



**UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO CIÊNCIAS EXATAS E TECNOLOGIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA E TECNOLOGIA AMBIENTAL**

LANNA ALMEIDA PEREIRA

**IDENTIFICAÇÃO DE ÁREAS DE EMISSÃO DE MATERIAL
PARTICULADO A PARTIR DE MODELOS FENOMENOLÓGICOS DE
DISPERSÃO ATMOSFÉRICA E ALGORITMOS DE APRENDIZADO
PROFUNDO**

SÃO LUÍS, MA

2026

LANNA ALMEIDA PEREIRA

IDENTIFICAÇÃO DE ÁREAS DE EMISSÃO DE MATERIAL
PARTICULADO A PARTIR DE MODELOS FENOMENOLÓGICOS DE
DISPERSÃO ATMOSFÉRICA E ALGORITMOS DE APRENDIZADO
PROFUNDO

Dissertação apresentada ao
Programa de Pós-Graduação em
CIÊNCIAS & TECNOLOGIA
AMBIENTAL da Universidade Federal
do Maranhão como requisito à
obtenção do título de MESTRE.

Orientador(a): Harvey Alexander Villa-Vélez

Coorientador(a): Elmo de Sena Ferreira Júnior

Linha de pesquisa: Biotecnologia e Tecnologias Aplicadas ao Meio Ambiente

SÃO LUÍS, MA

2026

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Pereira, Lanna Almeida.

IDENTIFICAÇÃO DE ÁREAS DE EMISSÃO DE MATERIAL PARTICULADO A PARTIR DE MODELOS FENOMENOLÓGICOS DE DISPERSÃO ATMOSFÉRICA E ALGORITMOS DE APRENDIZADO PROFUNDO / Lanna Almeida Pereira. - 2026.

42 f.

Coorientador(a) 1: Elmo de Sena Ferreira Júnior.

Orientador(a): Harvey Alexander Villa-vélez Villa-vélez.

Dissertação (Mestrado) - Programa de Pós-graduação em Ciência e Tecnologia Ambiental/ccet, Universidade Federal do Maranhão, São Luís, 2026.

1. Fluidodinâmica Computacional (cfd). 2. Material Particulado (pm). 3. Redes Neurais Artificiais (anns). I. Villa-vélez, Harvey Alexander Villa-vélez. II. Júnior,



UNIVERSIDADE FEDERAL DO MARANHÃO

Fundação Instituída nos termos da Lei nº 5.152, de 21/10/1966 – São Luís - Maranhão.

Programa de Pós-Graduação em Ciência e Tecnologia Ambiental



LANNA ALMEIDA PEREIRA

IDENTIFICAÇÃO DE ÁREAS DE EMISSÃO DE MATERIAL PARTICULADO A PARTIR DE MODELOS FENOMENOLÓGICOS DE DISPERSÃO ATMOSFÉRICA E ALGORITMOS DE APRENDIZADO PROFUNDO

Dissertação apresentada ao Programa de Pós-Graduação em CIÊNCIAS & TECNOLOGIA AMBIENTAL da Universidade Federal do Maranhão como requisito à obtenção do título de MESTRE.

Aprovada em 27 de fevereiro de 2026.

BANCA EXAMINADORA

Prof. Dr. Harvey Alexander Villa-Vélez
Universidade Federal do Maranhão - UFMA

Prof. Dr. Sergio Souza Costa
Universidade Federal do Maranhão - UFMA

Prof. Dr. Paulo Henrique da Silva Leite Coelho
Universidade Federal do Maranhão - UFMA

São Luís (MA), 27 de fevereiro de 2026

AGRADECIMENTOS

Agradeço ao Programa de Pós-Graduação em Ciência e Tecnologia Ambiental da Universidade Federal do Maranhão (PPGCTA/UFMA) pelo suporte institucional e acadêmico que viabilizou o desenvolvimento deste trabalho. Agradeço também o apoio financeiro da Agência Espacial Brasileira (AEB), por meio do Programa Global Learning and Observation to Benefit the Environment (GLOBE) e ao CENAPAD-SP pelo fornecimento dos recursos computacionais utilizados.

A Deus, por colocar esta oportunidade em meu caminho e guiar cada passo da minha jornada, sua presença me sustentou e me fortaleceu para seguir adiante. Ao professor Harvey Alexander Villa-Vélez e ao professor Elmo de Sena Ferreira Júnior, meus orientadores, pela confiança, paciência e incentivo contínuo. Cada orientação, cada conversa e cada desafio proposto contribuíram de forma decisiva para minha formação acadêmica e pessoal.

Agradeço aos meus pais e a minha irmã que viveram cada etapa deste processo comigo de forma intensa. Obrigada por me apoiarem incondicionalmente, a presença de vocês foi um abraço constante ao longo dessa trajetória.

Ao meu noivo, que me incentivou a ingressar no mestrado e esteve ao meu lado em todos os momentos, celebrando cada conquista e me dando força nos dias difíceis. Sua parceria tornou essa caminhada mais leve e significativa.

E à minha amiga Ana Rita, com quem compartilho o ambiente de trabalho e que sempre demonstrou compreensão e flexibilidade para que eu pudesse conciliar minhas responsabilidades profissionais com as demandas do mestrado. Seu apoio constante e generoso fez toda a diferença para que eu conseguisse chegar até aqui.

A todos vocês, meu mais sincero e eterno agradecimento.

RESUMO

A operação combinada de múltiplas fontes de emissão de material particulado (PM) em áreas industriais e portuárias gera grandes ameaças ambientais e sérios riscos à saúde pública. Os métodos atuais de monitoramento e os modelos preditivos não possuem capacidade suficiente para detectar fontes de emissão de MP em tempo real. Este estudo desenvolveu uma estrutura integrada que utiliza Redes Neurais Artificiais (ANNs) e Fluidodinâmica Computacional (CFD) para localizar com precisão as fontes de emissão de PM em terrenos planos. O modelo de CFD foi validado por meio da análise de dados experimentais e da teoria de similaridade de Monin-Obukhov, a fim de representar com precisão o transporte de material particulado e os perfis atmosféricos. Um conjunto de dados de simulação foi gerado contendo 243 execuções que testaram diferentes combinações de velocidade e direção do vento, com variações na altura e no intervalo de emissão. Esse conjunto de dados serviu como material de treinamento para dois modelos de aprendizado profundo, uma rede LSTM (Memória de Longo e Curto Prazo) e uma CNN1D (Rede Neural Convolucional Unidimensional), para realizar a classificação da localização das emissões de MP. Ambos os modelos alcançaram altos níveis de acurácia, com valores de F1-score acima de 0,95. O tempo necessário para a otimização dos hiperparâmetros evidenciou a diferença entre os modelos, uma vez que a LSTM demandou 4 h e 15 min, enquanto a CNN1D necessitou de 4 h e 43 min. O estudo demonstra que a utilização de dados gerados por CFD em conjunto com modelos de ANN permite uma localização confiável de fontes de emissão, mostrando potencial para a regulação ambiental, a responsabilização industrial e a proteção da saúde pública. A estrutura proposta representa um avanço significativo na localização em tempo real de fontes de MP em ambientes industriais e portuários.

PALAVRAS-CHAVE: Fluidodinâmica Computacional (CFD); Material Particulado (PM); Redes Neurais Artificiais (ANNs).

ABSTRACT

The combined operation of multiple particulate matter (PM) emission sources in industrial and port areas creates major environmental threats and serious public health risks. Current methods of monitoring and predictive models lack sufficient capability to detect PM emission sources in real time. This study developed an integrated framework that uses Artificial Neural Networks (ANNs) and Computational Fluid Dynamics (CFD) to precisely locate PM emission sources in flat terrain. The CFD model was validated through experimental data analysis and the Monin-Obukhov similarity theory to precisely represent the particulate matter transport and atmospheric profiles. We created a simulation dataset containing 243 runs that tested different wind speed and direction combinations with variations in emission height and emission interval. The dataset served as training material for two deep learning models which used Long Short-Term Memory (LSTM) and a one-dimensional Convolutional Neural Network (CNN1D) to perform PM emission location classification. Both models achieved high accuracy levels with F1- scores above 0.95. The time needed to optimize hyperparameters proved the difference between models because LSTM required 4 h and 15 min and CNN1D needed 4 h and 43 min. This study proves that using CFD-generated data with ANN models allows reliable emission source localization which shows promise for environmental regulation, industrial accountability, and public health protection. The proposed framework represents a major breakthrough in real-time PM source localization in industrial and port environments.

KEYWORD: Computational fluid dynamics (CFD); particulate matter (PM) emission; Artificial Neural Networks (ANNs).

LISTA DE ABREVIATURAS

- ANN — Artificial Neural Network
- ANNs — Artificial Neural Networks
- CFD — Computational Fluid Dynamics
- ABL — Atmospheric Boundary Layer
- CNN1D — One-Dimensional Convolutional Neural Network
- CO — Monóxido de carbono
- F1-score — Medida harmônica entre precisão e revocação
- GRU — Gated Recurrent Unit
- KNN — K-Nearest Neighbors
- LES — Large Eddy Simulation
- LSTM — Long Short-Term Memory
- ML — Machine Learning
- MOST — Monin–Obukhov Similarity Theory
- NO₂ — Dióxido de nitrogênio
- NO_x — Óxidos de nitrogênio
- O₃ — Ozônio
- PM — Particulate matter
- PM_{2.5} — Material particulado com diâmetro aerodinâmico menor que 2,5 µm
- PM₁₀ — Material particulado com diâmetro aerodinâmico menor que 10 µm
- PMF — Positive Matrix Factorization
- RANS — Reynolds-Averaged Navier–Stokes
- SO₂ — Dióxido de enxofre
- St — Número de Stokes
- SVM — Support Vector Machine
- SVR — Support Vector Regression
- VLES — Very Large Eddy Simulation
- WHO — World Health Organization

SUMÁRIO

1. INTRODUÇÃO	8
2. FUNDAMENTAÇÃO TEÓRICA.....	10
2.1. Material Particulado (PM).....	10
2.2. Estrutura e Dinâmica da Camada Limite Atmosférica (ABL)	11
2.3. Fluidodinâmica Computacional (CFD) Aplicada à Dispersão de Material Particulado	13
2.4. Redes Neurais Artificiais (ANNs).....	15
3. JUSTIFICATIVA.....	17
4. HIPÓTESE	18
5. OBJETIVOS	19
5.1 Geral.....	19
5.2 Específicos	19
REFERÊNCIAS.....	19
6. APRESENTAÇÃO DO ARTIGO.....	25
ARTIGO	26
7. CONTRIBUIÇÕES ATRELADAS A DISSERTAÇÃO	26
7.1 Importância Social	26
7.2 Importância Econômica	26
7.3 Importância Ambiental.....	27
NORMAS DA REVISTA	27

1. INTRODUÇÃO

A armazenagem e o transporte de diversos materiais, como soja, arroz, milho, farinha de trigo, amido, açúcar, cacau e minerais, ocorrem em áreas portuárias e setores industriais, onde também são realizadas operações de beneficiamento, carregamento e descarregamento. Essas atividades resultam em emissões de material particulado (PM), que se dispersam para as áreas ao redor, afetando tanto populações urbanas quanto zonas ambientais protegidas (SORTE et al., 2020; PINHEIRO; VENTURI; GALVANI, 2020). Em muitos casos, essas concentrações ultrapassam os limites de segurança estabelecidos pela Organização Mundial da Saúde (WORLD HEALTH ORGANIZATION, 2021). Nos últimos dez anos, a poluição por PM tornou-se um problema crítico de saúde pública, pois está associada ao aumento de doenças cardíacas e mortalidade (LEÃO; ZHANG; SILVA JÚNIOR, 2023; RAJAGOPALAN et al., 2024).

Diversas técnicas de monitoramento têm sido utilizadas para medir concentrações de PM, incluindo métodos gravimétricos, ópticos, difusivos, de impacto e análises químicas, além de abordagens baseadas em sensores. Entre elas, métodos gravimétricos permanecem amplamente utilizados devido à sua robustez e confiabilidade, enquanto dispositivos ópticos que utilizam espalhamento a laser e análise de tempo de voo oferecem medições em tempo real da concentração de massa e da distribuição de tamanho das partículas (O'CONNOR et al., 2014; ZHANG et al., 2023). Sensores de baixo custo também tem sido empregados para monitorar PM₁₀ e PM_{2.5} em áreas poluídas, embora apresentem precisão e sensibilidade limitadas (CRNOSIJA et al., 2022).

Nos últimos anos, modelos de aprendizado de máquina (ML) têm sido aplicados para prever concentrações de PM em ambientes urbanos e industriais. Entre esses modelos estão Adaptive Boosting (AdBoost), Redes Neurais Artificiais (ANNs), Random Forests e Máquinas de Vetores de Suporte (SVMs) (IFTIKHAR et al., 2024; ZHOU et al., 2024; MOHAMMADI; TEIRI; HAJIZADEH, 2024). Alsaber et al. (2023) analisaram o desempenho de KNN, ANN e SVR na previsão de níveis de PM₁₀ no Kuwait usando três anos de dados. Os resultados mostraram que a qualidade do ar é influenciada por variáveis meteorológicas e tipos de poluentes (ALSABER et al., 2023). A aplicação de modelos de ML a dados meteorológicos e de poluentes (como temperatura, umidade, velocidade do vento, SO₂, NO₂, NO_x, CO e O₃) tem sido amplamente investigada (IFTIKHAR et al., 2024; ZHOU et al.,

2024; MOHAMMADI; TEIRI; HAJIZADEH, 2024; ALSABER et al., 2023). No entanto, a identificação de fontes emissoras de PM em tempo real permanece um desafio crítico.

O modelo Positive Matrix Factorization (PMF) tem sido amplamente utilizado em estudos ambientais para quantificar e diferenciar fontes de poluição por PM (HO et al., 2018; DUTTON et al., 2010; SRIVASTAVA et al., 2021; WANG et al., 2024). O PMF decompõe uma matriz de dados observados (X) em perfis de fontes (F) e contribuições de fontes (G), resolvendo $X = GF + E$, onde E representa o erro (variações não explicadas). Uma vantagem importante do PMF é sua restrição de não negatividade (SRIVASTAVA et al., 2021; WANG et al., 2024; PAATERO; TAPPER, 1994).

Por exemplo, um estudo baseado em PMF em Sofia, Bulgária (2019–2020), identificou como principais contribuintes para PM_{10} : poeira suspensa (25%), queima de biomassa (23%) e novas fontes, como sulfatos mistos (HRISTOVA et al., 2020). De forma semelhante, em Nelson, Nova Zelândia, a análise PMF identificou sete fontes distintas de PM_{10} , destacando a queima de biomassa (35%) e o tráfego em estradas não pavimentadas (ANCELET et al., 2014; HRISTOVA et al., 2020).

