

# IQArMobi: Classificação Inteligente da Qualidade do Ar e Ciente de Localização em Ambientes Externos e Internos

Eusébio Thaylor<sup>1</sup>, Nandson Cunha<sup>1</sup>, Alife Moraes<sup>1</sup>, Warley Junior<sup>1</sup>, Elton Alves<sup>2</sup>

<sup>1</sup>Faculdade de Sistemas de Informação  
Universidade Federal do Sul e Sudeste do Pará, Marabá, PA - Brasil

<sup>2</sup>Faculdade de Engenharia da Computação  
Universidade Federal do Sul e Sudeste do Pará, Marabá, PA - Brasil

{eusebio.jadjiski,nandsoncunha,alife.silva,wmvj}@unifesspa.edu.br

**Abstract.** Air pollution, driven by urban, industrial, and agricultural growth, has negatively impacted human health, biodiversity, and the environment, demanding effective monitoring solutions. Faced with this challenge, this work proposes an intelligent solution, called IQArMobi, which combines machine learning algorithms and distance calculation to classify the Air Quality Index (AQI) based on IoT sensor data, providing accurate and personalized information to users. As the main result, the Logistic Regression algorithm stood out as the best classifier, with 99% accuracy, followed by Random Forest (96%), validating the effectiveness of this solution in real-time decision-making.

**Resumo.** A poluição atmosférica, impulsionada pelo crescimento urbano, industrial e agrícola, tem impactado negativamente a saúde humana, a biodiversidade e o meio ambiente, exigindo soluções eficazes de monitoramento. Diante desse desafio, este trabalho propõe uma solução inteligente, denominada IQArMobi, que combina algoritmos de aprendizado de máquina e cálculo de distância para classificar o Índice de Qualidade do Ar (IQAr) com base em dados de sensores IoT, fornecendo informações precisas e personalizadas aos usuários. Como principal resultado, o algoritmo Logistic Regression destacou-se como o melhor classificador, com 99% de acurácia, seguido pelo Random Forest (96%), validando a eficácia desta solução na tomada de decisões em tempo real.

## 1. Introdução

A poluição atmosférica é um grave problema enfrentado pelo Brasil e por muitos outros países ao redor do mundo. Com o crescimento urbano, industrial e agrícola, as concentrações de poluentes no ar têm aumentado significativamente, gerando impactos negativos na saúde humana, na biodiversidade e no meio ambiente como um todo. As principais fontes de poluição atmosférica no Brasil incluem veículos automotores, indústrias, queimadas, emissões de resíduos agrícolas e desmatamento. Esses poluentes, como partículas finas, óxidos de nitrogênio, óxidos de enxofre e compostos orgânicos voláteis, podem causar doenças respiratórias, cardiovasculares e até mesmo câncer, além de contribuir para o aquecimento global e a degradação da camada de ozônio. Diante desse cenário preocupante, é fundamental adotar medidas eficazes de monitoramento e controle da poluição atmosférica para proteger a saúde pública [Wallbanks et al. 2024].

Em resposta aos problemas mencionados anteriormente, o uso de algoritmos de classificação de aprendizado de máquina para classificar o Índice da Qualidade do Ar (IQAr) combinado com dispositivos de Internet das Coisas (IoT - *Internet of Things*) permite um monitoramento mais preciso e dinâmico da poluição atmosférica. Ao integrar sensores distribuídos em diferentes locais, o sistema pode analisar grandes volumes de dados em tempo real, classificando a qualidade do ar com maior precisão. Além disso, ao considerar a proximidade do usuário em relação ao sensor mais próximo, as previsões se tornam mais relevantes e personalizadas para cada local específico. Essa abordagem melhora a tomada de decisão para autoridades ambientais e indivíduos, permitindo ações preventivas mais eficazes contra os impactos da poluição [Imam et al. 2024].

Em face do contexto apresentado, o objetivo deste trabalho é apresentar o IQAr-Mobi, uma solução inteligente que faz uso de algoritmos de aprendizagem de máquina para classificar o IQAr em conjunto com algoritmo de cálculo de distância para um sensor de monitoramento de poluentes atmosféricos de modo a emitir dados mais precisos que sejam relevantes para o usuário interessado. Esta solução foi avaliada a partir de duas perspectivas, sendo a primeira, baseada em uma metodologia que faz uso de um banco de dados real de poluentes capturados em ambientes internos e externos, para etapas de pré-processamento e avaliação de desempenho dos algoritmos *Random Forest*, *Gradient Boosting*, *Support Vector Machine* e *Logistic Regression*, e a segunda, em experimentos envolvendo mobilidade do dispositivo móvel para avaliar a decisão em tempo real do IQArMobi quando se tem sensores instalados em locais abertos e fechados.

