

TÍTULO

SENSOR RESSONANTE DE MICRO-ONDAS APLICADO NA CARACTERIZAÇÃO DIELÉTRICA DE MISTURAS ETANOL-GASOLINA.

Ricarte Domingos Ferreira Júnior¹ (IC), Diego Camilo Tami López (PQ)¹

¹ Universidade Federal de Itajubá - Campus Itabira

Palavras-chave: Sensor de micro-ondas, Combustíveis líquidos, Etanol, Gasolina, rede neural artificial, medição não invasiva.

Introdução

O presente estudo tem como objetivo o desenvolvimento de um sensor ressonante de microfita (*microstrip*) para identificação e estimativa do volume de líquidos, em especial misturas de etanol e gasolina, sem contato direto com a amostra. A proposta baseia-se na análise do comportamento eletromagnético do sensor por meio de simulações realizadas no software COMSOL Multiphysics, cujos resultados são posteriormente utilizados como entrada em uma rede neural artificial (RNA).

A motivação deste estudo está no fato de que, apesar da ampla utilização do etanol e da gasolina como combustíveis no Brasil, ainda existem desafios no controle de qualidade, especialmente devido à adulteração e à manipulação indevida das proporções (Puppim de Oliveira, 2002), (RAKOPOULOS et al., 2010). Métodos laboratoriais convencionais, como espectroscopia e cromatografia, embora precisos, apresentam custo elevado e baixa aplicabilidade em campo.

Nesse contexto, sensores de micro-ondas surgem como uma alternativa promissora, permitindo análises rápidas, não invasivas e de baixo custo. Pesquisas recentes têm demonstrado o potencial de integrar sensoriamento por micro-ondas a técnicas de aprendizado de máquina, alcançando resultados de alta precisão. No entanto, ainda há lacunas quanto ao desenvolvimento de soluções robustas, sem contato direto, capazes de diferenciar com precisão misturas complexas como Hosseini, Baghelani e Daneshmand (2020), Baghelani, Hosseini e Daneshmand (2021).

Metodologia

O sensor proposto consiste em uma linha de microfita com duas portas (entrada e saída) acoplada a um anel ressonante centralizado, alimentada por linha de 50Ω sobre substrato FR-4 ($\epsilon_r = 4.4$, $\tan \delta = 0.02$, $h = 1.6 \text{ mm}$) (POZAR, 2012). Nesse contexto, Z_0 representa a impedância característica da linha, ϵ_r a permissividade relativa do substrato, σ a condutividade do condutor metálico e S_{21} o parâmetro de transmissão entre as portas do dispositivo. O sensor foi projetado para operar em uma frequência de 2 GHz. As dimensões do dispositivo foram obtidas a partir de uma geometria previamente desenvolvida para detecção de combustíveis e posteriormente adaptadas para o substrato FR-4.




Figura 1:

Geometria sensor.

Fonte: Autoria própria (2025).

Tabela 1: Parâmetros utilizados no sensor

Variável	Valor
L	60 mm
H	66 mm
e	1,9 mm
f	1 mm
p	0,5 mm
B	8,05 mm
C	14,6 mm

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

As simulações do sensor visto na Figura 1 foram realizadas no *COMSOL Multiphysics* (RF Module), utilizando o Método dos Elementos Finitos (FEM) para resolver as equações de Maxwell especificadas pelos parâmetros da Tabela 1. Camadas perfeitamente casadas (*Perfectly Matched Layer – PML*) foram aplicadas nas fronteiras para minimizar reflexões indesejadas. O sensor foi avaliado inicialmente em espaço livre e, em seguida, com diferentes amostras dielétricas (ELLISON, 2007).

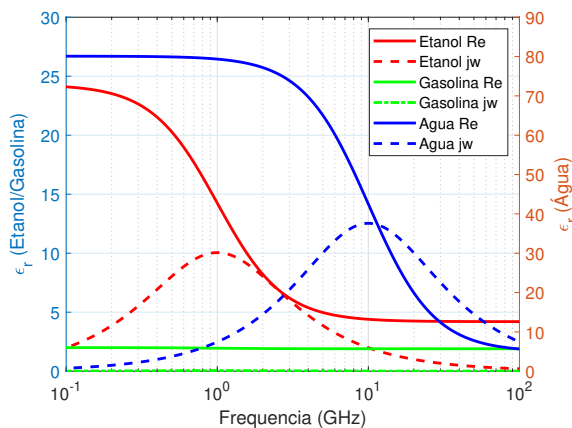


Figura 2: Curva de permissividade relativa complexa etanol e gasolina.

Fonte: Autoria própria (2025).

