

Sistema de Monitoramento Ambiental de Baixo Custo com Sensores IoT, Coleta Móvel e Análise Espacial de Ilhas Urbanas

Low-Cost Environmental Monitoring System with IoT Sensors, Mobile Data Collection and Spatial Analysis of Urban Islands

Lucas Freitag¹

¹ Universidade Federal do Rio Grande do Norte, Rio Grande do Norte, Natal, Brasil

Data de recebimento do manuscrito: 05/07/2026

Data de aceitação do manuscrito: 20/08/2026

Data de publicação: 28/08/2026

Resumo—Este artigo apresenta um sistema de monitoramento ambiental de baixo custo voltado ao mapeamento urbano colaborativo por meio de sensores comerciais, microcontrolador embarcado e coleta móvel de dados. O sistema integra sensores de material particulado, temperatura, umidade, pressão e gases com transmissão sem fio para um aplicativo Android, que registra localização, armazena medições em buffer e envia os dados para a nuvem. A principal contribuição é uma arquitetura aberta e reproduzível que combina sensoriamento móvel com algoritmos de agregação espacial em múltiplas escalas e detecção qualitativa de ilhas urbanas de calor, poluição, umidade, conforto, circulação de ar e albedo. Testes de campo foram realizados em rotas de ônibus em Natal, Brasil, com o dispositivo transportado em mochila próximo à janela do veículo. Os valores observados de material particulado variaram entre 4 e 15 microgramas por metro cúbico, majoritariamente entre 4 e 8, enquanto a umidade relativa permaneceu entre 68 e 75 por cento, com estabilidade em torno de 70 a 73 por cento durante o percurso. Os resultados indicam que a plataforma pode apoiar a validação conceitual da metodologia, estudos de microclima urbano e futuras implantações em frotas de transporte público.

Palavras-chave—Sensores de baixo custo, Monitoramento móvel, Microclima urbano, Agregação espacial, Sensoriamento ambiental, Sistemas embarcados

Abstract—This paper presents a low-cost environmental monitoring system designed for collaborative urban mapping using commercial sensors, an embedded microcontroller and mobile data collection. The system integrates particulate matter, temperature, humidity, pressure and gas sensors with wireless transmission to an Android application that records location, buffers measurements and sends data to a cloud service. The main contribution is an open and reproducible architecture that combines mobile sensing with spatial aggregation algorithms at multiple scales and qualitative detection of urban heat, pollution, humidity, comfort, air circulation and albedo-related islands. Field tests were conducted on bus routes in Natal, Brazil, with the device carried in a backpack near the vehicle window. The observed particulate matter values ranged from 4 to 15 micrograms per cubic meter, mostly between 4 and 8, while relative humidity remained between 68 and 75 percent and was stable around 70 to 73 percent during the route. The results indicate that the platform can support the conceptual validation of the methodology, urban microclimate studies and future deployments in public transport fleets.

Keywords—Low-cost sensors, Mobile monitoring, Urban microclimate, Spatial aggregation, Environmental sensing, Embedded systems

I. INTRODUÇÃO

A poluição do ar e o fenômeno das ilhas de calor urbanas (UHI) representam desafios críticos para a sustentabilidade e saúde pública em cidades de médio e grande porte. De acordo com a Organização Mundial da Saúde (OMS), a exposição crônica a material particulado fino (PM_{2.5}) está

associada a doenças cardiovasculares, respiratórias e câncer de pulmão, resultando em milhões de mortes prematuras anualmente [1]. No Brasil, cidades como Natal enfrentam desafios específicos devido ao clima tropical costeiro, alta densidade populacional e expansão urbana desordenada [2]. Além disso, o monitoramento ambiental tradicional, baseado em estações fixas de alto custo, apresenta cobertura espacial limitada, especialmente em países em desenvolvimento [3, 4]. Nesse contexto, sensores de baixo custo (LCS) emergem como uma alternativa promissora

para ampliar a malha de monitoramento [3, 4]. A utilização de plataformas móveis (ônibus, bicicletas, pedestres) para monitoramento tem crescido, permitindo a captura de dados em alta resolução espacial [5, 6].

O sensor *Sensirion SPS30* é amplamente avaliado na literatura para medição de material particulado. Estudos demonstram que o SPS30 apresenta a melhor performance entre sensores de baixo custo, com R^2 mínimo de 0,911 quando calibrado com algoritmos de rede neural artificial, erro médio absoluto percentual (MAPE) inferior a 10% e erro quadrático médio raiz (RMSE) inferior a 7% [7]. Além disso, o SPS30 apresenta a menor variabilidade entre unidades ($CV < 6\%$) [7]. Em testes com aerossóis monodispersos, o SPS30 demonstrou capacidade de detectar concentrações numéricas elevadas, embora com resolução de tamanho inferior aos sensores OPC-N3 e OPC-R2 [8]. Estudos de campo confirmam que o SPS30 correlaciona-se bem com instrumentos de referência para PM_{2.5} e PM₁₀ [7]. Em ambientes com alta umidade, o SPS30 supera outros sensores em sensibilidade às mudanças de umidade relativa [7].

O *Bosch BME280* é amplamente utilizado para medição de temperatura, umidade relativa e pressão barométrica, com precisão de $\pm 0,5^\circ\text{C}$ para temperatura, $\pm 3\%$ para umidade relativa e ± 1 hPa para pressão atmosférica [9]. Estudos de campo demonstram alta concordância do BME280 com estações de referência após procedimentos de calibração, com erro médio de poucos décimos de hPa na pressão atmosférica [10].

O *ScioSense ENS160* é um sensor de qualidade do ar baseado em tecnologia MOX que mede concentrações de TVOC e eCO₂. O sensor utiliza algoritmos de fusão sensorial embarcados que produzem saídas de TVOC, eCO₂ e índice de qualidade do ar (AQI) alinhadas com a resposta natural de ocupantes humanos [11].

O presente trabalho contribui com:

1. Uma prova de conceito de sistema completo de monitoramento ambiental de baixo custo, open-source, integrando sensores SPS30, BME280 e ENS160 com ESP32 e transmissão BLE;
2. Um aplicativo Android para coleta, processamento e envio de dados para a nuvem, com buffer local em SQLite;
3. Algoritmos de agregação espacial em múltiplas escalas (100m, 1km, 10km) para otimização da visualização em mapas, evitando sobrecarga de requisições;
4. Algoritmos de detecção de seis tipos de ilhas urbanas (calor, poluição, umidade, conforto térmico, circulação de ar e albedo), com limiares relativos justificados pela literatura;
5. Uma ferramenta de acesso aberto, replicável e adaptável para diferentes contextos urbanos.

