

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS E TECNOLOGIAS PARA A SUSTENTABILIDADE
PROGRAMA DE PÓS-GRADUAÇÃO EM PLANEJAMENTO E USO DE RECURSOS
RENOVÁVEIS

Ana Carolina Godoy Albino

Avaliação de Modelos de Dispersão Atmosférica no Contexto de Avaliação de Impacto do
Ciclo de Vida no Brasil

Sorocaba

2024

Ana Carolina Godoy Albino

Avaliação de Modelos de Dispersão Atmosférica no Contexto de Avaliação de Impacto do
Ciclo de Vida no Brasil

Dissertação apresentada ao programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis para obtenção do título de Mestre em Planejamento e Uso de Recursos Renováveis.

Orientador: Prof. Dr. Diogo Aparecido Lopes Silva

Coorientadora: Prof. Dra. Yara de Souza Tadano

Financiamento: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 88887.703365/2022-00

Sorocaba

2024

Albino, Ana Carolina Godoy

Avaliação de Modelos de Dispersão Atmosférica no Contexto de Avaliação de Impacto do Ciclo de Vida no Brasil / Ana Carolina Godoy Albino -- 2024.
152f.

Dissertação (Mestrado) - Universidade Federal de São Carlos, campus Sorocaba, Sorocaba
Orientador (a): Diogo Aparecido Lopes Silva
Banca Examinadora: Leila Droprinchinski Martins,
Virgínia Aparecida da Silva Moris
Bibliografia

1. Avaliação de Impacto de Ciclo de Vida (AICV). 2. Fatores de Caracterização. 3. Material Particulado. I. Albino, Ana Carolina Godoy. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática
(SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Maria Aparecida de Lourdes Mariano -
CRB/8 6979



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências e Tecnologias Para a Sustentabilidade
Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis

Folha de Aprovação

Defesa de Dissertação de Mestrado da candidata Ana Carolina Godoy Albino, realizada em 28/08/2024.

Comissão Julgadora:

Prof. Dr. Diogo Aparecido Lopes Silva (UFSCar)

Profa. Dra. Leila Droprinchinski Martins (UTFPR)

Profa. Dra. Virgínia Aparecida da Silva Moris (UFSCar)

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Planejamento e Uso de Recursos Renováveis.

AGRADECIMENTOS

Primeiramente, gostaria de expressar minha gratidão aos meus pais, Rosinei Godoy Leal Albino e Claudio Albino, que sempre me apoiaram incondicionalmente, me incentivando a seguir em frente mesmo diante dos maiores desafios. Seu amor e suporte ao longo dessa jornada foram fundamentais.

Ao meu digníssimo Bruno Gabriel Amaral da Silva, minha eterna fonte de apoio e coragem, que esteve ao meu lado em todos os momentos, me ajudando a superar cada obstáculo e acreditando em minha capacidade, mesmo quando eu duvidava de mim mesma. Sem você, essa conquista não seria possível.

Aos meus orientadores, Dr. Diogo Aparecido Lopes Silva e Dra. Yara de Souza Tadano, que com paciência, sabedoria e orientação me guiaram. Agradeço por todo o conhecimento compartilhado e por acreditarem no meu potencial.

Agradeço também às minhas colegas de profissão, Gabriela Giusti e Iara da Silva, que contribuíram de forma significativa para o desenvolvimento deste projeto. Vocês tornaram os desafios mais leves e a trajetória mais gratificante.

Ao Grupo EngS, ao qual tenho o privilégio de pertencer, que me proporcionou experiências acadêmicas e profissionais enriquecedoras durante esses dois anos de pós-graduação. A troca de conhecimentos e o companheirismo foram fundamentais para o meu crescimento.

Aos meus colegas de laboratório, que com suas presenças tornaram o processo de pesquisa mais leve e colaborativo. A amizade e a parceria de vocês foram essenciais para enfrentar os momentos mais difíceis.

Por fim, agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo financiamento (Código de Financiamento 88887.703365/2022-00) que tornou possível a realização deste trabalho.

RESUMO

A poluição atmosférica é um dos principais desafios ambientais e de saúde pública, com o Material Particulado ($MP_{2,5}$) sendo um dos poluentes mais críticos devido aos seus impactos adversos. Este estudo investigou a modelagem da concentração de $MP_{2,5}$ no Brasil, considerando as particularidades regionais, com o objetivo de aprimorar a Avaliação de Impacto do Ciclo de Vida (AICV). Diferentes modelos de dispersão de poluentes foram mapeados e o modelo InMAP foi selecionado para simular as concentrações de $MP_{2,5}$. Os inventários avaliados abrangeram cinco setores-chave: agricultura, indústria, transporte, queima de biomassa e emissões biogênicas. Para o setor agrícola, foi utilizado o inventário EDGAR, no setor industrial, foram considerados os inventários EDGAR, BRAIN e Rey (2023), o setor de transporte os inventários EDGAR e BRAVES. A queima de biomassa foi representada pelo inventário FINN, enquanto as emissões biogênicas o inventário MEGAN. A partir dessas fontes, seis conjuntos de dados (C_01 a C_06) foram formulados e aplicados no modelo InMAP, sendo posteriormente validados por meio da Raiz do Erro Quadrático Médio (RMSE) contra dados de concentração monitorada em 31 estações do estado de São Paulo. A análise revelou uma escassez significativa de dados específicos em setores-chave, como o agronegócio, evidenciando a necessidade urgente de desenvolver inventários de emissão mais detalhados no Brasil. O inventário BRAVES destacou-se por sua representatividade superior, sendo utilizado nas três melhores combinações de inventários utilizados, o que sugere sua adequação ao contexto brasileiro. As regiões sul e sudeste do Brasil, especialmente áreas urbanas como a região metropolitana de São Paulo, apresentaram as maiores concentrações de $MP_{2,5}$, refletindo a forte influência das emissões de transporte e industriais. Entre os seis conjuntos de inventários avaliados, o C_03 foi identificado como o mais robusto, esse conjunto combinou dados do EDGAR para agricultura e indústria, BRAVES para transporte, FINN para queima de biomassa e MEGAN para emissões biogênicas, apresentando o menor RMSE e maior coerência entre os inventários utilizados. O estudo ressaltou a importância da uniformidade na coleta de dados para aumentar a precisão das simulações, indicando que a adoção de padrões de coleta de dados é essencial para aprimorar a modelagem de inventários de emissões no Brasil.

Palavras-chave: Material Particulado; Avaliação de Impacto de Ciclo de Vida (AICV); Fatores de Caracterização; Impacto Ambiental.

ABSTRACT

Air pollution is one of the main environmental and public health challenges, with Particulate Matter (PM_{2.5}) being one of the most critical pollutants due to its adverse impacts. This study investigated the modeling of PM_{2.5} concentrations in Brazil, considering regional specificities, aiming to improve Life Cycle Impact Assessment (LCIA). Different pollutant dispersion models were mapped, and the InMAP model was selected to simulate PM_{2.5} concentrations. The evaluated inventories covered five key sectors: agriculture, industry, transportation, biomass burning, and biogenic emissions. For the agricultural sector, the EDGAR inventory was used; in the industrial sector, the EDGAR, BRAIN, and Rey (2023) inventories were considered; and for the transportation sector, the EDGAR and BRAVES inventories were used. Biomass burning was represented by the FINN inventory, while biogenic emissions were represented by the MEGAN inventory. From these sources, six datasets (C_01 to C_06) were formulated and applied in the InMAP model, subsequently validated using the Root Mean Square Error (RMSE) against monitored concentration data from 31 stations in the state of São Paulo. The analysis revealed a significant lack of specific data in key sectors, such as agribusiness, highlighting the urgent need to develop more detailed emission inventories in Brazil. The BRAVES inventory stood out for its superior representativeness, being used in the three best-performing combinations of inventories, suggesting its suitability for the Brazilian context. The southern and southeastern regions of Brazil, especially urban areas such as the São Paulo metropolitan area, showed the highest PM_{2.5} concentrations, reflecting the strong influence of transportation and industrial emissions. Among the six evaluated inventory sets, C_03 was identified as the most robust. This set combined data from EDGAR for agriculture and industry, BRAVES for transportation, FINN for biomass burning, and MEGAN for biogenic emissions, presenting the lowest RMSE and the greatest consistency among the inventories used. The study emphasized the importance of uniformity in data collection to increase the accuracy of simulations, indicating that the adoption of data collection standards is essential to improving the modeling of emission inventories in Brazil.

Keywords: Particulate Matter; Life Cycle Impact Assessment (LCIA); Characterization Factors; Environmental Impact.

LISTA DE FIGURAS

| | |
|-------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1. Componentes químicos e biológicos do MP. | 27 |
| Figura 2. Etapas da ACV | 30 |
| Figura 3. Importância dos Modelos de Dispersão na Determinação dos Fatores de Caracterização para MP na AICV..... | 36 |
| Figura 4. Cadeia de causa e efeito para a formação de MP em AICV | 37 |
| Figura 5. Esquematização do modelo Van Zelm (2016). | 43 |
| Figura 6. Fluxo Metodológico | 49 |
| Figura 7. Fluxograma da RBS | 50 |
| Figura 8. Fluxograma do Processo de Seleção de Artigos para a RBS | 52 |
| Figura 9. Série histórica de publicações da RBS..... | 64 |
| Figura 10. Análise Bibliométrica de Tendências e Conexões em Modelagem de Dispersão de Poluentes Atmosféricos (Temporal) | 65 |
| Figura 11. Análise Bibliométrica de Tendências e Conexões em Modelagem de Dispersão de Poluentes Atmosféricos (Nº de citações)..... | 67 |
| Figura 12. Distribuição Geográfica das Citações: Ênfase no Brasil e Comparação Global..... | 69 |
| Figura 13. Predominância de Modelos de Dispersão Atmosférica..... | 70 |
| Figura 14. Frequência de Citações de Poluentes Atmosféricos..... | 74 |
| Figura 15. Mapa de Emissões do Inventário EDGAR para o setor de Agricultura..... | 82 |
| Figura 16. Mapa de Emissões do Inventário EDGAR para o setor de Transporte | 85 |
| Figura 17. Mapa de Emissões do de Inventário BRAVES, | 86 |
| Figura 18. Mapa de Emissões do Inventário de Rey (2023) | 89 |
| Figura 19. Mapa de Emissões do Inventário BRAIN | 90 |
| Figura 20. Mapa de Emissões do Inventário EDGAR para o setor Industrial..... | 91 |
| Figura 21. Mapa de Emissões do Inventário FINN | 96 |
| Figura 22. Mapa de Emissões do Inventário MEGAN..... | 98 |

| | |
|-----------------------------------------------------------------------------------------------------------|-----|
| Figura 23. Distribuição Espacial das Concentrações de MP _{2,5} nos Seis Conjuntos de Dados | 101 |
| Figura 24. Distribuição das concentrações médias de MP _{2,5} para o C_03 | 109 |
| Figura 25. Gráfico Q-Q para o inventário BRAVES para o setor de transporte..... | 136 |
| Figura 26. Gráfico Q-Q para o inventário EDGAR v8.1 para o setor de transporte | 137 |
| Figura 27. Gráfico Q-Q para o inventário EDGAR v8.1 para o setor industrial..... | 139 |
| Figura 28. Gráfico Q-Q para o inventário Rey (2023) para o setor industrial | 140 |
| Figura 29. Gráfico Q-Q para o inventário BRAIN para o setor industrial | 140 |

LISTA DE TABELAS

| | |
|---------------------------------------------------------------------------------------------------------------|-----|
| Tabela 1. Padrões de Qualidade do Ar Nacionais e Estaduais..... | 21 |
| Tabela 2. Poluentes Atmosféricos: Fontes e Impactos | 25 |
| Tabela 3. Número de artigos antes e depois dos procedimentos de filtragem..... | 55 |
| Tabela 4. Características e distribuição dos inventários de emissão | 59 |
| Tabela 5. Classificação e Frequência de Modelos de Dispersão Atmosférica na Pesquisa Científica Atual..... | 72 |
| Tabela 7. Tabela de Disponibilidade de Dados por Setor e Inventário..... | 78 |
| Tabela 8. Comparação das médias (μ) e desvios padrão (σ) de emissão entre inventários..... | 80 |
| Tabela 9. Teste Kruskal-Wallis e teste de Dunn para o setor Industrial | 94 |
| Tabela 10. Conjunto de inventários | 100 |
| Tabela 11. RMSE dos conjuntos de inventários modelados no InMAP..... | 106 |
| Tabela 12. Estatísticas Descritivas das Emissões por Inventário e Setor em toneladas por ano | 133 |
| Tabela 13. Resultados do Teste de Normalidade (Kolmogorov-Smirnov) para Emissões do Setor de Transporte | 135 |
| Tabela 14. Teste Mann-Whitney U para o setor de transporte..... | 137 |
| Tabela 15. Resultados do Teste de Normalidade (Kolmogorov-Smirnov) para Emissões do Setor Industrial..... | 138 |
| Tabela 16. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_01 | 141 |
| Tabela 17. Valores de p da matriz post-hoc (teste de Dunn) para NH ₃ para o C_01 | 141 |
| Tabela 18. Valores de p da matriz post-hoc (teste de Dunn) para NO _x para o C_01 | 141 |
| Tabela 19. Valores de p da matriz post-hoc (teste de Dunn) para MP _{2,5} para o C_01 | 142 |
| Tabela 20. Valores de p da matriz post-hoc (teste de Dunn) para SO _x para o C_01..... | 142 |
| Tabela 21. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_02 | 143 |
| Tabela 22. Valores de p da matriz post-hoc (teste de Dunn) para NH ₃ para o C_02..... | 143 |
| Tabela 23. Valores de p da matriz post-hoc (teste de Dunn) para NO _x para o C_02..... | 143 |

| | |
|----------------------------------------------------------------------------------------------------|-----|
| Tabela 24. Valores de p da matriz post-hoc (teste de Dunn) para MP _{2,5} para o C_02..... | 144 |
| Tabela 25. Valores de p da matriz post-hoc (teste de Dunn) para SO _x para o C_02..... | 144 |
| Tabela 26. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_03..... | 145 |
| Tabela 27. Valores de p da matriz post-hoc (teste de Dunn) para NH ₃ para o C_03..... | 145 |
| Tabela 28. Valores de p da matriz post-hoc (teste de Dunn) para NO _x para o C_03..... | 145 |
| Tabela 29. Valores de p da matriz post-hoc (teste de Dunn) para MP _{2,5} para o C_03..... | 146 |
| Tabela 30. Valores de p da matriz post-hoc (teste de Dunn) para SO _x para o C_03..... | 146 |
| Tabela 31. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_04..... | 147 |
| Tabela 32. Valores de p da matriz post-hoc (teste de Dunn) para NH ₃ para o C_04..... | 147 |
| Tabela 33. Valores de p da matriz post-hoc (teste de Dunn) para NO _x para o C_04..... | 147 |
| Tabela 34. Valores de p da matriz post-hoc (teste de Dunn) para MP _{2,5} para o C_04..... | 148 |
| Tabela 35. Valores de p da matriz post-hoc (teste de Dunn) para SO _x para o C_04..... | 148 |
| Tabela 36. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_05..... | 149 |
| Tabela 37. Valores de p da matriz post-hoc (teste de Dunn) para NO _x para o C_05..... | 149 |
| Tabela 38. Valores de p da matriz post-hoc (teste de Dunn) para MP _{2,5} para o C_05..... | 149 |
| Tabela 39. Valores de p da matriz post-hoc (teste de Dunn) para SO _x para o C_05..... | 150 |
| Tabela 40. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_06..... | 151 |
| Tabela 41. Valores de p da matriz post-hoc (teste de Dunn) para NH ₃ para o C_06..... | 151 |
| Tabela 42. Valores de p da matriz post-hoc (teste de Dunn) para NO _x para o C_06..... | 151 |
| Tabela 43. Valores de p da matriz post-hoc (teste de Dunn) para MP _{2,5} para o C_06..... | 152 |
| Tabela 44. Valores de p da matriz post-hoc (teste de Dunn) para SO _x para o C_06..... | 152 |

SUMÁRIO

| | |
|-------------------------------------------------------------------------------------------------------------|-----------|
| 1. INTRODUÇÃO | 14 |
| 1.1. ACV E A CATEGORIA DE FORMAÇÃO DE MP | 16 |
| 1.2. SOBRE A LACUNA DA PESQUISA | 17 |
| 1.3. OBJETIVOS..... | 18 |
| 2. REFERENCIAL TEÓRICO | 19 |
| 2.1. PANORAMA DA POLUIÇÃO ATMOSFÉRICA..... | 19 |
| 2.2. CARACTERIZAÇÃO DOS PRINCIPAIS POLUENTES ATMOSFÉRICOS: FONTES E IMPACTOS | 23 |
| 2.3. MATERIAL PARTICULADO: FONTES E EFEITOS | 27 |
| 2.4. CONTEXTO ATUAL DA ACV APLICADA SOBRE A POLUIÇÃO DO AR..... | 29 |
| 2.4.1. <i>ACV aplicada à poluição atmosférica</i> | 32 |
| 2.4.2. <i>Modelos de caracterização e Determinação dos Fatores de Inalação e Efeito (FI e FE)</i> | 39 |
| 2.4.2.1. Modelo de Fantke <i>et al.</i> (2017;2019) para Obtenção de FI e FE..... | 40 |
| 2.4.2.2. Modelo de Van Zelm <i>et al.</i> (2016) para obtenção de FI e FE..... | 42 |
| 2.4.2.3. Modelo de Thind <i>et al.</i> (2022) para obtenção de FCs..... | 44 |
| 2.4.3. <i>Implicações da regionalização dos FCs para políticas ambientais brasileiras</i> | 46 |
| 2.5. MODELOS DE DISPERSÃO ATMOSFÉRICA | 47 |
| 3. METODOLOGIA..... | 48 |
| 3.1. REVISÃO BIBLIOGRÁFICA SISTEMÁTICA SOBRE MODELOS DE DISPERSÃO ATMOSFÉRICA | 50 |
| 3.1.1 Planejamento | 50 |
| 3.1.2 Levantamento de Trabalhos | 51 |
| 3.1.3 Levantamento de dados..... | 53 |
| 3.1.4 Comunicação..... | 54 |
| 3.2. SELEÇÃO E JUSTIFICATIVA DO MODELO DE DISPERSÃO..... | 55 |
| 3.2.1. <i>Caracterização do Modelo InMAP</i> | 55 |
| 3.2.1.1. Equações do Modelo..... | 56 |
| 3.2.1.2. Uso de Precursores no InMAP..... | 56 |
| 3.2.1.3. Funcionamento do Modelo | 57 |

| | | |
|-----------|------------------------------------------------------------------------------|------------|
| 3.3. | COLETA E PADRONIZAÇÃO DOS DADOS DE INVENTÁRIO | 57 |
| 3.4. | ANÁLISE DE INVENTÁRIO..... | 59 |
| 3.5. | CONFIGURAÇÃO DO MODELO INMAP | 62 |
| 3.6. | ANÁLISE DOS CONJUNTOS DE INVENTÁRIOS (ERRO QUADRÁTICO MÉDIO) | 62 |
| 4. | RESULTADOS E DISCUSSÕES | 64 |
| 4.1. | ESTADO DA ARTE DOS MODELOS DE DISPERSÃO ATMOSFÉRICA NO BRASIL.. | 64 |
| 4.1.1. | <i>Modelos de Dispersão Atmosférica e Aplicação no Brasil</i> | 70 |
| 4.1.2. | <i>Modelos de Dispersão de Baixa Complexidade</i> | 76 |
| 4.2. | ANÁLISE DE INVENTÁRIOS | 78 |
| 4.2.1. | <i>Análise de Inventário – Setor: Agricultura</i> | 81 |
| 4.2.1. | <i>Análise de Inventário – Setor: Transporte</i> | 84 |
| 4.2.1.1. | <i>Análise Comparativa de Inventários do Setor de Transporte</i> | 87 |
| 4.2.2. | <i>Análise de Inventário – Setor: Industrial</i> | 88 |
| 4.2.2.1. | <i>Análise Comparativa de Inventários do Setor Industrial</i> | 93 |
| 4.2.3. | <i>Análise de Inventário – Setor: Queima de Biomassa (FINN)</i> | 95 |
| 4.2.4. | <i>Análise de Inventário – Setor: Emissões biogênicas (MEGAN)</i> | 98 |
| 4.3. | ANÁLISE E INTERPRETAÇÃO DOS RESULTADOS DO MODELO INMAP | 99 |
| 4.3.1. | <i>Mapas de concentração de MP_{2,5}</i> | 100 |
| 4.3.2. | <i>Comparação das concentrações simuladas no InMAP com dados monitorados</i> | 105 |
| 4.4. | IMPLICAÇÕES PARA PESQUISAS FUTURAS | 109 |
| 4.5. | PERSPECTIVAS DE TRABALHOS FUTUROS | 112 |
| 5. | CONSIDERAÇÕES FINAIS..... | 112 |
| | REFERÊNCIAS..... | 115 |
| | APÊNDICE | 133 |

1. INTRODUÇÃO

A poluição atmosférica é um desafio crítico que afeta a saúde pública e o meio ambiente em nível global. De acordo com a Lei nº 14.850 de 2 de maio de 2024, que estabelece a Política Nacional de Qualidade do Ar, a gestão da qualidade do ar é definida como um conjunto de ações e procedimentos realizados por entidades públicas e privadas visando manter ou recuperar a qualidade do ar em uma determinada região (BRASIL, 2024).

