

PREDIÇÃO DE CAMPOS ELETROMAGNÉTICOS UTILIZANDO IA

Arthur N. Interaminense (IFPB, Campus João Pessoa)

Glênio K. S. Nóbrega (IFPB, Campus João Pessoa)

Edvaldo S. Pires (IFPB, Campus João Pessoa)

Emails: Arthur.interaminense@academico.ifpb.edu.br, glenio.kewy@academico.ifpb.edu.br, edvaldo.pires@ifpb.edu.br.

Área de conhecimento (Tabela CNPq): 3.04.06.03-0 Sistemas de Telecomunicações.

Palavras-chave: Inteligência artificial; regressão linear; campo eletromagnético; predição; python.

1. Introdução

Diante da crescente demanda por conexões Wi-Fi de qualidade em ambientes internos, este trabalho apresenta o desenvolvimento de uma inteligência artificial capaz de prever a qualidade do sinal Wi-Fi com base em parâmetros como distância do roteador, altura da instalação e potência de transmissão. O modelo foi desenvolvido em Python, utilizando scikit-learn e PyTorch, baseado em regressão linear com gradiente descendente. A aplicação possui uma interface interativa criada com Streamlit, permitindo que os usuários insiram os parâmetros e obtenham rapidamente estimativas da qualidade do sinal, auxiliando no planejamento e na otimização de redes Wi-Fi em ambientes confinados. A escolha por roteadores TP-Link, para as medidas de sinal, também se baseou em análises atualizadas de mercado, destacando modelos com melhor desempenho para 2025 (Nóbrega, 2014).

2. Materiais e métodos

O trabalho validou um algoritmo de regressão linear com gradiente descendente utilizando uma base de dados pública contendo informações construtivas de veículos, como consumo de combustível, tamanho do motor, número de cilindros e emissão de CO₂ (Almeida, 2014). Para a validação do algoritmo foram selecionadas três variáveis independentes — consumo combinado, tamanho do motor e número de cilindros — para prever a emissão de CO₂, com base em estratégias comprovadas de predição com regressão linear múltipla. Os dados foram normalizados com a biblioteca Scikit-learn e processados com PyTorch, utilizando um modelo linear simples (com uma entrada e uma saída), treinado com MSE Loss e o otimizador SGD (taxa de aprendizado 0,01) ao longo de 1000 épocas, onde o resultado é apresentado no gráfico 1. Durante o treinamento, foram plotados gráficos com a evolução da função de custo e a reta de regressão. Estratégias relacionadas à escolha e ajuste da taxa de aprendizado foram consideradas com base em estudos sobre aceleração do gradiente descendente. O modelo demonstrou boa capacidade preditiva: por exemplo, para um veículo com motor 2.0, 4 cilindros e consumo de 8,5 km/L, a predição foi de 198,2 g/km de CO₂, próxima ao valor real de 196 g/km, como é mostrado na base pública de dados disponibilizada no Github. Também foi realizada uma validação experimental com medições de intensidade de sinal Wi-Fi usando dois roteadores TP-Link em diferentes distâncias e potências, observando a degradação do sinal em função da distância e obstáculos. O modelo foi testado com os dados de potência, altura e distância. A aplicação foi disponibilizada por meio da biblioteca Streamlit, permitindo que usuários acessem o modelo pela web e façam predições inserindo parâmetros diretamente na interface interativa hospedada na nuvem, podendo ser conferido através do QR Code na figura 2 e no link disponível nas referências.

2.1 Modelo de equação

A equação 1 calcula a regressão linear que tem como objetivo encontrar a relação linear entre as variáveis de entrada (x) e a variável de saída (y), sendo representada da seguinte maneira:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon \quad (1)$$

Onde, y é a variável dependente (qualidade do sinal), x_n são as variáveis independentes (distância, altura e potência.), β_n são os coeficientes da regressão e ϵ é o erro aleatório. A equação 2 calcula o ajuste dos coeficientes utilizando o método de gradiente descendente, que busca minimizar a função de custo $J(\beta)$, representada pelo erro quadrático médio:

$$J(\beta) = \frac{1}{2m} \sum_{i=1}^m \left(h_{\beta}(x^{(i)}) - y^{(i)} \right)^2 \quad (2)$$

A equação 3 é responsável pela atualização dos coeficientes, da seguinte forma:

$$\beta_j := \beta_j - \alpha \frac{\partial J(\beta)}{\partial \beta_j} \quad (3)$$


Onde, α é a taxa de aprendizado e $\alpha \frac{\partial J(\beta)}{\partial \beta_j}$ representa a derivada parcial da função de custo em relação a cada coeficiente.

