a capacidade de detectar os níveis de poluição da água com uma resposta imediata. Os sensores identificaram três picos ressonantes distintos na faixa de 1 a 3 GHz, que correspondiam a níveis variados de contaminação. Isso marcou a primeira aplicação bem-sucedida de sensores de micro-ondas planares em ambientes reais, demonstrando seu potencial para classificar a qualidade da água com base nos níveis de poluição.

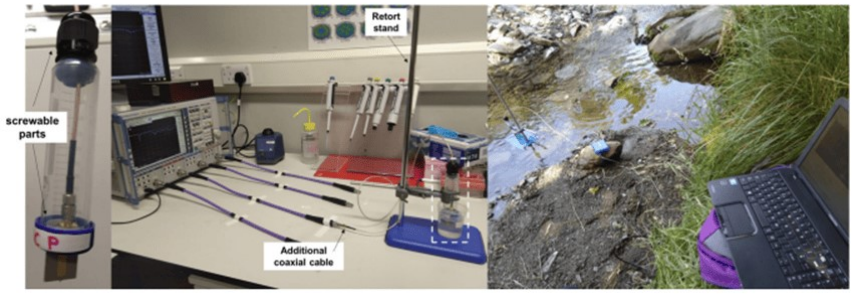


Figura 2.10: Configuração de medidas: em laboratório e em In Situ. Fonte: (FRAU et al. 2021*a*).

Os resultados do estudo indicaram que os sensores adaptados de eletrodos interdigitados (IDE) de oito pares poderiam quantificar os níveis de contaminação em frequências ressonantes específicas, fornecendo um meio confiável de avaliar a qualidade da água. As descobertas destacam a viabilidade do uso da espectroscopia de micro-ondas como uma tecnologia eficaz e de baixo custo para o monitoramento em tempo real de traços de metais na água, oferecendo um avanço significativo nas práticas de monitoramento ambiental. A pesquisa ressalta o potencial desses sensores para facilitar intervenções oportunas em resposta às mudanças na qualidade da água, contribuindo, em última análise, para melhorar a saúde pública e o gerenciamento ambiental, conforme apontado por (FRAU et al. 2021*b*).



Figura 2.11: Design sensor IDE proposto. Fonte: (FRAU et al. 2021*b*).

2.3.7 Sensor de Micro-ondas Inspirado em Metamaterial para Detectar a Concentração de Fosfato e Nitrato Mistos na Água

O estudo aborda a construção de um sensor de micro-ondas inspirado em metamateriais para medir concentrações de fosfato, nitrato e suas misturas em soluções aquosas. O dispositivo proposto é baseado em uma linha microstrip acoplada a um ressonador de anel partido complementar quadrado (SCSRR), operando na faixa de frequência de 1,0 a 1,2 GHz. O sensor foi projetado para maximizar a intensidade do campo elétrico na área ativa, resultando em maior sensibilidade e seletividade.

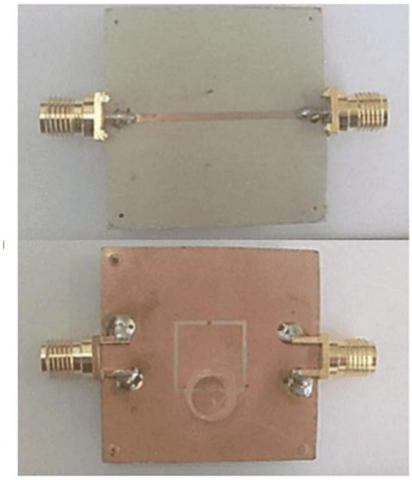


Figura 2.12: Design sensor micro-ondas SCSRR proposto. Fonte: (HARNSOONGNOEN et al. 2019).

Foram realizadas medições do coeficiente de transmissão (S_{21}) e da frequência de ressonância para diferentes concentrações de fosfato e nitrato (0 a 1 mg/ml), utilizando-se água desionizada. Os resultados indicaram que o aumento das concentrações de nitrato e fosfato diminuiu a magnitude de S_{21}, e a frequência de ressonância variou com base nas propriedades dielétricas e condutivas das amostras. Além disso, foi utilizado o método de análise de componentes principais (PCA) para classificar e discriminar as soluções testadas, conforme apontado por (HARNSOONGNOEN et al. 2019).

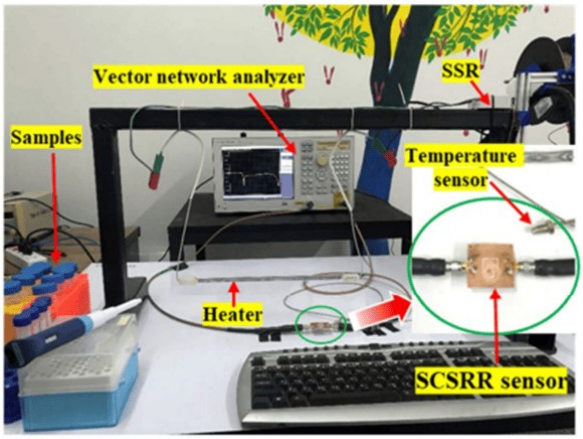


Figura 2.13: Configuração do setup de medição mostrando o sensor e seus principais componentes. Fonte: (HARNSOONGNOEN et al. 2019).

2.3.8 Sensoriamento de Micro-ondas da Concentração de Amônia e Ferro na Água com Base em Resistor de Anel Duplo Complementar

(YEE et al. 2021) aborda o desenvolvimento de um sensor de micro-ondas baseado em um ressonador de anel partido duplo complementar (DSRR) para detectar concentrações de amônia e ferro em amostras de água. A técnica tradicional de medição dessas substâncias depende de instrumentos volumosos e caros, além de envolver reagentes químicos perigosos e procedimentos complexos. O trabalho propõe uma alternativa mais simples, portátil e de baixo custo, que utiliza um sensor de micro-ondas para medir o deslocamento da frequência de ressonância causado pela variação nas concentrações de amônia e ferro. As amostras foram aplicadas à área sensora do dispositivo, que consistia em uma antena retangular com ressonadores de anel partido duplo complementares, otimizados para operar na frequência de ressonância de 2,38 GHz.

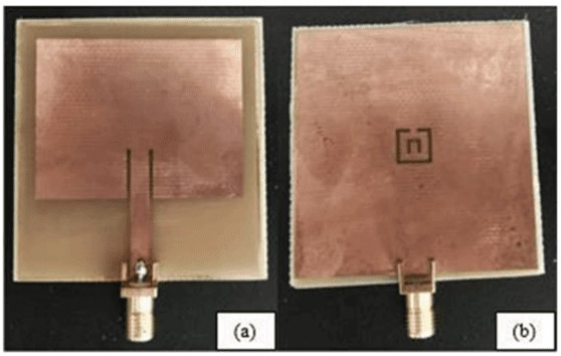


Figura 2.14: Design sensor micro-ondas DSRR proposto. Fonte: (YEE et al. 2021).

Os principais resultados mostraram que o sensor apresentou sensibilidade média de 0,0067 GHz/(mg/L) para amônia e 0,0112 GHz/(mg/L) para ferro, com o sensor demonstrando maior sensibilidade ao ferro. A contribuição principal deste estudo é a proposta de um sensor eficiente e de baixo custo para monitoramento da qualidade da água, capaz de detectar amônia e ferro em concentrações relevantes.

2.3.9 1.3.9. Sensor Planar de Micro-ondas Sem Contato para Detecção de Água de Alta Salinidade Contendo NaCl, KCl, CaCl2, MgCl2 e Na2CO3

O estudo apresenta um novo sensor de micro-ondas planar sem contato projetado para a detecção de água de alta salinidade contendo vários sais de cloreto e carbonato, especificamente cloreto de sódio (NaCl), cloreto de potássio (KCl), cloreto de magnésio (MgCl2), cloreto de cálcio (CaCl2) e carbonato de sódio (Na2CO3). Esse sensor integra uma linha de microfita e um ressonador de anel dividido (SRR) com um orifício circular no centro, permitindo a medição eficaz das concentrações de sal sem contato direto com a amostra. O sensor foi fabricado usando uma técnica de litografia fotorresistente de filme seco, o que facilita a fabricação precisa dos componentes do sensor.

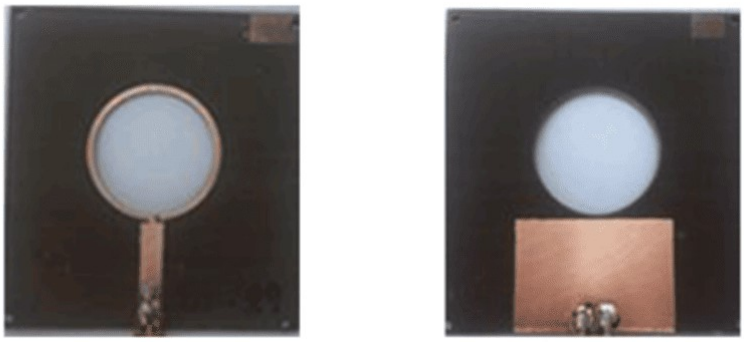


Figura 2.15: Design sensor micro-ondas proposto. Fonte: (HARNSOONGNOEN & WANTHONG 2021).

A configuração experimental envolveu a medição de soluções salinas em concentrações que variam de 40 mg/mL a 200 mg/mL em uma faixa de frequência de 0,5 GHz a 2,2 GHz. O desempenho do sensor foi validado por meio de simulação e medições experimentais, com foco no coeficiente de reflexão (S_{11}) e na frequência de ressonância (fr).

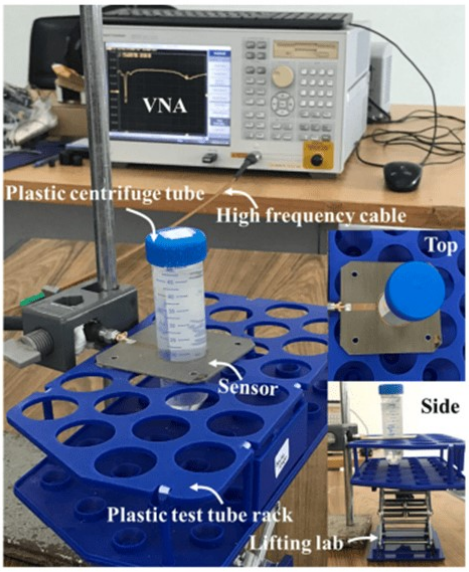


Figura 2.16: Configuração do setup de medição mostrando o sensor e seus principais componentes. Fonte: (HARNSOONGNOEN & WANTHONG 2021).

Os resultados apontados por (HARNSOONGNOEN & WANTHONG 2021) indicam que, com o aumento da concentração de sal, a magnitude de S_{11} apresentou variações distintas em diferentes picos de ressonância, demonstrando a sensibilidade do sensor às mudanças na salinidade. Em suma, essa pesquisa ressalta a eficácia das técnicas de detecção por micro-ondas para a detecção não invasiva de substâncias inorgânicas em soluções aquosas.

2.3.10 Sensoriamento de Micro-ondas da Qualidade da Água

O estudo apresenta um array de sensores de micro-ondas projetado para operar na banda de 1 a 10 GHz e na detecção e avaliação da qualidade da água. A pesquisa enfatiza a necessidade de dados finos e dinâmicos para compreender as interações complexas entre os estressores ambientais, como a poluição e as mudanças climáticas. A utilização de sensores de micro-ondas é proposta como uma solução eficaz para o monitoramento, permitindo medições rápidas e confiáveis de parâmetros como condutividade, permissividade e temperatura. Além disso, o estudo sugere a aplicação de algoritmos de aprendizado de máquina e reconhecimento de padrões para a detecção autônoma de contaminantes, visando aumentar a precisão na avaliação da qualidade da água. A pesquisa também aborda a influência da temperatura nas medições, propondo métodos de calibração para mitigar seus efeitos.

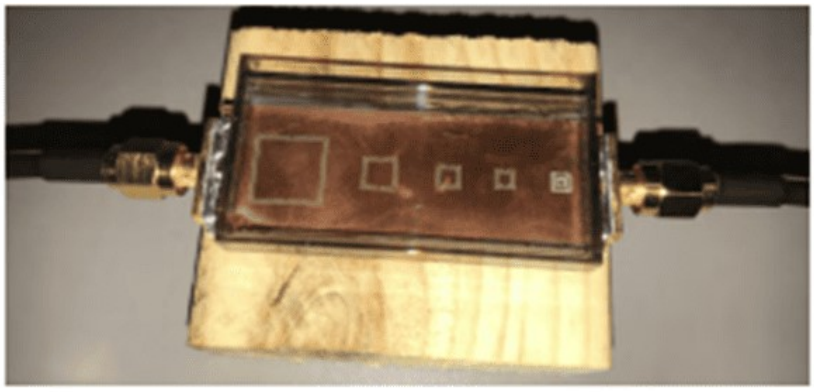


Figura 2.17: Design do array de sensores micro-ondas proposto. Fonte: (ZHANG et al. 2019).

Em suma, (ZHANG et al. 2019) investigam a crescente necessidade de monitoramento da qualidade da água em um contexto de estresse ambiental causado por fatores como crescimento populacional, urbanização e mudanças climáticas. A poluição das fontes hídricas, especialmente devido ao escoamento agrícola, é um dos principais problemas abordados, resultando em surtos de algas e diminuição do oxigênio dissolvido, o que afeta negativamente os ecossistemas aquáticos

Ano	**Autores**	**Tecnologia utilizada**	**Poluente Analisado**	**Contribuição**
2024	Imran Basha Syed, Baranidharan Sundaram e S. Yuvaraj	SSRR	Nitrato e Fosfato	Utilização de um design inovador de SSRR com extremidade afilada para melhorar a sensibilidade, e a integração de técnicas de análise multivariada.
2024	Shaza El-Nady, Asmaa Afifi e Anwer S. Abd El-Hameed	Antena Vivaldi e ENZ	Sal e Açúcar	Desenvolvimento de um sensor compacto, de baixo custo e com alta precisão, que pode ser aplicado em indústrias alimentícias e ambientais para monitoramento da qualidade de líquidos.
2024	N. F. S. S. Anar et al.	CSRR	Nitrogênio Amoniacal	Cria sensores de micro-ondas mais eficientes para o monitoramento da qualidade da água, especialmente na detecção de contaminantes em baixas concentrações e compara diferentes geometrias.
2024	Ruann Victor de Andrade Lira et al.	Antena Patch e CSRR	Solo e Água	Desenvolvimento de um sensor de micro-ondas compacto e de alta sensibilidade baseado em CSRR para a medição do teor de água no solo
2024	Jinglei Yong, Xingli He, Lingfeng Li, Peng Li, e Yunjing Zhang	SRR	Etanol, água DI Metanol, Acetona, Éter	A combinação de múltiplos SRRs com diferentes frequências de ressonância e a estrutura interdigital inovadora
2021	Ilaria Frau, Stephen Wylie, Patrick Byrne, Patrizia Onnis, Jeff Cullen, Alex Mason e Olga Korostynska	IDE e IDC	Água corrente	Desenvolvimento de um design de sensor de microondas para o monitoramento em tempo real de traços de metais afetadas por atividades de mineração.
2021	Supakorn Harnsoongnoen	SCSRR	Fosfato e Nitrato	O sensor foi capaz de detectar e diferenciar eficientemente concentrações de nitrato, fosfato e suas misturas, com alta sensibilidade em baixas concentrações.
2021	Yee Ska, Ong Ntj, Lim Scj, Mohd, Zin Ns, Sh Dahlan, Ayi Ashyap e Cf Soon	CSRR	Amônia e ferro	O estudo oferece uma alternativa promissora para técnicas convencionais, com potencial para ser integrada em sistemas portáteis de medição de qualidade da água, promovendo monitoramento em tempo real e in situ.
2021	Supakorn Harnsoongnoen, e Anuwat Wanthong	SRR	NaCl, KCl, CaCl2, MgCl2 e Na2CO3	O uso análise de componentes principais (PCA) para classificar os dados e estabelecer correlações entre a concentração de sal e os parâmetros medidos.
2019	Kunyi Zhang, Reza K. Amineh, Ziqian Dong e David Nadler	CSRR	Nitrato, Fosfato, Amonia, Cromio, Mercurio, Chumbo, pH da Agua	Criação de um array de sensores de microondas para testes de qualidade da água em diversos tipos de amostra.

Tabela 2.3: Resumo dos artigos que contribuíram para a pesquisa de projetos de sensores para o monitoramento de qualidade da água. Fonte: Autor, 2024.

A tabela 2.3 sintetiza a vanguarda da pesquisa em sensores de micro-ondas para monitoramento da qualidade da água entre 2019 e 2024, destacando o uso dominante de Estruturas Ressonantes (SRR, CSRR, IDC) como principal tecnologia para alcançar alta sensibilidade e detecção de contaminantes em baixas concentrações. Os estudos recentes focam em designs inovadores e na integração de análise multivariada para aprimorar a detecção e diferenciação de poluentes críticos como nitrato, fosfato e metais pesados. Esta convergência tecnológica visa o desenvolvimento de dispositivos compactos, de baixo custo e alta precisão, com o objetivo de oferecer soluções portáteis e em tempo real para

o monitoramento ambiental e industrial, consolidando as estruturas ressonantes como a espinha dorsal para o avanço do sensoriamento químico na qualidade da água.

2.3.11 Considerações Gerais

A revisão de bibliografia apresentada demonstra, principalmente que a pesquisa em sensores planares de micro-ondas para qualidade da água é um campo em rápida e robusta evolução. Com o crescimento no uso de sensores de micro-ondas para medição de poluentes na água tem se tornado cada vez mais discutidos estudos fundamentais que forneceram a base teórica para o desenvolvimento dessa tecnologia. Além disso, verificou-se que esses sensores possuem características promissoras, pois, devido à sua adaptabilidade, podem ser aplicados de maneira eficaz no monitoramento da qualidade da água em diferentes contextos de pesquisa ambiental.

A tecnologia de Estruturas Ressonantes (SRR, CSRR) emergiu claramente como o vetor principal de inovação, confirmada tanto pela sua frequência na literatura recente quanto pela sua contribuição direta para a criação de dispositivos de alta sensibilidade e compactos. Essa ênfase tecnológica está intrinsecamente ligada à necessidade de monitorar poluentes cruciais, como nitratos, fosfatos e metais pesados, em baixas concentrações, conforme detalhado nos artigos de 2021 a 2024.

O campo de pesquisa está se movendo de um foco em detecção básica para soluções multifuncionais que integram designs aprimorados, como as geometrias inovadoras de IDC, com análise multivariada de dados. Essa abordagem não apenas melhora a precisão, mas também permite a diferenciação eficaz de múltiplos contaminantes. Em última análise, a trajetória da pesquisa aponta para a consolidação de sistemas de sensoriamento portáteis e em tempo real que transformarão o monitoramento ambiental, tornando-o mais acessível e eficaz no controle da qualidade da água.

Capítulo 3

Referêncial Teórico

O aprendizado de máquina (*machine learning*) é uma área da inteligência artificial que desenvolve algoritmos capazes de aprender padrões a partir de dados (Kazemi et al. 2024). Em vez de construir um modelo puramente baseado em equações físicas, utiliza-se o poder dos dados para que o algoritmo aprenda relações complexas, muitas vezes não lineares, entre variáveis de entrada e saída (Kazemi et al. 2024). Esse paradigma é especialmente útil em sistemas complexos como sensores de micro-ondas, onde parâmetros como a frequência de ressonância e a amplitude do parâmetro $|S_{21}|$ podem estar relacionados de forma não trivial com a permissividade relativa ε_r ou com a presença de contaminantes (Sim et al. 2024). Nesse sentido, é apresentado um resumo teórico focado na discussão dos principais conceitos empregados nas análises e tomadas de decisão da aprendizagem máquina.

3.1 Regressão vs Classificação

Regressão O objetivo é prever valores numéricos contínuos. No nosso caso, queremos estimar a curva da permissividade relativa $\varepsilon_r(f)$ em função da frequência. Outros exemplos incluem previsão de preços de imóveis ou previsão de temperatura (Harnsoongnoen et al. 2025).

Classificação O objetivo é atribuir uma classe ou categoria a cada amostra. Neste estudo, desejamos classificar a amostra em uma das três classes: *Água Destilada*, *Água + Fosfato* ou *Água + Nitrato*. Exemplos em outras áreas incluem reconhecimento de dígitos escritos à mão e diagnóstico de doenças (Lei et al. 2025).

3.2 Pré-processamento de Dados

Antes de treinar modelos, é essencial preparar os dados:

- **Análise Exploratória**: gera estatísticas descritivas, gráficos (boxplots, histogramas) e correlações para entender o comportamento dos dados.
- **Tratamento de Valores Faltantes**: valores ausentes podem ser substituídos pela média, mediana ou imputados por algoritmos.

- **Detecção de Outliers**: pontos muito diferentes dos demais podem distorcer os modelos. Métodos como IQR, box-plot ou z-score ajudam a identificar.
- **Escalonamento**: padronização (z-score) ou normalização (min-max) asseguram que atributos com escalas diferentes tenham a mesma importância.
- **Codificação de Variáveis Categóricas**: categorias são transformadas em números, por exemplo, via one-hot encoding.
- **Divisão de Dados**: separar treino, validação e teste assegura avaliação justa do desempenho.

3.3 Modelos de Regressão

3.3.1 Regressão Linear

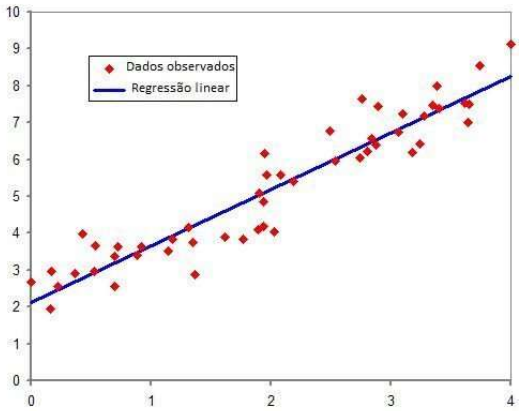


Figura 3.1: Regressão linear. Fonte: Autor, 2025.

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_p x_p. \tag{3.1}$$

$\hat{y}$ é a predição do modelo. $x_1, x_2, ..., x_p$ são as variáveis de entrada. Os coeficientes β_i indicam o peso de cada variável. β_0 é o intercepto. O modelo ajusta esses valores para minimizar a diferença entre y real e $\hat{y}$ previsto (Mosavirik et al. 2023).

3.3.2 Regressão Polinomial

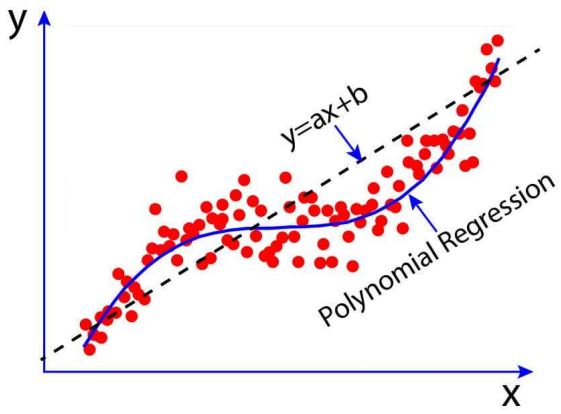


Figura 3.2: Regressão Polinomial. Fonte: Autor, 2025.

$$\hat{y} = \beta_0 + \beta_1 x + \beta_2 x^2 + \cdots + \beta_d x^d. \tag{3.2}$$

É como a regressão linear, mas adiciona potências da variável x. Isso permite que o modelo capture curvas em vez de apenas linhas retas (Cardinali et al. 2025).

3.3.3 SGD Regressor

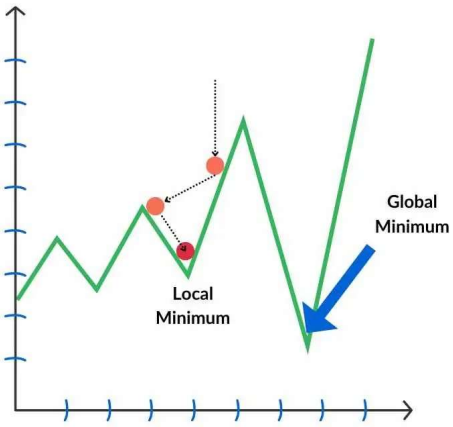


Figura 3.3: Regressão SGD. Fonte: Neri Otten, 2024.

O Stochastic Gradient Descent (SGD) é um método iterativo muito usado em machine learning e em otimização para encontrar os melhores parâmetros de um modelo, de forma a minimizar a função objetivo. Ele é especialmente útil quando trabalhamos com grandes

conjuntos de dados, permitindo que o modelo aprenda de forma eficiente mesmo em situações complexas (Lajnef et al. 2015). Sua formula é dada por:

$$\beta_j \leftarrow \beta_j - \eta \cdot \frac{\partial J}{\partial \beta_j}. \tag{3.3}$$

O parâmetro β_j é ajustado a cada iteração. J é a função de erro (como MSE). η é a taxa de aprendizado. O algoritmo move os coeficientes na direção que diminui o erro.

3.3.4 MLP Regressor

$$\hat{y} = f\left(W^{(2)} g(W^{(1)} x + b^{(1)}) + b^{(2)}\right). \tag{3.4}$$

As entradas x são multiplicadas por pesos W, somadas a vieses b, passam por funções de ativação g e produzem a saída $\hat{y}$. O processo se repete em várias camadas (Kazemi & Moradi 2021).

3.3.5 Decision Tree

Divide os dados em grupos cada vez mais homogêneos. Cada divisão é escolhida para minimizar o erro médio quadrático em cada nó.

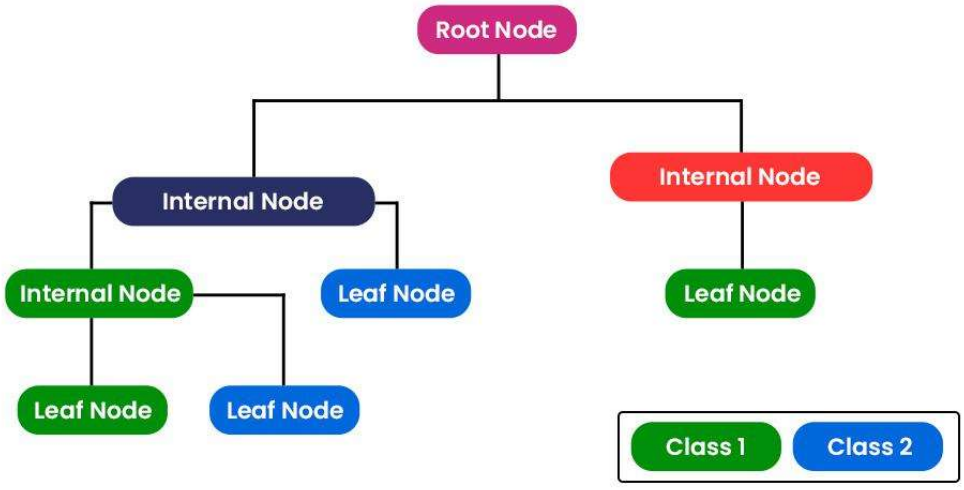


Figura 3.4: Exemplo Árvore de Decisão. Fonte: Al-Absi et, al., 2024.

O modelo de árvore de decisão é representado como uma árvore binária. Cada nó da árvore corresponde a uma variável de entrada (x) e a um ponto de divisão dessa variável (considerando que ela seja numérica). Já os nós folha contêm a variável de saída (y), que é usada para gerar a previsão. Para fazer uma previsão, percorremos a árvore seguindo as

divisões até chegar a uma folha, onde encontramos o valor da classe correspondente (Rai et al. 2024).

As árvores de decisão são muito eficientes, permitindo fazer previsões rapidamente. Além disso, costumam ser precisas em uma ampla variedade de problemas e não exigem etapas complexas de preparação dos dados antes do uso.

3.3.6 Random Forest

O Random Forest é um algoritmo baseado em várias árvores de decisão que trabalham em conjunto. Ele costuma ser treinado com a técnica chamada bagging, que parte da ideia de que, quando combinamos diferentes modelos, o resultado tende a ser melhor do que o de cada modelo individualmente (Li et al. 2025).

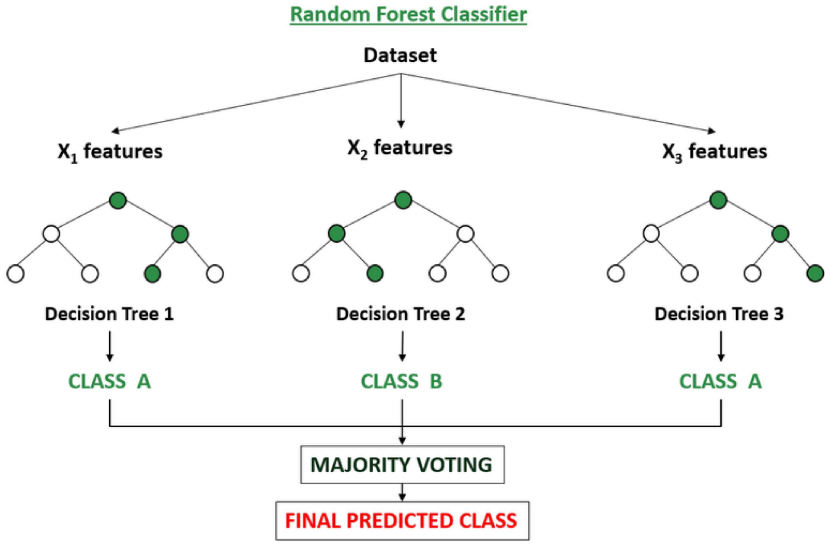


Figura 3.5: Exemplo Random Forest. Fonte: Al-Absi et, al., 2025.

Na prática, esse classificador reúne os hiperparâmetros tanto de uma árvore de decisão quanto do próprio bagging, permitindo controlar como as árvores vão interagir entre si. Em vez de montar manualmente um modelo de bagging e depois ajustá-lo a uma árvore de decisão, é muito mais prático utilizar diretamente a classe de floresta aleatória.

Por conta dessa versatilidade, o Random Forest tem aplicações em várias áreas. No setor bancário, por exemplo, ele pode prever quais clientes têm maior chance de usar determinados serviços ou de pagar suas dívidas em dia. No mercado financeiro, ajuda a estimar o desempenho futuro de ações. Já na saúde, auxilia tanto na escolha da melhor combinação de medicamentos quanto na análise de históricos clínicos para identificar possíveis doenças. No e-commerce, é usado para personalizar recomendações, prevendo se um cliente vai gostar de um produto e sugerindo aqueles que mais se alinham ao seu perfil.

$$\hat{y} = \frac{1}{T}\sum_{t=1}^{T} h_t(x). \tag{3.5}$$

Cada $h_t(x)$ é a previsão de uma árvore. A previsão final é a média de todas as árvores.

3.3.7 Support Vector Regressor (SVR)

$$|y_i - (w \cdot x_i + b)| \leq \varepsilon. \tag{3.6}$$

O modelo tenta prever valores dentro de uma margem ε ao redor dos pontos reais. Se passar dessa margem, aplica penalidade.

3.4 Modelos de Classificação

3.4.1 Regressão Logística

A Regressão Logística é um algoritmo de machine learning supervisionado utilizado para problemas de classificação. Diferente da regressão linear, que prevê valores contínuos, a regressão logística estima a probabilidade de uma entrada pertencer a uma classe específica (Musa et al. 2025).

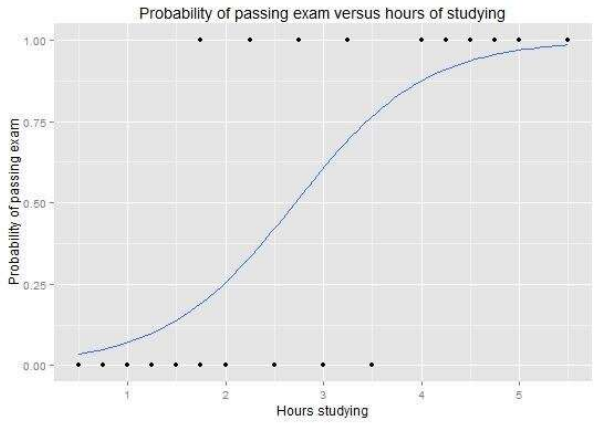


Figura 3.6: Exemplo Classificador por Regressão Logística. Fonte: Whitfield, 2025.

Ela é geralmente usada para classificação binária, em que o resultado pode ser uma de duas categorias possíveis, como Sim/Não, Verdadeiro/Falso ou 0/1. Para isso, o algoritmo utiliza a função sigmoide, que transforma os valores de entrada em uma probabilidade entre 0 e 1.

$$P(y = 1|x) = \frac{1}{1 + e^{-(w^T x + b)}}. \tag{3.7}$$

O modelo dá como saída a probabilidade de uma amostra pertencer à classe positiva. O resultado varia de 0 a 1.

3.4.2 Decision Tree Classifier

Fórmula do índice de Gini

$$Gini = 1 - \sum_{k=1}^{K} p_k^2. \tag{3.8}$$

p_k é a proporção de amostras da classe k em um nó. Quanto menor o Gini, mais puro é o nó.

3.4.3 Random Forest Classifier

$$\hat{y} = \text{mode}\{h_t(x)\}_{t=1}^{T}. \tag{3.9}$$

Cada árvore vota em uma classe e a classe mais votada é escolhida.

3.4.4 K-Nearest Neighbors (KNN)

O KNN (K-Nearest Neighbors) é um algoritmo que classifica novos dados analisando a semelhança com seus vizinhos mais próximos, ou seja, outros dados que possuem características parecidas (Ting et al. 2024).

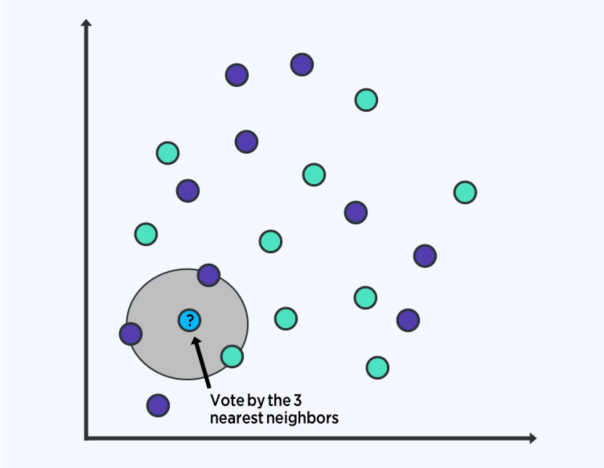


Figura 3.7: Exemplo Classificador por KNN. Fonte: Whitfield, 2025.

A ideia é simples: itens semelhantes tendem a estar próximos uns dos outros. Assim, o algoritmo tenta encaixar o dado em questão no grupo formado pelos seus vizinhos. O que muda é o valor de K (a letra “K” do nome), que define quantos vizinhos serão considerados. Quanto mais próximos estiverem os vizinhos, maior a chance de eles realmente

serem parecidos. Dependendo do valor escolhido para K, o algoritmo pode considerar, por exemplo, os 3 vizinhos mais próximos ou até os 50 mais próximos.

$$D(x_i, x_j) = \sqrt{\sum_{m=1}^{p} (x_{im} - x_{jm})^2}. \tag{3.10}$$

D é a distância entre duas amostras. O modelo olha para os k vizinhos mais próximos e escolhe a classe mais frequente.

3.4.5 Gaussian Naive Bayes

Por ser simples e rápido, o Naive Bayes é um modelo bastante usado hoje em dia e geralmente apresenta um desempenho superior em comparação a outros classificadores. Além disso, ele consegue obter boas previsões mesmo com uma quantidade relativamente pequena de dados de teste (Harrsion et al. 2020).

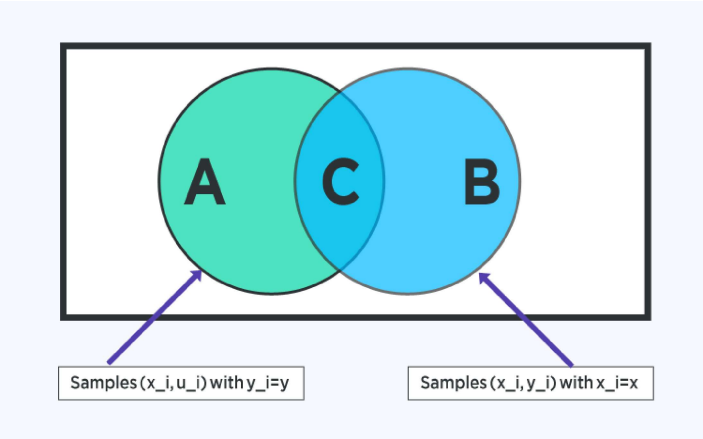


Figura 3.8: Exemplo Classificador por GNB. Fonte: Whitfield, 2025.

O motivo pelo qual ele é chamado de “naive” (ingênuo) está na sua principal característica: o algoritmo ignora completamente a correlação entre as variáveis. Ou seja, se quisermos classificar uma fruta como “laranja” com base em características como “cor amarela”, “formato arredondado” e “diâmetro de 8 cm”, o Naive Bayes trata cada uma dessas características de forma independente, sem considerar como elas podem estar relacionadas entre si.

$$P(B|A) = \frac{P(A|B)P(B)}{P(A)}. \tag{3.11}$$

O modelo usa o teorema de Bayes. Assume que as variáveis são independentes e que seguem uma distribuição gaussiana.

3.4.6 MLP Classifier

O Multi-Layer Perceptron (MLP) é uma rede neural composta por camadas densamente conectadas que transformam os dados de entrada de uma dimensão para outra. Ele é chamado de "multi-layer" (multicamadas) porque possui uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. O objetivo do MLP é modelar relações complexas entre entradas e saídas, permitindo que padrões complicados nos dados sejam aprendidos (Darwish et al. 2024).

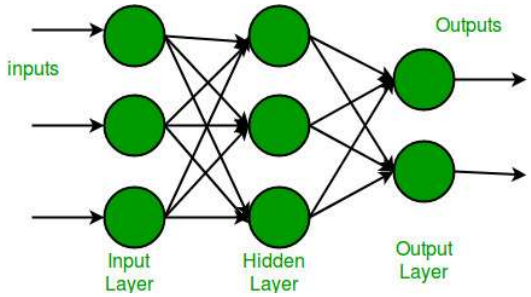


Figura 3.9: Exemplo Classificador por MLP. Fonte: Autor, 2025.

Os Componentes do Multi-Layer Perceptron (MLP) são

- Camada de entrada: Cada neurônio ou nó desta camada representa uma característica (feature) de entrada. Por exemplo, se você tiver três características de entrada, a camada de entrada terá três neurônios.
- Camadas ocultas: O MLP pode ter qualquer número de camadas ocultas, e cada uma pode conter diversos neurônios. Essas camadas processam as informações recebidas da camada de entrada, extraindo padrões e relações mais complexas.
- Camada de saída: A camada de saída gera a previsão final ou o resultado do modelo. Se houver múltiplas saídas, a camada terá um neurônio correspondente para cada resultado esperado.

Sua equação é frequentemente dado por:

$$P(y = k|x) = \frac{e^{z_k}}{\sum_{j=1}^{K} e^{z_j}}. \tag{3.12}$$

A função softmax transforma as saídas em probabilidades que somam 1. A classe escolhida é a de maior probabilidade.

3.4.7 Support Vector Machine (SVM)

O SVM (Support Vector Machine) é muito usado para tarefas de classificação. A ideia principal do algoritmo é encontrar um hiperplano em um espaço de N dimensões (onde N é o número de variáveis) que consiga separar os dados em classes diferentes (Farouk et al. 2025).

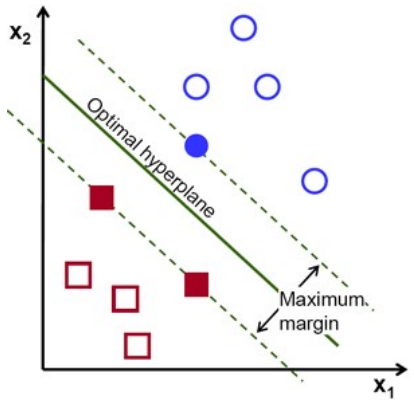


Figura 3.10: Exemplo Classificador por SVM. Fonte: Agarap, 2017.

Os hiperplanos funcionam como limites de decisão, ajudando a determinar a qual classe cada ponto do conjunto de dados pertence. Os pontos que ficam de lados opostos do hiperplano são atribuídos a classes diferentes.

A forma do hiperplano depende da quantidade de variáveis de entrada: se forem 2, o hiperplano é apenas uma linha; se forem 3, ele se torna um plano tridimensional. Quando o número de variáveis excede 3, fica mais difícil visualizar, mas o conceito continua o mesmo, ou seja, o hiperplano ainda separa os dados em classes diferentes.

$$y_i(w^T x_i + b) \geq 1. \tag{3.13}$$

O modelo busca o hiperplano que separa melhor as classes, maximizando a margem entre os pontos das diferentes classes.

3.5 Métricas de Avaliação

Regressão

$$\text{MSE} = \frac{1}{n}\sum(y_i - \hat{y}_i)^2, \qquad \text{Mede o erro quadrático médio.} \tag{3.14}$$

$$\text{MAE} = \frac{1}{n}\sum|y_i - \hat{y}_i|, \qquad \text{Mede o erro absoluto médio.} \tag{3.15}$$

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2}, \quad \text{Indica quanto da variabilidade dos dados é explicada pelo modelo.} \tag{3.16}$$

Classificação

$$\text{Accuracy} = \frac{no.\,of\ correct\ preditions}{Total\ no.\,of\ preditions}, \tag{3.17}$$

$$\text{Precision} = \frac{TP}{TP+FP}, \tag{3.18}$$

$$\text{Recall} = \frac{TP}{TP+FN}, \tag{3.19}$$

$$\text{F1} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}. \tag{3.20}$$

A curva ROC e a área sob a curva (AUC) são calculadas considerando classificadores *one-vs-rest* para o caso multiclasse.

Curva ROC e AUC A curva ROC (*Receiver Operating Characteristic*) representa graficamente a relação entre a taxa de verdadeiros positivos (TPR) e a taxa de falsos positivos (FPR), variando o limiar de decisão do classificador. Cada ponto da curva corresponde a um valor de limiar específico, mostrando o compromisso entre sensibilidade e especificidade (Seyyedmasoumian et al. 2025).

A área sob a curva (AUC) quantifica a capacidade discriminativa do modelo. Um valor de AUC igual a 0,5 indica desempenho aleatório, enquanto valores próximos de 1,0 indicam excelente separação entre classes.

