



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA**  
**MESTRADO ACADÊMICO EM ENGENHARIA DE TELEINFORMÁTICA**

**NICOLAS DE CARVALHO MONTEIRO**

**SENSEAIR: ARQUITETURA DE MONITORAMENTO DE QUALIDADE DO AR COM  
SENSORES DE BAIXO CUSTO E VISÃO COMPUTACIONAL PARA TRÁFEGO  
VEICULAR**

**FORTALEZA**

**2026**

NICOLAS DE CARVALHO MONTEIRO

SENSEAIR: ARQUITETURA DE MONITORAMENTO DE QUALIDADE DO AR COM  
SENSORES DE BAIXO CUSTO E VISÃO COMPUTACIONAL PARA TRÁFEGO  
VEICULAR

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia de Teleinformática do Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas.

Orientador: Prof. Dr. Jarbas Aryel Nunes da Silveira.

Coorientadora: Prof. Dra. Lara Sucupira Furtado.

FORTALEZA

2026

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Sistema de Bibliotecas  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

- M778s Monteiro, Nicolas de Carvalho.  
SenseAir: Arquitetura de Monitoramento de Qualidade do Ar com Sensores de Baixo Custo e Visão Computacional para Tráfego Veicular / Nicolas de Carvalho Monteiro. – 2026.  
82 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2026.  
Orientação: Prof. Jarbas Aryel Nunes da Silveira.
1. Qualidade do Ar. 2. Sensores de Baixo Custo. 3. Visão Computacional. 4. Calibração. 5. Cidades Inteligentes. I. Título.

CDD 621.38

---

NICOLAS DE CARVALHO MONTEIRO

SENSEAIR: ARQUITETURA DE MONITORAMENTO DE QUALIDADE DO AR COM  
SENSORES DE BAIXO CUSTO E VISÃO COMPUTACIONAL PARA TRÁFEGO  
VEICULAR

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia de Teleinformática do Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas.

Aprovada em: 16/01/2026.

BANCA EXAMINADORA

---

Prof. Dr. Jarbas Aryel Nunes da Silveira (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dra. Lara Sucupira Furtado (Coorientadora)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Danielo Gonçalves Gomes  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Fabiano Passuelo Hessel  
Pontifícia Universidade Católica do Rio Grande do  
Sul (PUCRS)

Dedico este trabalho a Deus, à minha família e a todos que, de alguma forma, contribuíram para sua realização.

## **AGRADECIMENTOS**

Agradeço à minha esposa, Rafaela, por estar sempre ao meu lado, inclusive nos dias de coleta, e por me apoiar em tudo o que faço. À minha filha, Gabriela, por me motivar todos os dias.

Agradeço à minha família e aos amigos. Em especial, à Nayara Gurjão, por esclarecer inúmeras dúvidas sobre o tema e sobre o mestrado.

Agradeço ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro, por meio da bolsa de auxílio, fundamental para a realização desta pesquisa.

Agradeço ao Prof. Dr. Jarbas Silveira, pela excelente orientação, disponibilidade e contribuições ao longo de todo o desenvolvimento do trabalho. À Prof<sup>a</sup> Dr<sup>a</sup> Lara Furtado, pela coorientação e pelas valiosas sugestões.

Aos professores membros da banca examinadora, Danielo Gomes e Fabiano Hessel, agradeço pelo tempo dedicado, pelas contribuições e pelas sugestões que enriqueceram este estudo.

## RESUMO

A escassez e a concentração regional das estações de referência de qualidade do ar no Brasil limitam diagnósticos confiáveis e o desenho de políticas públicas baseadas em evidências, sobretudo em regiões menos monitoradas como o Nordeste. Como alternativa complementar às redes oficiais, esta dissertação investiga uma arquitetura de baixo custo formada por um nó sensor embarcado (*SenseAir*), um aplicativo móvel em tempo real, um modelo de visão computacional para quantificação de tráfego veicular e um módulo de calibração exploratória de  $PM_{2,5}$  ancorado em dados de um equipamento portátil de melhor desempenho. A solução integra aquisição contínua, transmissão segura e armazenamento em nuvem, e visualização do Índice de Qualidade do Ar (IQA) derivado de  $PM_{2,5}$  com geolocalização, voltada ao monitoramento indicativo em cenários urbanos. A calibração é discutida à luz das diretrizes da U.S. EPA para sensores de  $PM_{2,5}$ , utilizando métricas como coeficiente de determinação ( $R^2$ ), viés (inclinação e intercepto da regressão) e erro quadrático médio (RMSE) para avaliar a correção aplicada ao *SenseAir*. Em paralelo, um modelo YOLO embarcado no Raspberry Pi estima fluxo e composição da frota veicular, permitindo analisar o papel do tráfego, em conjunto com outros fatores externos, na degradação local da qualidade do ar. Os resultados discutem custo, desempenho e limitações da arquitetura proposta, bem como seu potencial de uso em redes densas de monitoramento indicativo e em aplicações de pesquisa e apoio à gestão pública.

**Palavras-chave:** qualidade do ar; sensores de baixo custo;  $PM_{2,5}$ ; calibração; visão computacional; cidades inteligentes.

## ABSTRACT

The scarcity and regional concentration of reference air quality monitoring stations in Brazil limit reliable diagnostics and the design of evidence-based public policies, especially in under-monitored regions such as the Northeast. As a complementary alternative to official networks, this dissertation investigates a low-cost architecture composed of an embedded sensor node (*SenseAir*), a real-time mobile application, a computer vision model for vehicle traffic quantification, and an exploratory calibration module for  $PM_{2,5}$  anchored in data from a higher-performance portable instrument. The solution integrates continuous data acquisition, secure transmission and cloud storage, and visualization of the Air Quality Index (AQI) derived from  $PM_{2,5}$  with geolocation, targeting indicative monitoring in urban scenarios. Calibration is discussed in light of U.S. EPA guidelines for  $PM_{2,5}$  sensors, using metrics such as coefficient of determination ( $R^2$ ), bias (regression slope and intercept), and root mean square error (RMSE) to evaluate the correction applied to *SenseAir*. In parallel, a YOLO-based model embedded in the Raspberry Pi estimates the flow and composition of the vehicle fleet, enabling analysis of the role of traffic, together with other external factors, in the local degradation of air quality. The results discuss cost, performance, and limitations of the proposed architecture, as well as its potential use in dense indicative monitoring networks and in research and decision-support applications for public management.

**Palavras-chave:** air quality; low-cost sensors;  $PM_{2,5}$ ; calibration; computer vision; smart cities.

## LISTA DE FIGURAS

Figura 1 – localização das estações oficiais de monitoramento de qualidade do ar . . . .	22
Figura 2 – Estação de monitoramento de referência para PM <sub>2,5</sub> . . . . .	27
Figura 3 – Estação de monitoramento com módulo de amostragem, analisador contínuo de partículas e sistema de comunicação de dados para transmissão em tempo quase real. . . . .	28
Figura 4 – Esquema ilustrativo de campanha de co-localização para calibração de sensores de baixo custo. Uma estação de referência central . . . . .	33
Figura 5 – Visão geral da arquitetura do sistema <i>SenseAir</i> . . . . .	41
Figura 6 – Raspberry Pi 4 Model B . . . . .	43
Figura 7 – Placa UPS HAT para duas baterias 18650 . . . . .	43
Figura 8 – Módulo BME280 . . . . .	44
Figura 9 – Sensor óptico de partículas HM3301 . . . . .	44
Figura 10 – Módulo GPS GY-NEO6MV2 . . . . .	44
Figura 11 – Câmera USB. . . . .	45
Figura 12 – baterias Li-ion 18650. . . . .	45
Figura 13 – Equipamento Temtop M2000 . . . . .	52
Figura 14 – Quantidade de pares de dados Temtop– <i>SenseAir</i> de material particulado com diâmetro aerodinâmico menor que 2,5 $\mu m$ (PM <sub>2.5</sub> ) obtidos em cada dia do experimento de calibração . . . . .	52
Figura 15 – Dispositivo embarcado <i>SenseAir</i> em operação . . . . .	56
Figura 16 – Uso de CPU do Raspberry Pi 4B nos três modos de operação do nó <i>SenseAir</i> . . . . .	58
Figura 17 – Uso de memória RAM do Raspberry Pi 4B nos três modos de operação do nó <i>SenseAir</i> . . . . .	58
Figura 18 – Interface do aplicativo móvel mostrando o Índice de Qualidade do Ar para PM <sub>2.5</sub> . . . . .	60
Figura 19 – Comparação de desempenho entre diferentes versões do YOLO com base em <i>recall</i> , <i>precision</i> e mAP50 . . . . .	61
Figura 20 – Detecção de veículos utilizando YOLO em sistema embarcado . . . . .	62
Figura 21 – Comparação de FPS entre modelos em Raspberry Pi 4B . . . . .	63

Figura 22 – Dispersão entre PM2.5 medido pelo Temtop M2000 e pelo <i>SenseAir</i> , comparando as leituras brutas e os valores calibrados pelo modelo KNN, com indicação da linha de identidade 1:1. . . . .	64
Figura 23 – Comparação temporal entre as concentrações de PM2.5 do Temtop (referência), do <i>SenseAir</i> bruto e do <i>SenseAir</i> calibrado pelo modelo KNN no subconjunto de teste. . . . .	65
Figura 24 – Localização do Túnel Wellington Landim e do ponto de medição utilizado na campanha. . . . .	66
Figura 25 – Localização do Túnel Olga Barroso e do ponto de medição utilizado na campanha. . . . .	66
Figura 26 – Localização do Túnel Sérgio Nogueira e do ponto de medição utilizado na campanha. . . . .	67
Figura 27 – Contagem manual de veículos por classe e total na janela 09:51-10:51. . . .	67
Figura 28 – Concentração de PM2.5 (bruto e calibrado) na janela 09:51-10:51 com limites até “Moderate” ( <i>Environmental Protection Agency / Agência de Proteção Ambiental (EPA)</i> ). A caixa informa o AQI (EPA) calculado pela média móvel de 1h ao final da janela. . . . .	68
Figura 29 – Concentração de PM2.5 (bruto e calibrado) na janela 09:51-10:51 com limites até “Moderada” (CONAMA). A caixa informa o IQAr (CONAMA) calculado pela média móvel de 1h ao final da janela. . . . .	68
Figura 30 – Contagem manual de veículos por classe e total na janela 12:51-13:51. . . .	69
Figura 31 – Concentração de PM2.5 (bruto e calibrado) na janela 12:51-13:51 com limites até “Moderate” (EPA). A caixa informa o AQI (EPA) calculado pela média móvel de 1h ao final da janela. . . . .	69
Figura 32 – Concentração de PM2.5 (bruto e calibrado) na janela 12:51-13:51 com limites até “Moderada” (CONAMA). A caixa informa o IQAr (CONAMA) calculado pela média móvel de 1h ao final da janela. . . . .	70
Figura 33 – Contagem manual de veículos por classe e total na janela 15:33-16:33. . . .	70
Figura 34 – Concentração de PM2.5 (bruto e calibrado) na janela 15:33-16:33 com limites até “Moderate” (EPA). A caixa informa o AQI (EPA) calculado pela média móvel de 1h ao final da janela. . . . .	71

Figura 35 – Concentração de PM2.5 (bruto e calibrado) na janela 15:33-16:33 com limites até “Moderada” (CONAMA). A caixa informa o IQAr (CONAMA) calculado pela média móvel de 1h ao final da janela. . . . .	71
Figura 36 – Exemplo de ventilação mecânica no interior do Túnel Sérgio Nogueira. . . .	72

## LISTA DE TABELAS

Tabela 1	– Relação entre faixas do Índice de Qualidade do Ar (IQA) da EPA e concentrações de PM2.5 na média de 24 horas . . . . .	26
Tabela 2	– Faixas do IQA da Conselho Nacional do Meio Ambiente (CONAMA) para PM2.5 na média de 24 horas . . . . .	26
Tabela 3	– Comparação entre sistemas de monitoramento da qualidade do ar baseados em IoT . . . . .	39
Tabela 4	– Componentes principais do nó <i>SenseAir</i> , funções e interfaces de comunicação.	46
Tabela 5	– Estimativa de custo dos componentes do <i>SenseAir</i> . . . . .	57
Tabela 6	– Utilização média e máxima de CPU e memória em diferentes modos de operação do nó <i>SenseAir</i> . . . . .	57
Tabela 7	– Corrente média e máxima e autonomia estimada do <i>SenseAir</i> sob alimentação por bateria em diferentes modos de operação. . . . .	59
Tabela 8	– Métricas de desempenho no conjunto de teste para o <i>SenseAir</i> bruto e modelos de calibração em relação ao Temtop M2000. . . . .	63

## LISTA DE ABREVIATURAS E SIGLAS

CONAMA	Conselho Nacional do Meio Ambiente
EPA	<i>Environmental Protection Agency</i> / Agência de Proteção Ambiental
IoT	<i>Internet of Things</i> / Internet das Coisas
IQA	Índice de Qualidade do Ar
KNN	<i>k-Nearest Neighbors</i> / k-vizinhos mais próximos
MLP	<i>Multi-Layer Perceptron</i> / Perceptron Multicamada
MMA	Ministério do Meio Ambiente
MQTT	<i>Message Queuing Telemetry Transport</i> / Transporte de telemetria de filas de mensagens
OMS	Organização Mundial da Saúde
PM10	Material particulado com diâmetro aerodinâmico menor que $10 \mu m$
PM2.5	material particulado com diâmetro aerodinâmico menor que $2,5 \mu m$
PNQA	Política Nacional de Qualidade do Ar
RBF	<i>Radial Basis Function</i> / Função de Base Radial
SVM	<i>Support Vector Machine</i> / Máquina de Vetores de Suporte
SVR	<i>Support Vector Regression</i> / Regressão por Vetores de Suporte
YOLO	<i>You Only Look Once</i> / Você só olha uma vez

## LISTA DE SÍMBOLOS

$\mu g/m^3$	Microgramas por metro cúbico
$R^2$	Coefficiente de determinação (adimensional)
$RMSE$	Raiz do erro quadrático médio ( $\mu g/m^3$ )
$NRMSE$	RMSE normalizado (adimensional)
%	Porcentagem
$\mu m$	Micrômetro
$O_3$	Ozônio
$NO_2$	Dióxido de nitrogênio
$SO_2$	Dióxido de enxofre
$CO$	Monóxido de carbono

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
<b>1.1</b>	<b>Objetivo</b>	<b>17</b>
<b>1.2</b>	<b>Organização do Trabalho</b>	<b>18</b>
<b>1.3</b>	<b>Produção Intelectual</b>	<b>19</b>
<b>2</b>	<b>FUNDAMENTOS TEÓRICOS</b>	<b>20</b>
<b>2.1</b>	<b>Panorama da qualidade do ar no Brasil e no Nordeste</b>	<b>20</b>
<b>2.1.1</b>	<i>Iniciativa local no Nordeste: parceria UFC-SEUMA e a rede MoQA em Fortaleza</i>	<b>21</b>
<b>2.2</b>	<b>Poluentes atmosféricos e indicadores de qualidade do ar</b>	<b>22</b>
<b>2.3</b>	<b>Padrões e diretrizes recentes para PM<sub>2.5</sub></b>	<b>24</b>
<b>2.4</b>	<b>Índices de Qualidade do Ar (IQA) e esquemas de cálculo</b>	<b>24</b>
<b>2.5</b>	<b>Monitoramento com estações de referência e lacunas de cobertura</b>	<b>26</b>
<b>2.6</b>	<b>Sensores de baixo custo para qualidade do ar</b>	<b>28</b>
<b>2.7</b>	<b>Avaliação e calibração de sensores de baixo custo</b>	<b>29</b>
<b>2.8</b>	<b>Co-localização com referência</b>	<b>32</b>
<b>2.8.1</b>	<i>Modelos de regressão supervisionada para calibração de sensores</i>	<b>33</b>
<b>2.8.1.1</b>	<i>Regressão linear</i>	<b>34</b>
<b>2.8.1.2</b>	<i>k-Nearest Neighbors / k-vizinhos mais próximos (KNN)</i>	<b>34</b>
<b>2.8.1.3</b>	<i>Random Forest</i>	<b>34</b>
<b>2.8.1.4</b>	<i>Support Vector Regression SVR com kernel Radial Basis Function / Função de Base Radial (RBF)</i>	<b>35</b>
<b>2.8.1.5</b>	<i>Perceptron multicamada MLP</i>	<b>35</b>
<b>2.9</b>	<b>Fatores que degradam a qualidade do ar em contextos urbanos</b>	<b>36</b>
<b>2.9.1</b>	<i>Tráfego veicular</i>	<b>36</b>
<b>2.9.2</b>	<i>Emissões industriais</i>	<b>36</b>
<b>2.9.3</b>	<i>Queimadas</i>	<b>36</b>
<b>2.9.4</b>	<i>Condições meteorológicas</i>	<b>37</b>
<b>2.10</b>	<b>Estudos relacionados sobre monitoramento da qualidade do ar</b>	<b>37</b>
<b>3</b>	<b>METODOLOGIA</b>	<b>40</b>
<b>3.1</b>	<b>Visão geral da abordagem metodológica</b>	<b>40</b>

3.2	<b>Ambiente de estudo e cenários de uso</b>	41
3.3	<b>Arquitetura do sistema SenseAir</b>	42
3.3.1	<i>Hardware do nó</i>	42
3.3.2	<i>Firmware e software embarcado</i>	45
3.3.3	<i>Avaliação de desempenho computacional e energético do nó</i>	47
3.4	<b>Aplicativo móvel e apresentação do IQA</b>	48
3.5	<b>Modelo de visão computacional para tráfego</b>	49
3.5.1	<i>Conjunto de dados e processo de treinamento</i>	49
3.5.2	<i>Otimização e implantação no Raspberry Pi</i>	50
3.5.3	<i>Métricas de desempenho do modelo em campo</i>	50
3.6	<b>Metodologia de calibração exploratória de PM2.5</b>	51
3.6.1	<i>Procedimento de comparação em laboratório</i>	51
3.6.2	<i>Ajuste do modelo e análise de métricas</i>	53
3.7	<b>Protocolo experimental em campo</b>	54
3.8	<b>Limitações metodológicas</b>	54
4	<b>RESULTADOS</b>	56
4.1	<b>Hardware desenvolvido</b>	56
4.1.1	<i>Caracterização do nó e custo de montagem</i>	56
4.1.2	<i>Desempenho computacional do nó SenseAir</i>	57
4.1.3	<i>Consumo de energia e autonomia em campo</i>	58
4.2	<b>Aplicativo móvel desenvolvido</b>	59
4.2.1	<i>Comparação entre versões do YOLO</i>	60
4.3	<b>Modelo YOLO implementado</b>	61
4.3.1	<i>Detecção de veículos em campo</i>	61
4.3.2	<i>Desempenho em tempo real no Raspberry Pi</i>	62
4.4	<b>Modelo de calibração implementado</b>	63
4.5	<b>Relação entre tráfego veicular e PM2.5</b>	65
4.5.1	<i>Túnel Wellington Landim</i>	65
4.5.2	<i>Túnel Olga Barroso</i>	67
4.5.3	<i>Túnel Sérgio Nogueira</i>	68
4.5.4	<i>Síntese dos resultados</i>	69
5	<b>CONCLUSÕES E TRABALHOS FUTUROS</b>	73

<b>5.1</b>	<b>Trabalhos Futuros</b> . . . . .	<b>74</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>77</b>

## 1 INTRODUÇÃO

No Brasil, a disponibilidade de dados sobre qualidade do ar permanece escassa e desigual. Em 1º de março de 2024, o Instituto Ar reportou que apenas cerca de 1,6% dos municípios contam com monitoramento sistemático, com forte concentração regional, o que limita diagnósticos e a formulação de políticas públicas baseadas em evidências (Instituto Ar, 2024). Essa lacuna decorre, em parte, do alto custo de aquisição e manutenção das estações de referência, da complexidade dos equipamentos e da necessidade de operação especializada, fatores que restringem sua capilaridade territorial (Jaafar *et al.*, 2024; Bagkis *et al.*, 2025).