II. DECLARAÇÃO DO PROBLEMA

O problema abordado neste trabalho é a baixa disponibilidade de medições ambientais urbanas com resolução espacial suficiente para apoiar análises de

microclima, exposição a material particulado e identificação de ilhas urbanas em contextos de infraestrutura limitada. Estações fixas de referência oferecem alta qualidade metrológica, porém apresentam custo elevado e cobertura espacial restrita [3, 4]. Como consequência, variações locais associadas a corredores de transporte, áreas com baixa ventilação, zonas com pouca vegetação e ambientes de circulação cotidiana podem permanecer subamostradas. Assim, este estudo investiga se um sistema móvel, reproduzível e de baixo custo, composto por sensores comerciais, microcontrolador, aplicativo móvel e algoritmos de agregação espacial, pode coletar dados úteis para a validação conceitual da metodologia e a detecção qualitativa de padrões ambientais urbanos.

III. METODOLOGIA

a. Arquitetura do Sistema

O sistema é composto por três camadas principais, conforme ilustrado na Figura 1:

1. **Camada de Sensoriamento:** ESP32 conectado aos sensores SPS30, BME280 e ENS160.
2. **Camada de Comunicação:** Transmissão via Bluetooth Low Energy (BLE) utilizando o perfil NUS (Nordic UART Service).
3. **Camada de Processamento:** Aplicativo Android com buffer, armazenamento SQLite e envio para a nuvem (TagoIO).

b. Sensores Utilizados e Evidências de Desempenho na Literatura

A Tabela 1 apresenta as especificações técnicas dos sensores embarcados no ESP32, com referências que evidenciam sua precisão em comparação com equipamentos de referência.

Nota importante: Nenhum dos sensores utilizados neste estudo foi submetido a calibração individual ou certificação. Todos os sensores são novos e foram utilizados com sua calibração de fábrica. O foco deste trabalho está na metodologia de análise e na ferramenta, e não na obtenção de dados com rastreabilidade metrológica. Estudos futuros podem incorporar calibração em campo para maior precisão absoluta.

c. Protocolo de Comunicação BLE e Bufferização

O ESP32 atua como periférico BLE. O aplicativo Android realiza a varredura (scan) por dispositivos com nome contendo “particulagps”. A conexão é estabelecida via GATT, e as notificações são habilitadas através do descritor de configuração do cliente (CCC). Os dados são transmitidos em formato JSON a cada nova leitura, contendo os campos `pm1p0`, `pm2p5`, `pm10p0`, `tvoc`, `eco2`, `aqi`, `temp`, `hum`, `press`, `bat` e `uptime`.

A frequência de amostragem foi configurada para **1 leitura a cada 10 metros** (aproximadamente 1 leitura a cada 2–3 segundos em velocidade urbana), com um **buffer de 10 leituras** no ESP32 antes da transmissão em lote, otimizando o consumo de energia e a largura de banda BLE.




Figura 1: Arquitetura geral do sistema de monitoramento ambiental móvel, organizada em camadas para evitar sobreposição visual.

TABELA 1: SENSORES EMBARCADOS, PARÂMETROS MONITORADOS E EVIDÊNCIAS DE DESEMPENHO NA LITERATURA.

Sensor	Parâmetros	Especificação e evidências	Referência
Sensirion SPS30	PM1.0, PM2.5, PM10	Melhor desempenho entre sensores de baixo custo para material particulado, com $R^2 > 0,911$, $MAPE < 10\%$, $RMSE < 7\%$ e $CV < 6\%$.	[7, 8]
Bosch BME280	Temperatura, umidade relativa e pressão	Precisão de $\pm 0,5^\circ\text{C}$, $\pm 3\%$ de umidade relativa e $\pm 1\text{ hPa}$, com concordância em campo com estações de referência.	[9, 10]
ScioSense ENS160	TVOC, eCO ₂ e índice de qualidade do ar	Sensor MOX com fusão sensorial embarcada para indicadores de qualidade do ar.	[11]




Figura 2: Fluxo de comunicação BLE entre o ESP32 e o aplicativo Android, com mensagens separadas para melhor leitura.

TABELA 2: ESCALAS DE AGREGAÇÃO ESPACIAL IMPLEMENTADAS NO SISTEMA.

Nome	Zoom Máx	Célula (°)	Equivalência
Brutos	99	0,000	Pontos individuais
100m	15	0,001	~100 m
1km	11	0,009	~1 km
10km	8	0,09	~10 km

TABELA 3: REDUÇÃO DE PONTOS POR ESCALA DE AGREGAÇÃO (EXEMPLO COM 10.000 PONTOS BRUTOS).

Escala	Pontos após agregação	Redução (%)
Brutos	10.000	0%
100m	~2.500	75%
1km	~350	96,5%
10km	~15	99,85%

Em caso de perda de conexão, o aplicativo Android armazena os dados localmente em um banco SQLite para envio posterior quando a conectividade com a internet for restabelecida.

O diagrama de sequência da comunicação BLE é apresentado na Figura 2. A implementação completa do firmware e do aplicativo, incluindo os exemplos de payload, está disponível no repositório de código aberto [12].

d. Agregação Espacial em Múltiplas Escalas

Para otimizar a visualização em mapas e evitar sobrecarga de requisições, os dados brutos são agregados em grades espaciais conforme o nível de zoom. A Tabela 2 define as escalas implementadas.

A chave da célula é calculada pela Equação 1:

$$\text{key} = \left\lfloor \frac{\text{lat}}{\text{cellSize}} \right\rfloor 2^{32} + \left\lfloor \frac{\text{lng}}{\text{cellSize}} \right\rfloor \quad (1)$$

Os valores em cada célula são agregados pela média

aritmética:

$$\bar{v} = \frac{1}{n} \sum_{i=1}^n v_i \quad (2)$$

Este mecanismo reduz significativamente o número de pontos a serem transmitidos e renderizados, conforme demonstrado na Tabela 3. A implementação (estrutura GridCell, controle de número máximo de células e atualização incremental das médias) está disponível em [12]; por clareza, o detalhamento de código foi omitido deste manuscrito e mantido no repositório.

e. Índice de Conforto Térmico

O sistema calcula um índice de conforto térmico baseado em temperatura e umidade, adaptado da literatura [13]:

$$C = 100 - \left(\frac{|T - 22|}{30} \times 60 + \frac{|H - 50|}{50} \times 40 \right) \quad (3)$$

onde T é a temperatura em $^{\circ}\text{C}$ e H é a umidade relativa em %. O índice varia de 0 a 100, onde valores mais altos indicam maior conforto térmico. A Equação 3 atribui maior peso relativo aos desvios de temperatura (60%) do que aos desvios de umidade (40%), refletindo a maior sensibilidade do conforto térmico humano à temperatura em climas tropicais úmidos [13, 14].

f. Detecção de Ilhas Urbanas

O sistema implementa seis algoritmos de detecção de ilhas urbanas, cada um baseado em diferentes parâmetros e métricas. O fluxograma geral é apresentado na Figura 3.