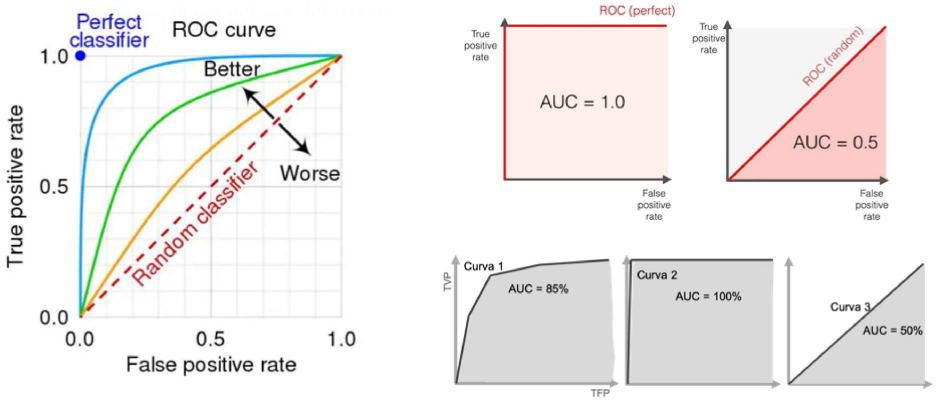


Figura 3.11: Exemplo curva ROC AUC. Fonte: Mesuga, 2022.

No caso de problemas multiclasse, utiliza-se a estratégia
textbfone-vs-rest. Para cada classe, constrói-se uma curva ROC tratando aquela classe como positiva e todas as demais como negativas. Em seguida, podem ser calculadas AUCs individuais por classe e também uma AUC média (macro ou micro), que resume o desempenho geral do classificador em cenários multiclasse.

Essa abordagem garante uma avaliação detalhada do desempenho de classificadores em múltiplas classes, permitindo comparar a sensibilidade e especificidade de cada modelo de forma justa.

3.6 Validação cruzada

Para garantir robustez, serão aplicadas as técnicas Leave-One-Out (LOO), Stratified K-Fold (SKF) e Repeated Stratified K-Fold (RSKF). O processo de validação cruzada divide os dados em treino e teste de forma iterativa, preservando proporções de classes.

A validação cruzada é um procedimento estatístico utilizado para avaliar o desempenho de modelos de aprendizado de máquina de forma mais confiável e robusta. Seu objetivo é mitigar problemas de sobreajuste (overfitting) e subajuste (underfitting), fornecendo uma estimativa mais realista da capacidade de generalização do modelo em dados não vistos (Tao et al. 2025).

Em vez de realizar uma única divisão entre treino e teste, a validação cruzada explora diferentes partições do conjunto de dados. Assim, cada amostra é utilizada em algum momento para teste e em outro para treino. Esse processo reduz o viés na avaliação e a variância dos resultados, oferecendo métricas mais estáveis.

Leave-One-Out (LOO) No método Leave-One-Out, cada amostra do conjunto é usada isoladamente como teste, enquanto todas as demais $n-1$ formam o conjunto de treino. Isso significa que, para n amostras, o modelo será treinado n vezes. Embora seja um dos métodos mais completos, pois aproveita ao máximo os dados, seu custo computacional é elevado. É especialmente útil quando o número de amostras é pequeno (Seyyedmasoumian et al. 2025).

Stratified K-Fold (SKF) No Stratified K-Fold, o conjunto de dados é dividido em K subconjuntos (folds), garantindo que a proporção de classes seja preservada em cada divisão. Em cada iteração, um fold é usado como teste e os $K-1$ restantes como treino. Esse processo se repete até que todos os folds tenham sido usados como teste. Esse método é ideal para problemas de classificação, pois assegura representatividade das classes em cada etapa (Seyyedmasoumian et al. 2025).

Repeated Stratified K-Fold (RSKF) O Repeated Stratified K-Fold repete o processo do Stratified K-Fold várias vezes, cada vez com divisões aleatórias diferentes. Isso aumenta a robustez da avaliação, fornecendo uma distribuição de métricas (como acurácia, precisão e F1-score) ao longo de diferentes partições. A média e o desvio padrão dessas métricas permitem comparar modelos com mais confiabilidade (Seyyedmasoumian et al. 2025).

Vantagens e limitações

- LOO: utiliza ao máximo os dados, mas é custoso e pode ser instável se houver outliers.
- SKF: balanceia bem custo computacional e representatividade das classes; amplamente usado.
- RSKF: fornece estimativas ainda mais estáveis, mas exige maior tempo de processamento.

Em conjunto, esses métodos ajudam a comparar diferentes algoritmos de regressão e classificação, garantindo que o desempenho reportado não dependa de uma única divisão arbitrária do conjunto de dados.

3.7 Síntese final

Este referencial teórico fornece um arcabouço matemático e conceitual dos principais modelos de regressão e classificação aplicados à caracterização de contaminantes em água via sensores de micro-ondas. As equações apresentadas formalizam os métodos e as métricas de avaliação definem critérios quantitativos para comparar modelos. Essa abordagem permirte a reprodutibilidade e rigor científico na avaliação de desempenho dos modelos aplicados ao problema em estudo.

Capítulo 4

Metodologia

Neste estudo, foram desenvolvidos três trabalhos separadamente de investigação de sensores planares de micro-ondas com tecnologia DGS baseado em CSRR e IDC. O primeiro dele cria um design de sensor micro-ondas para medir concentrações de glicose em água utilizando um tubo bifilar como recipiente do material sob teste. Já o segundo trabalho faz um comparativo da performance de quatro sensores de micro-ondas para monitorar a qualidade da água em relação a contaminantes criticos (Nitrato, Fosfato, Amônia e Condutividade). O terceiro visa estudar a topologia de ressoador IDC, afim de quantificar sua sensibilidade em relação aos outros sensores fabricados. A pesquisa nessa área visa explorar o potencial dos diferentes tipos de topologia dos sensores planares com intuito de investigar a eficiência em relação a sensibilidade, precisão, compactabilidade e custo do sensores para aplicações que envolvam estudo e qualidade da água.

Após a analise qualitativa e quantitativa da bibliografia é possível fazer um levantamentos das etapas para desenvolvimentos do sensores planares de micro-ondas baseados em CSRR e IDC para monitorar a qualidade da água. A pesquisa seguiu o fluxograma do diagrama da figura 4.1 com as etapas detalhadas na tabela 4.1.

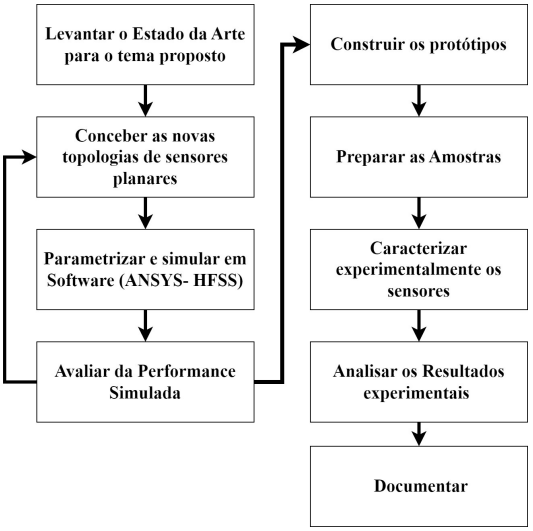


Figura 4.1: Fluxograma dos procedimentos que compõem a metodologia adotada nesta pesquisa para desenvolvimento dos sensores. Fonte: Autor, 2025.

	Etapa	**Descrição**
1	Levantar o Estado da Arte para o tema proposto	Fazer o levantamento bibliografico do tema proposto, usar ferramentas de base de dados para analisar os principais e mais recentes trabalhos relacionados ao tema
2	Conceber as novas topologias de sensores planares	Criar novos designs e novos métodos para o topologia dos sensores a partir do resultados encontrados na etapa anterior
3	Parametrizar e simular em Software	Utilizando um software de simulação eletromagnética como ANSYS-HFSS projetar o design concebido e parametrizar seus resultados para frequência de corte desejada
4	Avaliar a Performance Simulada	Avaliar os resultados encontrados com que se esperado para o estudo, caso incompatível voltar para etapa 2 e fazer retro simulação para novas topologias.
5	Construir os protótipos	Construir os protótipos em laboratório utilizando os materiais adequados com a tecnologia de fabricação apropriada para o tamanho do sensor
6	Preparar as Amostras	Preparar as amostras de água com contaminantes em laboratório que serão testadas, a fim de garantir os padrões mínimos desejáveis
7	Caracterizar experimentalmente os sensores	Medir utilizando o um analisador vetorial de rede os parâmetros de dispersão do sensores fabricados
8	Analisar os Resultados experimentais	Avaliar os resultados encontrados e compará-los com os obtidos na simulação
9	Documentar	Preparação do documento para publicação em periódicos

Tabela 4.1: Etapas da metodologia empregada na pesquisa. Fonte: Autor, 2025.

4.1 Projeto dos Sensores

Nesta seção, serão apresentados três projetos, dos quais se produziu três novas topologias de sensores micro-ondas baseados em CSRR e uma topologia baseada em IDC para verificação da qualidade da água com contaminantes críticos.

4.1.1 Sensor de micro-ondas baseado em CSRR para avaliar a qualidade da água e evitar a contaminação indesejada por açúcar

Para caracterizar líquidos, especialmente a glicose, que serve principalmente para prevenir e controlar doenças como diabetes ou medição de insulina para ajustar a dosagem de medicamentos (OMER et al. 2020). No entanto, estudos voltados para a agricultura e a aquicultura têm ganhado destaque ultimamente, devido à demanda por formas mais alternativas de monitorar ambientes agrícolas de forma eficiente em grande escala. Por exemplo, os sensores de micro-ondas podem ser usados para avaliar tanques de criação de peixes ou crustáceos e avaliar o nível de glicose presente no ambiente, controlando contra micro-organismos indesejados (MOHAMMADI et al. 2020). Além disso, em (SILVA et al. 2023) é proposto um sensor baseado em uma estrutura com resposta metamaterial para monitoramento da umidade do solo e aplicações agrícolas.

É possível avaliar a qualidade da água nos sistemas de irrigação para garantir que não haja acúmulos indesejados. A qualidade da água usada para irrigar grandes plantações é crucial para o crescimento e a saúde das plantas, bem como para a produtividade agrícola, e pode causar problemas como o crescimento de microrganismos patogênicos que afetam as plantações ou seu crescimento e a obstrução das tubulações no sistema de irrigação. Grande parte do açúcar indesejado vem da contaminação cruzada de resíduos de cultivos anteriores, fertilizantes e outros produtos químicos industriais usados para fins agrícolas (GAO et al. 2020). Para garantir que a água usada nos sistemas de irrigação de grandes plantações esteja livre de contaminação por açúcares indesejados, é essencial monitorar e testar periodicamente suas plantações para garantir as especificações mínimas desejáveis para o plantio (FøRE et al. 2024). Portanto, o uso de biossensores de micro-ondas de baixo custo que não interfiram diretamente nos tanques de água é essencial para garantir uma agricultura sustentável e produtiva, protegendo o meio ambiente e as plantas, evitando assim a contaminação do solo (ZIDANE et al. 2021).

Neste trabalho propõe o desenvolvimento de um dispositivo barato e simples para evitar a contaminação por açúcares indesejados em sistemas de irrigação. Esse dispositivo caracterizará com precisão a permissividade das amostras de mistura de água e glicose. Foi apresentado um sensor de micro-ondas de baixo custo baseado em um ressonador complementar de anel dividido (CSRR) que opera na banda Industrial, Científica e Médica a uma frequência de 2,45 GHz para concentrações mais altas de glicose na água e na banda de 2,22 GHz a 2,24 GHz para concentrações mais baixas de glicose na água. A caracterização da permissividade relativa da mistura homogênea de água e glicose é realizada em um ambiente de laboratório, utilizando uma variedade de amostras de líquidos com diferentes constantes dielétricas, com o objetivo de calcular a porcentagem de sensibilidade do sensor CSRR sob investigação. O custo de fabricação do dispositivo é

baixo devido ao uso do material FR4. O processo de fabricação também é simples, compreendendo a inserção de um pequeno tubo capilar de plástico (polipropileno) no centro do sensor para verificar a LUT e evitar interferências ou danos ao sensor proposto.

A Figura 4.2 ilustra a configuração do sensor de micro-ondas proposto, que compreende uma placa de substrato com dois lados de cobre. A célula baseada em CSRR implementada consiste em uma fenda circular interconectada com um espaçamento de 0,5 mm entre as fendas e um espaçamento ao longo do eixo y e é delineada no plano de terra em um lado do substrato, enquanto no outro lado há uma linha de transmissão de microfita (TL). O cobre utilizado apresenta características físicas e elétricas, incluindo uma espessura de 0,035 mm e uma condutividade de $\sigma = 5,8 \times 10^7$ S/m, respectivamente. O substrato FR4 foi selecionado com base em suas características elétricas desejáveis e em seu baixo custo. O ANSYS-HFSS, um pacote de software para simulação eletromagnética, foi usado para determinar os parâmetros de dispersão do sensor. Duas portas de 50 Ω foram colocadas em ambas as extremidades da TL. Um orifício de 5,4 mm de diâmetro foi projetado no centro da placa para acomodar as amostras em teste.

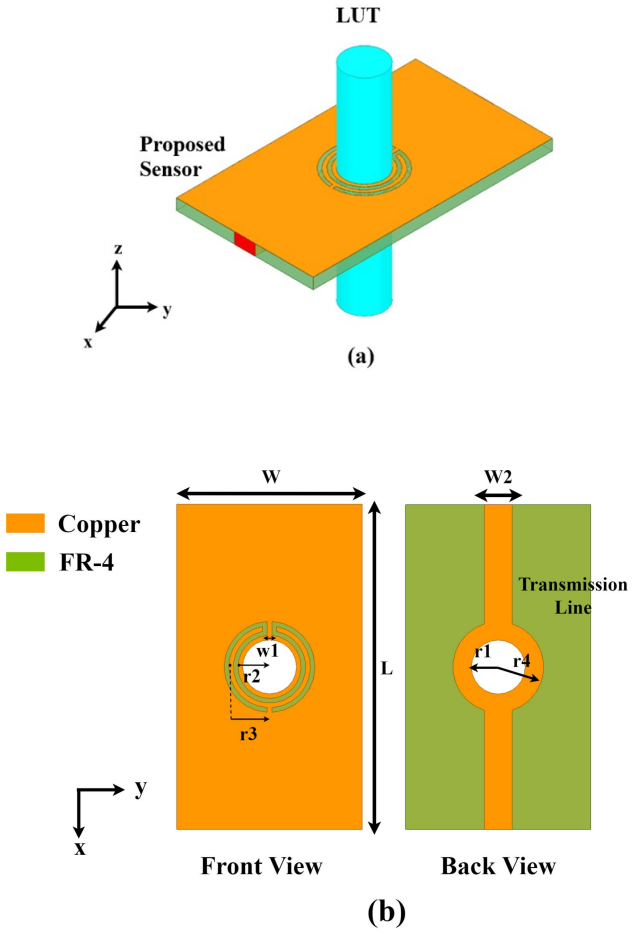
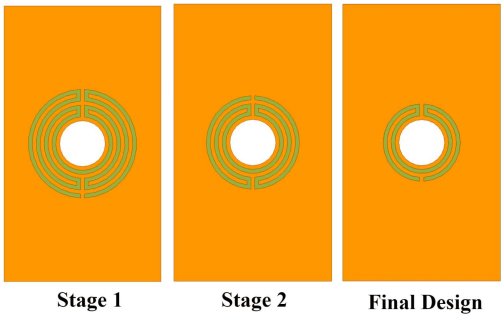


Figura 4.2: Geometria proposta do sensor de micro-ondas baseado em CSRR (L = 35 mm, W = 20 mm, W1 = 0,5 mm, W2 = 3 mm, r1 = 3,9 mm, r2 = 4,4 mm, r3 = 4,9 mm, r4 = 5,4 mm) (a) Vista isométrica (b) Vista superior e inferior. Fonte: Autor, 2025.

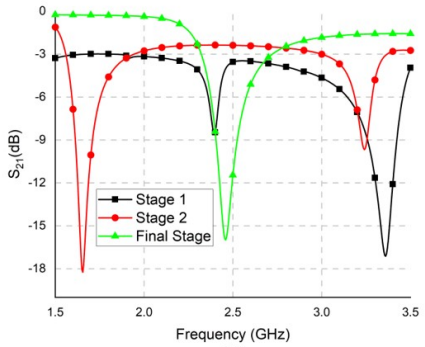
Em um ressonador da estrutura SRR, o modo de operação é baseado na geração de uma onda eletromagnética com alta impedância em uma faixa próxima à sua frequência ressonante. Isso é causado por uma corrente que excita os anéis do ressonador. Em contrapartida, o CSSR apresenta uma semelhança estrutural com o SRR. Entretanto, sua interação com o campo elétrico resulta em uma modificação da permissividade efetiva do material quando posicionado sobre o campo elétrico (HAQ et al. 2020).

Para este projeto, foi utilizado um CSSR devido ao posicionamento central da amostra em teste, por meio do qual o plano de aterramento do sensor pode ser centralizado na linha de transmissão. Isso resultou na criação de um sensor mais compacto e de um campo eletromagnético mais uniforme.

Um estudo abrangente da fase de desenvolvimento do sensor CSRR proposto foi realizado para verificar sua miniaturização e desempenho dentro da faixa de frequência especificada. A Figuras 4.3 mostram os estágios de projeto do sensor proposto e os coeficientes de transmissão correspondentes ($|S_{21}|$). A quantidade de anéis que constituem a estrutura baseada em CSRR é determinada pelos slots dos dois anéis interconectados que foram propostos no projeto final. Devido à sua frequência de ressonância exclusiva de 2,45 GHz, ela se desvia de outros projetos que exibem harmônicos na ressonância, um fenômeno que é previsto ao adicionar anéis à estrutura.



(a)



(b)

Figura 4.3: Evolução do projeto de sensor baseado em CSRR proposto. (a) Projetos de sensores (b) Avaliação $|S_{21}|$ dos projetos propostos. Fonte: Autor, 2025.

A área de sensibilidade máxima é definida como a região na qual o campo elétrico está em sua intensidade máxima. Isso pode ser expresso como a área com a capacitância máxima ou a região com a densidade máxima de corrente de superfície (JIANG et al. 2023). Durante a ressonância, um campo elétrico é estabelecido nas regiões situadas entre o cobre, formando assim capacitâncias no CSRR. Isso faz com que a região de campo próxima ao sensor CSRR se torne sensível a alterações na permissividade. É possível utilizar essa região dentro do CSRR para avaliar as propriedades dielétricas dos materiais. A Figura. 4.4 ilustra a distribuição do campo elétrico na superfície do sensor proposto na frequência de ressonância. É possível notar que a magnitude do pico do campo elétrico está concentrada no centro do elemento baseado em CSRR. Essa observação indica que, ao posicionar estrategicamente a LUT no centro, podemos aprimorar a resposta e, assim, otimizar a interação do campo elétrico gerado.

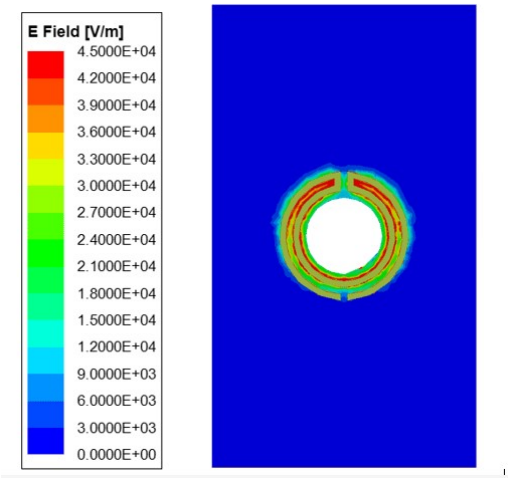


Figura 4.4: Distribuição simulada do campo elétrico. Fonte: Autor, 2025.

A Figura 4.5 mostra o campo elétrico simulado na amostra de água líquida dentro do tubo capilar de vidro, indicando a alteração no campo elétrico quando o líquido em teste é introduzido. Nesse cenário, a força elevada da distribuição do campo elétrico torna o sensor mais suscetível a variações na permissividade relativa. Para isso, o tubo capilar foi meticulosamente perfurado e posicionado dentro da placa, garantindo assim a interação ideal do campo elétrico com a LUT.

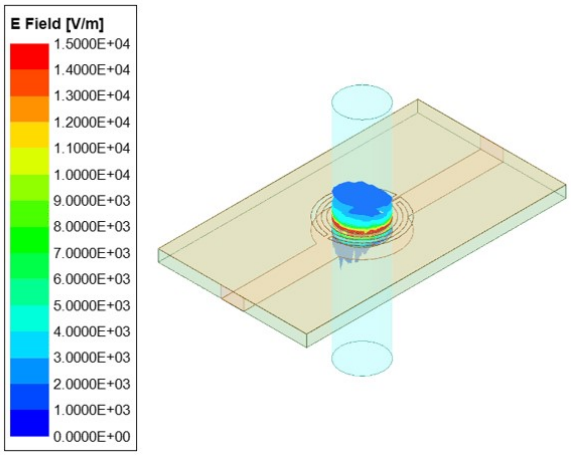


Figura 4.5: Simulação mostrando o campo elétrico de interação na LUT. Fonte: Autor, 2025.

As dimensões do CSRR foram projetadas para entrar em ressonância a $2,45$ GHz sem a amostra de líquido e otimizadas usando o simulador eletromagnético ANSYS-HFSS. As dimensões sugeridas na simulação foram implementadas na versão experimental.

O substrato selecionado para a fabricação do projeto proposto é o FR4, com uma permissividade relativa de $4,4$ e uma espessura de $1,57$ mm. A espessura do cobre para o plano de terra e o TL é de 35 μm. O protótipo fabricado é mostrado na Figura 4.6. O sensor é conectado às portas do analisador de rede vetorial (VNA) por meio de conectores Sub-Miniature Version A (SMA) soldados em ambas as extremidades da linha de microfita. O tubo capilar feito de material plástico (polipropileno) com um diâmetro externo de 5,8 mm e um diâmetro interno de $4,8$ mm é encaixado em um furo de $2,4$ mm de raio feito no meio do dispositivo.

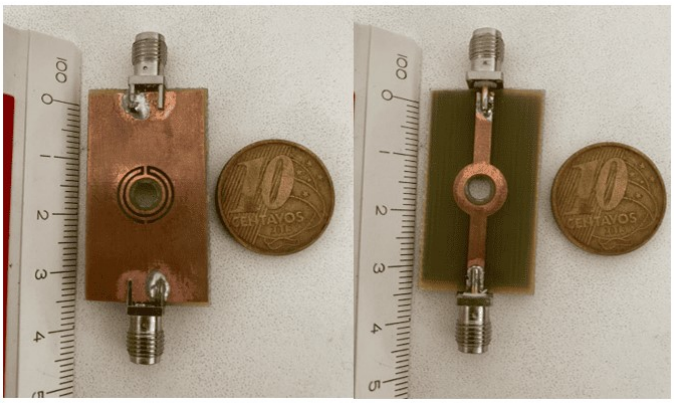


Figura 4.6: Plano de terra com CSRR (esquerda) e linha de transmissão (direita) do protótipo construído. Fonte: Autor, 2025.

As amostras de líquido utilizadas para as medições foram preparadas combinando glicose com água destilada. Para evitar a contaminação, cada solução foi colocada em um tubo capilar distinto, garantindo assim que elas não fossem misturadas. Todas as medições foram mantidas em temperatura ambiente, de modo que as amostras não alterassem suas respostas devido à mudança de temperatura, como pode ser visto na Fig. 4.7 abaixo.

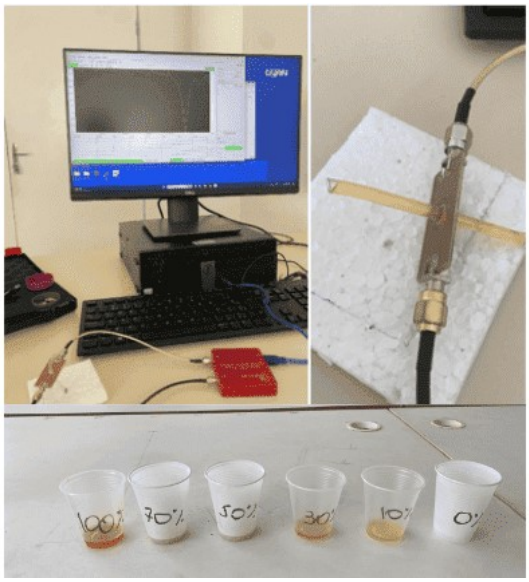


Figura 4.7: Preparar a configuração de medição e as amostras de glicose e água para diferentes concentrações. Fonte: Autor, 2025.

Foi observada uma forte concordância entre a ressonância do modelo simulado e o dispositivo experimental, o que valida o desempenho de nosso dispositivo fabricado.

4.1.2 Comparação de sensores de micro-ondas baseados CSRR para monitoramento de contaminantes críticos (nitrato, fosfato e amônio) em ambientes aquosos

Hoje em dia, o sistema de monitoramento para a qualidade da água nessas fontes são extremamente caras com técnicas de espectrometria e fixadas em alguns pontos ao longo do rio para o monitoramento contínuo da qualidade dessas fontes de água (MANFREDA et al. 2023). O uso de sensores micro-ondas móveis de baixo perfil, de fácil acesso e baixo custo são poucos explorados e utilizados no monitoramento dos níveis de contaminantes críticos como o nitrato, fosfato e amônio presentes em descartes da agroindústria na água para melhor entendimento da sua qualidade (AMINEH et al. 2023).

O Nitrogênio e o fósforo são elementos frequentemente detectados em corpos d'água devido principalmente a atividades agrícolas próximas a rios e lagos, apresentando implicações relevantes tanto para os ecossistemas aquáticos quanto para a saúde humana (ANAR et al. 2024*b*). O nitrogênio, frequentemente encontrado na forma de nitrato

(NO3), é indispensável para a vida, mas sua concentração elevada pode desencadear processos de eutrofização, caracterizados pela redução dos níveis de oxigênio dissolvido e pela consequente mortalidade dos peixes e organismos aquáticos que necessitam de oxigênio para sua sobrevivência (SAMSURI et al. 2023). Além disso, concentrações de nitrato superiores a 10 mg/L na água potável estão associadas a riscos à saúde humana (MIRZAVAND et al. 2018). O fósforo, principalmente na forma de fosfato (PO4), atua como um fator limitante nos ecossistemas de água doce. Mesmo pequenos aumentos em sua concentração podem induzir o crescimento excessivo de algas, causando desequilíbrios ecológicos severos (YAROSHENKO et al. 2020). Para águas residuais e potáveis, os limites de nitrato e fosfato são estabelecidos em 30 mg/L e 20 mg/L, respectivamente (HARNSOONGNOEN et al. 2019). Outro composto nitrogenado, o amônio (NH4), pode ser de origem natural ou antrópica e é tóxico para a vida aquática em determinadas concentrações, sendo que a água potável deve conter, no máximo, 20 µg/L (TANGUY et al. 2020).

Já os metais pesados, como mercúrio (Hg) e chumbo (Pb), também representam um grave problema ambiental e de saúde devido à sua toxicidade mesmo em concentrações reduzidas (FRAU et al. 2018). As fontes desses contaminantes incluem processos industriais, erosão geológica e práticas agrícolas inadequadas (HONG et al. 2021). Tais metais podem provocar diferentes impactos à saúde, como danos renais (Hg) e comprometimentos no desenvolvimento infantil (Pb) (FRAU et al. 2020). Os limites regulatórios para essas substâncias variam entre águas potáveis e residuais tratadas, sendo comumente estabelecidos em 5 µg/L para mercúrio e 50 µg/L para chumbo (YEE et al. 2021).

Além disso, o pH da água e sua salinidade são parâmetros essenciais, influenciando diretamente sua qualidade (ABBASI & DANESHMAND 2018). Valores entre 6,8 e 8,2 são considerados seguros para assegurar a potabilidade e a proteção dos ecossistemas aquáticos, além de possibilitar o uso recreativo seguro (ABBASI et al. 2020). Alterações na salinidade podem ser provocadas por atividades humanas, como irrigação, descarte de efluentes industriais, desmatamento e mudanças no fluxo hídrico devido à construção de barragens. Em ecossistemas aquáticos, essas variações podem impactar negativamente a biodiversidade, uma vez que muitas espécies têm tolerância limitada a mudanças bruscas na salinidade. Por exemplo, elevações na salinidade podem levar ao estresse osmótico em organismos de água doce, comprometendo seu crescimento, reprodução e sobrevivência (AMIRI et al. 2022).

Ultimamente algumas topologia de sensores micro-ondas fabricados para detecção da qualidade da água são utilizados de modo a monitorar de forma contínua, como os eletrodos interdigitais, sensores coaxiais open-end ou de maneira pontual com uso de sensores micro-ondas com uso defeitos no plano de terra (DGS), como CSRRs ou variações desse tipo de sensor (GAN et al. 2020).

Alguns tipos de sensores foram fabricados ao longo dos últimos anos, como o sensor micro-ondas desenvolvido em (ZHANG et al. 2019) nos mostra o design de um array de sensores de micro-ondas baseados em CSRR para testes de qualidade da água em diversos tipos de amostras aquosas com elementos químicos diferentes. O sensor IDE mostrado em (FRAU et al. 2021*a*) um design de sensor de micro-ondas para o monitoramento em tempo real de traços de metais afetados por atividades de mineração. Já o sensor apre-

sentado em (KAI BOON et al. 2021) nos mostra um microstrip ring resonator biossensor projetado para aplicações práticas no monitoramento da qualidade da água, com potencial para detectar contaminantes, como metais pesados e microrganismos. (LAZZONI et al. 2023) apresenta um sensor micro-ondas SCSRR capaz de detectar e diferenciar eficientemente concentrações de nitrato, fosfato e suas misturas, com alta sensibilidade em baixas concentrações.

Neste trabalho, quatro sensores micro-ondas com defeito no plano de terra (DGS) baseado em CSRR são propostos. Utilizado para detecção dos principais contaminantes como nitrato, fosfato, pH e salinidade da água e usado monitoramento local da qualidade da água. É comparado com outros três tipos de CSRR para avaliar seu desempenho de sensibilidade. Além disso, os sensores foram projetados para atuar na frequência de de ressonância de 1.5 GHz vazio e foi utilizado como substrato FR-4, um contêiner paralelepípedo de acrílico plástico foi desenvolvido de maneira a comportar o material sob-teste (MUT) e de modo que o líquido não interagir diretamente com sensor o desempenho do parâmetro-S do CSRR foi medido e a sensibilidade de cada sensor CSRR foi determinada, além da medição da permissividade de cada solução de contaminante na água. Dessa forma, foi criado um sensor compacto de tamanho 40mm x 70mm, de baixo custo e eficiente.

A Figura 4.8 mostra quatro tipos de ressoadores diferentes, dois com configurações mais convencionais SRRs circular e quadrada (SINGH et al. 2024), uma nova configuração DGS baseada em SRRs é apresentada na sua forma quadrada e circular qual sua performance de sensibilidade serão comparadas e suas frequências de ressonância serão analisadas. Todas estruturas ressonantes foram colocadas no centro da placa de forma complementar no terra formando um CSRR de uma placa duplamente laminada com cobre com condutividade de $o = 5,8 \times 10^7$ S/m com espessura de 0,035mm o qual foi a parte de cima é formada por um linha de transmissão microstrip carregada. Os quatro sensores foram desenvolvidos para funcionarem na frequência de ressonância de 1,5 GHz no vazio (sem o contêiner de acrílico). O substrato escolhido para todos os quatro sensores foi o FR-4 por suas características elétricas e seu baixo custo, desejável nessa aplicação. As frequências de ressonâncias dos quatro sensores simuladas encontradas são diferentes devido ao formato geométrico de cada ressonador, seu tipo e sua escala. Além disso, foi considerado as frequências de ressonâncias de cada sensor considerando o contêiner de acrílico que armazena o material sob teste (MUT) e posicionados no centro do sensor e da estrutura ressonante, embaixo do terra, para se tornar sensores mais compactos e com uma distribuição de campo eletromagnético mais uniforme. Todos sensores apresentados nessa sessão passaram por um estudo paramétrico para determinar os valores geométricos de suas estruturas, além de todas análises eletromagnéticas e os parâmetros de dispersão dos sensores propostos foram estudadas no software de simulação ANSYS-HFSS.

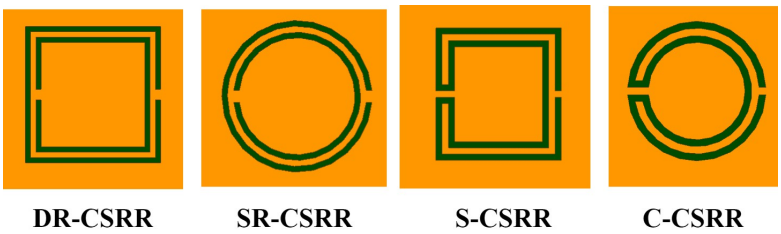


Figura 4.8: Tipos de ressoadores CSRR estudados. Fonte: Autor, 2025.

A figura 4.9 mostra o design do sensor baseado em um ressoador duplo CSRR quadrado denominado DR-CSRR, sua distribuição de corrente de superfície no ressoador (em A/m) e as características dos parâmetros-S do sensor proposto. O tamanho geral dos sensores considerando o tamanho da terra é de largura e altura de W =40 mm e L = 70 mm respectivamente. O substrato escolhido para os sensores proposto é FR-4 com permissividade de 4,4, espessura de 1,57 mm e tangente de perdas de 0,02. Para ressoar na frequência desejada de 1,5 GHz foi projetada uma linha microstrip de largura Ws = 3,1 mm para casar a impedância com o conector coaxial SMA de 50 Ohms. O DR-CSRR é composto por dois quadrados split ring com uma abertura em um dos lados. suas dimensões são de d1 = 11,5 mm, d2 = 9,74 mm e abertura de slot de g1 = 0,89 mm, além da largura de fenda de 0,5 mm. Seus parâmetros-S de coeficiente de reflexão ($|S_{11}|$) e coeficiente de transmissão ($|S_{21}|$) simulados considerando o contêiner de acrílico vazio são mostrados, obtendo um condição de ressonância para o sensor proposto de 1,46GHz. A máxima região de sensibilidade do sensor proposto é mostrada através da distribuição de campo elétrico no ressoador.

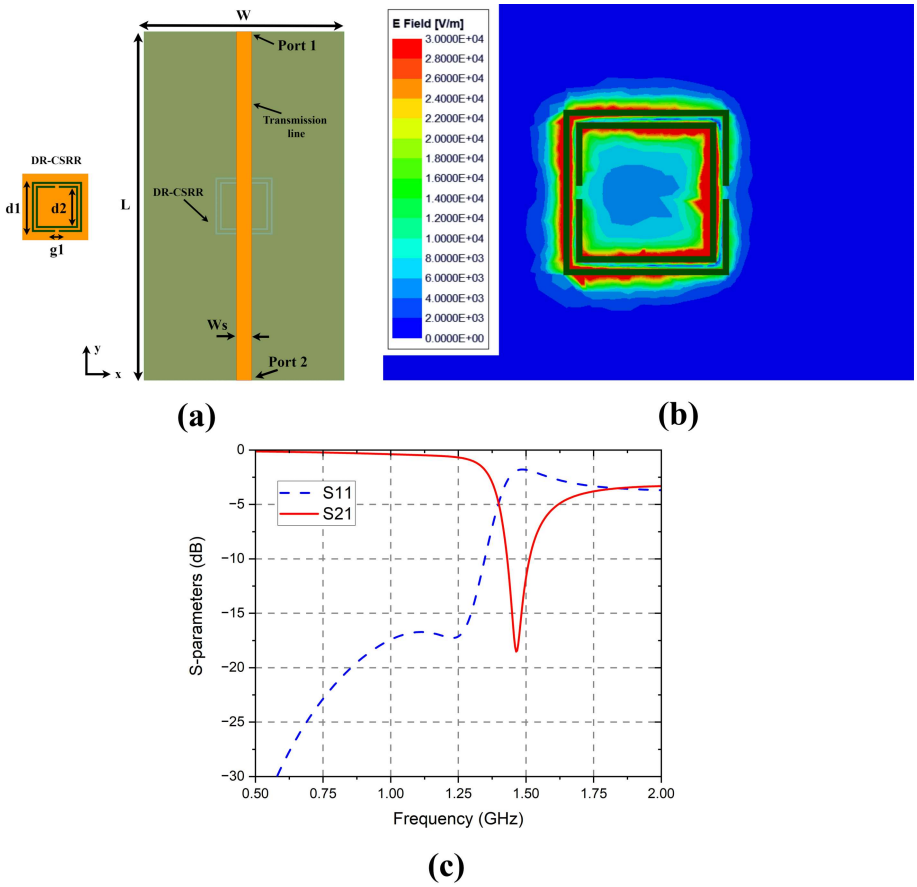


Figura 4.9: Sensor de micro-ondas baseado em DR-CSRR proposto: (a) estrutura. (b) distribuição de corrente de superfície a 1,5 GHz. (c) características do parâmetros-S. Fonte: Autor, 2025.

Figura 4.10 mostra o design do sensor baseado em um ressoador duplo CSRR circular denominado SR-CSRR, sua distribuição de corrente de superfície no ressoador (em A/m) e as características dos parâmetros-S do sensor proposto. As dimensões gerais e de construção do sensor são as mesmas que o sensor anterior. O substrato adotado é FR-4 com as mesmas características do sensor anterior. O ressoador SR-CSRR tem dimensões de r1 = 7 mm, r2 = 5,5 mm e abertura de slot de g2 = 1,1 mm. Além de uma largura de fenda de 0,5 mm. A estrutura é de slot é posicionada na mesma direção da linha de transmissão de modo que o comportamento do coeficiente de transmissão ($|S_{21}|$) e reflexão ($|S_{11}|$) sejam em uma frequência de ressonância de 1,46GHz. A máxima região de sensibilidade do sensor proposto é mostrada através da distribuição de campo elétrico no ressoador.

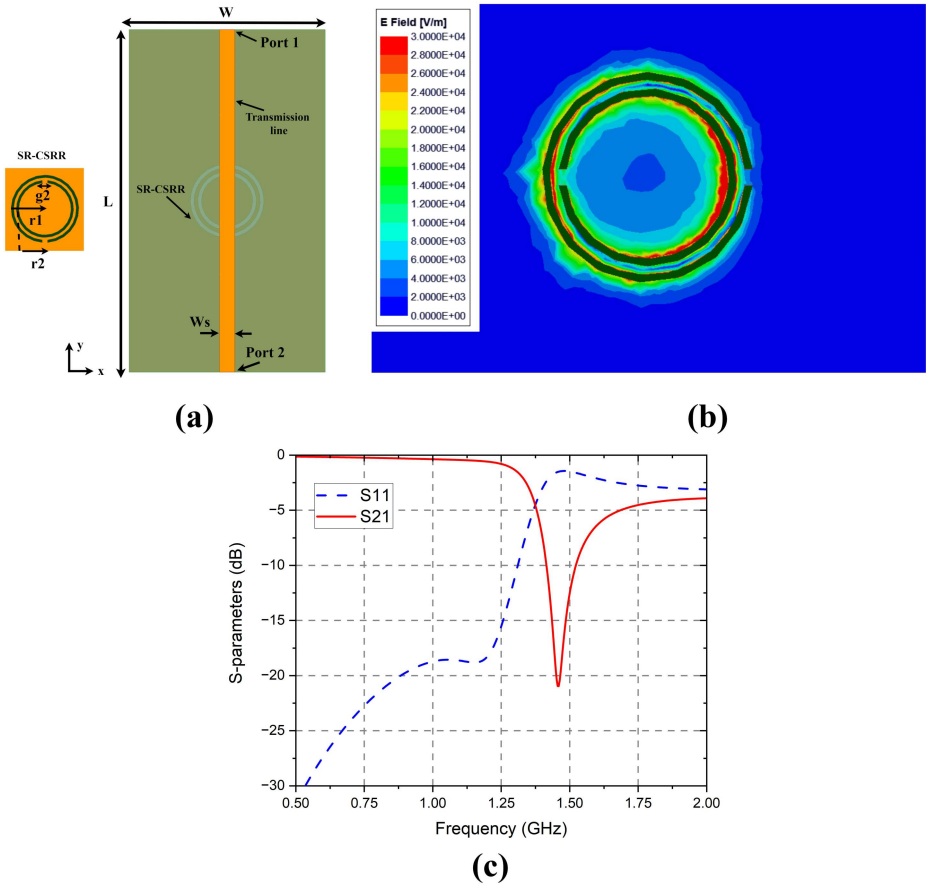


Figura 4.10: Sensor de micro-ondas baseado em SR-CSRR proposto: (a) estrutura. (b) distribuição de corrente de superfície a 1,5 GHz. (c) características do parâmetros-S. Fonte: Autor, 2025.

Figura 4.11 mostra o design do sensor baseado em um ressoador duplo CSRR quadrado auto-conectado com duas aberturas denominado S-CSRR, sua distribuição de corrente de superfície no ressoador (em A/m) e as características dos parâmetros-S do sensor proposto. As dimensões gerais e de construção do sensor são as mesmas que o sensor anterior. O substrato adotado é FR-4 com as mesmas características dos sensores anteriores. O ressoador S-CSRR tem dimensões de d3 = 11,9 mm, d4 = 9,5 mm e abertura de slot de g3 = 0,6 mm. Além de uma largura de fenda de 0,5 mm. A estrutura é de slot é posicionada na mesma direção da linha de transmissão de modo que o comportamento do coeficiente de transmissão ($|S_{21}|$) e reflexão ($|S_{11}|$) sejam em uma frequência de ressonância de 1,43 GHz. A máxima região de sensibilidade do sensor proposto é mostrada através da distribuição de campo elétrico no ressoador.

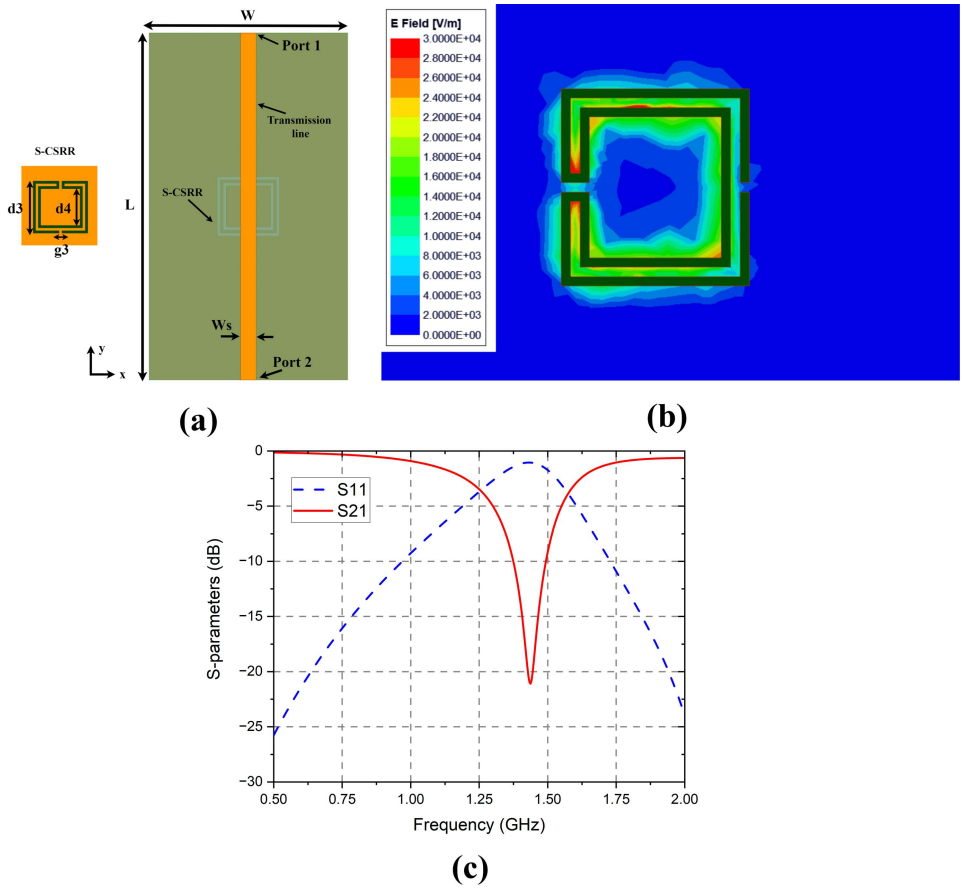


Figura 4.11: Sensor de micro-ondas baseado em S-CSRR proposto: (a) estrutura. (b) distribuição de corrente de superfície a 1,5 GHz. (c) características do parâmetros-S. Fonte: Autor, 2025.