Nos últimos anos, o tema ganhou maior visibilidade na agenda nacional com a Política Nacional de Qualidade do Ar (PNQA) pela Lei n. 14.850, de 2 de maio de 2024 (BRASIL. LEI Nº 14.850, DE 2 DE MAIO DE 2024. INSTITUI O CÓDIGO CIVIL., ), que estabelece diretrizes para monitoramento, avaliação e gestão da qualidade do ar em nível federal, estadual e municipal. Relatórios recentes do Ministério do Meio Ambiente e Mudança do Clima apontam, contudo, que a implementação dessa política ainda convive com limitações estruturais importantes, tanto em número de estações como em padronização e transparência dos dados (BRASIL. MINISTÉRIO DO MEIO AMBIENTE E MUDANÇA DO CLIMA, 2025b). Em regiões historicamente menos monitoradas, como grande parte do Nordeste, essas restrições são ainda mais evidentes.

Nesse cenário, alternativas complementares como redes de sensores de baixo custo podem ampliar a cobertura e a resolução espacial do monitoramento, aproximando medições de ambientes efetivamente ocupados pela população. Estudos recentes destacam tanto o potencial desses dispositivos para compor redes densas e flexíveis quanto os desafios de garantir confiabilidade, comparabilidade e rastreabilidade dos dados obtidos (Jaafar *et al.*, 2024; Bagkis *et al.*, 2025). A literatura internacional e documentos recentes da EPA reforçam que sensores de baixo custo não substituem equipamentos de referência, mas podem complementar e densificar a malha de observação, desde que acompanhados de protocolos de teste e métricas de desempenho bem documentadas para uso em aplicações não regulatórias (U.S. Environmental Protection Agency, 2021; Simcox; Alison, 2021).

Ainda assim, permanece pouco explorado, no contexto brasileiro e especialmente no Nordeste, de que forma arquiteturas que combinam sensores de baixo custo, modelos de calibração e dados contextuais podem ser organizadas em fluxos completos de aquisição, transmissão, interpretação e comunicação. Estudos recentes descrevem, por um lado, redes de monitoramento

e iniciativas de ciência cidadã baseadas em sensores de baixo custo, com foco em desenho de rede, engajamento comunitário e integração com plataformas de internet das coisas (Barros *et al.*, 2024; WORLD METEOROLOGICAL ORGANIZATION, 2023). Por outro lado, revisões e estudos de calibração concentram-se em modelos estatísticos e de aprendizado de máquina para corrigir viés, reduzir erro e melhorar a comparabilidade entre sensores e instrumentos de referência, frequentemente destacando desafios de padronização de métricas e protocolos (Nalankurthi *et al.*, 2024; Hayward *et al.*, 2024). Em menor número aparecem soluções que descrevem de forma integrada toda a cadeia, da medição em campo à geração de indicadores sintéticos voltados à gestão pública em nível local, com ênfase na combinação de sensores de baixo custo, dados auxiliares e estratégias de comunicação com usuários finais (Okorn; Iraci, 2024). Esta dissertação se insere nesse espaço ao investigar, em estudo de caso, uma cadeia completa que vai da medição em campo à apresentação de indicadores simplificados de qualidade do ar, incluindo um componente de calibração de PM<sub>2.5</sub> baseado em comparação com equipamento de referência portátil.

## 1.1 Objetivo

Este projeto desenvolve e avalia uma solução integrada para monitorar de forma indicativa a qualidade do ar, formada por um nó de baixo custo (*SenseAir*), um aplicativo móvel em tempo real, um modelo de visão computacional para quantificar tráfego veicular e um módulo de calibração exploratória de PM<sub>2.5</sub> baseado em comparação com equipamento portátil de referência. A meta é demonstrar a viabilidade técnica de uma cadeia completa que vai da medição em campo à apresentação de indicadores simplificados de qualidade do ar, criando base para futuras *redes densas* com baixo custo por ponto e desempenho adequado para pesquisa e apoio a políticas públicas. Os objetivos específicos são:

- Desenvolver o dispositivo *SenseAir* (uso *indoor/outdoor*) com sensores para inferir a qualidade do ar a partir de PM<sub>2.5</sub> e variáveis ambientais;
- Implementar o *firmware* e o software embarcado para aquisição contínua das medições, publicação via *Message Queuing Telemetry Transport* / Transporte de telemetria de filas de mensagens (MQTT) e registro de informações básicas de diagnóstico;
- Caracterizar o desempenho computacional e energético do nó embarcado, incluindo utilização de CPU e memória, consumo de corrente e autonomia em bateria;
- Construir um aplicativo móvel para exibir o IQA derivado de PM<sub>2.5</sub>, com mapa, geoloca-

- lização do usuário e associação ao nó *SenseAir* mais próximo;
- Embarcar e avaliar um modelo *You Only Look Once / Você só olha uma vez (YOLO)* para detecção e classificação de veículos, possibilitando a obtenção de contagens por classe em tempo real e a correlação exploratória com PM2.5;
  - Realizar calibração exploratória de PM2.5 com base na comparação entre o *SenseAir* e o Temtop M2000 em experimento de laboratório, estimando métricas como  $R^2$ , viés e *RMSE* e aplicando um modelo linear de ajuste;
  - Documentar hardware e software (lista de materiais, montagem e operação) em formato aberto, de forma a facilitar a reprodução e a adaptação do nó *SenseAir*;
  - Conduzir testes de campo exploratórios em cenários urbanos selecionados, avaliando o funcionamento integrado do nó, do aplicativo e dos módulos de visão computacional e calibração em condições reais de uso.

## 1.2 Organização do Trabalho

O Capítulo 2 apresenta um panorama da qualidade do ar no Brasil, com ênfase nas disparidades regionais de monitoramento e na situação do Nordeste; descreve os principais poluentes atmosféricos e indicadores de qualidade do ar, com foco em PM2.5; discute padrões e diretrizes recentes para esse poluente, bem como esquemas de cálculo de índices como o IQA brasileiro e o IQA da EPA; caracteriza o papel das estações de referência e as lacunas de cobertura associadas ao seu alto custo; revisa o estado da arte em sensores de baixo custo, incluindo métricas de desempenho, modelos de calibração e estratégias de co-localização com equipamentos de referência; analisa fatores externos que degradam a qualidade do ar em contextos urbanos (tráfego veicular, emissões industriais, queimadas, ressuspensão de poeira e condições meteorológicas); e, por fim, sintetiza estudos relacionados de monitoramento com IoT, destacando funcionalidades típicas e o posicionamento do protótipo *SenseAir* em relação a esses trabalhos.

O Capítulo 3 detalha a metodologia e a implementação: o nó *SenseAir* e seu *firmware/software* (coleta, pré-processamento e transmissão); o aplicativo móvel (visualização em tempo real e IQA derivado de PM2.5); o modelo de calibração com base em medições de referência; e o modelo YOLO embarcado para detecção e classificação de veículos, utilizado na correlação entre tráfego e PM2.5.

O Capítulo 4 apresenta os resultados e a discussão, incluindo custo e montagem do *SenseAir*, funcionamento do aplicativo, desempenho do YOLO e ganhos obtidos pela calibração

de PM2.5.

Por fim, o Capítulo 5 traz as conclusões e as direções para trabalhos futuros.

### 1.3 Produção Intelectual

Nesta dissertação, foi publicado um artigo no *IEEE International Smart Cities Conference (ISC2)*, patrocinado pela comunidade IEEE Smart Cities e organizado localmente pelo IEEE Power & Energy Society (Thailand Chapter).

**Referência:** FURTADO, Lara Sucupira; MONTEIRO, Nicolas; GURJÃO, N.; CAVALCANTE, R. M.; SILVA FILHO, J. E.; SILVEIRA, J. A. N.; SANTOS, R.; SOARES, J. B.; MACEDO, J. A. F. *Low-Cost Smart Sensing Pipeline: Assembly, Calibration, and Interpretation of Air Quality Data*. IEEE International Smart Cities Conference, 2024.

## 2 FUNDAMENTOS TEÓRICOS

Este capítulo apresenta o referencial teórico que fundamenta a proposta desta dissertação. Inicialmente, discute-se o panorama recente da qualidade do ar no Brasil, com ênfase no contexto normativo e na situação de monitoramento, destacando a criação da PNQA e as disparidades regionais de cobertura. Em seguida, são apresentados padrões e diretrizes para material particulado fino PM<sub>2.5</sub>, com foco nas atualizações da Organização Mundial da Saúde (OMS) e em iniciativas nacionais. Na sequência, são discutidas as características de estações de referência e lacunas de monitoramento, o estado da arte em sensores de baixo custo e os principais modelos de calibração descritos na literatura, incluindo calibração por *offset* e ganho, correção explícita de temperatura e umidade e calibração baseada em arranjos de sensores, bem como estratégias de recalibração em rede, como abordagens cegas, colaborativas e por transferência. Também são abordadas as métricas mais utilizadas para avaliar o desempenho de sensores calibrados, como o coeficiente de determinação  $R^2$ , o viés, o erro quadrático médio *RMSE* e o *NRMSE*. Por fim, examinam-se fatores externos relevantes para a degradação da qualidade do ar no contexto urbano, como tráfego veicular, emissões industriais, queimadas, ressuspensão de poeira e condições meteorológicas, e são apresentados os principais esquemas de cálculo do IQA, incluindo as funções de interpolação por faixas, pontos de corte e classes de risco adotadas no Brasil e em referências internacionais.

### 2.1 Panorama da qualidade do ar no Brasil e no Nordeste

A qualidade do ar em centros urbanos brasileiros tem recebido atenção crescente em virtude de seus impactos sobre a saúde, a produtividade e o planejamento urbano. A sanção da Lei n. 14.850, de 2 de maio de 2024, instituiu a PNQA e estabeleceu princípios, objetivos e instrumentos para a gestão da qualidade do ar em escala nacional (BRASIL. LEI Nº 14.850, DE 2 DE MAIO DE 2024. INSTITUI O CÓDIGO CIVIL., ). Entre os objetivos da PNQA, destacam-se a criação de um sistema unificado de monitoramento, a definição de padrões nacionais de qualidade do ar, a integração de dados de diferentes entes federativos e a promoção de transparência na divulgação das informações à população.

Relatório recente do Ministério do Meio Ambiente e Mudança do Clima indica, porém, que a rede de monitoramento ainda apresenta distribuição desigual, com concentração de estações em estados das regiões Sudeste e Sul e cobertura limitada em partes do Norte e do

Nordeste (BRASIL. MINISTÉRIO DO MEIO AMBIENTE E MUDANÇA DO CLIMA, 2025b). Essa assimetria produz lacunas relevantes na capacidade de diagnóstico, especialmente em áreas que combinam crescimento urbano acelerado, frota veicular significativa e proximidade de fontes industriais.

No levantamento divulgado em março de 2024, o Instituto Ar estimou que apenas cerca de 1,6% dos municípios brasileiros contavam com algum tipo de monitoramento sistemático de qualidade do ar, em geral com foco em poucas estações por estado e forte concentração regional (Instituto Ar, 2024). Esse quadro dificulta a avaliação de tendências de longo prazo, a identificação de episódios críticos e o acompanhamento de metas estabelecidas por normas nacionais ou internacionais.

No Nordeste, a situação é particularmente sensível. Embora existam experiências importantes de monitoramento em capitais e em áreas impactadas por polos industriais ou termoelétricas, a malha de estações permanece esparsa em comparação com regiões mais industrializadas. Relatórios estaduais, como o relatório anual de qualidade do ar do Instituto Estadual de Meio Ambiente e Recursos Hídricos do Espírito Santo (IEMA) (INSTITUTO ESTADUAL DO MEIO AMBIENTE E RECURSOS HÍDRICOS DO ESPÍRITO SANTO, 2025), ilustram como uma rede estruturada e relatórios periódicos permitem consolidar indicadores e orientar políticas. A ausência de documentos com formato semelhante em boa parte do Nordeste evidencia uma oportunidade de fortalecimento institucional e técnico. Um mapa da distribuição das estações oficiais no território brasileiro, destacando a menor densidade de pontos na região Nordeste, pode ser utilizado para ilustrar visualmente essas disparidades, como sugerido na Figura 1.

### ***2.1.1 Iniciativa local no Nordeste: parceria UFC-SEUMA e a rede MoQA em Fortaleza***

Como exemplo de avanço recente no Nordeste, destaca-se a experiência do município de Fortaleza, que em 2023 lançou uma política de vigilância da qualidade do ar e anunciou a implantação de uma rede municipal de monitoramento em parceria com a Universidade Federal do Ceará (UFC), com coordenação da Fundação de Ciência, Tecnologia e Inovação (Citinova) e da Secretaria Municipal de Urbanismo e Meio Ambiente (SEUMA) (FORTALEZA (Estado), 2023). A iniciativa buscou ampliar a capacidade de diagnóstico espacial na cidade por meio de monitores de baixo custo distribuídos no território, complementando a infraestrutura tradicional e favorecendo a comunicação de resultados para apoio a políticas públicas (FORTALEZA

Figura 1 – localização das estações oficiais de monitoramento de qualidade do ar



Fonte: Adaptado de (BRASIL. MINISTÉRIO DO MEIO AMBIENTE E MUDANÇA DO CLIMA, 2025b).

(Estado), 2023).

Nesse contexto, insere-se o MoQA (Monitor de Qualidade do Ar), desenvolvido por pesquisadores da UFC e associado ao núcleo TRAMA, que atua na interface entre sistemas de transportes e questões ambientais, reforçando a relevância do campo da Engenharia de Transportes para o monitoramento urbano e a compreensão de fontes veiculares de poluição (UNIVERSIDADE FEDERAL DO CEARÁ, 2024; TRAMA – Transportes e Meio Ambiente, 2026).

## 2.2 Poluentes atmosféricos e indicadores de qualidade do ar

A avaliação da qualidade do ar em áreas urbanas e industriais costuma se basear em um conjunto de poluentes chamados de poluentes critérios. Esses compostos representam diferentes tipos de fontes e processos de transformação na atmosfera e servem de base para índices sintéticos como o IQA (OMS, 2021a; CENTERS FOR DISEASE CONTROL AND PREVENTION, 2024; CETESB, 2023). Em geral, incluem material particulado fino e inalável, ozônio troposférico, dióxido de nitrogênio, dióxido de enxofre e monóxido de carbono.

A seguir, apresentam se brevemente os principais poluentes considerados em índices

de qualidade do ar.

- **Material particulado fino PM2.5:** corresponde a partículas com diâmetro aerodinâmico igual ou inferior a  $2,5 \mu\text{m}$ . Por serem muito pequenas, conseguem penetrar profundamente no sistema respiratório e atingir os alvéolos pulmonares. Estudos epidemiológicos recentes associam a exposição prolongada a PM2.5 a aumento de mortalidade cardiovascular e respiratória, agravamento de asma, doença pulmonar obstrutiva crônica e câncer de pulmão (OMS, 2021a; Meo *et al.*, 2024). Há consenso de que efeitos adversos podem ocorrer mesmo abaixo de limites legais menos restritivos.
- **Material particulado com diâmetro aerodinâmico menor que  $10 \mu\text{m}$  (PM10):** Abrange tanto a fração fina quanto partículas mais grossas, que se depositam principalmente nas vias aéreas superiores. Está associado a irritação de vias respiratórias, inflamação de mucosas e agravamento de sintomas em grupos sensíveis, além de representar parcela significativa da poeira ressuspensa por tráfego, atividades de construção e vento (OMS, 2021a; Meo *et al.*, 2024).
- **Ozônio troposférico ( $\text{O}_3$ ):** é um poluente secundário formado na baixa atmosfera por reações fotoquímicas envolvendo óxidos de nitrogênio e compostos orgânicos voláteis na presença de radiação solar. É componente importante do smog fotoquímico e está associado a irritação das vias aéreas, redução da função pulmonar e aumento de internações por causas respiratórias, especialmente durante episódios de calor intenso (OMS, 2021a; CENTERS FOR DISEASE CONTROL AND PREVENTION, 2024).
- **Dióxido de nitrogênio ( $\text{NO}_2$ ):** é emitido principalmente pela queima de combustíveis em veículos automotores e fontes estacionárias. Costuma ser usado como indicador de emissões de tráfego e de combustão em ambientes urbanos. A exposição a  $\text{NO}_2$  está ligada a inflamação de vias aéreas, aumento de sintomas respiratórios e maior risco de desenvolvimento ou agravamento de asma, com evidências recentes reforçando seu papel na carga global de doenças respiratórias (OMS, 2021a; Taha *et al.*, 2025).
- **Dióxido de enxofre ( $\text{SO}_2$ ):** é gerado pela combustão de combustíveis fósseis com teor de enxofre e por processos industriais específicos. Pode induzir broncoconstrição em indivíduos asmáticos, causar irritação de olhos e mucosas e contribuir para a formação de material particulado secundário e de chuva ácida (OMS, 2021a; Meo *et al.*, 2024).
- **Monóxido de carbono (CO):** gás incolor e inodoro produzido por combustão incompleta em motores, queimadas e outros processos. Apresenta alta afinidade pela hemoglobina,

reduzindo a capacidade do sangue de transportar oxigênio. Exposições mais elevadas estão associadas a cefaleia, tontura e, em casos extremos, risco de hipóxia grave (CENTERS FOR DISEASE CONTROL AND PREVENTION, 2024; Meo *et al.*, 2024).

Alguns sistemas de monitoramento incluem ainda poluentes adicionais, como chumbo e compostos orgânicos voláteis, em contextos específicos. Nesta dissertação, o foco recai sobre o material particulado fino PM<sub>2.5</sub>, tanto pela relevância epidemiológica descrita nas diretrizes globais de qualidade do ar (OMS, 2021a) quanto pela viabilidade de medição com sensores ópticos de baixo custo.

### 2.3 Padrões e diretrizes recentes para PM<sub>2.5</sub>

#### PM<sub>2.5</sub>

Para o material particulado fino PM<sub>2.5</sub>, este trabalho avaliou dois referenciais principais: as diretrizes globais da Organização Mundial da Saúde e os padrões atualmente adotados no Brasil em fase intermediária.

Nas Diretrizes Globais de Qualidade do Ar de 2021, a OMS recomenda para PM<sub>2.5</sub> um valor guia anual de 5  $\mu\text{g}/\text{m}^3$  e um valor guia de 24 horas de 15  $\mu\text{g}/\text{m}^3$ , acompanhados de valores intermediários pensados para trajetórias graduais de convergência (OMS, 2021a). Esses limites representam níveis associados ao menor risco possível à saúde segundo a evidência epidemiológica disponível.

No cenário nacional, documentos recentes de acompanhamento da qualidade do ar indicam que, na etapa intermediária vigente, os padrões adotados para PM<sub>2.5</sub> são de 17  $\mu\text{g}/\text{m}^3$  para a média anual e 50  $\mu\text{g}/\text{m}^3$  para a média de 24 horas (BRASIL. MINISTÉRIO DO MEIO AMBIENTE E MUDANÇA DO CLIMA, 2025b). Esses valores são mais permissivos do que os guias da OMS e delimitam a fronteira regulatória que estados e municípios precisam considerar no planejamento de políticas de controle.