O restante deste artigo está organizado da seguinte forma: Os trabalhos relacionados são discutidos na Seção 2. Na seção 3 é apresentado a arquitetura geral da proposta e algoritmo de cálculo de distância para os sensores. A seção 4 apresenta a avaliação de desempenho desta solução. Finalmente, a seção 5 conclui o artigo e aponta direções futuras que podem ser consideradas.

## 2. Trabalhos Relacionados

A Tabela 1 sintetiza a contribuição dos trabalhos mais promissores relacionados a esta pesquisa. Estas referências são categorizadas em cinco aspectos: objetivo geral, plataforma de execução, ciente de localização, validação da proposta em ambiente interno e externo, e algoritmos de aprendizagem de máquina.

Objetivo geral (C1), define a principal contribuição da solução quanto a temática de monitoramento, predição e classificação da qualidade do ar. Os trabalhos referenciados em [Kumar and Pande 2023, Imam et al. 2024, Mottahedin et al. 2024, Schürholz et al. 2020, Rastogi and Lohani 2022] tratam de soluções de aprendizagem de máquina e de aprendizagem profunda para garantir a previsão do IQAr em diferentes regiões tal como, cidades da Índia, Irã e Austrália. Porém, todas estas soluções limitam-se a utilizar metodologias relacionadas a coleta, pré-processamento e avaliação de desempenhos dos algoritmos de predição. Similar ao IQArMobi, os trabalhos de [Kumar and Doss 2023, Serdaroglu et al. 2023] propõem soluções de monitoramento da qualidade do ar baseados em IoT com infraestrutura de nuvem e *fog* para processamento massivo.

Ciente de localização (C2), define se a solução desenvolveu técnicas, algoritmos ou outra estratégia para mensurar a qualidade do ar de acordo com a localização atual do

usuário. Os únicos trabalhos que consideram a localização como critério para aumentar o desempenho e precisão de emissão de informações relacionadas a poluentes atmosféricos são os referenciados em [Serdaroglu et al. 2023, Schürholz et al. 2020]. O diferencial do IQArMobi em relação a estas soluções, é a aplicação do algoritmo de cálculo de distância (veja a seção 3.2) que considera a localidade atual do dispositivo móvel e do sensor mais próximo do mesmo.

Validação da proposta em ambiente interno e externo (C3), define se a solução fez avaliação de monitoramento da qualidade do ar envolvendo mobilidade em ambientes internos e externos. Na proposta de [Rastogi and Lohani 2022], o modelo preditor desenvolvido considera dados de poluentes de ambientes internos para compor um novo estado do ar interior, limitando-se a somente estes ambientes. Como pode ser percebido na Tabela 1, o IQArMobi é a única solução que faz monitoramento inteligente em ambientes externos e internos mesmo quando o usuário está em movimento.

Algoritmos de aprendizagem de máquina (C4), refere-se a quais algoritmos de predição ou classificação foram usado no estudo. Dentre o conjunto de algoritmos de predição utilizados, podemos destacar aqueles que tiveram o melhor desempenho para o banco de dados pela qual foram treinados. Por exemplo, em [Kumar and Pande 2023] o modelo *Gaussian Naive Bayes* (GNB) atingiu a maior acurácia, enquanto que o modelo *XGBoost* (XGB) apresenta o melhor desempenho geral ao atingir os valores ideais nas fases de treinamento e teste. Em [Imam et al. 2024], os modelos *Support Vector Machine* (SVM) e *Random Forest Classifier* (RFC) obtiveram as maiores acurácias em seus respectivos banco de dados. Já em [Mottahedin et al. 2024, Rastogi and Lohani 2022], o modelo *Adaptive Neuro-Fuzzy Inference System* (ANFIS) mostrou-se ser de alta confiabilidade em uma diversidade maior de banco de dados de poluentes atmosféricos.