Figura 4.12 mostra o design do último sensor baseado em um ressoador duplo CSRR circular auto-conectado com um duas aberturas denominado C-CSRR, sua distribuição de corrente de superfície no ressoador (em A/m) e as características dos parâmetros-S do sensor proposto. As dimensões gerais e de construção do sensor são as mesmas que o sensor anterior. O substrato adotado é FR-4 com as mesmas características dos sensores anteriores. O ressoador S-CSRR tem dimensões de r3 = 7,5 mm, r4 = 5 mm e abertura de slot de g4 = 0,77 mm. Além de uma largura de fenda de 0,5 mm. A estrutura é de slot é posicionada na mesma direção da linha de transmissão de modo que o comportamento do coeficiente de transmissão ($|S_{21}|$) e reflexão ($|S_{11}|$) sejam em uma frequência de ressonância de 1,43 GHz. A máxima região de sensibilidade do sensor proposto é mostrada através da distribuição de campo elétrico no ressoador.

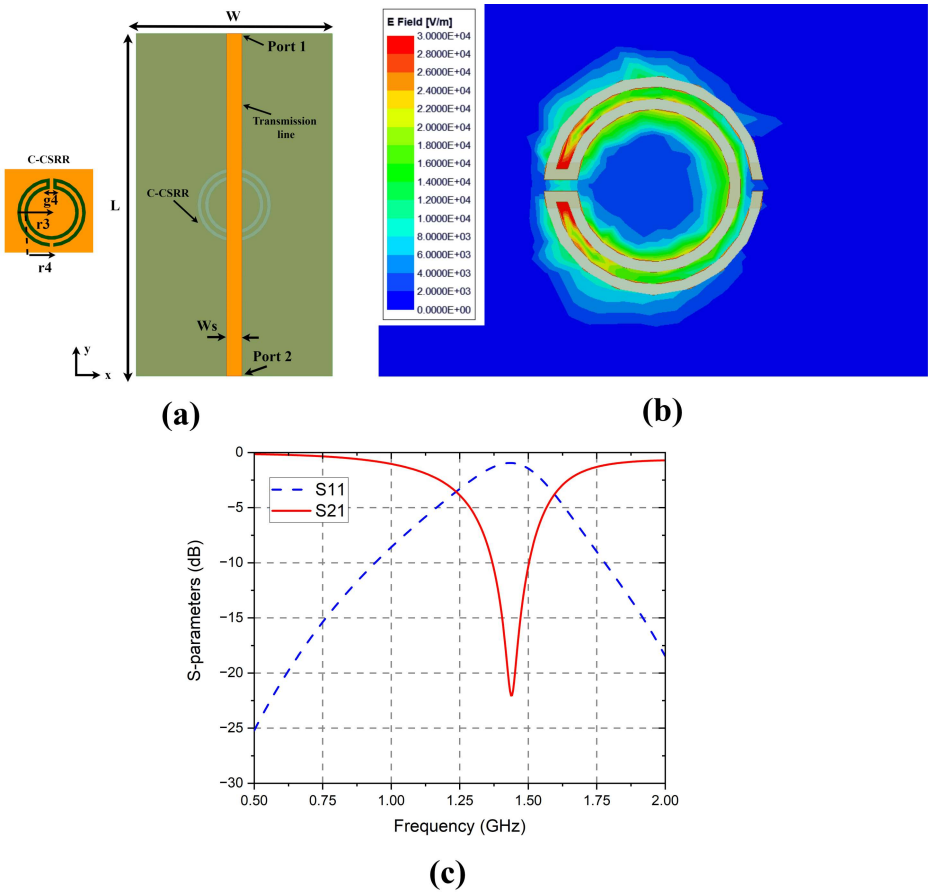


Figura 4.12: Sensor de micro-ondas baseado em C-CSRR proposto: (a) estrutura. (b) distribuição de corrente de superfície a 1,5 GHz. (c) características do parâmetros-S. Fonte: Autor, 2025.

Os protótipos finais e o processo de fabricação dos quatro sensores propostos são mostrados na figura 4.13 abaixo. O material utilizado para fabricação foi uma placa duplamente laminada de cobre, com um núcleo de substrato FR-4 com características de permissividade relativa de 4,4, espessura do substrato de 1,57 e tangente de perdas de 0,02. Foram soldadas as pontas em uma linha de transmissão microstrip de espessura 3,1 mm e altura 35 um dois conectores SMA 50 Ohms. As dimensões dos quatro sensores anteriormente descritas foram fabricadas com foto impressão e verificadas e validadas através de um analisador de redes vetorial (VNA) portátil devidamente calibrado.

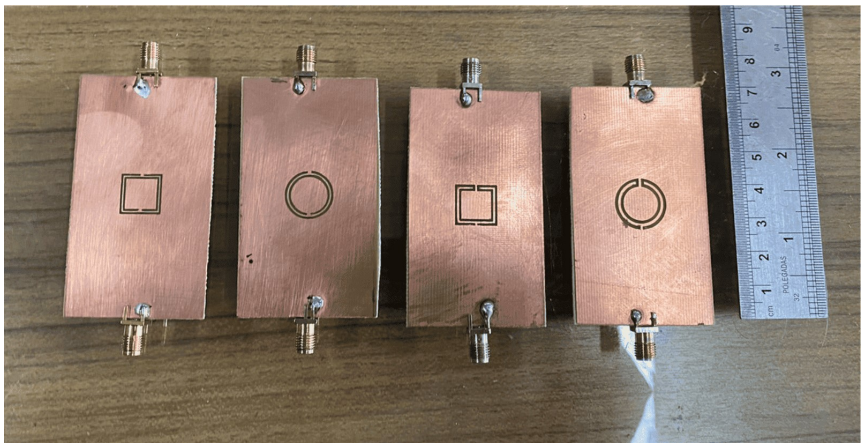


Figura 4.13: Sensores propostos fabricados. Fonte: Autor, 2025.

Figura 4.14 mostra o design e o protótipo do contêiner sobreposto ao sensor em material de acrílico, translúcido para facilitar a visualização do líquido aquoso testado com dimensões de 25 mm x 25 mm x 18 mm e espessura de 1 mm instalado sobre o terra e sobreposto a todo CSRR dos sensores propostos. Foram analisadas amostras de soluções aquosas no contêiner de cerca de 10 mL para cada amostra medida, os dados de $|S_{21}|$ eram analisados e realizados as medições.

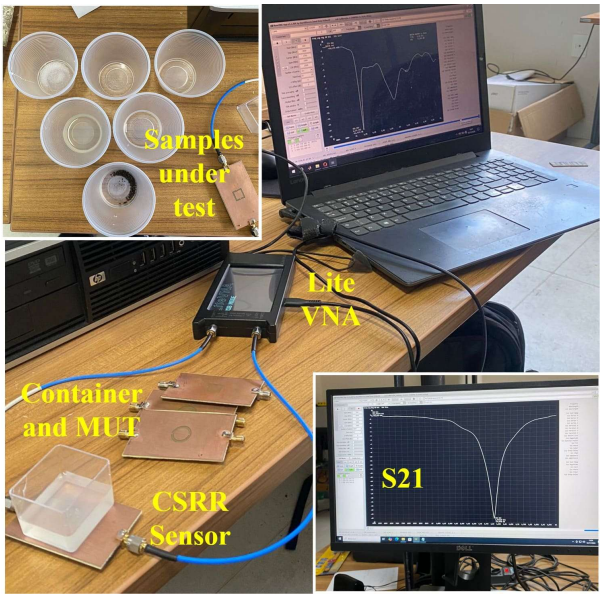


Figura 4.14: Recipiente de acrílico com LUT (Liquid under test) e sensores baseados em CSRR propostos. Fonte: Autor, 2025.

A configuração de medição é mostrado na figura 4.15 e apresenta o contêiner juntamente com MUT e sensores propostos, com medição dos parâmetros-S mostrados no

monitor através de um VNA portátil. A resposta analisada foi o coeficiente de transmissão $|S_{21}|$ em um range de frequência de 0,5 a 2 GHz de modo a ver o nível de amplitude do sinal em dB.

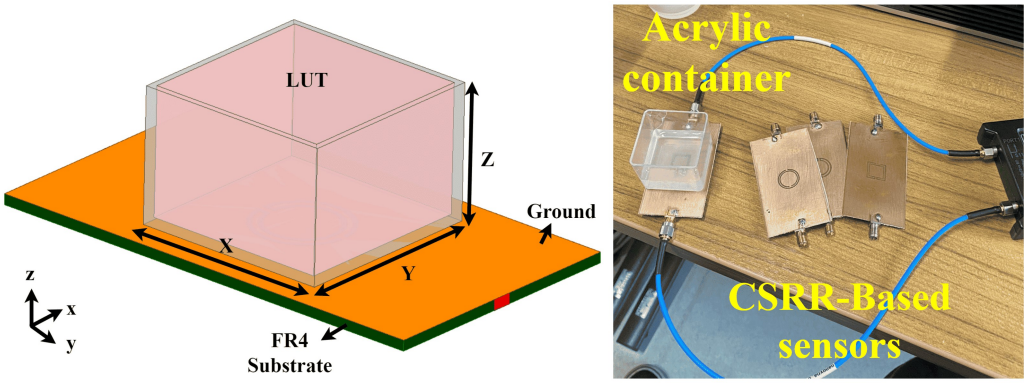


Figura 4.15: Configuração da medição e preparação da amostra para medições. Fonte: Autor, 2025.

4.1.3 Projeto sensor planar de micro-ondas baseado IDC para monitoramento de contaminantes críticos (Nitrato e Fosfato) em ambientes aquosos

Neste trabalho, sensor planar micro-ondas baseado em IDC complementar é proposto. O IDC apresenta uma topologia planar composta por eletrodos interdigitados, sendo predominantemente capacitivo e de fácil fabricação. Utilizado para detecção dos principais contaminantes como nitrato, fosfato em solução aquosa e usado monitoramento local da qualidade da água. Além disso, o sensor foi projetado para atuar na frequência de de ressonância de 2.0 GHz em vazio e foi utilizado como substrato FR-4, um contêiner paralelepípedo de acrílico plástico foi desenvolvido de maneira a comportar o material sob-teste (MUT) e de modo que o líquido não interagir diretamente com sensor o desempenho do parâmetro-S do IDC foi medido e a sensibilidade do sensor proposto foi determinada, além da medição da permissividade de cada solução de contaminante na água. Dessa forma, foi criado um sensor compacto de tamanho 40mm x 70mm, de baixo custo e eficiente.

A Figura 4.16(a) e (b) ilustra a configuração do sensor de micro-ondas proposto, que compreende uma placa de substrato com dois lados de cobre. A célula baseada em IDC complementar implementada consiste em uma fenda de capacitor interdigital interconectada com um fenda retangular dentro um circulo de cobre e é delineada no plano de terra em um lado do substrato, enquanto no outro lado há uma linha de transmissão de microfita (TL). O cobre utilizado apresenta características físicas e elétricas, incluindo uma espessura de 0,035 mm e uma condutividade de $\sigma = 5,8 \times 10^7$ S/m, respectivamente. O substrato FR4 foi selecionado com base em suas características elétricas desejáveis e em seu baixo custo. O ANSYS-HFSS, um pacote de software para simulação eletromagné-

tica, foi usado para determinar os parâmetros de dispersão do sensor. Duas portas de 50 Ω foram colocadas em ambas as extremidades da TL. Os parâmetros do ressoador IDC são $l_1 = 9,1$ mm, $l_2 = 0,34$ mm, $l_3 = 1,8$ mm, $l_4 = 5,4$ mm, $l_5 = 2,7$ mm, $r_1 = 4$ mm.

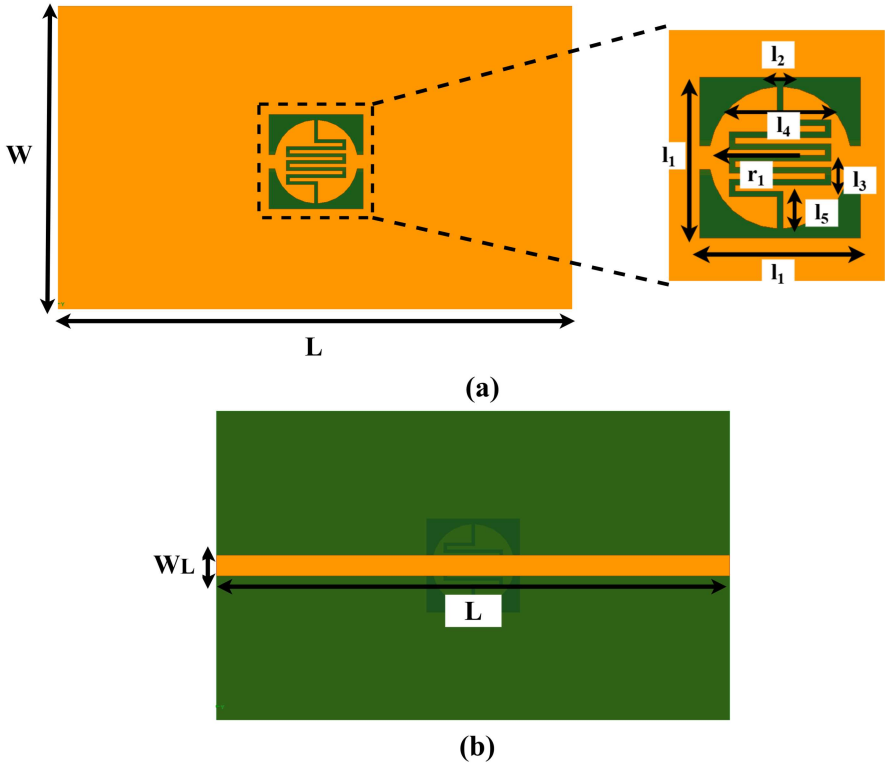


Figura 4.16: Geometria proposta do sensor de micro-ondas baseado em IDC (a) Vista inferior (plano de terra) (b) Vista superior. Fonte: Autor, 2025.

O sensor proposto foi projetado para operar na frequência de ressonância de 1.86 GHz em vazio, o estudo do deslocamento da frequência de ressonância do parâmetro de espalhamento (S21) é feito com a mudança de permissividade do material sob teste (MUT) dentro do recipiente utilizado para medições. O design do sensor proposto foi implementado no software ANSYS HFSS de simulação eletromagnética em alta frequência baseado no método do elemento finito. Na simulação é utilizado um recipiente de acrílico (PMMA) de dimensões 25 mm, 25 mm, 18 mm, no centro do ressoador onde a substância aquosa com contaminante (MUT) é posto e assim medido os parâmetros-S do sensor.

O ressoador baseado em IDC complementar é aplicado no centro do terra do sensor. A linha de transmissão de microfita de dimensão 2 mm x 70 mm para ter característica de impedância de 50Ω. Figura 4.17 mostra o sensor fabricado com as dimensões propostas.

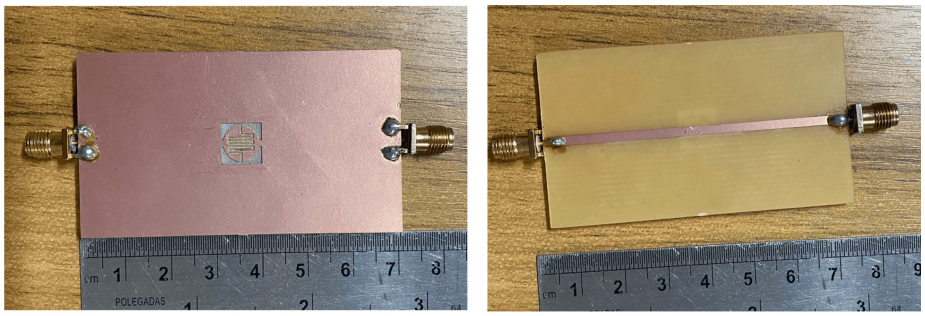


Figura 4.17: Protótipo fabricado do sensor IDC. Fonte: Autor, 2025.

Figura. 4.18 ilustra a distribuição do campo elétrico na superfície do sensor proposto e no MUT na frequência de ressonância desejada. É possível notar que a magnitude do pico do campo elétrico está concentrada no centro do elemento baseado em IDC. Essa observação indica que, ao posicionar estrategicamente a MUT no centro, podemos aprimorar a resposta e, assim, otimizar a interação do campo elétrico gerado.

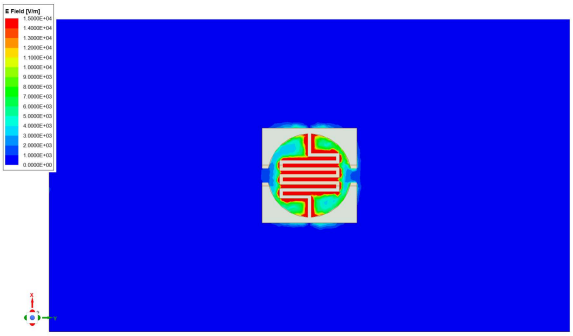


Figura 4.18: Distribuição de campo elétrica na superfície do sensor na frequência de 1.86 GHz. Fonte: Autor, 2025.

A configuração de medição é mostrado na figura 4.19 e apresenta o contêiner juntamente com MUT e sensores propostos, com medição dos parâmetros-S mostrados no monitor através de um VNA portátil. A resposta analisada foi o coeficiente de transmissão $|S_{21}|$ em um range de frequência de 1 a 3 GHz de modo a ver o nível de amplitude do sinal em dB.

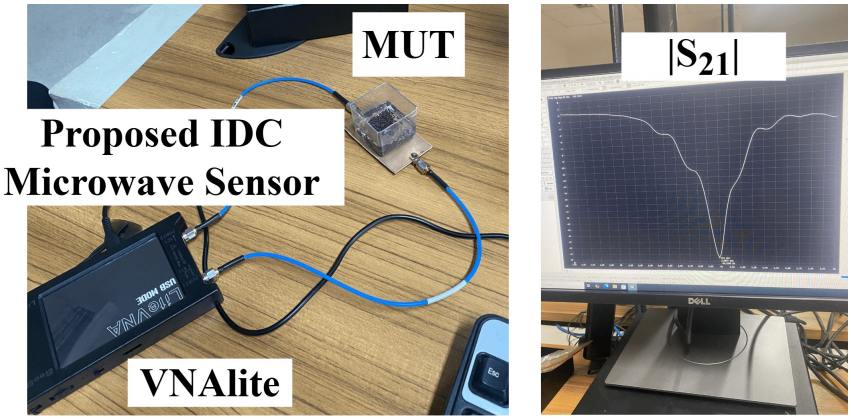


Figura 4.19: Configuração da medição. Fonte: Autor, 2025.

Capítulo 5

Resultados e Discussões

5.1 Projeto 01

5.1.1 Modelo de Circuito Equivalente e Sensibilidade

Para validar o sensor de micro-ondas, foi projetado um modelo de circuito equivalente (ECM) para a célula baseada em CSRR interconectada, inicialmente apresentado na referência (HANIF et al. 2024). O projeto final apresentado na figura 4.3 (a) foi simulado e comparado com o ECM e as medições. Os parâmetros do ECM incluem Z_0, que corresponde à impedância característica da linha de transmissão e foi definido como 50 Ω. Os parâmetros C_c, R e L correspondem à capacitância, à resistência e à indutância do CSRR, respectivamente. Nesse contexto, os parâmetros C e L_m representam a capacitância entre o plano de terra e a TL e a indutância da TL. Além disso, o ECM é empregado para determinar as dimensões da célula CSRR em uma frequência de ressonância de 2,45 GHz. O ECM foi inicialmente simulado usando o Advanced Design System (ADS), e seus valores foram ajustados para se alinharem aos resultados obtidos com o ANSYS-HFSS e aos obtidos por meio de experimentos, conforme ilustrado na Figura 5.1.

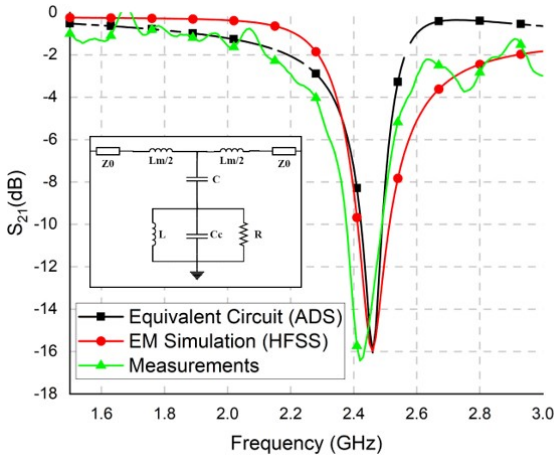


Figura 5.1: Comparação do $|S_{21}|$ do sensor proposto para ECM, HFSS e experimental com (Lm=0,38nH, C=1,547pF, L=0,348nH, Cc=10,466pF e R=370Ω). Fonte: Autor, 2025.

O circuito do sensor implementado entrará em um estado de ressonância quando o campo elétrico incidente for igual em magnitude àquele gerado pelas correntes induzidas na célula CSRR. Ao entrar em contato com o líquido em teste (LUT) e a região de sensibilidade máxima do sensor, a distribuição do campo elétrico desse último é interrompida, resultando em uma mudança na frequência de ressonância e em uma modificação de sua amplitude. A frequência de ressonância do modelo de circuito na Fig. 5.1 pode ser definida como (JAVED et al. 2020):

$$f_r = \frac{1}{2\pi\sqrt{L(C_c + C)}} \tag{5.1}$$

A relação entre a mudança na frequência de ressonância e as propriedades do material da amostra é a seguinte, conforme apresentado inicialmente na referência (PEREIRA et al. 2024). A análise de sensibilidade é realizada quando a MUT é colocada no ressonador e seu conteúdo é modificado, induzindo alterações nos campos elétricos e magnéticos, resultando em uma modificação da frequência de ressonância.

$$\frac{\Delta f_r}{f_r} = \frac{\int_v (\Delta\varepsilon E_1 E_0 + \Delta\mu H_1 H_0)\, dv}{\int_v (\varepsilon_0 |E_0|^2 + \mu_0 |H_0|^2)\, dv} \tag{5.2}$$

Onde Δf_r é a mudança na frequência ressonante do sensor v é o volume perturbado. E_0 e H_0 denotam a distribuição do campo sem perturbação e E_1 e H_1 são a distribuição do campo com perturbação. ε_0 e μ_0 são a permissividade e a permeabilidade do espaço livre, respectivamente. $\Delta\varepsilon$ e $\Delta\mu$ são as alterações na permissividade e na permeabilidade quando há uma alteração na MUT disposta no sensor. Como podemos ver esses parâmetros na Equação (5.2).

No projeto do sensor proposto, a amostra LUT é colocada dentro do tubo capilar, que é então posicionado dentro de um orifício com um diâmetro externo correspondente

ao do tubo capilar no centro do CSSR e da linha de transmissão (CHUMA et al. 2018). De acordo com a Equação (5.1), o capacitor $C = C_v + C_{LUT}$ é afetado pela mistura da colocação de líquidos perto do centro do CSSR pode ser entendido como uma combinação da capacitância do substrato dielétrico do CSRR, do tubo capilar vazio e do espaço próximo, bem como da capacitância da amostra de líquido carregada no tubo capilar. Essa última capacitância está diretamente relacionada à permissividade complexa do LUT (ARMGHAN et al. 2021).

A sensibilidade normalizada de um sensor CSRR proposto pode ser expressa em termos da variação na frequência de ressonância (Δf_r) devido a uma amostra com permissividade relativa, a alteração percentual na frequência de ressonância (PRFS). De acordo com (BERIA et al. 2023), os resultados são mostrados abaixo com as respectivas equações:

$$\Delta f_r = f_r - f_0 \tag{5.3}$$

$$PRFS = \frac{|f_r - f_0|}{f_r} \times 100\% \tag{5.4}$$

$$PRFSE = \frac{PRFS_{proposed}}{PRFS_{reference}} \tag{5.5}$$

$$S(\%) = \frac{|f_r - f_0|}{f_r(\varepsilon_r - 1)} \times 100\% \tag{5.6}$$

Uma análise mais robusta da sensibilidade média normalizada é apresentada na Figura 5.2, que emprega uma simulação do sensor baseado em CSRR proposto no projeto final. Essa análise é realizada variando a permissividade relativa das amostras MUT e observando as alterações correspondentes na frequência de ressonância. Além disso, a simulação demonstra a capacidade do sensor de detectar com precisão a permissividade relativa de amostras de soluções aquosas. Isso é obtido pela simulação do coeficiente de transmissão como uma função da constante dielétrica variando de 1 a 100, com uma etapa de 10.

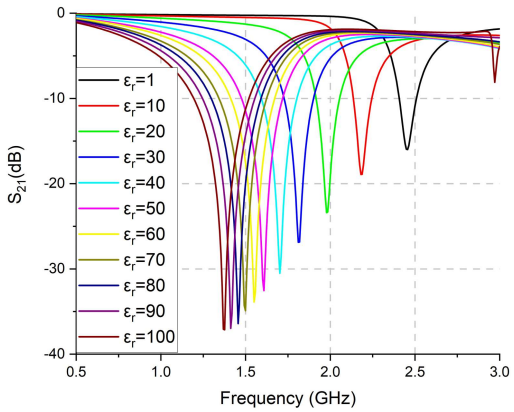


Figura 5.2: Simulação Coeficiente de transmissão, $|S_{21}|$, para diferentes valores de permissividade relativa. Fonte: Autor, 2025.

Para facilitar uma compreensão mais profunda da permissividade relativa e da análise de semblante, o componente imaginário da permissividade relativa é examinado por meio da lente de uma tangente de perda ($tan\delta$) para o substrato FR-4 em consideração. Esse substrato possui uma permissividade relativa real de 4,4 e uma tangente de perda variável. A Figura 5.3 mostra o $|S_{21}|$ para vários valores de $tan\delta$ de 0 a 0,03 quando $\varepsilon_r = 4,4$ e $\mu_r = 1$. Uma redução na profundidade do entalhe resultará em uma alteração correspondente na frequência de ressonância, dependendo da variação nos valores de tan de $0,0$ a $0,03$. Como o FR-4 tem uma tangente de perda de $\sim 0,02$ inerente ao substrato, obtemos uma amplitude de entalhe de $-15,3$ dB.

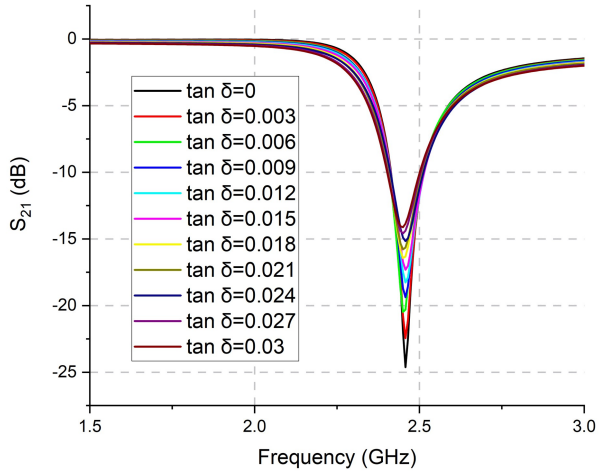


Figura 5.3: Resposta $|S_{21}|$ simulada do sensor CSRR proposto para a tangente de perda de $0,00$ a $0,03$ com intervalos de $0,003$. Fonte: Autor, 2025.

Nesse contexto, f_0 e f_r representam a frequência de ressonância quando o tubo capilar está sem carga (ou seja, sem LUT) e com carga (ou seja, com LUT), respectivamente. S representa a porcentagem da sensibilidade normalizada. A sensibilidade do sensor proposto pode ser determinada usando as Equações (5.3)-(5.6) para o deslocamento da frequência de ressonância e PRFS, conforme ilustrado na Figura 5.4 abaixo.

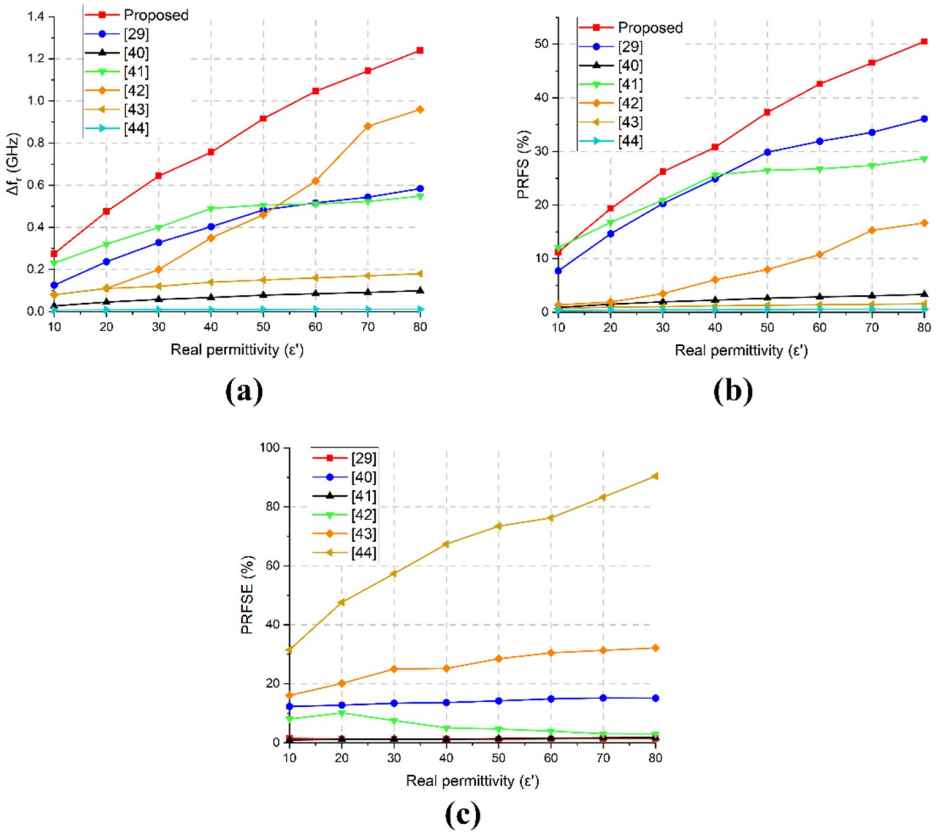


Figura 5.4: Os resultados da investigação dos principais parâmetros de sensibilidade do sensor baseado em CSRR proposto: (a) deslocamento ressonante (Δf_r); deslocamento de frequência relativa percentual (PRFS); (c) aprimoramento do deslocamento de frequência ressonante percentual (PRFSE). Fonte: Autor, 2025.

Para determinar a permissividade relativa da MUT, a relação entre a permissividade relativa e a frequência de ressonância foi analisada para valores simulados que variam de 1 a 10. Essa análise, realizada usando o projeto final do sensor baseado em CSRR, é representada por um ajuste de curva. Para obter uma compreensão mais profunda dessa relação, foi empregado um método matemático de ajuste de curva que permite a identificação precisa da frequência de ressonância, considerando diferentes tipos de líquidos em teste (LUT) e obtendo sua permissividade relativa com base na equação proposta. Com base nos pontos simulados do projeto final obtidos nessa análise, desenvolvemos e propusemos uma equação usando um ajuste polinomial de terceira ordem, traçando a curva

conforme ilustrado na figura 5.5 A equação é expressa na Equação (5.7). O coeficiente de determinação da regressão, $R^2 = 0,9945$, indica que o ajuste foi altamente preciso com os pontos obtidos para nossa análise.

$$\varepsilon'_r(f_r) = -5109.8f_r^3 + 34939f_r^2 - 79639f_r + 60532 \tag{5.7}$$

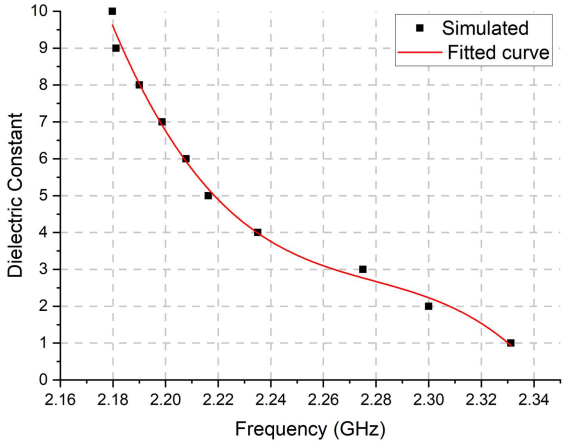


Figura 5.5: Curvas simuladas e ajustadas com frequência ressonante em diferentes valores de permissividade. Fonte: Autor, 2025.

De acordo com a metodologia empregada na análise anterior, foi proposta e analisada uma curva de tendência quadrática para avaliar o comportamento da frequência de ressonância em função dos valores correspondentes ao raio de abertura do tubo capilar, cujo raio variou de 4,5 mm a 2,6 mm, com incrementos de 0,3 mm. A análise do sensor baseado em CSRR, conforme apresentado no projeto final, é ilustrada na Figura 5.6 e descrita pela Equação (5.8). O coeficiente de determinação da regressão, $R^2 = 0,9987$, indica um ajuste altamente preciso em relação aos pontos experimentais obtidos para essa análise.

$$r1(f_r) = 0.3415f_r^2 - 3.372f_r + 10.125 \tag{5.8}$$

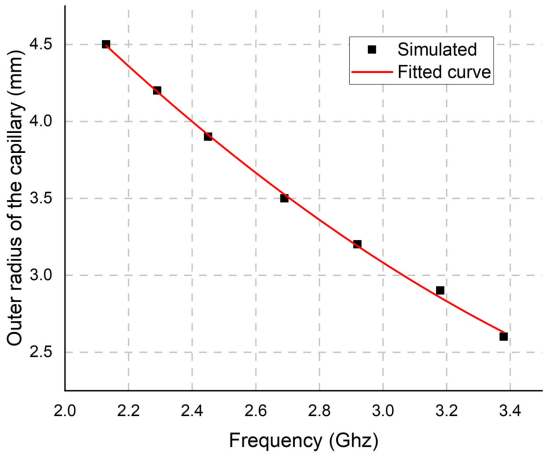


Figura 5.6: Raio de abertura do CSRR em diferentes frequências de ressonância. Fonte: Autor, 2025.

5.1.2 Resultados experimentais e comparações

Para validar o desempenho do sensor proposto, preparamos soluções usando xarope de glicose de milho comercial que consiste em 53% de glicose pura, 45% de outros açúcares e 2% de água. As soluções finais de xarope de glicose em água destilada em diferentes concentrações preparadas no laboratório foram medidas para avaliar o comportamento das propriedades dielétricas dessas misturas. A glicose foi adicionada à água em incrementos de 20% (20 mg/dL), resultando em concentrações específicas de 10% (10 mg/dL), 30% (30 mg/dL), 50% (50 mg/dL), 70% (70 mg/dL) e 90% (90 mg/dL) de água com glicose. Para uma análise mais detalhada, o parâmetro de transmissão também é medido para concentrações de 1% (1 mg/dL) a 20% (20 mg/dL), com uma etapa de 4% (4 mg/dL). Para garantir a precisão das quantidades de glicose em cada amostra, foi usada uma pipeta, garantindo assim a precisão das medições. Além disso, para evitar qualquer tipo de contaminação cruzada entre as amostras, a pipeta foi cuidadosamente seca após cada uso para eliminar qualquer resíduo da mistura anterior antes da próxima medição. É possível comparar nossas concentrações obtidas em laboratório com (MISHRA & PANDA 2024) um método rápido e econômico de glicosímetro que foi desenvolvido para medir os níveis de glicose em várias amostras de quatro tipos de folhas de plantas; os valores encontrados não ultrapassaram a faixa de 180 mg/dL. A Figura 5.7 ilustra o parâmetro de dispersão das diferentes concentrações da mistura de água e açúcar.

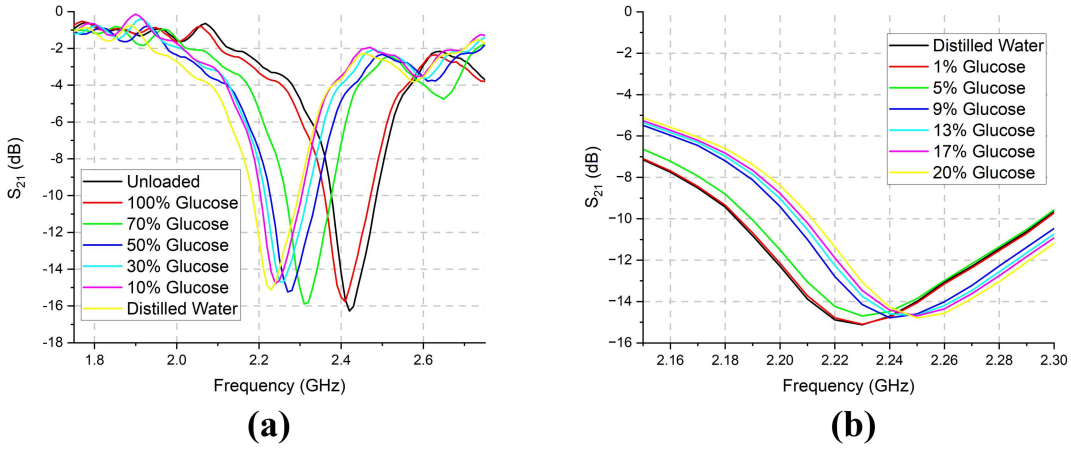


Figura 5.7: Resposta $|S_{21}|$ (em dB) medindo a mistura de água e glicose para diferentes frações de volume. (a) 10% a 100%. (b) 1% a 20%. Fonte: Autor, 2025.

A Figura 5.8 mostra o efeito da glicose-água em um gráfico da concentração de água na LUT como uma função da frequência em (GHz); é possível observar um declínio na frequência à medida que a concentração de água aumenta, o que é esperado.

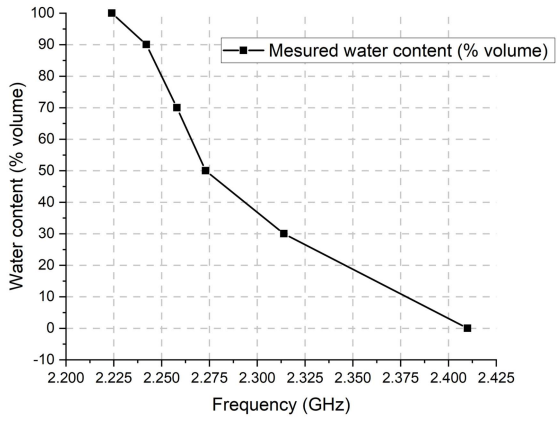


Figura 5.8: Concentração de água na LUT como uma função do desempenho da frequência (em GHz). Fonte: Autor, 2025.

Uma análise do coeficiente de transmissão do projeto final do sensor baseado em CSRR foi feita comparando a concentração da mistura de água e glicose. A solução com água destilada foi considerada 0%, e a carga de glicose pura foi considerada 100%. À medida que a concentração de glicose aumenta, a Figura 5.9 demonstra uma relação decrescente, indicando uma relação proporcional entre a concentração de glicose e o coeficiente de transmissão resultante.

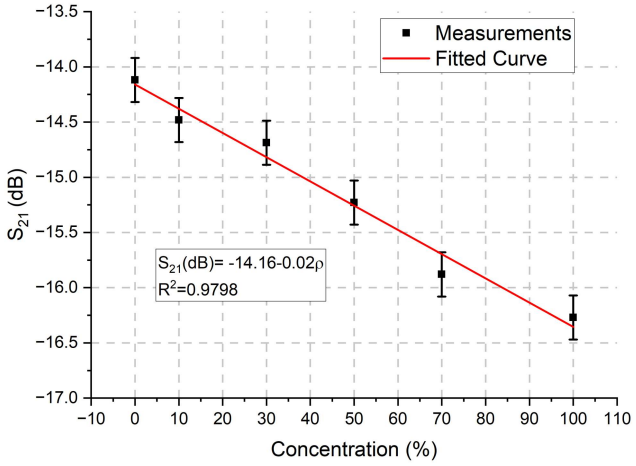


Figura 5.9: Efeitos da concentração de glicose na água sobre os parâmetros de transmissão $|S_{21}|$. Fonte: Autor, 2025.

A Figura 5.10 e a Tabela 5.1 mostram a comparação de desempenho entre o sensor proposto neste trabalho e outros sensores de micro-ondas relatados na literatura, usando a Equação 5.6 acima.

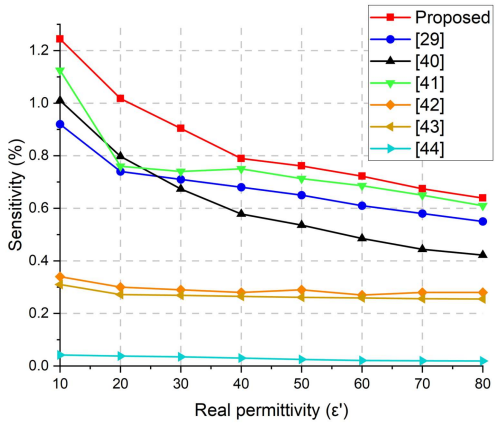


Figura 5.10: Comparação da sensibilidade do sensor proposto neste artigo com a de outros sensores avançados. Fonte: Autor, 2025.