A precisão na detecção e identificação das fontes de PM é essencial para o controle eficaz da poluição do ar. Entretanto, identificar fontes emissoras em regiões industriais e portuárias com múltiplos emissores é extremamente desafiador. Nesses ambientes, indústrias frequentemente enfrentam dificuldades para demonstrar conformidade com regulamentações de qualidade do ar, pois a dispersão do PM dificulta determinar se uma instalação específica é responsável por níveis excessivos de poluição. Além disso, em regiões portuárias, a gestão ambiental pode enfrentar desafios de planejamento relacionados às emissões de PM, especialmente há fontes próximas e de diferente jurisdição que contribuem para a poluição local. Nesse cenário aumenta a dificuldade de avaliação de responsabilidades e a implementação de estratégias eficazes de mitigação (HONG, 2024; AGARWAL et al., 2020; ENEBISH et al., 2021).

Para enfrentar esse desafio, este estudo propõe um modelo de identificação de fontes emissoras de PM que integra Dinâmica de Fluidos Computacional (CFD) e Redes Neurais Artificiais (ANNs). Embora estudos anteriores tenham investigado a previsão de concentrações de PM usando ANNs, métodos para localizar fontes emissoras de PM ainda não foram desenvolvidos, segundo o conhecimento dos autores. Os resultados deste

trabalho ampliam abordagens tradicionais ao prever concentrações de PM e identificar locais precisos de emissão.

Ao aplicar essa integração CFD–ANN, o modelo pode rastrear dinamicamente padrões de dispersão de PM e determinar se as emissões se originam de uma zona específica. Assim, o estudo contribui para a tecnologia ambiental ao fornecer uma abordagem inovadora, baseada em dados, para identificação de fontes de PM, apoiando fiscalização ambiental, transparência industrial e iniciativas de proteção à saúde pública.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Material Particulado (PM)

O material particulado é composto por partículas sólidas ou líquidas em suspensão na atmosfera, com ampla variação de tamanho, forma e composição. A literatura classifica o PM principalmente em PM₁₀ (diâmetro aerodinâmico < 10 µm) e PM_{2.5} (diâmetro < 2,5 µm), categorias diretamente associadas à capacidade de penetração no sistema respiratório humano. Estudos epidemiológicos mostram que partículas finas estão relacionadas ao aumento de doenças cardiovasculares e respiratórias, além de maior mortalidade em áreas urbanas e industriais (WHO, 2021; MARTINS et al., 2025).

Elevadas concentrações do poluente decorrem não só de altas taxas de emissões, mas também de uma dispersão reduzida, especialmente na camada atmosférica adjacente à superfície, certas condições climáticas também exercem influência substancial sobre as emissões de partículas (GIOVANNINI ET AL., 2020). O tamanho das partículas também é um fator importante, determinando o período que elas permanecerão no ar e como elas são transportadas. Partículas grossas tendem a se depositar no solo em poucas horas, enquanto partículas finas podem permanecer na atmosfera por várias semanas (DONG, 2020).

Do ponto de vista físico, o comportamento aerodinâmico das partículas depende de propriedades como densidade, diâmetro e coeficiente de arrasto. Modelos clássicos, como o de Schiller–Naumann, descrevem a dependência do arrasto com o número de Reynolds da partícula, sendo amplamente utilizados em simulações Lagrangianas (Crowe et al., 2011). Para representar distribuições de tamanho, modelos como Rosin–Rammler e

Lognormal são frequentemente empregados em estudos de dispersão atmosférica e processos industriais (HINDS, 1999).

O modelo Rosin–Rammmler, também conhecido como Weibull para distribuição de partículas, caracteriza a fração acumulada de partículas em função do diâmetro por meio de parâmetros que definem a dispersão e o tamanho característico, sendo especialmente adequado para materiais fragmentados ou gerados por processos mecânicos. Já a distribuição Lognormal assume que o logaritmo dos diâmetros segue uma distribuição normal, o que reflete adequadamente processos de formação de aerossóis governados por nucleação, condensação e coagulação (HINDS, 1999).

Em dinâmica atmosférica, as distribuições de partículas são essenciais para modelar sedimentação, deposição seca e úmida, coeficientes de dispersão e interação com radiação, influenciando diretamente estimativas de transporte e remoção de partículas. A literatura clássica de aerossóis destaca que a escolha adequada da distribuição é determinante para a precisão de modelos de dispersão e avaliação de impactos ambientais (HINDS, 1999).

2.2. Estrutura e Dinâmica da Camada Limite Atmosférica (ABL)

A camada limite atmosférica (ABL) é a porção mais baixa da atmosfera, diretamente influenciada pela superfície terrestre em escalas de tempo da ordem de uma hora ou menos. Nela, processos como atrito mecânico, trocas radiativas, evapotranspiração e fluxos turbulentos de calor e umidade moldam continuamente a estrutura vertical do vento, da temperatura e da umidade (STULL, 1988; GARRATT, 1992).

A ABL é caracterizada por intensa turbulência, que promove mistura eficiente e rápida, tornando suas propriedades altamente variáveis no tempo e no espaço. Sua espessura típica varia entre algumas centenas de metros e cerca de 2 km, dependendo da estabilidade atmosférica, da rugosidade da superfície e da intensidade da radiação solar (STULL, 1988; GARRATT, 1992).

Durante o dia, a ABL costuma ser convectiva e bem misturada; à noite, torna-se estável e rasa, com turbulência fraca e intermitente. Essa dinâmica diária influencia diretamente a dispersão de poluentes, o transporte de energia e o desenvolvimento de sistemas meteorológicos de mesoescala (KAIMAL; FINNIGAN, 1994). A ABL é tradicionalmente dividida em subcamadas, sendo a camada superficial a mais próxima da

superfície, onde os fluxos turbulentos podem ser considerados aproximadamente constantes com a altura, condição que fundamenta a Teoria de Similaridade de Monin–Obukhov (ARYA, 2001).

A Teoria de Similaridade de Monin–Obukhov (MOST) descreve como variáveis turbulentas (como velocidade do vento, temperatura potencial e concentração de scalars) variam verticalmente na camada limite atmosférica superficial. Parte-se da hipótese de que, em condições estacionárias e horizontalmente homogêneas, os fluxos turbulentos de momento e calor permaneçam aproximadamente constantes com a altura (MONIN; OBUKHOV, 1954). Nessas condições, o comportamento médio das propriedades atmosféricas pode ser representado por relações de similaridade que dependem apenas de parâmetros fundamentais, como o atrito mecânico, o fluxo de calor sensível e a aceleração da gravidade. Esses parâmetros permitem construir escalas características de velocidade, temperatura e comprimento (STULL, 1988; GARRATT, 1992).

A teoria MOS estabelece que o perfil de velocidade do vento na Camada Limite Superficial (SBL) é expresso pela Equação (1):

$$u(z) = \frac{u_*}{\kappa} \left[\ln \left(\frac{z}{z_0} \right) - \phi_m \left(\frac{z}{L} \right) \right] \quad (1)$$

Onde u_* é a velocidade de fricção, calculada por $u_* = \frac{\kappa u_{ref}}{\ln(z_{ref}/z_0)}$; $\kappa = 0.41$ é a constante de Von Kármán, z_0 é o comprimento de rugosidade da superfície, cujo valor de 0,03 m representa o comprimento de rugosidade de Davenport-Wieringa para o caso de pradarias e campos agrícolas (JACOBSON, 2005; MCGRATTAN et al., 2024).

O parâmetro L é o comprimento de Monin-Obukhov, que descreve a condição de estabilidade atmosférica, enquanto $\phi_m \left(\frac{z}{L} \right)$ é a função de similaridade para o fluxo de momento, definida pela Equação (2).

$$\phi_m \left(\frac{z}{L} \right) = \begin{cases} -5 \frac{z}{L}, & \text{for } L \geq 0 \\ 2 \ln(1 + \zeta^2) + 1 + \zeta^2 - 2 \tan^{-1}(\zeta) + 2, & \text{for } L < 0 \end{cases} \quad \zeta = 1 - 16 \frac{z^{1/4}}{L} \quad (2)$$

Esse comprimento representa a altura na qual os efeitos da produção mecânica de turbulência se equilibram com os efeitos da flutuabilidade (ARYA, 2001). Quando $L < 0$, a estratificação é instável e a convecção domina; quando $L > 0$, a estratificação é estável e a flutuabilidade suprime a turbulência; e quando $L \rightarrow \infty$, o regime é neutro e a turbulência é controlada quase exclusivamente pelo cisalhamento. Assim, L atua como parâmetro de similaridade que organiza o comportamento turbulento em diferentes regimes (FOKEN, 2006).

As funções de estabilidade permitem quantificar como a estratificação térmica modifica os gradientes verticais em relação ao caso neutro (logarítmico). A partir delas, obtêm-se perfis verticais amplamente utilizados em meteorologia, micrometeorologia, modelagem atmosférica e engenharia do vento, possibilitando estimativas de fluxos turbulentos e condições de superfície a partir de medições realizadas em uma única altura (GARRATT, 1992; STULL, 1988).

2.3. Fluidodinâmica Computacional (CFD) Aplicada à Dispersão de Material Particulado

A solução numérica das equações de Navier–Stokes constitui a base dos modelos de Fluidodinâmica Computacional (CFD), que descrevem a conservação de massa $\nabla \cdot \mathbf{u} = 0$ e de quantidade de movimento, expresso pela Equação (3).

$$\rho \left(\frac{\partial \mathbf{u}}{\partial t} + \mathbf{u} \cdot \nabla \mathbf{u} \right) = -\nabla p + \mu \nabla^2 \mathbf{u} + \rho \mathbf{g} \quad (3)$$

Na equação, ρ representa a densidade do ar; \mathbf{u} o vetor velocidade do escoamento; $\frac{\partial \mathbf{u}}{\partial t}$ corresponde a variação temporal da velocidade; e $\mathbf{u} \cdot \nabla \mathbf{u}$ é o termo convectivo, responsável pelo transporte de momento pelo próprio movimento do fluido. O termo $-\nabla p$ refere-se ao gradiente de pressão, enquanto $\mu \nabla^2 \mathbf{u}$ descreve a difusão viscosa do momento. Por fim, $\rho \mathbf{g}$ representa a força gravitacional atuante no fluido (BATCHELOR, 1967; POPE, 2000).

A turbulência atmosférica é tratada por meio de técnicas de fechamento, que são métodos utilizados para modelar as flutuações turbulentas que não podem ser resolvidas diretamente pelas equações médias. Entre essas técnicas, destacam-se os modelos RANS,

que representam toda a turbulência de forma estatística, e os métodos de resolução parcial, como LES, que resolvem explicitamente apenas as grandes escalas turbulentas (SAGAUT, 2006; WILCOX, 2006).

Enquanto Very Large Eddy Simulation (VLES) resolve apenas as maiores estruturas turbulentas, deixando que escalas médias e pequenas sejam modeladas, assim reduzindo o custo computacional em comparação ao LES clássico, mantendo fidelidade adequada para estudos ambientais (SAGAUT, 2006; WILCOX, 2006).

Enquanto isso para descrever o movimento das partículas, a abordagem Lagrangiana trata cada partícula como uma entidade individual cuja dinâmica é governada pela Equação (4).

$$\frac{dx_p}{dt} = u_p, \quad \frac{du_p}{dt} = \frac{1}{\tau_p}(u - u_p) + g\left(\frac{\rho_p}{\rho} - 1\right) + u'_{\text{turb}}, \quad (4)$$

Onde $\tau_p = \frac{\rho_p d_p^2}{18\mu}$ é o tempo de relaxação, u_p é a velocidade instantânea, $\frac{1}{\tau_p}(u - u_p)$ representa o arrasto que tende a ajustar a velocidade da partícula à do fluido em um tempo característico τ_p , o termo $g\left(\frac{\rho_p}{\rho} - 1\right)$ expressa a aceleração efetiva resultante da combinação entre peso e empuxo, e u'_{turb} incorpora as flutuações turbulentas não resolvidas, responsáveis por reproduzir a influência das pequenas escalas na dispersão e no transporte das partículas. Essa formulação permite capturar regimes intermediários de transporte, especialmente para partículas entre 1–10 μm , cujo número de Stokes $St = \frac{\tau_p U}{L}$ indica comportamento nem totalmente difusivo nem totalmente inercial (POPE, 2000; CROWE et al., 2011).

O termo u_p^* representa a velocidade efetiva do fluido percebida pela partícula em modelos Lagrangianos acoplados a LES/VLES. Essa velocidade é definida pela Equação (5).

$$u_p^* = \bar{u} + u'_{\text{sgs}}, \quad (5)$$

na qual \bar{u} corresponde à velocidade resolvida pelo modelo, associada às grandes escalas turbulentas capturadas pela malha, enquanto u'_{sgs} representa as flutuações turbulentas submalha que não são resolvidas numericamente e precisam ser reconstruídas por meio de modelos estocásticos. A combinação desses termos permite que a partícula

responda tanto às estruturas turbulentas resolvidas quanto às contribuições de pequena escala, resultando em uma descrição mais realista do transporte e da dispersão no escoamento atmosférico (POPE, 2000; SAGAUT, 2006).

2.4. Redes Neurais Artificiais (ANNs)

As Redes Neurais Artificiais (ANN) constituem modelos computacionais inspirados no funcionamento do cérebro humano e são amplamente utilizadas para resolver problemas não lineares e de alta complexidade. Elas são compostas por camadas de neurônios artificiais interconectados, capazes de aprender padrões a partir de dados por meio de processos de treinamento supervisionado ou não supervisionado (GOODFELLOW; BENGIO; COURVILLE, 2016).

As Redes Neurais Artificiais (ANN) tornaram-se ferramentas centrais no processamento de dados ambientais devido à sua capacidade de modelar relações altamente não lineares e integrar múltiplas fontes de informação. O uso dessas técnicas, permitindo a extração automática de padrões complexos em séries temporais, dados meteorológicos, sensoriamento remoto e medições de poluentes (MAO et al., 2021; QIAO et al., 2020).

Modelos modernos de ANN são compostos por camadas profundas capazes de aprender representações hierárquicas, o que os torna superiores a métodos estatísticos tradicionais em tarefas como previsão, classificação e detecção de eventos ambientais extremos. Revisões recentes destacam que arquiteturas profundas têm alcançado resultados de ponta em previsão de qualidade do ar, modelagem hidrológica e análise de variáveis climáticas (KIM et al., 2025; DU et al., 2019). Entre as arquiteturas mais relevantes para esse tipo de tarefa destacam-se as Long Short-Term Memory (LSTM) e as Convolutional Neural Networks unidimensionais (CNN1D).