1. Ilha de Calor

Baseado em [2, 15]:

$$\text{Ilha}_{\text{calor}}(i) = \begin{cases} 1, & \text{se } T_i > \mu_T \times 1,25 \\ 0, & \text{caso contrário} \end{cases} \quad (4)$$

2. Ilha de Poluição (PM_{2.5})

Baseado em [16]:

$$\text{Ilha}_{\text{pol}}(i) = \begin{cases} 1, & \text{se } PM_{2.5,i} > \mu_{PM} \times 1,3 \\ 0, & \text{caso contrário} \end{cases} \quad (5)$$

3. Ilha de Umidade

$$\text{Ilha}_{\text{umid}}(i) = \begin{cases} 1, & \text{se } H_i > \mu_H \times 1,25 \\ 0, & \text{caso contrário} \end{cases} \quad (6)$$

4. Zonas de Baixo Conforto Térmico

$$\text{Ilha}_{\text{desconforto}}(i) = \begin{cases} 1, & \text{se } C_i < \mu_C \times 0,7 \\ 0, & \text{caso contrário} \end{cases} \quad (7)$$

5. Índice de Circulação de Ar (Estagnação)

Inspirado em [17, 18]:

$$\text{Circ}_i = \frac{1}{3} \left(\frac{\sigma_T}{\bar{T}} + \frac{\sigma_H}{\bar{H}} + \frac{\sigma_{PM}}{\bar{PM}} \right) \times 100 \quad (8)$$

Zonas de ar preso são classificadas quando $\text{Circ}_i < \mu_{\text{Circ}} \times 0,7$.

6. Índice de Albedo Superficial

Baseado em [19]:

$$A_i = \left(0,5 \cdot \frac{T_i - \mu_T}{\mu_T} + 0,3 \cdot \frac{H_i - \mu_H}{\mu_H} + 0,2 \cdot \frac{\mu_P - P_i}{\mu_P} \right) \times 100 \quad (9)$$

Áreas com $A_i > 30\%$ são classificadas como superfícies de alta refletividade. Este índice é particularmente útil para identificar superfícies com alta refletividade, como áreas urbanas com baixa vegetação e alta densidade de construções [19].

g. Justificativa dos Limiares de Detecção

Os limiares de detecção (τ) adotados para a classificação das ilhas urbanas (1,25 para temperatura e umidade; 1,30 para

PM_{2.5}) foram definidos com base em estratégias de limiares relativos intraurbanos [20, 16]. A utilização do multiplicador relativo à média espacial do percurso (μ) permite isolar variações microclimáticas locais da variação sinótica diurna: como toda a rota é percorrida no mesmo intervalo de tempo, a média espacial μ embute a condição atmosférica geral do dia, e o multiplicador τ captura apenas o desvio local, tornando os critérios comparáveis entre dias e percursos distintos [14]. O fator 1,25 para temperatura corresponde a uma elevação relativa tipicamente entre $+2^{\circ}\text{C}$ e $+6^{\circ}\text{C}$ acima da média espacial da rota, patamar condizente com as intensidades de ilhas de calor urbanas documentadas para a região de Natal [2, 21, 22]. Para o material particulado (PM_{2.5}), o limiar de 1,30 (30% acima da média do percurso) foi estabelecido como critério empírico para filtrar ruídos estocásticos dos sensores de baixo custo e delimitar de forma robusta apenas os hotspots de poluição decorrentes do tráfego veicular em corredores viários [6, 16].

Em virtude da ausência de calibração metrológica neste estudo, os multiplicadores não permitem afirmar, em caráter absoluto, que uma determinada localidade constitui uma ilha quando comparada a medições oficiais. Entretanto, por serem pesos multiplicativos, tais limiares podem ser ajustados de forma sistemática no futuro: dispondo-se de medições calibradas (por exemplo, estações de referência ou campanhas de campo com instrumentos certificados), é possível correlacionar as localidades detectadas com ilhas já documentadas na literatura – por exemplo, “neste estudo, há uma ilha de calor na posição X com temperatura T ; no sensor de baixo custo, a mesma posição registrou $\tau \cdot \mu$, o que define o multiplicador de calibração” – e, assim, calibrar o multiplicador para cada tipo de ilha. Este procedimento de calibração relativa é análogo às estratégias de ajuste espacial de sensores de baixo custo reportadas na literatura [6, 16]. O objetivo deste trabalho, contudo, é demonstrar que, com recursos baratos, é possível obter grande quantidade de informação espacial, de forma simples e replicável por qualquer pesquisador, sem a necessidade de carros instrumentados com equipamentos caros circulando pela cidade [6, 5].

h. Configuração Experimental e Coleta de Dados

O sistema foi testado em um ônibus urbano na cidade de Natal-RN, Brasil, percorrendo a rota entre **Nova Parnamirim** e o **Midway Mall**, já na região central. O dispositivo foi **carregado em uma mochila, exposto ao ar próximo à janela do ônibus**, e não instalado fixamente no veículo. Esta configuração simula o uso do sistema por um cidadão comum ou pesquisador que deseja mapear uma área específica.

A Tabela 4 detalha as características do percurso e da coleta.

Importante: Os dados coletados nestes percursos servem **exclusivamente para a avaliação preliminar dos modelos de detecção de ilhas e da metodologia de coleta**, e não como dados calibrados para monitoramento oficial. O foco principal deste trabalho é a **ferramenta em si** – o hardware, o firmware, o aplicativo e os algoritmos – que pode ser replicada e adaptada por outros pesquisadores.




Figura 3: Fluxograma genérico para detecção de ilhas urbanas, com rótulos simplificados para evitar sobreposição.

TABELA 4: CARACTERÍSTICAS DA ROTA DE TESTE E CONFIGURAÇÃO DE COLETA.

Parâmetro	Valor
Cidade	Natal, Rio Grande do Norte, Brasil
Origem	Nova Parnamirim
Destino	Midway Mall, no Centro
Distância aproximada	18 km (trecho monitorado)
Duração média do percurso	40–50 minutos
Horários de coleta	8h–19h (diurno) e 20h–22h (noturno)
Dias de coleta	10 dias úteis
Posicionamento do sensor	Mochila, próximo à janela, exposto ao ar
Proteção	Estrutura de acrílico perfurado contra intempéries
Custo estimado do nó de sensoramento	Inferior a R\$ 500,00
Calibração dos sensores	Nenhuma calibração individual realizada

i. Variáveis de Confusão e Limitações Físicas da Coleta Móvel

A coleta móvel em veículos introduz uma série de variáveis de confusão que precisam ser discutidas explicitamente, uma vez que podem enviesar a amostragem e comprometer a interpretação dos dados [14, 6].

Posicionamento nas proximidades da janela. No teste realizado em ônibus, o sensor foi posicionado próximo à janela porque não havia possibilidade de instalar o dispositivo sobre o veículo ou em outro local com acesso direto ao ar externo. O posicionamento ideal seria em um local **fora** do veículo, preso atrás de alguma estrutura que bloqueie o vento, de modo que a corrente de ar não incida diretamente sobre o sensor: o vento direto pode gerar ruído nas leituras e acelerar o desgaste do equipamento. Estando o sensor protegido atrás de uma estrutura que corte o vento e entregue apenas as partículas ao sensor, as medições seriam mais representativas do ambiente. O estado da janela (aberta ou fechada) e o funcionamento do ar-condicionado também alteram o ar amostrado: janela fechada com ar-condicionado

isola o sensor do ar externo; janela aberta, ao contrário, expõe o sensor ao fluxo turbulento. A prática recomendada é testar a melhor posição de instalação comparando as leituras com dados calibrados para o mesmo local. Tal procedimento **não foi realizado** neste trabalho, pois esta pesquisa é essencialmente uma prova de conceito de tecnologia pronta para implementação, demonstrando que é possível realizar esse tipo de monitoramento de forma barata.