A Tabela 5.2 mostra o erro durante as medições de concentração de água e glicose, para diferentes valores de volume; nesse caso, uma pipeta de 10 mL e uma pipeta de 1 mL foram usadas para obter as misturas desejadas; os valores estimados em mililitros são 3, 5, 7 e 10 mL. Portanto, é possível observar no gráfico de barras da Figura 5.11 que todos os erros de medição foram inferiores a 5% para as medições realizadas. O estudo não

Ref	Tipo de ressoador	Frequência (GHz)	Faixa de Permissividade	$S_{avg}(\%)$	Fabricação	Custo
[29]-(GAN et al. 2020)	MCSRR	1,618	1-80	0,630	Complexo	Alto
[40]-(WANG et al. 2022)	CSRR	2,84-2,96	1-90	0,610-0,590	Fácil	Alto
[41]-(EBRAHIMI et al. 2019)	SIR	1,91	1-80	0,760	Complexo	Alto
[42]-(KIANI et al. 2020)	NIDSRR	5,76-7,83	1-80	0,280-0,300	Moderado	Alto
[43]-(YOO et al. 2016)	SRCR	11,46-12,12	1-24	0,240-0,270	Complexo	Baixo
[44]-(GULSU et al. 2021)	Minkowski-like Fractal	1,97	1-80	0,027	Complexo	Alto
Este trabalho	CSRR	2,45	1-100	0,844	Fácil	Baixo

Tabela 5.1: Comparação do sensor proposto com projetos anteriores da literatura. Fonte: Autor, 2025.

aprofundou no contexto de correlação entre o volume de liquido medido e o erro gerado no sensor.

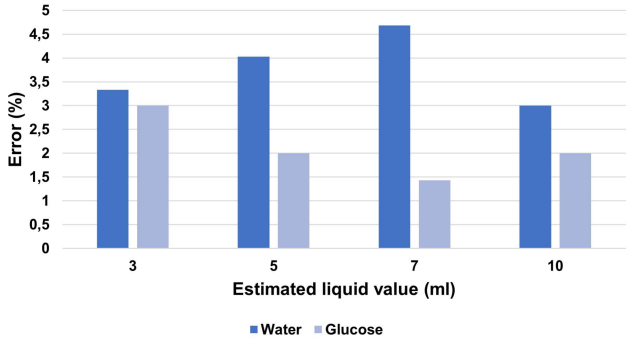


Figura 5.11: O erro percentual das medições de água e glicose de cada amostra em relação aos valores estimados (em mililitros). Fonte: Autor, 2025.

Volume estimado (mL)	Água		Glicose	
	Medido (mL)	Error (%)	Medido (mL)	Error (%)
3	2,90	3,33	2,91	3,00
5	5,21	4,03	4,90	2,00
7	6,70	4,68	6,90	1,43
10	9,80	3,00	9,80	2,00

Tabela 5.2: Erro de cálculo de água e glicose com valores estimados. Fonte: Autor, 2025.

Conforme previsto, o sensor CSRR proposto opera em uma frequência ressonante de 2,45 GHz quando descarregado. A adição do LUT aos tubos capilares de plástico resulta em uma variação de frequência, garantindo assim a sensibilidade normalizada. Como os tubos capilares são inseridos entre a estrutura CSRR e a linha de transmissão, o contato direto entre a LUT e o sensor é impedido. Além disso, os tubos capilares podem ser prontamente substituídos, se necessário. Portanto, o sensor proposto é a escolha ideal para medições de campo próximo de misturas homogêneas com alto grau de solubilidade

em água e baixa viscosidade. Essa metodologia nos permitiu determinar com precisão a proporção de água em misturas de água e glicose.

5.2 Projeto 02

5.2.1 Modelo de Circuito Equivalente e Sensibilidade

O modelo circuito equivalente (ECM) com elementos passivos dos quatro ressoadores (DR-CSRR, SR-CSRR, S-CSRR e C-CSRR) podem ser modelados através de indutores e capacitores em paralelo. Podemos ver com ajuda da figura 5.12 que o ECM1 e o ECM2 de ambos ressonadores podem expressar uma relação shunt-paralelo do CSRR de um resistor (R=247Ω e R=307Ω), uma capacitância (Cc=10,366pF e Cc=10,53pF) e um indutância (L=0,808nH e L=0,902nH). Já os parâmetros a capacitância (C=4,753pF e C=2,575pF) corresponde ao acoplamento entre linha de transmissão microstrip e o terra, juntamente com as indutâncias (Lm=1,726nH e Lm=1,726nH) da linha de transmissão. Para comparação foi simulado no software Advanced Design System (ADS) o ECM correspondente ao modelo ideal CSRRs do sensores, foram comparado ao seus valores simulados encontrados no ANSYS-HFSS e experimentais.

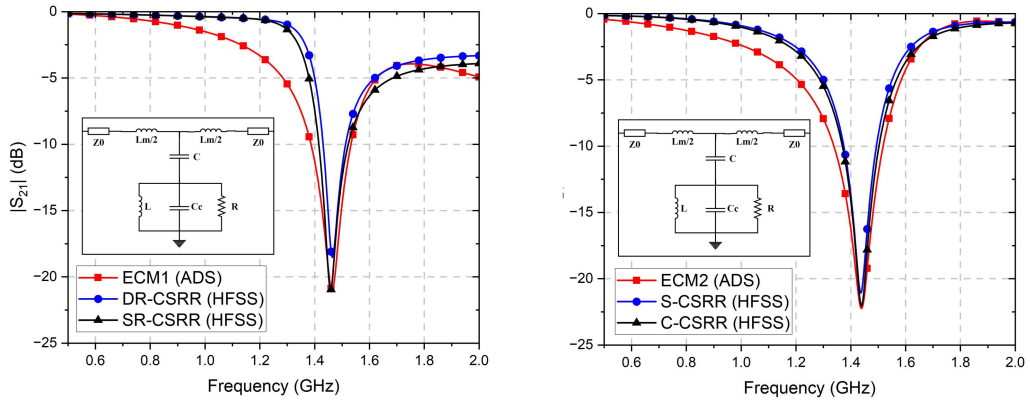


Figura 5.12: Comparação do $|S_{21}|$ do sensor proposto ECM, simulação ANSYS- HFSS. (a) DR-CSRR e SR-CSRR. (b) S-CSRR e C-CSRR. Fonte: Autor, 2025.

Foi comparado coeficiente de transmissão ($|S_{21}|$) simulado para diferentes permissividades diferentes. A mudança de permissividade do MUT, desloca a frequência de ressonância dos sensores propostos, foi realizado uma comparação dos quatro sensores propostos alterando a permissividade relativa de 1 a 100 com passo de 10. Nesse caso, a tangente de perdas do MUT foi setada em 0 para o caso sem perdas do material analisado e os parâmetros de dimensões e posicionamentos foram considerados os mesmos para todos os gráficos plotados. com dimensão de 1 mm de distancia do CSRR devido ao acrílico. como podemos ver na figura 5.13 do MUT abaixo. Figura 5.14 mostra a variação do

$|S_{21}|$ em relação a permissividade relativa comparada com os quatro sensores DR-CSRR, SR-CSRR, S-CSRR e C-CSRR propostos.

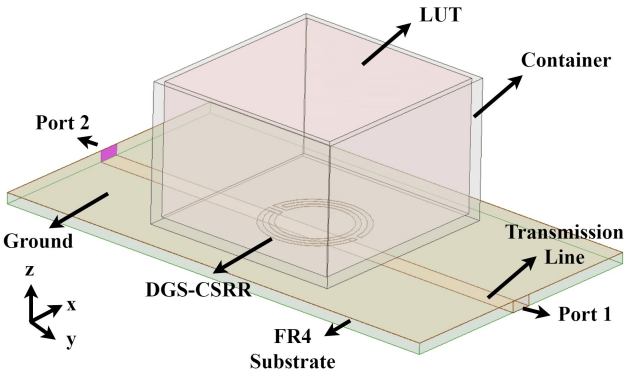


Figura 5.13: Estrutura dos sensores proposto com o contêiner de acrílico e LUT (líquido sob teste). Fonte: Autor, 2025.

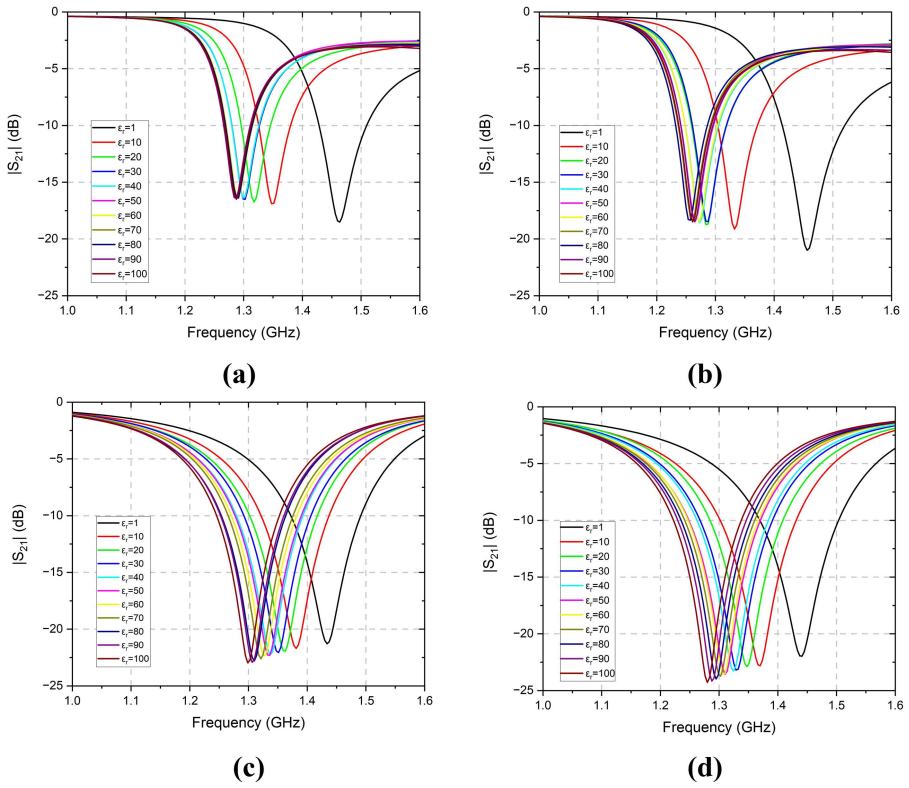


Figura 5.14: Simulação do parâmetro $|S_{21}|$ para diferentes permissividade relativas (1-100). (a) DR-CSRR. (b) SR-CSRR. (c) S-CSRR. (d) C-CSRR. Fonte: Autor, 2025.

Figura 5.15 mostra a variação do coeficiente de transmissão ($|S_{21}|$) dos sensores 4 sensores propostos em relação a tangente de perdas do substrato do sensor, variando a tangente de perdas de 0 a 0,03, e mantendo constante os valores de permissividade relativa $\varepsilon_r = 4,4$ e permeabilidade relativa $\mu_r = 1$. É possível notar uma variação considerável dos valores mínimos do coeficiente de transmissão para tangente de perdas menores, o que podemos confirmar que o FR-4 se obtém um valores de notch de -20 dB adequado para nossa análise.

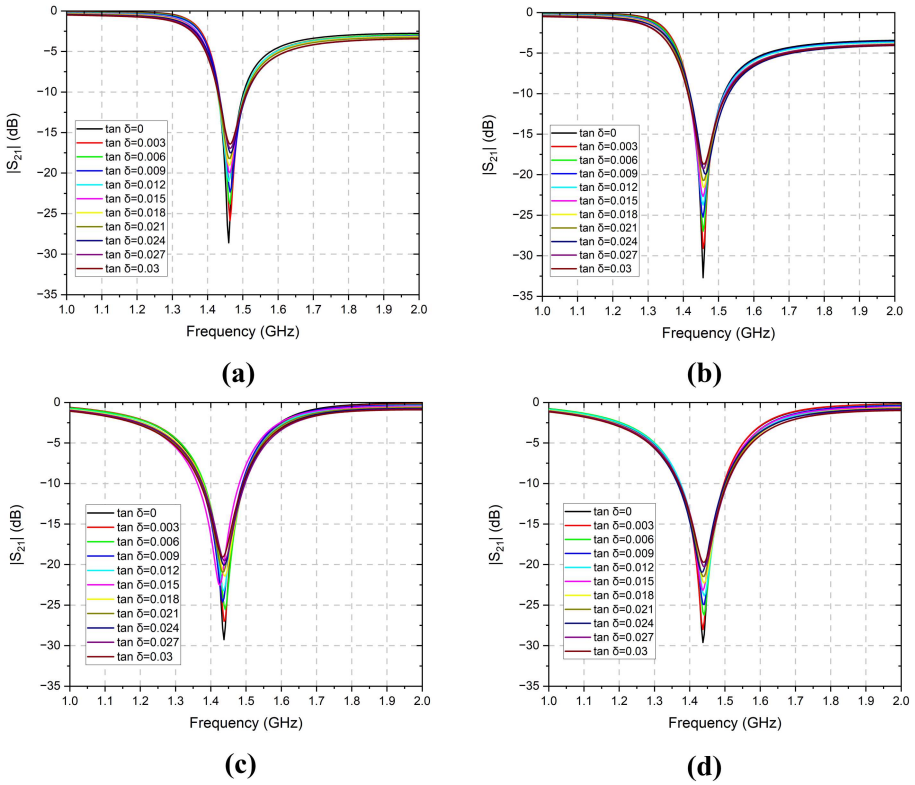


Figura 5.15: Simulação do parâmetro $|S_{21}|$ para diversas tangentes de perdas elétricas $tan\delta$ (0-0,03). (a) DR-CSRR. (b) SR-CSRR. (c) S-CSRR. (d) C-CSRR. Fonte: Autor, 2025.

A sensibilidade normalizada dos quatro sensores propostos foram analisadas através da mudança da permissividade relativa do MUT e dos resultados mostrados na figura 5.14. Para isso foi analisado o desvio da frequência de ressonância em comparação a frequência em vazio associado a cada sensor proposto (deltafr). Foram analisados também a porcentagem relativa ao desvio de frequência (PRFS), o aprimoramento do deslocamento da frequência ressonante percentual (PRFSE) comparadas ao sensor DR-CSRR, e por fim o percentual de aprimoramento da sensibilidade (SE) para os quatro sensores. Podemos ver na figura 5.16 abaixo os resultados encontrados para análises de sensibilidade feita nos sensores propostos.

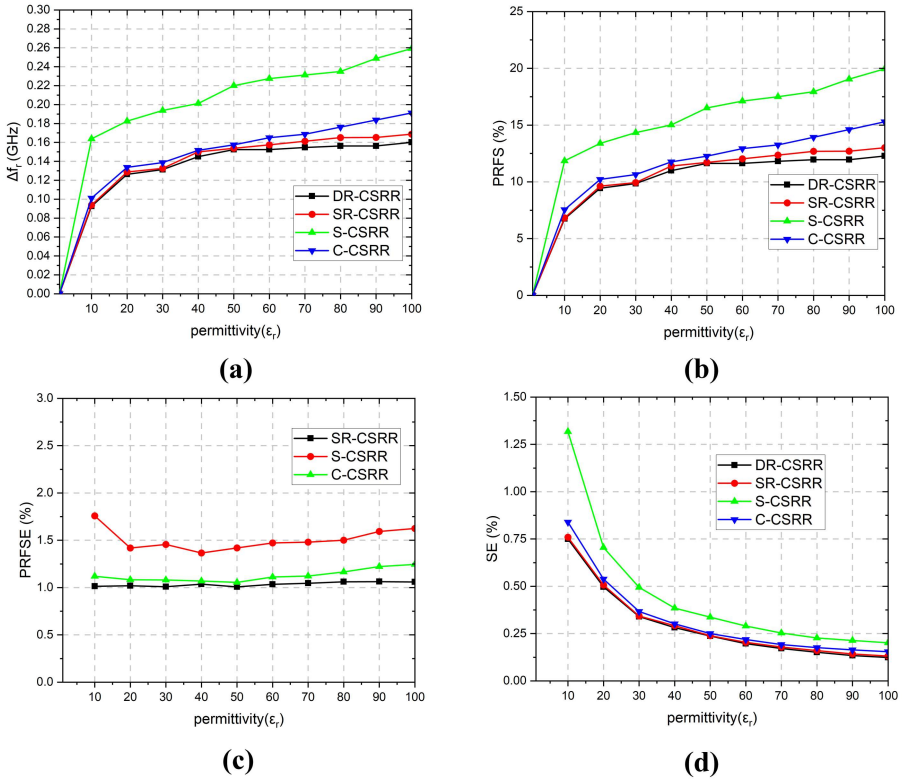


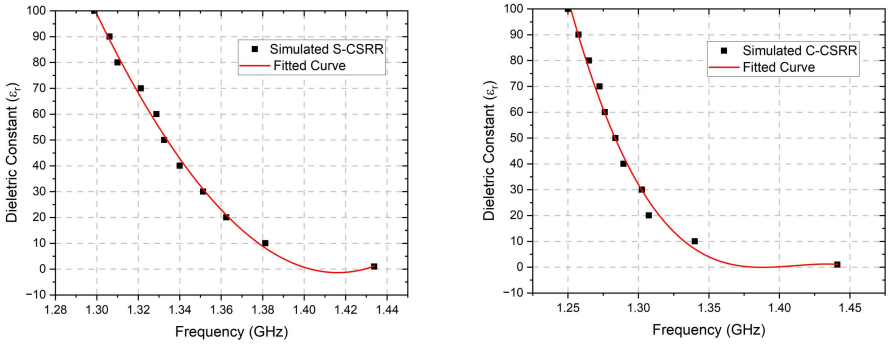
Figura 5.16: Comparação da sensibilidade simulada dos quatro sensores propostos: (a) Deslocamento de frequência (Δf_r (GHz)). (b)deslocamento de frequência relativa percentual (PRFS). (c) Aprimoramento percentual do deslocamento da frequência ressonante (PRFSE) em comparação com o sensor baseado em DR-CSRR. (d) Aprimoramento da sensibilidade percentual. Fonte: Autor, 2025.

Observou-se que a sensibilidade dos sensores apresentava uma relação inversa com a permissividade, mostrando-se mais elevada quando a permissividade era reduzida. Assim, verificou-se uma diminuição contínua da sensibilidade à medida que a permissividade aumentava para os quatro sensores analisados como podemos notar nos gráficos de aprimoramento da sensibilidade.

Figura 5.17 mostra alguns pontos de permissividade relativa real em função da frequência de ressonância para os sensores S-CSRR e C-CSRR foco de nosso estudo, foi traçado uma curva de ajuste utilizando o método matemático de ajuste polinomial aos pontos obtidos. Além disso, foi mostrado que a equação corresponde a curva de ajuste e o seu coeficiente de regressão $R^2 = 0,9952$ e $R^2 = 0,9907$, $R^2 = 0,9952$ e $R^2 = 0,9946$ respectivamente mostrando alta correlação entre os pontos e a curva, análise primordial para caracterizar a permissividade relativa real das amostras iniciais do estudo.

$$\varepsilon'(f_r) = 5075,5 f_r^3 - 13558,80 f_r^2 + 7866,77 f_r + 1635,77 \tag{5.9}$$

$$\varepsilon'(f_r) = -2640605,35 f_r^3 + 111773,17 f_r^2 - 157665,14 f_r + 74114,18 \tag{5.10}$$



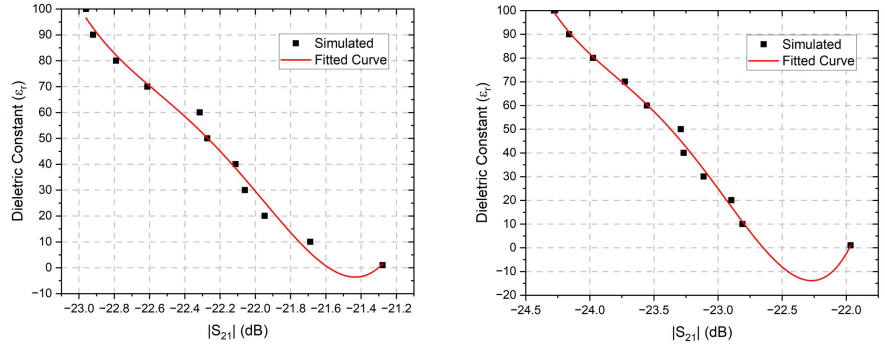
(a) **(b)**

Figura 5.17: Curvas simuladas e ajustadas com frequência ressonante em diferentes valores de permissividade. (a) S-CSRR. (b) C-CSRR. Fonte: Autor, 2025.

Figura 5.18 mostra alguns pontos de permissividade relativa imaginária em função da nível de amplitude da frequência de ressonância para os sensores S-CSRR e C-CSRR, foi usado o mesmo método matemático que anteriormente suas equação corresponde a curva de ajuste e o seu coeficiente de regressão $R^2 = 0,9952$ e $R^2 = 0,9946$, respectivamente mostrando alta correlação entre os pontos e a curva, análise primordial para caracterizar a permissividade relativa imaginária das amostras.

$$\varepsilon^{"}(S_{21}(dB)) = 52,64S_{21}(dB)^4 + 4686,52S_{21}(dB)^3 + 156422,91S_{21}(dB)^2 + 2319928,09S_{21}(dB) + 1,2899E7 \quad (5.11)$$

$$\varepsilon^{"}(S_{21}(dB)) = 20,97S_{21}(dB)^4 + 1960,73S_{21}(dB)^3 + 68714,87S_{21}(dB)^2 + 1069860,05S_{21}(dB) + 6243655,45 \quad (5.12)$$



(a) **(b)**

Figura 5.18: Curvas simuladas e ajustadas com amplitude de $|S_{21}|$,em dB, em diferentes valores de permissividade. (a) S-CSRR. (b) C-CSRR. Fonte: Autor, 2025.

5.2.2 Resultados experimentais e comparações

Também foi verificado os parâmetros-S dos quatro sensores propostos e comparados aos resultados obtidos pelo o software de simulação ANSYS-HFSS, observou-se um forte aproximação da frequência de ressonância do $|S_{21}|$ entre o modelo do circuito simulado e os resultados obtidos experimentalmente, apresentando uma boa resposta do sensores propostos, como podemos ver na figura 5.19 abaixo.

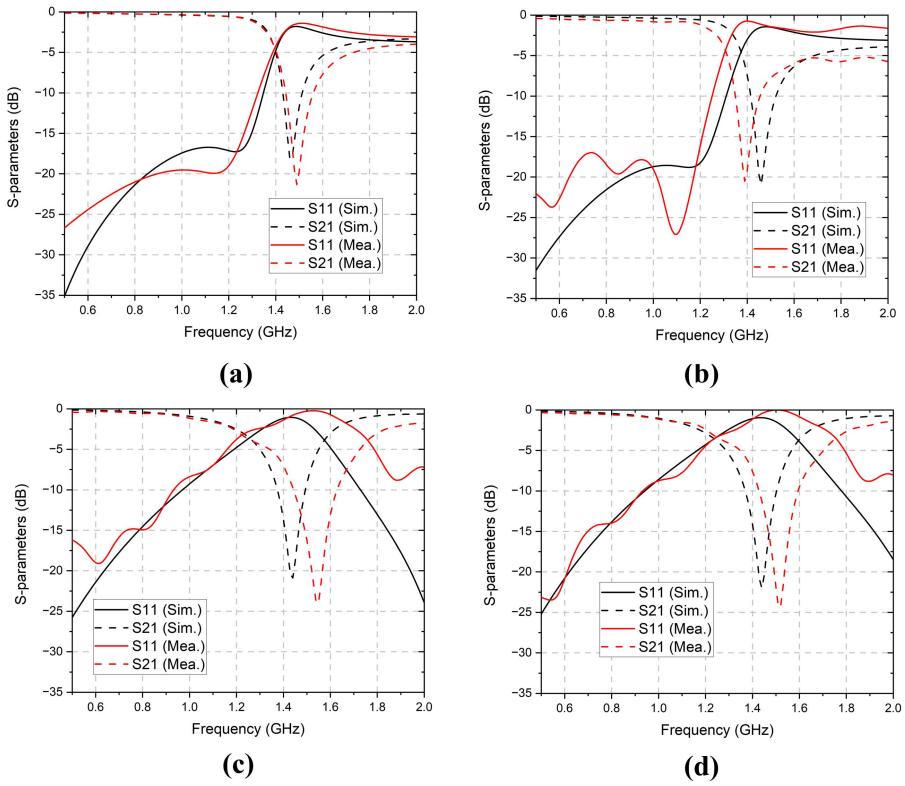


Figura 5.19: Comparação dos parâmetros S_{21} simulados e medidos. (a) DR-CSRR. (b) SR-CSRR. (c) S-CSRR. (d) C-CSRR. Fonte: Autor, 2025.

As principais diferenças encontradas na simulação e na medição são devido ao processo de fabricação do sensor envolver um erro de fabricação associado na ordem de mais ou menos 10% do valor esperado, ocasionando o desvio da frequencia encontrada e as perdas associadas a propriedades das placas utilizadas.

Para validar os resultados dos sensores propostos foram medidas os coeficientes de transmissão $|S_{21}|$ para diferentes soluções aquosas que correspondem aos principais contaminantes presentes em rios, mares e lagos. Foi medido as propriedades dielétricas de cada amostra com os respectivos contaminante ou modificação da característica da água, como solubilidade (salinidade/condutividade), ou contaminantes provenientes como agricultura (Nitrato, Fosfato e Amônia) ou de metais pesados provenientes de outras fontes industriais. A tabela 5.3 mostra as amostras comerciais usadas no estudo e seus respecti-

vos níveis de concentração ou valores de parâmetros. As amostras foram diluídas em 10 mL de água destilada, e os contaminantes foram introduzidos através de uma pipeta milimétrica. Além disso, para evitar qualquer tipo de contaminação cruzada entre as amostras, a pipeta foi cuidadosamente seca após cada uso para eliminar qualquer resíduo da mistura anterior antes da próxima medição. Figura 5.20 mostra o coeficiente de transmissão $|S_{21}|$, em dB, da onda para diferentes amostras dos sensores propostos.

Amostra	**Concentração em água (μg/mL)**
Fosfato (PO_4)	100
Nitrato (NO_3)	100
Amônio (NH_4)	100
Cloreto de Sódio (NaCl)	5000 and 40000

Tabela 5.3: Concentração das amostras usadas para obter a resposta de ressonância dos sensores propostos. Fonte: Autor, 2025.

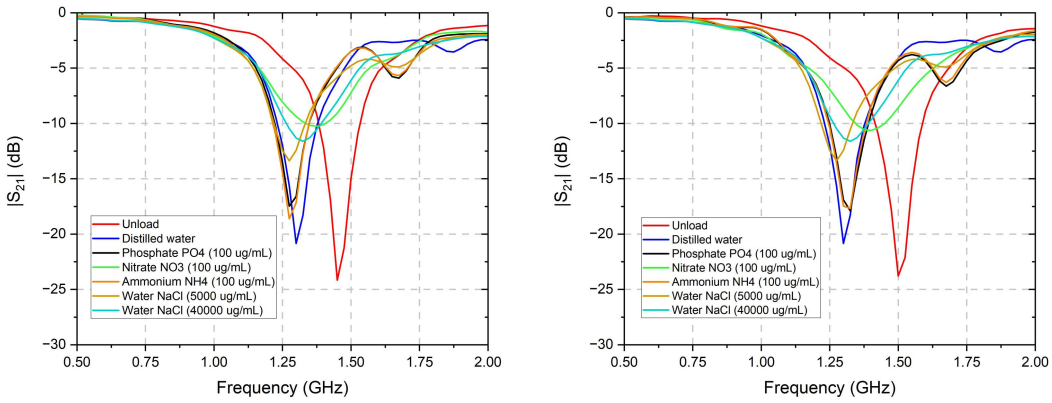


Figura 5.20: Medida $|S_{21}|$ realizada para diferentes amostras aquosas + contaminantes. (a) S-CSRR. (b) C-CSRR. Fonte: Autor, 2025.

		Nitrato	**Fosfato**	**Amônio**	**salt5k**	**salt40k**	**Água destilada**
S-CSRR	freq. (GHz)	1,375	1,275	1,275	1,275	1,325	1,300
	A (dB)	-10,2514	-17,4730	-18,6036	-13,3780	-11,6152	-20,8383
C-CSRR	freq. (GHz)	1,400	1,325	1,3000	1,2750	1,325	1,300
	A (dB)	-10,6332	-17,8973	-17,4594	-13,3780	-11,6152	-20,8383

Tabela 5.4: Valores de f_r e $|S_{21}|$ medidos para cada sensor proposto. Fonte: Autor, 2025.

Para a caracterização experimental das amostras aquosas e contaminantes do MUT utilizou o método matemático de Nicolson-Ross-Weir (NRW) utilizando para cálculo os parâmetros de espalhamentos (S_{11} e S_{21}) obtidos na etapa anterior, foi considerado a espessura da amostra de d = 18 mm e foi possível calcular a permissividade relativa real e imaginária para cada solução desejada.



Figura 5.21: Configuração de medição do método NRW utilizada para medir as amostras. Fonte: Autor, 2025.

Figura 5.22 mostra a permissividade relativa real e imaginária experimental de diferentes soluções aquosas de água destilada com os contaminantes de Nitrato, Fosfato e Amônia para os quatro sensores propostos. É possível observar uma mudança brusca devido ao método matemático utilizado em torno da frequência de ressonância dos sensores baseados em CSRR. É possível notar também uma estabilidade na permissividade relativa real em torno de 80 para as soluções aquosas.

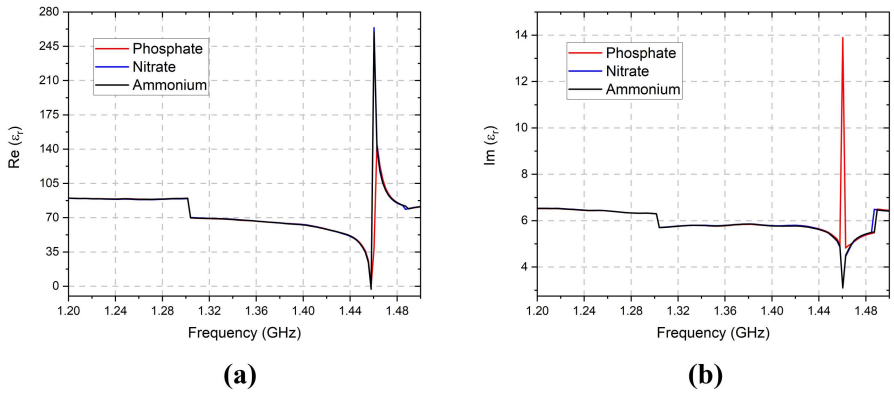
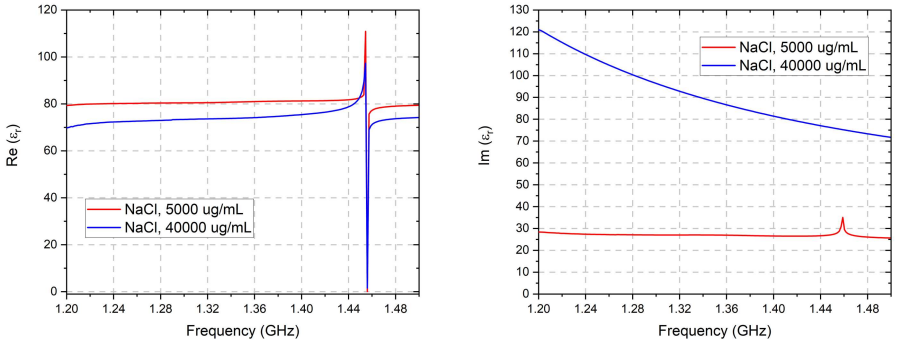


Figura 5.22: Variação da permissividade relativa real imaginária versus a frequência pelo método NRW para nitrato, fosfato e amônio. (a) ε'_r. (b) ε''_r. Fonte: Autor, 2025.

Figura 5.23 mostra a permissividade relativa real e imaginária experimental de diferentes soluções aquosas para salinidade da água com concentrações de 5000 e 40000 μg/mL. É possível observar que com aumento da salinidade da uma mudança na permissividade relativa imaginária da amostra como indicado nas figuras.



(a) **(b)**

Figura 5.23: Variação da permissividade relativa versus a frequência pelo método NRW para NaCl 5000 e NaCl 40000. (a) ε'_r. (b) ε''_r. Fonte: Autor, 2025.

Tabela 5.5 e 5.6 mostra a comparação dos valores encontrados nas equações de ajuste (5.9), (5.10) (5.11) e (5.12) de permissividade relativa real e imaginária e os valores NRW e os valores de permissividades esperados na literatura para os sensores S-CSRR e C-CSRR respectivamente.

Contaminantes	**Permissividade relativa baseada nas eq. 5.9 e 5.11**		**Permissividade relativa baseada no metódo NRW**	
Fosfato (PO_4)	**Real**	**Imag.**	**Real**	**Imag.**
	80,79	4,57	79,52	6,43
Nitrato (NO_3)	73,93	4,84	71,85	5,64
Amônio (NH_4)	80,79	4,98	82,43	6,38
Sal 5000 (NaCl)	80,79	25,36	79,80	28,02
Sal 40000 (NaCl)	70,97	94,56	72,76	95,27

Tabela 5.5: Comparação da permissividade relativa real e imaginária em diferentes métodos para o sensor S-CSRR. Fonte: Autor, 2025.

Contaminantes	**Permissividade relativa baseada nas eq. 5.10 e 5.12**		**Permissividade relativa baseada no metódo NRW**	
Fosfato (PO_4)	**Real**	**Imag.**	**Real**	**Imag.**
	71.62	5,19	79,52	6,43
Nitrato (NO_3)	78,13	4,38	71,85	5,64
Amônio (NH_4)	81,95	4,67	82,43	6,38
Sal 5000 (NaCl)	81,13	25,52	79,80	28,02
Sal 40000 (NaCl)	71.62	98.47	72,76	95,27

Tabela 5.6: Comparação da permissividade relativa real e imaginária em diferentes métodos para o sensor C-CSRR. Fonte: Autor, 2025.

Além disso, a figura 5.24 e 5.25 mostra os valores encontrados para o diferença de frequência de ressonância da amostra+contaminante para o frequência do MUT vazio (Δf_r), além da sua diferença de amplitude $|S_{21}|$ Em comparação ao MUT vazio (ΔA) para diferentes medidas realizadas, o estudo tem o propósito de verificar outros tipos de sensibilidade do sensor para detecção dos contaminantes mencionados nas soluções aquosas para cada tipo de sensor. A tabela 5.7 mostra o erro percentual e o desvio padrão encontrado nas medidas obtidas da figura 5.20 para cada tipo de amostra analisada.

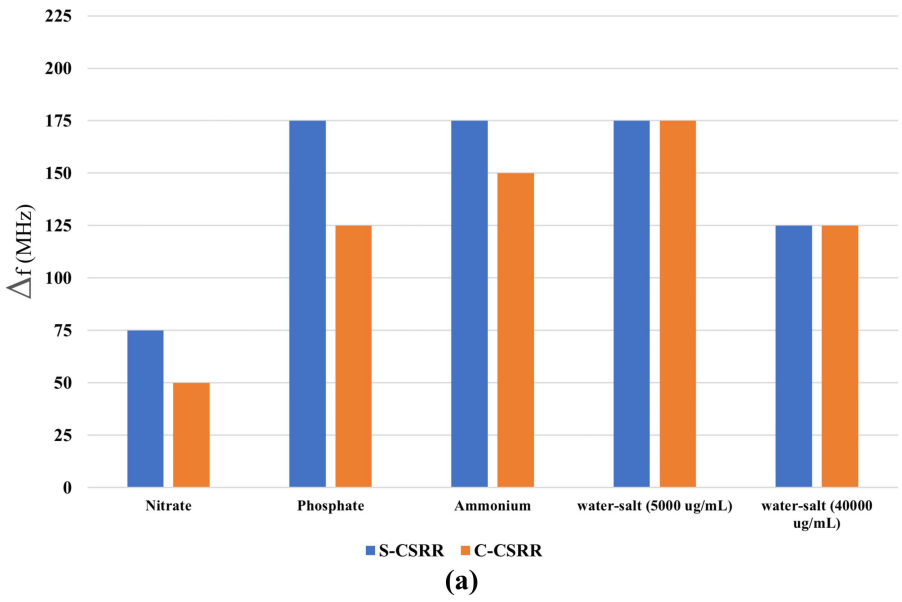


Figura 5.24: Alterações de resposta devido a soluções de água com duas concentrações para as soluções testadas para deslocamento da frequência. Fonte: Autor, 2025.

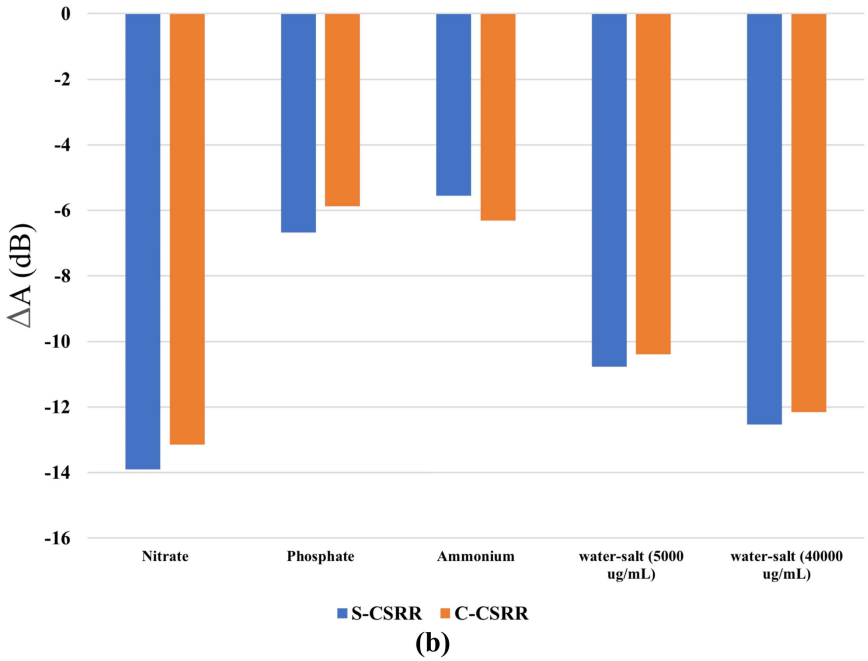


Figura 5.25: Alterações de resposta devido a soluções de água com duas concentrações para as soluções testadas para Deslocamento da amplitude. Fonte: Autor, 2025.

Contaminantes	**Valor Estimado (μg)**	**Média medida (μg)**	**Numero de amostras (N)**	**Erro (%)**	**Desvio Padrão (σ)**
Fosfato (PO_4)	100	93,9	10	6,10	0,875
Nitrato (NO_3)	100	97,2	10	2,80	1,451
Amônio (NH_4)	100	95,3	10	4,70	1,232
Sal (NaCl)	5000	4987,5	10	0,25	1,099
Sal (NaCl)	40000	39984,0	10	0,038	0,656

Tabela 5.7: O erro percentual e desvio padrão das medições dos reagentes químicos utilizados em cada amostra em relação aos valores estimados (em micrograma). Fonte: Autor, 2025.

Por fim, foi feito um comparativo do sensores de micro-ondas baseados em CSRR fabricados, com sensores disponíveis na literatura atualmente com os mesmo intuito e característica, foram comparados seus aprimoramentos de sensibilidade e algumas outras características importantes para esses tipo de sensores. como podemos ver na figura 5.26 e tabela 5.8.

Ref.	Tipo de ressoador	Freq. (GHz)	Faixa de permissividade	Savg (%)	Fabricação	Custo
[34]-(WANG et al. 2022)	CSRR	2,84	1-90	0,306	Fácil	Alto
[35]-(ALSHALTONE et al. 2023)	CSRR	3	1-80	0,253	Fácil	Baixo
Esse trabalho	S-CSRR	1,5	1-100	0,493	Fácil	Baixo
Esse trabalho	C-CSRR	1,5	1-100	0,320	Fácil	Baixo

Tabela 5.8: Comparação dos sensores micro-ondas proposto com sensores presente na literatura. Fonte: Autor, 2025.

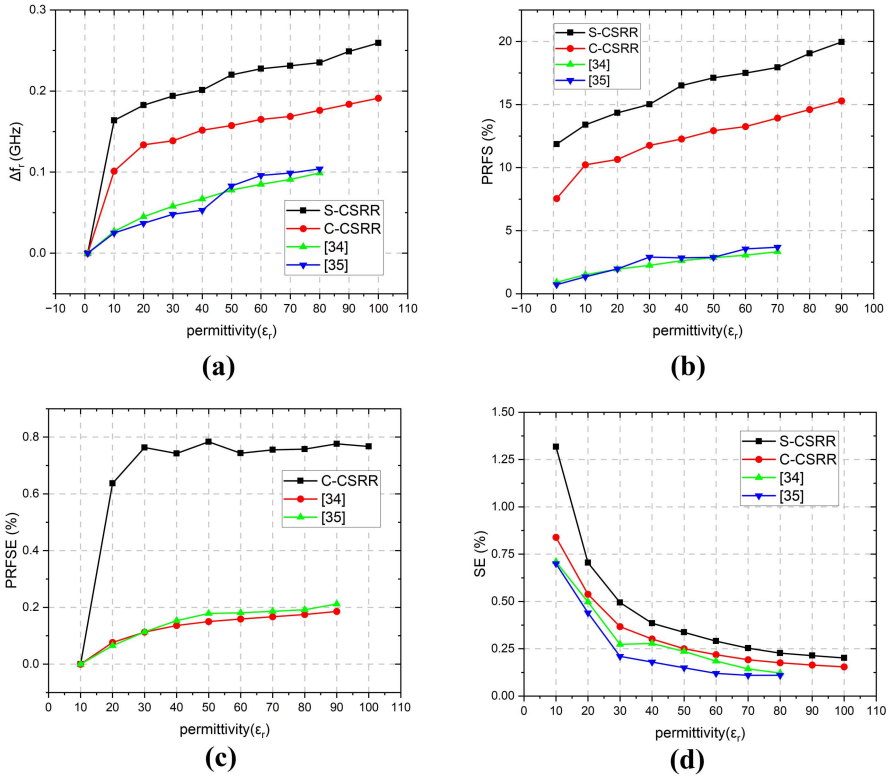


Figura 5.26: Comparação da sensibilidade em relação dos sensores S-CSRR e C-CSRR a sensores presente na literatura: (a) Deslocamento de frequência (Δf_r (GHz)). (b)deslocamento de frequência relativa percentual (PRFS). (c) Aprimoramento percentual do deslocamento da frequência ressonante (PRFSE) em comparação com o sensor baseado em DR-CSRR. (d) Aprimoramento da sensibilidade percentual. Fonte: Autor, 2025.

No geral, observa-se mudanças na resposta da frequência de ressonância dos sensores de micro-ondas propostos, principalmente nas novas topologias de sensor S-CSRR e C-CSRR no qual é possível notar uma que a maior sensibilidade encontrada para sensores, além de seu baixo perfil e custo de fabricação o tornando ideal para medidas de campo próximo de misturas aquosas homogêneas.