2.4.1. Redes LSTM (Long Short-Term Memory)

As redes Long Short-Term Memory (LSTM) tornaram-se uma das arquiteturas mais utilizadas para previsão de séries temporais ambientais, são uma evolução das redes neurais recorrentes tradicionais, projetadas para superar problemas de gradiente e capturar dependências de longo prazo em séries temporais. Cada célula LSTM utiliza mecanismos

de portas *input*, *forget* e *output* que controlam o fluxo de informações e permitem armazenar ou descartar estados internos ao longo do tempo (HOCHREITER; SCHMIDHUBER, 1997).

Os mecanismos de portas que controlam o fluxo de informação, permitem capturar dependências de longo prazo e padrões sazonais. Estudos recentes mostram que modelos LSTM superam abordagens estatísticas clássicas na previsão de $PM_{2.5}$, O_3 e outros poluentes, apresentando maior precisão e estabilidade. Além disso, demonstram também que LSTM são eficazes mesmo em cenários com dados faltantes ou alta variabilidade temporal, especialmente quando combinadas com técnicas de otimização ou decomposição de sinais (DU et al., 2019; KRATZERT et al., 2018).

2.4.2. Redes CNN1D (Convolutional Neural Networks 1D)

As Convolutional Neural Networks unidimensionais (CNN1D) aplicam filtros convolucionais ao longo de séries temporais para extrair automaticamente características locais, como picos, tendências curtas e padrões repetitivos. Diferentemente das LSTM, que modelam dependências temporais longas, as CNN1D são eficientes na captura de estruturas locais e hierárquicas, reduzindo o número de parâmetros e aumentando a capacidade de generalização (KIRANYAZ et al., 2021; YU et al., 2024).

Uma das principais vantagens das CNN1D é sua eficiência computacional. Como não dependem de estados recorrentes, essas redes realizam operações paralelas, reduzindo significativamente o número de parâmetros e o tempo de treinamento quando comparadas a arquiteturas como LSTM e GRU. Essa característica torna as CNN1D especialmente adequadas para sistemas de previsão em tempo real, nos quais a atualização contínua dos modelos é essencial para acompanhar mudanças rápidas nas condições atmosféricas. Além disso, sua estrutura convolucional tende a ser mais robusta a falhas de medição e interferências instrumentais, problemas comuns em sensores ambientais (KIRANYAZ et al., 2021; YU et al., 2024).

Em aplicações ambientais, CNN1D têm sido utilizadas para classificação de padrões de poluição, detecção de eventos críticos de qualidade do ar e previsão de séries temporais ambientais. Estudos mostram que CNN1D podem superar modelos tradicionais e, quando combinadas com LSTM, resultam em arquiteturas híbridas altamente eficazes para previsão de poluentes atmosféricos e variáveis hidrometeorológicas (DU et al., 2019; XU et al., 2023)

3. JUSTIFICATIVA

Segundo a Organização Pan-Americana da Saúde - OPAS, mundialmente muitas cidades apresentam exposição a níveis insalubres de material particulado, no entanto esse número é ainda maior em países de baixa e média renda. Entre os 117 países que monitoram a qualidade do ar para os parâmetros PM_{2,5} ou PM₁₀, os de alta renda possuem 17% das cidades conforme as Diretrizes de Qualidade do Ar da OMS, enquanto os de baixa e média renda possuem menos de 1 % das cidades.

Embora havendo melhorias na abrangência das medições, com relação a última atualização do banco de dados em 2018, devido os custos elevados não é possível monitorar o ar em todos os locais (OPAS, 2024). Portanto, as estimativas e modelagens permitem avaliar, de forma barata e com razoável precisão, a qualidade do ar em áreas onde não existe monitoramento (MMA, 2023).

Para a formulação de estratégias e o planejamento de ações de controle da poluição, questões importantes ainda carecem de resposta para identificar e quantificar as fontes que mais impactam, avaliar a eficiência das estratégias de mitigação, a eficácia dessas medidas com relação aos cenários futuros etc. (THUNIS, 2019).

De que área o particulado monitorado foi emitido? Como evitar essas emissões? É possível identificar o local de origem da emissão do particulado com os dados de monitoramento de partículas suspensas? Essas perguntas são desafiadoras e as respostas para elas tem potenciais científico-tecnológico inovadores. Neste contexto, presente projeto de pesquisa se propõe em desenvolver uma metodologia para responder algumas dessas perguntas.

As causas relacionadas a dispersão de particulados acidentais (evento indesejado onde a concentração de particulados está fora das especificações do CONAMA N° 506/2024) dependem de vários fatores. Alguns destes são estocásticos, ou seja, “aleatórios” ou probabilísticos, como a estabilidade atmosférica, a direção do vento, a sua velocidade e a quantidade de material particulado emitido. Tais fatores tem influência significativa no desdobramento da dispersão, mas a luz do melhor conhecimento científico, pouco se sabe como eles podem ser usados para fazer a previsão de uma dispersão acidental ou a origem de sua emissão. No que diz respeito a utilização dos resultados de simulações computacionais com a finalidade de identificar a área de origem da emissão do particulado,

não foi encontrado nenhum modelo ou metodologia que possa ser usada para esta finalidade na literatura.

O conhecimento do local de origem da emissão acidental de particulados em tempo real, ou mais apropriadamente, em tempo “quasi-real”, abre uma nova lacuna para tomada de decisão, treinamento de pessoal, e avaliação mais adequada da eficácia quando a mitigação de acidentes relacionados a emissão de particulados.

Portanto, o presente projeto de pesquisa, além de gerar conhecimento, formar recursos humanos especializados, irá considerar o estado da arte em termos de simulação virtual de dispersão de poluentes, utilizando técnicas avançadas de modelagem e simulação.

4. HIPÓTESE

O projeto admite como pergunta central “Como identificar a localização da emissão de partículas por meio de dispositivos de monitoramento?” e assume como hipótese “Identificação dos locais de emissão de partículas por meio da Modelagem de Dispersão de Poluentes (MD) e das Redes Neurais Artificiais (RNAs)”.

Enquanto a Modelagem de Dispersão (MD) emprega formulações matemáticas para representar a dispersão de poluentes a partir de uma fonte, as Redes Neurais Artificiais (RNAs) utilizam grandes volumes de dados para discernir relações entre variáveis. Portanto, espera-se que prevejam a localização da emissão com base em entradas meteorológicas.

Para testar a hipótese, serão necessários dados meteorológicos (por exemplo, velocidade e direção do vento) e informações sobre a taxa de fluxo de massa de emissão de partículas. Esses dados serão configurados dentro de um ambiente de Modelagem de Dispersão e vários cenários de dispersão serão conduzidos. Os resultados dos cenários de dispersão serão então utilizados para construir Redes Neurais Artificiais (RNAs) usando o software Matlab.

Considerando as possíveis limitações da hipótese, a principal reside no fato de que as RNAs não são construídas com dados reais de dispersão, assim esforços devem ser feitos para minimizar erros. Uma hipótese alternativa poderia considerar os cenários de dispersão reais, mas a falta de controle sobre variáveis meteorológicas torna os

experimentos custosos e potencialmente perigosos para a realização de múltiplos testes de dispersão de partículas.

Outros riscos da abordagem é a possibilidade de que a modelagem de dispersão tradicional não seja a melhor alternativa para representar os cenários de dispersão da vida real. Uma alternativa é empregar modelos mais robustos, como a Dinâmica dos Fluidos Computacional com uma abordagem Lagrangeana. No entanto, isso pode ser computacionalmente muito demorado, exigindo um computador muito poderoso (por exemplo, clusters).

Atualmente, não existe uma ferramenta com a capacidade de avaliar simultaneamente a concentração de partículas e estimar a área de emissão para avaliação em tempo real. Conseqüentemente, essa inovação representa um avanço tecnológico significativo.

5. OBJETIVOS

5.1 Geral

Desenvolver uma metodologia baseada em Redes Neurais Artificiais (ANNs) integrada a modelagem fenomenológica de dispersão atmosférica que estime a área de origem da emissão de material particulado (MP).

5.2 Específicos

1. Planejar, simular e validar modelo de dispersão para cenários de emissão de particulados.
2. Construir um framework gerador de dados a partir das simulações, com atributos relevantes para treinamento de ANNs, incluindo etapas de normalização, conversão e particionamento das variáveis.
3. Treinar, ajustar e comparar diferentes arquiteturas de Redes Neurais Artificiais, avaliando seu desempenho.

REFERÊNCIAS

AGARWAL, S.; SHARMA, S.; RAHMAN, M. H.; et al. Air quality forecasting using artificial neural networks with real-time dynamic error correction in highly polluted regions. *Science of the Total Environment*, v. 735, 139454, 2020. DOI:

10.1016/j.scitotenv.2020.139454.

ALSABER, A.; ALSAHLI, R.; AL-SULTAN, A.; et al. Evaluation of various machine learning prediction methods for particulate matter PM₁₀ in Kuwait. *International Journal of Information Technology*, v. 15, n. 8, p. 4505–4519, 2023. DOI: 10.1007/s41870-023-01521-2.

ANCELET, T.; DAVY, P. K.; TROMPETTER, W. J.; et al. Sources of particulate matter pollution in a small New Zealand city. *Atmospheric Pollution Research*, v. 5, n. 4, p. 572–580, 2014. DOI: 10.5094/APR.2014.066.

BAI, S.; KOLTER, J. Z.; KOLTUN, V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling, 2018.

BATCHELOR, G. K. *An Introduction to Fluid Dynamics*. Cambridge: Cambridge University Press, 1967.

BLOCKEN, B. 50 years of Computational Wind Engineering. *Journal of Wind Engineering and Industrial Aerodynamics*, v. 129, p. 69–102, 2015.

BRUNTON, S.; KUTZ, J. *Data-Driven Science and Engineering*. Cambridge: Cambridge University Press, 2019.

CONSELHO NACIONAL DO MEIO AMBIENTE (CONAMA). Resolução nº 506, de 5 de julho de 2024. Estabelece padrões nacionais de qualidade do ar e dá outras providências. *Diário Oficial da União*: seção 1, Brasília, DF, 9 jul. 2024. p. 133.

CROWE, C. T.; SCHWARZKOPF, J. D.; SOMMERFELD, M.; TSUJI, Y. *Multiphase Flows with Droplets and Particles*. Boca Raton: CRC Press, 2011.

CRNOSIJA, N.; LEVY ZAMORA, M.; RULE, A. M.; et al. Laboratory chamber evaluation of flow air quality sensor PM_{2.5} and PM₁₀ measurements. *International Journal of Environmental Research and Public Health*, v. 19, n. 12, 7340, 2022. DOI: 10.3390/ijerph19127340.

DONG, J.; CHI, Y.; EPHRAIM, A.; NZIHOU, A.; ROMERO MILLÁN, L. M. Particulate Matter. In: NZIHOU, A. (ed.). *Handbook on Characterization of Biomass, Biowaste and Related By-products*. Cham: Springer, 2020. DOI: 10.1007/978-3-030-35020-8_14.

DU, S.; LI, T.; YANG, Y.; HORNG, S. Deep air quality forecasting using hybrid deep learning framework. *IEEE Transactions on Knowledge and Data Engineering*, v. PP, p. 1–11, 2019. DOI: 10.1109/TKDE.2019.2954510.

DUTTON, S.; VEDAL, S.; PIEDRAHITA, R.; et al. Source apportionment using positive matrix factorization on daily measurements of inorganic and organic speciated PM_{2.5}. *Atmospheric Environment*, v. 44, n. 23, p. 2731–2741, 2010. DOI: 10.1016/j.atmosenv.2010.04.038.

ENEBISH, T.; CHAU, K.; JADAMBA, B.; et al. Predicting ambient PM_{2.5} concentrations in Ulaanbaatar, Mongolia with machine learning approaches. *JouANNI of Exposure Science & Environmental Epidemiology*, v. 31, n. 4, p. 699–708, 2021. DOI: 10.1038/s41370-020-0257-8.

FOKEN, T. 50 years of the Monin–Obukhov similarity theory. *Boundary-Layer Meteorology*, v. 119, p. 431–447, 2006.

GARRATT, J. R. *The Atmospheric Boundary Layer*. Cambridge: Cambridge University Press, 1992.

GIOVANNINI, L.; FERRERO, E.; KARL, T.; et al. Atmospheric pollutant dispersion over complex terrain: challenges and needs for improving air quality measurements and modeling. *Atmosphere*, v. 11, 646, 2020. DOI: 10.3390/atmos11060646.

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

HINDS, W. C. *Aerosol Technology: Properties, Behavior, and Measurement of Airborne Particles*. 2. ed. New York: Wiley-Interscience, 1999.

HO, W.; TSENG, K.; LIOU, M.; et al. Application of positive matrix factorization in the identification of the sources of PM_{2.5} in Taipei city. *International Journal of Environmental Research and Public Health*, v. 15, n. 7, 1305, 2018. DOI: 10.3390/ijerph15071305.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural Computation*, v. 9, p. 1735–1780, 1997.

HONG, W. Y. Meteorological variability and predictive forecasting of atmospheric

particulate pollution. *Scientific Reports*, v. 14, n. 1, 14, 2024. DOI: 10.1038/s41598-023-41906-8.

HRISTOVA, E.; VELEVA, B.; GEORGIEVA, E.; et al. Application of positive matrix factorization receptor model for source identification of PM10 in the city of Sofia, Bulgaria. *Atmosphere*, v. 11, n. 9, 890, 2020. DOI: 10.3390/atmos11090890.

IFTIKHAR, H.; QURESHI, M.; ZYWIOŁEK, J.; et al. Short-term PM2.5 forecasting using a unique ensemble technique for proactive environmental management initiatives. *Frontiers in Environmental Science*, v. 12, 1442644, 2024. DOI: 10.3389/fenvs.2024.1442644.

IRANYAZ, S.; INCE, T.; ABDULKADIR, A.; GABBOUJ, M. 1D Convolutional Neural Networks and Applications. *Mechanical Systems and Signal Processing*, v. 151, 107398, 2021.

JACOBSON, M. Z. *Fundamentals of Atmospheric Modeling*. 2. ed. Cambridge: Cambridge University Press, 2005. DOI: 10.1017/CBO9781139165389.

KAIMAL, J. C.; FINNIGAN, J. J. *Atmospheric Boundary Layer Flows: Their Structure and Measurement*. New York: Oxford University Press, 1994.

KIM, J.; KIM, H.; KIM, H.; LEE, D.; YOON, S. A comprehensive survey of deep learning for time series forecasting: architectural diversity and open challenges. *Artificial Intelligence Review*, v. 58, 2025. DOI: 10.1007/s10462-025-112239.

KRATZERT, F.; KLOTZ, D.; BRENNER, C.; et al. Rainfall–runoff modelling using Long Short-Term Memory (LSTM) networks. *Hydrology and Earth System Sciences*, v. 22, p. 6005–6022, 2018.

LEÃO, M. L. P.; ZHANG, L.; SILVA JÚNIOR, F. M. R. Effect of particulate matter (PM2.5 and PM10) on health indicators: climate change scenarios in a Brazilian metropolis. *Environmental Geochemistry and Health*, v. 45, p. 2229–2240, 2023. DOI: 10.1007/s10653-022-01331-8.