Dentre os principais poluentes, o Material Particulado (MP) se destaca devido aos seus impactos adversos à saúde humana e ao ecossistema (CETESB, 2024b). As partículas finas, especialmente MP_{2,5} (MP com diâmetro aerodinâmico menor ou igual a 2,5 µm), estão associadas a um aumento no risco de morbidade e mortalidade. Estudos revelam que a exposição ao MP_{2,5} está diretamente relacionada a uma gama de doenças, incluindo problemas respiratórios e cardiovasculares, reforçando a necessidade de abordagens eficazes para a gestão da qualidade do ar (Kim; Kabir; Kabir, 2015).

No Brasil, a recente Política Nacional de Qualidade do Ar reforçou a necessidade de estabelecer padrões nacionais de qualidade do ar, tarefa que cabe ao Conselho Nacional do Meio Ambiente (CONAMA) dos quais serão incluídos ao Programa Nacional de Controle da Qualidade do Ar (PRONAR). Atualmente, estes padrões são delineados pela Resolução CONAMA nº 491 de 2018 para diversos poluentes, incluindo material particulado (MP₁₀ e MP_{2,5}), baseando-se nas diretrizes da Organização Mundial da Saúde (OMS) (BRASIL, 2024; CONAMA, 2018).

Os padrões definidos na Resolução 491 de 2018 do CONAMA, são implementados de forma gradual em fases intermediárias e uma fase final, permitindo uma adaptação progressiva e a implementação de medidas de controle e monitoramento da qualidade do ar. Atualmente, o Brasil está na primeira fase intermediária que estabelece para o MP₁₀, a concentração de 120 µg/m³, enquanto para o MP_{2,5}, a concentração de 60 µg/m³ um período de 24 horas¹.

Além disso, é possível comparar esses padrões com os Limites Planetários estabelecidos para a formação de MP, para avaliar sua adequação dentro do conceito de “espaço operacional seguro”. Esses limites foram estabelecidos para diversos processos essenciais ao funcionamento do sistema terrestre, incluindo a carga de aerossóis atmosféricos (Steffen *et al.*, 2015). Contudo,

¹ Significa que a média da concentração do MP₁₀ e MP_{2,5} no ar, durante qualquer intervalo de 24 horas, não deve ultrapassar esses valores.

os Limites Planetários (LP)² representam limites de segurança para diferentes processos essenciais ao funcionamento do sistema terrestre, incluindo a formação de MP. De acordo com Richardson et al. (2023), o limite seguro para a profundidade óptica do aerossol (AOD), que é uma medida da densidade de partículas suspensas na atmosfera, é de 0,1 (adimensional), com uma zona de incerteza que vai até 0,25, considerando médias anuais. Pesquisas indicam que concentrações de MP_{2,5} em torno de 50 µg/m³ podem equivaler a um AOD de aproximadamente 0,1 em áreas urbanas típicas (Jin; Crippa; Pryor, 2020; Zhang, et al., 2018).

Estudos, como o de Jin *et al.* (2020), mostram que a relação entre AOD e MP_{2,5}. Os valores de MP_{2,5} estabelecidos pelo CONAMA (20 µg/m³) e pelos padrões estaduais são próximos, mas ainda acima do limite seguro derivado do AOD (7 a 9,3 µg/m³) e dentro da zona de risco (até 23,25 µg/m³). Para MP₁₀, os limites de 40 µg/m³ também excedem os valores seguros correspondentes ao AOD de 0,1.

Os padrões atuais de qualidade do ar estabelecidos pelo CONAMA e adotados pelos estados são mais elevados do que os valores considerados seguros quando comparados aos limites planetários baseados em AOD. Desse modo, é possível destacar a necessidade urgente de políticas mais rigorosas e eficazes para a redução da poluição do ar no Brasil. A adoção de valores mais restritivos alinhados aos Limites Planetários seria crucial para minimizar os riscos à saúde humana e ao meio ambiente, garantindo um desenvolvimento sustentável e seguro, visto que o MP tem influência no sistema climático e nos efeitos adversos na saúde humana em escala regional e global (Rockström *et al.*, 2009).

Ao comparar os valores estabelecidos pela OMS para a primeira fase dos níveis recomendados com os limites presentes na legislação brasileira e os limites planetários, fica evidente que estes últimos são bem mais conservadores. A OMS, em suas diretrizes de 2022, estabelece um limite de 35 µg/m³ para MP_{2,5} e 70 µg/m³ para MP₁₀ na primeira fase dos alvos intermediários. Esses valores são significativamente mais baixos do que os limites geralmente adotados na legislação brasileira e os limites planetários, que frequentemente são mais permissivos e, portanto, menos rigorosos em termos de proteção à saúde pública e ambiental (WHO, 2023).

A implementação desses padrões é de responsabilidade dos estados e do Distrito Federal, que devem monitorar a qualidade do ar e elaborar planos de controle de emissões e

² Conceito desenvolvido para identificar e quantificar os limites dentro dos quais a humanidade pode operar com segurança, garantindo que o sistema terrestre permaneça em um estado estável e favorável para o desenvolvimento humano (Rockström *et al.*, 2009).

relatórios anuais de avaliação da qualidade do ar. Esta abordagem visa assegurar uma melhoria contínua na qualidade do ar, reduzindo os impactos da poluição atmosférica na saúde da população e no meio ambiente (CONAMA, 2018).

Diante disso, a Avaliação do Ciclo de Vida (ACV) emerge como uma ferramenta para avaliar os impactos ambientais associados a todos os estágios do processo de vida de um produto ou serviço, incluindo a formação de MP (Oliveira *et al.*, 2021). A ACV serve como um instrumento, por exemplo, para viabilizar a quantificação e o monitoramento da poluição e dos impactos que a formação de MP gera, podendo assim, amparar políticas públicas, tais como a recente Lei Nº 14.850. Todavia, o CONAMA (2018) não mostra, ou não foi atualizado, para incluir informações geradas por estudos de ACV nesse processo de monitoramento, o que se mostra uma oportunidade para futuras pesquisas, assim também justificando a presente proposta de pesquisa.

1.1. ACV e a categoria de formação de MP

A ACV é uma técnica desenvolvida em quatro etapas: definição de objetivo e escopo, análise de inventário, Avaliação de Impacto do Ciclo de Vida (AICV) e interpretação de resultados. Na etapa de definição dos objetivos e escopo, ocorre a determinação das fronteiras do estudo, temporal e geograficamente, do qual irá delimitar o espaço e tempo, para que seja coletado dados para criação de fluxos de massa e energia. Tais fluxos possibilitam a avaliação de impactos dos dados analisados, convertendo-os, por meio de fatores de equivalência ou também chamados de Fatores de Caracterização (FCs), que mensuram o impacto de um fluxo elementar dentro das categorias de AICV (Hauschild; Rosenbaum; Olsen, 2018; ISO, 2006).

Os FCs são determinados por modelos de caracterização que estabelecem relações dos fluxos elementares inventariados com categorias de impacto ambiental, usando o mecanismo de causa e efeito (Silva, 2018). De acordo com Mutel *et al.* (2019), estes modelos necessitam de uma regionalização, visto que, em sua maioria, foram definidos para escopos geográficos diferentes do brasileiro (Estados Unidos, Europa etc.). Para o Brasil, a regionalização de FCs se iniciou pelas categorias de escassez hídrica (Castro *et al.*, 2018), ecossistemas e biodiversidade (Turgeon *et al.*, 2021) e uso da terra (Morales *et al.*, 2019; Pavan; Ometto, 2016). Dentre as categorias que necessitam de regionalização para o Brasil, tem-se a de formação de MP (Giusti, 2021; RAICV, 2019).

Nesse contexto, o MP é um poluente atmosférico que pode ser classificado com base em seu tamanho aerodinâmico (MP₁₀ – MP com diâmetro aerodinâmico menor ou igual a 10

μm e $\text{MP}_{2,5}$ - MP com diâmetro aerodinâmico menor ou igual a $2,5 \mu\text{m}$) ou sua fonte de emissão, primária (liberação do poluente como MP) ou secundária (emissão de precursores gasosos como: dióxido de enxofre (SO_2) e amônia (NH_3)) (U. S. EPA, 2020).

Para determinar um FC para a categoria de formação de MP, é necessário levar em consideração o Fator de Inalação (FI), que quantifica a massa inalada de poluente em relação a massa de poluente emitida e o Fator de Efeito (FE), que apresenta a relação entre o impacto à saúde e a quantidade de massa inalada de poluente. Tais fatores levam em consideração características regionais para o cálculo, de forma que, quanto mais regionalizado, menor o grau de incerteza do dado obtido (Humbert; Fantke; Jolliet, 2015; Mutel et al., 2019).

De acordo com Van Zelm et al. (2016), a determinação do FI requer a integração de dados precisos sobre as concentrações de poluentes, a demografia da população exposta e a taxa de respiração humana. O FE, por sua vez, é calculado considerando a taxa de inalação, os dados de risco relativo (que fornecem uma estimativa quantitativa dos efeitos adversos à saúde associados à exposição ao poluente), a taxa de mortalidade e a concentração de fundo do poluente.

1.2. Sobre a lacuna da pesquisa

A concentração é uma variável fundamental para a quantificação do FCs na categoria de formação de MP (Giusti *et al.*, 2023). Avaliar a concentração de MP é importante para entender a exposição humana e os impactos ambientais e, o uso de modelos que estimam essas concentrações permitem uma análise detalhada da dispersão de poluentes e a avaliação dos riscos à saúde e ao meio ambiente (Mostafa *et al.*, 2016).

Sendo assim, os modelos de dispersão atmosférica desempenham um papel essencial na avaliação e gestão da qualidade do ar, especialmente no cálculo da concentração de poluentes. Esses modelos utilizam princípios matemáticos e físicos para simular como os poluentes se dispersam na atmosfera sob diferentes cenários e condições atmosféricas pelo estudo das complexas interações entre os poluentes e as condições meteorológicas e topográficas locais. Este complexo processo depende de vários fatores, tais como: efeitos térmicos, mecânicos, efeitos da turbulência, elevação do terreno, perfil vertical de temperatura da atmosfera, movimentação das massas de ar, entre outros (Barbero *et al.*, 2021; Gisch; Bodmann; Vilhena, 2015; Sekula *et al.*, 2022).

Portanto, para calcular a concentração de MP considerando as especificidades regionais do Brasil para aplicação na AICV, é fundamental determinar um modelo de dispersão adequado para este contexto. Esta necessidade surge da importância de reduzir as incertezas associadas ao cálculo dos FCs para a categoria de formação de MP. A regionalização eficaz não apenas melhora a precisão dos dados, mas também é essencial para o desenvolvimento de políticas de gestão ambiental e de saúde pública mais efetivas, que estejam alinhadas às particularidades regionais do Brasil.

1.3. Objetivos

O objetivo geral deste estudo compõe-se no cálculo da concentração de MP levando em consideração as características locais do Brasil para uso na AICV. Sendo assim, os objetivos específicos são:

- (1) Mapear e selecionar modelos de dispersão atmosférica disponíveis para uso no contexto da ACV;
- (2) Realizar uma análise detalhada dos inventários disponíveis para o Brasil;
- (3) Aplicar um modelo de dispersão em inventários de emissão de MP e seus precursores para o cálculo da concentração de MP;
- (4) Comparar a concentração modelada à dados de monitoramento obtidos pela CETESB.

2. Referencial Teórico

Nas próximas seções será discutido o referencial teórico deste estudo que aborda inicialmente o panorama da poluição atmosférica, explorando as principais fontes e os efeitos do MP na saúde e no meio ambiente. Em seguida, foi discutido o contexto atual da ACV aplicada à poluição do ar, com ênfase nos modelos de caracterização e na metodologia de cálculo dos FCs. A regionalização desses FCs é analisada em termos de suas implicações para as políticas ambientais brasileiras, destacando a importância de adaptar esses fatores ao contexto local. Por fim, são apresentados os modelos de dispersão atmosférica, enfatizando seu papel na determinação e na precisão dos FCs.

2.1. Panorama da Poluição Atmosférica

De acordo com o Ministério do Meio Ambiente (MMA, 2024b) e a OMS (2024), a qualidade do ar é um indicador essencial que reflete a presença de poluentes no ar, já que é o resultado de uma complexa interação de diversos fatores, como a intensidade das emissões, a topografia e as condições meteorológicas da região, das quais podem ser ou não favoráveis a dispersão de poluentes.

A poluição atmosférica é definida como a contaminação do ambiente por qualquer agente químico, físico ou biológico que alterem as características naturais da atmosfera, podendo elas serem prejudiciais à saúde humana e ao meio ambiente. Essas substâncias consistem em gases ou partículas contaminantes presentes no ambiente (WHO, 2021, 2024). Alguns poluentes podem ser categorizados em primários, dos quais são liberados diretamente na atmosfera, enquanto outros poluentes são formados no ar a partir de reações químicas, denominados como poluentes secundários (Barber; Kroll, 2021). Um exemplo relevante de poluente secundário é o ozônio troposférico, que se forma, principalmente, a partir das reações de óxidos de nitrogênio (NO_x) e compostos orgânicos voláteis (COVs) na presença da luz solar.

A OMS estabelece diretrizes que determinam limites máximos para concentrações de poluentes como partículas finas ($\text{MP}_{2,5}$ e MP_{10}), dióxido de enxofre (SO_2), dióxido de nitrogênio (NO_2), monóxido de carbono (CO) e ozônio (O_3) para garantir um ar de qualidade aceitável para a saúde humana (WHO, 2021). Essas diretrizes são adotadas ou adaptadas por países conforme suas especificidades regionais e capacidades de monitoramento e controle.

No Brasil, a regulamentação da qualidade do ar foi estabelecida, em um primeiro momento, pelo Instituto Brasileiro de Meio Ambiente (IBAMA) e aprovados pelo Conselho

Nacional de Meio Ambiente (CONAMA), por meio da resolução CONAMA nº 03 de 1990 (CONAMA, 1990). Contudo, em 2018, a Resolução CONAMA nº 491 revogou os padrões e substituiu a CONAMA nº 03/1990 (CONAMA, 2018).

Além dos padrões de qualidade do ar definidos em nível nacional pelo CONAMA, os estados brasileiros têm autonomia para estabelecer suas próprias normativas. A maioria dos estados segue os padrões nacionais, incluindo Minas Gerais, Rio Grande do Sul, Rio de Janeiro e Pará. No entanto, São Paulo e Espírito Santo adotam padrões próprios. O Espírito Santo, por meio do Decreto Estadual N° 3463-R de 2013, implementou padrões mais restritivos e adicionou poluentes que não são cobertos pela legislação nacional (ESPÍRITO SANTO, 2013). São Paulo, por meio do Decreto Estadual nº 59113/2013, além de estabelecer metas para a gestão da qualidade do ar, define critérios específicos para lidar com episódios agudos de poluição. Isso inclui a declaração dos estados de Atenção, Alerta e Emergência, quando os níveis de concentração são ultrapassados, juntamente com a previsão de condições meteorológicas que dificultam a dispersão dos poluentes (SÃO PAULO, 2013).

Conforme delimitado pela Resolução CONAMA nº 491 de 2018, a normatização ambiental brasileira estabelece padrões específicos, categorizados em Padrão Intermediário 1 (PI1), Padrão Intermediário 2 (PI2), Padrão Intermediário 3 (PI3) e Padrão Final (PF), como evidenciado na Tabela 1. Paralelamente, os Estados de São Paulo e Espírito Santo definem seus próprios parâmetros, denominadas como Meta Intermediária 1 (MI1), Meta Intermediária 2 (MI2), Meta Intermediária 3 (MI3) e Padrão Final (PF).