A resposta dielétrica dos materiais foi representada pelo modelo de Debye, visto na Figura 2, amplamente utilizado para substâncias polares. Foram considerados dois líquidos: etanol (polar, com perdas moderadas), gasolina (não polar, com baixas perdas) e água (altamente polar, com elevadas perdas dielétricas). A água apresenta uma constante dielétrica muito maior que a do etanol, o que se reflete em um deslocamento significativo da parte real da permissividade e em perdas mais acentuadas na parte imaginária, especialmente em frequências de micro-ondas. Nesse contexto, o termo Re refere-se à parte real da permissividade complexa, associada à capacidade de armazenamento de energia elétrica no meio, enquanto $j\omega$ expressa a dependência com a frequência angular ($\omega = 2\pi f$), representando o comportamento dispersivo e as perdas dielétricas do material. (MULEY; BOLDOR, 2013).




Figura 3:

Sensor e container de misturas.

Fonte: Autoria própria (2025).

Para maior realismo, as amostras foram inseridas em um recipiente de vidro borossilicato Figura 3, material de baixa permissividade e alta transparência eletromagnética. O recipiente foi projetado para comportar 150 mL, mas utilizou-se um volume de 50 mL nas simulações ao qual foram utilizadas as dimensões de 35mm de raio e 85 mm de altura contendo 1 mm de espessura.

Foram analisadas as curvas S_{21} para: (i) recipiente vazio, (ii) etanol puro, (iii) gasolina pura e (iv) misturas etanol–gasolina em diferentes proporções (50/50, 75/25 e 25/75). Além da composição, a distância sensor–amostra foi variada entre 1 e 6 mm, permitindo verificar a robustez frente a mudanças de posicionamento. Os deslocamentos de frequência e as variações de amplitude observados nas curvas fornecem informações discriminativas para o estágio de aprendizado de máquina.

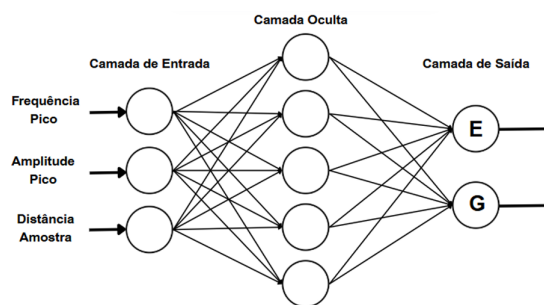


Figura 4:

Exemplo mlp.

Fonte: Autoria própria (2025).

A classificação e estimativa das misturas foram realizadas com uma rede neural perceptron multicamada (MLP) visto na Figura 4, composta por uma camada oculta com 10 neurônios e função de ativação sigmoide. A rede possui três entradas: (i) distância sensor–amostra (mm), (ii) frequência do primeiro pico ressonante (GHz) e (iii) amplitude do

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

pico (S_{21} em dB). A saída é composta por duas unidades, correspondendo às proporções estimadas de gasolina e etanol (%).

Foram geradas 30 amostras de treinamento, combinando concentrações (100% gasolina, 100% etanol, 50/50, 75/25 e 25/75) e diferentes distâncias sensor–amostra. As características extraídas das curvas S_{21} foram utilizadas como entrada, enquanto as proporções reais de cada mistura constituíram os rótulos. O treinamento da rede foi conduzido pelo algoritmo de retropropagação, minimizando o erro entre as saídas previstas e os valores reais.

Resultados e discussão

Inicialmente, considerando as diferentes respostas obtidas para os materiais puros, observa-se a diferença entre eles quando aplicados ao container a uma distância fixa de 1 mm em relação ao sensor. A distância sensor–amostra foi variada entre 1 e 6 mm, e verificou-se que essa variação impacta diretamente a posição e a intensidade do pico harmônico nos gráficos de S_{21} . Entre as distâncias analisadas, o valor de 1 mm foi escolhido como referência, justamente por apresentar a menor variação entre as curvas, garantindo maior confiabilidade na diferenciação das amostras.




Figura 5: Curvas container vazio, gasolina e etanol. Fonte: Autoria própria (2025).

Como mostrado na Figura 5, as curvas apresentam comportamento semelhante em termos de tendência geral, mas revelam diferenças significativas entre as respostas obtidas para o etanol e para

a gasolina no contêiner. A inclusão da curva correspondente ao contêiner vazio evidencia de forma mais clara as variações em relação ao recipiente sem amostra.

Realizou-se uma nova etapa de simulação incluindo variações nos volumes das misturas, a fim de avaliar a resposta do sensor a composições intermediárias. As substâncias previamente simuladas em isolamento (etanol puro e gasolina pura) foram combinadas em diferentes proporções. A Figura 6 apresenta os resultados dessas novas condições, incluindo misturas balanceadas (50% etanol e 50% gasolina), bem como misturas assimétricas com até 75% de um dos componentes.