5.3 Projeto 03

5.3.1 Modelo de Circuito Equivalente e Sensibilidade

Para validar o sensor planar de micro-ondas proposto, foi projetado um modelo de circuito equivalente (ECM) para a célula baseada em IDC interconectada ao terra. Os parâmetros do ECM incluem Z_0, que corresponde à impedância característica da linha de transmissão e foi definido como 50 Ω. Os parâmetros C_{int}, R_{int} e L_{int} correspondem à capacitância, à resistência e à indutância do IDC, respectivamente. Nesse contexto, os parâmetros e L_1 representam a indutância da linha de transmissão. Além disso, o ECM é empregado para determinar as dimensões da célula IDC em uma frequência de ressonância de 1,86 GHz em vazio. O ECM foi inicialmente simulado usando o Advanced Design System (ADS), e seus valores foram ajustados para se alinharem aos resultados obtidos com o ANSYS-HFSS e aos obtidos por meio de experimentos, conforme ilustrado na Figura 5.27.

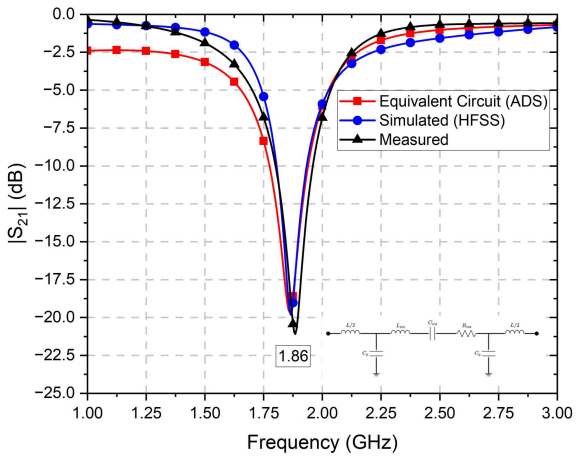


Figura 5.27: Comparação do $|S_{21}|$ do sensor proposto para ECM, HFSS e experimental com ($L = 17.7\,nH$, $L_{int} = 9.5\,nH$, $C_{int} = 26.4\,pF$, $R_{int} = 210\,\Omega$ e $C_p = 0.4\,nF$). Fonte: Autor, 2025.

Foi comparado coeficiente de transmissão ($|S_{21}|$) simulado para diferentes permissividades diferentes. A mudança de permissividade do MUT, desloca a frequência de ressonância dos sensores propostos, foi realizado uma comparação dos quatro sensores propostos alterando a permissividade relativa de 1 a 100 com passo de 10. Nesse caso, a tangente de perdas do MUT foi setada em 0 para o caso sem perdas do material analisado e os parâmetros de dimensões e posicionamentos foram considerados os mesmos para todos os gráficos plotados. Figura 5.28 mostra a variação do $|S_{21}|$ em relação a permissividade relativa comparada com os quatro sensor IDC proposto.

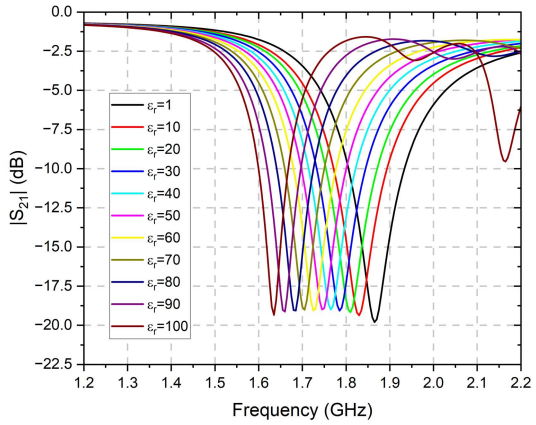


Figura 5.28: Simulação Coeficiente de transmissão, $|S_{21}|$, para diferentes valores de permissividade relativa. Fonte: Autor, 2025.

Figura 5.29 mostra a variação do coeficiente de transmissão ($|S_{21}|$) do sensor proposto em relação a tangente de perdas do substrato do sensor, variando a tangente de perdas de 0 a 0,03, e mantendo constante os valores de permissividade relativa $\varepsilon_r = 4,4$ e permeabilidade relativa $\mu_r = 1$.

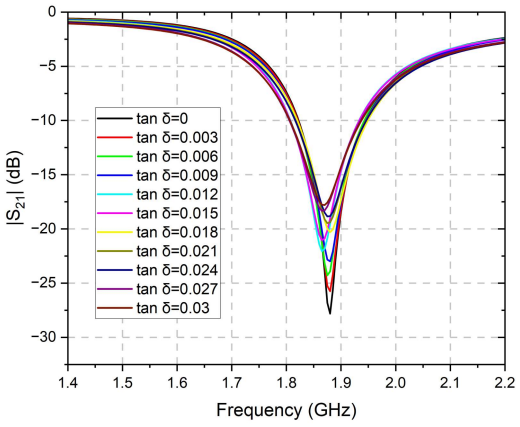


Figura 5.29: Resposta $|S_{21}|$ simulada do sensor CSRR proposto para a tangente de perda de $0,00$ a $0,03$ com intervalos de $0,003$. Fonte: Autor, 2025.

Foi analisado o desvio da frequência de ressonância em comparação a frequência em vazio associado a cada sensor proposto (deltafr). Foram analisados também a porcentagem relativa ao desvio de frequência (PRFS), o aprimoramento do deslocamento da frequência ressonante percentual (PRFSE) comparadas ao sensor DR-CSRR, e por fim o percentual de aprimoramento da sensibilidade (SE) para os quatro sensores. Podemos ver

na figura 5.30 abaixo os resultados encontrados para análises de sensibilidade feita nos sensores propostos.

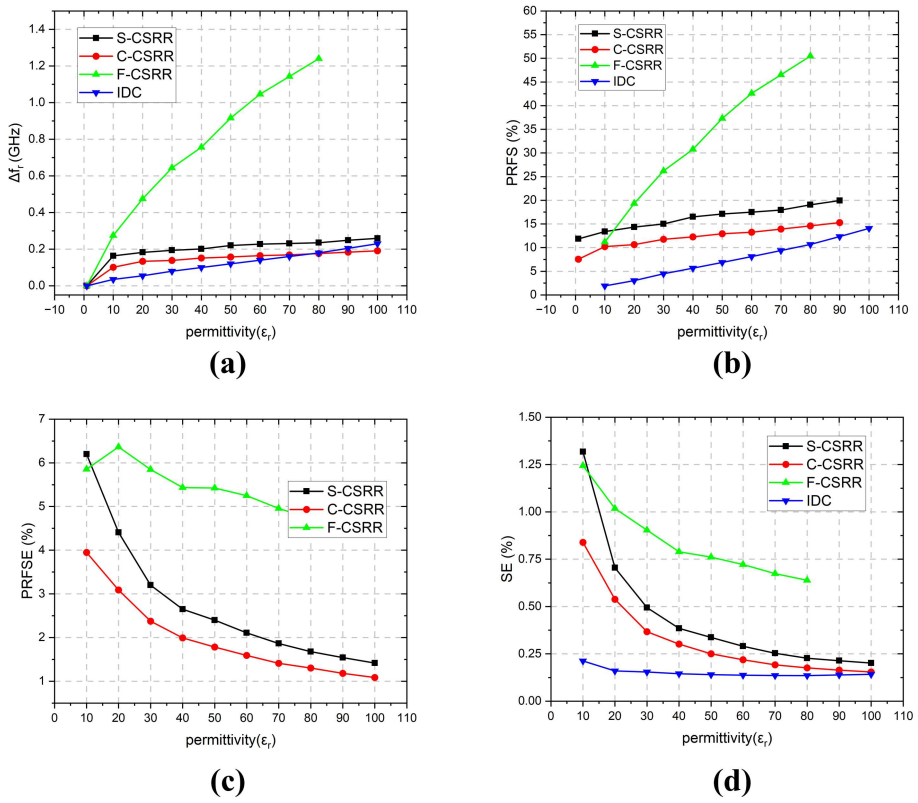


Figura 5.30: Os resultados da investigação dos principais parâmetros de sensibilidade do sensores proposto nesse trabalho comparando com IDC: (a) deslocamento ressonante (Δf_r); deslocamento de frequência relativa percentual (PRFS); (c) aprimoramento do deslocamento de frequência ressonante percentual (PRFSE). Fonte: Autor, 2025.

Figura 5.31 mostra alguns pontos de permissividade relativa real em função da frequência de ressonância para o sensor IDC, foi traçado uma curva de ajuste utilizando o método matemático de ajuste polinomial aos pontos obtidos. Além disso, foi mostrado que a equação corresponde a curva de ajuste e o seu coeficiente de regressão $R^2 = 0,9969$ respectivamente mostrando alta correlação entre os pontos e a curva, análise primordial para caracterizar a permissividade relativa real das amostras iniciais do estudo.

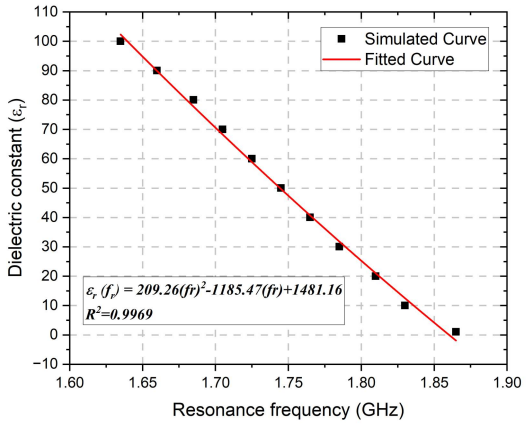


Figura 5.31: Curvas simuladas e ajustadas com frequência ressonante em diferentes valores de permissividade. Fonte: Autor, 2025.

5.3.2 Resultados experimentais e comparações

Foi medido as propriedades dielétricas de cada amostra com os respectivos contaminantes provenientes como agricultura (Nitrato e Fosfato). A tabela 5.3 mostra as amostras comerciais usadas no estudo e seus respectivos níveis de concentração ou valores de parâmetros. As amostras foram diluídas em 10 mL de água destilada, e os contaminantes foram introduzidos através de uma pipeta milimétrica. Além disso, para evitar qualquer tipo de contaminação cruzada entre as amostras, a pipeta foi cuidadosamente seca após cada uso para eliminar qualquer resíduo da mistura anterior antes da próxima medição. Figura 5.32 mostra o coeficiente de transmissão $|S_{21}|$, em dB, da onda para o sensor IDC proposto.

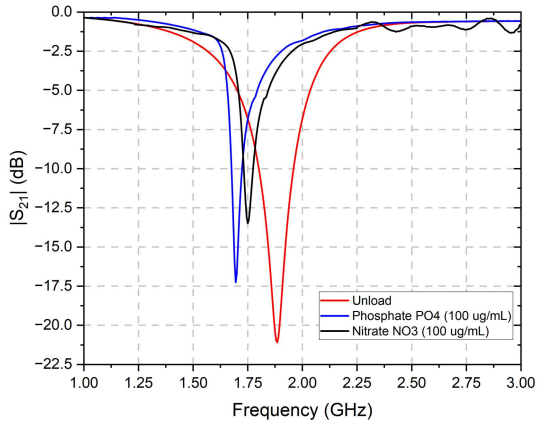


Figura 5.32: Medida $|S_{21}|$ realizada para o sensor sem carga e com os contaminantes nitrato e fosfato. Fonte: Autor, 2025.

Por fim, foi feito um comparativo do sensor de micro-ondas baseado em IDC, com as demais topologias propostas nesse trabalho e com sensores disponíveis na literatura atualmente com os mesmo intuito e característica, foram comparados seus aprimoramentos de sensibilidade e algumas outras características importantes para esses tipo de sensores. como podemos ver na tabela 5.8.

Dessa forma, a modificação da estrutura DGS é um parâmetro importante para melhor detalhamento do estudo de contaminantes em solução aquosa, o sensor IDC é uma topologia de ressoador que garante uma nova análise para a classificação dos contaminantes apresentou desempenho próximo ao esperado para esse tipo de ressoador, além de ser simples de fabricar e de baixo custo o que possibilita que o estudo seja ampliado para estruturas ressonantes e aplicações diferentes da SRR.

5.4 Detecção dos contaminantes por aprendizado de máquina

O sistema para detecção dos contaminantes se baseam na figura X. A partir do dataset foram realizados o pré-processamento dos dados coletados pelos dispositivos sensores fabricados anteriormente, após foi feita uma separação dos dados implementando técnicas de validação cruzada, após isso um estudo de regressão por aprendizado de máquina para aproximar a curva da permissividade relativa real em função da frequência para diversos modelos de regressores como (Linear Regressor, Polynomial Regressor, SGD Regressor, MLP Regressor, Decision Tree, Random Forest, Decision SVM) utilizados amplamente na área de aprendizado de máquina. Em outra face do estudo, serão abordados uma classificação dos contaminantes através de um método supervisionado utilizando uma validação cruzada pelo o método leave-one-out (LOO), Stratified Kfold Evaluation (SKF) e Repeated Stratified Kfold Evaluation (RSKF) e saber qual melhor modelo tem a predição de

classificar nossas amostras em relação ao contaminante (Água Destilada, Água + Fosfato e Água + Nitrato), com isso será feito o comparativo de diversos modelos de classificadores usuais na aprendizagem de máquina (Logistic Regression, Decision Tree, Random Forest, K-nearest Neighbors, Gaussian Naive Bayes, Multi-Layer Perceptron, Decision Support Vector Machine) e realizado uma comparação pela curva ROC, para determinar sua sensibilidade e especificidade de cada classificador, além do valor preditivo da área sob a curva (AUC) para cada modelo serão calculados suas matriz de confusão e seus parâmetros de acurácia, precisão, F1-score, recall. Por fim, será feita uma comparação com todos os modelos de sensores utilizados, para saber qual obteve o melhor desempenho para ácuracia. Como podemos ver na figura abaixo.

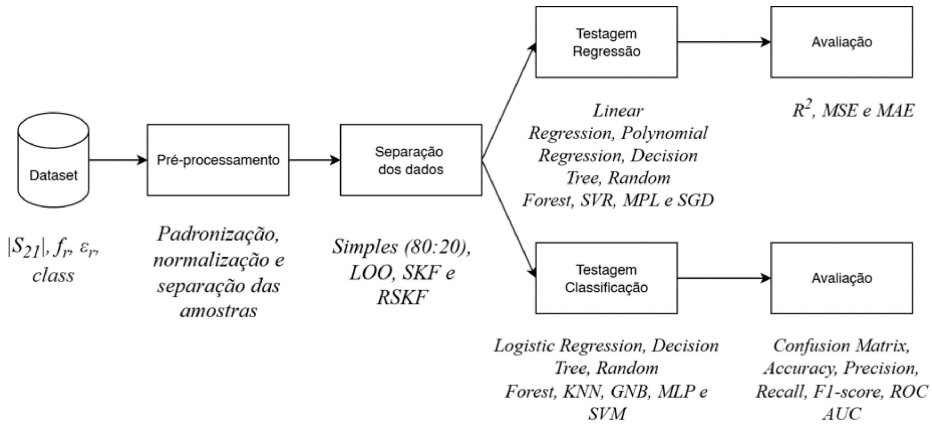


Figura 5.33: Fluxograma de aplicação ML. Fonte: Autor, 2025.

5.4.1 Coleta das amostras e montagem do Dataset

5.4.1.1 Coleta das amostras

O procedimento experimental desenvolvido neste trabalho foi estruturado em três etapas principais, conforme ilustrado na Figura 5.34. Inicialmente, foram preparados os contaminantes em solução aquosa, considerando água destilada (amostra de referência), nitrato e fosfato, ambos em concentração de 100 μg/mL. A preparação das amostras foi realizada em laboratório por meio de técnicas de pipetagem, diluições controladas (1:1) e homogeneização, assegurando reprodutibilidade entre as medidas. Em seguida, cada amostra foi acondicionada em recipientes padronizados, de modo a minimizar variações geométricas e garantir contato adequado com a região sensora. Para a etapa de caracterização, empregou-se um sensor planar em microfita com estrutura do tipo CSRR e IDC acoplado a um analisador vetorial de redes portátil (miniVNA), responsável pela aquisição da resposta em frequência $|S_{21}|$ no intervalo de 1 a 3 GHz. O sistema foi previamente calibrado pelo método open-short-load/through, de forma a corrigir efeitos parasitários e estabelecer uma linha de base confiável. Durante as medições, cada amostra foi posicionada sobre a região ressonante do sensor e submetida a varredura espectral, resultando em um conjunto de 300 aquisições, sendo 100 para cada classe de contaminante.

Podemos ver na figura abaixo, o fluxo da preparação laboraorial e medição das amostras.

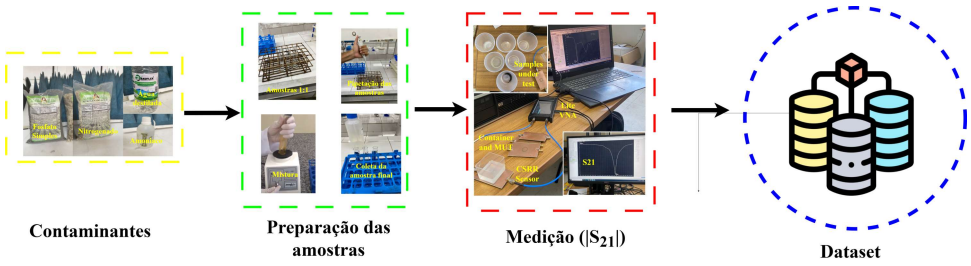


Figura 5.34: Setup de preparação e medição das amostras. Fonte: Autor, 2025.

5.4.1.2 Montagem do Dataset

A partir das curvas de transmissão $|S_{21}|$, foram extraídas informações sobre a frequência de ressonância, largura de banda, fase e profundidade do notch, além da estimativa da permissividade real. Os dados coletados foram organizados em um dataset balanceado, posteriormente utilizado para os processos de regressão e classificação no âmbito do aprendizado de máquina supervisionado. Como podemos ver abaixo.

	A	B	C	D	E	F	G	H
1	Nr	Ar	Pha	delta_Nr	delta_A	delta_pha	er	Class
2	1,4785	-20,51	147,55	100,2751	-4,49	12,24	81,03	W
3	1,6807	-33,57	148,75	100,5503	8,57	11,32	78,81	F
4	1,5939	-25,17	150,77	101,4153	0,17	10,41	79,65	N
5	1,6503	-31,75	148,41	99,23919	6,75	10,57	79,05	N

Figura 5.35: Estrutura do Dataset. Fonte: Autor, 2025.

O dataset construído a partir das medições experimentais contém atributos extraídos diretamente da resposta em frequência dos sensores de micro-ondas. A variável N_r representa a frequência de ressonância do notch (em GHz), enquanto A_r corresponde à amplitude mínima de transmissão associada a essa ressonância (em dB) a variável *Pha* representa a fase na frequência de ressonância. As variáveis ΔN_r e ΔA e Δpha indicam, respectivamente, as variações de frequência, de amplitude e de fase em relação à condição de referência do sensor no vazio, permitindo quantificar deslocamentos induzidos pelas propriedades dielétricas das amostras. O parâmetro ε_r representa a permissividade relativa real do material sob teste, estimada pelo os sensores deste estudo. Por fim, a variável *Class* identifica a categoria da amostra analisada, sendo N para soluções de nitrato, F para soluções de fosfato e W para água destilada. Esse conjunto de características foi organizado em formato tabular, constituindo a base de dados utilizada nos modelos de aprendizado de máquina para predição da permissividade e classificação dos contaminantes em água.

5.4.2 Etapa de pré-processamento dos dados

Após a recolha do conjunto de dados, contendo as medições experimentais referentes às três classes de amostras (nitrato, fosfato e água destilada), foi realizada uma etapa de pré-processamento com o objetivo de preparar os dados para os algoritmos de aprendizado de máquina. O dataset final foi composto por 300 amostras, sendo 100 registros para cada classe de contaminante, em que cada linha representa uma medição independente com seus respectivos atributos: frequência de ressonância (N_r), amplitude do notch (A_r), (Pha) Fase, variação de frequência em relação ao sensor em vazio (ΔN_r), variação de amplitude (ΔA),(Δpha) variação da fase, permissividade relativa real (ε_r) e a classe de identificação ($Class$).

A etapa de classificação dos contaminantes em água foi realizada empregando técnicas de aprendizado supervisionado baseadas em Árvore de Decisão e Máquinas de Vetores de Suporte (SVM). Para aumentar a precisão na identificação das amostras, adotou-se uma estratégia hierárquica de classificação utilizando dois modelos SVM em sequência. No primeiro modelo (SVM1), as amostras foram agrupadas em duas categorias principais: (i) água destilada, e (ii) mistura contendo água destilada com fosfato e nitrato. Em seguida, as amostras classificadas no segundo grupo foram processadas por um segundo modelo (SVM2), responsável por separar especificamente as classes de fosfato e nitrato. Essa abordagem em cascata permitiu uma categorização mais eficiente e reduziu ambiguidades entre classes com propriedades dielétricas semelhantes, ao mesmo tempo em que explorou a robustez das árvores de decisão para análise de relevância dos atributos e a capacidade das SVMs de maximizar margens de separação entre os grupos.

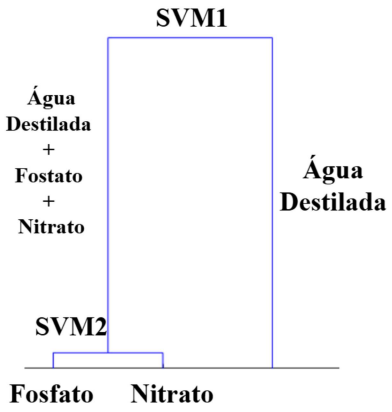


Figura 5.36: Dendograma da classificação baseada em árvore de decisão. Fonte: Autor, 2025.

O pré-processamento foi implementado em linguagem Python por meio da biblioteca *scikit-learn*, contemplando três etapas principais: (i) análise de valores atípicos, (ii) tratamento de dados ausentes e (iii) padronização dos atributos. Na primeira etapa, a detecção de valores atípicos foi realizada utilizando a técnica de *Box-Plot*, em que os limites inferior e superior foram definidos a partir do intervalo interquartil (IQR). Amostras com

valores inferiores a $Q_1 - 1,5 \times IQR$ ou superiores a $Q_3 + 1,5 \times IQR$ foram consideradas potenciais outliers.

Sensor 1

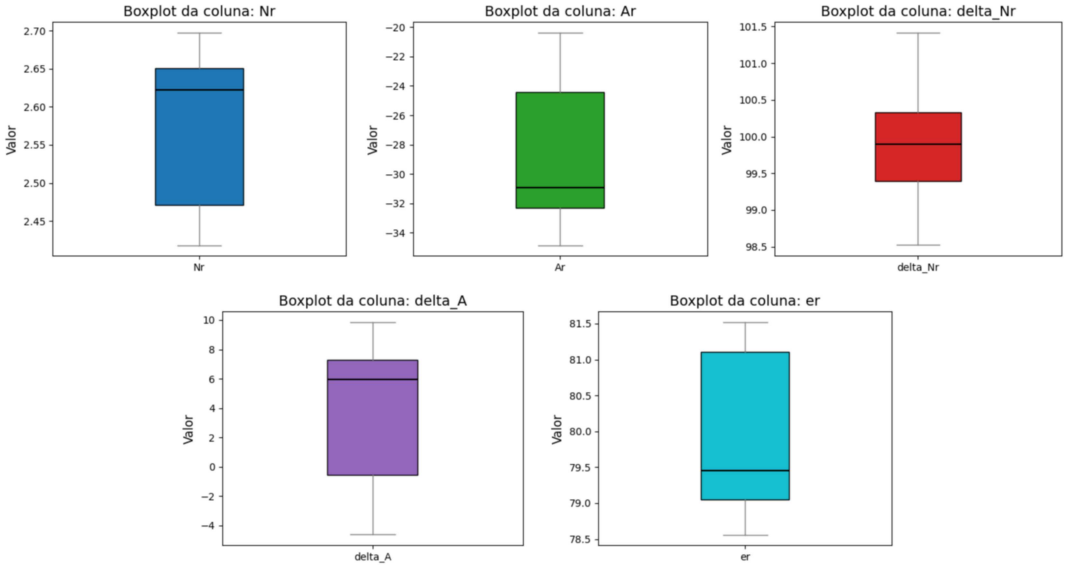


Figura 5.37: Box-plots dos parâmetros do dataset para o sensor 1. Fonte: Autor, 2025.

Sensor 2

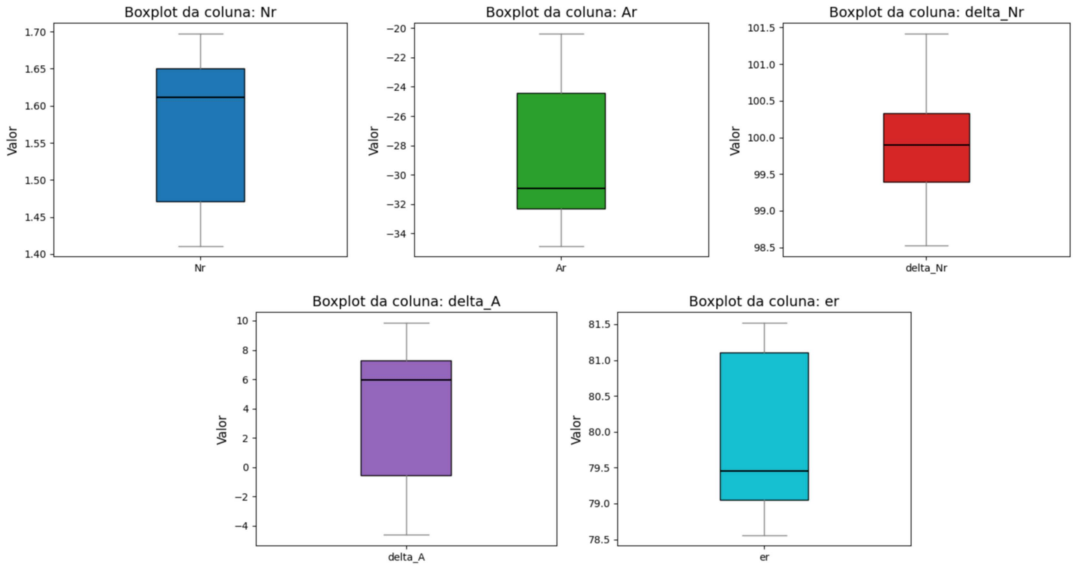


Figura 5.38: Box-plots dos parâmetros do dataset para o sensor 2. Fonte: Autor, 2025.

Sensor 3

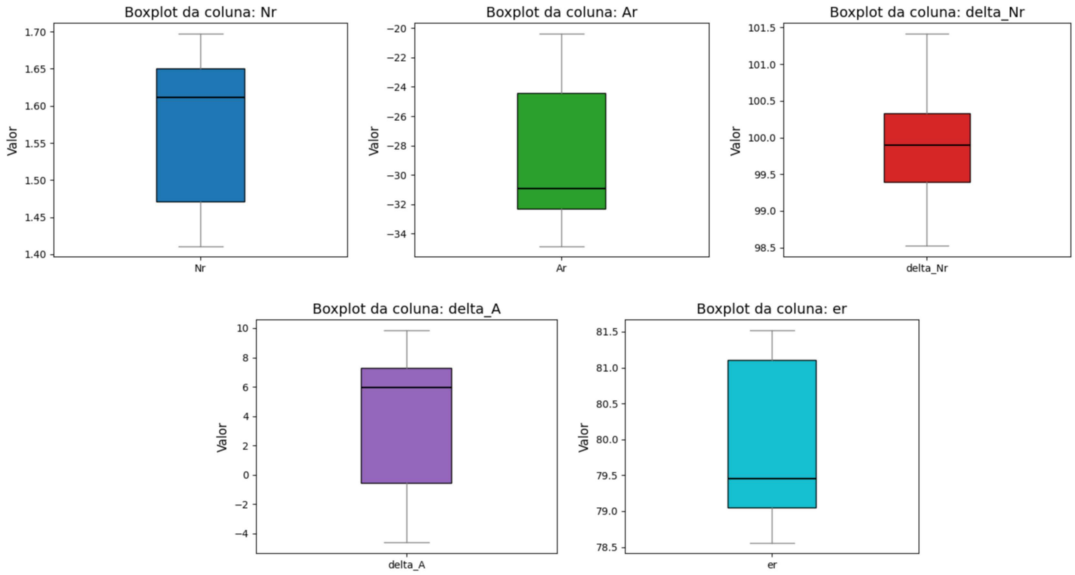


Figura 5.39: Box-plots dos parâmetros do dataset para o sensor 3. Fonte: Autor, 2025.

Sensor 4

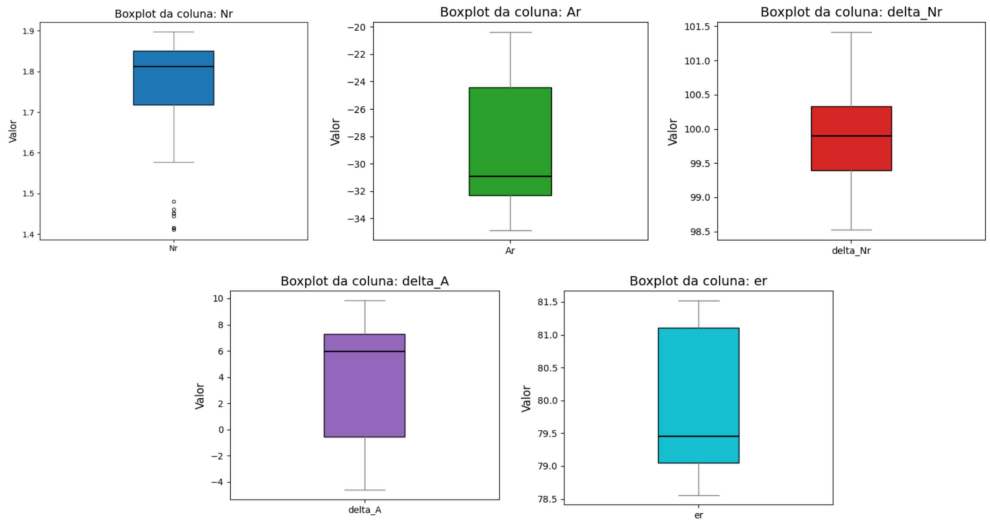


Figura 5.40: Box-plots dos parâmetros do dataset para o sensor 4. Fonte: Autor, 2025.

Esses pontos foram analisados individualmente e, quando comprovada a inconsistência em relação ao contexto experimental, foram removidos a fim de evitar vieses nos

modelos. Podemos notar as 6 valores de frequências de ressonância (Nr) sensor 4 apresentam possíveis outliers, dessa forma, esses dados foram retirados do dataset final antes de avaliar os modelos para o aprendizado de máquina e não comprometer analise definitiva.

Na segunda etapa, verificou-se a ocorrência de dados ausentes em alguns parâmetros; nesses casos, a técnica de imputação pela mediana foi adotada, pois se mostrou mais adequada para evitar distorções que poderiam ocorrer se fossem utilizados valores médios em distribuições assimétricas. Por fim, na terceira etapa, realizou-se a padronização dos atributos contínuos, como a frequência de ressonância, a magnitude de transmissão $|S_{21}|$ e a permissividade relativa real. Para isso, empregou-se o método *StandardScaler*, que consiste em subtrair a média de cada variável e dividi-la pelo respectivo desvio padrão, resultando em variáveis normalizadas com média zero e variância unitária. Esse processo é essencial para garantir que todos os atributos contribuam de maneira equilibrada durante o treinamento, especialmente em algoritmos sensíveis à escala dos dados, como Support Vector Machines (SVM) e regressões lineares.

Após o pré-processamento, o conjunto de dados foi dividido em subconjuntos de treino e teste, de forma a possibilitar a avaliação independente dos modelos. A divisão foi realizada na proporção de (80% ou 240 amostra/sensor) dos dados destinados ao treinamento e (20% ou 60 amostra/sensor) reservados para o teste, assegurando que a validação dos modelos de aprendizado de máquina fosse conduzida de maneira justa e reprodutível. Dessa forma, o dataset obtido não apenas contém informações representativas das propriedades dielétricas dos contaminantes em estudo, mas também foi tratado e normalizado para maximizar a eficiência dos métodos de classificação e regressão empregados neste trabalho.

5.4.3 Regressão

5.4.3.1 Aplicação dos modelos de aprendizado de máquina

Depois de escolher e padronizar o conjunto de dados, aplicamos diferentes modelos de regressão para treinar os algoritmos de aprendizagem automática. Na aprendizagem supervisionada, a regressão é utilizada para prever valores numéricos contínuos, enquanto a classificação prevê categorias discretas. Nosso estudo foca no desenvolvimento de modelos capazes de prever a concentração de contaminantes, como fosfato e nitrato, em soluções aquosas tratadas.

Foi realizada uma validação pela separação do dataset em 20% para testagem e 80% para treinamendo dos modelos. O desempenho dos modelos foi avaliado por métricas de regressão, como R^2, MSE (Mean Squared Error), MAE (Mean Absolute Error) e visualizações de ajuste por gráfico de dispersão entre valores reais e previstos.

Os modelos de regressão utilizados neste estudo são:

- **Regressão Linear (*Linear Regression*)**: Este modelo assume uma relação linear entre as variáveis independentes e a variável dependente, ajustando uma linha reta que minimiza o erro quadrático médio entre os valores observados e previstos.
- **Regressão Polinomial (*Polynomial Regression*)**: Extensão da regressão linear que permite modelar relações não-lineares elevando as variáveis independentes a po-

tências superiores. Foram utilizadas polinômios de **segunda e terceira ordem** para capturar relações mais complexas nos dados.

- **Árvore de Regressão (*Decision Tree Regressor*)**: Modelo que segmenta iterativamente os dados em regiões homogêneas de saída, criando uma árvore de decisões baseada nos valores das variáveis. Ideal para capturar relações não-lineares e interações complexas.
- **Random Forest Regressor**: Conjunto de múltiplas árvores de regressão que agregam suas previsões por média, aumentando a robustez e reduzindo o overfitting. Neste estudo, foi utilizado um número de **100 árvores**.
- **Support Vector Regressor (SVR)**: Modelo baseado em SVM que encontra a função que melhor aproxima os valores reais dentro de uma margem de tolerância. Foram utilizados três tipos de kernel: **linear**, **polinomial de terceira ordem** e **RBF** (radial basis function), para capturar diferentes padrões de relação entre variáveis.
- **Perceptron Multicamadas para Regressão (*Multi-Layer Perceptron Regressor - MPLR*)**: Rede neural de múltiplas camadas que aprende relações complexas entre variáveis de entrada e saída contínua. A arquitetura usada considerou uma camada oculta com **5 neurônios**.
- **Stochastic Gradient Descent Regressor (SGDR)**: Algoritmo de otimização iterativa que ajusta os pesos do modelo para minimizar a função de custo, eficiente para grandes conjuntos de dados e regressões lineares.

5.4.4 Classificação

5.4.4.1 Aplicação dos modelos de aprendizado de máquina

Depois de escolher e padronizar o conjunto de dados, usamos diferentes modelos de classificação para treinar a aprendizagem automática. Conforme previsto pelo modelo de aprendizagem supervisionada, a classificação e a regressão são categorizadas como formas de aprendizagem supervisionada para a aprendizagem automática, com a regressão a prever valores numéricos contínuos nas saídas, enquanto a classificação prevê categorias ou classes às quais um item pertence. O nosso estudo centra-se no desenvolvimento de um modelo de classificação capaz de prever contaminantes, como fosfato e nitrato, em soluções aquosas tratadas. Foi realizada uma validação cruzada utilizando o modelo Leave-One-Out (LOO), Stratified K-Fold (SKF), Repeated Stratified K-Fold (RSKF) e os resultados foram apresentados pelas métricas de desempenho que foram analisadas através da matriz de confusão gerada por cada modelo, e os valores de precisão, exatidão, F1-score e recall serão gerados para cada modelo, além da curva ROC e do valor sob esta curva.

Os modelos de classificação utilizados neste estudo são:

- **Regressão Logística (*Logistic Regression*)**: Este é um modelo de classificação de *machine learning* (ML) simples que utiliza a função logística sigmoide para classificar a classe à qual a substância pertence. É indicado quando há uma relação linear entre as variáveis.

- **Árvore de Decisão (*Decision Tree*)**: Este é um modelo de ML que organiza decisões na forma de uma árvore, com perguntas simples para definir a qual classe a substância de teste pertence. Em nosso estudo, o critério de **entropia** foi utilizado para a classificação.
- **Random Forest**: Este é um conjunto de várias árvores de decisão que votam entre si para decidir a classe da substância em estudo. É mais robusto e preciso do que uma única árvore. Em nosso estudo, utilizamos um número de **20 estimadores** e o critério de **entropia** para a classificação.
- **K-Nearest Neighbors (KNN)**: Este é um modelo de ML que classifica a amostra em estudo prevendo a variável dependente alvo para iniciar um dado de entrada, utilizando a **distância**, em um número K, dos dados mais próximos (*vizinhos*). Em nosso estudo, foi considerado um número de **5 vizinhos**.
- **Gaussian Naive Bayes (GNB)**: Este modelo assume que as variáveis na substância são independentes e seguem uma **distribuição normal** (gaussiana). Ele classifica com base nas probabilidades de cada classe e escolhe a classe com o maior valor de probabilidade.
- **Perceptron Multicamadas (*Multi-Layer Perceptron* - MLP)**: Esta é uma **rede neural** de múltiplas camadas que aprende padrões complexos. Ela utiliza essas conexões para decidir a classe da substância. Uma camada oculta com **5 neurônios** foi considerada para a abordagem MLP, a fim de obter o melhor desempenho de classificação correspondente.
- **Decision Support Vector Machine (SVM)**: Este é um modelo de ML que mapeia a localização dos dados e cria **margens** entre a categoria necessária e estas linhas, ou **hiperplanos** que separam as classes com a maior margem possível. Em nosso caso, utilizamos uma **função de kernel radial**.

5.4.5 Resultados alcançados

5.4.5.1 Regressão

Utilizando todos os modelos de aprendizado de maquina proposto neste estudo de regressão da permissividade relativa real em função da frequência de ressonância (em GHz) obtida na montagem do dataset, obtemos os resultados das curvas de regressão (em azul) comparadas aos dados reais (em vermelho), além dos resultados dos coeficiente R^2, MSE e MAE. Podemos o resultados para o sensores abaixo.

Sensor 1

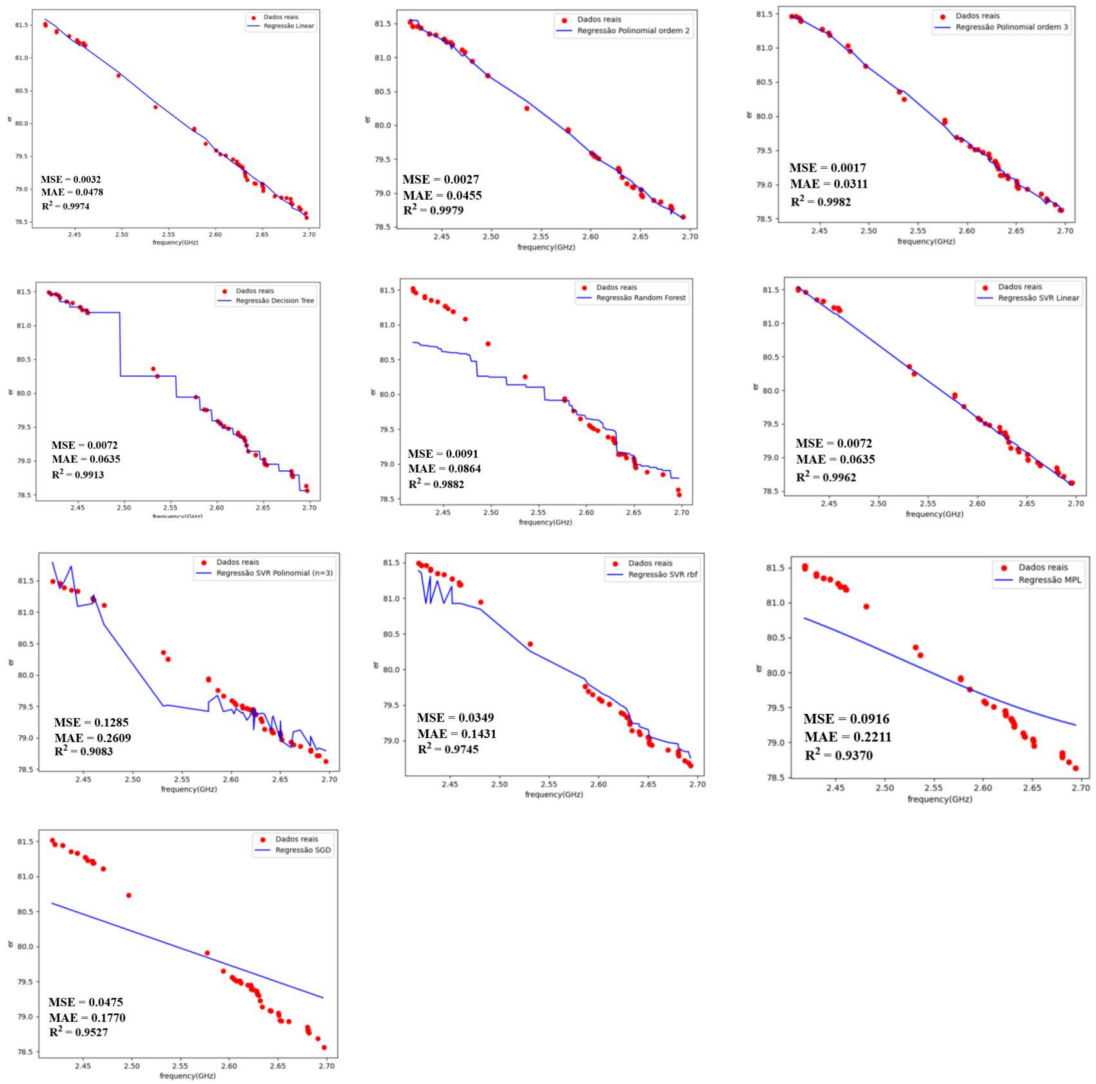


Figura 5.41: Comparação da curva de regressão para os diversos modelos estudados e os pontos reais obtidos para permissividade relativa em função da frequência sensor 1. Fonte: Autor, 2025.

É possível notar que o modelo que mais se aproxima são as regressões lineares e polinomiais, como esperado já que a curva se comporta como um polinômio, obtendo o R^2 acima de 0.99.