Tabela 1. Padrões de Qualidade do Ar Nacionais e Estaduais

| Poluente Atmosférico | Sigla | Período de Referência | Padrão Nacional | | | Padrão Nacional | | | Padrão Nacional | | | Padrão Nacional | | |
|--------------------------------|-------------------|-----------------------|--------------------------------------|-------------------------------------|-------------------------------------|--------------------------------------|-------------------------------------|-------------------------------------|--------------------------------------|-------------------------------------|-------------------------------------|------------------------------------|------------------------------------|------------------------------------|
| | | | PI-1 ($\mu\text{g}/\text{m}^3$) | MI1 ($\mu\text{g}/\text{m}^3$) | MI1 ($\mu\text{g}/\text{m}^3$) | PI-2 ($\mu\text{g}/\text{m}^3$) | MI2 ($\mu\text{g}/\text{m}^3$) | MI2 ($\mu\text{g}/\text{m}^3$) | PI-3 ($\mu\text{g}/\text{m}^3$) | MI3 ($\mu\text{g}/\text{m}^3$) | MI3 ($\mu\text{g}/\text{m}^3$) | PF ($\mu\text{g}/\text{m}^3$) | PF ($\mu\text{g}/\text{m}^3$) | PF ($\mu\text{g}/\text{m}^3$) |
| Material Particulado | MP ₁₀ | 24 horas | 120 | 120 | 120 | 100 | 100 | 80 | 75 | 75 | 60 | 50 | 50 | 50 |
| | | Anual | 40 | 40 | 45 | 35 | 35 | 33 | 30 | 30 | 25 | - | 20 | 20 |
| Partículas Inaláveis | MP _{2,5} | 24 horas | 60 | 60 | - | 50 | 50 | 50 | 37 | 37 | 37 | 25 | 25 | 25 |
| | | Anual | 20 | 20 | - | 17 | 17 | 20 | 15 | 15 | 15 | 10 | 10 | 10 |
| Dióxido de Enxofre | SO ₂ | 24 horas | 125 | 125 | 60 | 100 | 100 | 40 | 75 | 75 | 30 | - | - | 20 |
| | | Anual | 40 | 40 | 40 | 30 | 30 | 30 | 20 | 20 | 20 | - | - | - |
| Dióxido de Nitrogênio | NO ₂ | 1 hora | 260 | 260 | 240 | 240 | 240 | 220 | 220 | 220 | 210 | 200 | 200 | 200 |
| | | Anual | 60 | 60 | 50 | 50 | 50 | 45 | 45 | 45 | 42 | 40 | 40 | 40 |
| Partículas Totais em Suspensão | PTS | 24 horas | - | - | 180 | - | - | 170 | - | - | 160 | 240 | 240 | 150 |
| | | | - | - | 65 | - | - | 63 | - | - | 62 | - | 80 | 60 |
| Fumaça | - | 24 horas | 120 | 120 | - | 100 | 100 | - | 75 | 75 | - | 50 | 50 | - |
| | | Anual | 40 | 40 | - | 35 | 35 | - | 30 | 30 | - | 20 | 20 | - |
| Ozônio | O ₃ | 8 horas | 140 | 140 | 140 | 130 | 130 | 120 | 120 | 120 | 110 | 100 | 100 | 100 |
| Monóxido de Carbono | CO | 8 horas | - | - | - | - | - | - | - | - | - | 9 | 9 | 10 |
| | | 1 hora | - | - | - | - | - | - | - | - | - | - | - | 30 |
| Chumbo | Pb | Anual | - | - | - | - | - | - | 0,5 | - | - | - | 0,5 | - |
| Poeira Sedimentável | PS | 30 dias | - | - | 14 | - | - | - | - | - | - | - | - | - |

Fonte: (CONAMA, 2018; ESPÍRITO SANTO, 2013; SÃO PAULO, 2013)

A Tabela 1 compara os padrões de qualidade do ar estabelecidos nacionalmente e pelos estados de São Paulo e Espírito Santo, destacando as diferentes metas de controle para poluentes atmosféricos. Para MP₁₀, o padrão nacional estabelece um limite anual de 40 µg/m³, para MP_{2,5}, o limite anual é de 20 µg/m³. Esses valores são comparáveis aos padrões de qualidade do ar de São Paulo (SP) e Espírito Santo (ES), embora alguns limites estaduais sejam iguais ou ligeiramente mais altos.

Os padrões de qualidade do ar estabelecidos na Resolução 491 de 2018 do CONAMA e pelos estados de São Paulo e Espírito Santo são implementados de forma gradual para permitir uma adaptação progressiva e a implementação de medidas de controle e monitoramento da qualidade do ar, atualmente, o estado de SP está na Meta Intermediária 2, enquanto o ES continua na Meta Intermediária 1. O CONAMA estabelece que o avanço ou não das metas fica a critério dos órgãos estaduais, de acordo com a proposta que foi estabelecida.

Um ponto importante a ser abordado é a ausência de valores para MP_{2,5} na meta 1 (MI-1) do Espírito Santo. Assim, o estado segue o limite estabelecido pela legislação federal.

Ao expandir a comparação para incluir padrões internacionais, como os estabelecidos pela EPA nos Estados Unidos, pela União Europeia, China e OMS, pode-se observar disparidades significativas. Por exemplo, os padrões da EPA e da OMS para MP_{2,5} são mais rigorosos, sendo que para a EPA a média anual é de 15 µg/m³ para MP_{2,5} e 40 µg/m³ para MP₁₀ e, para a OMS, o valor é de 35 µg/m³ para MP_{2,5} para a primeira etapa das metas intermediárias, enquanto para MP₁₀ é de 45 µg/m³, refletindo um enfoque mais preventivo em relação à saúde pública (U. S. EPA, 2013; WHO, 2023).

Já para a legislação da União Europeia, a média anual estabelecida é de 20 µg/m³ para MP_{2,5} e 40 µg/m³ para MP₁₀ e, a legislação chinesa estabelece 15 µg/m³ (reservas naturais e áreas com proteção ambiental especial) e 35 µg/m³ (áreas urbanas e industriais) para MP_{2,5} e 40 µg/m³ (reservas naturais e áreas com proteção ambiental especial) e 70 µg/m³ (áreas urbanas e industriais) para MP₁₀ (MEE, 2016; União Europeia, 2008).

Órgãos como a Companhia Ambiental do Estado de São Paulo (CETESB) de São Paulo, Fundação Estadual do Meio Ambiente (FEAM) de Minas Gerais, Fundação Estadual de Proteção Ambiental Henrique Luiz Roessler (FEPAM) do Rio Grande do Sul, Instituto Água e Terra (IAT) do Paraná e o Instituto Nacional de Meteorologia (INMET) com atuação em todo o Brasil, são responsáveis pelo monitoramento e pela divulgação de informações sobre a qualidade do ar. A CETESB, por exemplo, opera uma extensa rede de monitoramento em todo

o estado de São Paulo, fornecendo dados cruciais para a gestão da qualidade do ar e para a saúde pública (CETESB, 2024a).

O último marco para a poluição do ar no Brasil veio a partir da lei nº 14.850, de 2 de maio de 2024 (BRASIL, 2024). Essa lei estabelece a Política Nacional de Qualidade do Ar e dispõe sobre seus princípios, objetivos e instrumentos, representando um avanço significativo na regulação ambiental no Brasil. A nova legislação promove a criação de planos nacionais e estaduais para a qualidade do ar, programas de controle e inventários de poluentes, o que é crucial para enfrentar os desafios da poluição atmosférica.

Entretanto os vetos sancionados levantam importantes preocupações sobre sua implementação prática. Os vetos mais críticos ocorreram sobre o Artigo 11 da Lei nº 14.850, que originalmente estabelecia prazos para a publicação dos inventários de emissões. A ausência desses prazos compromete significativamente a capacidade de planejamento e execução das políticas de qualidade do ar, uma vez que os inventários são fundamentais para a criação de planos de gestão eficazes. Sem prazos definidos, há o risco de atrasos e falta de transparência na divulgação das informações sobre as emissões de poluentes, o que pode enfraquecer a confiança pública e a responsabilidade governamental (BRASIL, 2024).

Além disso, os vetos que eliminam a possibilidade de monitoramento das emissões da frota de veículos por sensores instalados nos próprios veículos para sensoriamento remoto e que retiram a autonomia dos estados na definição de padrões de qualidade do ar são particularmente preocupantes. O uso de sensores para monitoramento remoto é uma ferramenta moderna e eficiente que pode proporcionar dados precisos e em tempo real sobre as emissões veiculares, uma das principais fontes de poluição nas áreas urbanas. No entanto, essa abordagem também enfrenta desafios relacionados à manutenção dos sensores e ao risco de adulteração. A retirada desta ferramenta limita a capacidade de monitoramento e controle das emissões. Da mesma forma, a centralização dos padrões de qualidade do ar pode não considerar as especificidades regionais, o que é essencial para a implementação de políticas ambientais eficazes (BRASIL, 2024).

2.2. Caracterização dos Principais Poluentes Atmosféricos: Fontes e Impactos

As fontes de poluentes e seus tipos variam amplamente conforme a localização geográfica, devido às diferenças em aspectos industriais, urbanos, rurais e naturais das regiões (He; Schäfer; Beck, 2022).

Em áreas urbanas e industrializadas, as principais fontes de poluentes incluem emissões de veículos, processos industriais, geração de energia e a queima de biomassa, que liberam poluentes como partículas finas (MP_{2,5}), óxidos de nitrogênio (NO_x) e compostos orgânicos voláteis (COVs) (Iqbal; Afroze; Rahman, 2021; Pu *et al.*, 2019; Zhou *et al.*, 2021). Esses poluentes afetam diretamente a qualidade do ar local e contribuem para problemas de saúde pública e ambientais.

Nas megacidades, a densidade populacional resulta em concentrações elevadas de poluentes locais. Além disso, o transporte de poluentes para regiões vizinhas é influenciada por fatores meteorológicos, como os padrões de vento e o transporte vertical. Por exemplo, as correntes de ar nos trópicos podem transportar poluentes para camadas mais altas da atmosfera, ajudando a espalhá-los para áreas mais distantes (Iqbal; Afroze; Rahman, 2021; Lawrence *et al.*, 2007; Mao *et al.*, 2020).

Em áreas menos urbanizadas, as fontes naturais, como poeira e emissões de compostos orgânicos por plantas, são predominantes. Além disso, atividades como a agricultura contribuem significativamente com amônia (NH₃) e outros gases relacionados ao uso de fertilizantes e manejo do solo (Ramanantenasoa *et al.*, 2018).

Em regiões polares e remotas, como o Ártico e a Antártica, poluentes persistentes, como os poluentes orgânicos persistentes (POPs), são transportados a longas distâncias pela atmosfera e acumulam-se devido às baixas temperaturas, afetando a qualidade do ar e a saúde ambiental em escala global (Wang *et al.*, 2019; Xie *et al.*, 2022).

Na Tabela 2 são apresentadas as principais fontes, efeitos adversos a saúde humana, a biodiversidade e ao clima, para MP_{2,5} e seus principais precursores.

Tabela 2. Poluentes Atmosféricos: Fontes e Impactos

| Poluente | Definição | Fontes Principais | Impactos na Saúde Humana | Impactos na Biodiversidade | Impactos no Clima |
|------------------------------------------|-----------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------|----------------------------------------------------------------------------------|
| Material Particulado | Mistura complexa de partículas sólidas e líquidas presentes no ar. | Queima de combustíveis fósseis; Queima de biomassa vegetal; Emissões de Amônia na Agricultura; Indústrias | Câncer Respiratório; Arteriosclerose; Inflamação no Pulmão; Problemas respiratórios; Doenças cardiovasculares | Redução da fotossíntese, danos a vida aquática | Contribuição para neblina urbana; Modificação do albedo das nuvens. |
| Dióxido de Enxofre (SO ₂) | Gás tóxico e incolor. Precursor de MP na atmosfera. | Naturais: Erupções vulcânicas; Antropogênicas: Queima de combustíveis fósseis, Usinas de energia, indústrias. | Irritação dos pulmões, problemas respiratórios | Chuva ácida, afetando ecossistemas aquáticos e terrestres. | Formação de chuva ácida |
| Dióxido de Nitrogênio (NO ₂) | Gás poluente com ação altamente oxidante. | Naturais: vulcanismos, ações bacterianas, descargas elétricas; Antropogênicas: Veículos, usinas de energia, indústria de fertilizantes | Irritação respiratória, diminuição da função pulmonar | Eutrofização, acidificação do solo e da água | Formação de ozônio no nível do solo, smog fotoquímico, chuva ácida |
| Amônia (NH ₃) | Gás incolor com cheiro característico | Agricultura (ex.: aplicação de fertilizantes e manejo de dejetos animais), indústria, emissões de veículos. | Irritação das vias respiratórias e dos olhos; pode levar à asma e outros problemas respiratórios em exposições elevadas. | Eutrofização de ecossistemas aquáticos, | Afeta a formação de aerossóis secundários. |
| Compostos Orgânicos Voláteis (COVs) | Grupo diverso de compostos químicos orgânicos que evaporam facilmente a temperaturas normais. | Emissões de solventes, queima de combustíveis fósseis, emissões industriais, produtos de consumo, florestas (emissões biogênicas). | Irritação dos olhos, nariz e garganta; efeitos no sistema nervoso central; possíveis efeitos cancerígenos em exposições prolongadas. | Contribui para o smog fotoquímico. | Influência indireta no efeito estufa através da formação de ozônio troposférico. |

Fonte: Elaborada pelo autor, com base em dados extraídos de Grzywa-Celińska et al., 2024; Kopel; Brower, 2019; Lambrechts; Sinha, 2016; MMA, 2024b; Wang et al., 2019b.

Além disso, a principal origem das emissões poluentes no mundo advém da queima de combustíveis fósseis. No Brasil, embora careça de inventários nacionais completos e atualizados sobre as emissões de poluentes atmosféricos de diferentes fontes, dados de inventários como do *Emission Database for Global Atmospheric Research* (EDGAR) (Comissão Europeia, 2024) indicam que os principais emissores são o setor de transporte, os processos industriais e a queima de biomassa.

De acordo com o Simoni et al. (2021), os veículos são a principal fonte de poluentes atmosféricos em centros urbanos. O transporte rodoviário, predominantemente composto por automóveis e caminhões movidos a diesel e gasolina, é responsável por uma significativa parcela das emissões de óxidos de nitrogênio (NO_x), material particulado (MP) e monóxido de carbono (CO).

Os veículos movidos a diesel, principalmente ônibus e caminhões, representam respectivamente 91% e 96% do total emitido pelo transporte rodoviário em 2012 (MMA, 2014). A poluição gerada por esse setor é exacerbada pela alta densidade de veículos e por padrões de emissão muitas vezes inadequados, mesmo com avanços recentes na legislação ambiental que busca controlar e reduzir poluentes como o SO_x e NO_x (Dantas et al., 2021).

Além do setor de transporte, a queima de biomassa é uma fonte significativa de poluição do ar, especialmente notável nas regiões Centro-Oeste e Norte do Brasil, onde práticas agrícolas e desmatamento resultam em extensas queimadas. Estas atividades liberam grandes quantidades de $\text{MP}_{2,5}$, monóxido de carbono e compostos orgânicos voláteis na atmosfera. A fumaça das queimadas não apenas compromete a qualidade do ar local, mas também afeta regiões mais distantes devido ao transporte desses poluentes por correntes de ar, influenciando o clima e a saúde pública em escala regional (Andreão et al., 2020).

A indústria é outra fonte relevante de poluição do ar no Brasil, especialmente nas áreas metropolitanas onde o desenvolvimento industrial não foi acompanhado por uma fiscalização ambiental eficaz nas décadas passadas. Poluentes como dióxidos de enxofre (SO_2), óxidos de nitrogênio, partículas em suspensão e diversos compostos orgânicos são emitidos por setores como metalurgia, química, e papel e celulose. A presença desses poluentes está associada a problemas de saúde pública e impacto negativo no meio ambiente, demandando ações regulatórias mais estritas e tecnologias de controle de poluição mais eficientes para mitigar seus efeitos (Andrade et al., 2015).

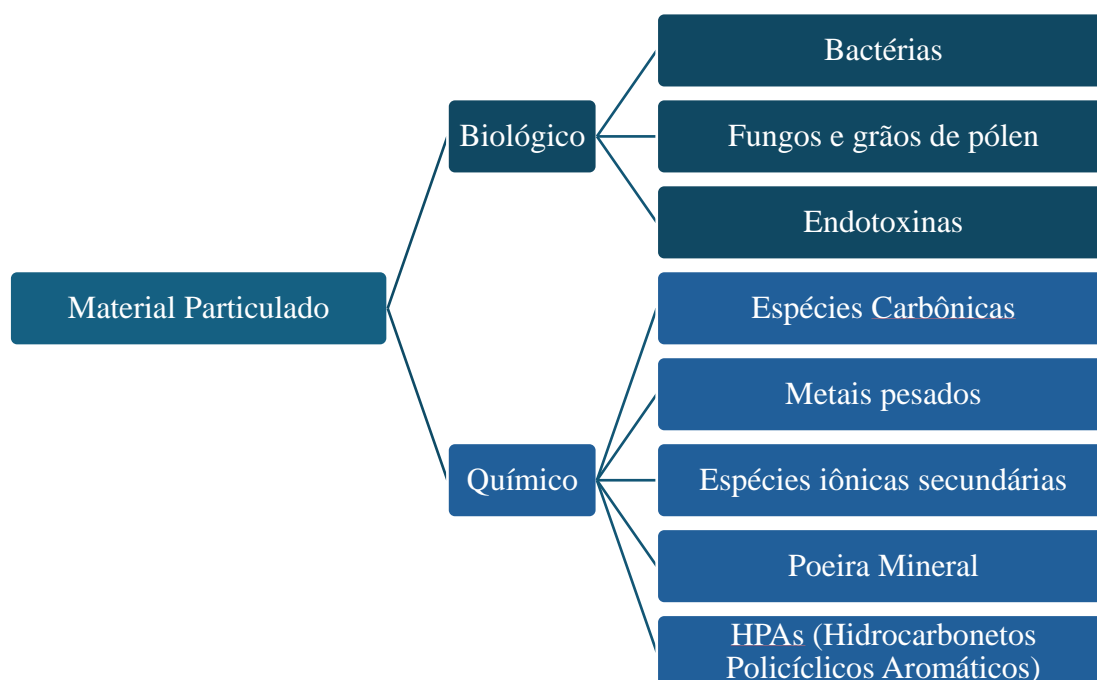
2.3. Material Particulado: Fontes e Efeitos

Dentre os principais poluentes, o MP se destaca devido aos seus impactos adversos à saúde humana e ao ecossistema (CETESB, 2024b). O MP origina-se de uma combinação de fontes naturais e atividades humanas, influenciando sua composição química e, conseqüentemente, seus impactos na saúde (Giusti, 2021). Dito isso, tem-se que as fontes primárias de MP incluem emissões diretas de veículos, indústrias e atividades como construção e agricultura (Iqbal; Afroze; Rahman, 2021).

Já as fontes secundárias, por outro lado, resultam de reações químicas na atmosfera envolvendo gases como dióxido de enxofre e amônia, formando partículas como sulfatos e nitratos. Estudos indicam que, além dos combustíveis fósseis, as emissões secundárias também são significativas, especialmente em áreas urbanas e industriais (Adams *et al.*, 2015; Zhu *et al.*, 2020)

Além disso, o MP pode conter diferentes características físicas, como tamanho e número de partículas, área superficial total e propriedades eletrostáticas (Oeder *et al.*, 2012), e componentes biológicos e químicos (Kelly; Fussell, 2012), como esquematizado na Figura 1.

Figura 1. Componentes químicos e biológicos do MP.



Fonte: Adaptado de Kelly; Fussell, 2012; Oeder *et al.*, 2012.