**Tabela 1. Tabela comparativa dos trabalhos relacionados com a proposta.**

Solução	C1	C2	C3	C4
[Kumar and Pande 2023]	Predição	✗	✗	KNN, GNB, SVM, RF e XGB
[Imam et al. 2024]	Predição	✗	✗	LR, DTC, RFC, SVM e NB
[Kumar and Doss 2023]	Monitoramento e Predição	✗	✗	CNN-Bi-LSTM
[Serdaroglu et al. 2023]	Monitoramento	✓	✗	Não Aplicável
[Mottahedin et al. 2024]	Predição	✗	✗	RF, M5P, RT, MP, LR e ANFIS
[Schürholz et al. 2020]	Predição	✓	✗	LSTM
[Rastogi and Lohani 2022]	Predição	✗	✗	ANFIS e DTMC
<b>IQArMobi</b>	<b>Monitoramento e Classificação</b>	<b>✓</b>	<b>✓</b>	<b>GBC, LR, RFC e SVM</b>

Em resumo, a principal contribuição da proposta, que diferencia dos trabalhos mencionados anteriormente é sua capacidade de monitoramento e classificação do IQAr em tempo real através de modelo de aprendizagem de máquina e que ao mesmo tempo considera a localidade atual tanto em ambientes externos, quanto internos.

### 3. IQArMobi

Detalhes da arquitetura da solução proposta é referenciada em [Cunha et al. 2024] de modo a descrever as camadas de coleta, roteamento e processamento dos dados referente aos poluentes atmosféricos. A seção a seguir destaca as melhorias nesta arquitetura,

com a criação dos módulos de classificação e cálculo de distância, bem como o banco de dados histórico dos poluentes atmosféricos e respectivo IQAr.

3.1. Arquitetura proposta

De acordo com a Figura 1 o IQArMobi esta dividido em três grandes partes: (i) coleta de dados relacionados a poluentes atmosféricos; (ii) roteamento destes dados para uma plataforma de middleware em uma *cloudlet*; (iii) aplicativo móvel para configuração e visualização pelos usuários interessados.

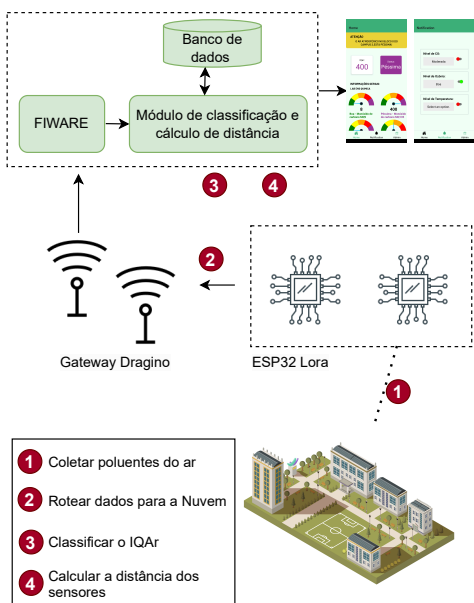


Figura 1. Arquitetura funcional do IQArMobi.

_id	00246a14-818
_rev	1-b5f9b7e223
roomRef	Corredor IESB
joined	12/04/24,17:13
LPG_MQ9_Level	2.91
CH4_MQ9_Level	3.62
CO_MQ9_Level	1.49
CO_MQ135_Level	0.67
Alcool_MQ135_Level	0.32
CO2_MQ135_Level	0.79
Toluen_MQ135_Level	0.12
NH3_MQ135_Level	1.43
Aceton_MQ135_Level	0.1
O3_MQ131_Level	3.86
Temperatura_Level	30.8
Humidade_Level	84
QualityAirConcept	Boa
CO_MQ9_Level_IQAR	4.4444444444
CO_MQ135_Level_IQAR	4.4444444444
O3_MQ131_Level_IQAR	1.6
CalcHeatIndex	41.610872436

Figura 2. Estrutura do arquivo com os dados dos sensores, poluentes e cálculo de IQAr.

Na primeira camada, representado pelo evento rotulado com o número (1), um microcontrolador ESP32 com interface Lora conectado a sensores de temperatura, umidade, e poluentes atmosféricos (gás ozônio (O3), monóxido de carbono (CO), metano (CH4), propano (C3H8), amônia (NH3), dióxido de carbono (CO2), benzeno (C6H6), óxido nítrico (NO), fumaça e álcool), captura dados constantemente em ambientes internos e externos, tais como salas e corredores de edifícios, e os envia por onda de rádio em vetores de *bytes* para um *gateway* dragino. O gateway possui interface LoRaWAN, que controlada pelo servidor ChirpStack, reconstrói os dados recebidos para uma mensagem em base64 e roteia-os para a *cloudlet* composta pelo *middleware* FIWARE, que é representado na figura como o evento de número (2).