3. Resultados e discussão

Os resultados obtidos estão alinhados com o que é discutido na literatura sobre regressão linear e otimização via gradiente descendente, demonstrando que, mesmo com modelos simples, é possível obter previsões precisas de variáveis contínuas. A utilização das bibliotecas Python, como scikit-learn e PyTorch, foi fundamental tanto na normalização dos dados quanto na construção e no treinamento do modelo (Oliveira, 2021). A IA desenvolvida apresentou resultados plausíveis na base experimental de intensidade de campos eletromagnéticos, exibido no gráfico 2, validando sua aplicação prática na previsão da qualidade do sinal Wi-Fi. Além disso, a integração com Streamlit e GitHub viabilizou a criação de uma interface web interativa, como mostra a figura 1, facilitando o acesso e a utilização do modelo de forma remota, intuitiva e eficiente (Sageerkaifi, 2025). Entre os resultados obtidos, destaca-se a previsão de perda de sinal de -42,69 dBm para um ponto de medição com distância de 60 centímetros, altura de instalação de 1 metro e potência de transmissão de 100 mW, retirado da tabela 1, enquanto o valor medido registrado na medição experimental foi de -40 dBm, evidenciando a proximidade entre os valores estimado e medido (Arthur, 2025). Além desse exemplo, foram realizadas diversas outras comparações entre os valores preditos e os valores medidos, que confirmaram a boa capacidade do modelo em aprender os padrões presentes nos dados. Essa aderência foi verificada em diferentes cenários com variações das distâncias e potências de transmissão, nos quais o modelo conseguiu representar com boa precisão a relação entre distância, potência e atenuação do sinal. Esses resultados reforçam a robustez da abordagem adotada, baseada em regressão linear com gradiente descendente, e comprovam que as ferramentas utilizadas foram eficazes tanto no desenvolvimento quanto na validação da inteligência artificial proposta. Vale destacar que os resultados obtidos até o momento são preliminares e novas interações do modelo poderão aprimorar ainda mais a acurácia das previsões. O código está retornando valores positivos, no entanto a leitura é feita como se os valores fossem negativos por se tratar da perda da potência do sinal em dBm.

3.1 Figuras

Figura 1 - Interface Streamlit



Fonte: Autoria própria (2025)

Figura 2 - QR Code para acesso da interface



Fonte - Autoria própria

3.2 Gráficos

Gráfico 1 – Reta de regressão após mil épocas



Fonte: Autoria própria (2025)

3.3 Tabelas

Tabela 1 - Trecho do dataset com valores medidos em laboratório

Roteador	Distância (cm)	Campo (dbm)	Altura (cm)	Potência (mW)
TP-LINK 62B04C	60	34	100	100
TP-LINK EC230-G1	60	32	100	300
TP-LINK EC230-G1	120	33	100	300
TP-LINK EC230-G1	180	35	100	300
TP-LINK 62B04C	120	38	100	100
TP-LINK 62B04C	180	44	100	100

Fonte - Autoria própria (2025)

4. Considerações finais

O projeto apresentou resultados satisfatórios, demonstrando que a inteligência artificial desenvolvida foi capaz de realizar previsões com boa precisão em relação aos valores medidos. Tanto na base de dados de emissão de CO₂ quanto na base de intensidade de campo eletromagnético, obtido por meio de medições em laboratório, os resultados previstos se mostraram plausíveis e próximos dos valores medidos. Isso evidencia a eficácia do modelo de regressão linear com gradiente descendente na previsão de variáveis com valores reais, validando sua aplicação em diferentes contextos e conjuntos de dados. Vale ressaltar que durante a apresentação no dia da mostra de projetos, um QR code será disponibilizado para que os ouvintes possam testar a interface intuitiva em tempo real, e, se desejável, testar a conexão dos dispositivos em suas casas.

Agradecimentos

Agradecemos ao CNPq e ao programa PIBIC pelo apoio e incentivo à pesquisa, bem como ao Instituto Federal da Paraíba (IFPB) por fornecer a estrutura necessária para o desenvolvimento deste projeto. Estendemos também nosso agradecimento ao SIMPIF pela oportunidade de apresentar e compartilhar os resultados deste trabalho com a comunidade acadêmica.

Referências

ALMEIDA, Humberto Moreira de. *Análise de regressão linear múltipla com estudo relacionado a horas de máquinas paradas na linha de produção de uma indústria de calçados*. 2014. Trabalho de Conclusão de Curso (Graduação em Estatística) – Universidade Estadual da Paraíba, Campina Grande, 2014.

ARTHUR; EDVALDO; GLENIO. *Preditor de Campos Eletromagnéticos*. Disponível em: <https://preditorcamposeletromagneticos.streamlit.app>. Acesso em: 9 jun. 2025.

NÓBREGA, Caio Santos Bezerra. *Uma estratégia para previsão da taxa de aprendizagem do gradiente descendente para aceleração da fatoração de matrizes*. 2014. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Campina Grande, Campina Grande, 2014.

OLIVEIRA, Leandro Nunes de; SILVA, André de Souza. *Aplicações de bibliotecas Python em ciência de dados: uma revisão sistemática*. Revista Brasileira de Computação Aplicada, v. 13, n. 1, p. 45–62, 2021. Disponível em: <https://revistas.unifacs.br/index.php/rbca/article/view/8350>. Acesso em: 09 jun. 2025.

SAGEERKAIFI. *CO2 Emissions by Vehicles — Dataset*. GitHub. Disponível em: https://github.com/sageerkaifi/Co2_emission-by-vehicles/blob/main/CO2%20Emissions_Canada.csv. Acesso em: 4 jun. 2025.