As partículas biológicas suspensas no ar, também conhecidos como bioaerossóis, compostos tanto por microrganismos vivos quanto mortos, além de diferentes formas de

biomassa aérea, apresentam tamanhos que variam de menos de 0,1 μm até 100 μm . Esses componentes biológicos geralmente se acumulam em partículas mais grossas do ar, porém esporos de fungos, fragmentos de pólen e bactérias isoladas também podem ser encontrados nas partículas mais finas (Haas *et al.*, 2013; Valdez-Castillo *et al.*, 2021; Xie *et al.*, 2021).

Já os componentes químicos do MP englobam substâncias como óxidos metálicos de alumínio, cálcio, silício, titânio, ferro, magnésio, manganês, sódio e potássio, além de matéria orgânica e carbono elementar. Aerossóis inorgânicos secundários, como sulfato, nitrato e amônio, junto com partículas carbonáceas, são especialmente preocupantes devido ao seu potencial para aumentar a acidez e a toxicidade do MP (Jacobs *et al.*, 2012; Lin *et al.*, 2007; Morakinyo *et al.*, 2016).

As partículas finas, especialmente $\text{MP}_{2,5}$, estão associadas a um aumento no risco de morbidade e mortalidade. Estudos revelam que a exposição ao MP está diretamente relacionada a uma gama de doenças, incluindo problemas respiratórios e cardiovasculares, reforçando a necessidade de abordagens eficazes para a gestão da qualidade do ar (Bonyadi *et al.*, 2016; Li *et al.*, 2023; Morakinyo *et al.*, 2016).

De acordo com Simoni *et al.* (2021), os primeiros estudos epidemiológicos e clínicos no Brasil que consideraram os efeitos adversos à saúde humana relacionados à poluição atmosférica são datados dentre as décadas de 1980 e 1990 (Böhm *et al.*, 1983, 1989; Massad *et al.*, 1985; Saldiva *et al.*, 1995, 1994; Schimmel, 1978).

Sob a perspectiva dos LP, segundo Richardson *et al.* (2023), o globo já transgrediu 6 dos nove limites, entre eles mudança climática, integridade da biosfera, e fluxos bioquímicos de nitrogênio e fósforo. No entanto, o limite planetário referente à carga de aerossóis atmosféricos ainda não foi transgredido. Entretanto, Rockström *et al.* (2009) destacam a carga de aerossol atmosférico como um processo antropogênico de mudança global com potencial para transgredir os limites planetários, devido à sua influência significativa no sistema climático e seus efeitos adversos na saúde humana em escala regional e global.

Segundo dados mais atualizados sobre qualidade do ar, tem-se que 98% das cidades em nações de baixa e média renda com populações superiores a 100.000 habitantes não estão dentro das diretrizes de qualidade do ar estabelecidas pela Organização Mundial da Saúde. Em contrapartida, em países de renda alta, a proporção diminui para 56% (WHO, 2018).

Estudos continuam a esclarecer que a exposição ao MP representa um dos maiores riscos à saúde pública, principalmente devido aos seus efeitos sobre os sistemas respiratório e

cardiovascular. Segundo Losacco e Perillo (2018), o $MP_{2,5}$ possuem maior potencial para causar danos devido à sua capacidade de penetrar profundamente nos pulmões e entrar na corrente sanguínea. O tamanho e a área superficial das partículas são fatores críticos que determinam seus efeitos biológicos, incluindo a indução de lesões inflamatórias e danos oxidativos (Grochanke, 2015; Künzli; Perez; Rapp, 2010).

Além disso, a exposição ao $MP_{2,5}$ tem demonstrado ter impactos significativos em indivíduos com doenças respiratórias crônicas, como a doença pulmonar obstrutiva crônica (COPD) e asma (Amiri *et al.*, 2019). Em um estudo com pacientes de COPD e asma em Pequim, Duan *et al.* (2021) observaram que um aumento de apenas $10 \mu\text{g}/\text{m}^3$ na exposição ao $MP_{2,5}$ está associado a uma redução mensurável na função pulmonar, incluindo a capacidade vital forçada e o volume expiratório forçado em um segundo.

A longo prazo, a exposição ao $MP_{2,5}$ também está ligada a um declínio acentuado na função pulmonar e um aumento no risco de desenvolver COPD (Amiri *et al.*, 2019). Um estudo realizado em Taiwan por Guo *et al.* (2018) encontrou que cada incremento de $5 \mu\text{g}/\text{m}^3$ em $MP_{2,5}$ estava associado a uma redução percentual na função pulmonar, acelerando o declínio pulmonar ao longo do tempo e aumentando significativamente o risco de desenvolver COPD.

Finalmente, um estudo de tendências de publicação por Lee, Lim e Kim (2021) destaca que a pesquisa global sobre matéria particulada e seus efeitos na saúde tem se concentrado principalmente em doenças respiratórias e cardiovasculares, identificando uma necessidade urgente de estratégias globais para mitigar a poluição do ar.

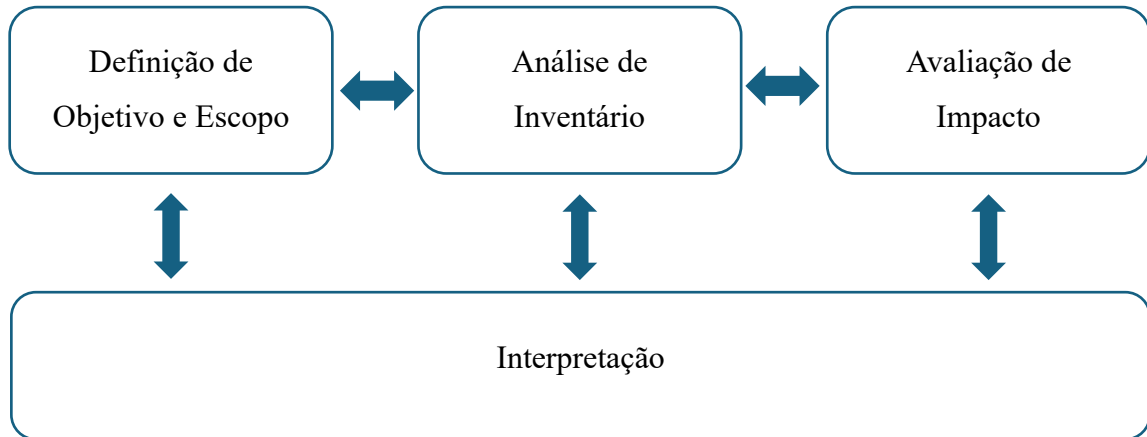
2.4. Contexto atual da ACV aplicada sobre a poluição do ar

A ACV emerge como uma metodologia sistemática usada para avaliar os impactos ambientais associados a todas as etapas de vida de um produto ou serviço, desde a extração de matérias-primas até a disposição final.

Essa técnica é normatizada pela ABNT ISO 14040:2009, sendo um método padronizado internacionalmente, que tem por função a quantificação de todas as emissões, recursos e impactos causados através da produção de um produto ou serviço, podendo estar relacionada tanto com questões ambientais como questões de saúde humana (ABNT, 2009a; Giusti, 2021).

As etapas fundamentais da ACV incluem a definição de objetivos e escopo, análise de inventário, avaliação de impacto e interpretação dos resultados (Figura 2).

Figura 2. Etapas da ACV



Fonte: Adaptado de ABNT ISO 14040:2009.

A primeira fase da ACV envolve a definição clara dos objetivos e do escopo do estudo. Isso inclui determinar a extensão do estudo, o sistema a ser avaliado, e os limites do sistema, que podem ser críticos para o resultado da ACV. Esta fase também define as categorias de impacto que serão consideradas, as premissas chave, e os critérios para a qualidade dos dados (Dicks; Hent, 2015).

Já a análise de Inventário do Ciclo de Vida (ICV) é o coração da ACV, em que se quantificam as entradas e saídas de energia e materiais do sistema. Isso inclui todas as emissões para o ar, água, e solo associadas com o produto ao longo de sua vida útil. A precisão nesta fase é de extrema importância, pois erros ou omissões podem afetar significativamente os resultados da ACV (Fnais *et al.*, 2022; Zargar; Yao; Tu, 2022). A complexidade da coleta de dados e a escolha de métodos de alocação são desafios comuns nesta etapa (Parvatker; Eckelman, 2019).

Após isso, durante a Avaliação de Impacto de Ciclo de Vida (AICV), os dados coletados na ICV são convertidos em impactos ambientais potenciais utilizando FCs para diferentes categorias de impacto, como mudanças climáticas, toxicidade, uso de recursos, formação de MP entre outros (Bare, 2010). Esta fase avalia o significado dos dados do inventário em termos de contribuição para impactos ambientais, utilizando para isso FCs para cada categoria.

De acordo com Oliveira et al. (2021), os FCs possuem uma estrutura genérica em que é calculado como o produto de três variáveis, o fator de destino, do qual avalia como a substância se dispersa e se distribui em diferentes ambientes, como água, solo, ar etc., o fator de exposição, que considera a concentração da substância no ambiente e a forma como os organismos ou humanos interagem a esse ambiente e o fator de efeito, que se baseia na toxicidade da substância e na sensibilidade dos organismos ou ecossistemas afetados.

A equação 1 traz uma estrutura genérica aplicada nas diferentes categorias de impacto relacionadas às emissões, com modificações que variam de acordo com cada categoria de impacto (Oliveira *et al.*, 2021).

$$I = \sum_i \sum_x FC_{x,i} \times E_{x,i} \quad (1)$$

Em que I é o impacto potencial; $FC_{x,i}$ é o fator de caracterização da substância x emitida para o compartimento i ; e $E_{x,i}$ é o fluxo registrado no ICV, ou seja, a emissão da substância x para o compartimento i .

Modelos de impacto são aplicados para rastrear os efeitos ambientais e transformar os fluxos de inventário em indicadores de impacto (Bulle *et al.*, 2019; Verones *et al.*, 2020). Desenvolvimentos recentes nesta área incluem a expansão das categorias de impacto e a melhoria dos métodos de modelagem para refletir mais precisamente os impactos reais (Iswara *et al.*, 2020)

A última fase da ACV, a interpretação, envolve sintetizar os resultados das fases anteriores para formular conclusões, recomendações e identificar áreas para melhoria. Nesta etapa, avalia-se a consistência e a completude dos dados e processos usados, e realiza-se uma análise de sensibilidade para verificar a robustez dos resultados. Esta fase é crucial para garantir que as conclusões da ACV sejam confiáveis e fundamentadas em evidências robustas (Fnais *et al.*, 2022; Zargar; Yao; Tu, 2022)

Cada etapa requer considerações detalhadas para garantir que o sistema de produto ou serviço avaliado seja representativo e que os impactos ambientais sejam medidos com precisão. A análise de inventário compila todas as entradas e saídas relevantes, como emissões para o ar, que podem incluir poluentes atmosféricos como MP e gases de efeito estufa. A fase de avaliação de impacto então, vincula essas entradas e saídas a categorias de impacto ambiental, incluindo potenciais de aquecimento global e a categoria de formação de MP (Finnveden *et al.*, 2009; Fnais *et al.*, 2022).

Com isso, a ACV serve não apenas como ferramenta de medição, mas como um facilitador na criação de políticas e práticas industriais mais sustentáveis devido a sua visão holística do todo, ajudando a identificar onde intervenções podem ser mais eficazes para reduzir emissões nocivas em diferentes fases do ciclo de vida de produtos e serviços.

2.4.1. ACV aplicada à poluição atmosférica

A ACV se apresenta como uma ferramenta essencial para analisar os impactos da poluição do ar e, conseqüentemente, da poluição por MP associados a processos produtivos e de consumo, visando entender e mitigar a poluição do ar. Essa importância é dada pois, segundo Bulle et al. (2019) a categoria de impacto de mudanças climáticas e a categoria de formação de MP possuem as maiores contribuições globais quando tratado de saúde humana.

Deste modo, ao longo dos anos, diversos estudos têm utilizado esta metodologia para explorar diferentes setores e produtos abordando a poluição atmosférica. Por exemplo, o estudo realizado por Shang et al. (2024) implementou a ACV para investigar o impacto ambiental da produção em larga escala de veículos elétricos na China. A análise abordou as diferenças nas emissões de poluentes atmosféricos e gases de efeito estufa entre veículos elétricos e veículos com motores de combustão interna, ao longo de um ciclo de vida completo. Os resultados indicam que os veículos elétricos reduzem as emissões de CO₂ em 12%, NO_x em 69% e COVs em 9% em comparação com os veículos com motores de combustão interna. Contudo, enfrentam desafios significativos devido ao impacto das emissões na fase de produção de materiais, especialmente as baterias de lítio.

De mesmo modo, o trabalho conduzido por Ali et al. (2024) explora a conversão de resíduos orgânicos em bioplásticos utilizando microrganismos produtores de bioplásticos. Apesar dos bioplásticos oferecerem redução significativa na pegada de carbono e auxiliarem na gestão de resíduos sólidos, a produção em escala industrial ainda enfrenta desafios devido aos custos elevados e à necessidade de melhorias na força mecânica dos produtos.

Já o estudo de Chan et al. (2023) analisou as sinergias entre a redução de poluentes atmosféricos e emissões de gases de efeito estufa em uma empresa integrada de ferro e aço na China. Utilizando a ACV, o estudo quantificou os efeitos sinérgicos entre os impactos ambientais dos poluentes atmosféricos e dos gases de efeito estufa sob diferentes cenários. Os resultados demonstraram que, enquanto o cenário de redução abrangente de emissões combinou as melhores práticas dos outros dois cenários para melhor coordenar as emissões de poluentes atmosféricos e gases de efeito estufa, cada cenário apresentou uma complexa matriz de *trade-off*³ e benefícios ambientais. A pesquisa destaca a importância de considerar as interações entre

³ *Trade-off* é um termo da língua inglesa que define uma situação em que há conflito de escolha. Ele se caracteriza em uma ação econômica que visa à resolução de problema, mas acarreta outro, obrigando uma escolha.

diferentes tipos de emissões e a eficácia das políticas de emissões em contextos industriais específicos.

Entre os vários estudos que exploram a aplicação da ACV para entender os impactos da poluição atmosférica, um foco particular tem sido dado a categoria de formação de MP, trazendo à tona os desafios e limitações ao se estudar tal área. Como por exemplo, o trabalho desenvolvido por (Li *et al.*, 2023) aborda a ACV de resíduos de construção e demolição, enfocando os desafios e limitações da ACV na avaliação de poluição atmosférica. O estudo destaca que, embora a ACV seja uma ferramenta poderosa para entender os impactos ambientais ao longo do ciclo de vida de materiais e processos, existem desafios específicos quando aplicada à poluição atmosférica. Estes desafios incluem a dificuldade de quantificar precisamente as emissões de gases e partículas na atmosfera devido à variabilidade das práticas de construção e demolição, assim como as condições ambientais variáveis que afetam a dispersão e a transformação desses poluentes no ar.

As limitações identificadas também envolvem a falta de dados específicos e regionais que possam refletir com precisão as emissões em diferentes locais e sob diversas condições operacionais. Além disso, o estudo aponta para a complexidade de integrar múltiplos poluentes com diferentes características de impacto na saúde e no ambiente em uma única análise de ACV, o que pode levar a avaliações que subestimam ou superestimam os impactos reais.

De maneira similar, o trabalho de Aseel *et al.* (2021) foca na avaliação das emissões atmosféricas e dos impactos na saúde humana associados ao transporte marítimo de Gás Natural Liquefeito (GNL). Este estudo desenvolve um modelo de ACV para quantificar e analisar as emissões de poluentes e seus impactos sociais e de saúde decorrentes do uso de diferentes tipos de combustíveis em navios que transportam GNL. A pesquisa examina especificamente as emissões de dióxido de carbono, óxidos de nitrogênio e material particulado fino. Um dos principais desafios identificados é a necessidade de melhorar a precisão dos fatores de emissão usados nos modelos de ACV. Dado que os fatores de emissão podem variar significativamente dependendo do tipo de combustível e das tecnologias de motor usadas nos navios, a falta de dados específicos e atualizados pode levar a estimativas imprecisas do impacto ambiental e de saúde humana.

Além disso, a análise mostra que as variações nos resultados da ACV podem ser influenciadas pela localização geográfica das rotas de navegação e pelas regulamentações ambientais locais. Isso aponta para a necessidade de regionalizar os modelos de ACV para

refletir mais precisamente as condições locais e os regulamentos específicos que afetam as emissões de poluentes atmosféricos e os impactos na saúde humana.

Por fim, o estudo de Giusti et al., (2023) analisou os impactos na saúde humana das partículas emitidas por diferentes sistemas de produção de leite no Brasil por meio de uma análise de sensibilidade da ACV. Para isso, foram aplicados diversos modelos de caracterização para investigar os níveis de regionalização (global, nacional e regional) e suas influências nos resultados da ACV. Os resultados revelaram uma alta variabilidade nos impactos devido às diferenças nos inventários, abrangências geográficas e FCs utilizados.

Inclusive os autores salientam que a precisão dos resultados da ACV pode ser comprometida pela falta de dados regionalizados e específicos que refletem as emissões em diferentes locais e sob diversas condições operacionais. Isso é crucial porque a localização onde os fluxos elementares ocorrem pode ter uma grande influência nos resultados de impacto para cada categoria de impacto, tornando os métodos de ACV existentes inadequados se não considerarem FCs dependentes do local.

Por meio da ACV, é possível não apenas quantificar as emissões de poluentes atmosféricos e gases de efeito estufa, mas também analisar detalhadamente os impactos ambientais e de saúde em diferentes fases do ciclo de vida dos produtos e serviços. Os estudos destacados, desde a produção de veículos elétricos até a conversão de resíduos em bioplásticos, revelam como a ACV contribui para identificar e mitigar os desafios ambientais mais significativos.