Na segunda camada, rotulada com o número (3), o FIWARE gerencia novos sensores e respectivos locais (cria, atualiza, consulta), e os dados dos poluentes atmosféricos em tempo real, de modo a persistir esses dados em um banco de dados NoSQL, para

então calcular a classificação do índice de qualidade do ar (IQAr) e rotular em cinco possíveis classes (péssima, muito ruim, ruim, moderada, boa), de acordo com a resolução de [CONAMA 2024]. Em um segundo momento nomeado com o número (4), calcula-se a distância (considerando dados de longitude e latitude) do dispositivo móvel que executa o IQArMobi para um conjunto de microcontroladores de modo a selecionar a menor distância e assim considerar os dados dos sensores do microcontrolador mais próximo. Por fim, o IQArMobi é responsável pela exibição em tempo real dos dados de poluentes e resultados do cálculo do IQAr.

Para melhor exemplificar a estrutura dos dados armazenados no banco e visualizados no aplicativo, a Figura 2 apresenta um registro de medição em arquivo JSON que contém esses dados. O atributo `roomRef` recebe o valor correspondente a localidade do sensor, enquanto `joined` é registrado no formato dia/mês/ano e horas:minutos para informar a data e horário de captura destes dados.

### 3.2. Algoritmo de cálculo de distância

O algoritmo 1 calcula a distância entre o dispositivo e os sensores utilizando latitude e longitude. As coordenadas são convertidas de graus para radianos para serem usadas em cálculos trigonométricos. Em seguida, esses dados convertidos são aplicados à fórmula *haversine*, com resultado final sendo a distância entre dois pontos em metros.

---

#### Algorithm 1 Cálculo de Distância

---

**Require:** lat1, lon1, lat2, lon2: coordenadas de latitude e longitude dos dois pontos

**Ensure:** distância entre os dois pontos em metros

Definir o raio da Terra,  $R$ , como 6371 quilômetros

Converter as coordenadas de graus para radianos:

$$dLat \leftarrow (lat2 - lat1) \times \frac{\pi}{180}$$

$$dLon \leftarrow (lon2 - lon1) \times \frac{\pi}{180}$$

Calcular as diferenças entre as latitudes e longitudes em radianos

Calcular  $a$ :

$$a \leftarrow \sin^2\left(\frac{dLat}{2}\right) + \cos(lat1 \times \frac{\pi}{180}) \times \cos(lat2 \times \frac{\pi}{180}) \times \sin^2\left(\frac{dLon}{2}\right)$$

Calcular  $c$ :

$$c \leftarrow 2 \times \arctan 2(\sqrt{a}, \sqrt{1-a})$$

Calcular a distância entre os pontos:

$$distance \leftarrow R \times c \times 1000 \text{ (em metros)}$$

**return** distance (distância entre os pontos)

---


## 4. Avaliação de Desempenho

Nesta seção, apresentamos o processo de avaliação dos algoritmos de classificação e respectivos resultados, bem como o resultado do algoritmo de cálculo de distância a partir de dois cenários de mobilidade em ambientes externos e internos.

### 4.1. Resultados dos algoritmos de classificação do IQAr

O processo de avaliação é ilustrado na Figura 3. Cada etapa é descrita a seguir: Na primeira etapa, o pesquisador deve executar o IQArMobi para coletar dados dos poluentes

atmosféricos em tempo real e armazenar no banco de dados NoSQL na *cloudlet* com a respectiva rotulagem do IQAr (ex., ruim, péssimo, bom). Em nossos testes, construímos um banco de dados<sup>1</sup> com 8.549 amostras, sendo que 6.151 estavam rotulados pela classe "bom" e 2.398 rotulados pela classe "péssimo".