Tratamento de ruído turbulento. Para ruídos turbulentos existem diversas formas de tratamento, incluindo o treinamento de redes neurais e métodos matemáticos que produzem uma previsão numérica do valor real, desconsiderando os fatores turbulentos. Tais métodos **ainda não foram implementados** neste estudo, pois requerem dados de calibração com alguma referência. Cabe observar que os dados de referência disponíveis para a cidade de Natal são limitados: as medições oficiais locais são realizadas por um número restrito de estações e extrapoladas por modelos matemáticos que estimam os valores no restante da cidade. Considerando essa limitação da própria referência, o sensor de baixo custo conseguiu chegar próximo dos valores esperados, como discutido na Seção de Resultados.

Efeitos da velocidade do veículo, turbulência e movimentação da mochila. A velocidade do ônibus, a turbulência do ar, o vento e a movimentação da mochila durante o trajeto afetam as leituras de maneiras distintas. Esses efeitos podem ser tratados com modelos matemáticos ou de aprendizado de máquina que utilizam o mesmo smartphone envolvido na coleta: além do GPS, o acelerômetro do celular pode medir vibrações e movimentos, servindo de entrada para corrigir as leituras ou treinar um modelo de ML para fazer essa correção. O treinamento, porém, exige dados medidos com sensores mais referenciados (mais caros) para estabelecer o comportamento esperado. O ideal é dispor de modelos matemáticos que corrijam as leituras tanto para movimento em veículos quanto para percursos a pé com mochila, permitindo, por exemplo, verificar áreas internas de parques da cidade sem infraestrutura de monitoramento.

Viés de amostragem específico do SPS30. O sensor de partículas SPS30 é um dispositivo óptico: um feixe de luz




Figura 4: Variação da concentração de PM_{2.5} ao longo do percurso, com valores verificados entre 4 e 15 $\mu\text{g}/\text{m}^3$ e predominância entre 4 e 8 $\mu\text{g}/\text{m}^3$.




Figura 5: Variação da temperatura ao longo do percurso (média de aproximadamente 29,0°C).

atravessa o fluxo de ar e o sensor conta as partículas que passam diante da luz. Vibrações e movimentos bruscos podem deslocar partículas aderidas ou levantar partículas de poeira no trajeto óptico, criando “rastros” na frente do feixe e dando a impressão de que passaram mais partículas do que realmente passaram, o que provoca picos espúrios de concentração. A estratégia de mitigação mais simples é descartar momentaneamente as leituras que coincidam com picos de aceleração, utilizando os dados do acelerômetro do smartphone para identificar esses eventos; técnicas mais avançadas (regressão múltipla, filtros adaptativos e filtro de Kalman) são discutidas na Seção de Discussão. Este viés deixa claro que a amostragem móvel sem controle de vibração não representa a concentração ambiente de forma absoluta, mas permanece adequada para a detecção qualitativa de hotspots e gradientes espaciais [6, 16].

IV. RESULTADOS

a. Perfil Temporal dos Parâmetros

As Figuras 4, 5 e 6 apresentam as séries temporais dos principais parâmetros coletados ao longo de um percurso típico. Os valores observados estão em conformidade com o clima tropical costeiro de Natal e com estudos anteriores [2].




Figura 6: Variação da umidade relativa ao longo do percurso (faixa verificada de 68–75%, com estabilidade predominante entre 70–73%).

TABELA 5: ESTATÍSTICAS DESCRITIVAS DOS PARÂMETROS NO PERCURSO TÍPICO ($N = 26$).

Métrica	PM _{2.5} ($\mu\text{g}/\text{m}^3$)	Temperatura (°C)	Umidade (%)
Média	6,6	29,0	71,8
Mediana	6,2	28,9	72,0
Desvio padrão	2,4	0,6	1,4
Coefficiente de variação	35,9%	2,0%	2,0%
Mínimo–Máximo	4,0–15,0	27,9–30,0	68–75
IC 95% da média	[5,7 ; 7,6]	[28,8 ; 29,2]	[71,2 ; 72,4]

b. Análise Estatística dos Parâmetros

Para além da inspeção visual das séries temporais, foram calculadas métricas estatísticas descritivas dos parâmetros coletados no percurso típico ($N = 26$ amostras), apresentadas na Tabela 5. Os mesmos padrões foram observados nos dez dias de coleta; a variabilidade entre percursos foi inferior a 15% para PM_{2.5} e inferior a 3% para temperatura e umidade relativa, indicando consistência temporal das medições.

O coeficiente de variação elevado do PM_{2.5} (35,9%) não reflete instabilidade instrumental do SPS30, mas sim a ocorrência de hotspots concentrados: quando os pontos de pico (11,0 e 15,0 $\mu\text{g}/\text{m}^3$) são desconsiderados, a série apresenta média de 6,0 $\mu\text{g}/\text{m}^3$ e desvio padrão de 1,4 $\mu\text{g}/\text{m}^3$ (CV de 23%), ainda assim superior aos CVs de temperatura e umidade, compatível com a variabilidade espacial esperada do material particulado em ambientes urbanos [16]. Os intervalos de confiança de 95% da média apresentam amplitude reduzida (inferior a ± 1 $\mu\text{g}/\text{m}^3$ para PM_{2.5} e inferior a $\pm 0,3$ unidades para temperatura e umidade), atestando a estabilidade das medições dentro de um mesmo percurso.

A correlação de Pearson entre PM_{2.5} e temperatura, calculada sobre as leituras georreferenciadas do percurso ($N = 19$ pontos), resultou em $r = 0,98$ ($p < 0,001$), com função de regressão aproximada $T \approx 27,4 + 0,15 \cdot \text{PM}_{2.5}$. Essa correlação forte e significativa indica que as zonas de

maior concentração de partículas coincidem espacialmente com as zonas de maior temperatura, como seria esperado em nós viários com alta densidade de tráfego e baixa ventilação [2, 23].

c. Mapeamento Geoespacial dos Parâmetros

A Figura 7 apresenta a geoespacialização das leituras do percurso em coordenadas de latitude e longitude (WGS-84), evidenciando a distribuição espacial das ilhas ao longo do corredor Nova Parnamirim–BR-101–Av. Senador Salgado Filho–Midway Mall. Os hotspots térmicos e de poluição concentram-se nos nós viários (viaduto de Neópolis e cruzamento da Av. Bernardo Vieira, junto ao Midway Mall), enquanto o trecho lindeiro ao Parque das Dunas/Campus da UFRN apresenta as menores concentrações e temperaturas, configurando a “ilha de frescor” documentada na literatura [2, 21, 22, 24].

d. Variação Diurna e Detecção de Ilhas

A Figura 8 apresenta a variação média dos parâmetros ao longo do dia, confirmando os picos de poluição no horário comercial e a persistência de ilhas de calor durante a noite, em concordância com [2].