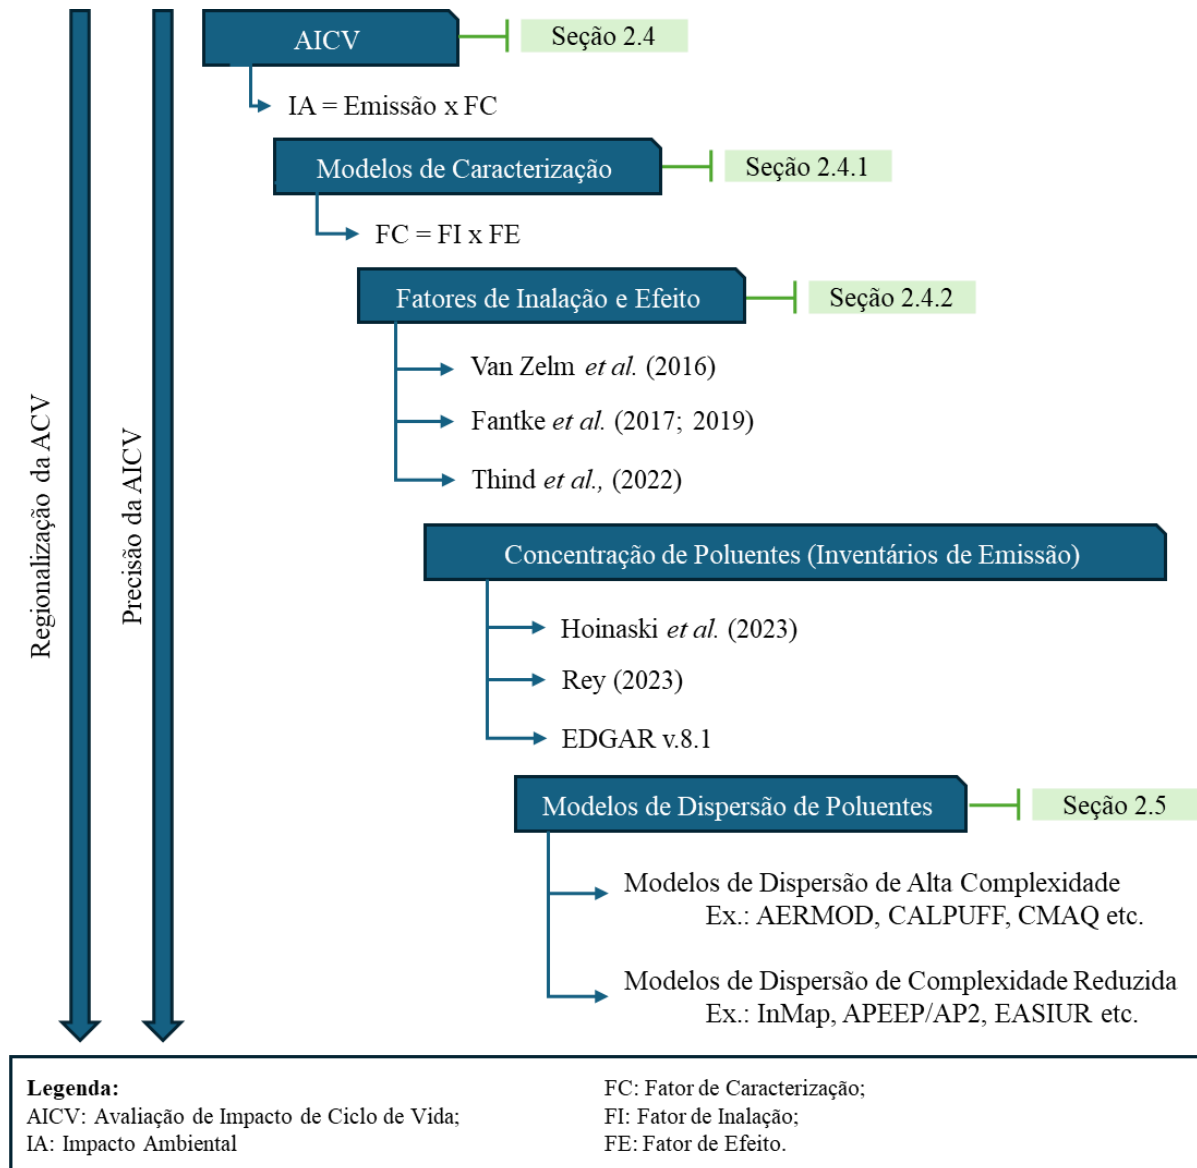
Entretanto, a área de formação de MP enfrenta vários desafios e dificuldades significativas, principalmente devido à complexidade dos processos envolvidos e à variabilidade das condições ambientais. Dentre os principais desafios encontrados nesta área estão a complexidade das fontes de emissão, já que podem variar significativamente dependendo do tipo de processo, das matérias-primas utilizadas e das tecnologias de controle de emissões empregadas (Chan *et al.*, 2023; Ortiz-Rojas *et al.*, 2024; Shang *et al.*, 2024), a falta de FCs regionalizados que reflitam os impactos considerando os tipos de partículas, variações temporais e espaciais, já que as emissões de MP são altamente dependentes das condições locais, como clima, topografia e padrões de vento (Giusti *et al.*, 2022, 2023; Thind *et al.*, 2022), a complexidade de integração do MP com outros poluentes, como óxidos de nitrogênio e compostos orgânicos voláteis, em uma única análise de ACV (Humbert *et al.*, 2011; Oberschelp; Pfister; Hellweg, 2020; Tran *et al.*, 2021), e por fim, a dificuldade na obtenção de dados confiáveis e representativos para o inventário de ciclo de vida é um desafio constante. Muitas

vezes, faltam dados específicos sobre as emissões de MP para certos processos ou regiões, o que pode levar a estimativas baseadas em suposições ou dados desatualizados (Ortiz-Rojas *et al.*, 2024; Portugal-Pereira *et al.*, 2016; Zhang *et al.*, 2023).

Deste modo, a fim de superar esses desafios e garantir a precisão na AICV, a utilização de modelos de dispersão atmosférica considerando as características e inventários regionais, se torna essencial. Esses modelos são fundamentais para estimar a distribuição espacial e temporal dos poluentes após sua emissão, permitindo uma análise detalhada da concentração de MP no ambiente.

A Figura 3 ilustra a importância dos modelos de dispersão na determinação dos FCs para a formação de MP na ACV, visto que é mostrado que dentro da AICV existem os modelos de caracterização, dos quais dependem dos FI e FE, que por sua vez, dependem das concentrações de MP_{2,5} (ou outro poluente atmosférico de interesse), calculadas a partir dos modelos de dispersão de poluentes atmosféricos.

Figura 3. Importância dos Modelos de Dispersão na Determinação dos Fatores de Caracterização para MP na AICV



Fonte: Autoria própria.

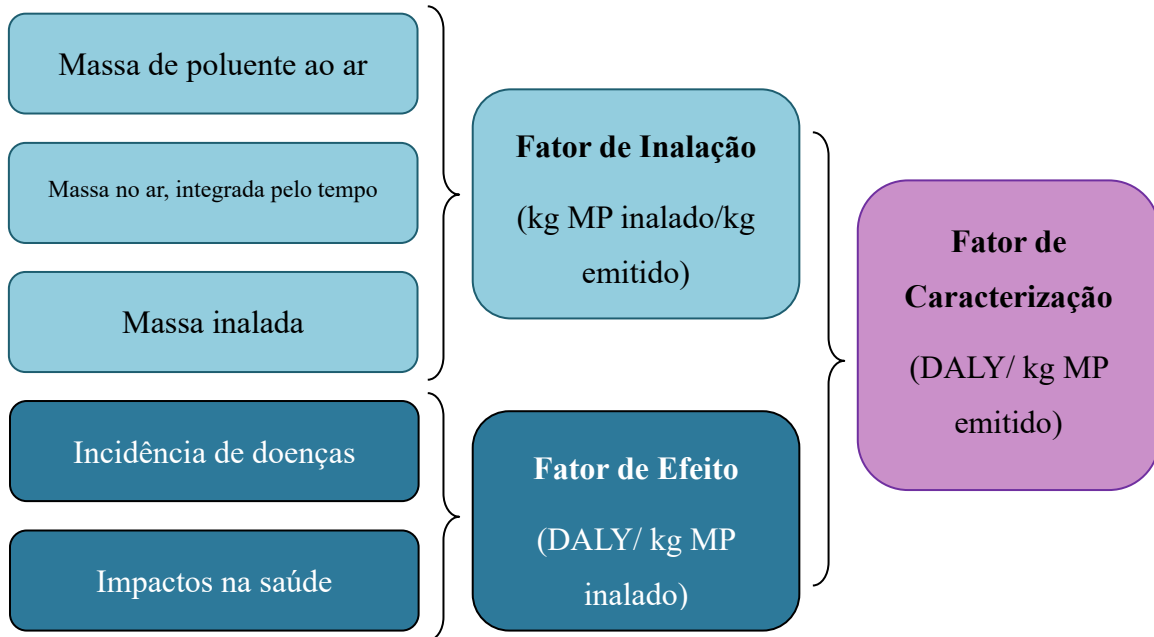
O fluxograma apresentado na Figura 3 destaca a relação entre a regionalização e a precisão na AICV, evidenciando como os modelos de dispersão de poluentes são cruciais para a regionalização dos FCs. A utilização de dados de dispersão regionais na criação dos FCs proporciona uma avaliação mais robusta, melhorando a qualidade dos dados e, conseqüentemente, a eficácia das políticas ambientais e das estratégias de mitigação.

Um dos principais desafios na categoria de formação de MP na AICV é a carência de FCs regionalizados (Giusti *et al.*, 2022; Kopp, 2024; Zhang *et al.*, 2023). Os FCs são coeficientes que traduzem a magnitude do impacto ambiental de uma substância emitida no ambiente (ABNT, 2009b, 2009a). Eles são essenciais para a AICV, pois fornecem uma

quantificação dos potenciais impactos ambientais associados a cada etapa do ciclo de vida de um produto ou serviço (Humbert; Fantke; Jolliet, 2015).

Os FCs são obtidos por meio de modelos de caracterização, que consideram o caminho ambiental (cadeia de causa e efeito) Humbert; Fantke; Jolliet, 2015). Para a categoria de formação de MP, a cadeia de causa e efeito é dada conforme a Figura 4.

Figura 4. Cadeia de causa e efeito para a formação de MP em AICV



Fonte: Adaptado de Fantke et al. (2015)

A Figura 4 ilustra a cadeia de causa e efeito de MP. O processo começa com a massa de poluente emitida ao ar, que consiste em emissões primárias ou secundárias de MP. Esta massa de poluente, quando integrada ao longo do tempo, permite medir a variação da concentração de MP no ambiente. Quando o MP atinge uma população, uma parte dele é inalada. A quantidade de massa inalada em relação à massa emitida define o Fator de Inalação (FI) desta categoria, expresso em kg de MP inalado por kg de MP emitido.

Uma vez inalado, o MP pode causar doenças, afetando negativamente a saúde humana. A avaliação do impacto na saúde, em relação à massa de MP inalada, define o Fator de Efeito (FE), expresso em DALY (*Disability-Adjusted Life Years*) por kg de MP inalado. O DALY representa a quantidade de anos de vida perdidos devido à incapacidade causada por doenças.

Por fim, o FCs para a formação de MP é obtido pela multiplicação do FI pelo FE, como mostrado na Equação 2. O FCs é geralmente medido em unidades de DALY por kg de MP emitido. Essa métrica quantifica o impacto total na saúde humana para cada unidade de MP

emitido no ambiente, proporcionando uma medida integrada do risco e do dano causado pelas emissões de MP.

$$FC = FI \times FE \quad (2)$$

De maneira geral, os modelos de caracterização apresentam duas abordagens para analisar a formação de MP. A primeira é no nível de ponto intermediário (*midpoint*). Nesta abordagem, os FCs são calculados em uma fase intermediária do impacto, antes de se converterem diretamente em danos específicos. Nesse caso, a unidade de referência para medir o FCs é dada, por exemplo, em kg equivalente de MP_{2,5} por kg de MP emitido (Hauschild et al., 2013; Huijbregts et al., 2017; Humbert; Fantke; Jolliet, 2015).

A segunda abordagem, mais frequente, é no nível de ponto final (*endpoint*), em que os FCs são calculados considerando diretamente os danos finais à saúde ou ao meio ambiente, como anos de vida ajustados por incapacidade (DALY) por kg de MP emitido (Huijbregts et al., 2017; Humbert; Fantke; Jolliet, 2015).

Para calcular os FCs para a formação de MP, são utilizados diferentes modelos de caracterização, cada um com suas metodologias e abordagens específicas. Entre os modelos mais utilizados estão o USEtox (Rosenbaum *et al.*, 2008), o *Intake Fraction* (iF) (Humbert *et al.*, 2011), o modelo da EPA (U.S. EPA, 2024) e o IMPACT World+ (Bulle *et al.*, 2019).

O USEtox é amplamente reconhecido por sua robustez na avaliação de toxicidade humana e ecotoxicidade. Este modelo utiliza fatores de inalação e efeito baseados em avaliações toxicológicas e dados de exposição humana para quantificar os impactos em termos de DALY por kg de MP inalado (Rosenbaum *et al.*, 2008).

O modelo *Intake Fraction* (iF) estima a fração de uma substância emitida que é efetivamente inalada pela população exposta. Este modelo é particularmente útil em contextos urbanos e industriais, onde a proximidade das fontes de emissão e a densidade populacional são elevadas (HUMBERT et al., 2011).

A *Environmental Protection Agency* (EPA) dos EUA oferece diversos modelos para a avaliação dos riscos associados à exposição a poluentes atmosféricos. Esses modelos fornecem uma base detalhada para o cálculo dos fatores de inalação e efeito, utilizando dados de dispersão atmosférica e epidemiológicos para correlacionar a exposição ao MP com efeitos adversos à saúde (U.S. EPA, 2024).

O IMPACT World+ é uma extensão do modelo IMPACT 2002+ e oferece uma abordagem global e regionalizada para a caracterização de impactos ambientais. Este modelo integra dados específicos de diferentes regiões para fornecer uma avaliação mais precisa dos impactos, considerando variabilidades regionais como condições meteorológicas, topografia e densidade populacional (BULLE *et al.*, 2019).

A regionalização dos FI e FE é essencial para aumentar a precisão dos modelos de caracterização. As características regionais influenciam significativamente a dispersão e a concentração de MP, bem como os impactos na saúde humana. Portanto, a regionalização permite capturar essas variabilidades, proporcionando resultados mais precisos e relevantes para a formulação de políticas ambientais e estratégias de mitigação (Fantke *et al.*, 2015; Jolliet *et al.*, 2003).

2.4.2. Modelos de caracterização e Determinação dos Fatores de Inalação e Efeito (FI e FE)

Um dos primeiros modelos a abordar a caracterização dos impactos do MP na saúde humana foi desenvolvido por Hofstetter (1998). Posteriormente, diversos modelos foram criados para diferentes contextos geográficos, como por exemplo o de Bare (2011) e Humbert *et al.* (2011) para a América do Norte, o de Hauschild e Potting (2005) e Van Zelm *et al.* (2008) para a Europa e o de Itsubo e Inaba (2012) para o Japão.

Recentemente, foram introduzidos modelos regionalizados que levam em consideração as particularidades locais. Entre estes, destacam-se os estudos de Fantke *et al.*, (2017, 2019), que exploram nuances regionais e fornecem uma perspectiva mais detalhada sobre os impactos do MP, com base em dados de 3448 cidades do mundo. Oberschelp, Pfister e Hellweg (2020) e Tang *et al.* (2018) também contribuíram com modelos que incorporam dados regionais específicos, proporcionando uma análise mais precisa. Além disso, Van Zelm *et al.* (2016) ampliaram suas pesquisas anteriores para incluir considerações regionais, dividindo o globo em 56 regiões.

Os modelos de caracterização utilizam duas abordagens principais: geográfica e arquetípica (Mutel *et al.*, 2019; Van Zelm *et al.*, 2016). Na abordagem geográfica, os FCs são agrupados em áreas delimitadas geograficamente, adaptando a avaliação de impactos às condições específicas de cada região, como clima, densidade populacional, topografia e uso do solo para avaliar como os poluentes se dispersam e impactam o meio ambiente (Azapagic; Pettit; Sinclair, 2007; Bulle *et al.*, 2019; Kounina *et al.*, 2014).

Enquanto a abordagem arquetípica simplifica a modelagem ao agrupar regiões com características semelhantes ou de fontes de emissão com características similares. Nessa abordagem, os FCs são agrupados em compartimentos, como áreas urbanas e rurais, ambientes internos e externos. Os arquétipos podem ser baseados em fatores como tipo de indústria, densidade populacional ou características climáticas. Um exemplo é o uso de arquétipos industriais para avaliar a emissão de poluentes em diferentes setores produtivos (Ciuffo; Sala, 2013; Hawkins; Mumovic, 2017; Kounina *et al.*, 2019).

Um estudo realizado por Giusti *et al.* (2022) avaliou os modelos existentes para a caracterização dos impactos na saúde humana causados pela formação de MP. Ao todo foram analisados 16 modelos, em que foi analisada a aplicabilidade destes modelos no contexto brasileiro, usando a técnica de avaliação multicritério simples (*SMART*) para analisar a robustez científica, abrangência e valores dos FI e FE para o Brasil. Os resultados indicaram que os modelos mais recentes com cobertura global e disponibilidade de FCs para o Brasil são os mais adequados, sendo eles os modelos de van Zelm *et al.* (2016), Fantke *et al.* (2017, 2019) e Oberschelp *et al.* (2020), entretanto limitações importantes foram observadas, incluindo a falta de regionalização mais detalhada e a ausência de fatores para precursores de MP nos modelos mais aplicáveis.

Visando o detalhamento dos modelos recomendados para o Brasil, de acordo com Giusti *et al.* (2022), nas próximas seções, serão apresentadas as metodologias para obtenção dos FI e FE nos modelos desenvolvidos por Oberschelp *et al.* (2020), Fantke *et al.* (2017, 2019) e Van Zelm *et al.* (2016).

Além desses modelos, será apresentado o modelo de Thind *et al.* (2022) que apresenta uma metodologia concisa. Este modelo utiliza o modelo de transporte químico InMAP para análises de alta resolução espacial, integra métricas de impacto na AICV, e introduz novas métricas como Capacidade Regulatória Disponível para Emissões Incrementais (ARCIE), Razão de FCs da Fonte e Razão de Impacto na Saúde da Atividade (AHI), sendo aplicável a diversas fontes de emissão e relevante para o setor de bioenergia. Esses fatores tornam o modelo de Thind *et al.* (2022) relevante e aplicável ao contexto brasileiro.

2.4.2.1. Modelo de Fantke *et al.* (2017;2019) para Obtenção de FI e FE

O modelo proposto por Fantke *et al.* (2017;2019) proporciona uma estrutura abrangente para quantificar os efeitos na saúde humana devido à exposição a material particulado fino (MP_{2,5}) em diferentes contextos ambientais. Este modelo segue uma estrutura da qual pode-se

chamar de híbrida, em que é usado uma abordagem por arquétipos que diferencia ambientes internos e externos, urbanos e rurais, além da abordagem geográfica que integra variáveis de poluição de fundo e condições meteorológicas locais, usando uma grade de resolução de $0,25^\circ \times 0,25^\circ$ para calcular os FCs regionais.

Os FE e FI são calculados utilizando uma série de coeficientes de taxa e fatores de exposição humana. A metodologia inclui uma abordagem de balanço de massa baseada em equações diferenciais de primeira ordem. A Equação 3 apresenta os dados para calcular o FI:

$$FI_{O,U} = 10^{-1,84} \times DR^{0,876} \times 10^{1,1016 \times \log(POP)} \times POP^{-0,1016} \quad (3)$$

Em que FI é o fator de inalação em função das emissões e exposições em ambientes externos (*outdoor - o*) urbanos (*urban - u*), DR é a taxa de diluição atmosférica em m^2/s e POP é a população da área estudada.