**Figura 3. Processo de avaliação de desempenho dos classificadores.**

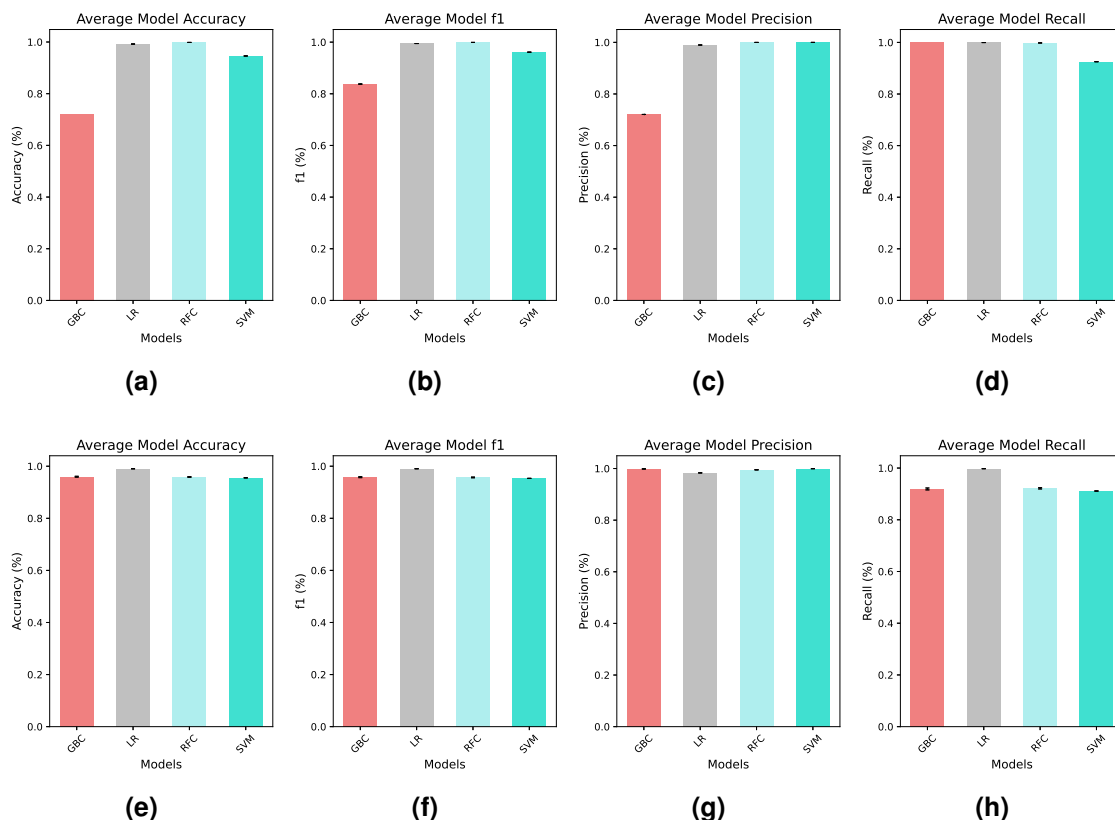
Na segunda etapa, de pré-processamento, foram realizadas três atividades: (1) **Remoção de atributos irrelevantes**, em que os atributos `_id`, `_rev`, `joined`, `roomRef`, `TargetConcept` foram eliminados por não terem importância na classificação do IQAr; (2) **Preenchimento de valores ausentes**, uma vez que haviam registros com valores nulos para alguns poluentes atmosféricos, foi aplicado a técnica de *SimpleImputer* para substituir os dados faltantes (em torno de 7.921 valores) pela média dos valores correspondentes para cada atributo do poluente; (3) **Balanceamento do banco de dados**, considerando que o banco de dados está inicialmente desbalanceado (a classe "bom" contém um número maior de amostras quando comparado a classe "péssimo") e sabendo que o desbalanceamento afeta o treinamento dos algoritmos, uma vez vão tender a aprender mais com a classe que possui um número maior de amostras, foi aplicado a técnica de *Oversampling*, ou seja, a classe minoritária se iguala, em número, às amostras da classe majoritária. Como resultado obteve-se o total de 12.302 amostras (6.151 para a classe "bom" e 6.151 para a classe "péssimo").

Na terceira etapa, é executado a avaliação de desempenho de cada algoritmo classificador através das métricas de *accuracy*, *F1*, *precision* e *recall*, sendo que 70% dos dados foram divididos para treinamento e 30% para testes (30 repetições de validação cruzada estratificada através das técnicas *05-fold cross-validation* e *random seed*). Para esta avaliação, quatro algoritmos de classificação promissores foram selecionados (*Random Forest*, *Gradient Boosting*, *Support Vector Machine* (SVM) e *Logistic Regression*). A escolha destes algoritmos se deve ao fato de terem eficiência computacional, interpretabilidade, robustez a dados ruidosos e facilidade de implementação, quando comparados a algoritmos de *deep learning*.

Foram realizadas 30 interações independentes para avaliar a metodologia. O valor do *K* utilizado no K-fold foi igual a 5. De acordo com a Figura 4, a primeira análise realizada foi sem o balanceamento das amostras. Nas Figuras 4a, 4b, 4c e 4d pode-se visualizar os resultados obtidos, com a média e o desvio padrão das iterações para cada métrica. O melhor resultado obtido foi com os algoritmos *Logistic Regression* (LR) e *Random Forest Classifier* (RFC), com a acurácia de 0.9921 (99%) e 0.9983 (99%), e F1-Score de 0.9945 e 0.9988, respectivamente. O pior resultado foi alcançado pelo algoritmo

<sup>1</sup>Segue o link do banco de dados: [https://github.com/EuJadjiski/BD\\_IQAR.git](https://github.com/EuJadjiski/BD_IQAR.git)

*Gradient Boosting Classifier* (GBC), com acurácia de 0.7205 (72%) e precisão de 0.7205, que mesmo sendo um algoritmo conhecido por sua alta precisão em uma variedade de tarefas, teve dificuldade de aprender na classe com menor número de amostras.