Sensor 2

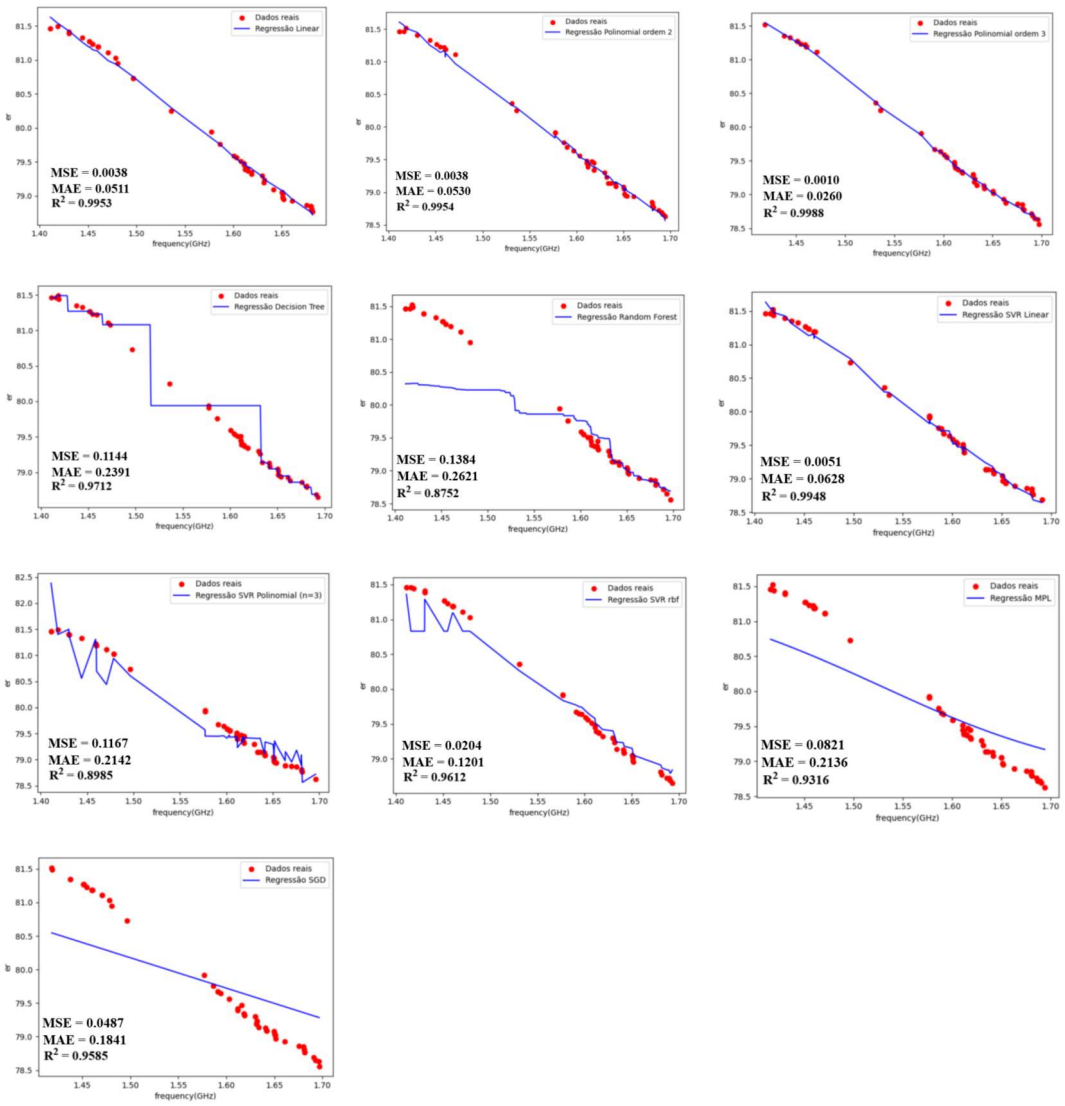


Figura 5.42: Comparação da curva de regressão para os diversos modelos estudados e os pontos reais obtidos para permissividade relativa em função da frequência para o sensor 2. Fonte: Autor, 2025.

É possível notar que o modelo que mais se aproxima são as regressões lineares e polinomiais, como esperado já que a curva se comporta como um polinômio, obtendo o R^2 acima de 0.99.

Sensor 3

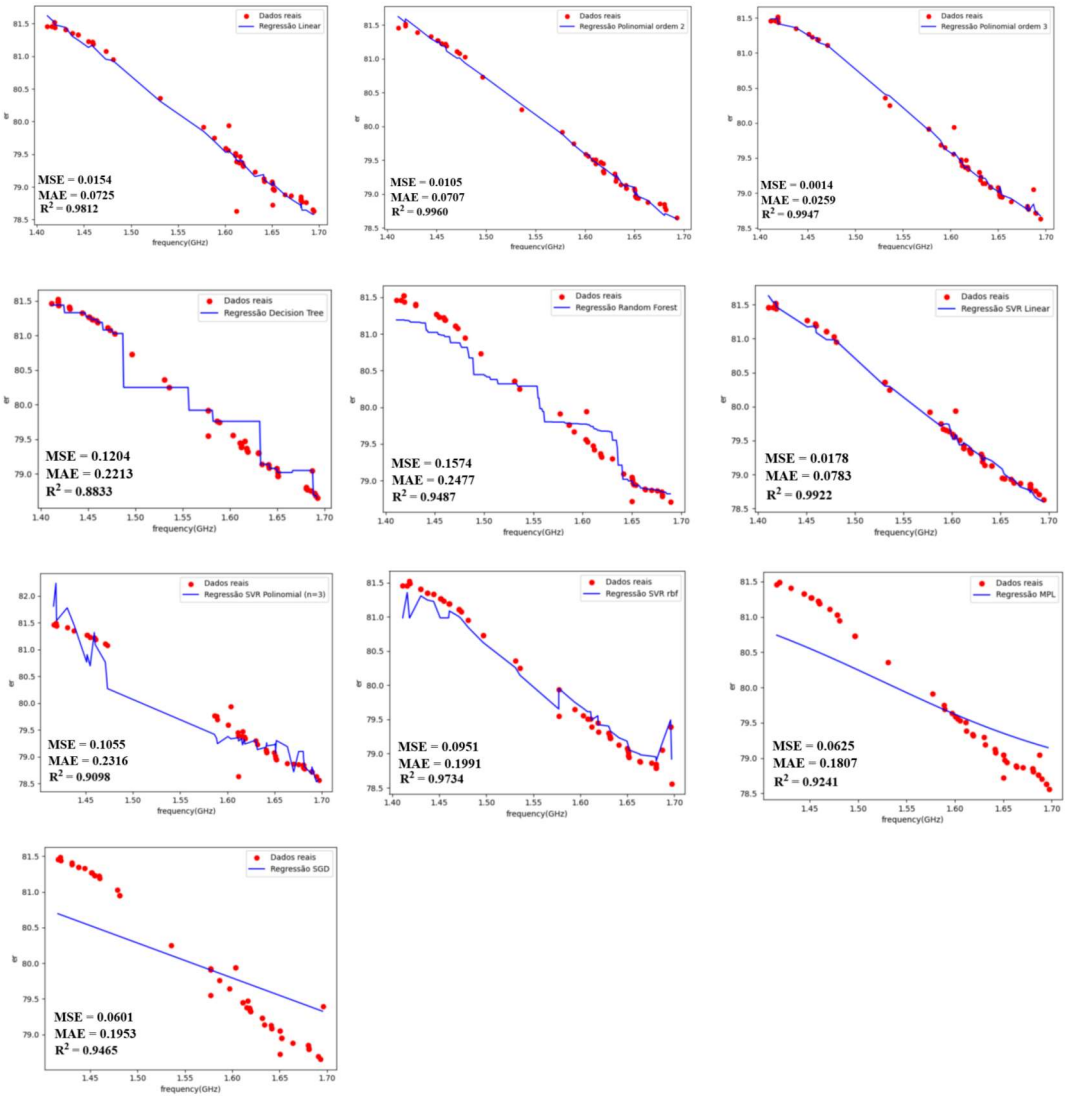


Figura 5.43: Comparação da curva de regressão para os diversos modelos estudados e os pontos reais obtidos para permissividade relativa em função da frequência para o sensor 3. Fonte: Autor, 2025.

É possível notar que o modelo que mais se aproxima são as regressões lineares e polinomiais, como esperado já que a curva se comporta como um polinômio, obtendo o R^2 acima de 0.99.

Sensor 4

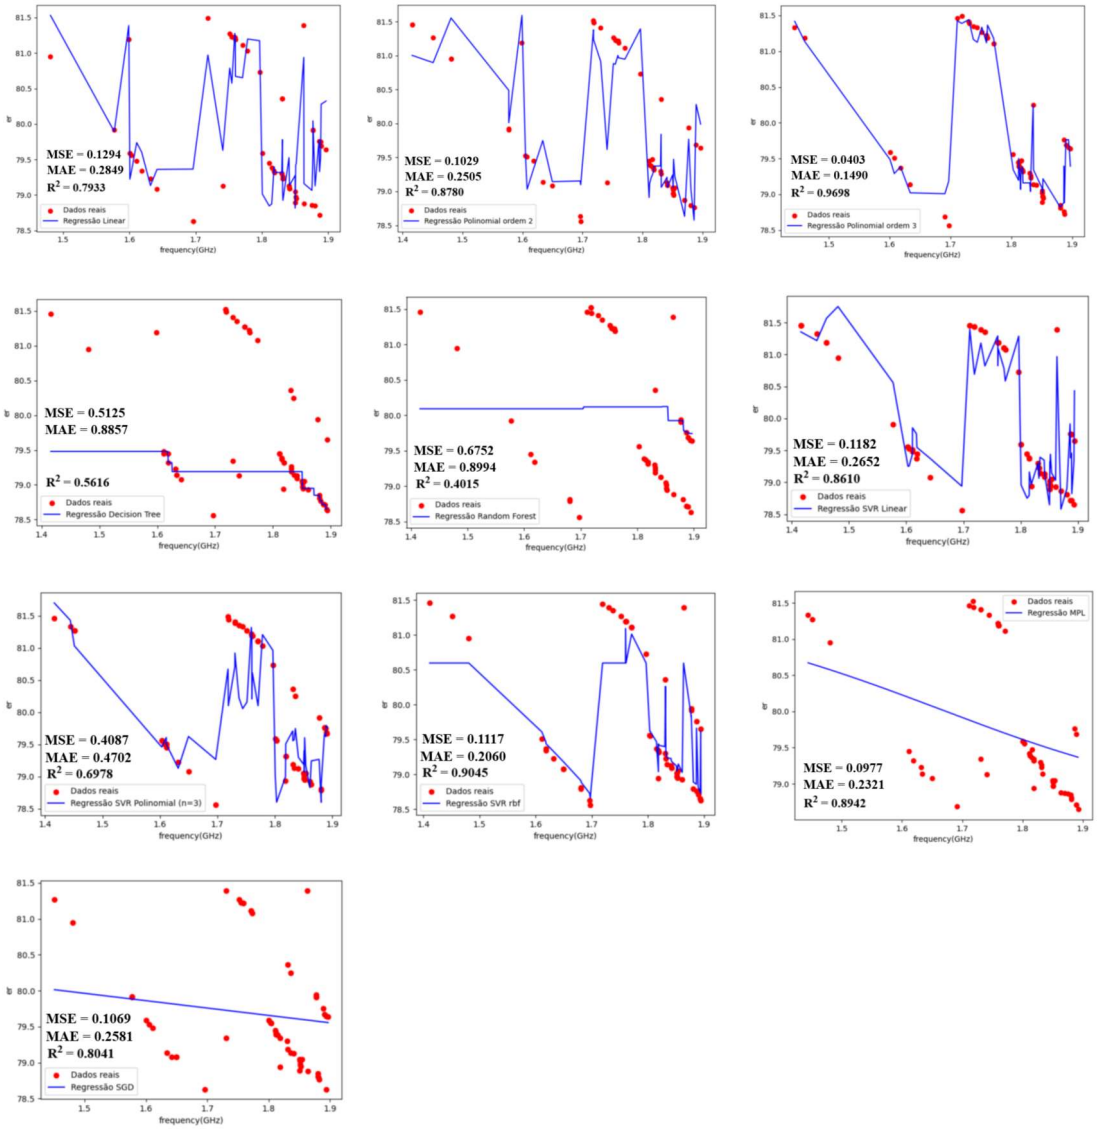


Figura 5.44: Comparação da curva de regressão para os diversos modelos estudados e os pontos reais obtidos para permissividade relativa em função da frequência para o sensor 4. Fonte: Autor, 2025.

É possível notar que o modelo que mais se aproxima são as regressões lineares, polinomiais, SVR, como esperado já que a curva se comporta como um polinômio, obtendo o R^2 acima de 0.90.

5.4.5.2 Classificação

Validação por separação 20% das amostras para testagem e 80% para treino

Sensor 1

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

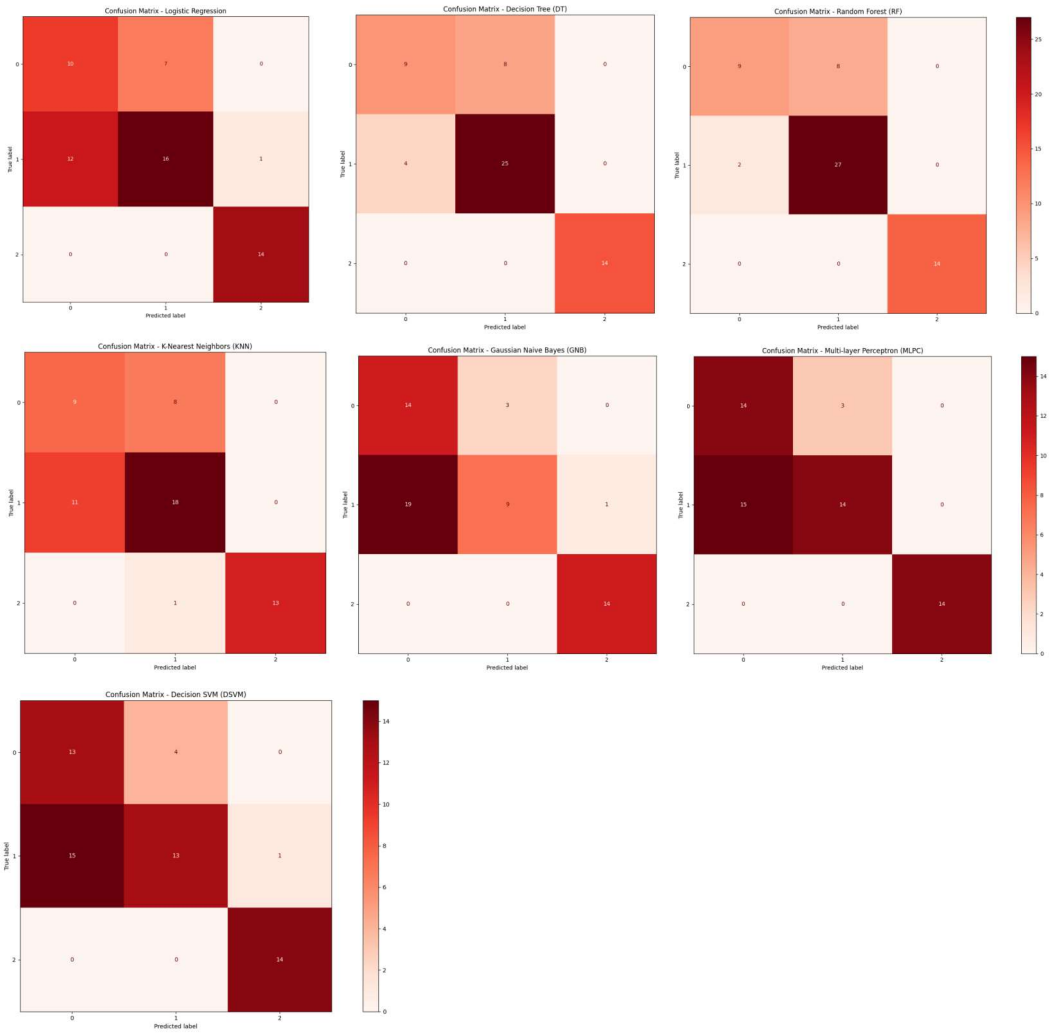


Figura 5.45: Matriz de confusão validação por separação das amostras (20:80) para sensor 1 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.9 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão,

Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $83,33\%$, $83,80\%$, $0,8333$ e $0,8323$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	**Accuracy**	**Precision**	**Recall**	**F1-Score**
Logistic Regression	0.6667	0.6828	0.6667	0.6680
Decision Tree (DT)	0.8000	0.7956	0.8000	0.7931
Random Forest (RF)	0.8333	0.8380	0.8333	0.8323
K-Nearest Neighbors (KNN)	0.6667	0.6831	0.6667	0.6732
Gaussian Naive Bayes (GNB)	0.6167	0.7005	0.6167	0.5961
Multi-layer Perceptron (MLPC)	0.7000	0.7682	0.7000	0.7000
Decision SVM (DSVM)	0.6667	0.7189	0.6667	0.6622

Tabela 5.9: Resultados obtidos para o sensor 1 da classificação por split (20% : 80%) em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que os modelos Decision Tree e Random Forest tiveram os melhores desempenhos com uma AUC de 0,90.

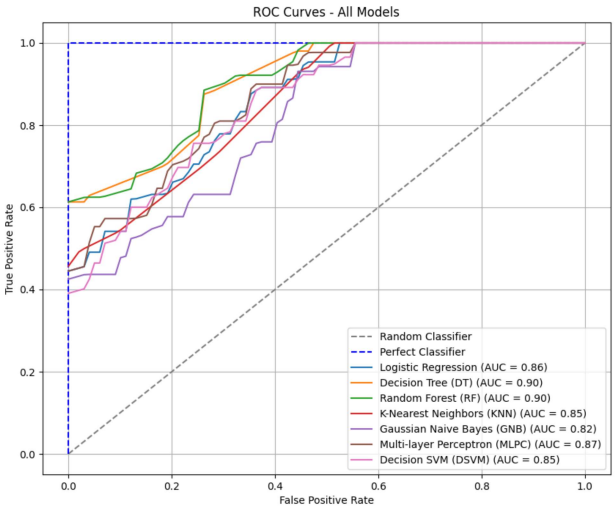


Figura 5.46: Curva ROC da validação por separação das amostras (20:80) para sensor 1 cada modelo classificador. Fonte: Autor, 2025.

Sensor 2

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

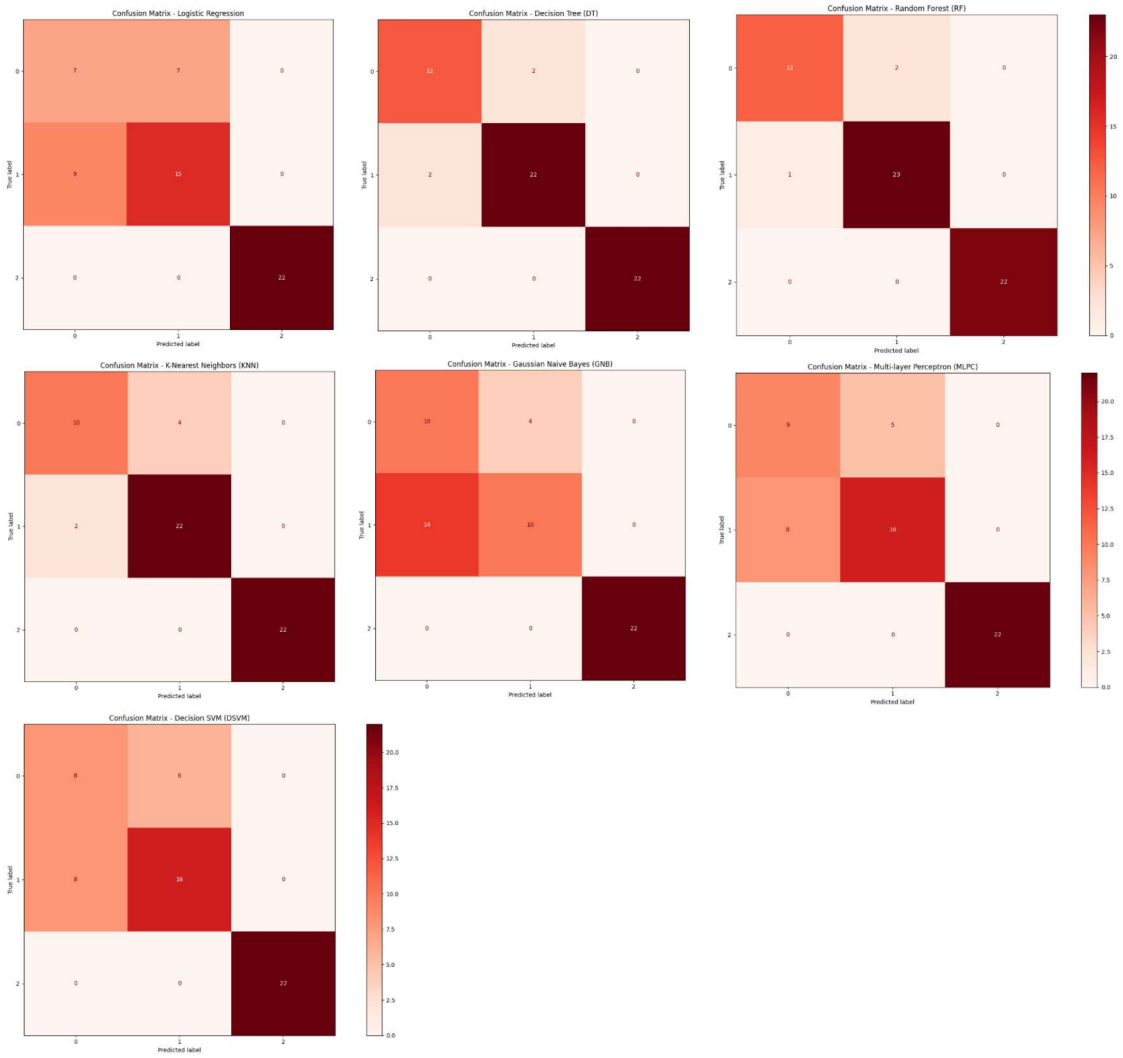


Figura 5.47: Matriz de confusão validação por separação das amostras (20:80) para sensor 2 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.10 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $95,00\%$, $95,01\%$, $0,9500$ e $0,9496$, respectivamente,

conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7333	0.7415	0.7333	0.7364
Decision Tree (DT)	0.9333	0.9333	0.9333	0.9333
Random Forest (RF)	0.9500	0.9501	0.9500	0.9496
K-Nearest Neighbors (KNN)	0.9000	0.9096	0.9000	0.8982
Gaussian Naive Bayes (GNB)	0.7000	0.7496	0.7000	0.7000
Multi-layer Perceptron (MLPC)	0.7833	0.7950	0.7833	0.7866
Decision SVM (DSVM)	0.7667	0.7742	0.7667	0.7694

Tabela 5.10: Resultados obtidos para o sensor 2 da classificação por split (20% : 80%) em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que os modelos Decision Tree e Random Forest tiveram os melhores desempenhos com uma AUC de 0,98.

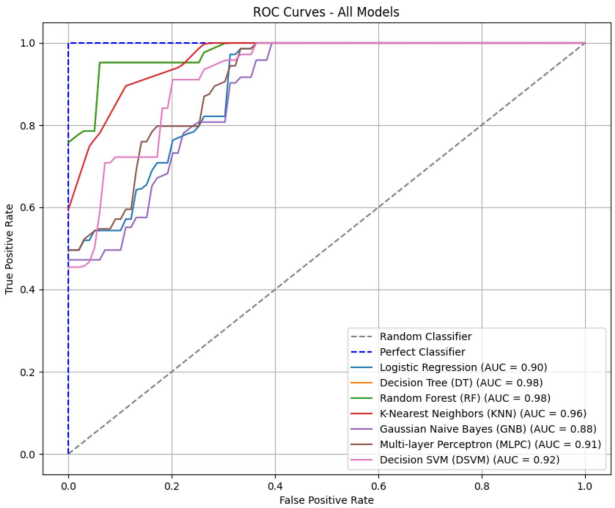


Figura 5.48: Curva ROC da validação por separação das amostras (20:80) para sensor 2 cada modelo classificador. Fonte: Autor, 2025.

Sensor 3

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legen-

das 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

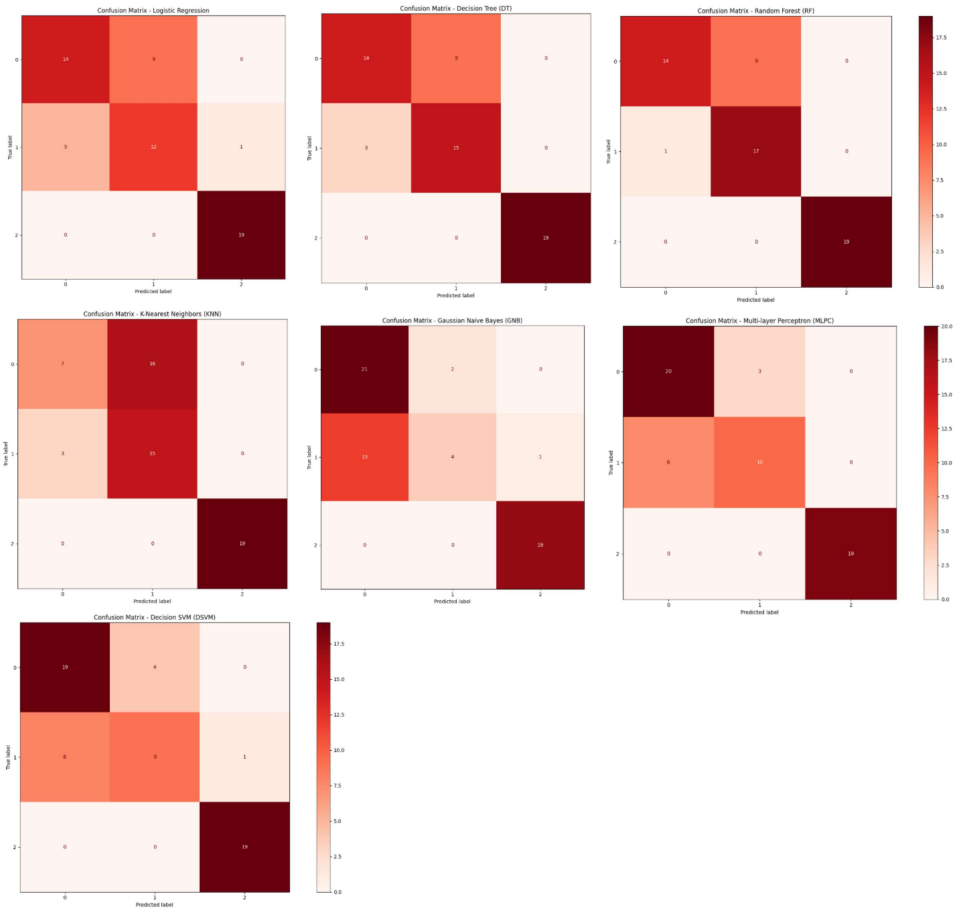


Figura 5.49: Matriz de confusão validação por separação das amostras (20:80) para sensor 3 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.11 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $83,33\%$, $87,06\%$, $0,8333$ e $0,8390$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7500	0.7547	0.7500	0.7487
Decision Tree (DT)	0.8000	0.8199	0.8000	0.7993
Random Forest (RF)	0.8333	0.8706	0.8333	0.8390
K-Nearest Neighbors (KNN)	0.6833	0.7302	0.6833	0.6630
Gaussian Naive Bayes (GNB)	0.7333	0.7376	0.7333	0.6910
Multi-layer Perceptron (MLPC)	0.8167	0.8212	0.8167	0.8109
Decision SVM (DSVM)	0.7833	0.7783	0.7833	0.7741

Tabela 5.11: Resultados obtidos para o sensor 3 da classificação por split (20% : 80%) em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que o modelo Random Forest teve o melhor desempenho com uma AUC de 0,93.

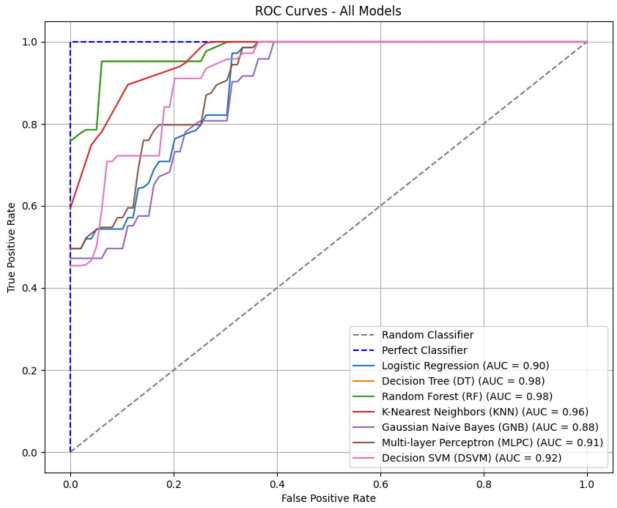


Figura 5.50: Curva ROC da validação por separação das amostras (20:80) para sensor 3 cada modelo classificador. Fonte: Autor, 2025.

Sensor 4

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

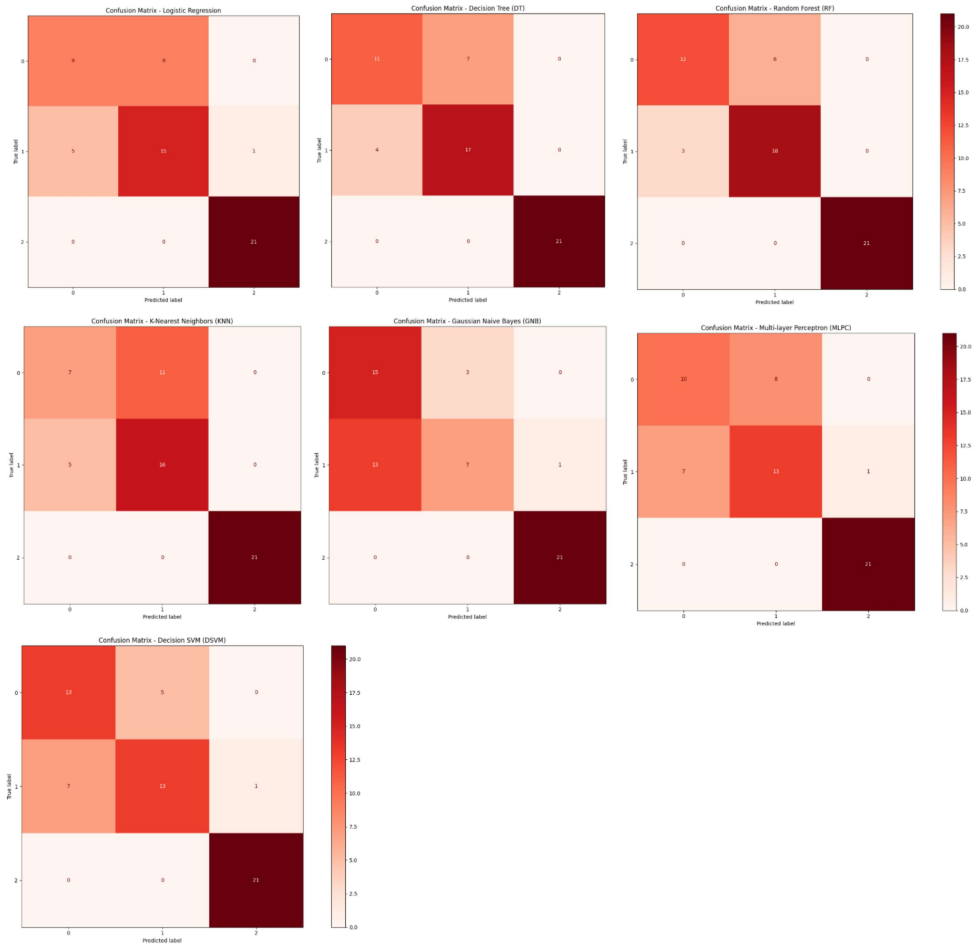


Figura 5.51: Matriz de confusão validação por separação das amostras (20:80) para sensor 4 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.12 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $85,00\%$, $85,25\%$, $0,8500$ e $0,8482$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7500	0.7457	0.7500	0.7439
Decision Tree (DT)	0.8167	0.8179	0.8167	0.8144
Random Forest (RF)	0.8500	0.8525	0.8500	0.8482
K-Nearest Neighbors (KNN)	0.7333	0.7324	0.7333	0.7233
Gaussian Naive Bayes (GNB)	0.7167	0.7398	0.7167	0.6956
Multi-layer Perceptron (MLPC)	0.7333	0.7272	0.7333	0.7300
Decision SVM (DSVM)	0.7833	0.7819	0.7833	0.7805

Tabela 5.12: Resultados obtidos para o sensor 4 da classificação por split (20% : 80%) em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que o modelo Random Forest teve o melhor desempenho com uma AUC de 0,92.

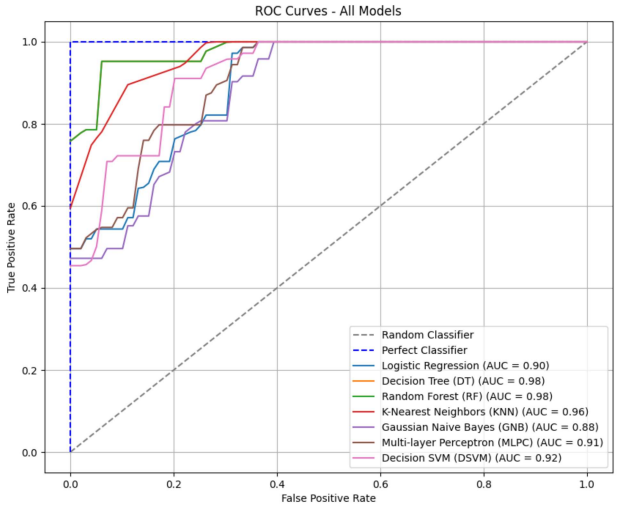


Figura 5.52: Curva ROC da validação por separação das amostras (20:80) para sensor 4 cada modelo classificador. Fonte: Autor, 2025.

Validação Leave-One-Out

Sensor 1

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legen-

das 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

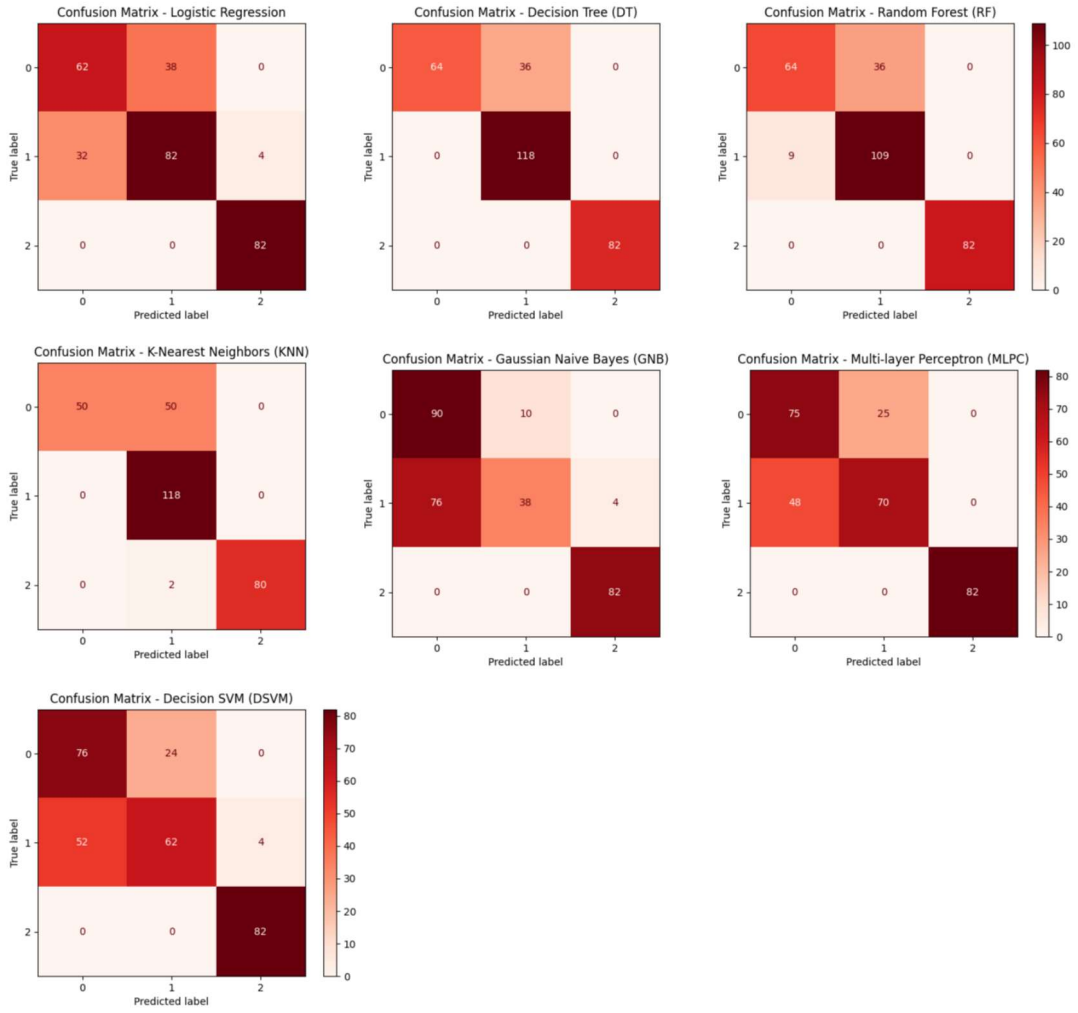


Figura 5.53: Matriz de confusão validação por LOO para sensor 1 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.13 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Decision Tree. Isso sugere que o modelo DT é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $88,00\%$, $90,81\%$, $0,8800$ e $0,8748$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7533	0.7493	0.7533	0.7509
Decision Tree (DT)	0.8800	0.9081	0.8800	0.8748
Random Forest (RF)	0.8500	0.8612	0.8500	0.8460
K-Nearest Neighbors (KNN)	0.8267	0.8797	0.8267	0.8145
Gaussian Naive Bayes (GNB)	0.7000	0.7527	0.7000	0.6725
Multi-layer Perceptron (MLPC)	0.7567	0.7664	0.7567	0.7561
Decision SVM (DSVM)	0.7333	0.7421	0.7333	0.7281

Tabela 5.13: Resultados obtidos para o sensor 1 da classificação utilizando validação LOO em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que os modelos Decision Tree e Random Forest tiveram os melhores desempenhos com uma AUC de 0,91.

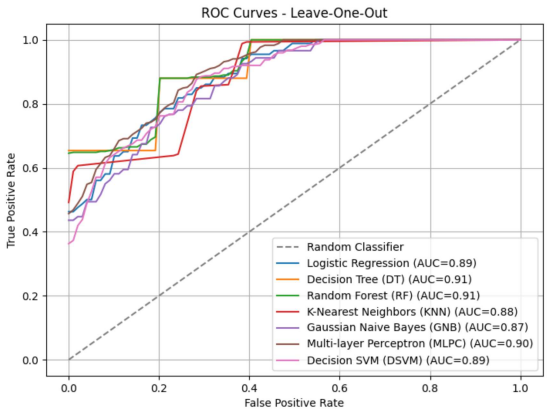


Figura 5.54: Curva ROC da validação por LOO para sensor 1 cada modelo classificador. Fonte: Autor, 2025.

Sensor 2

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

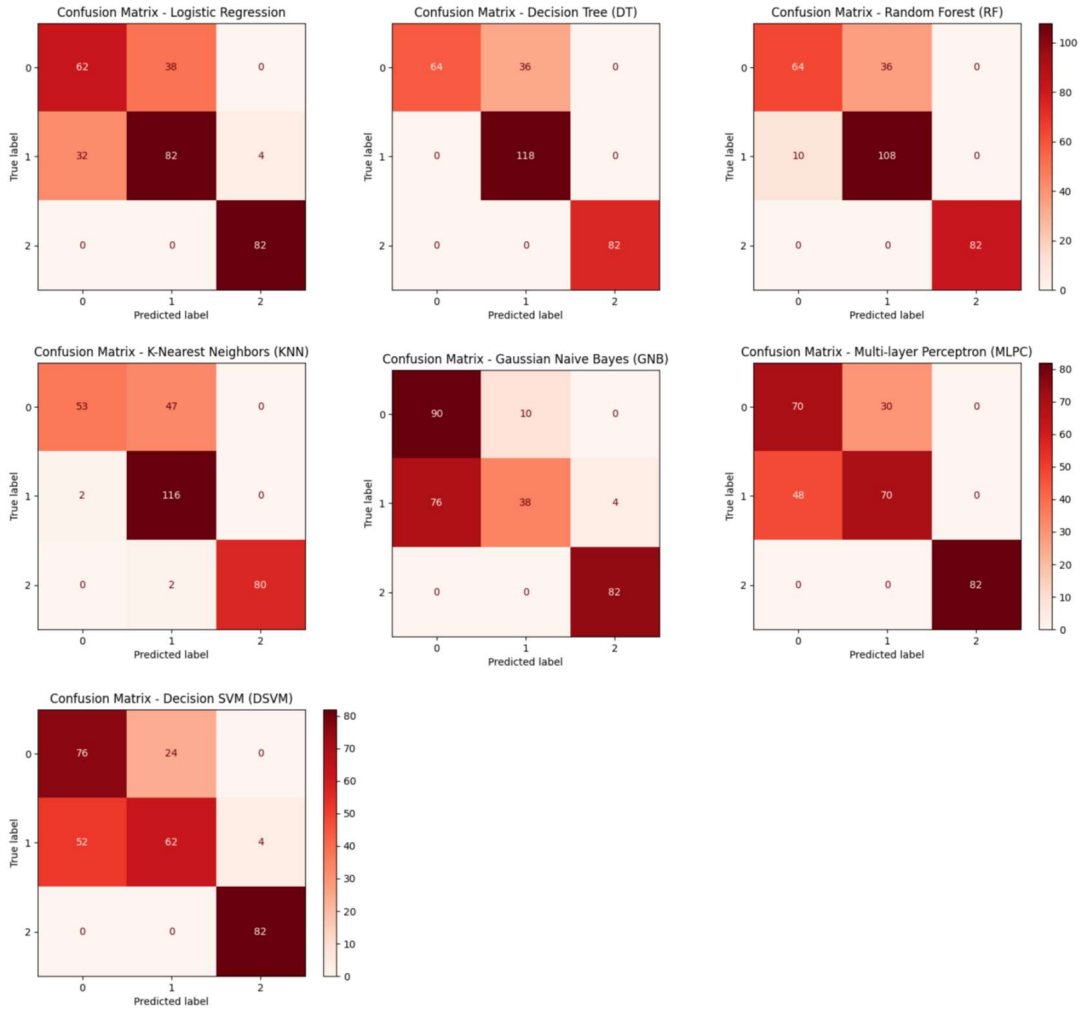


Figura 5.55: Matriz de confusão validação por LOO para sensor 2 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.14 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Decision Tree. Isso sugere que o modelo DT é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $88,00\%$, $90,81\%$, $0,8800$ e $0,8748$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7533	0.7493	0.7533	0.7509
Decision Tree (DT)	0.8800	0.9081	0.8800	0.8748
Random Forest (RF)	0.8467	0.8566	0.8467	0.8428
K-Nearest Neighbors (KNN)	0.8300	0.8711	0.8300	0.8204
Gaussian Naive Bayes (GNB)	0.7000	0.7527	0.7000	0.6725
Multi-layer Perceptron (MLPC)	0.7400	0.7464	0.7400	0.7400
Decision SVM (DSVM)	0.7333	0.7421	0.7333	0.7281

Tabela 5.14: Resultados obtidos para o sensor 2 da classificação utilizando validação LOO em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que o modelo Random Forest teve o melhor desempenho com uma AUC de 0,92.