Em média, foram detectadas **3 ilhas urbanas por percurso**, conforme detalhado na Tabela 6.

e. Consistência com Estudos Prévios do Corredor Monitorado

Os dados deste trabalho não foram submetidos a validação cruzada externa com estações de referência ou dados de satélite, e portanto a detecção aqui realizada deve ser entendida como **preliminar**, sem afirmação metrológica sobre os locais detectados. Não obstante, as leituras são **consistentes** com os estudos de clima urbano e microclima da Região Metropolitana de Natal, conduzidos por pesquisadores da UFRN e do IFRN, que analisam exatamente o corredor Nova Parnamirim–BR-101–Av. Senador Salgado Filho–Midway Mall sob a perspectiva das ilhas de calor, ilhas de umidade e concentração de poluição [21, 22, 25, 24, 26].

1. **Ilhas de Calor Urbanas (ICU):** o nó Midway Mall/Av. Bernardo Vieira é destacado como um dos principais núcleos de ilha de calor do corredor [25, 21]; a altíssima taxa de impermeabilização do solo (asfalto, concreto e edificações de grande porte), a geometria urbana e o grande volume de tráfego geram acréscimos térmicos de até 3–6 °C em relação às áreas rurais e de vegetação densa próximas [22, 25]. No presente experimento, o segmento do Midway registrou as maiores temperaturas (até 30,2 °C) e a maior concentração de PM_{2.5} (até 15,0 µg/m³) de todo o percurso, em acordo com esse cenário. O eixo BR-101/Nova Parnamirim, descrito como corredor térmico contínuo pelo adensamento populacional e pela perda de cobertura vegetal recente [25], também apresentou elevações consistentes de temperatura (29,0–29,9 °C) e de material particulado (8–11 µg/m³) ao longo dos segmentos de acesso aos viadutos. Por

outro lado, o trecho compreendido pelo Campus Central da UFRN e pela borda do Parque das Dunas, reconhecido como **ilha de frescor** que reduz localmente a radiação absorvida e amortecce o calor vindo do asfalto [21, 24], registrou as menores temperaturas do percurso (27,5–27,8 °C) e as menores concentrações de PM_{2.5} (4,0–4,4 µg/m³), replicando de forma qualitativa esse efeito atenuador.

2. **Ilhas de Umidade e Comportamento Higrométrico:** as áreas secas (menor umidade) previstas junto aos nós viários mais asfaltados (Midway Mall e viadutos da BR-101), onde o escoamento superficial rápido da água pluvial e a baixa evapotranspiração criam episódios de “ilha seca” nas horas mais quentes [25, 22], correspondem às menores umidades relativas registradas (68–70%) no entorno do Midway. As ilhas de umidade previstas ao longo do limite leste da Av. Salgado Filho (junto ao Parque das Dunas) e nas proximidades do curso do Rio Pitumbu [25], mantidas por evapotranspiração vegetal e umidade do solo, correspondem às maiores leituras de umidade do percurso (73–75%) no trecho lindeiro ao parque.
3. **Ilhas de Poluição e Qualidade do Ar:** os gargalos de emissões veiculares descritos na literatura – o cruzamento da Salgado Filho com a Bernardo Vieira (Midway) e os acessos aos viadutos de Neópolis e Nova Parnamirim – coincidem com as três ilhas de poluição detectadas em cada percurso [25, 22]. A dinâmica dos ventos alísios litorâneos, que auxilia a dispersão na maior parte do trajeto, é localmente anulada pelo efeito de “cânion urbano” gerado pela verticalização na Salgado Filho e Nova Parnamirim, além do tempo de espera nos semáforos, criando microrregiões de retenção de fuligem e gases [25, 22]. A coincidência espacial entre os picos de temperatura e de PM_{2.5} observada nos dados é compatível com esse mecanismo de retenção em nós viários intensamente verticalizados [23].

A leitura integrada da Figura 7, da Tabela 5 e dessa comparação qualitativa com a literatura local permite afirmar que, mesmo sem calibração absoluta, o sistema de baixo custo reproduziu os padrões espaciais de microclima e poluição documentados para o corredor – o que constitui o objetivo central desta prova de conceito.

f. Correlação entre Ilhas de Calor e Poluição

Os dados confirmam que as ilhas de calor não temporárias estão fortemente associadas a zonas com alta concentração de prédios, baixo relevo e intenso fluxo de tráfego, alinhando-se com estudos sobre ilhas de calor urbanas e interação entre temperatura de superfície e qualidade do ar [2, 23]. Observou-se também que zonas com alta umidade e baixa circulação apresentam menor concentração de PM_{2.5}, corroborando o mecanismo de agregação e deposição úmida descrito em estudos de umidade e partículas [27]. A Figura 9 ilustra essa relação espacial, com correlação de Pearson $r = 0,98$.




Figura 7: Distribuição espacial das leituras ao longo da rota monitorada: (a) concentração de PM_{2.5}; (b) temperatura do ar. Os maiores valores concentram-se nos nós viários (viaduto de Neópolis e Midway Mall), enquanto os menores ocorrem no trecho do Parque das Dunas/Campus UFRN (ilha de frescor).

TABELA 6: ILHAS DETECTADAS EM MÉDIA POR PERCURSO E SUAS CARACTERÍSTICAS.

Tipo de Ilha	Qtd.	Localização Típica	Mecanismo Observado
Poluição (PM _{2.5})	3	Midway Mall (Centro)	Alta densidade de tráfego e construções
Calor	3	Áreas com pouca vegetação	Retenção de calor em solo exposto
Umidade	2	Zonas fechadas	Ar retido, particulados agregados
Baixo Conforto	2	Áreas quentes e úmidas	Combinação de alta T e H
Ar Preso (Circulação)	1	Áreas abertas	Baixa renovação, alta variabilidade
Albedo	2	Solo arenoso, sem vegetação	Retenção de calor, evaporação intensa




Figura 8: Perfil diurno dos parâmetros normalizados, destacando picos de PM_{2.5} no horário comercial e elevação da umidade à noite.

Figura 9: Correlação positiva entre concentração de PM_{2.5} e temperatura, indicando sobreposição de ilhas de poluição e calor.