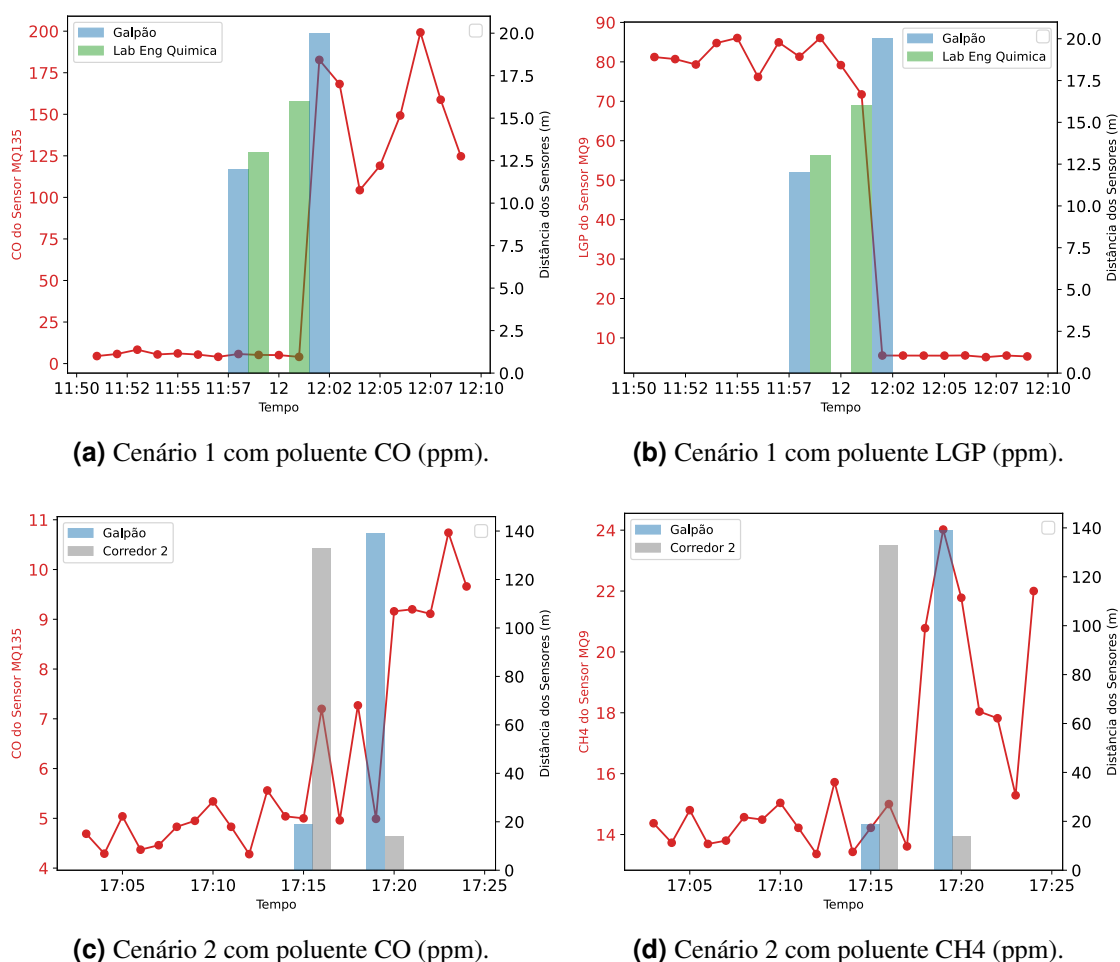
**Figura 4. Média e desvio padrão da Acurácia, Recall, F1 e Precisão para os dados desbalanceados (a-d) e balanceados (e-h).**

Na segunda análise foi utilizado o método de balanceamento, cujo objetivo é aumentar o número de amostras da menor classe (IQAr Péssimo), igualando ao número de amostras da maior classe (IQAr Bom). As Figuras 4e, 4f, 4g e 4h apresentam os resultados obtidos, com a média e o desvio padrão das 30 iterações para cada métrica. O algoritmo que obteve o melhor resultado foi o LR com acurácia, F1-Score e recall de 0.9903 (99%), 0.9903 e 0.9976, respectivamente. Este resultado revela que o LR mostra um nível de concordância substancial dos resultados e capacidade de lidar com dados desbalanceados. O GBC também apresentou um bom resultado, com uma acurácia de 0.9597 (95%), ou seja, sua proporção de acertos em relação às classes aumentou se comparado a base de dados desbalanceada.