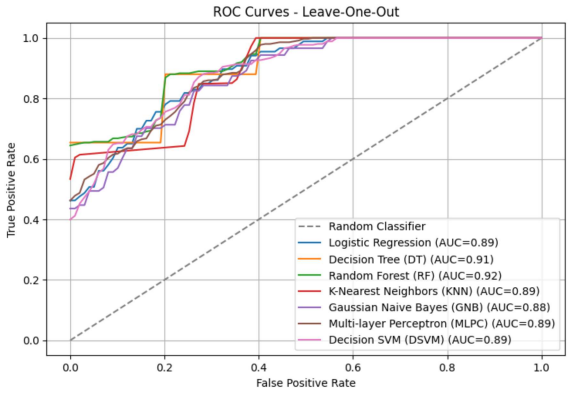


Figura 5.56: Curva ROC da validação por LOO para sensor 2 cada modelo classificador. Fonte: Autor, 2025.

Sensor 3

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

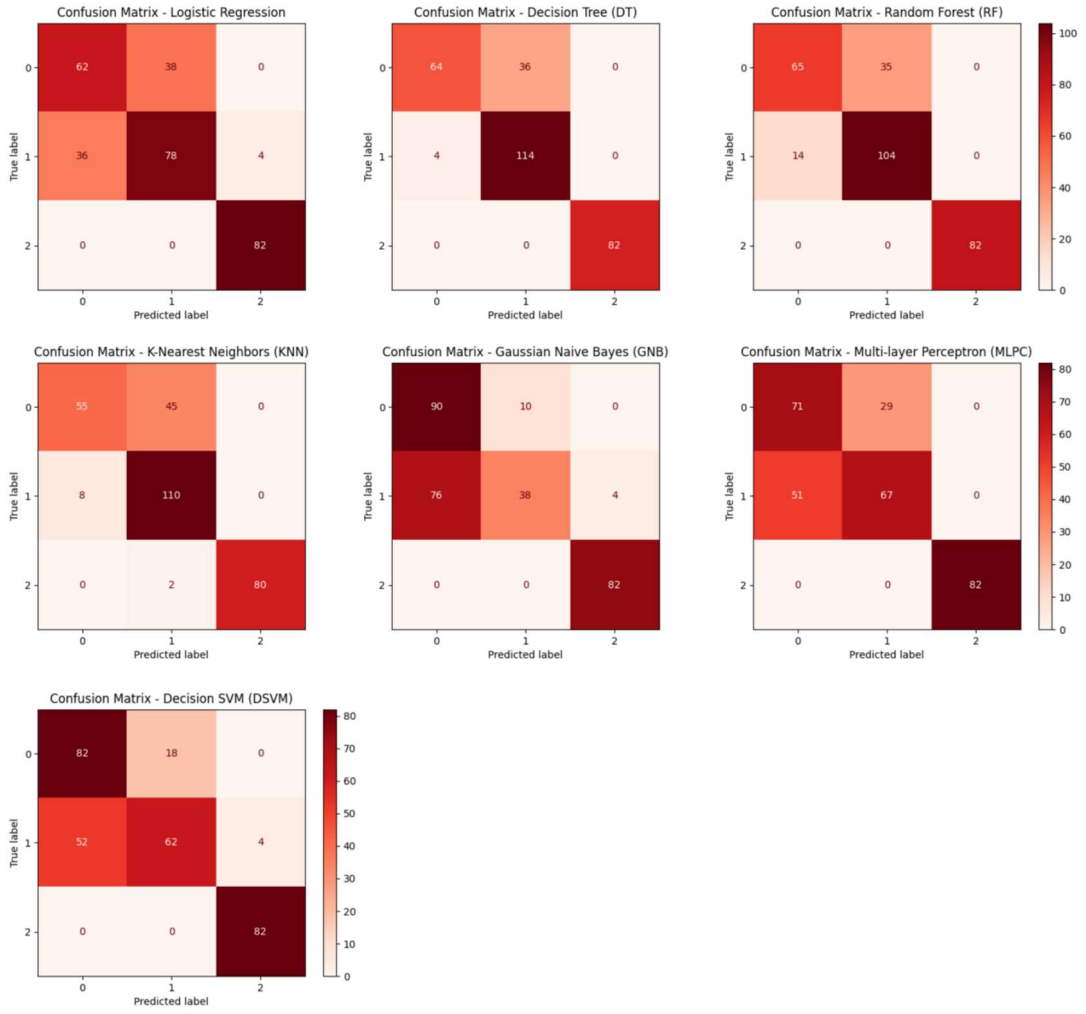


Figura 5.57: Matriz de confusão validação por LOO para sensor 3 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.15 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Decision Tree. Isso sugere que o modelo DT é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $86,67\%$, $88,60\%$, $0,8667$ e $0,8619$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7400	0.7360	0.7400	0.7378
Decision Tree (DT)	0.8667	0.8860	0.8667	0.8619
Random Forest (RF)	0.8367	0.8419	0.8367	0.8338
K-Nearest Neighbors (KNN)	0.8167	0.8399	0.8167	0.8096
Gaussian Naive Bayes (GNB)	0.7000	0.7527	0.7000	0.6725
Multi-layer Perceptron (MLPC)	0.7333	0.7418	0.7333	0.7328
Decision SVM (DSVM)	0.7533	0.7694	0.7533	0.7468

Tabela 5.15: Resultados obtidos para o sensor 3 da classificação utilizando validação LOO em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que o modelo Random Forest teve o melhor desempenho com uma AUC de 0,92.

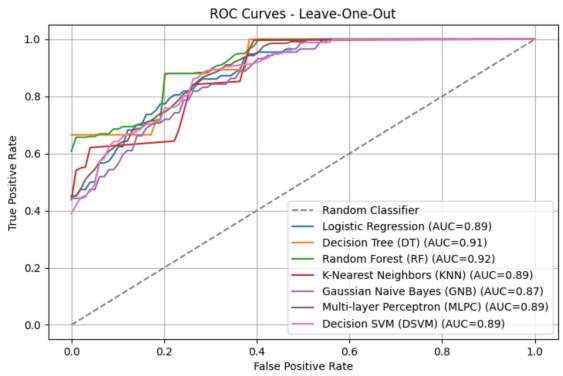


Figura 5.58: Curva ROC da validação por LOO para sensor 3 cada modelo classificador. Fonte: Autor, 2025.

Sensor 4

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

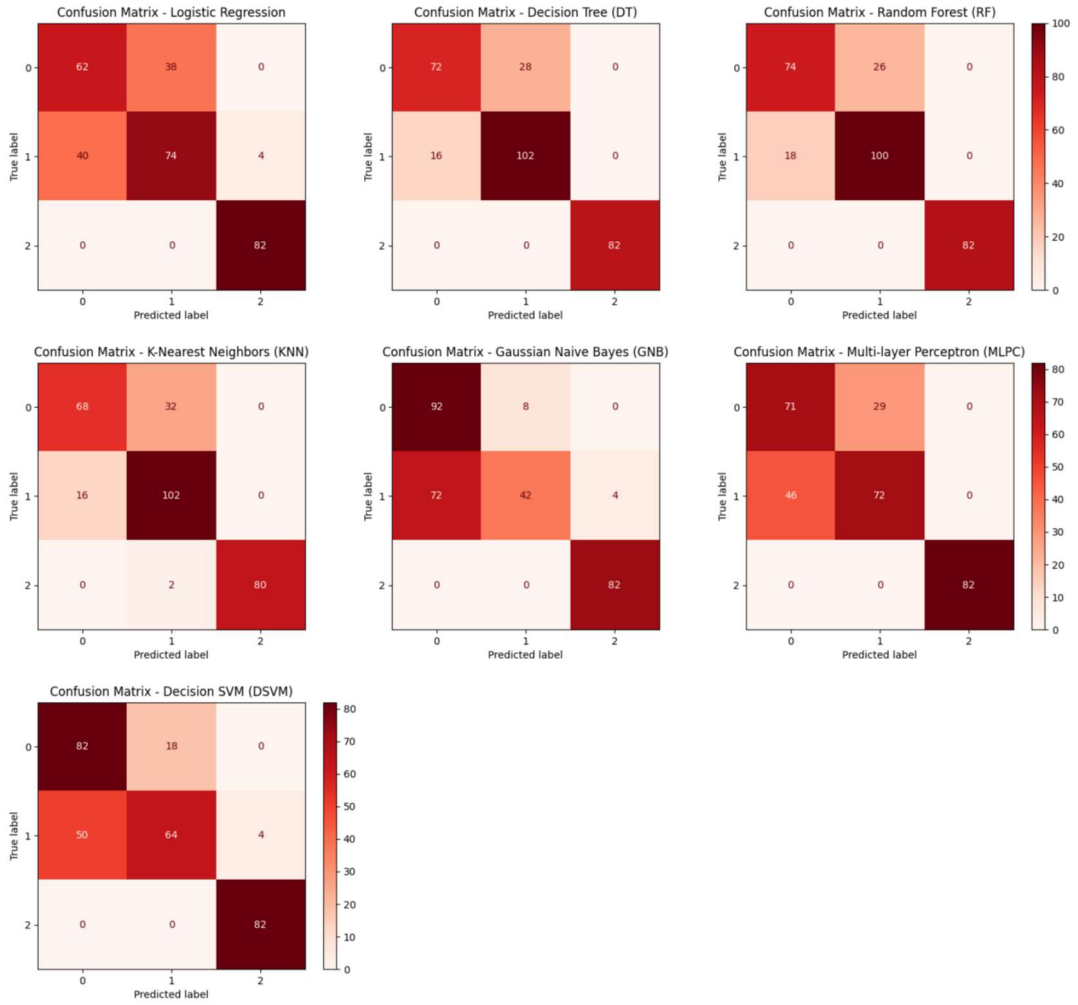


Figura 5.59: Matriz de confusão validação por LOO para sensor 4 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.16 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados nos modelos Decision Tree e Random Forest. Isso sugere que os modelos DT e RF são os melhores classificadores em comparação com as métricas utilizadas, apresentando valores ótimos de $85,33\%$, $85,47\%$, $0,8533$ e $0,8522$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7267	0.7231	0.7267	0.7245
Decision Tree (DT)	0.8533	0.8547	0.8533	0.8522
Random Forest (RF)	0.8533	0.8536	0.8533	0.8527
K-Nearest Neighbors (KNN)	0.8333	0.8382	0.8333	0.8322
Gaussian Naive Bayes (GNB)	0.7200	0.7780	0.7200	0.6958
Multi-layer Perceptron (MLPC)	0.7500	0.7560	0.7500	0.7501
Decision SVM (DSVM)	0.7600	0.7747	0.7600	0.7542

Tabela 5.16: Resultados obtidos para o sensor 4 da classificação utilizando validação LOO em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que os modelos Decision Tree e Random Forest tiveram os melhores desempenhos com uma AUC de 0,96.

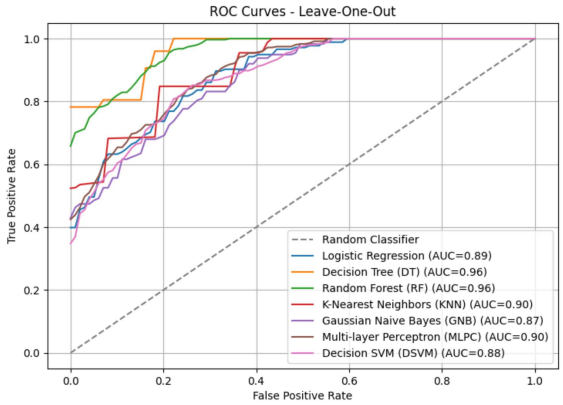


Figura 5.60: Curva ROC da validação por LOO para sensor 4 cada modelo classificador. Fonte: Autor, 2025.

Validação por Stratified K-fold (SKF)

Sensor 1

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

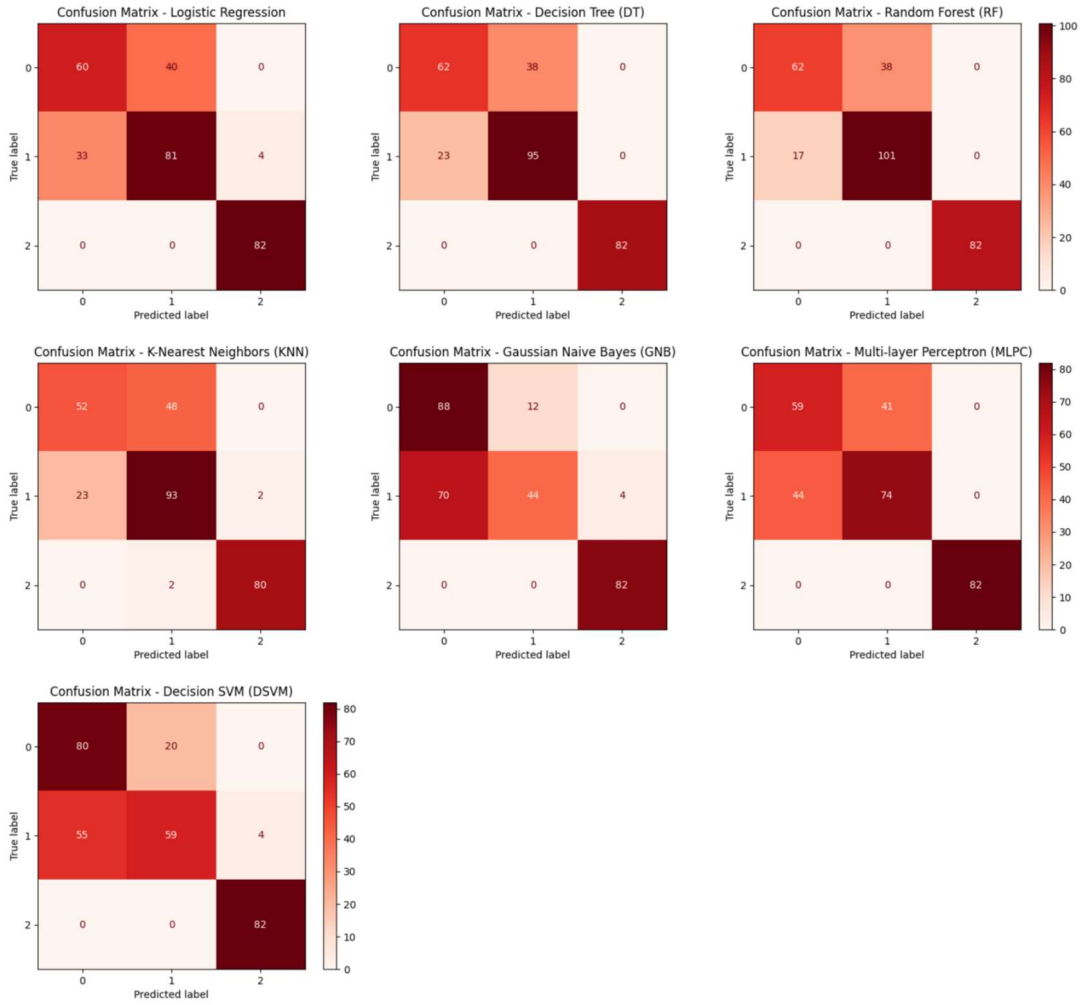


Figura 5.61: Matriz de confusão validação por SKF para sensor 1 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.17 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $81,67\%$, $82,07\%$, $0,8167$ e $0,8134$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7433	0.7390	0.7433	0.7407
Decision Tree (DT)	0.7967	0.7974	0.7967	0.7945
Random Forest (RF)	0.8167	0.8207	0.8167	0.8134
K-Nearest Neighbors (KNN)	0.7500	0.7536	0.7500	0.7451
Gaussian Naive Bayes (GNB)	0.7133	0.7553	0.7133	0.6931
Multi-layer Perceptron (MLPC)	0.7167	0.7174	0.7167	0.7169
Decision SVM (DSVM)	0.7367	0.7519	0.7367	0.7294

Tabela 5.17: Resultados obtidos para o sensor 1 da classificação utilizando validação SKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que o modelo Random Forest teve o melhor desempenho com uma AUC de 0,91.

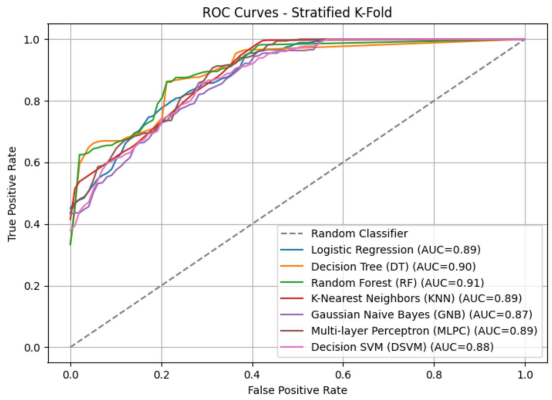


Figura 5.62: Curva ROC da validação por SKF para sensor 1 cada modelo classificador. Fonte: Autor, 2025.

Sensor 2

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

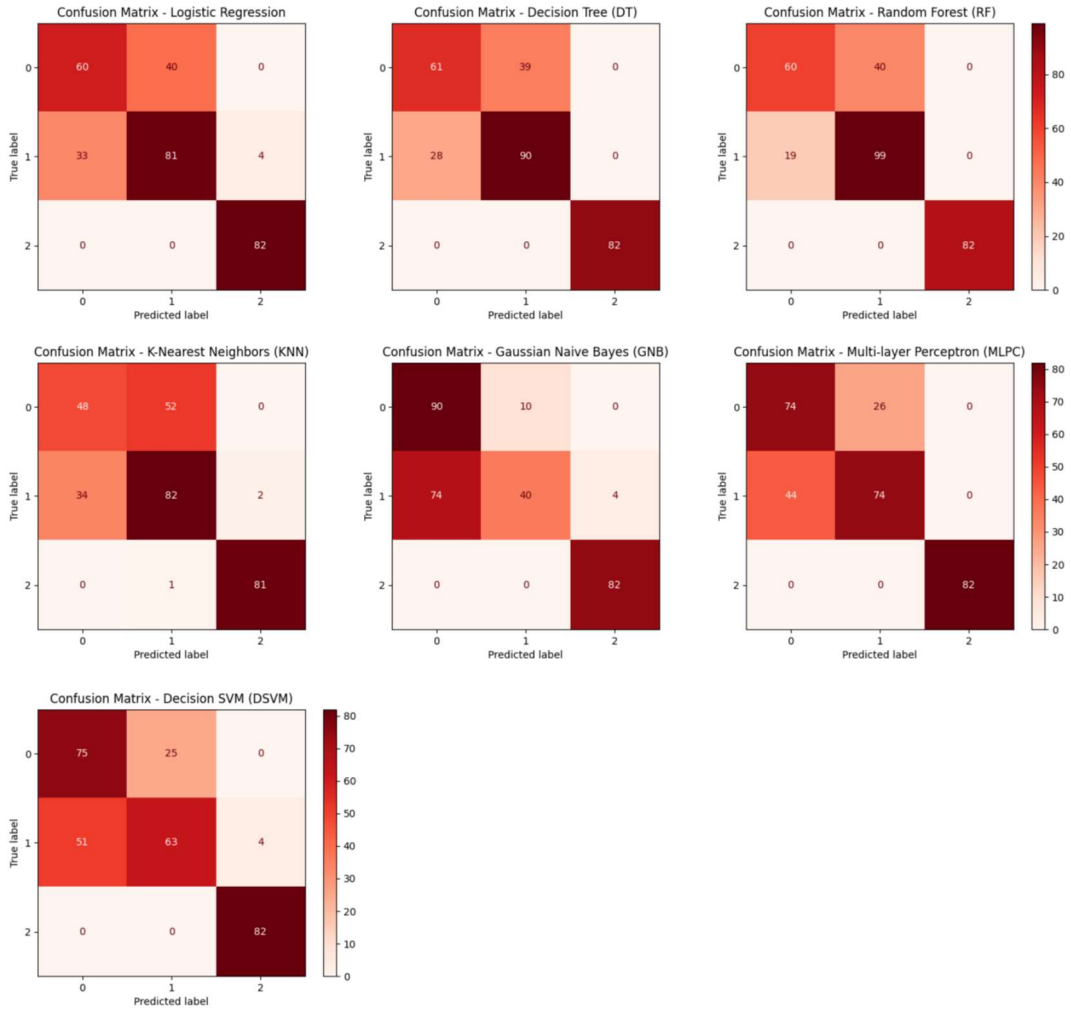


Figura 5.63: Matriz de confusão validação por SKF para sensor 2 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.18 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $80,33\%$, $80,66\%$, $0,8033$ e $0,7998$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7433	0.7390	0.7433	0.7407
Decision Tree (DT)	0.7767	0.7762	0.7767	0.7751
Random Forest (RF)	0.8033	0.8066	0.8033	0.7998
K-Nearest Neighbors (KNN)	0.7033	0.7088	0.7033	0.6992
Gaussian Naive Bayes (GNB)	0.7067	0.7582	0.7067	0.6814
Multi-layer Perceptron (MLPC)	0.7667	0.7734	0.7667	0.7667
Decision SVM (DSVM)	0.7333	0.7406	0.7333	0.7286

Tabela 5.18: Resultados obtidos para o sensor 2 da classificação utilizando validação SKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que os modelos Decision Tree e Random Forest tiveram os melhores desempenhos com uma AUC de 0,91.

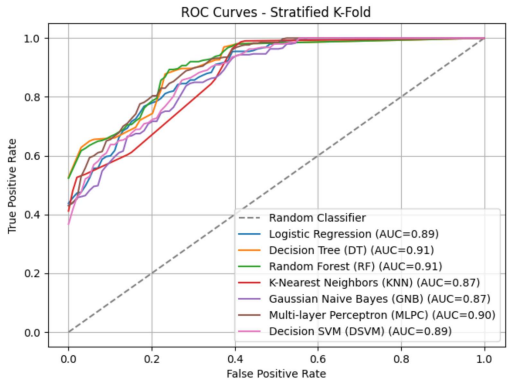


Figura 5.64: Curva ROC da validação por SKF para sensor 2 cada modelo classificador. Fonte: Autor, 2025.

Sensor 3

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

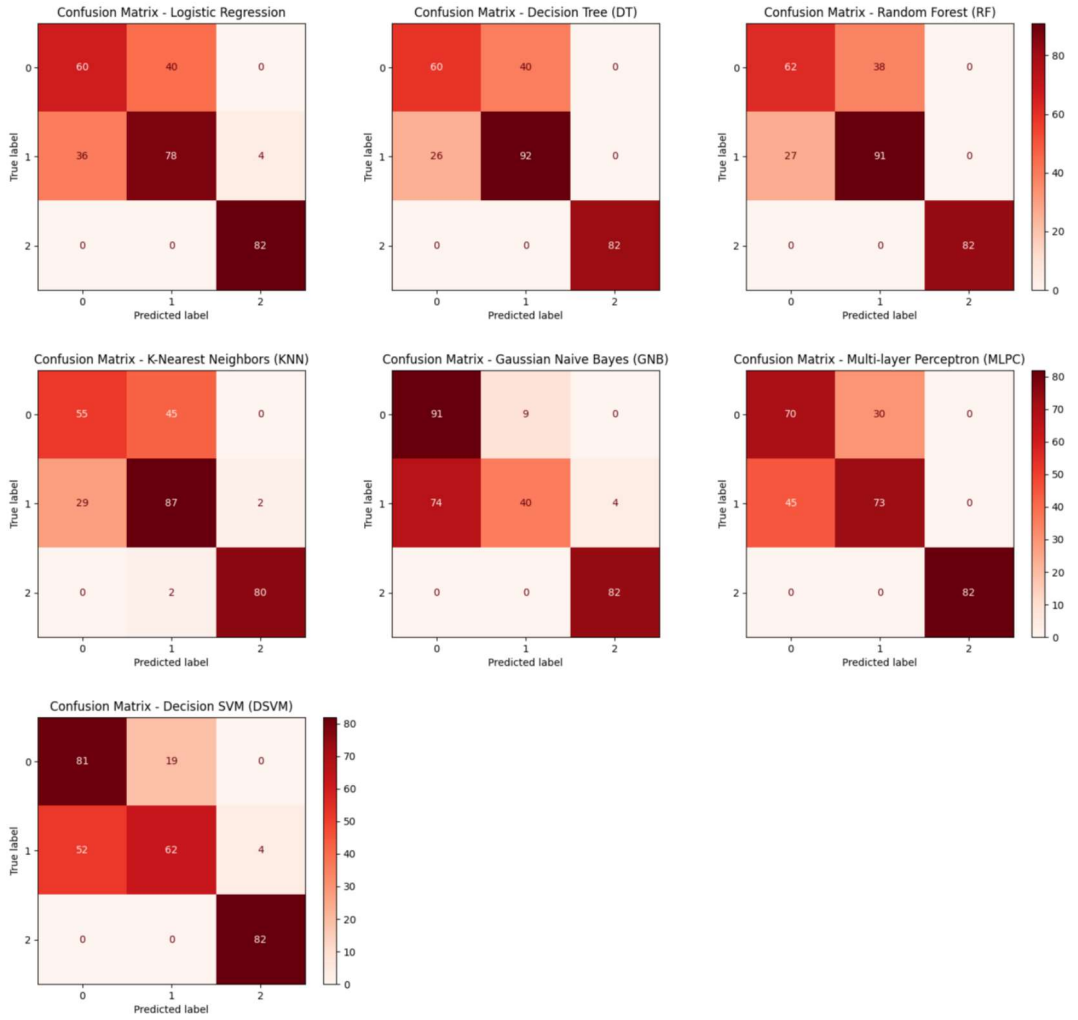


Figura 5.65: Matriz de confusão validação por SKF para sensor 3 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.19 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $78,33\%$, $78,30\%$, $0,7833$ e $0,7819$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7333	0.7290	0.7333	0.7309
Decision Tree (DT)	0.7800	0.7800	0.7800	0.7779
Random Forest (RF)	0.7833	0.7830	0.7833	0.7819
K-Nearest Neighbors (KNN)	0.7400	0.7403	0.7400	0.7375
Gaussian Naive Bayes (GNB)	0.7100	0.7655	0.7100	0.6842
Multi-layer Perceptron (MLPC)	0.7500	0.7550	0.7500	0.7502
Decision SVM (DSVM)	0.7500	0.7647	0.7500	0.7437

Tabela 5.19: Resultados obtidos para o sensor 3 da classificação utilizando validação SKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que o modelo Random Forest teve o melhor desempenho com uma AUC de 0,92.

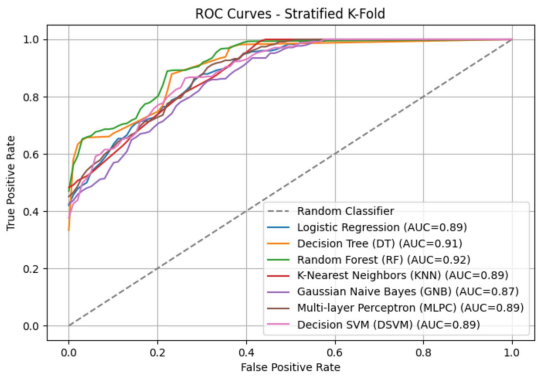


Figura 5.66: Curva ROC da validação por SKF para sensor 3 cada modelo classificador. Fonte: Autor, 2025.

Sensor 4

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

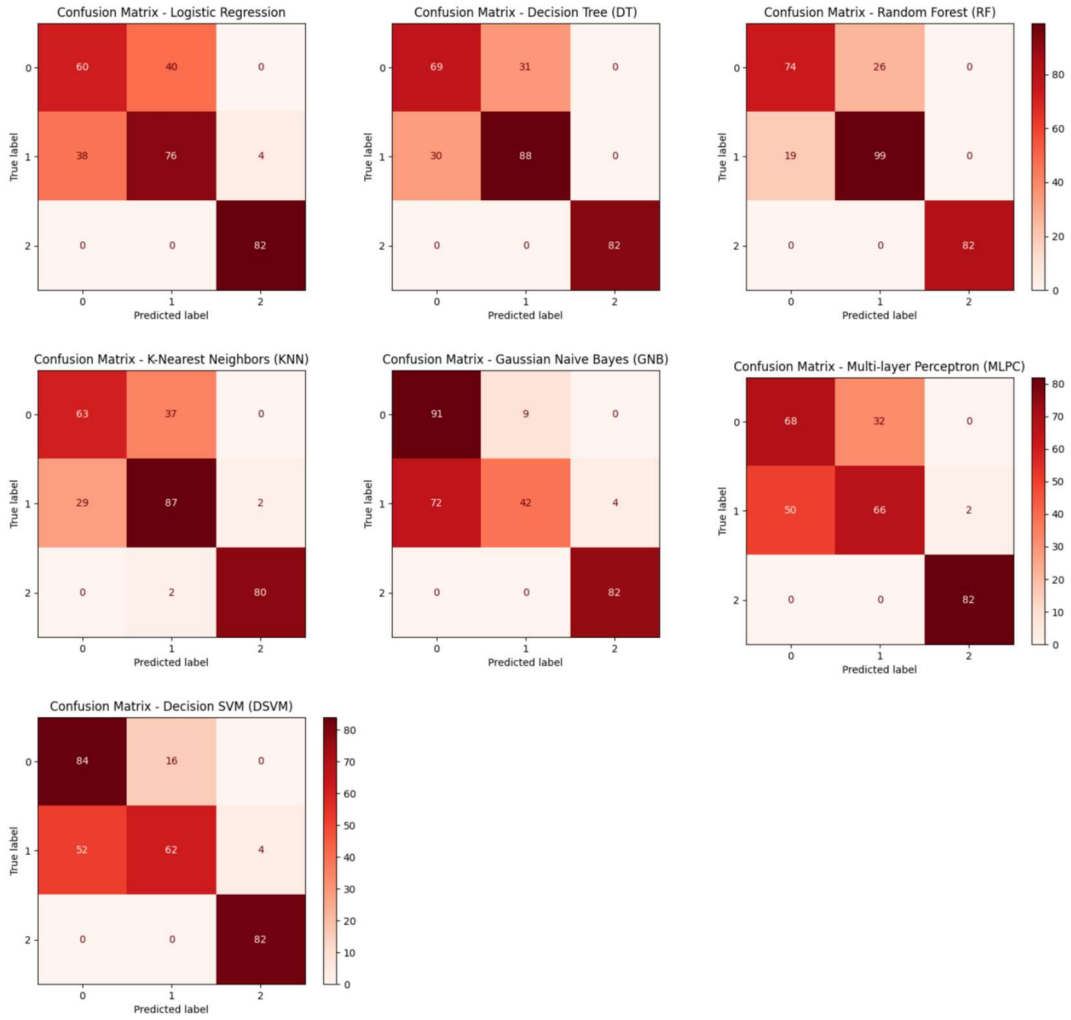


Figura 5.67: Matriz de confusão validação por SKF para sensor 4 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.20 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $85,00\%$, $85,01\%$, $0,8500$ e $0,8494$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7267	0.7224	0.7267	0.7243
Decision Tree (DT)	0.7967	0.7965	0.7967	0.7966
Random Forest (RF)	0.8500	0.8501	0.8500	0.8494
K-Nearest Neighbors (KNN)	0.7667	0.7665	0.7667	0.7659
Gaussian Naive Bayes (GNB)	0.7167	0.7706	0.7167	0.6930
Multi-layer Perceptron (MLPC)	0.7200	0.7238	0.7200	0.7184
Decision SVM (DSVM)	0.7600	0.7792	0.7600	0.7530

Tabela 5.20: Resultados obtidos para o sensor 4 da classificação utilizando validação SKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que o modelo Random Forest teve o melhor desempenho com uma AUC de 0,95.

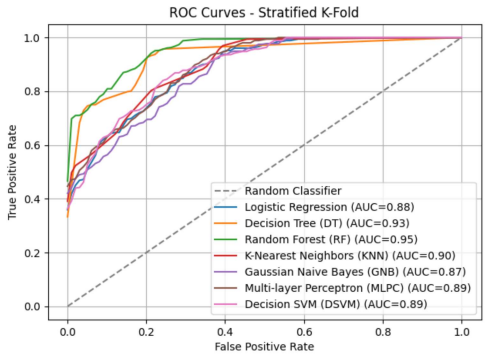


Figura 5.68: Curva ROC da validação por SKF para sensor 4 cada modelo classificador. Fonte: Autor, 2025.

Validação por Repeated Stratified K-fold (RSKF)

Sensor 1

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

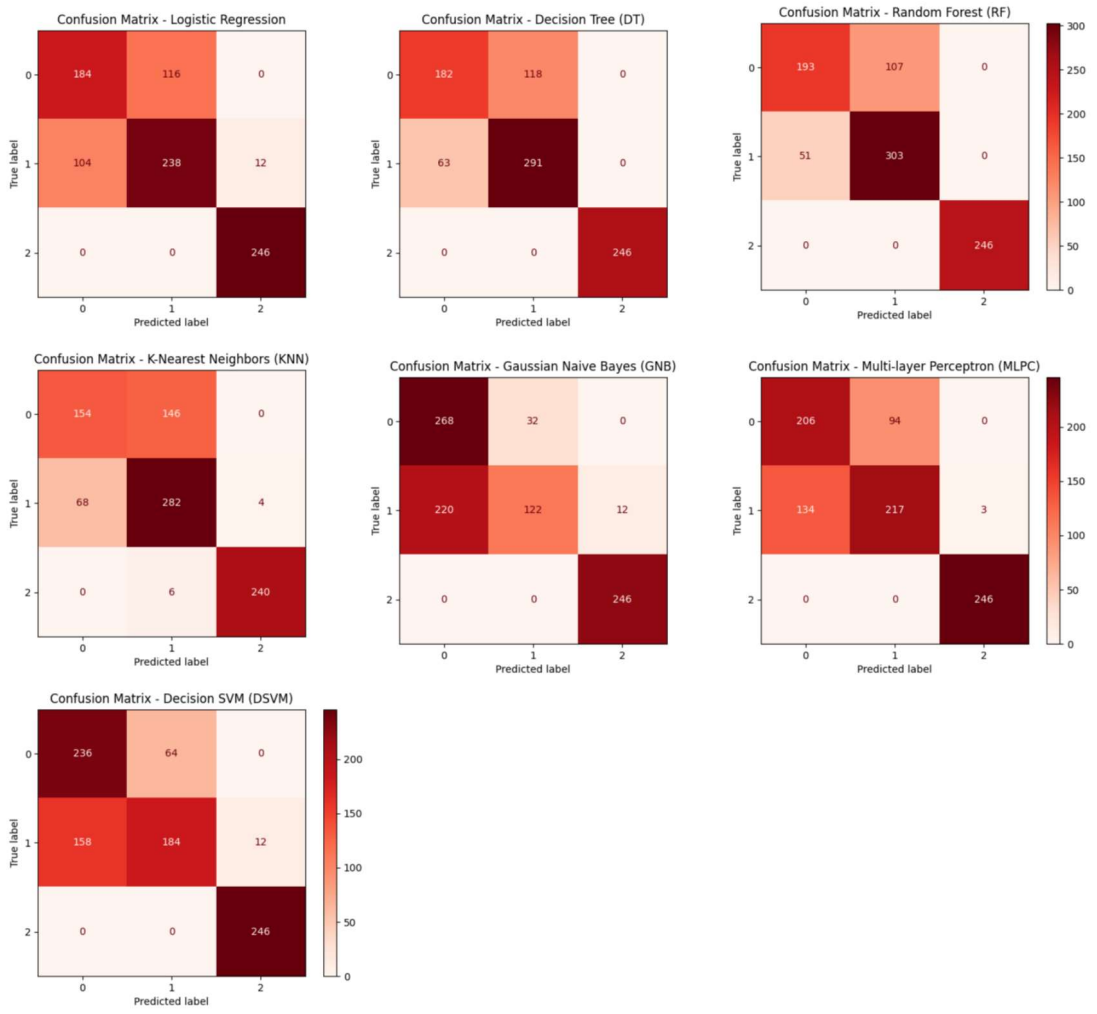


Figura 5.69: Matriz de confusão validação por RSKF para sensor 1 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.21 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $82,44\%$, $82,77\%$, $0,8244$ e $0,8218$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7422	0.7380	0.7422	0.7399
Decision Tree (DT)	0.7989	0.8008	0.7989	0.7960
Random Forest (RF)	0.8244	0.8277	0.8244	0.8218
K-Nearest Neighbors (KNN)	0.7511	0.7557	0.7511	0.7460
Gaussian Naive Bayes (GNB)	0.7067	0.7553	0.7067	0.6825
Multi-layer Perceptron (MLPC)	0.7433	0.7464	0.7433	0.7430
Decision SVM (DSVM)	0.7400	0.7521	0.7400	0.7340

Tabela 5.21: Resultados obtidos para o sensor 1 da classificação utilizando validação RSKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que o modelo Random Forest teve o melhor desempenho com uma AUC de 0,92.

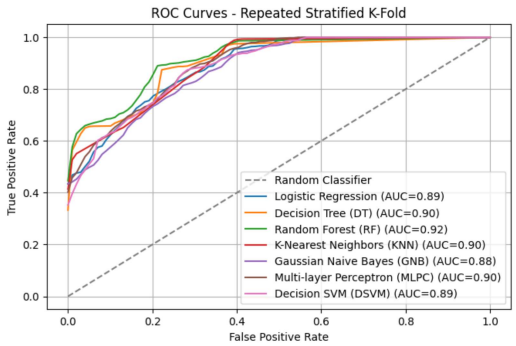


Figura 5.70: Curva ROC da validação por RSKF para sensor 1 cada modelo classificador. Fonte: Autor, 2025.

Sensor 2

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

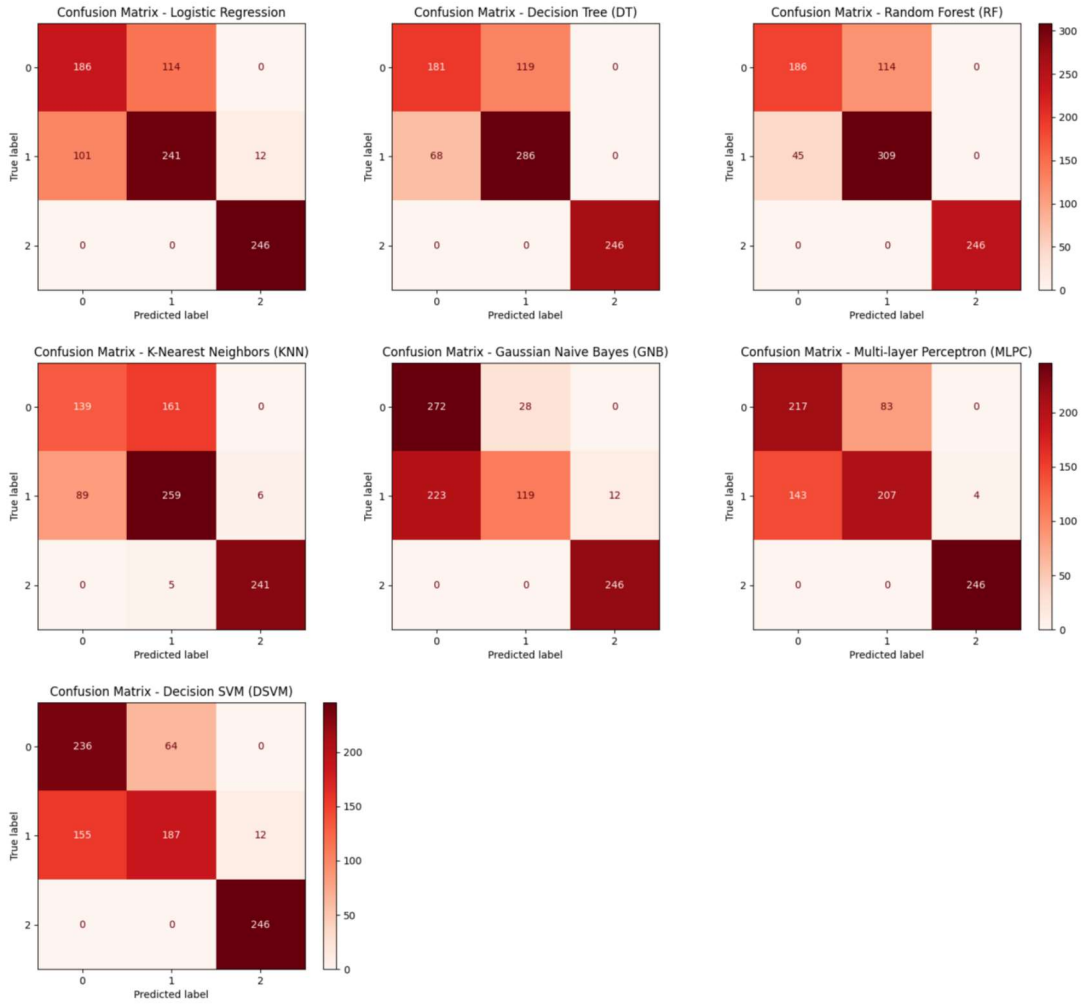


Figura 5.71: Matriz de confusão validação por RSKF para sensor 2 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.22 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $82,33\%$, $82,91\%$, $0,8291$ e $0,8197$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7478	0.7437	0.7478	0.7455
Decision Tree (DT)	0.7922	0.7934	0.7922	0.7896
Random Forest (RF)	0.8233	0.8291	0.8233	0.8197
K-Nearest Neighbors (KNN)	0.7100	0.7096	0.7100	0.7043
Gaussian Naive Bayes (GNB)	0.7078	0.7622	0.7078	0.6818
Multi-layer Perceptron (MLPC)	0.7444	0.7506	0.7444	0.7432
Decision SVM (DSVM)	0.7433	0.7549	0.7433	0.7377

Tabela 5.22: Resultados obtidos para o sensor 2 da classificação utilizando validação RSKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que o modelo Random Forest teve o melhor desempenho com uma AUC de 0,92.

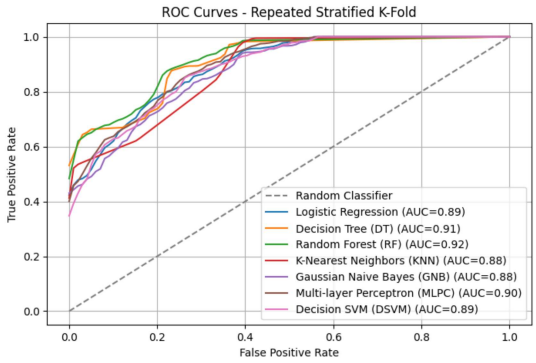


Figura 5.72: Curva ROC da validação por RSKF para sensor 2 cada modelo classificador. Fonte: Autor, 2025.