LEE, D.; BARQUILLA, C. A. M.; LEE, J. Analyzing dispersion characteristics of fine particulate matter in high-density urban areas: a study using CFD simulation and machine learning. *Land*, v. 14, 632, 2025. DOI: 10.3390/land14030632.

MAO, W.; WANG, W.; JIAO, L.; ZHAO, S.; LIU, A. Modeling air quality prediction using a deep learning approach: method optimization and evaluation. *Sustainable Cities and Society*, v. 65, 102567, 2021. DOI: 10.1016/j.scs.2020.102567.

MARTINS, E. H.; DE SOUZA EICARDI, M.; NOGAROTTO, D. C.; et al. Health and economic benefits of lowering particulate matter (PM) levels: scenarios for a southern Brazilian metropolis. *Aerosol Science and Engineering*, v. 9, p. 1–12, 2025. DOI: 10.1007/s41810-024-00239-3.

MCGRATTAN, K.; HOSTIKKA, S.; FLOYD, J.; et al. *Fire Dynamics Simulator – User Guide*, 2024.

MMA. Ministério do Meio Ambiente e Mudança do Clima. *Relatório Anual de Acompanhamento da Qualidade do Ar 2023*. Brasília: MMA, 2023.

MOHAMMADI, F.; TEIRI, H.; HAJIZADEH, Y. Prediction of atmospheric PM_{2.5} level by machine learning techniques in Isfahan, Iran. *Scientific Reports*, v. 14, 2109, 2024. DOI: 10.1038/s41598-024-52617-z.

MONIN, A. S.; OBUKHOV, A. M. Basic laws of turbulent mixing in the surface layer of the atmosphere. *Trudy Geofizicheskogo Instituta*, v. 24, p. 163–187, 1954.

O’CONNOR, S.; O’CONNOR, P. F.; FENG, H. A.; et al. Gravimetric analysis of particulate matter using air samplers housing inteANNI filtration capsules. *Gefahrstoffe Reinhaltung der Luft*, v. 74, n. 10, p. 403–410, 2014.

OPAS. Atualização das Diretrizes de Qualidade do Ar da OMS e situação global da poluição atmosférica. Washington, D.C.: OPAS, 2024.

PAATERO, P.; TAPPER, U. Positive matrix factorization: a non-negative factor model with optimal utilization of error estimates of data values. *Environmetrics*, v. 5, p. 111–126, 1994. DOI: 10.1002/env.3170050203.

PINHEIRO, J. M.; VENTURI, L. A. B.; GALVANI, E. Atmospheric pollution: a case study of the municipality of São Luís do Maranhão. *Sociedade & Natureza*, v. 32, p. 808–819, 2020. DOI: 10.14393/SN-v32-2020-56162.

POPE, S. B. *Turbulent Flows*. Cambridge: Cambridge University Press, 2000.

QIAO, L.; ZHU, M.; WU, L.; PAN, X.; TANG, X. Deep learning for air quality forecasts: a review. *Current Pollution Reports*, v. 6, p. 111–125, 2020. DOI: 10.1007/s40726-020-00159-z.

RAISSI, M.; PERDIKARIS, P.; KARNIADAKIS, G. Physics-informed neural networks. *JouANNI of Computational Physics*, v. 378, p. 686–707, 2019.

RAJAGOPALAN, S.; BROOK, R. D.; SALERNO, P. R. V. O.; et al. Air pollution exposure and cardiometabolic risk. *The Lancet Diabetes & Endocrinology*, v. 12, n. 3, p. 196–208, 2024. DOI: 10.1016/S2213-8587(23)00361-3.

RYA, S. P. *Introduction to Micrometeorology*. San Diego: Academic Press, 2001.

SAGAUT, P. *Large Eddy Simulation for Incompressible Flows*. Berlin: Springer, 2006.

SORTÉ, S.; RODRIGUES, V.; BORREGO, C.; et al. Impact of harbour activities on local air quality: a review. *Environmental Pollution*, v. 257, 113542, 2020. DOI: 10.1016/j.envpol.2019.113542.

THUNIS, P.; CLAPPIER, A.; TARRASON, L. Source apportionment to support air quality planning: strengths and weaknesses of existing approaches. *Environmental International*, v. 130, p. 104825, 2019

SRIVASTAVA, D.; XU, J.; VU, T.; et al. Insight into PM_{2.5} sources by applying positive matrix factorization (PMF) at urban and rural sites of Beijing. *Atmospheric Chemistry and Physics*, v. 21, p. 14703–14724, 2021. DOI: 10.5194/acp-21-14703-2021.

STULL, R. B. *An Introduction to Boundary Layer Meteorology*. Dordrecht: Kluwer Academic Publishers, 1988.

WANG, Q.; ZHU, S.; WANG, S.; et al. Short-term source apportionment of fine particulate matter with time-dependent profiles using SOFI Pro: exploring the reliability of rolling positive matrix factorization (PMF). *Atmospheric Chemistry and Physics*, v. 24, p. 475–486, 2024. DOI: 10.5194/acp-24-475-2024.

WILCOX, D. C. *Turbulence Modeling for CFD*. La Cañada: DCW Industries, 2006.

WORLD HEALTH ORGANIZATION. *WHO global air quality guidelines: particulate matter (PM_{2.5}, PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide*.

Geneva: WHO, 2021. Disponível em:
<https://www.who.int/publications/i/item/9789240034228> (who.int in Bing).

XU, R.; WANG, D.; LI, J.; et al. A hybrid deep learning model for air quality prediction based on the time–frequency domain relationship. *Atmosphere*, v. 14, 405, 2023. DOI: 10.3390/atmos14020405.

YU, D.; et al. A 1D Convolutional Neural Network (1D-CNN) temporal filter for atmospheric variability. *Applied Sciences*, v. 14, 6289, 2024. DOI: 10.3390/app14146289.

ZHANG, J.; ZHANG, Z.; HOU, L.; ZHOU, W. A novel optical instrument for measuring mass concentration and particle size in real time. *Sensors*, v. 23, n. 7, p. 3616, 2023. DOI: 10.3390/s23073616.

ZHOU, S.; WANG, W.; ZHU, L.; QIAO, Q.; KANG, Y. Deep-learning architecture for PM2.5 concentration prediction: a review. *Environmental Science & Ecotechnology*, v. 21, 100400, 2024. DOI: 10.1016/j.ese.2024.100400.

6. APRESENTAÇÃO DO ARTIGO

Título do artigo: Identificação de áreas de emissão de material particulado a partir de modelos fenomenológicos de dispersão atmosférica e algoritmos de aprendizado profundo.

Artigo a ser submetido ou submetido: Particulate matter emission area identification based on phenomenological atmospheric dispersion and deep learn algorithms

Nome da revista: Environmental Technology

QUALIS da Capes para a área de Geociências: A2

Fator de Impacto da Revista: 2.0 (2024)

Objetivos Específicos da Dissertação atrelados ao artigo:

1. Planejar, simular e validar modelo de dispersão para cenários de emissão de particulados.

2. Construir um framework gerador de dados a partir das simulações, com atributos relevantes para treinamento de ANNs, incluindo etapas de normalização, conversão e

particionamento das variáveis.

3. Treinar, ajustar e comparar diferentes arquiteturas de Redes Neurais Artificiais, avaliando seu desempenho.

ARTIGO

Em anexo ao documento

7. CONTRIBUIÇÕES ATRELADAS A DISSERTAÇÃO

7.1 Importância Social

A identificação de áreas emissoras de material particulado, fundamentada na integração entre modelos fenomenológicos de dispersão atmosférica e algoritmos de aprendizado de máquina, apresenta elevada relevância social ao aprimorar a capacidade de diagnóstico e gestão da qualidade do ar. A exposição a partículas finas está associada ao aumento da incidência de doenças respiratórias, cardiovasculares e inflamatórias, impactando de forma mais intensa populações vulneráveis e comunidades situadas próximas a polos industriais, portuários e vias de tráfego intenso. A metodologia proposta contribui para reduzir incertezas na localização de fontes emissoras, permitindo que órgãos públicos implementem ações de controle mais direcionadas e eficientes. Ao subsidiar políticas de saúde pública, planejamento urbano e estratégias de vigilância ambiental, o estudo fortalece a proteção social e promove condições mais seguras para o desenvolvimento humano em ambientes urbanos e periurbanos.

7.2 Importância Econômica

A abordagem desenvolvida na dissertação possui relevância econômica significativa, uma vez que aprimora a eficiência dos processos de monitoramento e controle de emissões atmosféricas. A utilização combinada de modelos de dispersão e técnicas de aprendizado profundo reduz custos operacionais associados a campanhas extensivas de medição, ao mesmo tempo em que aumenta a precisão na identificação de fontes críticas. Essa melhoria contribui para otimizar investimentos em tecnologias de mitigação, evitar penalidades regulatórias e minimizar interrupções produtivas decorrentes de não conformidades ambientais. Além disso, a redução de doenças relacionadas à poluição atmosférica diminui gastos públicos e privados com tratamentos médicos e afastamentos laborais. Assim, o

estudo favorece um ambiente econômico mais competitivo, sustentável e alinhado às exigências normativas contemporâneas.

7.3 Importância Ambiental

A relevância ambiental desta pesquisa decorre da capacidade de aprimorar a identificação e a caracterização espacial de áreas emissoras de material particulado, contribuindo para uma compreensão mais robusta dos processos de dispersão atmosférica. A integração entre modelos fenomenológicos e algoritmos de deep learning permite detectar padrões complexos de emissão, reduzindo incertezas associadas ao monitoramento convencional. Essa precisão favorece a implementação de estratégias de controle mais eficazes, resultando na diminuição das concentrações de partículas em suspensão e, conseqüentemente, na mitigação de impactos sobre ecossistemas terrestres e aquáticos. Além disso, o aprimoramento do diagnóstico ambiental fortalece políticas públicas voltadas à gestão sustentável da qualidade do ar, promovendo maior resiliência ambiental e preservação dos recursos naturais.

NORMAS DA REVISTA

Estrutura obrigatória:

- Página de título com nome completo dos autores, afiliação institucional, ORCID (se disponível) e autor correspondente com e-mail.
- Resumo não estruturado de até 250 palavras.
- Palavras-chave (quantidade livre, otimizadas para mecanismos de busca).
- Texto principal: introdução, materiais e métodos, resultados, discussão.
- Agradecimentos (opcional).
- Declaração de interesse: caso não haja conflitos, informar “Os autores relatam que não há conflitos de interesse a declarar.”
- Referências (qualquer estilo consistente; DOI recomendado).
- Apêndices, se aplicável.
- Tabelas e figuras em páginas separadas, com legendas listadas.

Resumo gráfico:

- Obrigatório: imagem clara representando o conteúdo do artigo, máx. 525 pixels de largura, enviada separadamente.

Material suplementar online (opcional):

- Arquivos, vídeos ou outros suportes que reforcem os resultados.

Figuras, Tabelas e Equações:

- Figuras: alta resolução (1200 dpi linha, 600 dpi tons de cinza, 300 dpi colorida); formatos aceitos: PS, JPEG, TIFF, Word.
- Tabelas: apresentar informações novas, interpretáveis sem consultar o texto.
- Equações: devem ser editáveis em Word.
- Unidades: SI, sem itálico.

Disponibilidade de dados:

- Incluir declaração detalhando onde os dados do estudo podem ser encontrados (ex.: repositório, DOI, ou solicitação direta aos autores).

Envio e revisão:

- Submissão via ScholarOne Manuscripts.
- Verificação de originalidade via Crossref™.
- Após aceitação, fornecer versão editável do manuscrito.

Taxas e publicação:

- Não há taxas de submissão ou publicação online.
- Figuras coloridas online gratuitas; impressão colorida sujeita a taxa.

Direitos autorais:

- Permitem proteção do material original e escolha de licenças, incluindo Creative Commons para acesso aberto.

Outras normas disponíveis em:

<https://www.tandfonline.com/action/authorSubmission?show=instructions&jouANNICode=ent20>



Particulate matter emission area identification based on phenomenological atmospheric dispersion and deep learn algorithms

Lanna Almeida Pereira, Hilton Costa Louzeiro, Harvey Alexander Villa-Vélez, Aline Bessa Veloso, Alex Oliveira Barradas Filho, Mikele Candida Sousa de Sant Anna & Elmo de Sena Ferreira Júnior

To cite this article: Lanna Almeida Pereira, Hilton Costa Louzeiro, Harvey Alexander Villa-Vélez, Aline Bessa Veloso, Alex Oliveira Barradas Filho, Mikele Candida Sousa de Sant Anna & Elmo de Sena Ferreira Júnior (15 Oct 2025): Particulate matter emission area identification based on phenomenological atmospheric dispersion and deep learn algorithms, Environmental Technology, DOI: [10.1080/09593330.2025.2573837](https://doi.org/10.1080/09593330.2025.2573837)

To link to this article: <https://doi.org/10.1080/09593330.2025.2573837>



Published online: 15 Oct 2025.



Submit your article to this journal [↗](#)










View related articles [↗](#)



View Crossmark data [↗](#)

Particulate matter emission area identification based on phenomenological atmospheric dispersion and deep learn algorithms

Lanna Almeida Pereira ^a, Hilton Costa Louzeiro ^a, Harvey Alexander Villa-Vélez ^a, Aline Bessa Veloso ^b, Alex Oliveira Barradas Filho ^a, Mikele Candida Sousa de Sant Anna ^a and Elmo de Sena Ferreira Júnior ^a

^aExact Sciences and Technology Center (CCET), Federal University of Maranhão (UFMA), São Luis, Brazil; ^bBrazilian Space Agency (AEB), Federal Police Sector, Brasília, Brazil

ABSTRACT

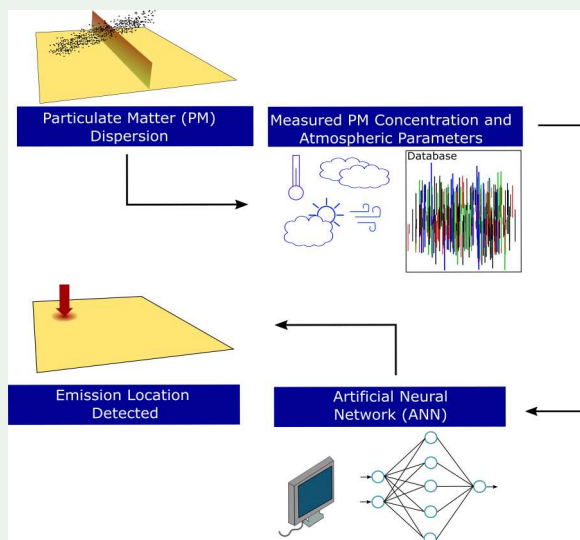
The combined operation of multiple particulate matter (PM) emission sources in industrial and port areas creates major environmental threats and serious public health risks. Current methods of monitoring and predictive models lack sufficient capability to detect PM emission sources in real time. This study developed an integrated framework that uses Artificial Neural Networks (ANNs) and Computational Fluid Dynamics (CFD) to precisely locate PM emission sources in flat terrain. The CFD model was validated through experimental data analysis and the Monin-Obukhov similarity theory to precisely represent the particulate matter transport and atmospheric profiles. We created a simulation dataset containing 243 runs that tested different wind speed and direction combinations with variations in emission height and emission interval. The dataset served as training material for two deep learning models which used Long Short-Term Memory (LSTM) and a one-dimensional Convolutional Neural Network (CNN1D) to perform PM emission location classification. Both models achieved high accuracy levels with F1-scores above 0.95. The time needed to optimize hyperparameters proved the difference between models because LSTM required 4 h and 15 min and CNN1D needed 4 h and 43 min. This study proves that using CFD-generated data with ANN models allows reliable emission source localization which shows promise for environmental regulation, industrial accountability, and public health protection. The proposed framework represents a major breakthrough in real-time PM source localization in industrial and port environments.