### 2.4 Índices de Qualidade do Ar (IQA) e esquemas de cálculo

Para além dos valores numéricos de concentração, a comunicação com o público em geral requer métricas sintéticas que traduzam a qualidade do ar em faixas e categorias compreensíveis. IQA adotado por órgãos ambientais brasileiros e o EPA, cumprem exatamente esse papel ao transformar concentrações de poluentes em classes qualitativas associadas a cores

e recomendações de saúde (CETESB, 2023; WORLD HEALTH ORGANIZATION, 2024).

Em geral, esses índices definem, para cada poluente regulado, intervalos de concentração e classes de risco correspondentes. Cada intervalo é associado a uma faixa numérica de IQA e a uma cor. No caso dos Estados Unidos, o IQA da EPA utiliza categorias como *Boa/Good*, *Moderada/Moderate*, *Não saudável para grupos sensíveis/Unhealthy for Sensitive Groups*, *Não saudável/Unhealthy*, *Muito não saudável/Very Unhealthy* e *Perigosa/Hazardous*, com faixas de concentração de PM<sub>2.5</sub> atualizadas em 2024 para refletir a revisão dos padrões de partículas finas e a evidência recente sobre impactos à saúde (U.S. ENVIRONMENTAL PROTECTION AGENCY, 2024). No Brasil, a estrutura do IQA, definida em orientação técnica do Ministério do Meio Ambiente e articulada com as Resoluções CONAMA n. 491/2018 e 506/2024, adota categorias N1 a N5 (boa, moderada, ruim, muito ruim e péssima) e estabelece faixas de concentração específicas para PM<sub>2.5</sub> na média de 24 horas (BRASIL. MINISTÉRIO DO MEIO AMBIENTE E MUDANÇA DO CLIMA, 2025a).

Do ponto de vista matemático, o cálculo do índice para um dado poluente segue, em ambos os esquemas, o mesmo princípio. Seja um intervalo de concentração  $[C_{\text{low}}, C_{\text{high}}]$  associado a um intervalo de índice  $[I_{\text{low}}, I_{\text{high}}]$ . Se a concentração observada  $C$  pertence a esse intervalo, o valor do índice é obtido por interpolação linear:

$$IQA = I_{\text{low}} + \frac{I_{\text{high}} - I_{\text{low}}}{C_{\text{high}} - C_{\text{low}}} \cdot (C - C_{\text{low}}). \quad (2.1)$$

Quando vários poluentes são monitorados simultaneamente, a regra usual é definir o índice global de uma estação ou nó como o maior índice obtido entre os poluentes, isto é, aquele que representa o risco mais elevado naquele período. Em aplicações focadas em PM<sub>2.5</sub>, como a desta dissertação, é comum calcular o IQA apenas a partir da concentração desse poluente, utilizando faixas de concentração e categorias de risco compatíveis com esquemas nacionais e internacionais.

A Tabela 1 apresenta as faixas do IQA da EPA para PM<sub>2.5</sub> (média de 24 horas), considerando os limites atualizados em 2024, enquanto a Tabela 2 resume a estrutura do IQA brasileiro para o mesmo poluente, com base na orientação técnica publicada em 2025 (U.S. ENVIRONMENTAL PROTECTION AGENCY, 2024; BRASIL. MINISTÉRIO DO MEIO AMBIENTE E MUDANÇA DO CLIMA, 2025a).

A comparação entre as Tabelas 1 e 2 mostra que tanto o IQA da EPA quanto o IQA nacional seguem a mesma lógica geral de construção de índices, embora adotem faixas de concentração e limites numéricos próprios. Nesta dissertação, as faixas do IQA para PM<sub>2.5</sub> são

Tabela 1 – Relação entre faixas do IQA da EPA e concentrações de PM<sub>2.5</sub> na média de 24 horas

<b>Categoria</b>	<b>Faixa de AQI</b>	<b>PM<sub>2,5</sub> (µg/m<sup>3</sup>, 24 h)</b>
Boa ( <i>Good</i> )	0 a 50	0,0 a 9,0
Moderada ( <i>Moderate</i> )	51 a 100	9,1 a 35,4
Não saudável para grupos sensíveis ( <i>Unhealthy for Sensitive Groups</i> )	101 a 150	35,5 a 55,4
Não saudável ( <i>Unhealthy</i> )	151 a 200	55,5 a 125,4
Muito não saudável ( <i>Very Unhealthy</i> )	201 a 300	125,5 a 225,4
Perigosa ( <i>Hazardous</i> )	301 a 500	225,5 ou mais

Fonte: Adaptada de *Final Updates to the Air Quality Index (AQI) for Particulate Matter* (U.S. ENVIRONMENTAL PROTECTION AGENCY, 2024).

Tabela 2 – Faixas do IQA da CONAMA para PM<sub>2.5</sub> na média de 24 horas

<b>Qualidade do ar</b>	<b>Faixa de IQA</b>	<b>PM<sub>2,5</sub> (µg/m<sup>3</sup>, 24 h)</b>
N1 Boa	0 a 40	0 a 15
N2 Moderada	41 a 80	>15 a 50
N3 Ruim	81 a 120	>50 a 75
N4 Muito ruim	121 a 200	>75 a 125
N5 Péssima	201 a 400	>125 a 300

Fonte: Adaptada de *Orientação técnica: IQA* (BRASIL. MINISTÉRIO DO MEIO AMBIENTE E MUDANÇA DO CLIMA, 2025a).

avaliadas nos dois cenários; contudo, é com base no IQA da EPA que o aplicativo móvel SenseAir converte as concentrações medidas em categorias de qualidade do ar exibidas ao usuário.

## 2.5 Monitoramento com estações de referência e lacunas de cobertura

O monitoramento oficial de PM<sub>2.5</sub> costuma se apoiar em equipamentos de referência ou equivalentes, certificados por agências reguladoras. Entre os instrumentos amplamente utilizados encontram-se monitores baseados em atenuação beta, como o BAM 1020 (MET ONE INSTRUMENTS POWERED BY ACOEM, 2025), e analisadores contínuos de partículas de fabricantes como a Thermo Fisher Scientific (THERMO FISHER SCIENTIFIC, 2025). Esses dispositivos apresentam alta precisão, estabilidade e rastreabilidade metrológica, o que os torna adequados para fins regulatórios, definição de políticas e estudos epidemiológicos.

Por outro lado, tais equipamentos têm custo de aquisição e manutenção elevado, demandam infraestrutura elétrica e de comunicação robusta, além de equipe técnica especializada para operação, calibração e diagnóstico de falhas. Como resultado, a implantação de estações de referência tende a se concentrar em pontos estratégicos, muitas vezes em áreas com maior capacidade institucional ou interesse regulatório, deixando vastas áreas sem monitoramento

contínuo.

Relatórios como o produzido pelo Ministério do Meio Ambiente (MMA) (BRASIL. MINISTÉRIO DO MEIO AMBIENTE E MUDANÇA DO CLIMA, 2025b) evidenciam ainda desafios adicionais, como a heterogeneidade de metodologias entre estados, descontinuidade de séries temporais e dificuldades na integração de dados em plataformas nacionais. Mesmo onde há estações ativas, problemas de manutenção, indisponibilidade de dados em tempo quase real e atrasos em publicações oficiais podem limitar o uso dessas informações para respostas rápidas em episódios críticos. As Figuras 2 e 3 correspondem, respectivamente, ao monitor BAM 1020 e a um analisador contínuo da Thermo Fisher Scientific.

Figura 2 – Estação de monitoramento de referência para  $PM_{2,5}$ .



Fonte: Adaptado de documentação técnica de (MET ONE INSTRUMENTS POWERED BY ACOEM, 2025).

Essas limitações não invalidam a centralidade das estações de referência, mas reforçam a necessidade de soluções complementares que possam ampliar a cobertura espacial

Figura 3 – Estação de monitoramento com módulo de amostragem, analisador contínuo de partículas e sistema de comunicação de dados para transmissão em tempo quase real.



Fonte: Adaptado de (THERMO FISHER SCIENTIFIC, 2025).

e temporal, mantendo um vínculo com a rastreabilidade provida pelos instrumentos de maior precisão.

## 2.6 Sensores de baixo custo para qualidade do ar

O uso de sensores de baixo custo para qualidade do ar tem crescido de forma consistente nos últimos anos, acompanhando avanços em eletrônica embarcada, comunicação sem fio e processamento em nuvem. Em vez de poucas estações de referência dispersas, torna-se possível operar redes com dezenas ou centenas de nós, distribuídos em escala de bairro ou cidade. Revisões recentes mostram que esses sistemas vêm sendo empregados tanto em estudos acadêmicos quanto em iniciativas operacionais, com atenção especial a questões de calibração, padronização e integração com infraestruturas de dados já existentes (Concas *et al.*, 2021; Phala *et al.*, 2016).

No caso do material particulado fino PM<sub>2.5</sub>, há um corpo crescente de trabalhos que avaliam sensores de baixo custo em condições reais de uso. Huda *et al.* (Huda *et al.*, 2024), por exemplo, relatam uma campanha de monitoramento em áreas urbanas de Jodhpur (Índia), utilizando sensores de baixo custo para caracterizar padrões espaciais de qualidade do ar em cenários com recursos limitados. Outros estudos concentram-se na etapa de calibração: Si *et al.* (Si *et al.*, 2020) demonstram o uso de métodos de aprendizado de máquina para avaliar e calibrar um sensor de partículas em condições ambientais reais, enquanto Aula *et al.* (Aula *et al.*, 2022) comparam diferentes modelos de calibração para sensores de baixo custo, discutindo desempenho, robustez e limitações em ambientes urbanos complexos. Em conjunto, esses trabalhos indicam que, quando devidamente calibrados, sensores de PM<sub>2.5</sub> de baixo custo podem fornecer estimativas consistentes com equipamentos de maior precisão, especialmente para fins de mapeamento relativo e análise de tendências.

Do ponto de vista prático, a principal contribuição das redes de sensores de baixo custo está na capacidade de aumentar a resolução espacial e temporal do monitoramento, oferecendo uma visão mais detalhada das variações intraurbanas de PM<sub>2.5</sub> e outros poluentes. Concas et al. (Concas *et al.*, 2021) destacam que essa densificação abre espaço para novas aplicações, como a identificação de microambientes críticos e o suporte a políticas locais de mitigação, mas também introduz desafios em termos de seleção de modelos de calibração, manutenção de longo prazo e manejo do grande volume de dados gerados. Estudos focados em modelagem e calibração (Si *et al.*, 2020; Aula *et al.*, 2022) reforçam que o desempenho de redes de baixo custo depende menos de um único sensor isolado e mais da combinação entre desenho experimental, escolha de modelos, estratégias de co-localização e políticas de controle de qualidade. Em paralelo, a adoção de padrões e arquiteturas compatíveis com sistemas de monitoramento consolidados (Phala *et al.*, 2016) torna-se fundamental para que esses dados possam, no futuro, dialogar com redes oficiais e apoiar ações de gestão ambiental.

## 2.7 Avaliação e calibração de sensores de baixo custo

Para que sensores de baixo custo sejam utilizados de forma confiável, é necessário avaliar seu desempenho em cenários representativos de uso e aplicar calibração sempre que a discrepância em relação a instrumentos de referência exceder limites aceitáveis. Além de fontes clássicas sobre metrologia e instrumentação, documentos técnicos da EPA, como o relatório sobre protocolos, métricas e valores alvo para sensores de PM<sub>2.5</sub> em aplicações de monitoramento suplementar e informacional, propõem conjuntos consistentes de testes, indicadores e critérios mínimos de desempenho (U.S. Environmental Protection Agency, 2021). Entre as métricas recomendadas estão o coeficiente de determinação, os parâmetros da regressão linear, medidas de erro médio e indicadores de precisão. A seguir, descrevem-se brevemente cada uma delas e a forma de cálculo.

Considere um conjunto de  $n$  observações simultâneas de um sensor de baixo custo e de um instrumento de referência. Seja  $y_i$  a leitura de referência (Temptop, por exemplo) e  $\hat{y}_i$  a leitura do sensor ou do modelo calibrado, para  $i = 1, 2, \dots, n$ .

O coeficiente de determinação  $R^2$  mede quão bem as previsões  $\hat{y}_i$  explicam a variabi-

lidade dos valores de referência  $y_i$ . Ele pode ser escrito como

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (2.2)$$

em que  $\bar{y}$  é a média das leituras de referência. Valores de  $R^2$  próximos de 1 indicam maior aderência entre sensor e referência.

Para quantificar o erro médio em unidades físicas de concentração, utiliza-se o erro quadrático médio (*Root Mean Square Error* – RMSE), definido por

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (2.3)$$

Quanto menor o RMSE, menor a discrepância típica (em  $\mu\text{g}/\text{m}^3$ ) entre o sensor e a referência.

Uma forma de tornar esse erro comparável entre diferentes faixas de concentração é normalizá-lo pela média das leituras de referência, obtendo-se o RMSE normalizado (NRMSE) em porcentagem:

$$\text{NRMSE} = \frac{\text{RMSE}}{\bar{y}} \times 100. \quad (2.4)$$

Valores de NRMSE menores indicam melhor desempenho relativo.

Os documentos da EPA recomendam ainda analisar a regressão linear entre as leituras do sensor e da referência. Em muitos estudos, ajusta-se um modelo da forma

$$y_i = a\hat{y}_i + b + \varepsilon_i, \quad (2.5)$$

em que  $a$  é a inclinação (*slope*),  $b$  é o intercepto e  $\varepsilon_i$  é o termo de erro. A inclinação  $a$  indica se o sensor tende a subestimar ou superestimar a variação da referência (valores próximos de 1 são desejáveis), enquanto o intercepto  $b$  representa um viés aditivo aproximadamente constante (espera-se que  $b$  esteja próximo de 0).

A precisão também pode ser avaliada a partir de sensores idênticos operando em paralelo. Sejam  $y_{1,i}$  e  $y_{2,i}$  as leituras de dois sensores iguais no instante  $i$ . Define-se a diferença

$$d_i = y_{1,i} - y_{2,i}, \quad (2.6)$$

e calcula-se, por exemplo, o desvio padrão dessas diferenças,

$$s_d = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (d_i - \bar{d})^2}, \quad (2.7)$$

em que  $\bar{d}$  é a média de  $d_i$ . Valores menores de  $s_d$  indicam melhor repetibilidade entre sensores.

Por fim, é comum analisar a razão entre sensor e referência, útil para identificar vieses multiplicativos. Essa razão pode ser definida como

$$r_i = \frac{\hat{y}_i}{y_i}, \quad (2.8)$$

e resumizada, por exemplo, pela média  $\bar{r}$ . Quando  $\bar{r} \approx 1$ , o sensor não apresenta viés sistemático dominante em relação à referência; valores muito maiores ou menores que 1 indicam subestimação ou superestimação persistente das concentrações.

Revisões recentes organizam o campo de calibração de sensores de baixo custo a partir de dois eixos principais: (i) o momento em que a calibração é realizada (pré-implantação em laboratório ou pós-implantação em campo) e (ii) a classe de modelo adotada (Maag *et al.*, 2018; Concas *et al.*, 2021). Em termos de modelos, destacam-se três categorias centrais: *offset* e ganho, modelos com covariáveis ambientais e calibração em arranjos ou redes de sensores.

A categoria mais simples corresponde à calibração por *offset* e ganho, em que uma curva (em geral linear) é ajustada para transformar a leitura bruta  $C_{\text{sensor}}$  em uma estimativa de concentração  $C_{\text{ref}}$  coerente com a referência (Maag *et al.*, 2018). Esse modelo pode ser escrito como

$$C_{\text{ref}} = a \cdot C_{\text{sensor}} + b, \quad (2.9)$$

em que  $a$  e  $b$  são parâmetros determinados por regressão. A abordagem é atrativa por ser fácil de implementar e interpretar, e costuma produzir melhorias significativas quando o sensor apresenta viés multiplicativo ou aditivo relativamente estável ao longo do tempo.

Uma extensão natural consiste em incorporar variáveis ambientais, como temperatura, umidade relativa e, em alguns casos, concentrações de outros poluentes, tratando a calibração como um problema de regressão multivariada. Nessa classe de modelos, busca-se compensar dependências ambientais e sensibilidade cruzada dos sensores, por exemplo:

$$C_{\text{ref}} = f(C_{\text{sensor}}, T, UR, \dots), \quad (2.10)$$

em que  $f$  pode ser uma regressão linear múltipla ou um modelo não linear. Trabalhos como o de Ali *et al.* comparam explicitamente três níveis de complexidade: (i) correção simples de *offset* e ganho, (ii) regressão linear múltipla com temperatura e umidade relativa e (iii) calibração baseada em redes neurais artificiais, observando ganhos progressivos em termos de MAPE e  $R^2$  à medida que o modelo se torna mais flexível (Ali *et al.*, 2021; Si *et al.*, 2020). De forma

semelhante, revisões como as de Nalakurthi et al. e Hayward et al. destacam o crescimento de abordagens baseadas em Randon Florest e outros métodos de aprendizado de máquina, mas também chamam atenção para desafios de comparabilidade entre estudos, diferenças de protocolo e risco de sobreajuste (Nalakurthi *et al.*, 2024; Hayward *et al.*, 2024).

Uma terceira família de métodos desloca parte do esforço de calibração para o nível de rede, explorando arranjos de sensores e estratégias de recalibração distribuída. Essa classe inclui técnicas colaborativas, em que subconjuntos de nós são co-localizados com referência e depois “transferem” calibrações para outras unidades da mesma série, e abordagens cegas (*blind calibration*), em que a calibração é inferida a partir de redundâncias espaciais e temporais da própria rede (Maag *et al.*, 2018; Concas *et al.*, 2021). Trabalhos recentes têm proposto formulações bayesianas que combinam dados históricos de estações de referência com observações parciais da rede de sensores, buscando aliviar o problema de poucos dados de referência pós-implantação e melhorar a robustez frente a deriva e interferências ambientais (Li *et al.*, 2023).

## 2.8 Co-localização com referência


A forma mais direta de calibrar e avaliar um sensor de baixo custo consiste em co-localizá-lo com uma estação de referência ou monitor equivalente, operando ambos em paralelo por um período suficientemente longo. Durante essa campanha, as leituras são registradas com a mesma resolução temporal e organizadas em uma base de dados comum, permitindo análise estatística detalhada. Esse procedimento é amplamente utilizado tanto para calibração por *offset* e ganho quanto para modelos multivariados e técnicas de aprendizado de máquina (Maag *et al.*, 2018; Concas *et al.*, 2021).

A literatura recomenda campanhas de co-localização com duração de pelo menos algumas semanas, preferencialmente abrangendo diferentes condições meteorológicas e faixas de concentração de PM<sub>2.5</sub> (U.S. Environmental Protection Agency, 2021; Maag *et al.*, 2018). Dados ausentes, valores aberrantes e eventuais falhas de comunicação devem ser tratados de modo transparente, com critérios claros de inclusão e exclusão. Em geral, o conjunto resultante é dividido em subconjuntos para ajuste do modelo de calibração e validação independente (por exemplo, por validação cruzada ou separação em conjuntos de treino e teste), de modo a evitar sobreajuste e obter estimativas realistas de desempenho.