Sensor 3

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

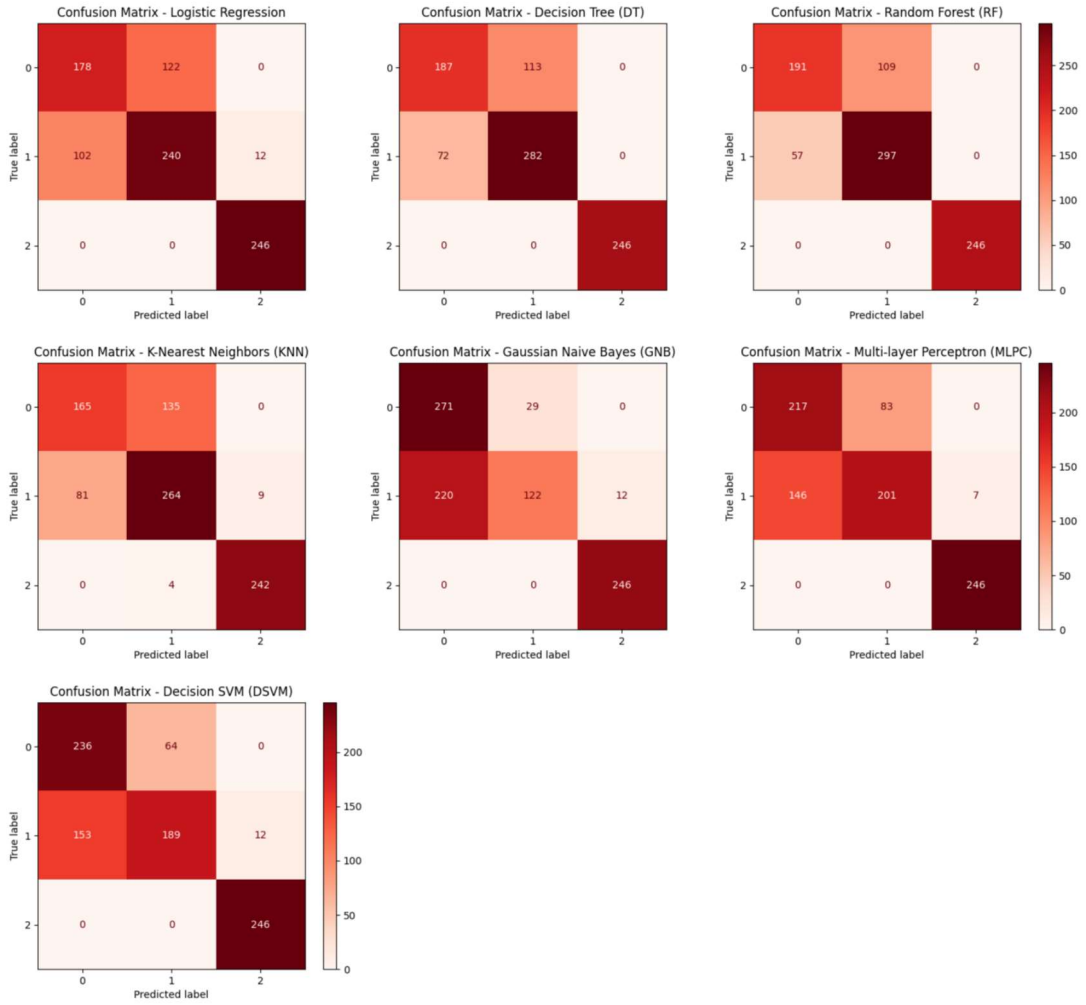


Figura 5.73: Matriz de confusão validação por RSKF para sensor 3 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.23 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $81,56\%$, $81,78\%$, $0,8156$ e $0,8131$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7378	0.7333	0.7378	0.7351
Decision Tree (DT)	0.7944	0.7948	0.7944	0.7925
Random Forest (RF)	0.8156	0.8178	0.8156	0.8131
K-Nearest Neighbors (KNN)	0.7456	0.7448	0.7456	0.7420
Gaussian Naive Bayes (GNB)	0.7100	0.7624	0.7100	0.6853
Multi-layer Perceptron (MLPC)	0.7378	0.7434	0.7378	0.7355
Decision SVM (DSVM)	0.7456	0.7567	0.7456	0.7401

Tabela 5.23: Resultados obtidos para o sensor 3 da classificação utilizando validação RSKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que os modelos Decision Tree e Random Forest obtiveram os melhores desempenhos com uma AUC de 0,92.

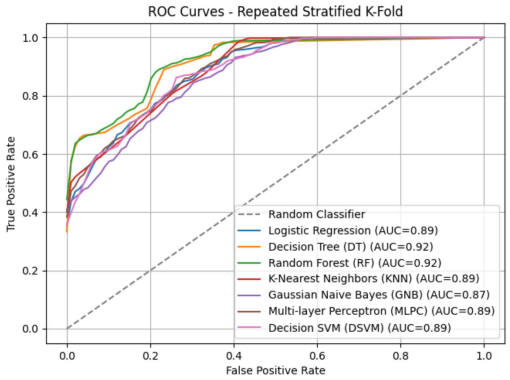


Figura 5.74: Curva ROC da validação por RSKF para sensor 3 cada modelo classificador. Fonte: Autor, 2025.

Sensor 4

Matriz de confusão

A matriz confusão para os modelos de aprendizagem estudados foram geradas utilizando a técnica de validação correspondente como mostrada na figura abaixo. As legendas 0, 1 e 2 representam fosfato, nitrato e água destilada, respectivamente.

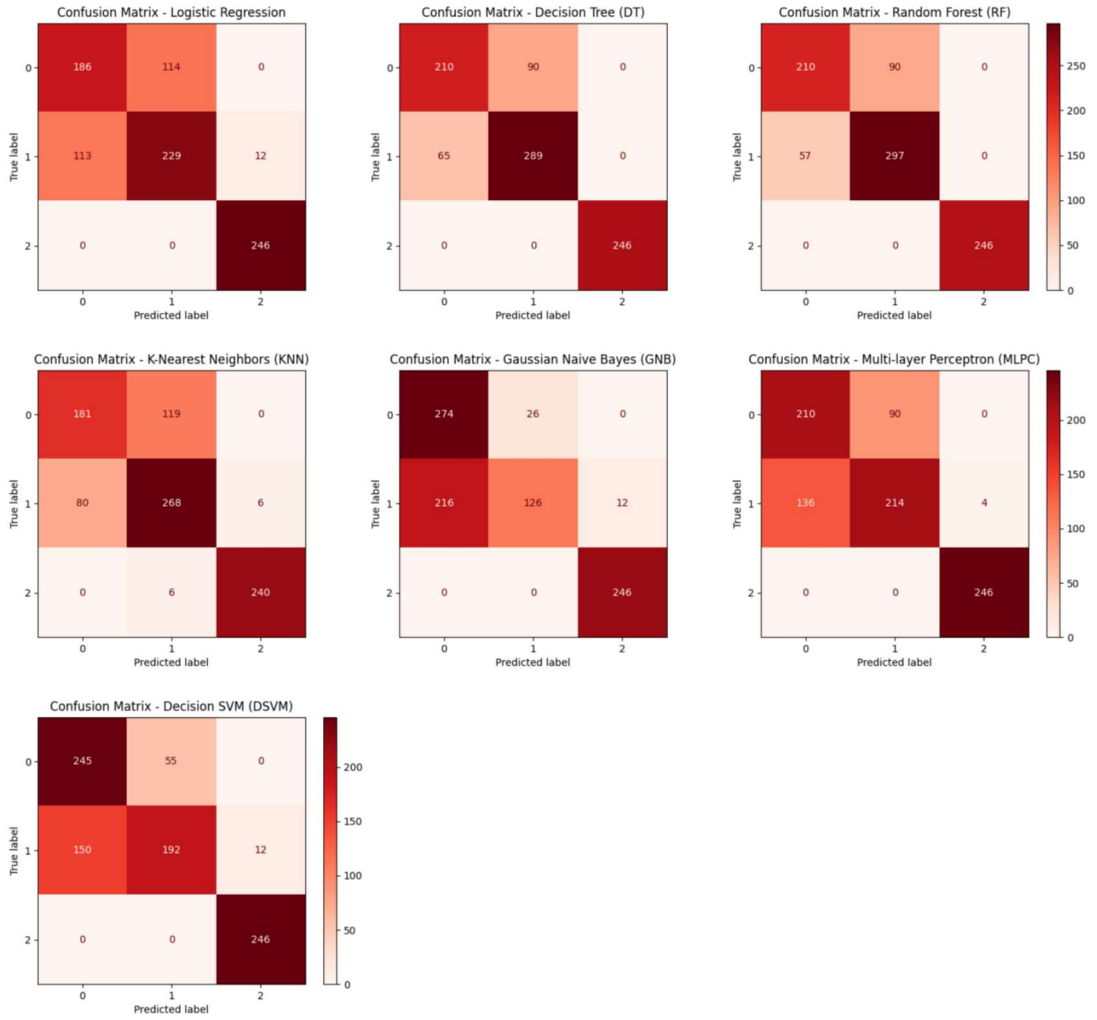


Figura 5.75: Matriz de confusão validação por RSKF para sensor 4 cada modelo classificador. Fonte: Autor, 2025.

A Tabela 5.24 mostra os valores de acurácia, precisão, recall e F1-score encontrados para cada modelo de aprendizagem utilizado. O treino mostrou que a acurácia, precisão, Recall e F1-score máximos foram encontrados no modelo Random Forest. Isso sugere que o modelo RF é o melhor classificador em comparação com as métricas utilizadas, apresentando valores ótimos de $83,67\%$, $83,74\%$, $0,8367$ e $0,8356$, respectivamente, conforme mostrado na tabela abaixo.

Modelo	Accuracy	Precision	Recall	F1-Score
Logistic Regression	0.7344	0.7306	0.7344	0.7323
Decision Tree (DT)	0.8278	0.8278	0.8278	0.8270
Random Forest (RF)	0.8367	0.8374	0.8367	0.8356
K-Nearest Neighbors (KNN)	0.7656	0.7661	0.7656	0.7640
Gaussian Naive Bayes (GNB)	0.7178	0.7731	0.7178	0.6939
Multi-layer Perceptron (MLPC)	0.7444	0.7482	0.7444	0.7437
Decision SVM (DSVM)	0.7589	0.7731	0.7589	0.7532

Tabela 5.24: Resultados obtidos para o sensor 4 da classificação utilizando validação RSKF em termos de Acurácia, Precisão, Recall e F1-Score para diferentes modelos de machine learning. Fonte: Autor, 2025.

Foi plotado a curva ROC e calculados as áreas debaixo das curvas para os modelos utilizados no estudo. Podemos ver que o modelo Random Forest teve o melhor desempenho com uma AUC de 0,94.

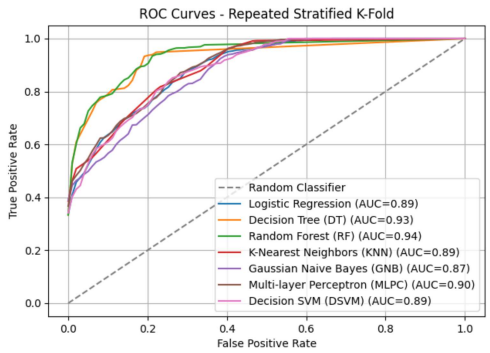


Figura 5.76: Curva ROC da validação por RSKF para sensor 4 cada modelo classificador. Fonte: Autor, 2025.

5.4.6 Analise final dos resultados obtidos

A tabela 5.25 mostra um resumo dos resultados mostram que os sensores respondem bem a determinados contaminantes e podem fornecer respostas perceptíveis e legíveis de sensibilidade desses contaminantes estudos. Além disso, observa-se que os parâmetros estudados de sensibilidade a mudança de frequência e a alteração da amplitude da resposta na frequência de ressonância são parâmetros importantes a serem considerados para a detecção e avaliação dos parâmetros e contaminantes da água propostos. A análise de sensibilidade dos sensores demonstrou que o primeiro sensor para glicose+água exibiu uma permissividade média de $0,844\%$ no intervalo de 1 a 100, com desempenho aprimorado observado em permissividades mais baixas. Já para os sensores S-CSRR e C-CSRR a análise de sensibilidade demonstrou que os sensores exibiram uma sensibilidade média

de $0,443\%$ e $0,312\%$ na faixa de 1 a 100. Já para o sensor IDC a análise de sensibilidade demonstrou que exibe uma sensibilidade média de $0,150\%$ na faixa de 1 a 100, abaixo das anteriores. Essas descobertas sugerem que o sensor apresenta desempenho superior em comparação com outros dispositivos descritos anteriormente na literatura.

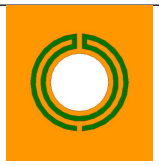
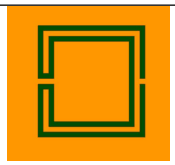
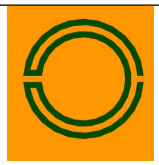
				
Tipo de ressoador	CSRR	CSRR	CSRR	IDC
Frequência de Operação	2,45 GHz	1,45 GHz	1,45 GHz	1,93 GHz
Sensibilidade	0,844%	0,443%	0,312%	0,150%

Tabela 5.25: Tabela de comparação dos principais sensores produzidos. Fonte: Autor, 2025.

Podemos observar também que, tanto para regressão quanto para classificação, os resultados obtidos foram satisfatórios, permitindo a predição e a detecção dos contaminantes analisados na concentração de 100 $\mu g/mL$. Entre os modelos de regressão, os que apresentaram melhor desempenho foram os modelos polinomiais, o que pode ser explicado pelo comportamento naturalmente não linear da curva da permissividade relativa real dos sensores em função da frequência.

No caso da classificação, os modelos Decision Tree e Random Forest se destacaram, alcançando desempenho superior a 90% em termos de acurácia e AUC, quando comparados aos demais modelos. Para melhor visualização, é possível traçar a figura da acurácia máxima obtida pelos sensores em função dos diferentes métodos de validação, como ilustrado na figura abaixo.

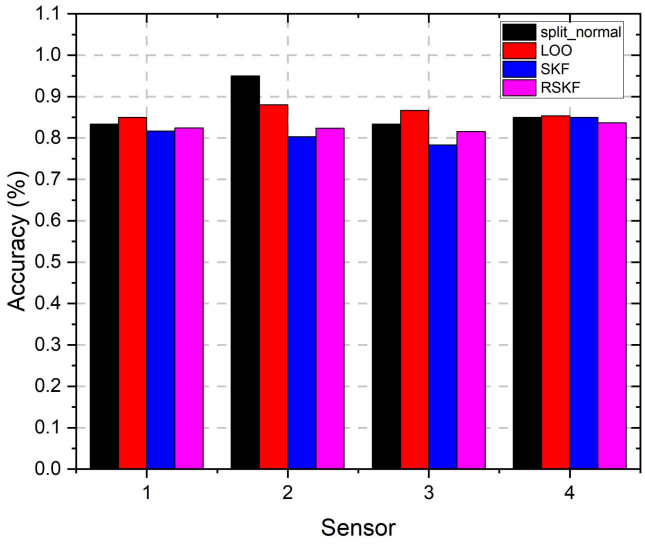


Figura 5.77: Curva da comparação acurácia máxima por sensor com a validação utilizada. Fonte: Autor, 2025.

As legendas 1, 2, 3 e 4 para os sensores corresponde os sensores F-CSRR, S-CSRR, C-CSRR e IDC respectivamente. Adicionalmente, observa-se que os sensores 2 e 4 apresentaram o melhor desempenho na detecção dos contaminantes em relação aos demais. Entre as técnicas de validação cruzada, a que obteve o melhor desempenho médio foi o Leave-One-Out (LOO), seguida pela divisão tradicional das amostras na proporção 20:80.

Capítulo 6

Conclusão

6.1 Conclusão

Ao longo desde trabalho foi produzido quatro novos sensores de micro-ondas três deles baseados em CSRR e um baseado em IDC para medir a permissividade de contaminantes críticos na água. O primeiro deles um sensor de micro-ondas, caracterizado pelo baixo custo, fabricação simples e design compacto, foi desenvolvido, fabricado e validado. O projeto do sensor CSRR proposto consiste em uma célula interconectada baseada em CSRR com raio e dimensões mínimos para operar na frequência desejada. Além disso, foi incorporada uma linha de transmissão microstrip, excitada pela fonte do plano de aterramento. Essa abordagem facilita a interação mais eficaz com uma variedade de amostras. O objetivo principal do sensor é caracterizar diferentes concentrações de glicose na água, com o intuito de evitar a presença de açúcares na água de irrigação de grandes plantações. O sensor proposto opera variando as frequências de ressonância para os vários tipos de amostras líquidas utilizadas. Já os dois outros sensores de micro-ondas baseados CSRR com alta-sensibilidade (S-CSRR e C-CSRR) foram, simulados, fabricados e testados para caracterizar soluções aquosas com poluentes como nitrato, fosfato, amônio. Ele também foi testado com amostras de água destilada com diferentes níveis de salinidade. Esses sensores foram desenvolvidos para funcionar na frequência de ressonância de 1,45 GHz. Foi analisado ao total uma banda variando de 500MHz a 2GHz para notar variações de sensibilidade desses sensores. A solução dos sensores micro-ondas encontradas apresenta um baixo custo de produção devido ao substrato FR-4 ser facilmente utilizado em larga escala, além disso possui um baixo perfil com tamanho total de 70 mm x 40 mm, por fim, foi simulado, fabricado e validado um sensor planar de micro-ondas baseados em IDC, no qual opera na frequência de ressonância de 1.925 GHz e foi principalmente utilizado para prever alterações de contaminantes de fosfato, nitrato e amônia em concentrações especificas de $100\mu/mL$.

Os resultados obtidos demonstram que os modelos de aprendizado de máquina aplicados foram eficazes tanto em tarefas de regressão quanto de classificação, evidenciando sua aplicabilidade na detecção dos contaminantes analisados. Para regressão, os modelos polinomiais apresentaram desempenho superior, refletindo a natureza não linear da resposta dos sensores em função da frequência. Já no contexto da classificação, os modelos Decision Tree e Random Forest se destacaram, alcançando acurácia e AUC acima de 90%, o que confirma sua robustez frente a outros algoritmos testados.

Adicionalmente, verificou-se que os sensores 2 e 4 ofereceram melhor desempenho comparativo, reforçando sua relevância para a aplicação proposta. Entre as estratégias de validação, o método Leave-One-Out (LOO) apresentou o melhor desempenho médio, seguido pela divisão tradicional em 20:80. Esses resultados indicam que a escolha criteriosa do modelo e da técnica de validação é determinante para garantir previsões confiáveis e precisas no contexto estudado.

Portanto, as principais contribuições deste estudo destacam-se pela implementação da técnica DGS para monitorar contaminantes em água, que proporcionou uma sensibilidade aprimorada nos sensores desenvolvidos.

6.2 Proposta de Continuidade

Abaixo, são apresentados pontos que resumem objetivos futuros para o prosseguimento da pesquisa realizada neste trabalho:

- Coletar amostras In Situ dos principais lagos e rios de Natal/RN e região metropolitana e comparar com resultados experimentais encontrados em laboratório;
- Avaliar os resultados encontrados no estudo geral;
- Documentar e publicar os principais resultados encontrados;
- Elaboração de um prototipo para determinação da concentrações dos contaminantes estudados e patentear o subproduto gerado.

6.3 Trabalhos Produzidos Relacionados ao Tema

A seguir, são apontados os artigos científicos cujo assunto se relaciona com o tema desta dissertação:

- (*Publicado*) Low-Cost CSRR-based Microwave Sensor for Evaluating Water Quality to Prevent Unwanted Sugar Contamination. Autores: de Sousa, B. M., Duarte Júnior, J. G., Silva Neto, V. P., JMOe - Journal of Microwaves, Optoelectronics and Electromagnetic Applications.
- (*Aceito*) Planar Microwave Sensor for Phosphate and Nitrate Detection in Rivers and Lakes Using Machine Learning Techniques. Autores: de Sousa, B. M., Silva Neto, V. P., IMOC 2025 - International Microwave and Optoelectronics Conference.
- (*Publicado*) Microwave Sensor with Hairpin Resonator-Based Line and Defected Ground Structure. Autores: de Sousa, B. M., da Silva, J. P., Silva Neto, V. P., SbrT 2025 - BRAZILIAN SYMPOSIUM ON TELECOMMUNICATIONS AND SIGNAL PROCESSING.
- (*Submetido*) Design of Microwave Sensors for Detection and Classification of Critical Contaminants in Water Using Machine Learning Techniques. Autores: de Sousa, B. M., Silva Neto, V. P., Sensors and Actuators A: Physical.

Outros trabalhos:

- (*Publicado*) Antena dipolo cruzado bowtie compacta para toda banda GNSS. Autores: de Sousa, B. M., Silva Neto, V. P., D'Assunção, A. G., SBMO 2024 - Sociedade Brasileira de Micro-ondas e Optoeletrônica.
- (*Publicado*) A Novel Wideband Magnetoelectric Dipole Antenna with Circular Polarization Applied to CubeSat. Autores: de Sousa, B. M., Duarte Júnior, J. G., Silva Neto, V. P., JMOe - Journal of Microwaves, Optoelectronics and Electromagnetic Applications.
- (*Submetido*) Otimized Hairpin Bandpass Filter Using DGS. Autores: de Sousa, B. M., da Silva, T. J. C., da Silva, J. P., Silva Neto, V., JMOe - Journal of Microwaves, Optoelectronics and Electromagnetic Applications.

Referências Bibliográficas

ABBASI, Zahra, Hamid Niazi, Mohammad Abdolrazzaghi, Weixing Chen & Mojgan Daneshmand (2020), 'Monitoring ph level using high-resolution microwave sensor for mitigation of stress corrosion cracking in steel pipelines', *IEEE Sens. J.* **20**(13), 7033–7043.

ABBASI, Zahra & Mojgan DANESHMAND (2018), Contactless ph measurement based on high resolution enhanced Q microwave resonator, *em* '2018 IEEE/MTT-S International Microwave Symposium - IMS', IEEE.

ABRAHAMYAN, T, R Khachatryan, D Hambaryan, B Hovhannisyan, B Minasyan, L Odabashyan & A Babajanyan (2019), 'Investigation of ag nanoparticles/water solutions by microwave stripline sensor', *J. Contemp. Phys.* **54**(2), 196–202.

ADJOVU, Godson Ebenezer, Haroon Stephen, David James & Sajjad Ahmad (2023), 'Overview of the application of remote sensing in effective monitoring of water quality parameters', *remote sensing* **15**(1938), 1–35.

ALSHALTONE, Omar, Eqab Almajali & Abir Hussain (2023), Improved simulation-based circular microwave sensor for water quality assessment, *em* '2023 16th International Conference on Developments in eSystems Engineering (DeSE)', IEEE, pp. 288–291.

AMINEH, Reza K, Maryam Ravan & Dhara Tandel (2023), 'Detection of water pollutants with a nonuniform array of microwave sensors', *IEEE Trans. Instrum. Meas.* **72**, 1–11.

AMIRI, Majid, Mehran Abolhasan, Negin Shariati & Justin Lipman (2022), 'Remote water salinity sensor using metamaterial perfect absorber', *IEEE Trans. Antennas Propag.* **70**(8), 6785–6794.

ANAR, N F S Saiful, M F Sapuri, S A Enche Ab Rahim, Z I Khan, N A Z Zakaria & A H Ma'Radzi (2024*a*), Enhancing ammoniacal nitrogen detection in water quality applications using complementary split-ring resonators: A comparison between rectangular and circular configurations, *em* '2024 IEEE Symposium on Wireless Technology & Applications (ISWTA)', Vol. 4, IEEE, pp. 121–125.

ANAR, N F S Saiful, M F Sapuri, S A Enche Ab Rahim, Z I Khan, N A Z Zakaria & A H Ma'Radzi (2024*b*), Enhancing ammoniacal nitrogen detection in water quality applications using complementary split-ring resonators: A comparison between

rectangular and circular configurations, *em* '2024 IEEE Symposium on Wireless Technology & Applications (ISWTA)', Vol. 4, IEEE, pp. 121–125.

ARMGHAN, A., T. M. Alanazi, A. Altaf & T. Haq (2021), 'Characterization of dielectric substrates using dual band microwave sensor', *IEEE Access* **9**, 62779–62787.

BERIA, Y., A. Buragohain, G. S. Das, P. P. Kalita & B. B. Chamuah (2023), 'Highly sensitive miniaturized ds-csrr sensor for complex permittivity measurements', *2023 First International Conference on Microwave, Antenna and Communication (MAC)* pp. 1–4.

Cardinali, Leonardo, Valeria Mariano, David O Rodriguez-Duarte, Jorge A Tobon Vasquez, Rosa Scapaticci, Lorenzo Crocco & Francesca Vipiana (2025), 'Early detection of alzheimer's disease via machine learning-based microwave sensing: An experimental validation', *Sensors (Basel)* **25**(9), 2718.

CHUMA, E. L., Y. Iano, G. Fontgalland & L. L. Bravo Roger (2018), 'Microwave sensor for liquid dielectric characterization based on metamaterial complementary split ring resonator', *IEEE Sensors Journal* **18**(24), 9978–9983.

COSTANZO, Sandra (2024), Microwave sensor for water pollutants detection: Design and preliminary results, *em* 'Proceedings of the 4th URSI Atlantic RadioScience Conference – AT-RASC 2024', URSI - International Union of Radio Science.

Darwish, Ali, Marco Ricci, Jorge A Tobon Vasquez, Claire Migliaccio & Francesca Vipiana (2024), 'Near-field microwave sensing technology enhanced with machine learning for the non-destructive evaluation of packaged food and beverage products', *Sci. Rep.* **14**(1), 13413.

DING, Shuying, Yingsong Li, Zhixiang Huang, Eugene Sinkevich & Vladimir Mordachev (2024), A microwave sensor for detection of water adulteration and spoilage in milk based on split-ring resonator, *em* '2024 IEEE 7th International Conference on Electronic Information and Communication Technology (ICEICT)', IEEE, pp. 32–33.

EBRAHIMI, A., J. Scott & K. Ghorbani (2019), 'Ultrahigh-sensitivity microwave sensor for microfluidic complex permittivity measurement', *IEEE Transactions on Microwave Theory and Techniques* **67**(10), 4269–4277.

EL-NADY, Shaza, Asmaa Afifi & Anwer S Abd El-Hameed (2024), 'Sugar and salt concentration detection in water employing ENZ metamaterial microwave sensor', *Wirel. Pers. Commun.* .

Farouk, Mariam, Anwer S Abd El-Hameed, Angie R Eldamak & Dalia N Elsheakh (2025), 'Noninvasive blood glucose monitoring using a dual band microwave sensor with machine learning', *Sci. Rep.* **15**(1), 16271.

FRAU, I, S R Wylie, P Byrne, J D Cullen, O Korostynska & A Mason (2020), 'Functionalised microwave sensors for real-time monitoring of copper and zinc concentration in mining-impacted water', *Int. J. Environ. Sci. Technol. (Tehran)* **17**(4), 1861–1876.

FRAU, Ilaria, Olga Korostynska, Alex Mason & Patrick Byrne (2018), 'Comparison of electromagnetic wave sensors with optical and low-frequency spectroscopy methods for real-time monitoring of lead concentrations in mine water', *Mine Water Environ.* **37**(3), 617–624.

FRAU, Ilaria, Stephen Wylie, Patrick Byrne, Patrizia Onnis, Jeff Cullen, Alex Mason & Olga Korostynska (2021*a*), 'Microwave sensors for in situ monitoring of trace metals in polluted water', *Sensors (Basel)* **21**(9), 3147.

FRAU, Ilaria, Stephen Wylie, Patrick Byrne, Patrizia Onnis, Jeff Cullen, Alex Mason & Olga Korostynska (2021*b*), 'Microwave sensors for in situ monitoring of trace metals in polluted water', *Sensors (Basel)* **21**(9), 3147.

FøRE, M., M. O. Alver, J. A. Alfredsen, A. Rasheed, T. Hukkelås, H. V. Bjelland, B. Su, S. J. Ohrem, E. Kelasidi, T. Norton & N. Papandroulakis (2024), 'Digital twins in intensive aquaculture — challenges, opportunities and future prospects', *Computers and Electronics in Agriculture* **218**, 108676–108696.

GAN, Hong-Yi, Wen-Sheng Zhao, Qi Liu, Da-Wei Wang, Linxi Dong, Gaofeng Wang & Wen-Yan Yin (2020), 'Differential microwave microfluidic sensor based on microstrip complementary split-ring resonator (MCSRR) structure', *IEEE Sens. J.* **20**(11), 5876–5884.

GAO, B., Z. Chen, X. Gong, P. Wang & L. Tong (2020), 'Design and experiment of microwave soil moisture sensor', *IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium* pp. 5053–5056.

GULSU, M. S., F. Bagci, S. Can, A. E. Yilmaz & B. Akaoglu (2021), 'Minkowski-like fractal resonator-based dielectric sensor for estimating the complex permittivity of binary mixtures of ethanol, methanol and water', *Sensors and Actuators A: Physical* **330**, 112841–112851.

HAN, Xueyun, Ke Liu, Siyu Zhang, Peidong Peng, Chenghao Fu, Lei Qiao & Zhongjun Ma (2024), 'CSRR metamaterial microwave sensor for measuring dielectric constants of solids and liquids', *IEEE Sens. J.* **24**(9), 14167–14176.

HANIF, A., M. L. Hakim, T. Alam, B. Bais, S. Alamri, A. M. Alrashdi, M. S. Soliman & M. T. Islam (2024), 'Highly sensitive miniaturized labyrinth shape circular split ring resonator (LC-SRR) based microwave sensor for low permittivity characterization applications', *Engineering Science and Technology, an International Journal* **53**(101687), 101687.

HAQ, T., C. Ruan, X. Zhang, S. Ullah, A. K. Fahad & W. He (2020), 'Extremely sensitive microwave sensor for evaluation of dielectric characteristics of low-permittivity materials', *Sensors (Basel)* **20**(7), 1916–1933.

HARNSOONGNOEN, Supakorn (2021), 'Metamaterial-inspired microwave sensor for detecting the concentration of mixed phosphate and nitrate in water', *IEEE Trans. Instrum. Meas.* **70**, 1–6.

HARNSOONGNOEN, Supakorn & Anuwat WANTHONG (2021), 'A non-contact planar microwave sensor for detection of high-salinity water containing NaCl, KCl, CaCl2, MgCl2 and Na2CO3', *Sens. Actuators B Chem.* **331**(129355), 129355.

HARNSOONGNOEN, Supakorn, Anuwat Wanthong, Urit Charoen-In & Apirat Siritaratiwat (2019), 'Microwave sensor for nitrate and phosphate concentration sensing', *IEEE Sens. J.* **19**(8), 2950–2955.

Harnsoongnoen, Supakorn, Saksun Srisai, Pongsathorn Kongkeaw & Benjaporn Buranrat (2025), 'Detection and classification of glucose solution concentration and blood sugar levels at the fingertip using a novel planar microwave sensor and deep learning techniques', *Sens. Actuators B Chem.* **430**(137322), 137322.

Harrsion, Luke, Maryam Ravan, Dhara Tandel, Kunyi Zhang, Tanvi Patel & Reza K. Amineh (2020), 'Material identification using a microwave sensor array and machine learning', *Electronics (Basel)* **9**(2), 288.

HONG, Wong, Norazanita Shamsuddin, Emeroylariffion Abas, Rosyzie Apong, Zarifi Masri, Hazwani Suhaimi, Stefan Gödeke & Muhammad Noh (2021), 'Water quality monitoring with arduino based sensors', *Environments* **8**(1), 6.

JAFARI, Fahimeh & Mazdak RAD MALEKSHAHI (2024), 'A new technique of using a neural network classifier in microwave microfluidic sensors for purity detection of liquids', *IEEE Sensing Journal* **24**(16), 25662–25669.

JAVED, A., A. Arif, M. Zubair, M. Q. Mehmood & K. Riaz (2020), 'A low-cost multiple complementary split-ring resonator-based microwave sensor for contactless dielectric characterization of liquids', *IEEE Sensors Journal* **20**(19), 11326–11334.

JIANG, S., G. Liu, M. Wang, Y. Wu & J. Zhou (2023), 'Design of high-sensitivity microfluidic sensor based on csrr with interdigital structure', *IEEE Sensors Journal* **23**(16), 17901–17909.

KAI BOON, Wee, Universiti Tun Hussein Onn Malaysia, Zuhairiah Zainal Abidin, Adel Yahya Isa Ashyap, Universiti Tun Hussein Onn Malaysia & Universiti Tun Hussein Onn Malaysia (2021), 'Designing of microwave metamaterial biosensor for water pollution monitoring', *Journal of Electronic Voltage and Application* **2**(2).

Kazemi, Kianoosh & Gholamreza Moradi (2021), Machine learning approach for retrieval of complex permittivity in cavity resonators, *em* '2021 29th Iranian Conference on Electrical Engineering (ICEE)', IEEE.

Kazemi, Nazli, Mohammad Abdolrazzaghi, Petr Musilek & Elham Baladi (2024), A cnn-based material classification approach using heatmap of a dual-band microwave sensor, *em* '2024 EEE International Symposium on Antennas and Propagation and INC/USNC-URSI Radio Science Meeting AP-S/INC-USNC-URSI', IEEE, pp. 671–672.

KIANI, S., P. Rezaei & M. Navaei (2020), 'Dual-sensing and dual-frequency microwave srr sensor for liquid samples permittivity detection', *Measurement: Journal of the International Measurement Confederation* **160**, 107805–107813.

Lajnef, Tarek, Sahbi Chaibi, Perrine Ruby, Pierre-Emmanuel Aguera, Jean-Baptiste Eichenlaub, Mounir Samet, Abdennaceur Kachouri & Karim Jerbi (2015), 'Learning machines and sleeping brains: Automatic sleep stage classification using decision-tree multi-class support vector machines', *J. Neurosci. Methods* **250**, 94–105.

LAZZONI, Valeria, Riccardo Rossi, Danilo Brizi, Francesca Ugolini, Silvia Baronti, Marco Moriondo, Marco Bindi & Agostino Monorchio (2023), Implementation of a microwave sensor for the non-destructive detection of plant water stress, *em* '2023 17th European Conference on Antennas and Propagation (EuCAP)', IEEE, pp. 1–4.

Lei, Yajuan, Dongjie Zhang, Qingzhou Wang, Sui Mao, Eun-Seong Kim, Nam-Young Kim, Qihui Zhou, Yuanyue Li & Zhao Yao (2025), 'Detection of carcinoembryonic antigen specificity using microwave biosensor with machine learning', *Biosens. Bioelectron.* **269**(116908), 116908.

Li, Jiajun, Sihui Wu, Xueran Shi, Yingbo Cao, Han Hao, Jing Wang & Qian Han (2025), 'Machine learning-assisted biomass-derived carbon dots as fluorescent sensor array for discrimination of warfarin and its metabolites', *Langmuir* **41**(3), 1694–1702.

LIRA, Ruann Victor de Andrade, Cefas Rodrigues Freire, Isaac Barros Tavares Da Silva, Valdemir Praxedes da Silva Neto, João Guilherme Domingos de Oliveira, Humberto Dionísio de Andrade & Antonio Luiz Pereira de Siqueira Campos (2024), 'A compact CSRR-based microwave sensor for soil water content', *Sens. Actuators A Phys.* **370**(115211), 115211.

MANFREDA, Salvatore, Domenico Miglino, Khim Saddi, Seifeddine Jomaa, Anette Etner, Matthew Perks, Salvador Peña-Haro, Thom Bogaard, Tim van Emmerik, Stefano Mariani, Ian Maddock, Flavia Tauro, Salvatore Grimaldi, Yijian Zeng, Gil Gonçalves, Dariia Strelnikova, Martina Bussettini, Giulia Marchetti, Barbara Lastoria, Bob Su & Michael Rode (2023), Advancing hydrological monitoring using image-based techniques: challenges and opportunities.

MIRZAVAND, Rashid, Mohammad Mahdi Honari, Bahareh Laribi, Behnam Khorshidi, Mohtada Sadrzadeh & Pedram Mousavi (2018), 'An unpowered sensor node for real-time water quality assessment (humic acid detection)', *Electronics (Basel)* **7**(10), 231.

MISHRA, A. K. & J. PANDA (2024), 'Development of a rapid and cost-effective method for estimating plant glucose levels with a glucometer', *International Journal of Environment Agriculture and Biotechnology* pp. 1–3.

MOHAMMADI, Sevda, Anupama Vijaya Nadaraja, Deborah J Roberts & Mohammad H Zarifi (2020), 'Real-time and hazard-free water quality monitoring based on microwave planar resonator sensor', *Sens. Actuators A Phys.* **303**(111663), 111663.

Mosavirik, Tahoura, Vahid Nayyeri, Mohammad Hashemi, Mohammad Soleimani & Omar M Ramahi (2023), 'Direct permittivity reconstruction from power measurements using a machine learning aided method', *IEEE Trans. Microw. Theory Tech.* **71**(10), 4437–4448.

Musa, Ahmad, Touhidul Alam, Mohammad Tariqul Islam, Yeasin Arafat Payek & Mohamed S Soliman (2025), 'Machine learning-optimized metamaterial sensor for real-time insoluble particle position monitoring in multiphase oil flow', *IEEE Trans. Instrum. Meas.* **74**, 1–9.

OMER, A. E., G. Shaker, S. Safavi-Naeini, H. Kokabi, G. Alquie, F. Deshours & R. M. Shubair (2020), 'Low-cost portable microwave sensor for non-invasive monitoring of blood glucose level: novel design utilizing a four-cell CSRR hexagonal configuration', *Scientific reports* **10**(1), 15200–15220.

PEREIRA, R. N., J. G. D. Júnior, M. E. T. S. Praxedes, K. C. Cabral, V. P. d. S. Neto & A. G. D'Assunção (2024), 'A planar dgs sensor for moisture analysis in civil construction aggregates', *Sensors and Actuators A: Physical* **367**, 115042–115052.

Rai, Yajush, Moulik Razdan, Rahul Bajaj & Smriti Agarwal (2024), Machine learning inspired classification model of different edible oil samples using high sensitivity microwave sensor, *em* '2024 11th International Conference on Signal Processing and Integrated Networks (SPIN)', IEEE.

SAMSURI, Wan Nurnabihah Wan Muhammed, Muhd Faris Sapuri, S A Enche Ab Rahim, Farah Adilah Mohd Kasran, Norliyana Yusof & Zuhani Ismail Khan (2023), High Q double-ring complementary split ring resonator to detect ammoniacal nitrogen for water quality applications, *em* '2023 IEEE Symposium on Wireless Technology & Applications (ISWTA)', IEEE, pp. 174–178.

Seyyedmasoumian, Sevda, Maede Chavoshi, Marie Mertens & Dominique Schreurs (2025), 'The integration of machine learning in microwave dielectric sensing: From design to postprocessing', *IEEE Microw. Mag.* **26**(3), 60–77.

SILVA, L. A. Paz, F. A. Brito Filho & H. D. de Andrade (2023), 'Soil moisture monitoring system based on metamaterial-inspired microwave sensor for precision agriculture applications', *IEEE Sensors Journal* **23**(19), 23713–23720.

Sim, Man Seng, Kok Yeow You, Raimi Dewan, Fahmiruddin Esa, Rozeha A Rashid & Kim Yee Lee (2024), Advances in artificial neural network assisted microwave sensors for material characterization, *em* '2024 IEEE International Conference on Advanced Telecommunication and Networking Technologies (ATNT)', IEEE, pp. 1–4.

SINGH, Kunal Kumar, Ajit Kumar Singh, Santosh Kumar Mahto, Rashmi Sinha & Ahmed Jamal Abdullah Al-Gburi (2024), 'Enhanced accuracy and high sensitivity in dielectric characterization through a compact and miniaturized metamaterial inspired microwave sensor', *Sens. Actuators A Phys.* **370**(115271), 115271.

SYED, Imran Basha, Baranidharan Sundaram & S Yuvaraj (2024), An integrated approach for nitrate and phosphate detection using squared SRR microwave resonator, *em* '2024 IEEE Applied Sensing Conference (APSCON)', IEEE, pp. 1–4.

TANGUY, Nicolas R, Benjamin Wiltshire, Mohammad Arjmand, Mohammad H Zarifi & Ning Yan (2020), 'Highly sensitive and contactless ammonia detection based on nanocomposites of phosphate-functionalized reduced graphene oxide/polyaniline immobilized on microstrip resonators', *ACS Appl. Mater. Interfaces* **12**(8), 9746–9754.

Tao, Shunzhen, Yang Gao, Bo Li, Jianrui Zhang, Min Qian & Fuzhen Xuan (2025), 'Water-based srr sensor with machine learning algorithms for simultaneous temperature and pressure detection', *IEEE Sens. J.* **25**(3), 5470–5477.

Ting, Te Meng, Nur Syazreen Ahmad & Patrick Goh (2024), 'Material classification via embedded rf antenna array and machine learning for intelligent mobile robots', *Alex. Eng. J.* **106**, 60–70.

VELEZ, Paris, Jonathan Munoz-Enano, Katia Grenier, Javier Mata-Contreras, David Dubuc & Ferran Martin (2019), 'Split ring resonator-based microwave fluidic sensors for electrolyte concentration measurements', *IEEE Sens. J.* **19**(7), 2562–2569.

WANG, C., X. Liu, Z. Huang, S. Yu, X. Yang & X. Shang (2022), 'A sensor for characterisation of liquid materials with high permittivity and high dielectric loss', *Sensors (Basel)* **22**(5), 1764–1778.

YAROSHENKO, Irina, Dmitry Kirsanov, Monika Marjanovic, Peter A Lieberzeit, Olga Korostynska, Alex Mason, Ilaria Frau & Andrey Legin (2020), 'Real-time water quality monitoring with chemical sensors', *Sensors (Basel)* **20**(12), 3432.

YE, Wei, Wen-Sheng Zhao, Jing Wang, Da-Wei Wang & Gaofeng Wang (2022), A split-ring resonator-based planar microwave sensor for microfluidic applications, *em* '2022 IEEE MTT-S International Microwave Biomedical Conference (IMBioC)', IEEE.

YEE, S K, N T J Ong, S C J Lim, N S Mohd Zin, S H Dahlan, A Y I Ashyap & C F Soon (2021), 'Microwave sensing of ammonia and iron concentration in water based on complementary double split-ring resonator', *Sens. Actuators Rep.* **3**(100044), 100044.

YONG, Jinglei, Xingli He, Lingfeng Li, Peng Li & Yunjing Zhang (2024), Multi-resonant non-intrusive microwave sensor for liquid identification with high accuracy, *em* '2024 Photonics & Electromagnetics Research Symposium (PIERS)', IEEE, pp. 1–6.

YOO, Minyeong, Hyung Ki Kim & Sungjoon Lim (2016), 'Electromagnetic-based ethanol chemical sensor using metamaterial absorber', *Sensors and Actuators B: Chemical* **222**, 173–180.

ZHANG, Kunyi, Reza K Amineh, Ziqian Dong & David Nadler (2019), 'Microwave sensing of water quality', *IEEE Access* **7**, 69481–69493.

ZIDANE, M. A., A. Rouane, C. Hamouda & H. Amar (2021), 'Hyper-sensitive microwave sensor based on split ring resonator (srr) for glucose measurement in water', *Sensors and Actuators A: Physical* **321**, 112601–112612.