V. DISCUSSÃO

a. Evidências de Desempenho dos Sensores na Literatura

A escolha dos sensores SPS30, BME280 e ENS160 é amplamente justificada pela literatura. O SPS30 apresenta a melhor performance entre sensores de baixo custo para PM_{2.5}, com R² mínimo de 0,911 e CV < 6% [7]. Estudos de campo confirmam alta linearidade (R² 0,90–0,99) com instrumentos de referência [7]. O BME280 oferece precisão de ±0,5°C para temperatura, com concordância comprovada em campo com estações de referência após calibração [10]. O ENS160, com sua tecnologia de fusão sensorial, oferece detecção estável de TVOC e eCO₂ [11]. Embora os sensores não tenham sido calibrados individualmente neste estudo, a extensa evidência na literatura indica que os dados são adequados para fins de pesquisa e desenvolvimento metodológico, desde que tratados como medições relativas e não absolutas [3, 4]. Nesse sentido, este estudo não pretende validar os sensores, mas sim demonstrar a viabilidade de uma plataforma de coleta de baixo custo.

b. Avaliação Conceitual da Detecção de Ilhas

Os modelos de detecção de ilhas propostos foram submetidos a uma **avaliação preliminar (prova de conceito)** por meio da correspondência qualitativa com padrões esperados: ilhas de calor em áreas com pouca vegetação e alta densidade construtiva, ilhas de poluição em corredores de tráfego intenso e zonas de ar preso em áreas com baixa circulação. Estes padrões são consistentes com os estudos de UHI em Natal [2, 21, 22, 25] e com modelos de estagnação atmosférica [17, 18]. Não se trata, portanto, de uma validação absoluta do algoritmo de detecção – que demandaria calibração metrológica, campanhas maiores e validação cruzada com instrumentos de referência – mas de uma **validação conceitual** de que a arquitetura proposta é capaz de reproduzir, com recursos de baixo custo, os padrões espaciais documentados na literatura para o corredor monitorado.

c. Técnicas para Redução de Ruído e Falhas de Leitura em Veículos ou Mochilas

Conforme discutido na Metodologia, a vibração e a movimentação são fontes de erro nas leituras, especialmente do sensor óptico de partículas SPS30. Para reduzir o ruído e as falhas de leitura em veículos ou mochilas, as seguintes técnicas podem ser adotadas em ordem crescente de complexidade:

1. **Regressão Múltipla (MLR):** é a mais simples de implementar e validar. Incorpora os dados de um acelerômetro (eixos X, Y e Z) como variáveis adicionais na equação de correção, modelando diretamente o impacto da vibração sobre a leitura bruta:

$$\widehat{PM}_{2.5}(t) = \beta_0 + \beta_1 PM_{2.5}^{bruta}(t) + \beta_2 a_x(t) + \beta_3 a_y(t) + \beta_4 a_z(t) \quad (10)$$

onde $\widehat{PM}_{2.5}$ é a concentração corrigida, $PM_{2.5}^{bruta}$ é a leitura do sensor, a_x , a_y e a_z são as componentes da

aceleração medida pelo acelerômetro do smartphone e β_j são coeficientes ajustados por mínimos quadrados a partir de dados de calibração com instrumento de referência. A Equação 10 modela a correção linear e é adequada quando a relação vibração-efeito é aproximadamente linear e estacionária ao longo do percurso.

2. **Filtro Adaptativo (RLS):** se o ruído for muito variável e a MLR não for suficiente, implementa-se um filtro de mínimos quadrados recursivos (RLS), utilizando o sinal do acelerômetro como entrada de referência de ruído. O filtro RLS adapta seus coeficientes a cada amostra, minimizando recursivamente o erro médio quadrático entre a saída corrigida e o valor esperado, sendo mais robusto a mudanças graduais no perfil de vibração (por exemplo, trechos pavimentados versus trechos irregulares).
3. **Filtro de Kalman:** para sistemas complexos, em que se dispõe de um modelo dinâmico do movimento (posição e velocidade, por exemplo) e de múltiplos sensores, o filtro de Kalman é a solução mais poderosa e robusta: ele funde as leituras dos sensores ambientais com o modelo dinâmico do veículo e os dados do acelerômetro, produzindo estimativas ótimas que ponderam incertezas de cada fonte. Essa abordagem também pode ser combinada com modelos de rede neural para correção não linear dos fatores turbulentos.

Estas técnicas demandam dados de calibração com sensores de referência para ajuste e avaliação, o que constitui trabalho futuro. A mitigação imediata já aplicada na análise dos dados deste estudo foi a inspeção dos picos: leituras coincidentes com eventos bruscos de aceleração foram identificadas e tratadas como suspeitas, evitando que picos espúrios fossem contabilizados como ilhas de poluição.

d. Trabalhos Correlatos e Diferenciais da Proposta

A Tabela 7 compara a solução proposta com trabalhos representativos da literatura de monitoramento móvel. O diferencial central deste trabalho é a combinação, em uma única arquitetura aberta e de custo muito baixo, de (i) hardware com sensores de múltiplos parâmetros (partículas, temperatura, umidade, pressão, TVOC/eCO₂), (ii) aplicativo Android próprio que usa o smartphone já existente para GPS, acelerômetro e buffer local, (iii) envio estruturado para nuvem e (iv) algoritmos de agregação espacial multi-escala e detecção de seis tipos de ilhas urbanas – replicável por qualquer pesquisador ou cidadão.

e. Aplicações e Potencial de Replicação

O sistema é apresentado como uma ferramenta de código aberto, com as seguintes aplicações potenciais:

1. **Monitoramento colaborativo:** Cidadãos podem portar o dispositivo em mochilas durante deslocamentos cotidianos, gerando mapas colaborativos de qualidade do ar.

TABELA 7: COMPARAÇÃO DA SOLUÇÃO PROPOSTA COM TRABALHOS CORRELATOS DA LITERATURA.

Trabalho	Plataforma/Hardware	Sensores	App móvel	Custo	Foco/Diferencial
Apte et al. (2017) [6]	Carros Google Street View instrumentados	Instrumentos de referência (PM2.5, NOx, black carbon)	Não	Alto	Mapeamento de alta resolução; precisão máxima, inviável para replicação em larga escala
Gujar et al. (2025) [5]	STM32 embarcado em 4 ônibus universitários	SDS011 (PM2.5/PM10) e AHT10 (T, UR)	Não	Baixo	6 meses de coleta em Hyderabad; dashboard web; sem processamento móvel local
Mészáros et al. (2025) [16]	Rede fixa de sensores comerciais (AirVisual Pro)	PM2.5 + CO ₂	Não	Médio	Heterogeneidade espacial do PM2.5 entre 8 estações; avaliação da confiabilidade de LCS
Este trabalho	ESP32 + app Android (BLE, GPS, SQLite) + nuvem	SPS30, BME280, ENS160	Sim	Muito baixo (nó < R\$ 500)	Coleta móvel em mochila/ônibus; agregação multi-escala; 6 tipos de ilhas; open-source [12]

- Integração em frotas:** O sistema pode ser integrado a ônibus, Ubers ou outros veículos que já possuem GPS e celular, ampliando a cobertura espacial.
- Estudos específicos:** Pesquisadores podem adaptar o dispositivo para mapear áreas específicas como parques, shoppings, corredores de transporte ou zonas industriais.
- Planejamento urbano:** Os dados gerados podem subsidiar políticas públicas de mobilidade, arborização e zoneamento.