Esse procedimento apresenta vantagens adicionais, como a possibilidade de comparar múltiplos sensores idênticos co-localizados, estimando a repetibilidade entre unidades de um

mesmo modelo, e de verificar a estabilidade temporal da calibração. Em estudos que envolvem redes densas, é comum co-localizar apenas um subconjunto de nós com a referência e utilizar esse grupo como base para transferir calibrações para outros dispositivos da mesma série, ou ainda como *âncoras* em esquemas de calibração colaborativa e cega (Maag *et al.*, 2018; Li *et al.*, 2023). Um esquema simplificado dessa configuração, com uma estação de referência e múltiplos nós *SenseAir*, é apresentado na Figura 4

Figura 4 – Esquema ilustrativo de campanha de co-localização para calibração de sensores de baixo custo. Uma estação de referência central



Fonte: elaborada pelo autor.

### 2.8.1 Modelos de regressão supervisionada para calibração de sensores

A calibração de sensores de baixo custo pode ser formulada como um problema de regressão supervisionada, em que se busca aprender uma função

$$\hat{y} = f(x), \quad (2.11)$$

que aproxima a relação entre a leitura bruta do sensor ( $x$ ) e a concentração de referência medida por um instrumento de melhor desempenho ( $y$ ). Diversos trabalhos recentes em calibração de sensores de qualidade do ar avaliam e comparam diferentes modelos de regressão, incluindo

métodos lineares e modelos não lineares baseados em *machine learning* (Concas *et al.*, 2021; Si *et al.*, 2020; Aula *et al.*, 2022; Ali *et al.*, 2021).

### 2.8.1.1 Regressão linear

A regressão linear é o modelo mais simples e amplamente utilizado como linha de base em problemas de regressão, incluindo aplicações de calibração de sensores de PM2.5. No caso univariado, assume-se que a relação entre a leitura do sensor e a referência pode ser descrita por

$$y = \beta_0 + \beta_1 x + \varepsilon, \quad (2.12)$$

em que  $\beta_0$  é o intercepto,  $\beta_1$  é o coeficiente angular (ganho) e  $\varepsilon$  representa o termo de erro. Os parâmetros são normalmente estimados por mínimos quadrados ordinários, minimizando a soma dos erros ao quadrado (Montgomery *et al.*, 2012; Hastie *et al.*, 2009). Pela sua interpretabilidade e baixo custo computacional, a regressão linear costuma ser o primeiro modelo avaliado em problemas de calibração e modelagem preditiva.

### 2.8.1.2 KNN

O regressor KNN. é um método não paramétrico em que a predição para um novo ponto  $x^*$  é obtida a partir das  $k$  amostras de treinamento mais próximas de  $x^*$  no espaço de entrada. De forma simplificada, a predição pode ser escrita como

$$\hat{y}(x^*) = \frac{1}{k} \sum_{x_i \in \mathcal{N}_k(x^*)} y_i, \quad (2.13)$$

em que  $\mathcal{N}_k(x^*)$  denota o conjunto dos  $k$  vizinhos mais próximos de  $x^*$  e  $y_i$  são os valores de referência associados. O KNN é capaz de capturar relações não lineares sem assumir uma forma funcional específica para  $f(\cdot)$ , mas sua qualidade depende da densidade de pontos no espaço de entrada e da escolha adequada de  $k$  (Cover; Hart, 1967; Hastie *et al.*, 2009).

### 2.8.1.3 Random Forest

O modelo *Random Forest* é um método de comitê baseado em árvores de decisão, em que vários regressores em árvore são treinados sobre subconjuntos aleatórios dos dados e/ou das variáveis, e a predição final resulta da média das saídas das árvores individuais. Sejam

$T_1, T_2, \dots, T_M$  as árvores do conjunto; a predição pode ser escrita como

$$\hat{y}(x) = \frac{1}{M} \sum_{m=1}^M T_m(x). \quad (2.14)$$

Esse tipo de modelo é capaz de capturar não linearidades e interações entre variáveis, tende a ser robusto a ruído e a sobreajuste moderado e é amplamente utilizado em tarefas de regressão e classificação com dados tabulares (Breiman, 2001; Hastie *et al.*, 2009).

#### 2.8.1.4 Support Vector Regression SVR com kernel RBF

A *Support Vector Regression* / Regressão por Vetores de Suporte (SVR) é a extensão para regressão do método de *Support Vector Machine* / Máquina de Vetores de Suporte (SVM). Na SVR, procura-se uma função que aproxime os dados com erro no máximo  $\varepsilon$  para a maior parte dos pontos, maximizando ao mesmo tempo a margem do modelo. Quando se utiliza um *kernel* radial de base gaussiana RBF, os dados são implicitamente mapeados para um espaço de dimensão mais alta, permitindo capturar relações não lineares entre leituras do sensor e valores de referência (Cortes; Vapnik, 1995; Smola; Schölkopf, 2004). Modelos SVR com *kernel* RBF são particularmente úteis quando o conjunto de dados não é muito grande e se deseja controlar a complexidade do modelo via hiperparâmetros como  $C$ ,  $\varepsilon$  e o parâmetro do *kernel*.

#### 2.8.1.5 Perceptron multicamada MLP

O *Multi-Layer Perceptron* / Perceptron Multicamada (MLP) é um tipo de rede neural artificial composta por camadas de neurônios interconectados, com funções de ativação não lineares. Em um MLP simples para regressão com uma camada oculta, a saída pode ser escrita como

$$\hat{y}(x) = \phi_{\text{out}} \left( \sum_{j=1}^H w_j^{(2)} \phi_{\text{hid}} \left( w_j^{(1)} x + b_j^{(1)} \right) + b^{(2)} \right), \quad (2.15)$$

em que  $H$  é o número de neurônios na camada oculta,  $w_j^{(1)}$  e  $w_j^{(2)}$  são os pesos das camadas intermediária e de saída,  $b_j^{(1)}$  e  $b^{(2)}$  são termos de viés, e  $\phi_{\text{hid}}$  e  $\phi_{\text{out}}$  são funções de ativação. Por serem aproximadores universais, MLP conseguem modelar relações complexas entre sensores e referência, mas requerem maior cuidado na escolha da arquitetura, na regularização e no tamanho do conjunto de dados para evitar sobreajuste (Bishop, 2006; Goodfellow *et al.*, 2016).

## **2.9 Fatores que degradam a qualidade do ar em contextos urbanos**

A qualidade do ar em áreas urbanas resulta da interação entre múltiplas fontes de emissão, processos físicos e químicos na atmosfera e condições meteorológicas.

### **2.9.1 Tráfego veicular**

O papel do tráfego veicular nas concentrações urbanas de partículas finas não se limita às emissões de escapamento. Revisão recente de literatura mostra que partículas geradas por desgaste de freios, pneus e pavimento, bem como pela ressuspensão de poeira de pista, já respondem por parcela relevante da massa de material particulado associada ao tráfego em muitos centros urbanos, podendo inclusive se aproximar das emissões de escapamento em alguns cenários (Fussell *et al.*, 2022)

### **2.9.2 Emissões industriais**

Instalações industriais de grande porte, como refinarias de petróleo, complexos petroquímicos, siderúrgicas, fábricas de cimento e usinas termelétricas, são reconhecidas como fontes relevantes de material particulado fino e de espécies químicas associadas em áreas urbanas e periurbanas. Revisão recente sobre qualidade do ar em regiões influenciadas por grandes complexos industriais mostra que emissões provenientes de processos de combustão e de operações industriais podem contribuir de forma significativa para as concentrações de PM<sub>2.5</sub> observadas em bairros vizinhos, muitas vezes caracterizados por uso misto industrial–residencial, e discute os impactos potenciais desses perfis de poluição na saúde da população exposta (Fadel *et al.*, 2024; Karagulian *et al.*, 2015).

### **2.9.3 Queimadas**

Queimadas em áreas rurais, queima de resíduos sólidos e incêndios em vegetação urbana constituem fontes importantes de PM<sub>2.5</sub>, especialmente em períodos secos. Revisão recente sobre a região Amazônica mostra que a exposição à fumaça de queimadas está associada a aumento de sintomas respiratórios, exacerbações de asma e internações hospitalares, evidenciando o impacto sanitário desses episódios (Urrutia-Pereira *et al.*, 2021). Em cidades de clima temperado, o uso de lenha para aquecimento residencial durante o inverno também é uma fonte relevante de aerossóis finos, e estudos em ambientes urbanos europeus indicam que a queima

de biomassa pode responder por parcela importante da massa e da fração orgânica do material particulado fino em períodos frios (Sopčić *et al.*, 2025).

#### **2.9.4 Condições meteorológicas**

Variáveis meteorológicas como velocidade e direção do vento, temperatura, umidade relativa, precipitação e estabilidade atmosférica influenciam diretamente a dispersão, a transformação e a remoção de poluentes. Estudos recentes em cidades brasileiras e asiáticas mostram que variações sazonais e diárias desses parâmetros explicam parcela substancial da variabilidade observada em PM<sub>2.5</sub>, modulando tanto a formação de aerossóis secundários quanto a eficiência de processos de deposição seca e úmida (Souza *et al.*, 2025; Hwang; Park, 2025). Em dias de forte estabilidade, com camada de mistura rasa e ventos fracos, emissões tendem a se acumular próximo à superfície, resultando em concentrações elevadas mesmo sem aumento expressivo nas fontes; por outro lado, episódios de chuva e períodos com maior ventilação favorecem a diluição e a remoção de partículas.

As diretrizes da OMS e análises recentes sobre os novos limites globais enfatizam que a interpretação de séries temporais de poluentes deve considerar explicitamente o regime meteorológico, tanto ao comparar períodos distintos quanto ao avaliar tendências de longo prazo (WORLD HEALTH ORGANIZATION, 2021; Pai *et al.*, 2022).

#### **2.10 Estudos relacionados sobre monitoramento da qualidade do ar**

Diversos autores propuseram soluções baseadas em *Internet of Things* / Internet das Coisas (IoT) para monitoramento da qualidade do ar, explorando diferentes combinações de sensores, conectividade, alimentação de energia e interfaces de visualização. De modo geral, esses trabalhos buscam conciliar baixo custo, possibilidade de implantação em larga escala e disponibilidade quase em tempo real das medições para usuários e gestores.

Bermudez Arboleda e Shamim (Arboleda; Shamim, 2024) apresentam um *wireless sensor node* autoalimentado e de baixo custo para monitoramento da qualidade do ar, destacando duas inovações principais de hardware. A primeira é o uso de uma antena inteligente opticamente transparente, que permite a instalação discreta do sensor em ambientes urbanos sem comprometer a estética do entorno. A segunda é a integração de células solares transparentes, possibilitando operação autônoma sem necessidade de fonte de alimentação externa. O nó é capaz de medir os

principais parâmetros associados ao índice de qualidade do ar (AQI), o que o torna atrativo para projetos de monitoramento em larga escala, sobretudo em regiões com restrições orçamentárias.

Sharafat Ali et al. (Ali *et al.*, 2021) propõem um nó sensor que combina duas tecnologias de comunicação: LoRaWAN, de longo alcance e baixo consumo de energia, para comunicação em área ampla, e Wi-Fi, de curta distância e alta taxa de dados, para transmissão local e configuração. O dispositivo é projetado para monitorar poluentes como CO, NO<sub>2</sub> e material particulado, podendo ser alimentado por bateria recarregada por energia solar ou por rede elétrica. Além disso, os autores exploram técnicas de calibração baseadas em aprendizado de máquina, comparando abordagens tradicionais com modelos mais flexíveis para reduzir o erro em relação à referência.

Payali Das et al. (Das *et al.*, 2022) apresentam um dispositivo de baixo custo para monitoramento de poluição do ar ambiente, no qual se destaca a integração de um subsistema de GPS. O equipamento, denominado APMD (*Air Pollution Monitoring Device*), agrega as medições de qualidade do ar em quadros que incluem posição geográfica, data e horário, enviando essas informações para um servidor em nuvem. Essa integração permite associar diretamente concentração de poluentes e localização, favorecendo análises espaciais mais detalhadas e a construção de mapas de poluição.

Purbakawaca et al. (Purbakawaca *et al.*, 2022) desenvolvem um sistema de monitoramento de ar ambiente com ênfase em estabilidade de desempenho ao longo do tempo. O trabalho inclui um painel de visualização integrado ao Google Maps, que apresenta a localização dos pontos de medição e os valores dos parâmetros monitorados, acessível por meio de navegador em dispositivos móveis. Essa abordagem reforça o papel de interfaces georreferenciadas na interpretação dos dados e na comunicação com usuários não especializados.

A Tabela 3 apresenta uma visão comparativa dos trabalhos mencionados, destacando os tipos de sensores de qualidade do ar empregados, a presença de geolocalização, o uso de aplicativos móveis e a integração de câmeras para análise de tráfego ou outras aplicações complementares.

Observa-se que os estudos analisados tendem a enfatizar subconjuntos específicos de funcionalidades, como autoalimentação e transparência óptica do nó sensor (Arboleda; Shamim, 2024), estratégias de comunicação eficientes (Ali *et al.*, 2021) ou integração de geolocalização e painéis georreferenciados (Das *et al.*, 2022; Purbakawaca *et al.*, 2022). Em contraste, o protótipo desenvolvido nesta dissertação integra sensores de PM<sub>2.5</sub>, geolocalização, aplicativo móvel e um

Tabela 3 – Comparação entre sistemas de monitoramento da qualidade do ar baseados em IoT

<b>Estudo</b>	<b>Sensores de qualidade do ar</b>	<b>GPS</b>	<b>App móvel</b>	<b>Câmera</b>
Bermudez Arboleda et al. (2024)	Conjunto de sensores AQI	Não	Não	Não
Sharafat Ali et al. (2021)	CO, NO <sub>2</sub> , PM <sub>10</sub>	Não	Não	Não
Payali Das et al. (2022)	Conjunto de sensores AQI	Sim	Não	Não
Purbakawaca et al. (2022)	CO, NO <sub>2</sub> , SO <sub>2</sub> , PM <sub>2,5</sub> , PM <sub>10</sub>	Sim	Sim	Não
<b>Este trabalho</b>	PM <sub>2,5</sub>	Sim	Sim	Sim

Fonte: elaborada pelo autor.

sistema embarcado para detecção de veículos por visão computacional. Essa combinação permite monitorar simultaneamente a qualidade do ar e a dinâmica do tráfego em escala local, abrindo espaço para análises mais completas das interações entre emissões veiculares e concentrações de material particulado.

### 3 METODOLOGIA

Este capítulo descreve a metodologia adotada para conceber, implementar e avaliar a solução integrada proposta para monitoramento da qualidade do ar com o nó *SenseAir*. São apresentados o ambiente de estudo, a arquitetura de hardware e software, o fluxo de dados desde a borda até o aplicativo móvel, o desenvolvimento do modelo de visão computacional para quantificação de tráfego e o procedimento de calibração exploratória de PM<sub>2.5</sub> por comparação com um equipamento multiparâmetro Temtop M2000 de segunda geração, em experimento realizado em laboratório de produção de asfalto. Por fim, detalham-se o protocolo experimental em campo, os métodos de análise dos dados coletados e as principais limitações metodológicas.

#### 3.1 Visão geral da abordagem metodológica

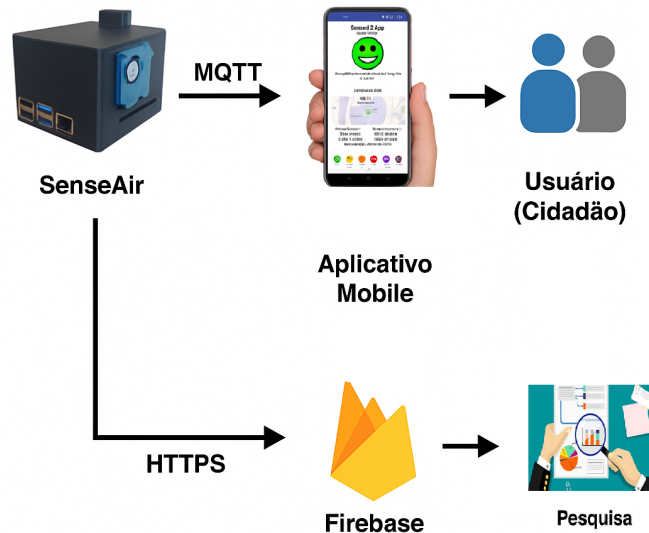
A abordagem metodológica foi organizada em três frentes complementares, cobrindo desde a construção do sistema até a avaliação exploratória em ambiente real:

- **Arquitetura de monitoramento:** concepção e implementação do nó *SenseAir*, incluindo seleção e integração dos componentes, desenvolvimento de *firmware* e software embarcado, e a infraestrutura de armazenamento/serviços em nuvem. Foi também desenvolvido um aplicativo móvel para visualização em tempo quase real de indicadores de qualidade do ar.
- **Calibração exploratória e caracterização de tráfego:** construção de um procedimento de calibração exploratória para PM<sub>2.5</sub> a partir de comparação pontual, em laboratório, com o equipamento Temtop M2000 (2<sup>a</sup> geração). As diretrizes recentes da EPA para avaliação de sensores de baixo custo (U.S. Environmental Protection Agency, 2021) são adotadas como referência conceitual, reconhecendo-se que o Temtop não é um monitor regulamentar de referência e que o conjunto de dados disponível é limitado. Em paralelo, foi desenvolvido um módulo experimental de visão computacional YOLO para investigar a viabilidade de estimar fluxo veicular em tempo quase real, além de contagens manuais realizadas nas campanhas de campo para contextualização do cenário.
- **Avaliação em campo:** realização de campanhas exploratórias em um túnel urbano, em três condições representativas de diferentes intensidades de tráfego: (i) entrada do túnel, associada a fluxo intenso; (ii) interior do túnel, com baixo movimento; e (iii) interior do túnel, com fluxo mediano. Nessas campanhas, o foco da análise recaiu sobre os dados de PM<sub>2.5</sub> medidos pelo *SenseAir*, após tratamento e aplicação da correção linear obtida em

laboratório, comparando-se padrões e variações de concentração entre os cenários.

A Figura 5 resume a cadeia de dados do sistema *SenseAir*, desde a aquisição no nó embarcado até o armazenamento no Firebase e a disponibilização das informações no aplicativo móvel.

Figura 5 – Visão geral da arquitetura do sistema *SenseAir*.



Fonte: elaborada pelo autor.

### 3.2 Ambiente de estudo e cenários de uso

O estudo foi conduzido em dois contextos experimentais:

1. **Laboratório (produção de asfalto):** ensaio exploratório no qual o nó *SenseAir* operou em paralelo ao Temtop M2000 para comparação pontual das leituras de PM2.5 em ambiente controlado, porém com emissão de partículas associada ao manuseio de agregados e misturas asfálticas.
2. **Campo (túnel urbano):** campanhas com o *SenseAir* em três condições de medição no mesmo túnel rodoviário: entrada (fluxo intenso), interior com baixo movimento e interior com fluxo mediano. O objetivo foi avaliar, de forma indicativa, como alterações no confinamento e no fluxo veicular se refletem nos níveis de PM2.5 observados.

A seleção dos pontos de medição em campo considerou: (i) presença de tráfego veicular relevante, (ii) viabilidade de instalação e operação segura do nó *SenseAir* e (iii) possibilidade de repetir medições em condições comparáveis. A comparação entre as três condições no túnel busca evidenciar, ainda que de maneira exploratória, padrões de aumento, redução

e variabilidade temporal de PM<sub>2.5</sub> em microambientes com diferentes níveis de ventilação e intensidade de tráfego.

Do ponto de vista de aplicação, a arquitetura proposta foi projetada para suportar, em princípio, três classes de uso:

1. **Monitoramento indicativo em redes densas:** distribuição de múltiplos nós para capturar gradientes intraurbanos de PM<sub>2.5</sub> e apoiar análises exploratórias;
2. **Estudos sobre tráfego e poluição:** implantação em pontos específicos de vias para investigar a associação entre variáveis de mobilidade e episódios de elevação de PM<sub>2.5</sub>;
3. **Comunicação com o público:** disponibilização, via aplicativo móvel, de uma indicação do índice de qualidade do ar em tempo quase real, em linguagem compatível com práticas adotadas por órgãos ambientais (CETESB, 2023).