#### 4.2. Resultados do algoritmo de cálculo de distância

O local definido para avaliação da proposta foi em um campus universitário, onde reside como unidade o Instituto de Geociências e Engenharias. Esta unidade é composta por diversos laboratórios dos cursos de engenharias (química, mecânica, civil) e de computação. Assim, foram selecionados três locais para alocação dos sensores e medição: (1) galpão de laboratórios (nomeado como *galpão*) é uma área ampla e fechada que acomoda

salas de professores, técnicos e diversos laboratórios para cada curso; (2) laboratório de engenharia química (nomeado como *lab. eng. química*) é um espaço fechado de pouca metragem e está dentro do galpão; e (3) corredor do prédio do bloco 2 (nomeado como *corredor 2*) é um espaço aberto que permite a circulação de alunos que entram e saem dos prédios de sala de aula.



**Figura 5. Resultados correspondente aos poluentes e cálculo de distância.**

Os experimentos de mobilidade para avaliar a decisão do IQArMobi durante o monitoramento e respectiva classificação esta dividido em dois cenários:

1. O usuário caminha a uma velocidade de 1,2m/s em direção ao galpão e entrando nele, vai em direção ao laboratório de engenharia química. Neste cenário, o usuário optou por monitorar o monóxido de carbono (CO) e gás de cozinha (LGP).
2. O usuário caminha a uma velocidade de 1,2m/s saindo do galpão em direção ao corredor do prédio do bloco 2. Neste cenário, o usuário optou por monitorar monóxido de carbono (CO) e metano (CH<sub>4</sub>).

De acordo com a Figura 5, em todos os gráficos, no *eixo y* encontram-se os níveis de captação do gás de um sensor em partes por milhão (ppm), no *eixo x* está a variação do tempo em horas e minutos, e no *eixo z* contém a distância em metros (m) do dispositivo



móvel para um sensor. Quanto menor for a distância de um sensor, mais próximo o usuário está do mesmo, logo, seus dados de captação serão mostrados.

Conforme ilustrado na Figura 5a no cenário 1, no momento em que o usuário se aproxima do sensor do galpão, percebe-se que o nível de monóxido de carbono (CO) está abaixo de 25ppm (em torno de 11 a 13ppm) o que pelo IQAr é classificada como ruim. Neste mesmo instante de tempo, o algoritmo de cálculo de distância (veja eixo z) define que o dispositivo do usuário está a 11 metros de distância para o sensor do galpão e 12,5 metros de distância para o sensor do laboratório de química, decidindo assim pelo menor valor, emitindo dados do sensor do galpão. No momento 12h:01, ao entrar na área do sensor localizado no laboratório de engenharia química, nota-se um aumento na concentração de CO, chegando a 200ppm, o que representa qualidade do ar péssima. Essa mudança abrupta de valor se deve ao fato do algoritmo realizar novo cálculo que revela a distância para o sensor do galpão ser maior em relação ao do sensor do laboratório de engenharia química, decidindo assim em mostrar dados deste laboratório. Ainda no cenário 1 na Figura 5b, agora correspondendo ao gás de cozinha (LGP), observa-se uma alta concentração de LGP que permanece oscilante entre 70ppm e 85ppm (não há classificação para o IQAr) até depois do momento 11h:58 na área do galpão, ocorrendo uma queda abrupta apenas no momento 12h:01 com concentração de 5ppm, quando se está mais perto da área do laboratório de engenharia química. Os resultados para o cálculo do algoritmo de distância são os mesmos já vistos no parágrafo anterior.

Com relação a Figura 5c correspondente ao cenário 2, as medições já foram realizadas em outro instante de tempo. A concentração de CO fica oscilando entre 4ppm e 5,5ppm (sendo assim classificado pelo IQAr como boa) quando o usuário ainda está na área do galpão e o algoritmo de distância calcula que o dispositivo está a 20 metros dos sensores do galpão e aproximadamente 135 metros dos sensores do corredor do bloco 2, decidindo então emitir dados dos sensores do galpão. Porém, no momento 17h:20, ao se aproximar do corredor do bloco 2, ocorre uma elevação acentuada do nível de CO, chegando ao pico de 11ppm (classificada pelo IQAr como moderada). Mudança justificada pelo fato de o algoritmo realizar novo cálculo de distância, revelando que é menor (4,5 metros) para o corredor do bloco 02. Situação semelhante ocorre na apresentação da Figura 5d com o nível de metano (CH<sub>4</sub>) oscilando entre 13ppm e 16ppm (não há classificação pelo IQAr) até em 17h:15 na área do galpão. Entretanto, ocorre uma grande elevação de metano chegando ao pico de 24ppm no tempo de 17h:19 na área do corredor do bloco 2.