ARTICLE HISTORY

Received 23 June 2025
Accepted 2 September 2025

KEYWORDS

Computational fluid dynamics (CFD); particulate matter (PM) emission; emission source localization; convolutional neural network (1D CNN); long short-term memory (LSTM)



1. Introduction

The storage and transportation of several materials, such as soybeans, rice, corn, wheat flour, starch, sugar, cocoa and minerals, occurs in port areas and industrial sectors,

while they also perform beneficiation, loading, and unloading operations. Various material storage and transportation operations result in particulate matter (PM) emissions that are distributed into the surrounding

areas, including both urban populations and protected environmental zones [1,2]. These concentrations exceed the World Health Organization (WHO) safety limits in numerous cases [3]. During the last ten years PM pollution has emerged as a critical public health issue because it leads to elevated heart disease and death statistics [4,5].

Various monitoring techniques have been employed to compute PM concentrations, such as gravimetric, optical, diffusion, impact, and chemical methods, as well as sensor-based approaches. Among them, gravimetric methods remain widely used owing to their robustness and reliability, whereas optical devices leveraging laser scattering and time-of-flight analysis offer real-time measurements of mass concentration and particle size distribution [6,7]. Moreover, low-cost sensors have been used for monitoring PM₁₀ and PM_{2.5} in polluted areas with limited precision and sensitivity [8].

In recent years, machine learning (ML) models have been used to predict PM concentrations in the urban and industrial sectors. These models are Adaptive Boosting (AdBoost), Artificial Neural Networks (ANNs), Random Forests, and Support Vector Machines (SVMs) as instance [9–11]. Alsaber et al. [12] analyzed the performance of k-nearest neighbors (KNN), ANN, and support vector regression (SVR) in forecasting PM₁₀ levels in Kuwait using three years of available data. Their findings show that air quality is influenced by meteorological variables and pollutant types [12]. The application of ML models to meteorological and pollutant data (e.g. temperature, humidity, wind speed, SO₂, NO₂, NO_x, CO, and O₃) to improve PM concentration predictions has been investigated by several authors [9–12]. However, the identification of PM emission sources in real-time remains a critical challenge.

The Positive Matrix Factorization (PMF) model has been widely used in environmental studies to quantify and differentiate PM pollution sources [13–16]. PMF decomposes an observed data matrix (X) into source profiles (F) and source contributions (G), solving $X = GF + E$, where E represents the residual matrix (unexplained variations). A key advantage of the PMF is its non-negative constraint [15–17].

For instance, a PMF-based study in Sofia, Bulgaria (2019–2020) identified major contributors to PM₁₀ emissions, including resuspended dust (25%), biomass burning (23%), and new sources, such as mixed sulfate [18]. Similarly, in Nelson, New Zealand, PMF analysis identified seven distinct sources of PM₁₀, emphasizing biomass burning (35%) and unpaved road traffic [18,19].

Precision in detecting and identifying the sources of PM is essential for the effective control of air pollution. However, it is a challenging to identify industrial and

port regions with multiple PM emission sources. In such environments, industries often face difficulties in demonstrating compliance with air quality regulations, because PM dispersion makes it difficult to determine whether a specific facility is responsible for excessive pollution levels. Moreover, in port regions, for instance, the port authority may face planning challenges related to PM emissions, especially when neighboring ports that do not fall under their jurisdiction contribute to local air pollution. This situation complicates environmental management, making it difficult to assess responsibility and implement effective mitigation strategies within the regulated area [20–22].

To address this challenge, we propose a model for PM emission source identification that integrates computational fluid dynamics (CFD) and artificial neural networks (ANNs). Although previous studies have investigated PM concentration prediction using Artificial Neural Network (ANN) models, PM emission localization methods have not yet been developed, to the best of the authors' knowledge. These results enhance traditional approaches by predicting PM concentrations and identifying precise emission locations.

By applying this CFD-ANN integration, the model can dynamically track PM dispersion patterns and determine whether emissions originate from a specific zone. Finally, this study contributes to environmental technology by providing a novel data-driven approach to PM source identification, supporting regulatory enforcement, industrial transparency, and public health initiatives.

2. Materials and methods

This study employed three steps: (i) numerical validation of the particulate matter (PM) distribution and atmospheric profile, (ii) CFD PM dispersion modeling and simulation for the dataset, and (iii) post-processing of the acquired dataset and Artificial Neural Network (ANN) emission area prediction network.

2.1. Numerical validation of the PM distribution and atmospheric profile

Particulate matter distribution was compared with experimental investigation performed by Lu et al. [23]. The wind profile was modeled based on the Monin-Obukhov Similarity Theory [24–26].

2.1.1. Experiment of PM distribution in two-zone environmental chamber

The experimental setup developed by Lu et al. [23] consisted of a two-zone environmental chamber with interzonal openings, one wind inlet, and one exhaust, as




Figure 1. Schematic of the two-zone environmental chamber featuring interzonal openings: one wind inlet, and one exhaust outlet. (a) Configuration of the experimental setup (b) Computational representation in a CFD VLES code at $t = 0$.

shown in Figure 1(a). Two experimental cases are selected for this study. The corresponding parameters are detailed as follows: chamber with dimensions of $L = 5$ m in length, $W = 3$ m in width and $H = 5$ m in height. The interzonal openings were $w_0 = 0.7$ m in length and $h_0 = 0.2$ m in height. At the start of the experiment, particulate matter (PM) with a density of 865 kg/m^3 and sizes ranging from 1 to $5 \mu\text{m}$ were introduced into Zone 1. To ensure uniform concentration within Zone 1, a mixing fan was initially operated. Once homogeneity was achieved, the diffusers and interzonal openings were opened, and the supply fan was activated to begin the ventilation process [23]. The total particle mass injected into zone 1 were 158 and 104.6 mg for case 01 and case 02, respectively. The ventilation rate was 11.484 h^{-1} for case 01 and 14.004 h^{-1} for case 02 [23].

The numerical modeling was developed using a CFD LES code, as shown in Figure 1(b), considering the following boundary condition: air supply with Dirichlet, exhauster with Neumann, and walls as the no-slip condition. Lagrangian particles were modeled with spherical geometry, and the drag coefficient (C_d) was defined as a function of the local Reynolds number (Re_D), calculated based on the particle diameter, as follows [27]:

$$C_d = \begin{cases} 24 / Re_D & Re_D < 1 \\ 24(0.85 + 0.15Re_D^{0.687}) / Re_D & 1 < Re_D < 1000 \\ 0.44 & 1000 < Re_D \end{cases} \quad (1)$$

$$Re_D = \frac{\rho |u_p - u| 2r_p}{\mu(T)} \quad (2)$$

where ρ is the fluid density, u_p is the particle velocity vector, u is the fluid velocity vector, r_p is the particle

radius, and $\mu(T)$ the dynamic viscosity of air at temperature [27].

The turbulence dispersion model for massive particles was activated [28]. In this model, the fluid velocity used in the drag force calculation was enhanced with an isotropic velocity fluctuation obtained from an estimate of the subgrid kinetic energy [28].

A very large eddy simulation (VLES) turbulent model was used, which is a hybrid approach that balances the computational efficiency of RANS with the scale-resolving capability of LES. To model the sub-grid scale turbulence, the Eddy Viscosity Model proposed by Deardorff [24] was applied, using a constant coefficient of Deardorff, $C_{deardorff} = 0.1$. This choice is well-suited for capturing large-scale turbulence dynamics while accounting for unresolved small-scale motions [29]. The pressure field was solved using a fast Fourier Transform (FFT)-based solver. This method transforms the pressure Poisson equation into the spectral space, significantly improving the computational efficiency, particularly for structured grids [30,31].

The total PM mass data in these zones were recorded and compared with the results of Lu et al. [23].

2.1.2. Atmospheric profile in a flat surface

The near-surface atmospheric boundary layer ($z < 250$ m) and microscale region (x and/or $y < 1$ km) were analyzed to model atmospheric dynamics over a flat surface under several stability conditions. The variation in wind velocity (u) with height (z) was specified in the inlet boundary conditions, based on the well-established principle that the average wind velocity increases logarithmically with height, starting from zero at the ground surface ($u = 0$).

Table 1. Atmospheric stability conditions considering Monin-Obukhov length parameter L .

Atmospheric Stability Class	$L(m)$ range	$L(m)$ used
Very unstable	$-200 \leq L < 0$	-100
Neutral	$L > 200$	10^6
Very stable	$0 \leq L < 200$	100

Atmospheric stability was compared with the Monin-Obukhov similarity (MOS) theory. MOS theory states that the wind velocity profile in the SBL is expressed by Equation (3):

$$u(z) = \frac{u_*}{\kappa} \left[\ln\left(\frac{z}{z_0}\right) - \phi_m\left(\frac{z}{L}\right) \right] \quad (3)$$


where u_* is the friction velocity, which is calculated from $u_* = \frac{\kappa u_{ref}}{\ln(z_{ref}/z_0)}$; $\kappa = 0.41$ is the Von Kármán constant, z_0 is the surface roughness length, where the value of 0.03 m was chosen considering the Davenport-Wieringa roughness length classification for the case grass prairie and farm fields; $u_{ref} = 6$ m and $z_{ref} = 4$ m are the reference height, where the wind velocity has been measured considering an arbitrary meteorological system [26,32]; L is the Monin-Obukhov length, which describes the atmospheric stability condition. A set of values for L was selected (see Table 1 further details). Finally, Equation 4 defines $\phi_m(\frac{z}{L})$ as the similarity function for the momentum flux.

$$\phi_m\left(\frac{z}{L}\right) = \begin{cases} -5\frac{z}{L}, & \text{for } L \geq 0 \\ 2 \ln(1 + \zeta^2) + 1 + \zeta^2 & \zeta = 1 - 16\frac{z^{1/4}}{L} \\ -2 \tan^{-1}(\zeta) + 2, & \text{for } L < 0 \end{cases} \quad (4)$$

2.2. CFD PM dispersion modeling and simulation for database development

2.2.1. General CFD modeling

A 3-D computational domain consisted of an open field and a flat surface with dimensions of 500 m in the x -direction, 610 m in the y -direction, and 50 m in the z -direction, as illustrated in Figure 2. Three emission sources were defined at a distance of $x_1 = 10$ m from the wind inlet and at an emission height h above the ground. The distances between the emission sources were denoted as $y_1 = 10$ m, $y_2 = 10$ m, $y_3 = 10$ m, and $y_4 = 10$ m. A particulate matter (PM) monitoring zone was established to capture PM concentration profiles over time. Atmospheric dynamics and PM dispersion were modeled and simulated within this

**Figure 2.** Particle dispersion scenario implemented in Computational Fluid Dynamics.

domain. In summary, the inlet boundary condition was defined based on the Monin-Obukhov similarity theory by applying a Dirichlet condition for velocity, temperature, and turbulence parameters. A solid wall was specified to represent the ground, thus enforcing a no-slip condition. The remaining boundaries were treated as open, with a Neumann zero-gradient condition applied to allow flow to exit freely. A structured mesh comprising quadrilateral elements with a uniform size 0.1 m to solve the conservation equations using a finite difference method.

The numerical experiments were conducted in a High-Performance Computing (HPC) environment using a Dell EMC PowerEdge R6515 server. This server is configured with two AMD EPYC 7282 processors, providing 32 cores, and is equipped with 64GB of memory. A typical simulation required approximately three days to solve 400 s of simulation time.

2.2.2. PM dispersion scenarios

The particulate matter dispersion scenarios described in Figure 2 involved a combination of three wind directions (northwest – NW, north – N and northeast – NE), three wind velocities (2.5, 4.0 and 6.0 m/s), three emission heights (10, 15 and 20 m), and three emission intervals (0.1, 0.2, and 0.5 s) originating from three distinct emission locations (E1, E2, and E3) as described in Table 2.

Table 2. Particle emission locations, emission intervals and height, wind directions and velocities considered in the CFD simulations.

	Emission location		Emission height (h) – z(m)	Wind Direction	Wind Velocity (m/s)	Emission interval (s)
	x(m)	y(m)				
E1	100.25	204.2	10, 15, 20	NW, N, NE	2.5, 4.0, 6.0	0.1, 0.2, 0.5
E2	100.25	306.2				
E3	100.25	408.2				

The dataset encompassed 243 CFD simulations. For some of these variables, historical data from the city of São Luis, Maranhão, were used as a guide, as the city faces challenges related to particulate matter emissions during the unloading of minerals and grains owing to its intense port activity [2].

During the time of 400 s of transient simulation, Lagrangean particles with aerodynamic diameters distribution between 2.5 and 10 μm were emitted. Hence, the size distribution model of Rosin-Rammler-Lognormal was used [33–35]. It integrates the features of both the Rosin-Rammler and lognormal distributions to describe particle size distributions.

2.3. ANN-based method for identifying PM emission areas

2.3.1. Data pre-processing

The database comprised 243 simulated scenarios for three possible output classifications (three possible PM emission locations). Six variables were initially considered: numerical (wind speed, emission height, emission interval, and PM concentration from monitoring points) and categorical features (wind direction and emission source). However, for the development of the time-series based ANN models, Long Short-Term Memory (LSTM) and Convolutional Neural Network (CNN1D), only numerical PM concentration data were used as inputs. These were standardized using z-score normalization (mean = 0, std = 1). Categorical variables were used as labels (emission sources) or were excluded from the input features. The database was randomly split into training and test subsets of 80% and 20%, respectively.

2.3.2. Development of an RNA classification model

Two deep learning architectures were implemented: LSTM and CNN1D. They were created using Python version 3.7.7 and the specialized libraries TensorFlow 1.14.0 and Keras 2.3.1.