Nesta dissertação, esses usos são avaliados em escala piloto, com um único nó *SenseAir* e campanhas de curta duração. A ênfase recai na demonstração da viabilidade técnica da cadeia completa (nó, nuvem e aplicativo), bem como na análise exploratória dos dados de PM<sub>2.5</sub> em ambiente urbano confinado. A implantação de redes com múltiplos nós e maior cobertura espacial é deixada como perspectiva para trabalhos futuros.

### 3.3 Arquitetura do sistema *SenseAir*


A arquitetura do sistema *SenseAir* segue o modelo em camadas discutido no Capítulo 2, combinando um nó de borda com sensores embarcados, um fluxo de comunicação baseado em MQTT e HTTPS, serviços em nuvem para armazenamento histórico e um aplicativo móvel para visualização. As subseções a seguir detalham o hardware, o *firmware* e o software embarcado.

#### 3.3.1 *Hardware do nó*

O nó *SenseAir* é construído por um conjunto de módulos integrados em torno de um Raspberry Pi 4 Model B, a saber: (i) placa principal de processamento, (ii) módulo de alimentação ininterrupta (UPS HAT) com baterias 18650, (iii) sensor de partículas, (iv) sensor ambiental, (v) módulo de GPS e (vi) câmera USB para visão computacional. As Figuras 6 a 12 ilustram individualmente esses componentes.


Do ponto de vista elétrico e de comunicação, o Raspberry Pi 4B funciona como

Figura 6 – Raspberry Pi 4 Model B



Fonte: elaborada pelo autor.

Figura 7 – Placa UPS HAT para duas baterias 18650



Fonte: elaborada pelo autor.


concentrador de todas as interfaces. A UPS HAT é conectada diretamente ao conector de 40 pinos do Raspberry Pi, fornecendo 5 V para a placa e realizando o gerenciamento de carga das duas baterias 18650. Os sensores BME280 e HM3301 compartilham o mesmo barramento I<sup>2</sup>C, ligado às linhas SDA e SCL expostas no conector GPIO (pinos físicos correspondentes aos GPIO3/SDA e GPIO5/SCL). Cada módulo possui endereço I<sup>2</sup>C próprio, o que permite a leitura simultânea no mesmo barramento.

Figura 8 – Módulo BME280




Fonte: elaborada pelo autor.

Figura 9 – Sensor óptico de partículas HM3301



Fonte: elaborada pelo autor.

Figura 10 – Módulo GPS GY-NEO6MV2



Fonte: elaborada pelo autor.

Figura 11 – Câmera USB.



Fonte: elaborada pelo autor.

Figura 12 – baterias Li-ion 18650.

Copyright 2021 - Prolumen



Fonte: elaborada pelo autor.

O módulo GPS GY-NEO6MV2 é conectado à interface UART do Raspberry Pi, operando em nível TTL: a saída de dados do GPS (TX) é ligada ao pino configurado como RX da UART (GPIO10), enquanto alimentação e terra são ligados às linhas de 3,3 V e GND, respectivamente. A câmera utilizada é conectada a uma das portas USB do Raspberry Pi, simplificando a integração com bibliotecas de visão computacional e permitindo a substituição do dispositivo sem alterações no cabeamento do GPIO.

A Tabela 4 resume os principais componentes do nó *SenseAir*, destacando função, interface empregada e pinos do Raspberry Pi utilizados, facilitando a reprodução do hardware em outros contextos.

### 3.3.2 *Firmware e software embarcado*

O firmware do nó *SenseAir* implementa todo o fluxo ilustrado na Figura 5: leitura dos sensores, cálculo de indicadores, publicação das medições via MQTT para o aplicativo móvel utilizado por cidadãos e envio, via HTTPS, de registros históricos para o Firebase, destinado à análise de pesquisa. Além disso, o nó executa o modelo de visão computacional responsável

Tabela 4 – Componentes principais do nó *SenseAir*, funções e interfaces de comunicação.

<b>Componente</b>	<b>Modelo ou tipo</b>	<b>Função principal</b>	<b>Interface / pinos no Raspberry Pi</b>
Placa principal	Raspberry Pi 4B	Processamento, comunicação e execução do modelo YOLO	CPU, RAM, Wi-Fi, Ethernet e GPIO de 40 pinos
UPS HAT	HAT para 2 baterias 18650	Gerenciamento de energia e recarga das baterias	Conectado ao conector GPIO (5 V, 3,3 V e GND)
Sensor de partículas	HM3301	Medição de PM <sub>1,0</sub> , PM <sub>2,5</sub> e PM <sub>10</sub>	I <sup>2</sup> C: GPIO2 (SDA), GPIO3 (SCL), 5 V e GND
Sensor ambiental	BME280	Medição de temperatura, umidade relativa e pressão atmosférica	I <sup>2</sup> C: GPIO2 (SDA), GPIO3 (SCL), 3,3 V e GND
Módulo GPS	GY-NEO6MV2	Geolocalização do nó e referência temporal	UART TTL: GPIO15 (RXD), GPIO14 (TXD), 3,3 V e GND
Câmera	Câmera USB	Captura de vídeo para detecção e contagem de veículos	Porta USB (UVC)
Baterias	2 baterias Li-ion 18650 (3500 mAh)	Suprimento de energia e autonomia nas campanhas	Conectadas à UPS HAT

Fonte: Elaborado pelo autor.

pela avaliação da possibilidade de detecção e contagem de veículos em tempo quase real.

A pilha de software é construída sobre o sistema operacional Raspberry Pi OS (Legacy, 64-bit) Lite. Sobre essa base são executados serviços desenvolvidos em Python, configurados como *daemons* de sistema, de forma a iniciar automaticamente na energização do dispositivo. Na prática, o firmware é organizado em três blocos principais: (i) serviço de aquisição de dados ambientais e geográficos, (ii) serviço de visão computacional para tráfego e (iii) cliente de publicação de dados (MQTT/HTTPS).

O fluxo de execução pode ser resumido nas seguintes etapas:

- Inicialização:** após o *boot* do Raspberry Pi OS, os serviços de aquisição de sensores, visão computacional e comunicação são iniciados em segundo plano. Não é necessária interação do usuário para colocar o nó em operação.
- Aquisição de sensores:** em intervalos de tempo pré-definidos (tipicamente um minuto), o serviço de aquisição lê o sensor de partículas (HM3301), o sensor ambiental (BME280) e o módulo GPS. A partir dessas leituras, é construído um registro contendo concentrações

de PM2.5, temperatura, umidade relativa, pressão atmosférica, horário e coordenadas geográficas do nó. Nesse momento também é calculado o índice de qualidade do ar provisório (IQA) correspondente à concentração de PM2.5, com base nas faixas apresentadas no Capítulo 2.

3. **Publicação MQTT para o aplicativo móvel:** o registro é serializado em formato JSON e publicado em tópicos MQTT específicos, organizados por identificador do nó e tipo de dado (por exemplo, `senseair/{id}/pm`, `/meteo`, `/gps`, `/iqa`). O aplicativo móvel se inscreve nesses tópicos e apresenta, em tempo real, a concentração de PM2.5 e o IQA para o usuário final (cidadão), conforme ilustrado na parte superior da Figura 5.
4. **Captura de vídeo, detecção e contagem de veículos:** em paralelo, um segundo serviço realiza a captura contínua de *frames* da câmera USB. Cada *frame* é processado pelo modelo YOLO embarcado no Raspberry Pi, produzindo detecções de veículos em cinco classes (ambulância, carro, motocicleta, ônibus e caminhão). As detecções instantâneas são acumuladas ao longo de janelas de 1 minuto, sincronizadas com a aquisição dos demais parâmetros ambientais, resultando em contagens por classe para cada intervalo. Esses dados de tráfego não são exibidos diretamente no aplicativo móvel.
5. **Envio HTTPS para o Firebase:** ao término de cada janela de 1 minuto, o nó *SenseAir* monta um registro único agregando todas as informações coletadas naquele período — identificador do nó, carimbo de data e hora, localização, medições de PM2.5, variáveis meteorológicas, IQA calculado e contagens de veículos por classe. Esse registro é serializado em JSON e enviado diretamente ao Firebase por meio de requisições HTTPS, utilizando a API de escrita do serviço. A base histórica formada no Firebase não é acessada pelo usuário final por meio do aplicativo móvel, mas serve como insumo para as análises de pesquisa e para a elaboração dos resultados apresentados nos capítulos seguintes.

Ao longo da operação, o *SenseAir* registra em arquivos de log eventos como falhas de leitura de sensores, perda temporária de conexão com o *broker* MQTT ou indisponibilidade do Firebase. Esses registros permitem diagnosticar problemas de hardware, comunicação ou configuração, e são úteis para planejamento de melhorias em versões futuras do protótipo.

### 3.3.3 Avaliação de desempenho computacional e energético do nó

Com o objetivo de caracterizar o desempenho computacional e energético do nó *SenseAir*, foram realizadas medições em condições controladas, com o dispositivo operando em

diferentes modos de carga: (i) apenas aquisição de sensores, (ii) aquisição de sensores com envio de dados para nuvem e (iii) operação completa com execução contínua do modelo YOLO.

O uso de CPU e memória foi acompanhado por meio de ferramentas nativas do sistema operacional `htop`, registrando-se a porcentagem máxima e média de utilização do processador e a ocupação de memória durante janelas de 2 horas em cada modo de operação. A taxa de quadros efetivamente processados pelo modelo YOLO foi estimada a partir de *logs* de inferência, permitindo relacionar desempenho de detecção ao uso de recursos de hardware.

Para avaliar o consumo de corrente elétrica e a autonomia em bateria, foram utilizados os recursos de monitoramento da própria placa UPS HAT. Esse módulo disponibiliza, via interface I<sup>2</sup>C, medições de tensão no barramento de carga, corrente instantânea, potência e estimativa de porcentagem de carga das baterias. Um script em Python foi executado periodicamente no *SenseAir* para registrar esses valores nos modos de operação já citados. A partir das medições de potência em regime permanente e da variação da porcentagem de carga ao longo do tempo durante operação exclusivamente em bateria, estimou-se a autonomia aproximada do nó *SenseAir* para campanhas de campo, sem necessidade de instrumentação externa adicional.

### 3.4 Aplicativo móvel e apresentação do IQA

O aplicativo móvel foi desenvolvido com o objetivo de oferecer ao usuário leigo uma leitura direta da qualidade do ar em sua vizinhança, em formato semelhante ao praticado por órgãos ambientais que utilizam índices de qualidade do ar (CETESB, 2023). A implementação foi realizada na plataforma App Inventor, que permite construir interfaces gráficas e lógica de interação com serviços de mensagem de forma visual, o que facilita futuras modificações por equipes não especializadas em desenvolvimento *mobile* nativo.

As principais funcionalidades do aplicativo são:

- **Localização do usuário:** o aplicativo obtém a posição atual do dispositivo por meio dos serviços de geolocalização do sistema operacional, permitindo associar o usuário ao nó *SenseAir* mais próximo.
- **Assinatura de tópicos MQTT:** uma vez escolhido o nó, o aplicativo se inscreve nos tópicos MQTT correspondentes (por exemplo, `senseair/{id}/pm` e `/iqa`) e passa a receber as medições em tempo quase real.
- **Apresentação do IQA:** a cada nova mensagem recebida, o aplicativo atualiza a tela principal exibindo o valor corrente do IQA, acompanhado de um ícone colorido e de um

texto curto que descreve a condição de qualidade do ar. As faixas de cores e mensagens seguem a lógica de categorias inspiradas em referências como a U.S. EPA e a CETESB (WORLD HEALTH ORGANIZATION, 2024; CETESB, 2023).

- **Mapa dos nós:** o aplicativo oferece ainda uma tela com mapa contendo a posição dos nós *SenseAir* disponíveis, configurada a partir de suas coordenadas geográficas. Essa visualização auxilia o usuário a entender a cobertura espacial do sistema e a selecionar manualmente um nó específico, quando desejado.

Dessa forma, o aplicativo atua como a principal interface entre o cidadão e o sistema *SenseAir*, traduzindo medições técnicas em informações sintéticas e visualmente acessíveis sobre a qualidade do ar no entorno imediato do usuário.

### 3.5 Modelo de visão computacional para tráfego

O componente de visão computacional do sistema tem como objetivo estimar, de forma exploratória, o fluxo e a composição da frota veicular em frente ao nó *SenseAir*. Para isso, foi adotada a família de modelos YOLO. Foram treinadas e avaliadas três variantes compactas YOLOv8n, YOLOv10n e YOLOv11n utilizando a mesma base de dados e o mesmo procedimento experimental, de modo a comparar o compromisso entre desempenho de detecção e viabilidade de execução em hardware embarcado. A escolha do modelo a ser implementado no *SenseAir* foi baseada principalmente em métricas de desempenho (*precision*, *recall* e mAP50), priorizando um comportamento mais equilibrado para contagem veicular em tempo quase real.

#### 3.5.1 Conjunto de dados e processo de treinamento

O treinamento dos modelos foi realizado em ambiente com maior capacidade computacional, utilizando um conjunto de dados público de detecção de veículos disponível na plataforma Kaggle (Erturan, 2023). Esse conjunto contém imagens de tráfego rodoviário anotadas com caixas delimitadoras e classes de veículos.

A adaptação do conjunto de dados para o contexto desta dissertação envolveu:

- revisão das anotações para garantir consistência entre classes;
- divisão do conjunto em subconjuntos de treinamento, validação e teste.

Durante o treinamento, o desempenho foi monitorado por métricas de detecção por classe, em particular *precision*, *recall* e mAP50. A *precision* (precisão) quantifica a fração de

detecções feitas pelo modelo que são corretas, isto é, a proporção de *true positives* em relação ao total de predições positivas ( $TP/(TP + FP)$ ); valores altos indicam menor incidência de falsos positivos. O *recall* (revocação) mede a capacidade do modelo de encontrar os objetos presentes nas imagens, correspondendo à proporção de *true positives* em relação ao total de objetos reais ( $TP/(TP + FN)$ ); valores altos indicam menor incidência de falsos negativos. Já o mAP50 (*mean Average Precision* a IoU de 0,5) resume o desempenho de detecção ao integrar a curva *precision–recall* para cada classe (AP).

### 3.5.2 *Otimização e implantação no Raspberry Pi*

Após o treinamento, o modelo YOLOv8n foi convertido para formato adequado à execução no Raspberry Pi 4B. A implantação envolveu:

- carregamento do arquivo .pt em um script Python no Raspberry Pi;
- medição de taxa de quadros por segundo;

Em operação, a câmera fornece um fluxo contínuo de frames. Cada frame é processado pelo modelo YOLO, que produz detecções com caixas delimitadoras e rótulos em uma das cinco classes definidas. As detecções são então convertidas em contagens por classe em janelas temporais curtas e publicadas via HTTPS para o firebasse, de modo que possam ser correlacionadas com as medições de PM2.5 obtidas pelo mesmo nó.

### 3.5.3 *Métricas de desempenho do modelo em campo*

O desempenho do modelo em campo foi avaliado de forma qualitativa por inspeção das detecções geradas em condições reais de operação, considerando variações de iluminação e diferentes intensidades de fluxo veicular (baixo, mediano e intenso). Para verificação da consistência das estimativas, em trechos selecionados foram realizadas contagens manuais de veículos e os totais obtidos foram comparados com aqueles estimados automaticamente pelo módulo de contagem do *SenseAir*. Essa comparação foi utilizada como referência prática para identificar discrepâncias e limitações típicas do cenário (por exemplo, oclusões, sobreposição de veículos e confusões entre classes). Ressalta-se que o objetivo desta dissertação não é uma validação exaustiva do modelo de visão computacional, mas demonstrar a viabilidade de obter indicadores de tráfego suficientemente consistentes para apoiar análises exploratórias em conjunto com os dados de PM2.5 no futuro.

### 3.6 Metodologia de calibração exploratória de PM2.5

A calibração de PM2.5 neste trabalho é de caráter exploratório e baseia-se na comparação entre o nó *SenseAir* e um equipamento Temtop M2000 de segunda geração, que é um analisador multiparâmetro portátil comercial. Embora o Temtop não seja um monitor regulamentar de referência, ele apresenta especificações superiores às de sensores ópticos de baixo custo típicos, o que o torna uma *proxy* pragmática para avaliar o comportamento do *SenseAir* em condições controladas.

O conjunto de dados disponíveis para essa comparação é reduzido, limitado pelo acesso ao laboratório de produção de asfalto e pela duração dos ensaios. Assim, os resultados da calibração devem ser interpretados como prova de conceito, não como validação formal nos moldes dos protocolos completos descritos em documentos da U.S. EPA (U.S. Environmental Protection Agency, 2021). O objetivo principal é verificar se uma correção simples (por exemplo, linear) é capaz de reduzir vieses mais evidentes e aproximar qualitativamente o desempenho do *SenseAir* de um comportamento desejável.

#### 3.6.1 Procedimento de comparação em laboratório

A comparação entre o *SenseAir* e o Temtop M2000 foi realizada em um laboratório de produção de asfalto, ambiente no qual há emissão de partículas associadas ao manuseio de agregados, betume e mistura asfáltica. Nesse contexto, o nó *SenseAir* e o Temtop foram posicionados lado a lado, em altura semelhante e sem obstruções entre os equipamentos, de modo a amostrar a mesma massa de ar em um espaço relativamente confinado.

A Figura 13 ilustra o equipamento Temtop M2000 utilizado como *proxy* de referência no experimento de calibração exploratória em laboratório.

A Figura 14 apresenta a distribuição do número de pares de dados Temtop–*SenseAir* obtidos em cada dia de medição, após o alinhamento temporal e a seleção dos instantes em comum que compõem a base utilizada na calibração.

Durante o período do experimento, ambos os equipamentos registraram leituras de PM2.5 em intervalos regulares. O procedimento adotado envolveu:


- sincronização aproximada do horário entre o Raspberry Pi e o Temtop, por meio de ajuste manual e/ou alinhamento posterior com base nos carimbos de data e hora;
- registro das leituras do Temtop em planilha ou arquivo de texto, com carimbo de data e

Figura 13 – Equipamento Temtop M2000



Fonte: elaborada pelo autor.

Figura 14 – Quantidade de pares de dados Temtop–SenseAir de PM2.5 obtidos em cada dia do experimento de calibração



Fonte: elaborada pelo autor.

hora;

- exportação das leituras do *SenseAir* a partir das mensagens registradas no Firebase para o intervalo correspondente ao experimento em laboratório;
- construção de uma base conjunta contendo pares de leituras *SenseAir*–Temtop obtidas em instantes tão próximos quanto possível.

Dado o número limitado de pontos, priorizou-se a qualidade da correspondência temporal entre as leituras, mesmo que isso implicasse o descarte de amostras para as quais não

havia par adequado no outro equipamento.

### 3.6.2 Ajuste do modelo e análise de métricas

Com a base conjunta de pares *SenseAir*–Temtop construída na Seção 3.6.1, adotou-se uma abordagem supervisionada para aprender uma função de calibração que aproxima as leituras do *SenseAir* dos valores indicados pelo Temtop M2000. As leituras brutas de PM<sub>2.5</sub> do *SenseAir* foram usadas como variável independente ( $X$ ) e as leituras correspondentes do Temtop como variável dependente ( $y$ ).