## 5. Conclusão e Direções Futuras

O objetivo deste trabalho foi avaliar o desempenho de algoritmos classificadores de aprendizagem de máquina considerados promissores a partir de um banco de dados histórico com dados de medições de poluentes atmosféricos coletados pelo IQArMobi, um aplicativo consciente de localização para visualização da qualidade do ar em ambientes externos e internos. Foram comparados os algoritmos *Random Forest*, *Gradient Boosting*, *Support Vector Machine* e *Logistic Regression*. Para o estudo de caso, o melhor classificador para o banco de dados desbalanceado e balanceado foi o *Logistic Regression* com acurácia de 99%, seguido do *Random Forest Classifier* que teve uma leve queda de desempenho após o balanceamento atingindo 96% de acurácia. Com os resultados obtidos neste trabalho, entende-se que o IQArMobi se mostra eficiente na tomada de decisão em exibir dados

de poluentes atmosféricos e classificação do IQAr com suporte dos modelos de aprendizagem de máquina e algoritmo de cálculo de distância, considerando a eminência destes poluentes e dos sensores mais próximos do dispositivo do usuário em curto espaço de tempo.

Em trabalhos futuros, pretende-se fazer a captura de informações sobre aspectos da saúde humana e inserir algoritmos de aprendizagem profunda para guardar e gerar informações únicas para usuários distintos, aumentando o grau de especificidade e ajuda em tempo real.

## Referências

- [CONAMA 2024] CONAMA (2024). Resolução nº 491/2018. *Padrões da qualidade do ar*.
- [Cunha et al. 2024] Cunha, N., Moraes, A., Silva, N., Malon, M., Junior, W., Alves, E., Eras, L., Victor, J., and Oliveira, A. (2024). Arquitetura de monitoramento de qualidade de ar baseada no lorawan e fiware em um campus universitário. In *Anais do XV Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais*, pages 169–178, Porto Alegre, RS, Brasil. SBC.
- [Imam et al. 2024] Imam, M., Adam, S., Dev, S., and Nesa, N. (2024). Air quality monitoring using statistical learning models for sustainable environment. *Intelligent Systems with Applications*, page 200333.
- [Kumar and Pande 2023] Kumar, K. and Pande, B. P. (2023). Air pollution prediction with machine learning: a case study of Indian cities. *International Journal of Environmental Science and Technology*, 20(5):5333–5348.
- [Kumar and Doss 2023] Kumar, T. and Doss, A. (2023). Airo: Development of an intelligent iot-based air quality monitoring solution for urban areas. *Procedia Computer Science*, 218:262–273.
- [Mottahedin et al. 2024] Mottahedin, P., Chahkandi, B., Moezzi, R., Fathollahi-Fard, A. M., Ghandali, M., and Gheibi, M. (2024). Air quality prediction and control systems using machine learning and adaptive neuro-fuzzy inference system. *Heliyon*, 10(21).
- [Rastogi and Lohani 2022] Rastogi, K. and Lohani, D. (2022). Context-aware iot-enabled framework to analyse and predict indoor air quality. *Intelligent Systems with Applications*, 16:200132.
- [Schürholz et al. 2020] Schürholz, D., Kubler, S., and Zaslavsky, A. (2020). Artificial intelligence-enabled context-aware air quality prediction for smart cities. *Journal of Cleaner Production*, 271.
- [Serdaroglu et al. 2023] Serdaroglu, K. C., Baydere, S., Saovapakhiran, B., and Charnsri-pinyo, C. (2023). Location Aware Fog Computing Based Air Quality Monitoring System. In *2023 International Conference on Smart Applications, Communications and Networking, SmartNets 2023*. Institute of Electrical and Electronics Engineers Inc.
- [Wallbanks et al. 2024] Wallbanks, S., Griffiths, B., Thomas, M., Price, O. J., and Sylvester, K. P. (2024). Impact of environmental air pollution on respiratory health and function. *Physiological Reports*, 12(16):e70006.