A Tabela 8 resume os potenciais usos do sistema.

f. Limitações do Estudo e Trabalhos Futuros

Impacto da ausência de calibração nas ilhas detectadas. Este trabalho não discute os dados em si com pretensão de precisão metrológica, mas sim a **viabilidade de utilizar equipamentos de baixo custo e o celular para reunir todos os dados e fazer mapeamentos na cidade**, viabilizando a implementação futura de modelos matemáticos e redes neurais para treinar uma inteligência artificial capaz de obter dados confiáveis mesmo com sensores baratos – permitindo que outros trabalhos repliquem e estudem diversos dados sem dificuldade. Como não houve calibração contra um instrumento de referência, não é possível afirmar quantitativamente que os locais detectados são ilhas urbanas em termos absolutos; a confiabilidade dos resultados se limita à detecção qualitativa de gradientes e hotspots, cuja plausibilidade foi corroborada pela comparação com a literatura local (Seção de Resultados). Em síntese, o impacto da falta de calibração é a impossibilidade de afirmações absolutas sobre a cidade, não a impossibilidade de demonstrar a validade conceitual da abordagem.

Amostragem limitada. A coleta foi realizada por apenas **10 dias em 1 rota**. Para o objetivo do trabalho – entregar uma solução de baixo custo pronta para uso, demonstrando que a arquitetura funciona e produz dados coerentes – essa amostra é suficiente como prova de conceito. Ela não é

suficiente, porém, para concluir qualquer coisa definitiva sobre a cidade de Natal: não se está analisando a cidade em si, e dados precisos da cidade exigiriam campanhas de mais longo prazo, cobertura sazonal (outras estações do ano), múltiplas rotas e outros horários, além de calibração. Em outras cidades ou estações, os limiares relativos tendem a se comportar de forma diferente, e a validação da metodologia em outros contextos é trabalho futuro. O que este trabalho busca viabilizar é justamente que qualquer pesquisador use sensores de baixo custo e modelos matemáticos para reduzir falhas de leitura e obter dados úteis, em escala e tempo reduzidos.

Outras limitações já discutidas incluem a conectividade BLE (instabilidade em áreas com alta interferência eletromagnética, mitigada por mecanismos de reconexão e buffer local), o consumo de bateria do smartphone (BLE + GPS contínuos, sem fonte externa), e as variáveis de confusão físicas da coleta móvel (Seção de Metodologia).

Trabalhos futuros incluem:

- Calibração em campo dos sensores com estações de referência e ajuste dos multiplicadores τ por correlação espacial com estudos documentados;
- Integração de acelerômetro e aplicação das técnicas de redução de ruído (MLR, RLS e filtro de Kalman) descritas na Seção de Discussão;
- Ampliação da rede de sensores com múltiplos dispositivos e campanhas sazonais;
- Desenvolvimento de um dashboard público para visualização dos dados;
- Dimensionamento da infraestrutura de nuvem para receber requisições simultâneas de uma frota em tempo real (ônibus ou aplicativos de transporte por aplicativo), com filas de mensagens e processamento distribuído.

TABELA 8: APLICAÇÕES POTENCIAIS DO SISTEMA DE MONITORAMENTO MÓVEL.

Cenário de Uso	Plataforma	Aplicação
Monitoramento urbano	Ônibus, Uber, pedestres	Mapas de qualidade do ar e UHI
Estudos de parques	Mochila (pedestre)	Microclima em áreas verdes
Ambientes fechados	Mochila (shopping)	Qualidade do ar indoor
Corredores de transporte	Ônibus, carros	Exposição a poluentes em vias
Planejamento urbano	Dados agregados	Identificação de hotspots
Educação e pesquisa	Código aberto	Reprodução e adaptação




Figura 10: Diagrama de conexão física entre ESP32 e sensores.

VI. DETALHES DE IMPLEMENTAÇÃO E REPRODUÇÃO

Por questão de espaço, os trechos de código e os payloads JSON completos foram omitidos deste manuscrito e disponibilizados no repositório de código aberto do projeto [12]. A seguir, são resumidos os principais detalhes de implementação.

a. Configuração de Conexão dos Sensores ao ESP32

A Figura 10 apresenta o diagrama simplificado de conexão. O SPS30 comunica-se via UART, enquanto BME280 e ENS160 utilizam I2C.

b. Protocolo de Dados

Cada leitura é serializada em um payload JSON compacto com os campos descritos na Seção de Metodologia (pm1p0, pm2p5, pm10p0, tvoc, eco2, aqi, temp, hum, press, bat, uptime). O aplicativo Android acrescenta a geolocalização (latitude, longitude e precisão do GPS) e o horário UTC antes de gravar no buffer SQLite e, posteriormente, enviar o lote para a nuvem.

c. Agregação Espacial

A agregação segue as Equações 1 e 2: para cada ponto recebido, calcula-se a chave da célula e atualiza-se incrementalmente a média e a contagem da célula correspondente, com limite máximo de células memorizadas para garantir estabilidade de memória no aplicativo. O detalhamento do código (estrutura GridCell, controle de limites e rotinas de serialização) está no repositório [12].

VII. CONCLUSÃO

O que este trabalho demonstrou. Foi desenvolvida e testada, em caráter de prova de conceito, uma plataforma completa e de baixo custo para monitoramento ambiental móvel: hardware com ESP32 e sensores SPS30, BME280 e ENS160; transmissão BLE; aplicativo Android com GPS,

buffer SQLite e envio à nuvem; algoritmos de agregação espacial em múltiplas escalas (redução de até 99,85% dos pontos) e detecção de seis tipos de ilhas urbanas (calor, poluição, umidade, conforto, circulação e albedo), com limiares relativos justificados pela literatura. Em 10 dias de coleta em rota de ônibus em Natal-RN, as leituras (PM2.5 entre 4 e 15 $\mu\text{g}/\text{m}^3$; temperatura entre 27,9 e 30,0 °C; umidade entre 68 e 75%) mostraram-se estáveis ($\text{CV} \leq 2\%$ para temperatura e umidade), estatisticamente descritas (Tabela 5) e geoespacialmente coerentes: os hotspots de calor e poluição coincidiram com os nós viários documentados na literatura (Midway Mall e viadutos da BR-101), e a ilha de frescor do Parque das Dunas/Campus UFRN apareceu de forma clara nos mapas. A correlação espacial entre PM2.5 e temperatura ($r = 0,98$) reforça a consistência interna dos dados. Essa coerência com estudos prévios constitui a evidência de que a abordagem funciona como viabilizadora de monitoramento de baixo custo, replicável e aberta.

O que ainda não foi comprovado. Não foram realizadas calibração metrológica dos sensores nem validação cruzada com estações de referência ou satélite; portanto, nenhuma afirmação absoluta sobre a cidade de Natal pode ser derivada destes dados. A amostragem (10 dias, 1 rota) é suficiente para a validação conceitual da metodologia, mas insuficiente para caracterização urbana ou climática. O tratamento automatizado de vibração e turbulência (MLR, RLS, filtro de Kalman e modelos de aprendizado de máquina) ainda não foi implementado, pois depende de dados de calibração.