Já os FE são derivados da concentração de exposição ao $MP_{2,5}$, utilizando a função de resposta integrada de exposição (IER) do *Global Burden of Disease* (GBD). Para tal, é utilizada a Equação 4 para FE Marginal, em que quantifica o impacto incremental de uma pequena mudança na concentração de MP sobre a saúde humana. Ele mede a variação na resposta de saúde para uma mudança marginal (muito pequena) na exposição ao poluente, e Equação (5) para FE médio, que quantifica o impacto médio ao longo de uma faixa de concentrações de MP. Ele considera a variação na resposta de saúde para uma mudança na concentração de exposição desde um valor de referência até a concentração de interesse.

$$FE_{marginal} = \frac{\sum_j M_{i,r} \times SF_{i,r} \times (RR_i(C_j) - 1)}{I} \quad (4)$$

Em que $EF_{marginal}$ é o fator de efeito marginal, $M_{i,r}$ é a mortalidade ou incidência de uma doença específica em ambientes internos (i) em áreas rurais (r), $SF_{i,r}$ é o fator de sensibilidade ou fração da população sensível à exposição em ambientes internos (i) em áreas rurais (r), $RR_i(C_j)$ é o risco relativo da doença i para a concentração C_j e, I é a Incidência total da doença na população.

$$FE_{médio} = \frac{\sum_j (M_{i,r}(C) - M_{i,r}(C_0)) \times SF_{i,r}}{I(C) - I(C_0)} \quad (5)$$

Em que $EF_{médio}$ é o Fator de efeito médio, $M_{i,r}(C)$ é mortalidade ou incidência de uma doença específica na concentração de interesse em ambientes internos (i) em áreas rurais (r),

$M_{i,r}(C_0)$ é mortalidade ou incidência da doença específica na concentração de referência em ambientes internos (i) em áreas rurais (r), $SF_{i,r}$ é o fator de sensibilidade ou fração da população sensível à exposição em ambientes internos (i) em áreas rurais (r), $I(C)$ é incidência total da doença na população na concentração de interesse e $I(C_0)$ é incidência total da doença na população na concentração de referência.

As principais incertezas nos modelos de Fantke *et al.* (2017; 2019) estão relacionadas à variabilidade espacial e à resolução dos dados. A resolução de $1^\circ \times 1^\circ$ utilizada em alguns casos pode não capturar adequadamente os picos de exposição em áreas urbanas densamente povoadas. Além disso, a falta de dados de alta resolução temporal e espacial para algumas regiões e a necessidade de maior detalhamento em áreas rurais representam limitações adicionais.

Para adaptar os modelos ao contexto brasileiro, são considerados dados específicos de densidade populacional e condições ambientais locais utilizando dados de 127 cidades brasileiras. Isso inclui ajustes nos arquétipos e parâmetros de troca de ar para refletir as características únicas das áreas urbanas e rurais no Brasil, como taxas de ventilação e ocupação de edifícios, além de levar em conta as condições climáticas brasileiras.

2.4.2.2. Modelo de Van Zelm *et al.* (2016) para obtenção de FI e FE

O modelo de Van Zelm (2016) foi desenvolvido para abrangência global, e para obtenção dos FCs, os autores utilizaram o modelo de transporte químico TM5-FASST (*Fast Scenario Screening Tool for Global Air Quality and Instantaneous Radiative Forcing*) com resolução espacial de 100×100 km, e ao final, dividiram o globo em 56 regiões.

Neste modelo, o FCs para danos à saúde humana é composto pelos fatores de inalação, efeito e dano (Equação 6)

$$FC_{HH,k,x,i} = \sum_j \left((iF_{k,x,i-j}) \times \sum_e (EF_{e,k,j} \times DF_{e,k,j}) \right) \quad (6)$$

Em que, os índices subscritos ‘ x ’, ‘ k ’, ‘ i ’, ‘ j ’ e ‘ e ’ referem-se, respectivamente à substância emitida, poluente atmosférico, região emissora, região receptora e efeito na saúde, como ilustrado na Figura 5. Sendo assim, $iF_{k,x,i-j}$ é o fator de inalação, adimensional; $EF_{e,k,j}$ é o fator de efeito, mensurado em kg^{-1} , e; $DF_{e,k,j}$ é o fator de dano, mensurado em anos.

Figura 5. Esquematização do modelo Van Zelm (2016).



Fonte: Criado a partir de Van Zelm (2016)

A metodologia para calcular os FE inclui a utilização de dados epidemiológicos sobre mortalidade atribuída ao MP, focando nas doenças com maior impacto na saúde humana, como doenças respiratórias e cardiovasculares. O cálculo dos FE é baseado na integração dos riscos relativos específicos das doenças e na severidade dessas doenças (expressa em DALY), como mostrado na Equação 7.

$$FE_{e,k,j} = \frac{dINC_{k,j}}{dEXP_{k,j}} = \frac{CRF_{e,k,j}}{BR} = \frac{(RR_{e,k} - 1) \times MR_{e,j}}{(RR_{e,k} - 1) \times C_{k,j} + 1} \quad (7)$$

Em que, $CRF_{e,k,j}$ ($m^3/ano/kg$) é a função concentração-resposta; BR ($m^3/pessoa/ano$) é a taxa respiratória ($4.745 m^3/pessoa/ano$); $RR_{e,k}$ ($\mu g/m^3$) é o risco relativo (RR) de obter o efeito na saúde 'e', devido à exposição ao poluente 'k'; $MR_{e,j}$ (mortes/pessoa/ano) é a taxa de mortalidade pelo efeito na saúde 'e' na região receptora 'j', e; $C_{k,j}$ ($\mu g/m^3$) é a concentração média de fundo, do poluente 'k' em uma região receptora 'j'.

O FI representa a mudança na exposição do poluente 'k' na região receptora 'j' ($dEXP_{k,j}$), devido à mudança na emissão da substância 'x' na região emissora 'i' ($dM_{x,i}$), e é calculado

com base nas frações de ingestão derivadas das sensibilidades de concentração-emissão (dC/dM) obtidas de uma perturbação de emissão de 20%. A equação geral para FI (Equação 8) inclui a taxa de respiração da população exposta e a fração de tempo gasto em diferentes ambientes (interno e externo). A metodologia também considera as taxas de remoção do MP em diferentes compartimentos (por exemplo, perda por deposição em áreas rurais e urbanas).

$$FI_{k,x,i-j} = \frac{dEXP_{k,j}}{dM_{x,i}} = \frac{dC_{k,j} \times N_j \times BR}{dM_{x,i}} \quad (8)$$

Em que $dC_{k,j}$ é a mudança na concentração do poluente 'k' na região receptora 'j', N_j é o número de pessoas na região receptora 'j', e BR é a taxa de respiração média por pessoa (4.745 m³/pessoa/ano).

O fator de dano é calculado integrando a exposição ao poluente, a resposta da população e a população ou área atingida.

O modelo apresenta várias incertezas, principalmente devido à natureza não-linear da química do ozônio e à variabilidade geográfica dos dados epidemiológicos e de concentração de MP. As incertezas estão associadas às diferenças nas condições locais e à extrapolação de dados de estudos regionais para outras áreas. Além disso, o uso de métricas de concentração baseadas em limiares, adiciona incerteza significativa aos resultados, especialmente em regiões com grandes perturbações nas emissões.

O modelo de Van Zelm *et al.* (2016) leva em consideração características locais de emissão e de dispersão de poluentes. Porém, ao agregar os fatores mundiais em 56 regiões emissoras e receptoras, os autores consideram o Brasil como um território único, o que pode não ser o mais representativo em vista da heterogeneidade que existe no país. Para adaptar o modelo ao contexto brasileiro, seria necessário ajustar os FCs e as sensibilidades de concentração-emissão às condições específicas do Brasil, como taxas de mortalidade regionais, densidade populacional e características das emissões locais. Isso incluiria a consideração de dados epidemiológicos brasileiros e a regionalização dos fatores de risco com base em estudos realizados no país. A adaptação também envolveria a modificação dos parâmetros de remoção de MP para refletir as condições atmosféricas e de uso do solo no Brasil.

2.4.2.3. Modelo de Thind *et al.* (2022) para obtenção de FCs

O modelo proposto por Thind *et al.* (2022) estabelece um quadro e métricas para estimar o impacto das fontes de emissão na conformidade regulatória e na saúde humana, aplicáveis ao

planejamento da qualidade do ar e à AICV. Este modelo utiliza o *Intervention Model for Air Pollution* (InMAP), um modelo de transporte químico de complexidade reduzida que permite análises em alta resolução espacial, sendo ideal para estimar as concentrações médias anuais de $MP_{2,5}$ e os impactos na saúde decorrentes de mudanças incrementais nas emissões de poluentes.

Os FCs são apresentados como indicadores de ponto médio dos impactos na saúde por unidade de massa de poluente emitido. Além dos FCs, o modelo introduz três novas métricas: Capacidade Regulatória Disponível para Emissões Incrementais (ARCIE), Razão de FCs da Fonte e Razão de Impacto na Saúde da Atividade (AHI). Essas métricas permitem uma análise espacialmente explícita dos impactos do ciclo de vida das emissões.

A ARCIE é uma métrica que quantifica a diferença entre a concentração de poluentes permitida pelas regulamentações e a concentração de poluentes em um local receptor (Equação 9).

$$ARCIE = [PX]_{regulado} - [PX]_{receptor} \quad (9)$$

Em que $[PX]_{regulado}$ é a concentração do poluente permitida pelas regulamentações, e $[PX]_{receptor}$ é a soma das concentrações de fundo das concentrações incrementais do novo emissor.

Já os FCs são utilizados para quantificar os impactos na saúde causados pelas emissões de poluentes, calculados a partir da Equação 10.

$$FC = \frac{Mortes\ prematuras}{Massa\ de\ poluente\ emitido} \quad (10)$$

As mortes prematuras são estimadas usando a função concentração-resposta (C-R) padrão.

A razão de FCs da fonte compara os impactos de saúde relativos das emissões de uma nova fonte com os impactos médios nacionais das emissões de baseline (Equação 11).

$$Razão\ de\ FC\ da\ Fonte = \frac{FC_{incremental, poluente, nova-fonte}}{FC_{baseline, poluente, domínioespacial}} \quad (11)$$

Em que o $FC_{incremental, poluente, nova-fonte}$ é o fator de caracterização das emissões incrementais do poluente na nova fonte e o $FC_{baseline, poluente, domínioespacial}$ é o fator de caracterização das emissões de *baseline* do poluente no domínio espacial.

Já a razão de impacto na saúde da atividade (AHI) quantifica os impactos na saúde por unidade de produto ou serviço, calculado pela Equação 12.

$$AHI = \frac{\text{Impacto na saúde do poluente}}{\text{Unidade de produto/serviço}} \quad (12)$$

Em que o impacto na saúde do poluente é a medida dos impactos na saúde devido à exposição ao poluente e a unidade de produto/serviço é a quantidade de produto ou serviço produzida pela atividade emissora.

Por fim, as mortes prematuras devido à exposição ao $MP_{2,5}$ são calculadas utilizando a equação 13.

$$\text{Mortes} = (e^{(\text{coef. linear } MP_{2,5} \times [MP_{2,5}])} - 1) \times P \times \frac{\text{Taxa de Mortalidade}}{100.000} \quad (13)$$

Em que o *Coefficiente Linear $MP_{2,5}$* é igual a $\ln(1,078) / 10 = 0,00751$, ou seja, um aumento de 7,8% no número de mortes prematuras para cada aumento de $10 \mu\text{g}/\text{m}^3$ na concentração de $MP_{2,5}$, $[MP_{2,5}]$ é a concentração de $MP_{2,5}$ e P é a população total.

As principais limitações do modelo de Thind *et al.* (2022) incluem a necessidade de dados detalhados de alta resolução temporal e espacial para estimativas precisas. Para adaptar o modelo ao contexto brasileiro, são necessários ajustes que considerem a densidade populacional específica e as condições ambientais locais, utilizando dados regionais brasileiros. Além disso, a metodologia requer a integração de dados locais de saúde e mortalidade para ajustar as funções concentração-resposta ao contexto brasileiro.

2.4.3. Implicações da regionalização dos FCs para políticas ambientais brasileiras

A disponibilização de FCs na AICV oferece uma vantagem significativa, pois diminui a necessidade de cada estudo criar seus próprios FCs. No entanto, quando existem múltiplos modelos para a mesma categoria de impacto, resultando em diferentes FCs para os mesmos fluxos elementares, é crucial escolher o modelo mais adequado aos objetivos específicos do estudo (RAICV, 2019).

No contexto brasileiro, a regionalização dos FCs é essencial devido à diversidade ambiental e socioeconômica do país. A formação de MP é um dos impactos ambientais críticos no Brasil, variando significativamente entre as regiões devido a fatores como densidade populacional, padrões industriais, uso do solo e clima (IBGE, 2015).

Por exemplo, na Amazônia, onde a principal fonte de MP é a queima de biomassa, políticas específicas de controle de queimadas e promoção de práticas agrícolas sustentáveis são mais eficazes (Imori *et al.*, 2011). Em áreas urbanas como São Paulo, as medidas focadas na melhoria do transporte público e na regulação de emissões veiculares são prioritárias. Estudos mostram que a qualidade do ar em regiões metropolitanas pode ser significativamente melhorada com a implementação de fatores de emissão aprimorados e políticas de transporte mais limpas (Andrade *et al.*, 2015).

Deste modo, a regionalização dos FCs tem implicações significativas para as políticas ambientais no Brasil apoiando a implementação de programas de monitoramento ambiental mais precisos, ajudando na alocação de recursos para áreas que apresentam maior risco ambiental. Modelos de inventário de emissões espaciais, como os desenvolvidos para fontes industriais no Brasil, demonstram a eficácia desta abordagem (Kawashima *et al.*, 2020).

2.5. Modelos de dispersão atmosférica

No contexto brasileiro, à medida que a ACV ganha destaque como ferramenta de suporte a decisões, surgem esforços significativos para regionalizar os FCs em categorias comuns da AICV (Giusti, 2021). Os FCs são métricas para quantificar o potencial impacto de uma substância ou atividade no meio ambiente ou na saúde humana. De maneira geral, os FCs transformam inventários de emissões em indicadores de impacto, permitindo comparar e agregar diferentes tipos de impactos ambientais e de saúde (RAICV, 2019).

Como mostrado nos tópicos 2.4.2.1, 2.4.2.2 e 2.4.2.3, os FCs estão estritamente relacionados com a quantidade de poluente inalado pela população e a quantidade de poluente emitido, exigindo assim, uma análise detalhada da concentração de poluentes na atmosfera, visto que, para determinar a exposição efetiva da população, é essencial considerar a dispersão atmosférica dos poluentes e as variações locais de concentração.

Sendo assim, a concentração de poluentes emerge como uma variável crítica para a quantificação dos FCs na categoria de formação de MP, já que essa variável é indispensável tanto no cálculo do FI quanto do FE, desempenhando um papel fundamental na avaliação acurada do impacto ambiental e na determinação dos riscos à saúde associados à presença de MP na atmosfera.

Os modelos de dispersão atmosférica desempenham um papel fundamental, permitindo estimar a dispersão de poluentes em diferentes cenários e regiões (MORAES, 2001). Esses

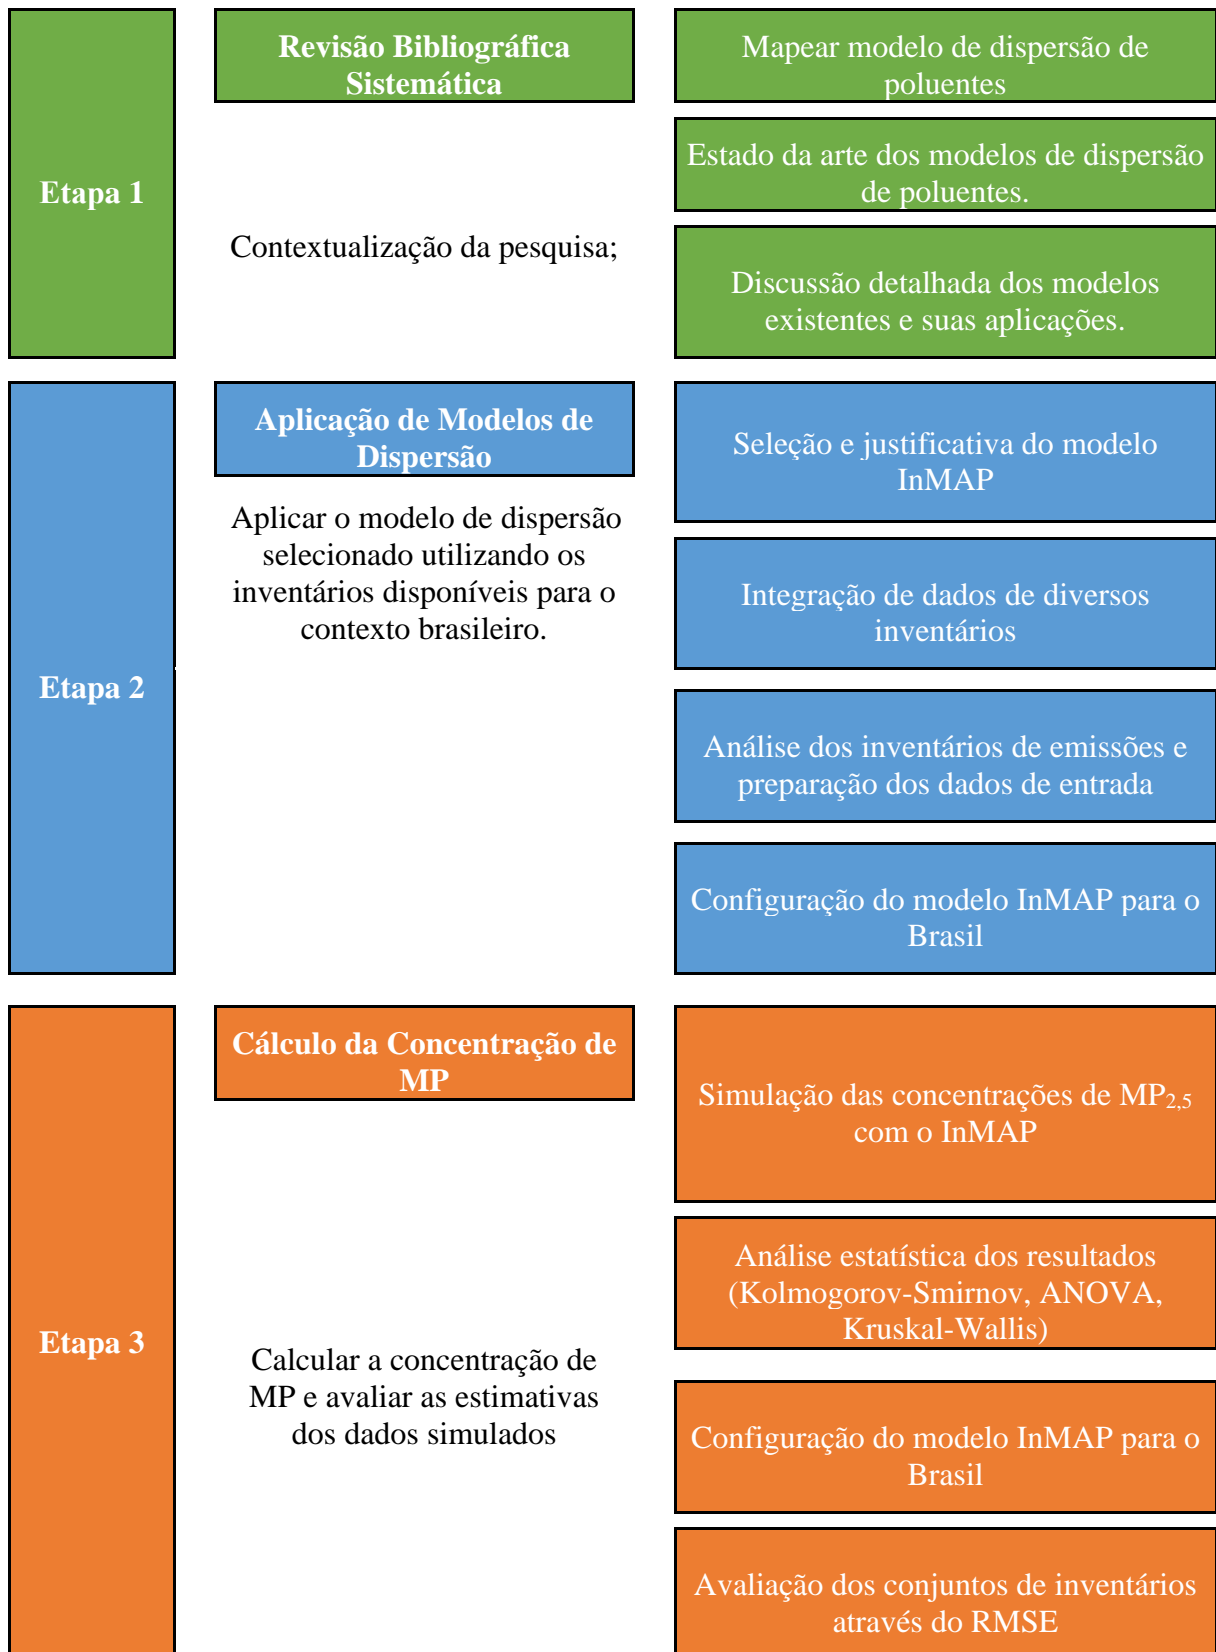
modelos são cruciais para a previsão da distribuição espacial e temporal dos contaminantes e para a avaliação da exposição da população a diversas substâncias nocivas. Além disso, constituem uma ferramenta decisiva na formulação de estratégias de mitigação, políticas de controle ambiental e no desenvolvimento de planos de gestão da qualidade do ar urbano e regional (Monks et al., 2009).