Como linha de base, foram inicialmente calculadas métricas de desempenho considerando o *SenseAir* sem qualquer correção, isto é, tomando diretamente  $X$  como aproximação de  $y$ . Em seguida, foram ajustados diferentes modelos de regressão supervisionada, incluindo Regressão Linear,  $k$ -Vizinhos Mais Próximos (KNN), *Random Forest*, *Support Vector Regression* (SVR) com *kernel* RBF e um perceptron multicamada (MLP), utilizando a biblioteca *scikit-learn*.

Para evitar viés de ajuste e avaliação sobre o mesmo conjunto, os dados pareados foram divididos aleatoriamente em subconjuntos de treinamento e teste por meio da função `train_test_split`, com 95 % das observações usadas para treinamento e 5 % reservadas para teste (`test_size = 0.05`, `random_state = 150`). Todas as métricas utilizadas na comparação entre modelos são calculadas sobre o subconjunto de teste.

As métricas analisadas incluem:

- coeficiente de determinação  $R^2$  entre os valores de referência (Temtop) e as predições;
- inclinação e intercepto da reta de regressão entre valores de referência e valores medidos/calibrados;
- erro quadrático médio (RMSE) entre as predições e os valores do Temtop;
- erro quadrático médio normalizado (NRMSE), calculado em relação à média das leituras de referência.

Como referência conceitual, adotaram-se os intervalos alvo propostos em documentos da U.S. EPA para avaliação de sensores de baixo custo de PM<sub>2.5</sub> em aplicações suplementares, que tipicamente recomendam  $R^2 \geq 0,70$ , inclinação entre 0,65 e 1,35, intercepto entre  $-5$  e  $+5 \mu\text{g}/\text{m}^3$  e  $\text{RMSE} \leq 7 \mu\text{g}/\text{m}^3$  como metas desejáveis de desempenho (U.S. Environmental Protection Agency, 2021; Simcox; Alison, 2021). Esses limites são usados apenas como guia qualitativo, e não para certificar formalmente o *SenseAir*. Entre os modelos testados, o melhor foi selecionado como função de calibração para uso nas campanhas de campo, por apresentar o

melhor compromisso global em termos das métricas avaliadas e por atender ao maior número de critérios de desempenho quando comparado aos demais modelos. Os valores numéricos das métricas antes e depois da calibração são apresentados e discutidos no Capítulo 4.

### 3.7 Protocolo experimental em campo

Após a etapa de calibração exploratória em laboratório, o nó *SenseAir* foi implantado em um túnel urbano, em três condições de medição associadas a diferentes intensidades de tráfego: (i) na entrada do túnel, com fluxo intenso de veículos; (ii) no interior do túnel, com baixo movimento; e (iii) no interior do túnel, com fluxo mediano. O equipamento Temtop não foi utilizado nessas campanhas de campo, e a caracterização do tráfego foi realizada por contagem manual.

O protocolo experimental em campo contemplou:

- **Seleção dos pontos:** escolha de locais representativos (entrada e interior do túnel), com posição segura para instalação do nó *SenseAir* e condições adequadas para a medição contínua durante o período de coleta;
- **Períodos de medição:** definição de janelas de coleta que contemplassem diferentes níveis de tráfego, incluindo horários de maior e menor movimento, de modo a permitir comparação exploratória dos padrões de PM<sub>2.5</sub> entre as três condições;
- **Operação e registro:** execução das coletas com o nó em operação contínua durante as janelas definidas, com verificação periódica do funcionamento do sistema por meio de *logs* e do acompanhamento das mensagens no *broker* MQTT.

Ao final de cada campanha, os dados armazenados no Firebase foram exportados para análise em ambiente de ciência de dados, incluindo etapas de tratamento, aplicação da correção linear obtida em laboratório e comparação exploratória entre as condições avaliadas.

### 3.8 Limitações metodológicas

A metodologia adotada apresenta limitações que devem ser consideradas na interpretação dos resultados:

- o número de nós *SenseAir* utilizados em campo é limitado, o que restringe a capacidade de generalização dos resultados para outras regiões, vias ou cidades;
- as campanhas cobrem períodos específicos e de curta duração, podendo não representar

- adequadamente a variabilidade sazonal, meteorológica e de padrões de tráfego ao longo de dias úteis, fins de semana e diferentes horários;
- o procedimento de calibração é exploratório, com poucos pontos de comparação em laboratório e uso de um equipamento Temtop M2000, que não é um monitor regulamentar de referência;
  - as medições em campo foram realizadas sem co-localização com um equipamento de referência, o que limita a quantificação do erro absoluto das concentrações de PM<sub>2.5</sub> após a correção;
  - a contagem de veículos depende da qualidade do sistema de aquisição de imagem: a câmera utilizada possui limitações de resolução, sensibilidade e faixa dinâmica, o que pode degradar o desempenho em condições adversas (baixa iluminação, contraluz, chuva), além de oclusões, vibração e variações no enquadramento;
  - a estimativa de tráfego (manual ou automática) está sujeita a incertezas em situações de alta densidade veicular, quando ocorre sobreposição de veículos, mudanças rápidas de faixa e oclusões, o que pode gerar subcontagem ou supercontagem;
  - diferenças de posicionamento do nó (altura, distância da via e ângulo de instalação) podem alterar a representatividade das medições, especialmente em microambientes confinados como túneis, nos quais gradientes espaciais de concentração podem ser relevantes;
  - fatores não controlados, como condições de ventilação do túnel, eventos pontuais (congestionamentos, acelerações bruscas, presença de veículos pesados) e ressuspensão de poeira, podem introduzir variações nas concentrações medidas e dificultar a comparação direta entre campanhas.

Apesar dessas limitações, a abordagem metodológica é suficiente para demonstrar a viabilidade da arquitetura proposta, fornecer estimativas iniciais de desempenho em condições reais de uso e apoiar a discussão de seu potencial para compor redes densas de monitoramento de qualidade do ar em ambientes urbanos.

## 4 RESULTADOS

Este capítulo apresenta os principais resultados obtidos com o desenvolvimento e a avaliação do sistema *SenseAir*. São descritos o hardware construído e suas características de custo e desempenho, o aplicativo móvel para visualização do IQA em tempo quase real, o modelo YOLO embarcado para detecção de veículos e os resultados da calibração exploratória de PM2.5. Em seguida, são analisados o comportamento temporal do IQA em cenários urbanos, a relação entre tráfego veicular e concentrações de partículas, a comparação entre diferentes pontos de medição e a integração das evidências em termos de fontes de poluição.

### 4.1 Hardware desenvolvido

#### 4.1.1 Caracterização do nó e custo de montagem

A Figura 15 mostra o *SenseAir*, um nó de monitoramento de baixo custo pensado para implantação em larga escala. Em uso *indoor*, o equipamento permanece ligado à tomada, garantindo operação contínua. Em uso *outdoor*, funciona alimentado por bateria.

Figura 15 – Dispositivo embarcado *SenseAir* em operação



Fonte: elaborada pelo autor.

A Tabela 5 apresenta uma estimativa de custo de componentes do *SenseAir*.

Tabela 5 – Estimativa de custo dos componentes do *SenseAir*.

<b>Componente</b>	<b>Qtd.</b>	<b>Preço unit. (R\$)</b>
Raspberry Pi 4 Model B (4 GB)	1	520,00
Sensor PM2.5 (laser scattering)	1	160,00
Módulo GPS (GNSS)	1	75,00
Módulo de câmera (1080p)	1	120,00
Bateria LiPo 3 500 mAh	2	95,00
Carregador 5 V / 3 A	1	60,00
HAT de alimentação/monitoramento	1	140,00
Módulo BME280	1	45,00
<b>Subtotal (por unidade)</b>		<b>R\$ 1.310,00</b>

Fonte: elaborada pelo autor.

#### 4.1.2 Desempenho computacional do nó *SenseAir*

Foram realizados testes de desempenho computacional para avaliar o uso de recursos do Raspberry Pi 4B em diferentes modos de operação. A Tabela 6 resume a utilização média e máxima de CPU e memória em três cenários: modo de sensores apenas (leitura periódica de PM2.5 e variáveis ambientais), modo com sensores e envio de dados, e modo completo com sensores, envio de dados e inferência do modelo YOLO em tempo real. A Figura 16 apresenta a evolução temporal do uso de CPU nos três modos de operação, enquanto a Figura 17 mostra o comportamento correspondente da utilização de memória RAM.

Tabela 6 – Utilização média e máxima de CPU e memória em diferentes modos de operação do nó *SenseAir*.


<b>Modo de operação</b>	<b>CPU média (%)</b>	<b>CPU máxima (%)</b>	<b>Memória média (%)</b>	<b>Memória máxima (%)</b>
Sensores apenas	0,95	29,60	2,58	3,00
Sensores + Envios	1,55	32,10	2,63	3,30
Sensores + Envios + YOLO	72,82	100,00	5,93	6,60

Fonte: elaborada pelo autor a partir de medições no Raspberry Pi 4B.

Observa-se que o acréscimo do modelo YOLO é o principal responsável pelo aumento do uso de CPU, saindo de valores máximos em torno de 32,1% nos modos sem visão computacional para uma situação em que, com YOLO ativado, a utilização da CPU atinge 100% em alguns momentos da operação. A Figura 16 evidencia esse comportamento, com oscilações mais intensas e picos frequentes no modo que inclui visão computacional. O uso de memória também se eleva, mas permanece em patamar relativamente baixo, com menos de 7% da RAM ocupada mesmo no modo completo, como ilustrado na Figura 17. Esses resultados indicam que o Raspberry Pi 4B consegue executar simultaneamente a leitura dos sensores, o envio de

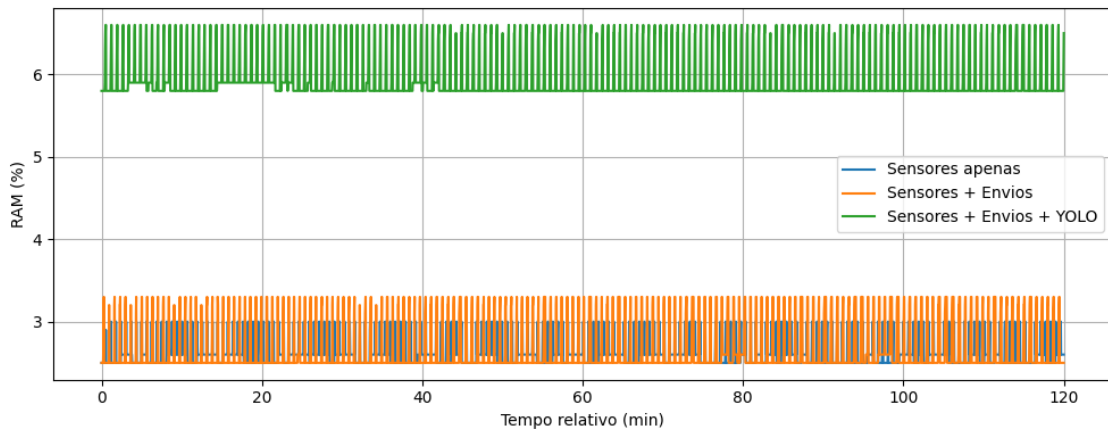
dados e a inferência do YOLO, porém em regime próximo ao limite de processamento. Picos de 100% de uso de CPU podem aumentar o risco de atrasos na inferência, perda de quadros ou resposta mais lenta do sistema, o que sugere a necessidade de ajustes finos, como redução da taxa de processamento de vídeo, simplificação do modelo ou otimizações adicionais, caso se deseje operação contínua em campo com maior margem de segurança.

Figura 16 – Uso de CPU do Raspberry Pi 4B nos três modos de operação do nó *SenseAir*.



Fonte: elaborada pelo autor.

Figura 17 – Uso de memória RAM do Raspberry Pi 4B nos três modos de operação do nó *SenseAir*.



Fonte: elaborada pelo autor.

### 4.1.3 Consumo de energia e autonomia em campo

O consumo de energia do nó *SenseAir* foi avaliado sob alimentação por bateria, com o objetivo de estimar a autonomia em cenários de uso *outdoor*. As leituras de corrente foram obtidas diretamente pelo HAT INA219 instalado no Raspberry Pi 4B, com amostragens

periódicas durante a operação em cada modo de uso. A partir dessas medições de corrente e da capacidade nominal das baterias, foram estimados a potência média consumida e o tempo de operação até o esgotamento da carga. A plataforma utiliza duas células de 3 500 mAh ligadas em série, resultando em uma capacidade equivalente de aproximadamente 3 500 mAh a cerca de 7,4 V (cerca de 26 Wh).

A Tabela 7 apresenta, para cada modo de operação, a corrente média e máxima observadas, bem como a autonomia teórica estimada a partir da capacidade nominal do conjunto de baterias e da corrente média medida. A autonomia teórica foi calculada de forma aproximada por

$$T_{\text{aut}} \approx \frac{C_{\text{bat}}}{I_{\text{média}}}, \quad (4.1)$$

em que  $C_{\text{bat}}$  é a capacidade nominal do banco de baterias, em mAh, e  $I_{\text{média}}$  é a corrente média drenada no modo considerado.

Tabela 7 – Corrente média e máxima e autonomia estimada do *SenseAir* sob alimentação por bateria em diferentes modos de operação.

Modo de operação	Corrente média (mA)	Corrente máxima (mA)	Autonomia teórica (h)
Sensores apenas	400	720	≈ 8,8
Sensores + Envios	440	760	≈ 8,0
Sensores + Envios + YOLO	700	960	≈ 5,0

Fonte: elaborada pelo autor a partir de medições com o módulo INA219.

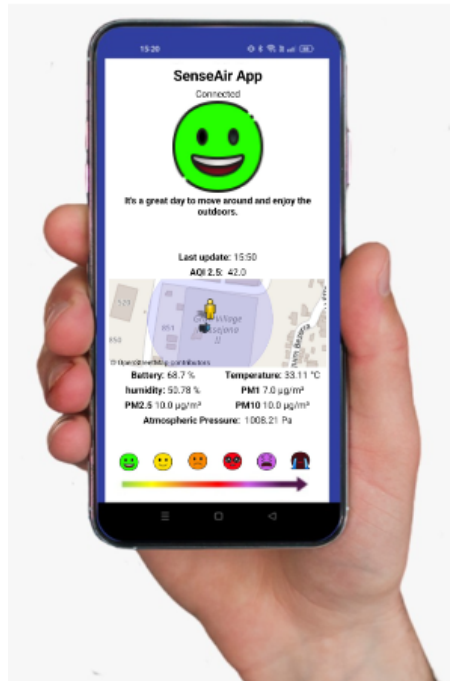
No modo completo, com sensores, envio de dados e YOLO ativado, a corrente média observada foi da ordem de 0,70 A, o que leva a uma autonomia teórica em torno de 5 horas para o conjunto de baterias considerado. Na prática, em um dos ensaios de campo, o sistema iniciou a operação às 11:41 e desligou por esgotamento da bateria às 15:56, indicando uma autonomia real de aproximadamente 4,25 horas. A diferença entre o valor teórico e o observado pode ser atribuída a perdas nos estágios de conversão de energia, à redução da tensão útil ao longo da descarga, a picos transitórios de consumo durante a inferência do modelo e à diferença entre a capacidade nominal e a capacidade efetiva das células em condições reais de uso.

## 4.2 Aplicativo móvel desenvolvido

A Figura 18 apresenta o aplicativo móvel em funcionamento, exibindo em tempo quase real as métricas ambientais, incluindo o IQA para PM2.5, com paleta de cores alinhada às diretrizes de órgãos ambientais. Usando a geolocalização do usuário, o aplicativo identifica

automaticamente o *SenseAir* mais próximo para mostrar leituras representativas do local de interesse. Quando disponível, a posição do dispositivo é exibida no mapa junto às últimas amostras, o que oferece uma visualização clara e intuitiva da qualidade do ar ao redor do usuário.

Figura 18 – Interface do aplicativo móvel mostrando o Índice de Qualidade do Ar para PM2.5



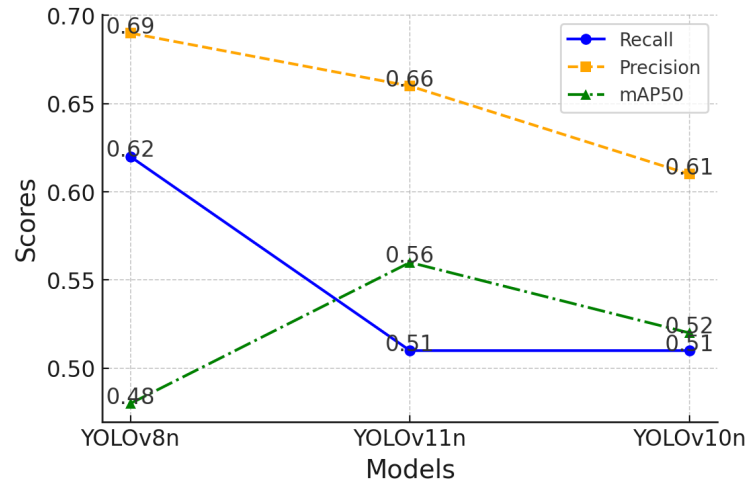
Fonte: elaborada pelo autor.

Os resultados demonstram que o sistema atende ao objetivo de prover ao usuário uma visão em tempo quase real da qualidade do ar, com responsividade adequada para aplicações de monitoramento ambiental urbano.

#### 4.2.1 Comparação entre versões do YOLO

A Figura 19 apresenta resultados de teste para diferentes variantes compactas do YOLO (YOLOv8n, YOLOv11n e YOLOv10n), avaliadas por *precision*, *recall* e mAP50. Considerando o conjunto de dados utilizado e o compromisso entre desempenho e custo computacional, o YOLOv8n foi selecionado como a alternativa mais adequada para a implementação embarcada. Ainda assim, ressalta-se que, nas condições de maior fluxo, o desempenho de contagem em campo ficou aquém do necessário para uso operacional, sendo a solução mais apropriada para análises exploratórias em situações de tráfego leve a moderado.

Figura 19 – Comparação de desempenho entre diferentes versões do YOLO com base em *recall*, *precision* e *mAP50*



Fonte: elaborada pelo autor.


### 4.3 Modelo YOLO implementado

#### 4.3.1 Detecção de veículos em campo

A Figura 20 apresenta exemplos de detecções geradas pelo modelo de visão computacional embarcado no nó *SenseAir*. O modelo foi configurado para identificar veículos em cinco classes (ambulância, carro, motocicleta, ônibus e caminhão), de modo a produzir um indicador de tráfego local associado às medições de PM<sub>2.5</sub>. A motivação principal dessa funcionalidade é apoiar análises exploratórias de correlação entre variações de tráfego e oscilações na concentração de particulados.

Entretanto, durante os testes em campo observou-se que a contagem automática é fortemente sensível às condições do cenário. Em situações de fluxo veicular elevado e alta densidade de veículos, o modelo apresentou subcontagem significativa, chegando a registrar menos de 10% do total observado manualmente em alguns trechos. Esse comportamento está associado principalmente à oclusão entre veículos, à sobreposição de caixas de detecção e às limitações de resolução/qualidade da câmera e do processamento embarcado. Por outro lado, em condições de fluxo leve a mediano e com iluminação favorável, as detecções mostraram-se mais consistentes, permitindo obter contagens mais próximas das observadas manualmente.