Perspectivas. A integração futura em frotas de ônibus ou aplicativos de transporte (Uber e similares), que já possuem GPS e celular, permitiria medição contínua e em tempo real em escala metropolitana; para isso, a infraestrutura de nuvem deve ser significativamente ampliada para receber múltiplas requisições simultâneas, com filas de mensagens, processamento distribuído e dashboards públicos. O código aberto disponível no repositório [12] permite que qualquer pesquisador ou cidadão replique o sistema, adapte-o e contribua com a expansão da malha de monitoramento ambiental urbano.

REFERÊNCIAS

- [1] World Health Organization, "Who global air quality guidelines: particulate matter (pm2.5 and pm10), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide," Geneva, 2021.
- [2] A. T. B. Santos *et al.*, "Urban heat islands in coastal metropolitan areas of fortaleza and natal, northeastern brazil, and their interactions with local wind patterns," Preprint, SSRN, 2024.
- [3] F. Karagulian, M. Barbiere, A. Kotsev, L. Spinelle, M. Gerboles, F. Lagler, N. Redon, S. Crunaire, and A. Borowiak, "Review of

- the performance of low-cost sensors for air quality monitoring,” *Atmosphere*, vol. 10, no. 9, p. 506, 2019.
- [4] B. Alfano, L. Barretta, A. Del Giudice, S. De Vito, G. Di Francia, E. Esposito, F. Formisano, E. Massera, M. L. Miglietta, and T. Polichetti, “A review of low-cost particulate matter sensors from the developers’ perspective,” *Sensors*, vol. 20, no. 23, p. 6819, 2020.
 - [5] S. Gujar, H. Pamireddy, N. S. Maradani, S. Sara, S. Chaudhari, and K. S. Rajan, “Citywide mobile air quality monitoring using gps-enabled low-cost iot sensors,” *E3S Web of Conferences*, vol. 620, p. 01002, 2025.
 - [6] J. S. Apte, K. P. Messier, S. Gani, M. Brauer, T. W. Kirchstetter, M. M. Lunden, D. C. Quiros, A. P. Grieshop, and S. P. Hamburg, “High-resolution air pollution mapping with google street view cars: exploiting big data,” *Environmental Science and Technology*, vol. 51, no. 12, pp. 6999–7008, 2017.
 - [7] D. Agrawal *et al.*, “In chamber calibration and performance evaluation of air quality low-cost sensors,” *Atmospheric Pollution Research*, vol. 15, no. 12, 2024.
 - [8] M. Nothhelfer, A. M. Todea, D. Bathen, and C. Asbach, “Performance evaluation of five different low-cost particulate matter sensors for monodisperse test aerosols,” *Aerosol and Air Quality Research*, 2025.
 - [9] Bosch Sensortec, “Bme280: Combined humidity and pressure sensor – datasheet (bst-bme280-ds002),” Documento técnico, Bosch Sensortec GmbH, 2018.
 - [10] H. A. Kusuma, Yuliani, T. Suhendra, D. Devendra, and D. E. D. Setyono, “Evaluating the accuracy of bmp280 and bme280 sensors for sea level in a coastal environment: a field study at tanjung siambang pier,” *Ilmu Kelautan: Indonesian Journal of Marine Sciences*, vol. 28, no. 2, pp. 189–202, 2023.
 - [11] ScioSense, “Ens160: Digital multi-gas sensor for monitoring air quality – datasheet (sc-001224-ds-9, version 1.3),” Documento técnico, ScioSense B.V., 2023.
 - [12] houslast3, “App de comunicação android (wifi, udp, https ou bluetooth) para coleta de dados ambientais,” Repositório de código aberto disponível em <https://github.com/houslast3/app-android-communication-wifi-udp-https-or-bluetooth->, 2025.
 - [13] N. O. Adelakun, “Development and application of a simplified thermal comfort index for urban environmental monitoring,” *International Journal of Environmental Monitoring and Analysis*, 2023.
 - [14] T. R. Oke, G. Mills, A. Christen, and J. A. Voogt, *Urban Climates*. Cambridge: Cambridge University Press, 2017.
 - [15] S. Croce *et al.*, “Urban microclimate monitoring with mobile transects and low-cost sensors for heat island detection,” *Urban Climate*, vol. 45, 2022.
 - [16] R. Mészáros, Z. Barcza, B. Atfeh, R. Hollós, E. Kristóf, Á. V. Tordai, and V. Groma, “Quantification of the spatial heterogeneity of pm_{2.5} to support the evaluation of low-cost sensors: a long-term urban case study,” *Atmosphere*, vol. 16, no. 9, p. 998, 2025.
 - [17] Q. Huang *et al.*, “The variation of air stagnation and its impact on air quality in china,” *Atmospheric Environment*, vol. 161, pp. 112–120, 2017.
 - [18] Y. Wang *et al.*, “Atmospheric stagnation events and their contribution to urban air pollution episodes,” *Atmospheric Research*, vol. 265, 2022.
 - [19] T. Hidayat *et al.*, “Combined surface albedo index for urban heat island assessment using remote sensing data,” *Remote Sensing Applications: Society and Environment*, vol. 24, 2021.
 - [20] B. Bechtel, P. J. Alexander, J. Böhner, J. Ching, O. Conrad, J. Feddema, G. Mills, L. See, and I. D. Stewart, “Mapping local climate zones for urban heat island studies,” *Remote Sensing*, vol. 7, no. 2, pp. 1992–2019, 2015.
 - [21] M. J. d. O. Alexandre, “El clima urbano de la ciudad de natal (brasil), aplicando modelos de campo y teledetección orbital,” Ph.D. dissertation, Universidad Autónoma de Madrid, Madrid, Espanha, 2014.
 - [22] F. R. B. d. Silva, “A influência da velocidade do vento na intensidade das ilhas de calor urbanas na cidade de natal/rn,” Master’s thesis, Universidade Federal do Rio Grande do Norte (UFRN), Natal, RN, Brasil, 2025.
 - [23] L. Zhang *et al.*, “Interaction between surface urban heat island and air quality in coastal cities,” *Urban Climate*, vol. 59, 2025.
 - [24] Prefeitura Municipal do Natal, “Cidade para pessoas: Arborização nas ações pelo clima,” Natal, RN, 2022, accessed: 2026-08-20. [Online]. Available: https://redus-homolog.s3-sa-east-1.amazonaws.com/initiative_library_items/clb3mzalu000g2l840way95ae-Primeiro%20Lugar%20-%20Natal.%20Proposta%20-%20Cidade%20para%20Pessoas.pdf
 - [25] M. J. de Oliveira Alexandre, “Ilhas de calor urbanas em natal-rn: análise integrada das condições térmicas, higrômicas e ventos na área metropolitana,” Projeto de pesquisa aplicada, Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte (IFRN), 2026, accessed: 2026-08-20. [Online]. Available: <https://portal.ifrn.edu.br/projetos-de-pesquisa/8127/>
 - [26] I. D. Stewart and T. R. Oke, “Local climate zones for urban temperature studies,” *Bulletin of the American Meteorological Society*, vol. 93, no. 12, pp. 1879–1900, 2012.
 - [27] S. Kaur *et al.*, “Influence of relative humidity and low wind conditions on particulate matter accumulation in urban canyons,” *Atmospheric Pollution Research*, 2025.