Por isso, na seção 4.1 são apresentados resultados sobre o Estado da Arte desses modelos de dispersão e a análise de sua aplicabilidade no contexto da avaliação de impactos na ACV.

3. Metodologia

A Figura 6 ilustra as principais etapas do estudo, desde a revisão bibliográfica sistemática até o cálculo de concentração de $MP_{2,5}$ avaliando as estimativas comparando com dados de monitoramento.

Figura 6. Fluxo Metodológico



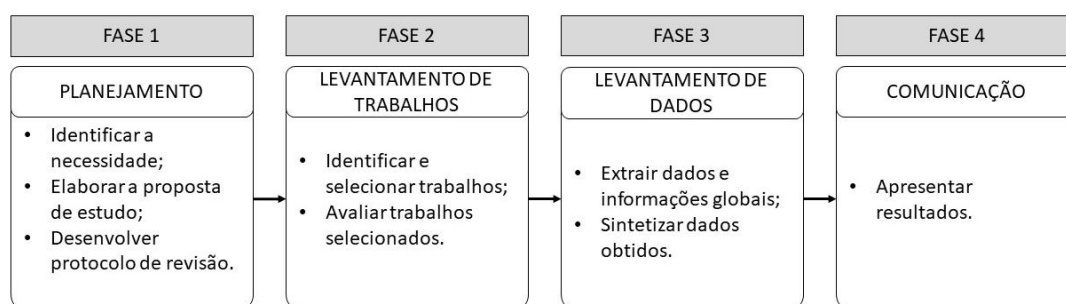
Fonte: Autoria própria.

Sendo assim, inicialmente, foi realizada a contextualização e o mapeamento dos modelos de dispersão atmosférica disponíveis para utilização no contexto brasileiro. Em seguida, o modelo selecionado foi aplicado aos inventários brasileiros de emissão de MP e seus precursores. Na sequência, calculou-se a concentração de MP e, por fim, foi avaliada a precisão dos resultados modelados por meio de uma análise de erro. Os detalhes sobre cada etapa estão descritos nas seções a seguir.

3.1. Revisão bibliográfica sistemática sobre modelos de dispersão atmosférica

O estado da arte ou revisão bibliográfica sistemática trata-se de um tipo de investigação focada em uma questão definida, a fim de identificar, selecionar, avaliar e sintetizar dados relevantes para a pesquisa em questão (Siddaway; Wood; Hedges, 2019). Com base nisso, foi elaborada uma Revisão Bibliográfica Sistemática (RBS) inicial, a fim de avaliar a produção científica sobre o tema de modelos de dispersão atmosférica no Brasil. Esse estudo foi dividido em quatro etapas, conforme ilustrado na Figura 7.

Figura 7. Fluxograma da RBS



3.1.1 Planejamento

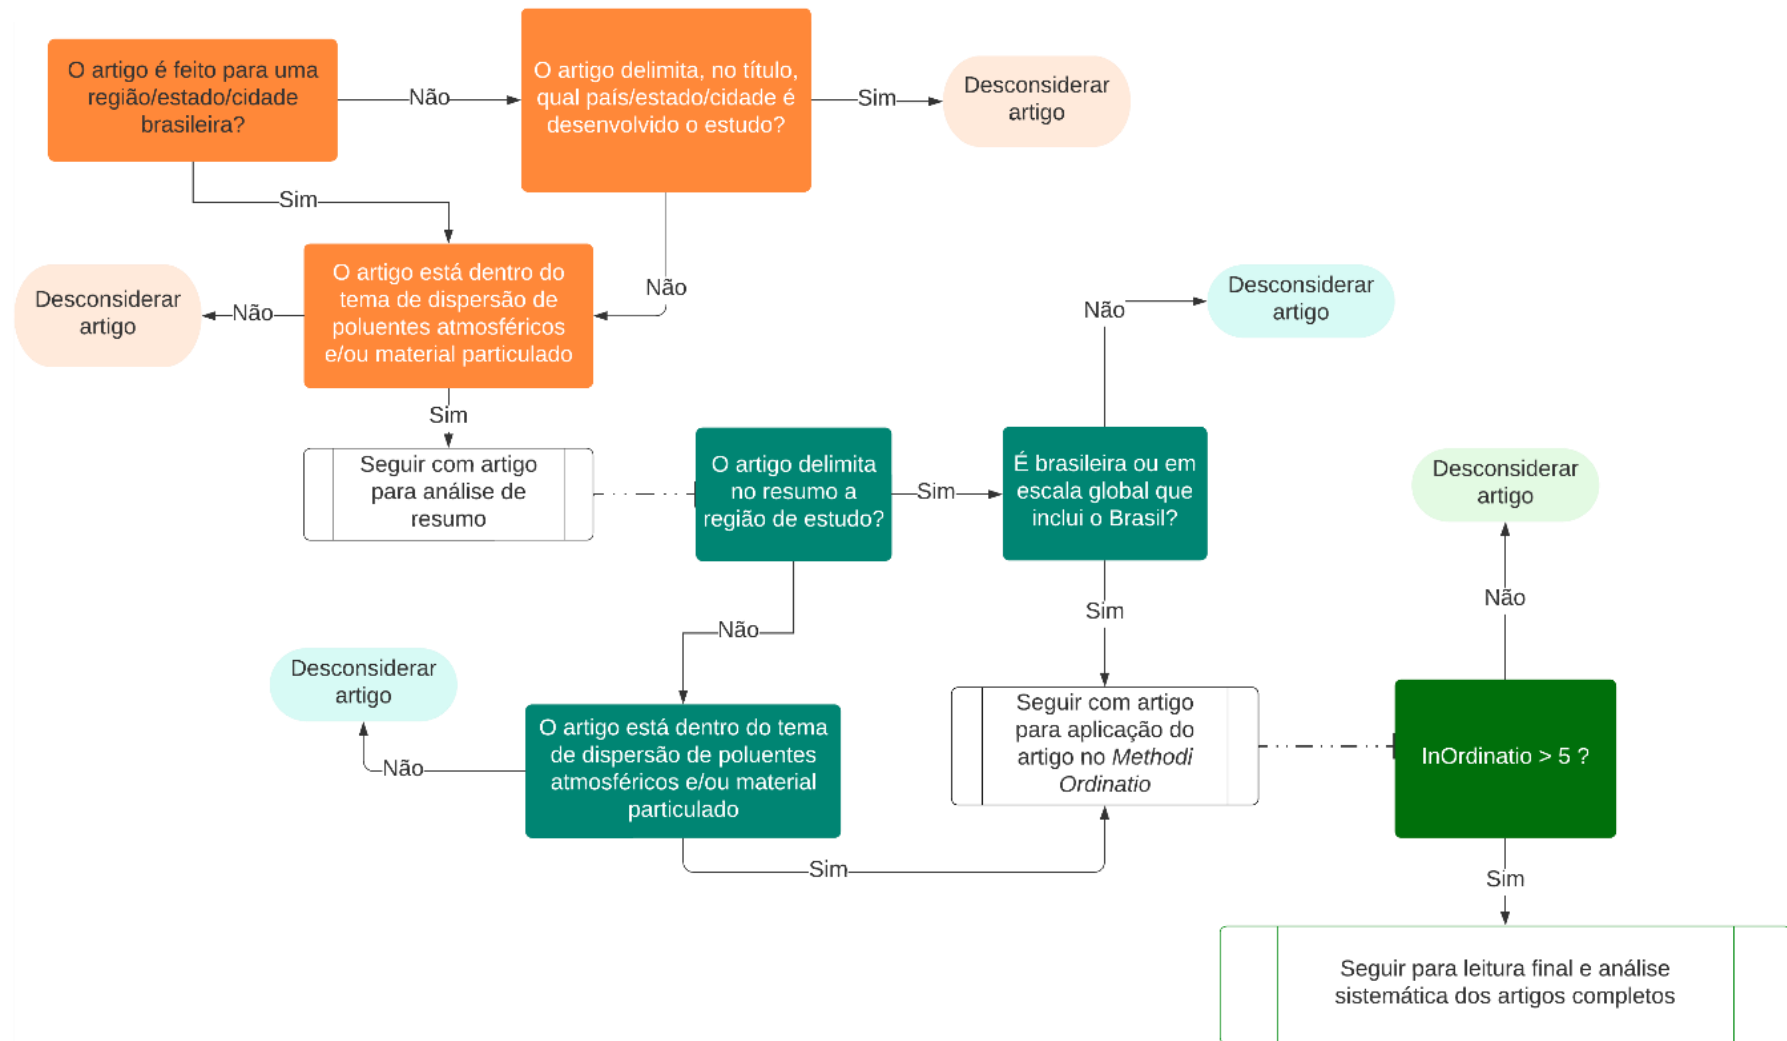
Na elaboração da RBS, foi aplicado o guia PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) (Moher *et al.*, 2015). A estrutura do guia PRISMA inclui uma lista de verificação de 27 itens essenciais, diretrizes específicas para a elaboração de resumos e diagramas de fluxo detalhados (Page *et al.*, 2021).

Foram estabelecidos critérios de inclusão para manter uma análise consistente na seleção de artigos, considerando a importância do tema e da localização do estudo, a utilização ou investigação de modelos de dispersão atmosférica, e a aplicação de modelos para quantificar a concentração de poluentes atmosféricos.

3.1.2 Levantamento de Trabalhos

A busca ocorreu no primeiro trimestre de 2023, considerando todos os artigos publicados antes disso, nas bases de dados *Web of Science* e *Scopus* empregando as palavras-chave "*Particulate Matter*", "*Transport models*" ou "*Dispersion models*" e "*Brazil*". Após a realização da busca bibliográfica nas bases de dados, procedeu-se à avaliação dos títulos e resumos dos artigos identificados. Essa etapa envolveu uma análise dos conteúdos à luz dos critérios de inclusão previamente delineados, conforme ilustrado na Figura 8. Os artigos que estavam em conformidade com o escopo do estudo e os critérios definidos foram escolhidos para avançar para a etapa seguinte de seleção. Nessa fase, o *Methodi Ordinatio* (Pagani; Kovaleski; Resende, 2015) foi empregado para categorizar os estudos de acordo com sua importância e qualidade.

Figura 8. Fluxograma do Processo de Seleção de Artigos para a RBS



Fonte: Autoria Própria.

O *Methodi Ordinatio* é uma metodologia multicritério de auxílio à decisão, tendo como característica a aplicação de uma fórmula quantitativa para a ordenação de artigos, chamada de *InOrdinatio*, que considera três fatores relevantes para classificar um artigo científico: o ano de publicação, o número de citações e o fator de impacto da revista.

A fórmula do *InOrdinatio* é expressa pela Equação 15:

$$\begin{aligned} InOrdinatio = & \left(\frac{IF}{1000} \right) \\ & + \alpha \times [10 - (Ano\ de\ pesquisa - Ano\ de\ publicação)] \\ & + \sum C_i \end{aligned} \quad (14)$$

em que: *IF* é o fator de impacto das revistas, conforme emitido pelo *Journal Citation Report* (JCR), *CiteScore*, *SCImago Journal Rank* (SJR) ou SNIP; α é o coeficiente cujo valor de importância é atribuído pelo pesquisador ao ano do artigo, variando de 1 a 10; *Ano de Pesquisa* é o ano em que a pesquisa está sendo realizada; *Ano de Publicação* é o ano em que o artigo foi publicado; C_i é o número total de citações do artigo.

Neste estudo, o fator de impacto foi obtido do *Journal Citation Report* (JCR) de 2022, e o coeficiente α atribuído foi o valor máximo de 10, para enfatizar a relevância dos artigos mais recentes na área de interesse. Por fim, vale ressaltar que na Equação 14, apenas os resultados acima de 5 foram considerados para a definição da amostra final de artigos. Isso se deve à necessidade de selecionar estudos com influência e reconhecimento significativos na comunidade científica. Os valores de *InOrdinatio* abaixo de 5 indicaram uma combinação de menor impacto na citação, idade avançada do artigo e/ou baixo fator de impacto da revista. A imposição de um limiar na pontuação garante que os artigos incluídos na amostra final sejam não apenas recentes, mas também tenham contribuído de maneira substancial para o avanço do conhecimento na área de modelos de dispersão atmosférica.

3.1.3 Levantamento de dados

Após a conclusão de todos os processos de filtragem, procedeu-se à análise dos artigos selecionados no software VOSViewer (VOSVIEWER, 2023). O objetivo dessa etapa foi avaliar a distribuição geográfica e as palavras-chave predominantes nos artigos escolhidos, a fim de validar tanto as palavras-chave utilizadas neste estudo quanto a seletividade junto a regionalização dos artigos.

Inicialmente, na condução da síntese dos dados, procedeu-se com a leitura integral de cada documento com o objetivo de alcançar uma compreensão abrangente do seu conteúdo. Esta leitura focou em elementos cruciais como o poluente estudado, a localização da pesquisa, os modelos de dispersão ou transporte atmosférico empregados, as características e métodos desses modelos, abordagens metodológicas para a regionalização do estudo, as principais limitações, além de sugestões e informações relevantes.

Os dados foram então, condensados e reformulados de forma a apresentar um resumo claro e conciso dos principais pontos de cada artigo ([Material Suplementar 1](#)).

Para a avaliação e classificação dos artigos, foram estabelecidos critérios específicos alinhados ao tema da pesquisa. Os critérios de avaliação incluíram:

- **Relevância do Estudo:** A relevância foi avaliada com base no alinhamento do foco do estudo com o tema da pesquisa. A relevância foi categorizada como alta, moderada ou baixa, dependendo da aplicabilidade direta do conteúdo do artigo ao contexto da pesquisa.
- **Qualidade Metodológica:** A robustez metodológica foi julgada com base na profundidade, validação e reconhecimento dos métodos empregados no estudo. Os artigos foram classificados como possuindo alta robustez, robustez moderada ou limitações metodológicas significativas.
- **Tipo de Modelo de Dispersão:** Identificou-se se o estudo utilizava modelos quantitativos, qualitativos ou mistos, com base na natureza das técnicas de modelagem e análise de dados adotadas.

Para efeito de conclusões e recomendações, de posse dos artigos caracterizados, foram sintetizadas as principais contribuições dessa pesquisa com efeito técnico, político e para pesquisas futuras na área.

3.1.4 Comunicação

Após a aplicação das palavras-chave, os artigos foram analisados individualmente aplicando filtros: eliminação de duplicidade; artigos com título e/ou resumo não relacionado à área e remoção de artigos com o índice *InOrdinatio* menor do que 5. Na Tabela 3 é apresentada detalhadamente a quantidade de artigos excluídas e a quantidade de artigos para leitura completa.

Tabela 3. Número de artigos antes e depois dos procedimentos de filtragem

| Procedimento de filtragem | Artigos selecionados | Artigos Excluídos | (%) |
|-------------------------------------------|----------------------|-------------------|------|
| Nº total de artigos | 773 | | 100% |
| Artigos duplicados | | 1 | 0,1% |
| Descartados após ler o título | | 501 | 65% |
| Descartados após resumo | | 134 | 17% |
| Descartados após <i>Methodi Ordinatio</i> | | 30 | 4% |
| Artigos de acesso fechado | | 7 | 1% |
| Total de artigos descartados | | 673 | 87% |
| Leitura completa | 100 | | 13% |

Fonte: Autoria Própria.

3.2. Seleção e Justificativa do modelo de dispersão

Com base na revisão bibliográfica realizada, para o desenvolvimento deste trabalho foi escolhido o modelo InMAP (*Intervention Model for Air Pollution*) para o cálculo de concentrações de $MP_{2,5}$. A escolha do modelo InMAP para este trabalho se baseia em uma série de vantagens técnicas e metodológicas que ele oferece, entre elas estão:

- a. **Precisão na Estimativa dos Impactos;**
- b. **Integração de Dados de Diversos Inventários;**
- c. **Resolução Espacial Flexível;**
- d. **Aplicabilidade em Diversos Contextos;**
- e. **Estima Mudanças Anuais Médias em $MP_{2,5}$;**
- f. **Menor Demanda Computacional.**

Este modelo se mostra essencial para a estimativa dos impactos na saúde humana associados às emissões de $MP_{2,5}$, considerando fontes primárias e secundárias do poluente, fornecendo fatores de caracterização específicos para fontes de emissão de área. Na seção 3.2.1 estão detalhadas as principais características do modelo de acordo com a sua documentação (InMAP, 2024).

3.2.1. Caracterização do Modelo InMAP

O InMAP (*Intervention Model for Air Pollution*) é um modelo multi-escala de avaliação de emissões e impactos na saúde relacionados ao $MP_{2,5}$. Este modelo realiza uma avaliação mecânica da qualidade do ar e dos benefícios à saúde resultantes de alterações nas emissões de base. Em comparação com modelos mais complexos, o InMAP utiliza uma média anual de

parâmetros, como taxas de transporte, deposição e reação, simplificando assim o processo de modelagem. Essa abordagem permite equilibrar a alta resolução espacial em áreas densamente povoadas e a eficiência computacional em regiões de menor densidade populacional.