Figura 20 – Detecção de veículos utilizando YOLO em sistema embarcado

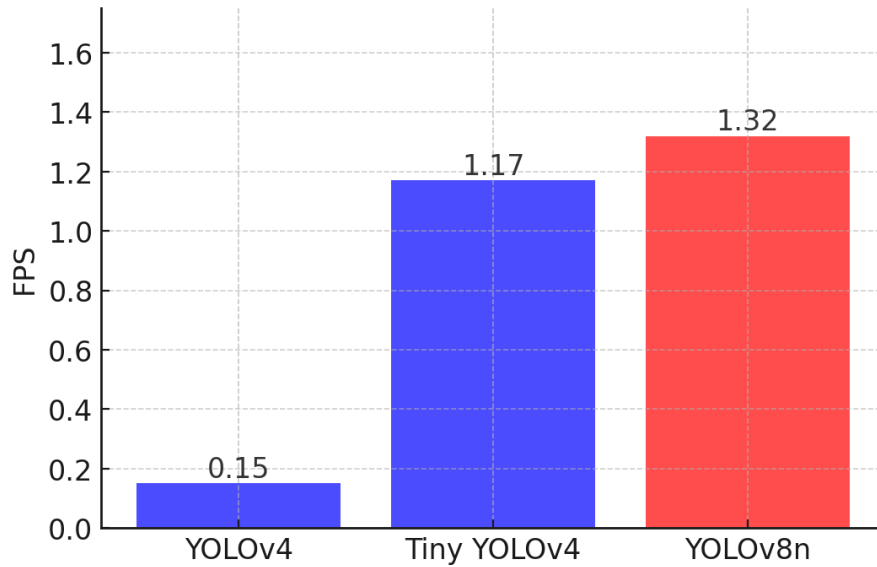


Fonte: elaborada pelo autor.

#### 4.3.2 Desempenho em tempo real no Raspberry Pi

A Figura 21 apresenta a comparação de quadros por segundo (FPS) entre as variantes avaliadas no Raspberry Pi 4 Model B. O YOLOv8n obteve os maiores valores de FPS entre os modelos testados, indicando viabilidade para execução em tempo quase real em cenários de detecção. Contudo, os experimentos em campo mostram que o principal fator limitante, no contexto deste trabalho, não é apenas a taxa de processamento, mas a robustez das detecções em condições adversas, especialmente em situações de tráfego intenso, com alta oclusão entre veículos, e sob iluminação baixa ou heterogênea. Nesses cenários, observou-se subcontagem significativa, o que reduz a utilidade do indicador automático de tráfego.

Figura 21 – Comparação de FPS entre modelos em Raspberry Pi 4B



Fonte: elaborada pelo autor.

#### 4.4 Modelo de calibração implementado

Seguindo o procedimento descrito na Seção 3.6.2, foram calculadas as métricas de desempenho do *SenseAir* bruto em relação ao Temtop M2000 e, em seguida, avaliados diferentes modelos de calibração supervisionada. A Tabela 8 resume os resultados obtidos no conjunto de teste.

Antes da calibração, o *SenseAir* apresentou RMSE de  $18,90 \mu\text{g}/\text{m}^3$ , NRMSE de  $24,20\%$ ,  $R^2$  de  $0,93$ , inclinação de  $0,90$  e intercepto de  $6,52 \mu\text{g}/\text{m}^3$ . Entre os modelos avaliados, o KNN se destacou por combinar o menor RMSE ( $15,66 \mu\text{g}/\text{m}^3$ ), NRMSE em torno de  $20\%$ ,  $R^2$  de  $0,95$  e parâmetros de regressão próximos dos alvos de inclinação e intercepto discutidos na Seção 3.6.2. Por esse motivo, ele foi selecionado como função de calibração adotada nas análises de campo.

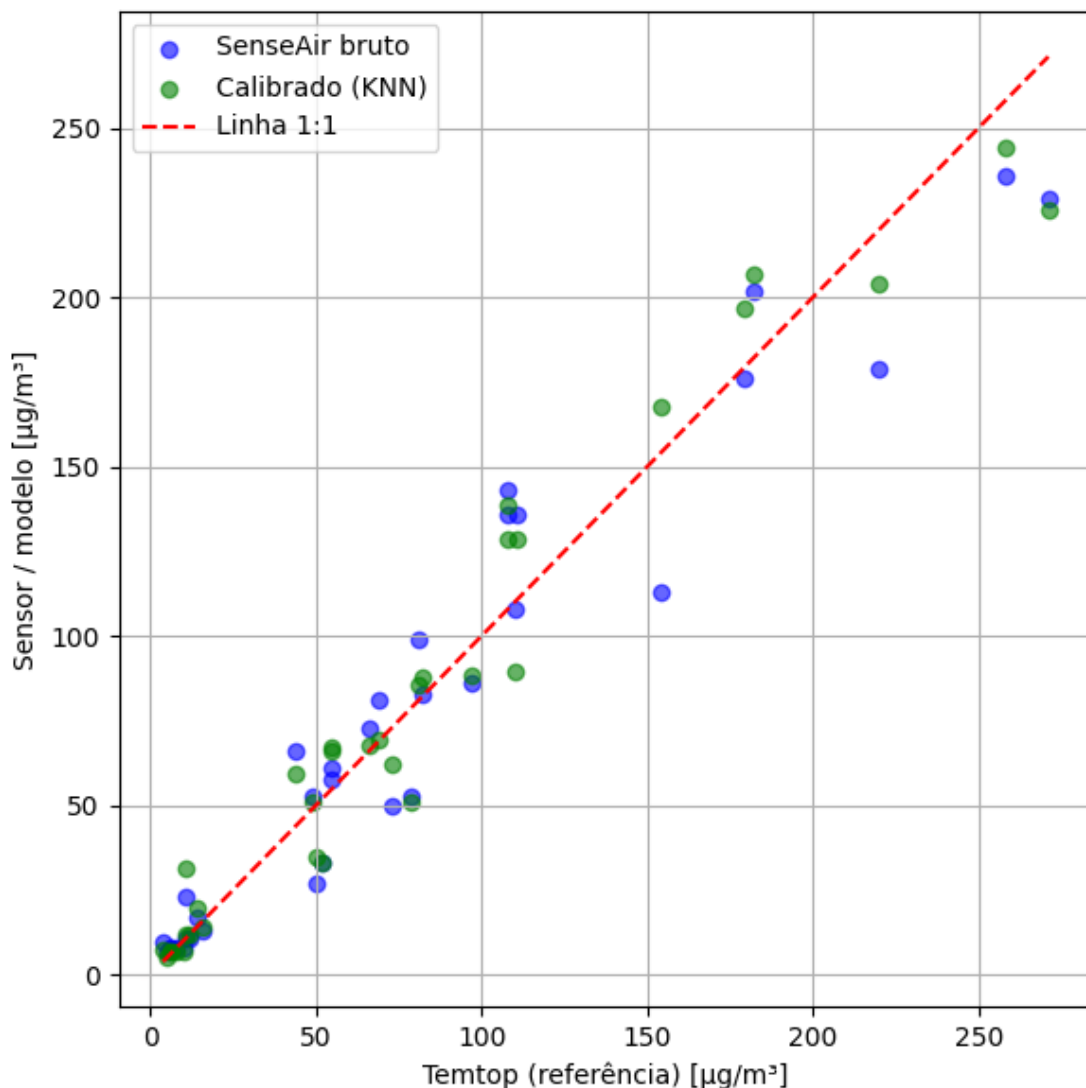
Tabela 8 – Métricas de desempenho no conjunto de teste para o *SenseAir* bruto e modelos de calibração em relação ao Temtop M2000.

Modelo	RMSE ( $\mu\text{g}/\text{m}^3$ )	NRMSE (%)	$R^2$	Inclinação	Intercepto ( $\mu\text{g}/\text{m}^3$ )
<i>Referência (alvos EPA)</i>	$\leq 7,0$	$\leq 30$	$\geq 0,70$	$0,65-1,35$	$[-5, +5]$
SenseAir bruto	18,90	24,20	0,93	0,90	6,52
Regressão linear	20,26	25,93	0,92	1,12	-6,73
Random Forest	20,68	26,48	0,92	0,96	1,94
KNN	<b>15,66</b>	<b>20,04</b>	<b>0,95</b>	<b>1,00</b>	<b>-1,05</b>
SVR_rbf	27,81	35,61	0,85	1,15	-1,37
MLP	20,40	26,12	0,92	1,10	-2,57

Fonte: elaborada pelo autor.

A Figura 22 apresenta o diagrama de dispersão entre as leituras do Temtop (eixo  $x$ ) e do *SenseAir* no conjunto de teste, mostrando simultaneamente os pontos brutos e os valores calibrados pelo modelo KNN, além da linha de identidade 1:1. Observa-se que, após a calibração, os pontos se aproximam mais da linha 1:1 em praticamente toda a faixa de concentrações, indicando redução do viés em relação ao equipamento de referência.

Figura 22 – Dispersão entre PM<sub>2.5</sub> medido pelo Temtop M2000 e pelo *SenseAir*, comparando as leituras brutas e os valores calibrados pelo modelo KNN, com indicação da linha de identidade 1:1.

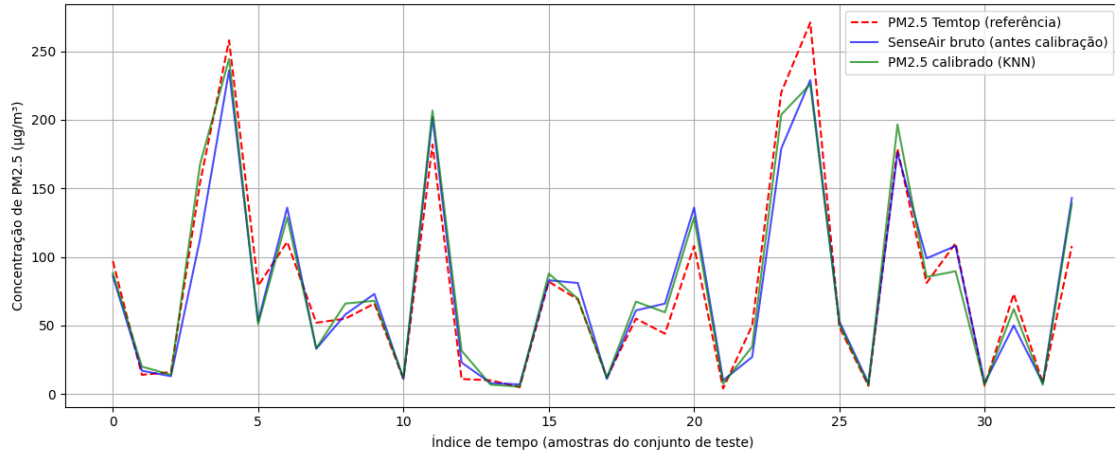


Fonte: elaborada pelo autor.

A Figura 23 complementa a análise ao mostrar, ao longo do índice de tempo do conjunto de teste, as séries de PM<sub>2.5</sub> do Temtop (referência), do *SenseAir* bruto e do *SenseAir* calibrado pelo KNN. Nota-se que a curva calibrada acompanha mais de perto a referência, especialmente nos picos de concentração, reduzindo tanto subestimativas quanto superestimativas

observadas nas leituras brutas.

Figura 23 – Comparação temporal entre as concentrações de PM2.5 do Temtop (referência), do *SenseAir* bruto e do *SenseAir* calibrado pelo modelo KNN no subconjunto de teste.



Fonte: elaborada pelo autor.

Embora nenhum modelo atinja todos os alvos de desempenho discutidos na Seção 3.6.2, a calibração via KNN reduz de forma consistente o erro médio e aproxima a inclinação e o intercepto dos intervalos considerados desejáveis, o que é suficiente para os objetivos exploratórios desta dissertação.

#### 4.5 Relação entre tráfego veicular e PM2.5

Esta seção apresenta uma análise exploratória da relação entre a contagem manual de veículos e as concentrações de PM2.5 medidas pelo *SenseAir*. Para cada janela de coleta, são apresentados: (i) a série temporal da contagem por classe e do total de veículos e (ii) a série temporal de PM2.5 (bruto e calibrado) nos parâmetro EPA e CONAMA. Ressalta-se que o objetivo aqui não é estabelecer causalidade, mas verificar se variações no fluxo veicular se refletem, de forma consistente, nas variações de PM2.5 no microambiente analisado.


As Figuras 24, 25 e 26 mostram a localização dos três túneis em Fortaleza nos quais foram realizadas as coletas, permitindo contextualizar os resultados em termos de entorno urbano.

##### 4.5.1 Túnel Wellington Landim

No Túnel Wellington Landim, foram coletados dados no intervalo de 09:51 a 10:51. Nesse período, observou-se um fluxo veicular elevado, com predominância de carros e presença




Figura 26 – Localização do Túnel Sérgio Nogueira e do ponto de medição utilizado na campanha.



Fonte: elaborada pelo autor.

Figura 27 – Contagem manual de veículos por classe e total na janela 09:51-10:51.




Fonte: elaborada pelo autor.

#### 4.5.2 Túnel Olga Barroso


No Túnel Olga Barroso, a coleta ocorreu no intervalo de 12:51 a 13:51. Em comparação com a janela anterior, a contagem manual indica fluxo significativamente menor (Fig. 30), com predominância de carros e menor participação das demais classes. As concentrações de PM<sub>2.5</sub> permaneceram baixas e com baixa variabilidade, mantendo-se majoritariamente abaixo dos limites de transição para as categorias “Moderate” (EPA) e “Moderada” (CONAMA) (Fig. 31 e Fig. 32). Coerentemente, os índices calculados pela média móvel de 1h permaneceram nas categorias *Good* (EPA) e *Boa* (CONAMA), compatíveis com o cenário de menor fluxo observado no período.

Figura 28 – Concentração de PM2.5 (bruto e calibrado) na janela 09:51-10:51 com limites até “Moderate” (EPA). A caixa informa o AQI (EPA) calculado pela média móvel de 1h ao final da janela.



Fonte: elaborada pelo autor.

Figura 29 – Concentração de PM2.5 (bruto e calibrado) na janela 09:51-10:51 com limites até “Moderada” (CONAMA). A caixa informa o IQAr (CONAMA) calculado pela média móvel de 1h ao final da janela.




Fonte: elaborada pelo autor.

### 4.5.3 Túnel Sérgio Nogueira


No Túnel Sérgio Nogueira, os dados foram coletados no intervalo de 15:33 a 16:33. Nessa janela, a contagem manual sugere um fluxo mediano (Fig. 33). Diferentemente das janelas anteriores, as concentrações de PM2.5 apresentaram um patamar mais elevado e mais persistente ao longo do período (Fig. 34 e Fig. 35). Como resultado, o AQI (EPA) calculado pela média móvel de 1h atingiu a categoria *Moderate*, enquanto o IQAr (CONAMA) permaneceu classificado como *Boa*. Esse contraste é coerente com os limiares distintos entre os referenciais e reforça que, além do volume de tráfego, características do microambiente (como confinamento e ventilação) podem favorecer a acumulação de PM2.5.

Figura 30 – Contagem manual de veículos por classe e total na janela 12:51-13:51.



Fonte: elaborada pelo autor.

Figura 31 – Concentração de PM2.5 (bruto e calibrado) na janela 12:51-13:51 com limites até “Moderate” (EPA). A caixa informa o AQI (EPA) calculado pela média móvel de 1h ao final da janela.




Fonte: elaborada pelo autor.

#### 4.5.4 Síntese dos resultados

Em conjunto, as três janelas reforçam que a relação entre tráfego veicular e PM2.5 é influenciada não apenas pela intensidade do fluxo, mas também pelas condições de ventilação e confinamento do microambiente. No Túnel Wellington Landim, mesmo com maior presença de circulação de ar (maior ação do vento) e com o maior fluxo veicular entre as campanhas, as concentrações de PM2.5 mantiveram-se baixas na maior parte do tempo, mas apresentaram picos pontuais que atingiram a faixa *Moderate* na escala da EPA. Ainda assim, o valor consolidado pela média móvel de 1h ao final da janela permaneceu na categoria *Good*, sugerindo que os aumentos observados foram episódicos e não sustentados.


No Túnel Olga Barroso, caracterizado por maior confinamento e menor circulação

Figura 32 – Concentração de PM2.5 (bruto e calibrado) na janela 12:51-13:51 com limites até “Moderada” (CONAMA). A caixa informa o IQAr (CONAMA) calculado pela média móvel de 1h ao final da janela.



Fonte: elaborada pelo autor.

Figura 33 – Contagem manual de veículos por classe e total na janela 15:33-16:33.




Fonte: elaborada pelo autor.

de ar, os resultados permaneceram favoráveis ao longo da janela analisada. Esse comportamento é coerente com o menor fluxo veicular registrado no período, indicando que, mesmo em um ambiente mais fechado, a ausência de tráfego intenso tende a reduzir a probabilidade de acúmulo de PM2.5.


Por fim, no Túnel Sérgio Nogueira, também com características de maior confinamento, observou-se o cenário mais crítico do ponto de vista dos indicadores de qualidade do ar. Apesar da existência de ventiladores no interior do túnel (Figura 36), as concentrações apresentaram um patamar mais elevado e persistente, e o AQI (EPA) pela média móvel de 1h atingiu a categoria *Moderate*. Esse resultado sugere que, para a condição observada, a ventilação mecânica disponível não foi suficiente para compensar o efeito combinado do confinamento com um fluxo veicular mediano, favorecendo a manutenção de níveis mais altos de PM2.5.

Figura 34 – Concentração de PM2.5 (bruto e calibrado) na janela 15:33-16:33 com limites até “Moderate” (EPA). A caixa informa o AQI (EPA) calculado pela média móvel de 1h ao final da janela.



Fonte: elaborada pelo autor.

Figura 35 – Concentração de PM2.5 (bruto e calibrado) na janela 15:33-16:33 com limites até “Moderada” (CONAMA). A caixa informa o IQAr (CONAMA) calculado pela média móvel de 1h ao final da janela.



Fonte: elaborada pelo autor.

Figura 36 – Exemplo de ventilação mecânica no interior do Túnel Sérgio Nogueira.



Fonte: elaborado pelo autor.

## 5 CONCLUSÕES E TRABALHOS FUTUROS

A presente dissertação apresentou o desenvolvimento e a avaliação de uma solução integrada para monitoramento indicativo da qualidade do ar em contexto urbano, combinando um nó embarcado de baixo custo (*SenseAir*), serviços em nuvem e um aplicativo móvel para usuários finais, além de módulos complementares para calibração exploratória de PM<sub>2.5</sub> e estimativa de tráfego veicular. A proposta buscou demonstrar a viabilidade técnica de uma cadeia completa, desde a coleta em campo até a disponibilização de indicadores simplificados de qualidade do ar, com custo por ponto significativamente inferior ao de estações regulamentares. Nesse sentido, o principal foco de integração do trabalho foi a implementação e validação de um fluxo ponta a ponta, contemplando a aquisição do dado no dispositivo embarcado, sua transmissão e armazenamento na nuvem, o tratamento e a consolidação das medições, e a entrega dos indicadores ao usuário final por meio do aplicativo móvel, de forma a fechar o ciclo entre coleta em campo e uso prático da informação. Como forma de garantir transparência e reprodutibilidade, a implementação da solução foi disponibilizada em repositório público (GitHub: <https://github.com/nicolas3010/SenseAir>), reforçando o caráter aberto e a possibilidade de replicação e extensão por terceiros.

No eixo de calibração, os resultados mostraram que é possível aplicar uma correção exploratória às leituras de PM<sub>2.5</sub> do *SenseAir* a partir de um experimento controlado, com melhoria da consistência das séries temporais quando comparadas ao comportamento esperado no cenário de testes. Embora a calibração não tenha sido realizada com monitor de referência regulamentar e o conjunto de dados disponível seja reduzido, o procedimento demonstrou o potencial de incorporar correções simples no pós-processamento para reduzir vieses sistemáticos e tornar o uso do sensor mais útil para fins indicativos e comparativos.