As shown in Table 3, both models received inputs structured as a matrix of $30 \times N$ sensors, where N corresponds to the number of temporal steps (for LSTM) or sliding windows (for CNN1D). The LSTM architecture consisted of an LSTM layer with 64 units followed by a dropout layer with a rate of 0.2 to prevent overfitting. For the CNN1D model, a single convolutional layer with 64 filters and a kernel size of three was used, followed by batch normalization to stabilize the learning process. The categorical cross-entropy loss function was applied in both models because of the multi-class classification task. The Adam optimizer was used for training, with different learning rate configurations. For the LSTM model, a fixed learning rate of 0.001 was

Table 3. Hyperparameter configuration for LSTM and CNN1D models.

Hyperparameters	LSTM	CNN1D
Input	$30 \times N$ (temporal steps)	$30 \times N$ (sliding windows)
Architecture	LSTM(64) – Dropout(0.2)	CNN1D(64) – BatchNorm
Loss function	categorical cross-entropy	categorical cross-entropy
Optimization	Adam (learn rate = 0.001)	Adam (learn rate = 0.0001, 0.001, 0.01)
Epochs	30–100 (EarlyStopping)	30–100 (EarlyStopping)
Validation	Val Loss ($k = 5$)	Val Loss ($k = 5$)

adopted, while for the CNN1D model, a learning rate search was performed within the set 0.0001, 0.001, 0.01. Batch sizes of 16, 32, and 64 were tested to assess their impact on the training dynamics and generalization. For the CNN1D model, the early stopping criterion was *val_loss*, with a patience of five epochs. The difference lies in the activation of the *verbose = 1* parameter, which prints messages to the console whenever EarlyStopping updates its state, making it easier to monitor training progress. EarlyStopping monitored *val_loss*, stopped training after five epochs without improvement, and restores the best weights. The LSTM model uses the identical CNN1D configuration to determine the likelihood of each PM emission location. The additional details are provided in Table 3.

Three main stages were proposed for identifying PM emission areas using ANN prediction. In the first stage, the geometry is defined, and CFD simulations are performed, supplemented by data from monitoring points (PM). In the second stage, the data were normalized, and categorical variables was encoded, formatted, and divided into training, validation, and test sets. In the final stage, ANN hyperparameters were defined, models were trained and validated, and the best-performing model was selected based on its performance.

3. Results and discussion

First, we discuss the validation process, which includes the particle distribution and the atmospheric profile. Second, we addressed particle dispersion and how its concentration profile was associated with emission location. In the third part, the prediction of the PM emission location results using LSTM and CNN-1D are presented.

3.1. PM distribution and atmospheric profile evaluation

Figure 3 presents the computational results of the suspended and migrated particle masses in a two-zone

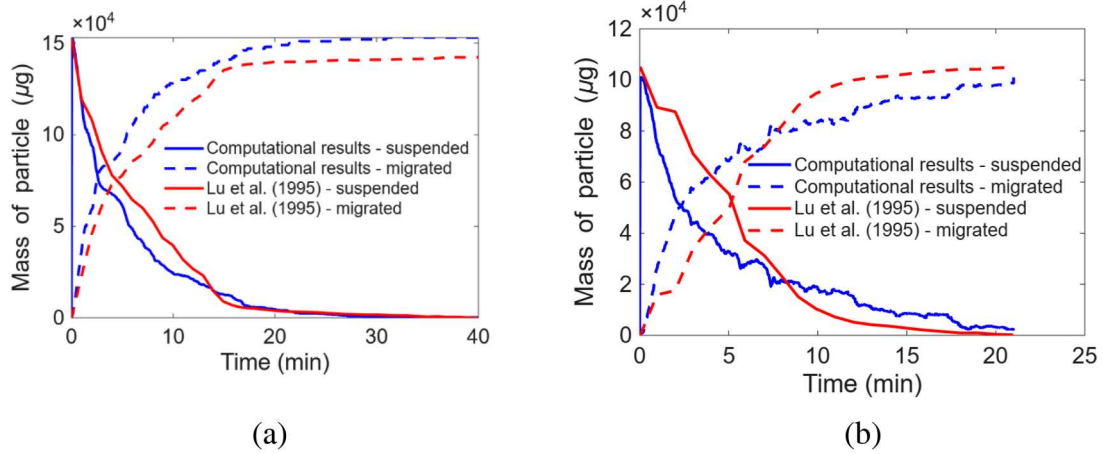


Figure 3. Comparison of the suspended and migrated mass particle in two-zone chamber. (a) Case 01. (b) Case 02.

chamber for Cases 01 and 02, which were originally studied by Lu et al. [23]. The computational results exhibited a behavior very similar to the findings reported by Lu et al. [23], showing a continuous and nonlinear decay in the mass of suspended particles over time. At the initial stages, the decline is steep, indicating a rapid removal of particles from Zone 1 of the chamber. As time progresses, the rate of decrease slows, approaching asymptotic behavior. This trend suggests a typical particle transport process governed by turbulent dispersion [23,27], where the majority of particles migrate from Zone 1 to Zone 2 during the early stages.

The atmospheric profile was also evaluated, and simulations were conducted using CFD software without any particle emissions, considering stability conditions such as neutral, very stable, and very unstable. A comparison between the CFD results and the Monin-Obukhov Similarity (MOS) model is shown in Figure 4. These results confirm that the inlet, outlet, and ground boundary conditions were properly defined. In addition, the atmospheric profile along the computational domain remained stable and appropriate for dispersion analysis.

3.2. PM dispersion modeling and simulation

Here, we address particle dispersion and how its concentration profile is associated with the emission location.

First, given that particles with diameters ranging from 2.5 to 10 μm pose significant risks to human health, their size distribution was thoroughly analyzed [3]. Figure 5 shows the Probability Distribution Function (PDF) of the particle diameters and particle velocities at the time of emission. The analysis of Figure 5(a) indicates that the emission source released particles with diameters uniformly distributed between 2.5–10 μm . This size range confirms the presence of both fine and coarse particulate matter, which can have distinct transport behaviors,

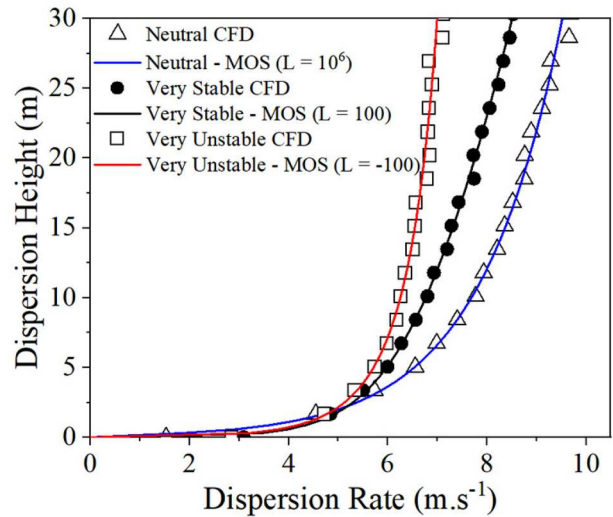


Figure 4. Atmospheric profiles computed from LES CFD formulation and Monin-Obukhov Similarity (MOS) model for very stable, neutral, and very unstable atmospheric profiles.

residence times, and deposition within the domain. Additionally, in Figure 5(b), the observed velocity distribution, ranging from 6 to 7 m/s, reinforces these differences, as particle size directly influences the dispersion patterns under the given flow conditions.

To enhance predictive accuracy under complex emission scenarios, a database obtained from 243 atmospheric particulate matter (PM) dispersion simulations using Computational Fluid Dynamics (CFD) was constructed to reflect a wide range of emission conditions. This dataset was used to train an Artificial Neural Network (ANN), aiming to develop a predictive model capable of estimating the likely locations of particulate emission sources. One of these scenarios is presented in Figure 6, wherein PM ranging in size from 2.5–10 μm is emitted from the emission location (E2), with an emission interval of 0.1, and a wind direction of

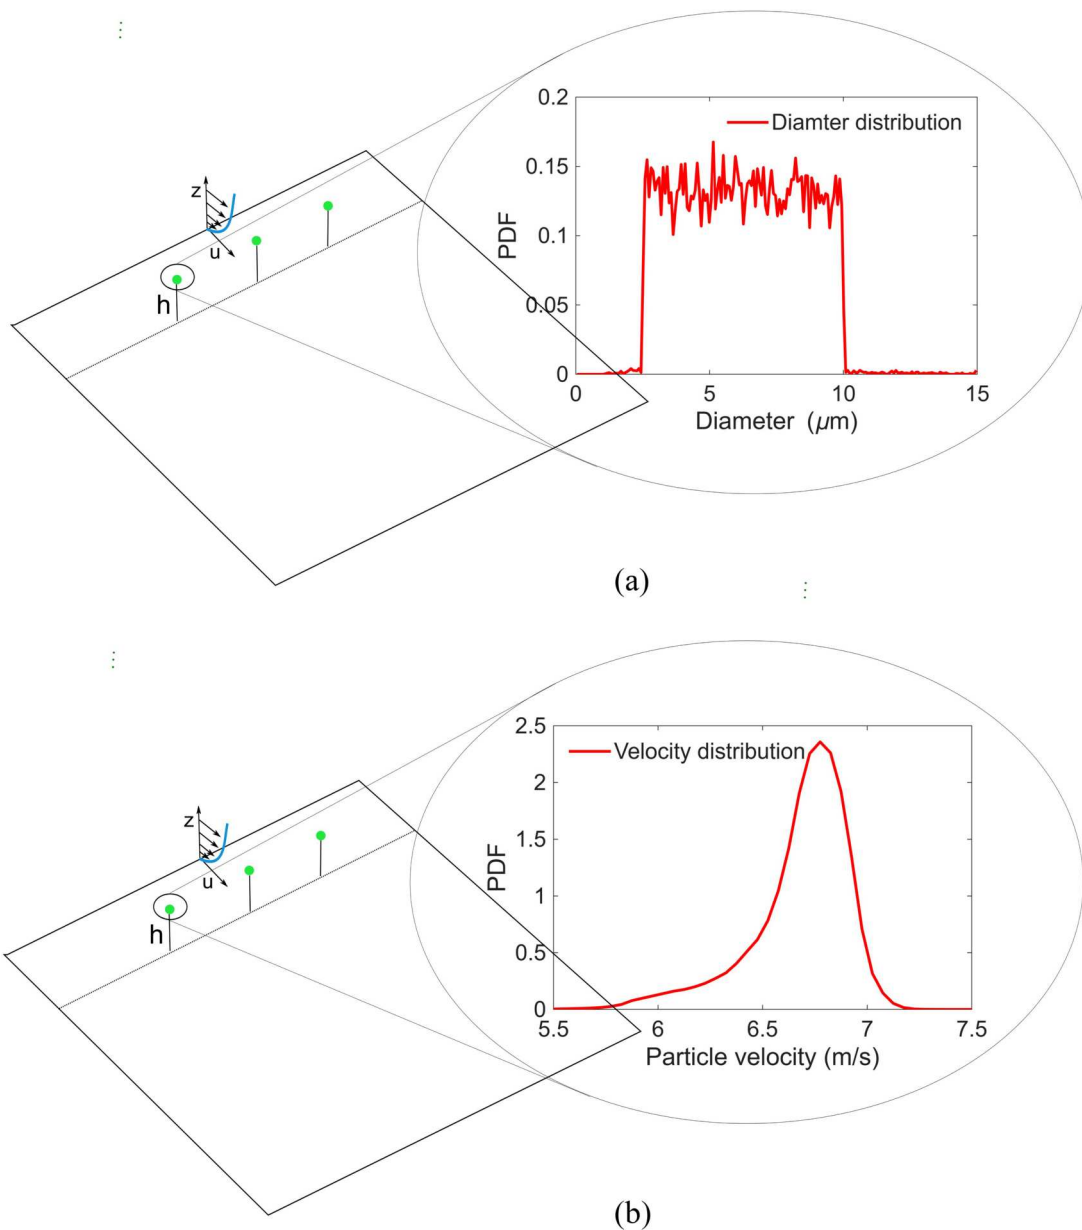


Figure 5. Probability distribution function (PDF) of the particle diameters (a) and particle velocity (b) at the time of emission.

225° (southwest). The PM dispersion followed the wind direction towards the monitoring point location MP3, located at $[x, y, z] = [349, 549, 19.5]$. All the monitoring points (MP) are presented in Appendix A.

Figure 7 illustrates the PM concentration over time for three different wind velocities (6, 4 and 2.5 m/s) under increasing emission heights of 10, 15 and 20 m. The analysis of Figure 7(a) shows that for the lower emission height, and any wind velocity PM has not reached MP3 owing to insufficient turbulent dispersion. As in Figure 7(b), at a height of 15 m, it is observed that higher wind speeds (4 and 6 m/s) transport PM to reach MP3. A wind velocity of 6 m/s disperse the particles faster and is captured by the PM at approximately 200 s. A

wind velocity of 2.5 m/s still shows very low transport at this height (15 m), indicating that both height and wind speed significantly impact dispersion. An emission height of 20 m enhances turbulent dispersion and facilitates PM transport, particularly under lower wind velocity condition (2.5 m/s), which now begin to register concentrations, as shown in Figure 7(c). High wind velocities, such as 6 and 4 m/s, lead to faster PM transport, with MP3 registering PM of approximately 60 s and approximately 100 s, respectively.