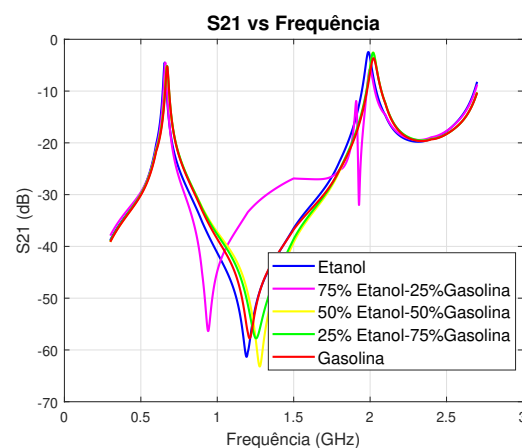


Figura 6: Curvas diferente misturas entre combustíveis.

Fonte: Autoria própria (2025).

Observa-se que as variações no perfil da resposta em frequência permitem distinguir as proporções das misturas, evidenciando a sensibilidade do sensor às diferenças nas propriedades dielétricas dos materiais analisados.

É importante destacar que as proporções apresentadas na saída da rede neural derivam de valores probabilísticos, e não de uma decomposição determinística com soma exata de 100%. Dessa forma, pequenas variações na soma total são esperadas e não comprometem a análise. A Tabela 2 apresenta os resultados obtidos para diferentes composições de amostras, considerando uma distância fixa entre o recipiente e o sensor, o que garante consistência nas medições.

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

Tabela 2: Resultados da rede neural para predição de concentração.

Gasolina Real (%)	Gasolina Prevista (%)	Erro (%)	Etanol Real (%)	Etanol Previsto (%)	Erro (%)
100	97.81	2.19	0	2.19	2.19
0	0.09	0.09	100	99.91	0.09
50	49.66	0.34	50	51.02	1.02
75	76.87	1.87	25	23.52	1.48
25	22.98	2.02	75	78.02	3.02

Conclusões

Os resultados obtidos demonstram que o sensor baseado em microfita apresenta boa sensibilidade à variação das propriedades dielétricas de líquidos como etanol, gasolina e suas misturas. A análise dos picos de ressonância permitiu a extração de características relevantes para o treinamento de uma rede neural, a qual obteve bom desempenho na identificação e estimativa das proporções dos materiais. O modelo apresentou baixos erros mesmo em composições mistas, destacando seu potencial para aplicações práticas na caracterização de líquidos utilizando técnicas de radiofrequência.

Vale destacar que as interações entre líquidos estão diretamente relacionadas à polaridade de suas moléculas. Substâncias polares, como água e etanol, tendem a se misturar entre si, enquanto substâncias apolares, como a gasolina, não se misturam facilmente com líquidos polares. Por esse motivo, por exemplo, água e gasolina não formam uma solução homogênea, o que afeta diretamente as propriedades dielétricas das misturas e, consequentemente, a resposta do sensor.

Agradecimentos

Este trabalho foi financiado pelas agências brasileiras CNPq (Processo nº 125895/2025-9) e CAPES. Os autores também agradecem à Universidade Federal de Itajubá (UNIFEI), à Universidade Federal de Minas Gerais (UFMG) e ao Prof. Gilberto Me-deiros Ribeiro pelo apoio e contribuições.

Referências

- J. A. Puppim de Oliveira, “The policymaking process for creating competitive assets for the use of biomass energy: The Brazilian alcohol programme,” *Renew. Sustain. Energy Rev.*, vol. 6, no. 1, pp. 129–140, 2002.
- D. C. Rakopoulos, C. D. Rakopoulos, D. T. Hountalas, E. C. Kakaras, E. G. Giakoumis, and R. G. Papagiannakis, “Investigation of the performance and emissions of bus engine operating on butanol/diesel fuel blends,” *Fuel*, vol. 89, no. 10, pp. 2781–2790, 2010.
- D. M. Pozar, *Microwaves and Microwave Systems*, 4th ed. São Paulo, Brazil: Bookman, 2012.
- N. Hosseini, M. Baghelani, and M. Daneshmand, “Selective volume fraction sensing using resonant-based microwave sensor and its harmonics,” *IEEE Trans. Microw. Theory Techn.*, vol. 68, no. 9, pp. 3958–3968, Sept. 2020.
- M. Baghelani, N. Hosseini, and M. Daneshmand, “Artificial intelligence assisted noncontact microwave sensor for multivariable biofuel analysis,” *IEEE Trans. Ind. Electron.*, vol. 68, no. 11, pp. 11492–11500, Nov. 2021.
- COMSOL AB, *COMSOL Multiphysics*® v6.2, Stockholm, Sweden: COMSOL Inc., 2024. [Online]. Available: <www.comsol.com>
- P. D. Muley and D. Boldor, “Investigation of microwave dielectric properties of biodiesel components,” *Bioresour. Technol.*, vol. 127, pp. 165–174, Jan. 2013.
- W. Ellison, “Permittivity of pure water, at standard atmospheric pressure, over the frequency range 0–25 THz and the temperature range 0–100 °C,” *J. Phys. Chem. Ref. Data*, vol. 36, p. 1, Mar. 2007, doi: 10.1063/1.2360986.