No eixo de visão computacional, o uso do YOLO permitiu avaliar a viabilidade de quantificação automática de tráfego em um sistema embarcado. Entretanto, os testes em campo evidenciaram que, no estado atual, a principal limitação não é apenas o desempenho computacional (FPS), mas a robustez das detecções em condições adversas, especialmente em tráfego intenso, com oclusões frequentes e baixa ou heterogênea iluminação. Nessas situações, observou-se subcontagem significativa em relação ao cenário real, indicando que a contagem automática ainda não é confiável para uso operacional. Para tornar esse módulo efetivamente aplicável, são necessários avanços como: (i) refinamento do treinamento com dados mais representativos do contexto local, (ii) uso de estratégias de rastreamento e pós-processamento

para reduzir perdas por oclusão, e (iii) melhorias de hardware, incluindo a substituição da câmera por um sensor de melhor qualidade.

A análise exploratória entre tráfego e PM<sub>2.5</sub> nas três janelas de coleta reforçou que a variação observada nas concentrações não depende apenas do volume de veículos, mas também das condições do microambiente (confinamento e ventilação). Mesmo no ponto com maior fluxo e maior ação do vento, ocorreram picos na faixa moderada na escala EPA, ainda que o indicador final por média móvel de 1h tenha permanecido em *Bom/Good*. Em contraste, em um túnel mais fechado, mas com baixo movimento, as concentrações permaneceram baixas; já em um túnel fechado com fluxo mediano, observou-se patamar mais elevado e classificação *Moderado/Moderate* na EPA, mesmo com presença de ventilação mecânica, sugerindo que a ventilação disponível não foi suficiente para neutralizar o efeito do confinamento associado ao tráfego no período analisado. Esses resultados, embora limitados em duração e repetição, indicam a relevância de considerar o microambiente e reforçam o valor de campanhas futuras mais longas e replicadas.

Do ponto de vista de impacto e aplicação, o aplicativo móvel mostrou-se um componente importante para traduzir medições técnicas em informação acessível à população, permitindo acompanhar, em tempo quase real, indicadores de qualidade do ar e facilitar a compreensão do risco associado à exposição. Além disso, a arquitetura proposta é compatível com a implantação em redes densas de sensoriamento, em que múltiplos nós de baixo custo distribuídos espacialmente podem capturar gradientes intraurbanos e apoiar diagnósticos exploratórios em escala local, algo que é inviável economicamente utilizando apenas estações de referência.

## 5.1 Trabalhos Futuros

A partir das experiências relatadas e das limitações identificadas, diversas linhas de continuidade e aprofundamento podem ser propostas:

- **Calibração com estação de referência e maior base de dados:** realizar novas campanhas de co-localização com uma estação de referência regulamentar para PM<sub>2.5</sub>, com duração de semanas a meses, permitindo avaliar diferentes faixas de concentração e condições meteorológicas. Isso possibilitaria testar modelos de calibração mais sofisticados e comparar diretamente o desempenho do *SenseAir* com critérios de documentos regulatórios.
- **Ampliação da rede e cobertura espacial:** construir e implantar múltiplos nós *SenseAir* em diferentes pontos de uma mesma cidade, incluindo vias arteriais, túneis, viadutos e

áreas residenciais, de modo a explorar gradientes intraurbanos de qualidade do ar. Uma rede mais densa permitiria aplicar técnicas de interpolação espaço-temporal e métodos de calibração colaborativa e cega em arranjos de sensores.

- **Evolução do hardware e da alimentação:** desenvolver uma versão do *SenseAir* com gabinete dedicado e maior grau de proteção ambiental, bem como integrar alimentação solar com gerenciamento de energia, visando campanhas de longa duração em ambiente externo.
- **Aprimoramento do modelo de visão computacional:** investigar variantes mais leves e otimizadas para execução em borda, ampliar e diversificar a base de treinamento com imagens mais representativas do contexto local e melhorar as técnicas de rastreamento (*tracking*) e pós-processamento para reduzir subcontagens, especialmente em cenários de tráfego intenso.
- **Integração de variáveis meteorológicas:** explorar, de forma sistemática, as variáveis meteorológicas registradas pelo próprio *SenseAir* como covariáveis nas análises, permitindo investigar com mais detalhe a influência das condições ambientais sobre as concentrações observadas de PM<sub>2.5</sub> e sobre a relação exploratória com o tráfego ao longo das janelas de coleta.
- **Expansão da aplicação móvel e avaliação de usabilidade:** ampliar as funcionalidades do aplicativo, incluindo histórico de séries temporais, alertas personalizados para grupos sensíveis, integração com mapas interativos e compartilhamento de informações com redes sociais. Estudos de usabilidade com diferentes perfis de usuários (moradores, estudantes, gestores públicos) poderiam avaliar o potencial da ferramenta para apoiar ações de educação ambiental e tomada de decisão.
- **Integração com órgãos ambientais e plataformas abertas:** disponibilizar os dados do *SenseAir* em formato aberto, com API pública e documentação, facilitando o uso por pesquisadores, gestores e desenvolvedores. A integração com portais governamentais ou iniciativas de ciência cidadã poderia aumentar o alcance da solução e favorecer a comparação com redes oficiais de monitoramento.
- **Extensão para outros poluentes:** avaliar a inclusão de sensores adicionais (por exemplo, NO<sub>2</sub>, O<sub>3</sub> ou compostos orgânicos voláteis) em versões futuras do nó, de modo a aproximar o escopo de medição dos conjuntos de poluentes critérios utilizados em índices oficiais de qualidade do ar.

Em conjunto, essas direções apontam para a possibilidade de evoluir o *SenseAir* de um protótipo de pesquisa para um componente de redes densas de monitoramento indicativo, com potencial de apoiar políticas públicas, estudos acadêmicos e iniciativas de ciência cidadã voltadas à melhoria da qualidade do ar em centros urbanos.

## REFERÊNCIAS

- ALI, S. *et al.* Low cost sensor with iot lorawan connectivity and machine learning-based calibration for air pollution monitoring. **IEEE Transactions on Instrumentation and Measurement**, New York, v. 70, p. 1–11, 2021.
- ARBOLEDA, M. M. B.; SHAMIM, A. Self-powered and cost-effective wireless sensor node for air quality monitoring with an optically transparent smart antenna system. **IEEE Sensors Journal**, New York, v. 24, n. 18, 2024.
- AULA, L. *et al.* Evaluation of low-cost air quality sensor calibration models. **ACM Transactions on Sensor Networks**, New York, v. 18, n. 2, p. 1–27, 2022.
- BAGKIS, E. *et al.* Evolving trends in application of low-cost air quality sensor networks: challenges and future directions. **npj Climate and Atmospheric Science**, London, v. 8, p. 335, 2025.
- BARROS, N. *et al.* Schoolair: A citizen science iot framework using low-cost sensing for indoor air quality management. **Sensors**, Basel, v. 24, n. 1, p. 148, 2024.
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006.
- BRASIL. Lei nº 14.850, de 2 de maio de 2024. Institui o Código Civil. **Diário Oficial da União**: seção 1, Brasília, DF, ano 161, n. 84, p. 1, 3 maio 2024. Disponível em: <https://www2.camara.leg.br/legin/fed/lei/2024/lei-14850-2-maio-2024-795555-publicacaooriginal-171660-pl.html>. Acesso em: 19 out. 2025.
- BRASIL. Ministério do Meio Ambiente e Mudança do Clima. **Orientação técnica: Índice de Qualidade do Ar (IQAr)**. Brasília, DF, 2025. 9 p. Documento orientador oficial para aplicação do IQAr no âmbito da PNQA. Disponível em: <https://www.gov.br/mma/pt-br/assuntos/meio-ambiente-urbano-recursos-hidricos-qualidade-ambiental/qualidade-do-ar/indice-de-qualidade-do-ar-iqar/orientacao-tecnica-indice-de-qualidade-do-ar-jan-25.pdf>. Acesso em: 02 fev. 2025.
- BRASIL. Ministério do Meio Ambiente e Mudança do Clima. **Relatório anual de acompanhamento da qualidade do ar: 2024**. Brasília, DF, 2025. 63 p. Síntese nacional publicada em 2025 sobre o ano-base 2024. Disponível em: <https://www.gov.br/mma/pt-br/centrais-de-conteudo/publicacoes/qualidade-ambiental-e-meio-ambiente-urbano/relatorio-anual-de-acompanhamento-da-qualidade-do-ar-2024.pdf>. Acesso em: 19 out. 2025.
- BREIMAN, L. Random forests. **Machine Learning**, Dordrecht, v. 45, n. 1, p. 5–32, 2001.
- CENTERS FOR DISEASE CONTROL AND PREVENTION. **Air pollutants: air quality**. 2024. Página institucional sobre os seis principais poluentes críticos. Disponível em: <https://www.cdc.gov/air-quality/pollutants/index.html>. Acesso em: 19 out. 2025.
- CETESB. **Poluentes: qualidade do ar**. 2023. Disponível em: <https://cetesb.sp.gov.br/ar/poluentes/>. Acesso em: 19 out. 2025.
- CONCAS, F. *et al.* Low-cost outdoor air quality monitoring and sensor calibration: a survey and critical analysis. **ACM Transactions on Sensor Networks**, New York, v. 17, n. 2, p. 1–44, 2021.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, Dordrecht, v. 20, n. 3, p. 273–297, 1995.

COVER, T. M.; HART, P. E. Nearest neighbor pattern classification. **IEEE Transactions on Information Theory**, New York, v. 13, n. 1, p. 21–27, 1967.

DAS, P. *et al.* A low cost outdoor air pollution monitoring device with power controlled built-in pm sensor. **IEEE Sensors Journal**, New York, v. 22, n. 13, p. 13682–13695, 2022.

ERTURAN, A. **Vehicle detection dataset**. 2023. Disponível em: <https://www.kaggle.com/datasets/alkanerturan/vehicledetection>. Acesso em: 19 nov. 2025.

FADEL, M. *et al.* A comprehensive review of pm-related studies in industrial proximity. **Sustainability**, Basel, v. 16, n. 20, p. 8739, 2024.

FORTALEZA (Estado). **Prefeitura lança política e rede de monitoramento da qualidade do ar de Fortaleza**. 2023. Disponível em: <https://www.fortaleza.ce.gov.br/noticias/prefeitura-lanca-politica-e-rede-de-monitoramento-da-qualidade-do-ar-de-fortaleza>. Acesso em: 27 jan. 2026.

FUSSELL, J. C. *et al.* A review of road traffic-derived non-exhaust particles: Emissions, physicochemical characteristics, health risks, and mitigation measures. **Environmental Science & Technology**, Washington, v. 56, n. 11, p. 6813–6835, 2022.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning**. 2. ed. New York: Springer, 2009. Data mining, inference, and prediction.

HAYWARD, I. *et al.* Low-cost air quality sensors: Biases, corrections and challenges in their comparability. **Atmosphere**, Basel, v. 15, n. 12, p. 1523, 2024.

HUDA, R. K. *et al.* Air quality monitoring using low-cost sensors in urban areas of jodhpur, rajasthan. **Atmosphere**, Basel, v. 15, n. 8, p. 651, 2024.

HWANG, K.; PARK, S. Understanding the physicochemical characteristics of pm2.5 under meteorological influence. **Atmospheric Pollution Research**, Amsterdam, v. 16, n. 6, p. 102497, 2025.

Instituto Ar. **Qual é a qualidade do ar que respiramos?** 2024. Disponível em: <https://institutoar.org.br/tpost/i0djak18c1-qual-a-qualidade-do-ar-que-respiramos>. Acesso em: 19 out. 2025.

INSTITUTO ESTADUAL DO MEIO AMBIENTE E RECURSOS HÍDRICOS DO ESPÍRITO SANTO. **Relatório 2024: qualidade do ar**. 2025. Disponível em: [https://iema.es.gov.br/Media/iema/CQAI/Relatorios\\_anuais/Relat%C3%B3rio%202024%20-%20Qualidade%20do%20Ar.pdf](https://iema.es.gov.br/Media/iema/CQAI/Relatorios_anuais/Relat%C3%B3rio%202024%20-%20Qualidade%20do%20Ar.pdf). Acesso em: 19 out. 2025.

JAAFAR, W. *et al.* Challenges and opportunities of low-cost sensors in capturing the impacts of construction activities on neighborhood air quality. **Building and Environment**, Amsterdam, v. 254, p. 111363, 2024.

KARAGULIAN, F.; BELIS, C. A.; DORA, C. F. C.; PRÜSS-USTÜN, A. M.; BONJOUR, S.; ADAIR-ROHANI, H.; AMANN, M. Contributions to cities' ambient particulate matter (pm): A systematic review of local source contributions at global level. **Atmospheric Environment**, Elsevier, Amsterdam, v. 120, p. 475–483, 2015.

LI, G. *et al.* A variational bayesian blind calibration approach for air quality sensor deployments. **IEEE Sensors Journal**, New York, v. 23, n. 7, p. 7129–7141, 2023.

MAAG, B. *et al.* A survey on sensor calibration in air pollution monitoring deployments. **IEEE Internet of Things Journal**, New York, v. 5, n. 6, p. 4857–4870, 2018.

MEO, S. A.; SALIH, M. A.; AL-HUSSAIN, F.; ALKHALIFAH, J. M.; MEO, A. S.; AKRAM, A. Environmental pollutants pm2.5, pm10, carbon monoxide (co), nitrogen dioxide (no2), sulfur dioxide (so2), and ozone (o3) impair human cognitive functions. **European Review for Medical and Pharmacological Sciences**, Rome, v. 28, n. 2, p. 789–796, 2024.

MET ONE INSTRUMENTS POWERED BY ACOEM. **BAM 1020 beta attenuation mass monitor**. 2025. Disponível em: <https://metone.com/products/bam-1020/>. Acesso em: 27 jan. 2026.

MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. **Introduction to Linear Regression Analysis**. 5. ed. Hoboken: Wiley, 2012.

NALAKURTHI, N. V. S. R. *et al.* Challenges and opportunities in calibrating low-cost environmental sensors. **Sensors**, Basel, v. 24, n. 11, p. 3650, 2024.

OKORN, K.; IRACI, L. T. An overview of outdoor low-cost gas-phase air quality sensor deployments: Current efforts, trends, and limitations. **Atmospheric Measurement Techniques**, Göttingen, v. 17, n. 21, p. 6425–6457, 2024.

OMS. **WHO global air quality guidelines: particulate matter (PM2.5 and PM10), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide**. Geneva: World Health Organization, 2021a. Diretrizes globais de qualidade do ar para PM2.5, PM10, O3, NO2, SO2 e CO. Disponível em: <https://www.who.int/publications/i/item/9789240034228>. Acesso em: 19 out. 2025.

PAI, S. J. *et al.* Updated world health organization air quality guidelines highlight the importance of non-anthropogenic pm2.5. **Environmental Science & Technology Letters**, Washington, v. 9, n. 6, p. 501–506, 2022.

PHALA, K. S. *et al.* Air quality monitoring system based on iso/iec/ieee 21451 standards. **IEEE Sensors Journal**, New York, v. 16, n. 12, p. 5037–5045, 2016.

PURBAKAWACA, R. *et al.* Ambient air monitoring system with adaptive performance stability. **IEEE Access**, New York, v. 10, p. 120086–120105, 2022.

SI, Y. *et al.* Evaluation and calibration of a low-cost particle sensor in ambient conditions using machine-learning methods. **Atmospheric Measurement Techniques**, Göttingen, v. 13, n. 3, p. 1693–1707, 2020.

SIMCOX; ALISON. **Low-cost sensors (LCS) for monitoring air quality**. 2021. Disponível em: <https://www.eanet.asia/wp-content/uploads/2022/08/Dr.-Alison-Simcox-Low-cost-sensors-LCS-for-monitoring-air-quality.pdf>. Acesso em: 19 out. 2025.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing**, London, v. 14, n. 3, p. 199–222, 2004.

SOPČIĆ, S. *et al.* The influence of biomass burning on the organic content of urban aerosols. **Biomass**, Basel, v. 5, n. 1, p. 1, 2025.

SOUZA, A. d. *et al.* The impact of meteorological variables on particulate matter concentrations. **Atmosphere**, Basel, v. 16, n. 7, p. 875, 2025.

TAHA, S. S.; IDOUDI, S.; ALHAMDAN, N.; IBRAHIM, R. H.; SURKATTI, R.; AMHAMED, A.; ALREBEI, O. F. Comprehensive review of health impacts of the exposure to nitrogen oxides (nox), carbon dioxide (co2), and particulate matter (pm). **Journal of Hazardous Materials Advances**, Amsterdam, v. 19, p. 100771, 2025.

THERMO FISHER SCIENTIFIC. **5014i Beta Continuous Ambient Particulate Monitor**. 2025. Disponível em: <https://www.thermofisher.com/order/catalog/product/5014I>. Acesso em: 19 out. 2025.

TRAMA – Transportes e Meio Ambiente. **Recursos**. 2026. Disponível em: <https://www.tramaufc.com.br/blank-1>. Acesso em: 27 jan. 2026.

UNIVERSIDADE FEDERAL DO CEARÁ. **Equipamento desenvolvido pela UFC monitora qualidade do ar em Fortaleza**. 2024. Disponível em: <https://www.ufc.br/noticias/noticias-ufctv/18886-equipamento-desenvolvido-pela-ufc-monitora-qualidade-do-ar-em-fortaleza>. Acesso em: 27 jan. 2026.

URRUTIA-PEREIRA, M. *et al.* Impact of exposure to smoke from biomass burning in the amazon rain forest on human health. **Jornal Brasileiro de Pneumologia**, Brasília, v. 47, n. 5, p. e20210219, 2021.

U.S. Environmental Protection Agency. **Performance Testing Protocols, Metrics, and Target Values for Fine Particulate Matter Air Sensors**: Use in ambient, outdoor, fixed site, non-regulatory supplemental and informational monitoring applications. Research Triangle Park, NC, 2021. Disponível em: <https://click.clarity.io/hubfs/Marketing%20Assets%20-%20PDFs/USEPA%20Performance%20Testing%20Protocols%20Metrics%20and%20Target%20Values%20for%20Fine%20Particulate%20Matter%20Air%20Sensors.pdf>. Acesso em: 19 out. 2025.

U.S. ENVIRONMENTAL PROTECTION AGENCY. **Final updates to the air quality index (AQI) for particulate matter**. 2024. Disponível em: <https://www.epa.gov/system/files/documents/2024-02/pm-naaqs-air-quality-index-fact-sheet.pdf>. Acesso em: 30 nov. 2025.

WORLD HEALTH ORGANIZATION. **WHO Global Air Quality Guidelines: Particulate Matter (PM<sub>2.5</sub> and PM<sub>10</sub>), Ozone, Nitrogen Dioxide, Sulfur Dioxide and Carbon Monoxide**. Geneva: World Health Organization, 2021. ISBN 978-92-4-003422-8. Disponível em: <https://iris.who.int/handle/10665/345334>. Acesso em: 19 out. 2025.

WORLD HEALTH ORGANIZATION. **Ambient (outdoor) air quality and health**. 2024. Disponível em: [https://www.who.int/news-room/fact-sheets/detail/ambient-\(outdoor\)-air-quality-and-health](https://www.who.int/news-room/fact-sheets/detail/ambient-(outdoor)-air-quality-and-health). Acesso em: 19 out. 2025.

WORLD METEOROLOGICAL ORGANIZATION. **Integrating Low-Cost Sensor Systems and Networks to Improve Air Quality Monitoring**. Geneva, 2023. Relatório sobre sensores de baixo custo e sua integração com o monitoramento oficial.