Figure 8 illustrates the PM concentration profiles for three different emission intervals (0.1, 0.2 and 0.5 s) under a fixed atmospheric condition (northeast wind direction, 6 m/s wind speed, and 20 m emission

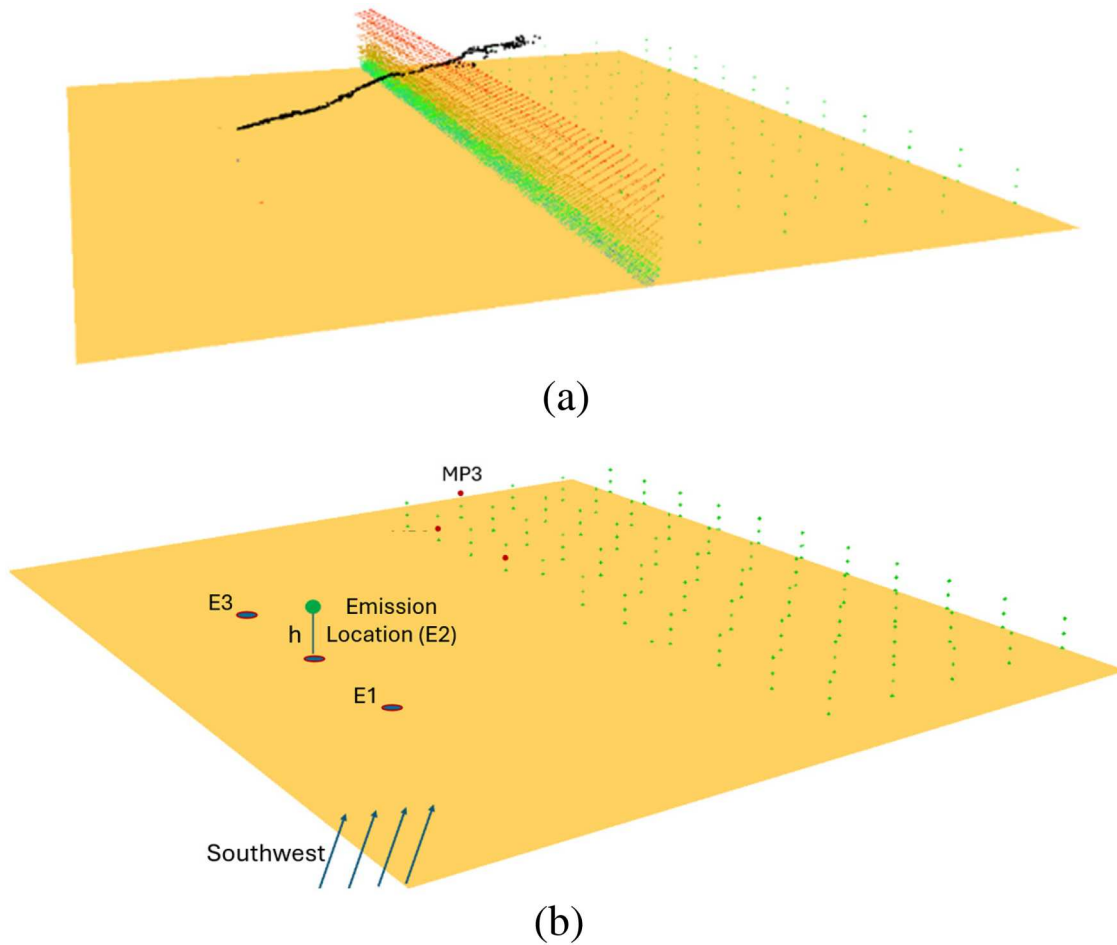


Figure 6. PM dispersion scenario considering 2.5–10 micrometers emitted from the emission area (E1), with an emission interval of 0.1, a wind velocity of 6 m/s, a wind direction of 225° (southwest), and an emission height of 20 m.

height). The analysis in Figure 8 reveals that the overall PM concentration patterns were similar across the three emission intervals, with comparable peak intensities and temporal distributions. This suggests that within the evaluated range, the emission interval did not significantly influence PM dispersion behavior.

With this information, the LSTM and CNN1D have the potential to precisely detect the origin of particulate emissions. The following section presents an LSTM-RNN and CNN1D approach that considers data acquisition time intervals to identify particulate locations from accidental emissions.

3.3. LSTM and CNN1D for PM emission location prediction

Figure 9 shows the training and validation loss curves of the LSTM and CNN1D models, using categorical cross-entropy as the loss function. The LSTM model was trained for 19 epochs whereas CNN1D for 16 epochs triggered early stopping. The optimized parameters corresponded to those obtained at the local minimum

found at epoch 12 for LSTM and epoch 9 for the CNN1D models, with loss function values at 0.095 and 0.089, respectively. Early stopping avoids model overfitting, ensures better generalization properties, and reduces the processing time. The time required to obtain optimized LSTM hyperparameters using the Grid Search method was approximately 4 h 15 min whereas for CNN1D was approximately 4 h 43 min.

Table 4 summarizes the performance of both the LSTM and CNN1D models for predicting particulate matter (PM) emission locations (E1, E2, and E3). Excellent and comparable overall performance was observed for the LSTM and CNN1D models across the accuracy, recall, and F1-score. For emission location E1, both the LSTM and CNN1D models achieved high performance, with a precision of 0.89, recall of 1.00, and F1-score of 0.94, indicating that all E1 data were correctly identified, with a few false positives. For emission location E2, the models reached perfect scores (1.00 in all metrics), indicating that this source was classified with complete accuracy. For emission source E3, both models had perfect precision (1.00), but slightly lower recall (0.86),

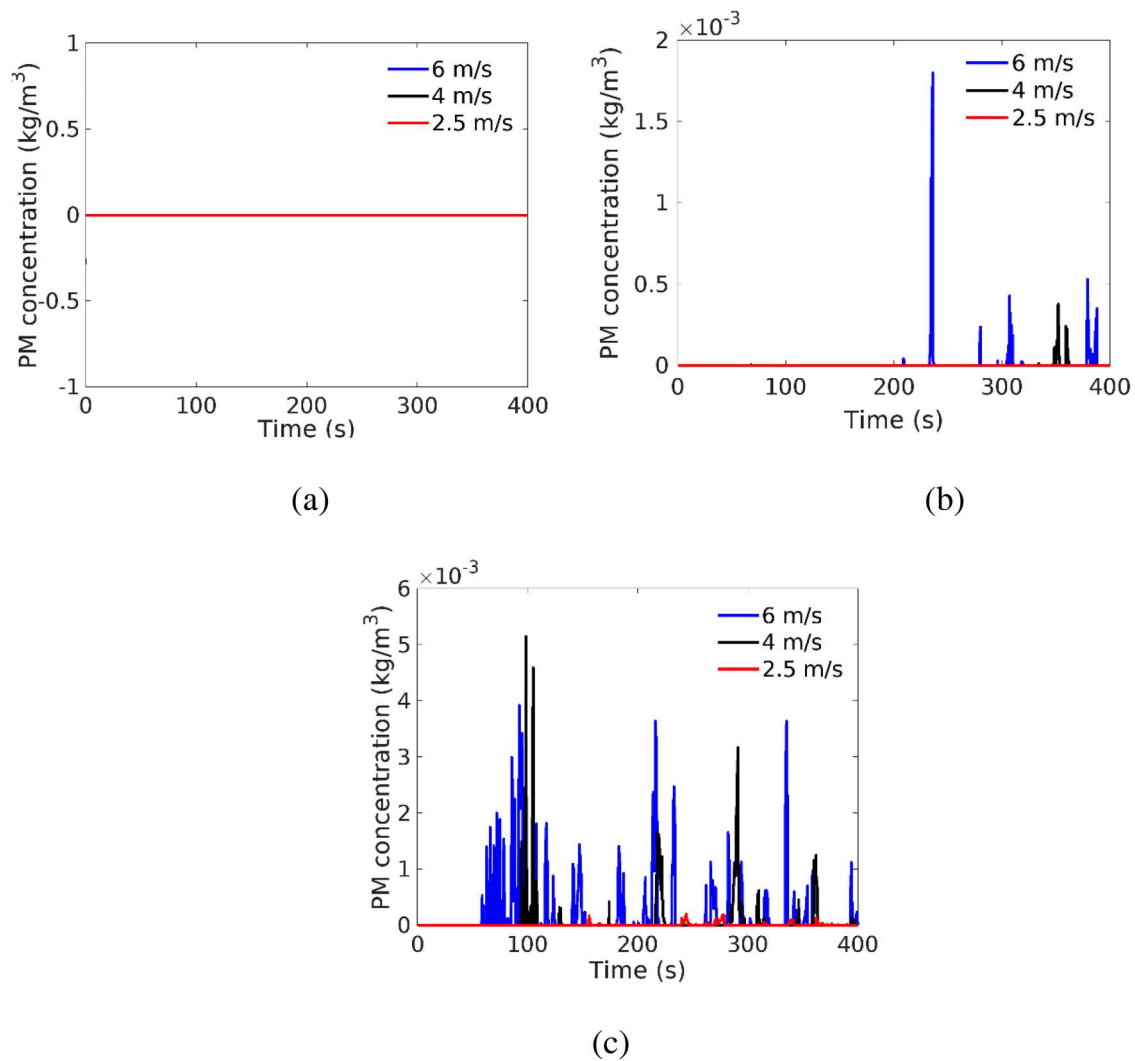


Figure 7. PM concentration profile at different velocities, monitored by MP3, for: (a) Emission height of 10 m (b) Emission height of 15 m and (c) Emission height of 20 m.

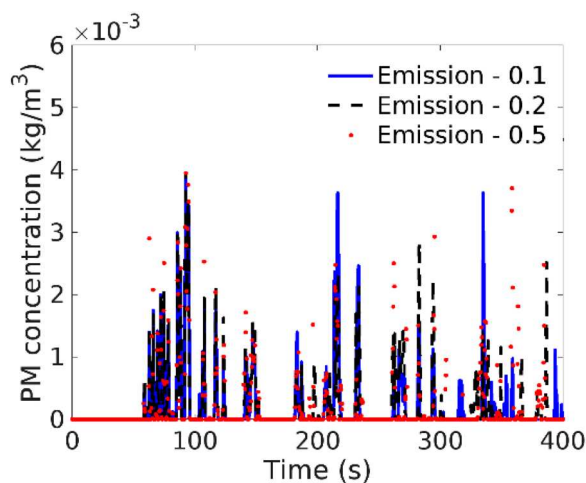


Figure 8. PM concentration profile at three different emission rates, 0.1s, 0.2 s and 0.5s under a fixed scenario of northeast wind direction, 6 m/s wind velocity, and 20 m emission height.

resulting in an F1-score of 0.93, which suggests that false negatives are present.

Figure 10 shows the confusion matrix where the rows represent the actual emission locations, and the columns correspond to the predicted emission location categories (E1, E2 and E3). The diagonals of the confusion matrix indicate the likelihood of correct predictions. Figure 10(a and b) show the test dataset results for LSTM and CNN1D models, respectively. The findings indicate that both models (LSTM and CNN1D) accurately predicted the emission locations E1 and E2 with 100% certainty. For emission location E3, the CNN1D model predicted it with 86.4% confidence, with a 13.6% probability of misclassification as E1. The LSTM model predicted E3 with 84.6% confidence, with misclassification probabilities of 14.9% for E1 and 0.4% for E2.

These misclassifications may be due to the similar concentration data profiles monitored by the sensors.

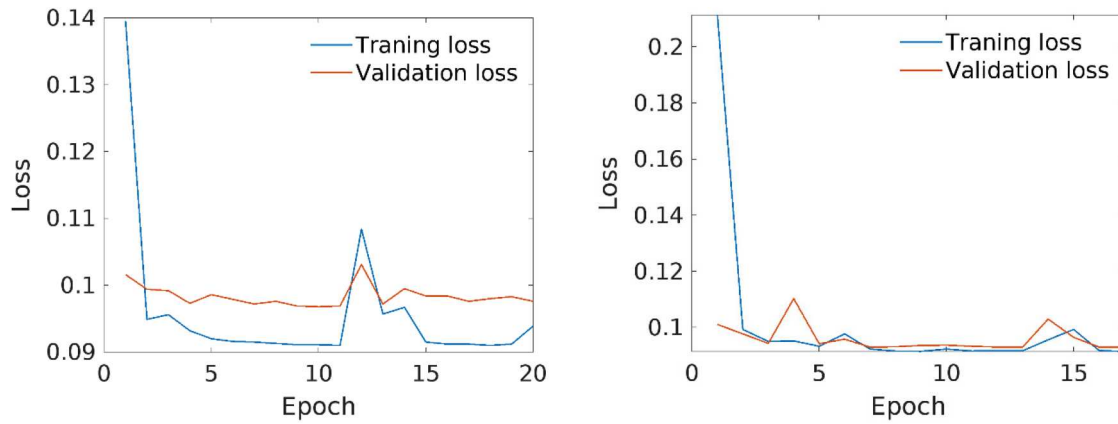


Figure 9. ANN models during training process. (a) LSTM e (b) CNN1D.

Table 4. Quantitative performance criteria for particulate matter (PM) emission location.

Emission Source	Test data for LSTM			Test data for CNN1D		
	Precision	Recall	f1-score	Precision	Recall	f1-score
E1	0.89	1.00	0.94	0.89	1.00	0.94
E2	1.00	1.00	1.00	1.00	1.00	1.00
E3	1.00	0.86	0.93	1.00	0.86	0.93
Overall	0.963	0.954	0.956	0.964	0.954	0.956

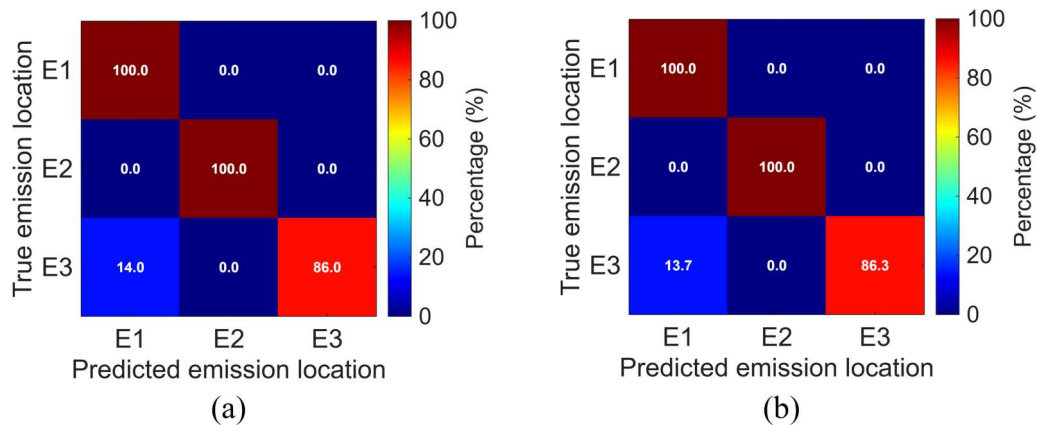


Figure 10. Confusion matrix for test dataset. (a) LSTM model (b) CNN1D model.

As long as emission locations E1 and E3 are quite distant, their positions are symmetric in relation to the E2 emission location. Particulate matter (PM) emitted from E1 and E3 may produce similar concentration profiles when northwesterly winds disperse emissions from E1 and northeasterly winds disperse PM emissions from E3, potentially leading to misclassification. Even so, both ANN models could be predicted with high accuracy.

4. Conclusions

Long Short-Term Memory (LSTM) and 1D Convolutional Neural Network (CNN1D) were trained and tested to

identify particulate matter (PM) emission locations in a flat terrain. The input variables considered for the RNN models were wind velocity, wind direction, PM emission interval and emission height. PM concentrations were also used to train prediction models. The dataset was generated using CFD simulations.

Numerical findings showed that wind speed and emission height have a strong impact on particulate matter (PM) concentrations. A lower emission height (10 m) resulted in limited PM dispersion regardless of wind velocity, whereas higher emission heights (15 and 20 m) combined with increased wind velocities (4–6 m/s) substantially enhanced turbulent dispersion and accelerated PM transport.

On the another hand, the emission interval within the tested range (0.1s–0.5 s) has a minimal impact on PM dispersion, exhibiting similar temporal PM distributions and peak intensities.

Both the LSTM and CNN1D models achieved excellent and comparable performance in identifying PM emission sources, with high accuracy across all classes. The hyperparameter optimization using the Grid Search method required a comparable computational effort for both models, with LSTM taking approximately 4 h 15 min and CNN1D taking approximately 4 h 43 min. Early stopping ensures optimal training and reduces overfitting. The confusion matrix confirmed 100% correct predictions for E1 and E2, with only minor confusion between E1 and E3 owing to similar concentration patterns influenced by wind direction and spatial symmetry.

The present study demonstrates that it is possible to accurately identify the location of particulate matter (PM) emissions. However, real-time PM emission location identification in a real industrial environment requires a substantial dataset that accurately represents the specific geometry and meteorological conditions of the facility or port area, which requires considerable investment and effort. Additionally, monitoring sensors must be strategically positioned and operated online to capture the PM concentrations as quickly and accurately as possible.

Acknowledgements

We are thankful for financial support from the Brazilian Space Agency (AEB) through the Global Learning and Observation to Benefit the Environment (Globe) Program. In addition, we thank CENAPAD-SP, which provided computational resources.

Disclosure statement

No potential conflict of interest was reported by the author(s).

Funding

This work was funded by the Brazilian Space Agency through a Decentralized Execution Transfer (TED), TED number [grant number 00424320240006-002573]. The funding agency supported both the execution of the project and the preparation of this article; Agência Espacial Brasileira.

Data availability statement

Raw data were generated at the high-performance computer center. The data supporting the findings of this study are available from the corresponding author E. S. Ferreira Jr. on request.

ORCID


Lanna Almeida Pereira  <http://orcid.org/0009-0007-0083-1380>

Hilton Costa Louzeiro  <https://orcid.org/0000-0003-1567-8183>

Harvey Alexander Villa-Vélez  <https://orcid.org/0000-0003-2394-4939>

Aline Bessa Veloso  <https://orcid.org/0000-0003-2329-2993>

Alex Oliveira Barradas Filho  <https://orcid.org/0000-0002-4134-7129>

Mikele Candida Sousa de Sant Anna  <https://orcid.org/0000-0002-9023-0154>

Elmo de Sena Ferreira Júnior  <https://orcid.org/0000-0003-4769-4698>

References

- [1] Sorte S, Rodrigues V, Borrego C, et al. Impact of harbour activities on local air quality: a review. *Environ Pollut.* 2020;257:113542. doi:10.1016/j.envpol.2019.113542
- [2] Pinheiro JM, Venturi LAB, Galvani E. Atmospheric pollution: a case study of the municipality of São Luís do Maranhão. *Soc Nat.* 2020;32:808–819. doi:10.14393/SN-v32-2020-56162
- [3] World Health Organization. WHO global air quality guidelines: particulate matter (PM2.5, PM10), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide. Geneva: World Health Organization; 2021; Available from: <https://www.who.int/publications/i/item/9789240034228>.
- [4] Leão MLP, Zhang L, Silva Júnior FMR. Effect of particulate matter (PM2.5 and PM10) on health indicators: climate change scenarios in a Brazilian metropolis. *Environ Geochem Health.* 2023;45:2229–2240. doi:10.1007/s10653-022-01331-8
- [5] Rajagopalan S, Brook RD, Salerno PRVO, et al. Air pollution exposure and cardiometabolic risk. *Lancet Diabetes Endocrinol.* 2024;12(3):196–208. doi:10.1016/S2213-8587(23)00361-3
- [6] O'Connor S, O'Connor PF, Feng HA, et al. Gravimetric analysis of particulate matter using air samplers housing internal filtration capsules. *Gefahrst Reinhalt Luft.* 2014;74(10):403–410.
- [7] Zhang J, Zhang Z, Hou L, et al. A novel optical instrument for measuring mass concentration and particle size in real time. *Sensors.* 2023;23(7):3616. doi:10.3390/s23073616
- [8] Crnosija N, Levy Zamora M, Rule AM, et al. Laboratory chamber evaluation of flow air quality sensor PM2.5 and PM10 measurements. *Int J Environ Res Public Health.* 2022;19(12):7340. doi:10.3390/ijerph19127340
- [9] Iftikhar H, Qureshi M, Zywołek J, et al. Short-term PM2.5 forecasting using a unique ensemble technique for proactive environmental management initiatives. *Front Environ Sci.* 2024;12:1442644. doi:10.3389/fenvs.2024.1442644
- [10] Zhou S, Wang W, Zhu L, et al. Deep-learning architecture for PM2.5 concentration prediction: a review. *Environ Sci Ecotechnol.* 2024;21:100400. doi:10.1016/j.ese.2024.100400
- [11] Mohammadi F, Teiri H, Hajizadeh Y. Prediction of atmospheric PM2.5 level by machine learning techniques in

- Isfahan: Iran. *Sci Rep.* 2024;14:2109. doi:10.1038/s41598-024-52617-z
- [12] Alsaber A, Alsahli R, Al-Sultan A, et al. Evaluation of various machine learning prediction methods for particulate matter PM₁₀ in Kuwait. *Int J Inf Technol.* 2023;15(8):4505–4519. doi:10.1007/s41870-023-01521-2
- [13] Ho W, Tseng K, Liou M, et al. Application of positive matrix factorization in the identification of the sources of PM_{2.5} in Taipei city. *Int J Environ Res Public Health.* 2018;15(7):1305. doi:10.3390/ijerph15071305
- [14] Dutton S, Vedal S, Piedrahita R, et al. Source apportionment using positive matrix factorization on daily measurements of inorganic and organic speciated PM_{2.5}. *Atmos Environ.* 2010;44(23):2731–2741. doi:10.1016/j.atmosenv.2010.04.038
- [15] Srivastava D, Xu J, Vu T, et al. Insight into PM_{2.5} sources by applying positive matrix factorization (PMF) at urban and rural sites of Beijing. *Atmos Chem Phys.* 2021;21:14703–14724. doi:10.5194/acp-21-14703-2021
- [16] Wang Q, Zhu S, Wang S, et al. Short-term source apportionment of fine particulate matter with time-dependent profiles using SOFI Pro: exploring the reliability of rolling positive matrix factorization (PMF). *Atmos Chem Phys.* 2024;24:475–486. doi:10.5194/acp-24-475-2024
- [17] Paatero P, Tapper U. Positive matrix factorization: a non-negative factor model with optimal utilization of error estimates of data values. *Environmetrics.* 1994;5:111–126. doi:10.1002/env.3170050203
- [18] Ancelet T, Davy PK, Trompette WJ, et al. Sources of particulate matter pollution in a small New Zealand city. *Atmos Pollut Res.* 2014;5(4):572–580. doi:10.5094/APR.2014.066
- [19] Hristova E, Veleva B, Georgieva E, et al. Application of positive matrix factorization receptor model for source identification of PM₁₀ in the city of Sofia, Bulgaria. *Atmosphere.* 2020;11(9):890. doi:10.3390/atmos11090890
- [20] Hong WY. Meteorological variability and predictive forecasting of atmospheric particulate pollution. *Sci Rep.* 2024;14(1):14. doi:10.1038/s41598-023-41906-8
- [21] Agarwal S, Sharma S, Rahman MH, et al. Air quality forecasting using artificial neural networks with real-time dynamic error correction in highly polluted regions. *Sci Total Environ.* 2020;735:139454. doi:10.1016/j.scitotenv.2020.139454
- [22] Enebish T, Chau K, Jadamba B, et al. Predicting ambient PM_{2.5} concentrations in Ulaanbaatar, Mongolia with machine learning approaches. *J Expo Sci Environ Epidemiol.* 2021;31(4):699–708. doi:10.1038/s41370-020-0257-8
- [23] Lu WZ, Howarth AT, Adams NM, et al. CFD modeling and measurement of aerosol particle distributions in ventilated multizone rooms. *ASHRAE Trans Res.* 1999;105(2):116–127.
- [24] Deardorff JW. Three-dimensional numerical study of the height and mean structure of a heated planetary boundary layer. *Boundary-Layer Meteorol.* 1974;7:81–106. doi:10.1007/BF00224974
- [25] Stull RB. *Meteorology for scientists and engineers.* 2nd ed. Pacific Grove (CA): Brooks/Cole; 2000.
- [26] Jacobson MZ. *Fundamentals of atmospheric modeling.* 2nd ed. Cambridge: Cambridge University Press; 2005. doi:10.1017/CBO9781139165389
- [27] Crowe C, Sommerfeld M, Tsuji Y. *Multiphase flows with droplets and particles.* Boca Raton (FL): CRC Press; 1998.
- [28] McGrattan K, McDermott R, Vanella M, et al. *Fire dynamics simulator – technical reference guide: volume 1: mathematical model.* 6th ed. Gaithersburg (MD): National Institute of Standards and Technology; 2024. (NIST Special Publication 1018-1). doi:10.6028/NIST.SP.1018
- [29] Deardorff JW. Stratocumulus-capped mixed layers derived from a three-dimensional model. *Boundary Layer Meteorol.* 1980;18:495–527. doi:10.1007/BF00119502
- [30] Caprace DG, Gillis T, Chatelain P. FLUPS: a Fourier-based library of unbounded poisson solvers. *SIAM J Sci Comput.* 2021;43(1):C31–C60. doi:10.1137/19M1303848
- [31] Gholami A, Malhotra D, Sundar H, et al. FMM, or multi-grid? A comparative study of state-of-the-art poisson solvers for uniform and nonuniform grids in the unit cube. *SIAM J Sci Comput.* 2016;38(3):C280–C306. doi:10.1137/15M1010798
- [32] McGrattan K, Hostikka S, Floyd J, et al. *Fire dynamics simulator – user’s guide.* 6th ed. Gaithersburg (MD): National Institute of Standards and Technology; 2024. (NIST Special Publication 1019). doi:10.6028/NIST.SP.1019
- [33] Chan TS. Measurements of water density and drop size distributions of selected ESFR sprinklers. *J Fire Prot Eng.* 1994;6(2):79–87. doi:10.1177/104239159400600202
- [34] Alderliesten M. Mean particle diameters. Part VII. The Rosin–Rammler size distribution: physical and mathematical properties and relationships to moment-ratio defined mean particle diameters. Part Part Syst Charact. 2013;30:244–257. doi:10.1002/ppsc.201200021
- [35] Colorado-Arango L, Menéndez-Aguado JM, Osorio-Correa A. Particle size distribution models for metallurgical coke grinding products. *Metals.* 2021;11(8):1288. doi:10.3390/met11081288

Appendix

APPENDIX A

Monitoring Points	x (m)	coordinates	
		y (m)	z (m)
MP1	300	50	0
MP2	300	100	0
MP3	300	150	0
MP4	300	200	0
MP5	300	250	0
MP6	300	300	0
MP7	300	350	0
MP8	300	400	0
MP9	300	450	0
MP10	300	500	0
MP11	300	550	0
MP12	350	50	0
MP13	350	100	0
MP14	350	150	0
MP15	350	200	0
MP16	350	250	0
MP17	350	300	0
MP18	350	350	0
MP19	350	400	0
MP20	350	450	0
MP21	350	500	0
MP22	350	550	0
MP23	400	50	0

(Continued)

Continued.

Monitoring Points	coordinates		
	x (m)	y (m)	z (m)
MP24	400	100	0
MP25	400	150	0
MP26	400	200	0
MP27	400	250	0
MP28	400	300	0
MP29	400	350	0
MP30	400	400	0
MP31	400	450	0
MP32	400	500	0
MP33	400	550	0
MP34	450	50	0
MP35	450	100	0
MP36	450	150	0
MP37	450	200	0
MP38	450	250	0
MP39	450	300	0
MP40	450	350	0
MP41	450	400	0
MP42	450	450	0
MP43	450	500	0
MP44	450	550	0
MP45	500	50	0
MP46	500	100	0
MP47	500	150	0
MP48	500	200	0
MP49	500	250	0
MP50	500	300	0
MP51	500	350	0
MP52	500	400	0
MP53	500	450	0
MP54	500	500	0
MP55	500	550	0
MP56	300	50	10
MP57	300	100	10
MP58	300	150	10
MP59	300	200	10
MP60	300	250	10
MP61	300	300	10
MP62	300	350	10
MP63	300	400	10
MP64	300	450	10
MP65	300	500	10
MP66	300	550	10
MP67	350	50	10
MP68	350	100	10
MP69	350	150	10
MP70	350	200	10
MP71	350	250	10
MP72	350	300	10
MP73	350	350	10
MP74	350	400	10
MP75	350	450	10
MP76	350	500	10
MP77	350	550	10
MP78	400	50	10
MP79	400	100	10
MP80	400	150	10
MP81	400	200	10
MP82	400	250	10
MP83	400	300	10
MP84	400	350	10
MP85	400	400	10
MP86	400	450	10
MP87	400	500	10
MP88	400	550	10
MP89	450	50	10
MP90	450	100	10
MP91	450	150	10
MP92	450	200	10
MP93	450	250	10

(Continued)

Continued.

Monitoring Points	coordinates		
	x (m)	y (m)	z (m)
MP94	450	300	10
MP95	450	350	10
MP96	450	400	10
MP97	450	450	10
MP98	450	500	10
MP99	450	550	10
MP100	500	50	10
MP101	500	100	10
MP102	500	150	10
MP103	500	200	10
MP104	500	250	10
MP105	500	300	10
MP106	500	350	10
MP107	500	400	10
MP108	500	450	10
MP109	500	500	10
MP110	500	550	10
MP111	300	50	20
MP112	300	100	20
MP113	300	150	20
MP114	300	200	20
MP115	300	250	20
MP116	300	300	20
MP117	300	350	20
MP118	300	400	20
MP119	300	450	20
MP120	300	500	20
MP121	300	550	20
MP122	350	50	20
MP123	350	100	20
MP124	350	150	20
MP125	350	200	20
MP126	350	250	20
MP127	350	300	20
MP128	350	350	20
MP129	350	400	20
MP130	350	450	20
MP131	350	500	20
MP132	350	550	20
MP133	400	50	20
MP134	400	100	20
MP135	400	150	20
MP136	400	200	20
MP137	400	250	20
MP138	400	300	20
MP139	400	350	20
MP140	400	400	20
MP141	400	450	20
MP142	400	500	20
MP143	400	550	20
MP144	450	50	20
MP145	450	100	20
MP146	450	150	20
MP147	450	200	20
MP148	450	250	20
MP149	450	300	20
MP150	450	350	20
MP151	450	400	20
MP152	450	450	20
MP153	450	500	20
MP154	450	550	20
MP155	500	50	20
MP156	500	100	20
MP157	500	150	20
MP158	500	200	20
MP159	500	250	20
MP160	500	300	20
MP161	500	350	20
MP162	500	400	20
MP163	500	450	20
MP164	500	500	20
MP165	500	550	20