3.2.1.1. Equações do Modelo

O InMAP utiliza um conjunto de equações para calcular as variações nas concentrações de $MP_{2,5}$, seus componentes e precursores, decorrentes de diferentes cenários de emissões, utilizando pré-processadores como o WRF-Chem e o GEOS-Chem. Esses pré-processadores são responsáveis por preparar os dados meteorológicos e de poluição necessários para a simulação. O WRF-Chem, por exemplo, converte várias espécies químicas e variáveis meteorológicas de suas unidades originais para unidades adequadas ao InMAP. As variáveis químicas incluem precursores de aerossóis orgânicos secundários (SOA), óxidos de nitrogênio (NO_x), óxidos de enxofre (SO_x), amônia (NH_3), e $MP_{2,5}$ total, entre outros.

Já o GEOS-Chem trabalha com os poluentes atmosféricos de entrada do modelo ($MP_{2,5}$, NH_3 , NO_x , SO_x e NMVOC) e parâmetros meteorológicos (como temperatura, pressão, fluxos de calor e vento). Esse pré-processador utiliza funções para ler e converter dados de variáveis químicas e atmosféricas, incluindo velocidades do vento, concentração de radicais hidroxila (OH^{\cdot}), temperatura, pressão, precipitação, entre outros. Além disso, utiliza mapas de uso do solo (como o mapa de Olson), para definir categorias de uso da terra, que afetam a deposição seca de gases e partículas.

O modelo permite a criação de variáveis de saída personalizadas, utilizando expressões matemáticas com variáveis já existentes. Por exemplo, a concentração total de $MP_{2,5}$ pode ser calculada pela equação 15:

$$MP_{2,5} Total = MP_{2,5} Primário + pNH_4 + pSO_4 + pNO_3 + SOA \quad (15)$$

Em que $MP_{2,5}$ primário representa a concentração de material particulado primário emitido diretamente; pNH_4 refere-se à concentração de partículas de amônio; pSO_4 corresponde à concentração de partículas de sulfato; pNO_3 refere-se à concentração de partículas de nitrato; SOA representa a concentração de aerossóis orgânicos secundários.

3.2.1.2. Uso de Precursores no InMAP

O InMAP considera diversos precursores de $MP_{2,5}$, incluindo NMVOC (compostos orgânicos voláteis não-metano), NO_x (óxidos de nitrogênio), NH_3 (amônia) e SO_x (óxidos de

enxofre). Estes precursores participam de reações químicas na atmosfera que resultam na formação de material particulado secundário. Por exemplo, NO_x e NMVOC contribuem para a formação de ozônio, que pode reagir para formar aerossóis orgânicos secundários (SOA). Da mesma forma, o NH₃ pode reagir com SO_x e NO_x, resultando na formação de partículas de nitrato e sulfato de amônio.

3.2.1.3. Funcionamento do Modelo

O InMAP utiliza uma grade de resolução variável, que ajusta o tamanho das células de acordo com a densidade populacional e a necessidade de maior precisão espacial. Esta abordagem permite a simulação de exposições populacionais ao MP_{2,5} com alta resolução em áreas urbanas, ao mesmo tempo em que minimiza o custo computacional. O modelo opera em um estado estacionário de média anual, calculando as concentrações médias anuais dos poluentes e seus respectivos impactos.

O processo de modelagem do InMAP inclui as seguintes etapas:

- **Especificação das Emissões:** As emissões são inseridas no modelo por meio de arquivos de dados em formatos como shapefile, SMOKE, ou COARDS NetCDF, contendo informações detalhadas sobre a localização, altura, temperatura e velocidade das fontes de emissão.
- **Configuração da Grade Espacial:** A grade espacial do modelo pode ser configurada de forma estática ou dinâmica. No modo dinâmico, o tamanho das células é ajustado periodicamente durante a simulação para aumentar a precisão em áreas de alta concentração populacional ou em regiões com grandes gradientes de concentração.
- **Configuração e Execução do Modelo:** O usuário configura o InMAP através de arquivos de configuração no formato TOML ou por meio de variáveis de ambiente. Estes arquivos definem os parâmetros da simulação, como as variáveis de saída, a extensão da grade espacial e os dados de entrada das emissões.

3.3. Coleta e padronização dos dados de inventário

Para a execução do modelo de dispersão do ar, foi realizada a coleta de dados de inventários de emissões disponíveis para o Brasil em cinco setores: agricultura, industrial,

transporte, queima de biomassa e emissões biogênicas. A seleção desses setores deve-se à disponibilidade de dados específicos para o Brasil.

Além disso, os setores selecionados são conhecidos por contribuírem de forma substancial para as emissões dos principais poluentes atmosféricos, como NH₃, Compostos Orgânicos Voláteis não-metano (NMVOC), SO_x, NO_x e MP_{2,5}. Estudos como o de Ervens (2015) demonstram que esses poluentes são frequentemente emitidos por atividades industriais e agrícolas. Monks et al. (2009) confirmam a importância do setor de transporte como uma fonte significativa desses poluentes. Ademais, Pu et al. (2019) destacam que a queima de biomassa e as emissões biogênicas são fontes críticas de NMVOC e MP_{2,5}.

Embora o setor agrícola não possua um inventário nacional, ele foi incluído devido à sua importância significativa no contexto das emissões no país (Mazzetto *et al.*, 2020). Sendo assim, os inventários analisados foram o *Fire Inventory from NCAR* (FINN) para o setor de queima de biomassa (Wiedinmyer *et al.*, 2023), *Brazilian vehicular emission inventory software* (BRAVES) para o setor de transporte (Hoinaski *et al.*, 2022), *Model of Emissions of Gases and Aerosols from Nature* (MEGAN) para o setor de emissões biogênicas (HOINASKI, 2022) e, para o setor industrial, foram analisados os inventários *industrial emission* (IND_BRAIN) (Hoinaski, 2022), o inventário de emissões elaborado por Kawashima et al. (2020) e o inventário elaborado por Rey (2023).

Além dos inventários nacionais, foi também utilizado o inventário global do EDGAR (*Emissions Database for Global Atmospheric Research*) versão 8.1, como referência comparativa para os setores industrial e de transporte, bem como para incluir o setor agrícola na análise. O uso do inventário EDGAR permite uma avaliação mais ampla e comparativa das emissões, fornecendo uma base sólida para análise e comparação com dados globais.

Após a obtenção dos inventários, que estavam em formato netCDF⁴, foi realizada a padronização dos arquivos de emissão. Como mostrado na Tabela 4, a resolução espacial dos *grids* dos inventários variava entre 0,1° x 0,1° e 20 km x 20 km. Para garantir a consistência dos dados, todos os arquivos foram ajustados para uma resolução espacial de 20km x 20km. Esse processo foi executado utilizando a ferramenta EPA ANTHRO_EMIS (NCAR, 2024; Pfister, 2014).

⁴ Arquivos netCDF (*Network Common Data Form*) são um formato de dados utilizado amplamente para a manipulação, armazenamento e compartilhamento de dados científicos, particularmente aqueles associados a séries temporais e dados espaciais multidimensionais.

Tabela 4. Características e distribuição dos inventários de emissão

| Setor | Inventário | Resolução Espacial | Referência |
|---------------------|------------|--------------------|--------------------------------------------|
| Agricultura | EDGAR v8.1 | 0,1° x 0,1° | (European Commission <i>et al.</i> , 2023) |
| | EDGAR v8.1 | 0,1° x 0,1° | (European Commission <i>et al.</i> , 2023) |
| Industrial | Kawashima | 0,1° x 0,1° | (Kawashima <i>et al.</i> , 2020) |
| | Rey (2023) | 0,1° x 0,1° | (Rey, 2023) |
| | IND BRAIN | 20km x 20km | (Hoinaski, 2022) |
| Transporte | BRAVES | 20km x 20km | (Hoinaski <i>et al.</i> , 2022) |
| | EDGAR v8.1 | 0,1° x 0,1° | (European Commission <i>et al.</i> , 2023) |
| Queima de Biomassa | FINN | 0,1° x 0,1° | (Wiedinmyer <i>et al.</i> , 2023) |
| Emissões Biogênicas | MEGAN | 20km x 20km | (Guenther <i>et al.</i> , 2012) |

Fonte: Autoria própria.

Após a utilização do EPA ANTHRO_EMIS, os arquivos netCDF foram convertidos para o formato *Shapefile*, compatível com o modelo InMAP, utilizando a linguagem *Python*. Nesse processo, também foram realizadas a conversão das unidades dos dados de emissão e a renomeação das variáveis, garantindo a compatibilidade com as configurações exigidas pelo modelo.

3.4. Análise de inventário

A análise dos inventários de emissões foi conduzida com o objetivo de comparar as emissões de poluentes entre diferentes fontes de inventário, especificamente nos setores de transporte e industrial, dos quais possuem diferentes inventários.

Os inventários BRAVES e EDGAR v8.1 foram utilizados para o setor de transporte e o IND_BRAIN, Rey (2023) e EDGAR v8.1 para o setor industrial. Os procedimentos analíticos seguiram uma sequência de passos baseada em métodos estatísticos para identificar variações significativas entre os conjuntos de dados. A análise foi realizada em *Python*, e os passos metodológicos incluíram:

I. Teste de Normalidade (Kolmogorov-Smirnov)

Inicialmente, os dados de emissão de cada inventário foram organizados em um *DataFrame* no *Python*, assegurando que os dados fossem categorizados adequadamente por tipo de fonte e localização geográfica. O teste de Kolmogorov-Smirnov foi aplicado para avaliar a normalidade das distribuições de emissões de cada inventário.

A determinação da normalidade dos dados orientou a escolha subsequente dos testes estatísticos para comparação entre os grupos.

II. Testes estatísticos

Para a análise dos dados provenientes de diferentes inventários, testes de semelhança foram utilizados com o objetivo de avaliar se as séries de dados são estatisticamente semelhantes ou apresentam diferenças significativas. Essas diferenças podem ser influenciadas pelos métodos variados de coleta de dados empregados em cada inventário.

A seleção do teste estatístico dependeu dos resultados do teste de normalidade e do número de conjuntos de dados analisados em cada setor:

- **Setor Industrial:** Dado que este setor apresenta mais de três conjuntos de dados, optou-se pelo uso da ANOVA (Análise de Variância) para dados normalmente distribuídos ou pelo teste de Kruskal-Wallis para aqueles não normalmente distribuídos. Esses testes permitiram a comparação das médias (ANOVA) ou das medianas (Kruskal-Wallis) das emissões entre os diversos inventários.
- **Setor de Transporte:** Com apenas dois conjuntos de dados disponíveis (BRAVES e EDGAR), o Teste *t de Student* foi aplicado para dados normalmente distribuídos, enquanto o Mann-Whitney U foi utilizado para dados não normalmente distribuídos. Esses testes focaram na comparação das médias ou medianas das emissões entre os dois inventários especificados.

Os testes foram realizados utilizando-se o *Python*, com base na normalidade dos dados previamente verificada, para assegurar a aplicação correta das técnicas estatísticas na análise das emissões.

1. Post-hoc

Uma análise post-hoc é frequentemente utilizada em estatística para realizar comparações múltiplas entre grupos após a identificação de diferenças significativas em um teste inicial. O objetivo é determinar quais pares de grupos apresentam diferenças significativas entre si. Neste estudo, ao identificar diferenças significativas nos testes de semelhança, caracterizadas por valores *p* iguais a zero, foi aplicada a análise post-hoc utilizando o teste de Dunn para identificar os inventários específicos onde essas diferenças ocorrem.

O teste de Dunn foi conduzido da seguinte forma: primeiramente, foi aplicado um teste de normalidade seguindo os critérios definidos na seção 3.4, tópico II, para verificar a presença

de diferenças estatisticamente significativas entre os inventários em geral. Dependendo dos resultados e das características dos dados, foi escolhido o teste de Dunn, um método não paramétrico amplamente utilizado para comparar múltiplos grupos após a realização de um teste global não paramétrico, como o Kruskal-Wallis, que sugere a existência de diferenças. Esse teste ajusta as comparações múltiplas, reduzindo a probabilidade de erros do Tipo I (falsos positivos), que aumentam com o número de comparações realizadas.

Os resultados do teste de Dunn são apresentados em uma matriz que varia de 0 a 1, onde a interpretação foca na similaridade entre grupos com base nesses indicadores. Cada linha e coluna da matriz representa diferentes grupos ou conjuntos de dados comparados entre si. O elemento (i, j) na matriz reflete o resultado do teste de Dunn entre o grupo i (linha) e o grupo j (coluna).

Um valor de '1' em uma posição (i, j) indica que não há diferença estatisticamente significativa entre os grupos i e j , com o p-valor ajustado sendo maior que o nível de significância definido (0,05), o que leva à não rejeição da hipótese nula de igualdade das medianas. Por outro lado, um valor de '0' indica que existe uma diferença estatisticamente significativa entre os grupos i e j , com o p-valor ajustado sendo menor que o nível de significância, permitindo rejeitar a hipótese nula de igualdade das medianas.

A diagonal principal da matriz (onde $i = j$) normalmente apresenta valores de '1', uma vez que um grupo comparado consigo mesmo sempre será considerado similar. A matriz também tende a ser simétrica, com os valores (i, j) iguais aos valores (j, i) , pois a comparação é bidirecional e a similaridade é uma relação recíproca.

Esse teste foi realizado utilizando linguagem Python e foi aplicado tanto na comparação entre os inventários do setor industrial quanto nos conjuntos de inventários simulados no InMAP apresentados na seção 3.6.

III. Visualização de Dados

Por fim, mapas foram elaborados para analisar a distribuição espacial das emissões de poluentes, permitindo uma compreensão mais profunda das variações e concentrações por região. Para a criação dos mapas, foram empregadas ferramentas do *software* QGIS Desktop v.3.28.10.

3.5. Configuração do Modelo InMAP

Quanto à configuração para execução do modelo InMAP, tem-se que o domínio de estudo abrange todo o território brasileiro. A resolução espacial foi definida pelo modelo com base na densidade populacional do Brasil. A resolução temporal adotada para o estudo é anual, permitindo a captura de variações sazonais e tendências de longo prazo.

Os arquivos de entrada foram formatados de acordo com os dados pré-estabelecidos pelo modelo e conforme especificado na documentação. A unidade dos dados de emissão foi padronizada em toneladas por ano. Os dados de entrada foram determinados com base nos inventários de emissões apresentados na Tabela 4.

3.6. Análise dos Conjuntos de Inventários (Erro quadrático médio)

Para avaliar a precisão e qualidade dos diferentes inventários, foram determinados seis conjuntos distintos, conforme demonstrado abaixo. Estes conjuntos foram configurados para representar diferentes combinações de fontes de dados para as emissões agrícolas, industriais, de transporte, queima de biomassa e emissões biogênicas.

Desse modo, os conjuntos são:

- **C_01:** Combinação dos inventários EDGAR para agricultura, Rey (2023) para setor industrial, BRAVES para transporte, FINN para queima de biomassa e MEGAN para emissões biogênicas.
- **C_02:** Combinação dos inventários EDGAR para agricultura, Rey (2023) para setor industrial, EDGAR para transporte, FINN para queima de biomassa e MEGAN para emissões biogênicas.
- **C_03:** Combinação dos inventários EDGAR para agricultura, EDGAR para setor industrial, BRAVES para transporte, FINN para queima de biomassa e MEGAN para emissões biogênicas.
- **C_04:** Combinação dos inventários EDGAR para agricultura, EDGAR para setor industrial, EDGAR para transporte, FINN para queima de biomassa e MEGAN para emissões biogênicas.
- **C_05:** Combinação dos inventários EDGAR para agricultura, BRAIN para setor industrial, BRAVES para transporte, FINN para queima de biomassa e MEGAN para emissões biogênicas.

- **C_06:** Combinação dos inventários EDGAR para agricultura, BRAIN para setor industrial, EDGAR para transporte, FINN para queima de biomassa e MEGAN para emissões biogênicas.

Nestes conjuntos, foi desconsiderado o inventário de Kawashima *et al.* (2020), pois de acordo com os autores, os dados de inventário não foram calculados considerando os fatores de controle determinados pela CETESB, superestimando assim, os dados de emissão do inventário em questão.

Cada um dos seis conjuntos de inventários foi inserido no modelo InMAP para simulação das concentrações anuais de $MP_{2,5}$. As simulações geraram dados anuais de concentração de $MP_{2,5}$ primário e secundário para cada conjunto de inventários.

Para fins de uma análise quantitativa de qual conjunto de inventários é mais representativo para o Brasil, os dados de monitoramento de 31 estações do estado de SP foram comparados com os dados simulados pelo InMAP através da Raiz do Erro Quadrático Médio (RMSE) entre as concentrações anuais simuladas pelo InMAP e as concentrações anuais de monitoramento observadas pela CETESB.

A fórmula para o cálculo do RMSE é:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^n (P_i - O_i)^2} \quad (16)$$

Onde P_i é a concentração simulada pelo InMAP no local i , O_i é a concentração observada pela CETESB no local i e n é o número total de locais de monitoramento.

Os dados simulados foram obtidos ao sobrepor as coordenadas geográficas das 31 estações de monitoramento com os resultados do InMAP, garantindo a correspondência exata entre os dados simulados e as localizações das estações. Com isso, os valores de RMSE foram calculados para cada conjunto de inventários.

Comparando os valores de RMSE, identificamos o conjunto de inventários que apresenta a menor discrepância entre as concentrações simuladas e observadas, indicando a configuração que mais se aproxima do cenário real, sendo esse conjunto determinado como o melhor conjunto de inventários a serem analisados para o cenário brasileiro.

4. Resultados e discussões


4.1. Estado da Arte dos Modelos de Dispersão Atmosférica no Brasil

Na Figura 9, é possível observar a distribuição da produção de artigos ao longo dos anos. Pode-se constatar um crescente interesse na área, principalmente no ano de 2021, em que 22 artigos foram publicados. É possível observar também a presença de dois períodos de aumento, um até 2010 e outro a partir de 2011. Esse crescimento após 2010 pode ser atribuído devido diversos fatores, como por exemplo, os avanços na modelagem computacional e análise de dados, que podem ter ampliado a capacidade dos pesquisadores para estudos mais detalhados e abrangentes.

Além disso, a conscientização global sobre questões ambientais e as regulamentações ambientais mais rigorosas no Brasil, como a criação do Programa Nacional de Controle de Emissões Atmosféricas (PROCONVE) de 2011 para veículos automotores, podem ter exercido influência. Mudanças regionais, como urbanização e industrialização, além da disseminação de informações por plataformas digitais e a colaboração internacional, também podem ter estimulado investimentos na pesquisa.

Vale ressaltar que o número de artigos publicados em 2023 é baixo visto que a pesquisa foi realizada no primeiro trimestre de 2023, sendo assim, abordando artigos publicados até este período.

Figura 9. Série histórica de publicações da RBS

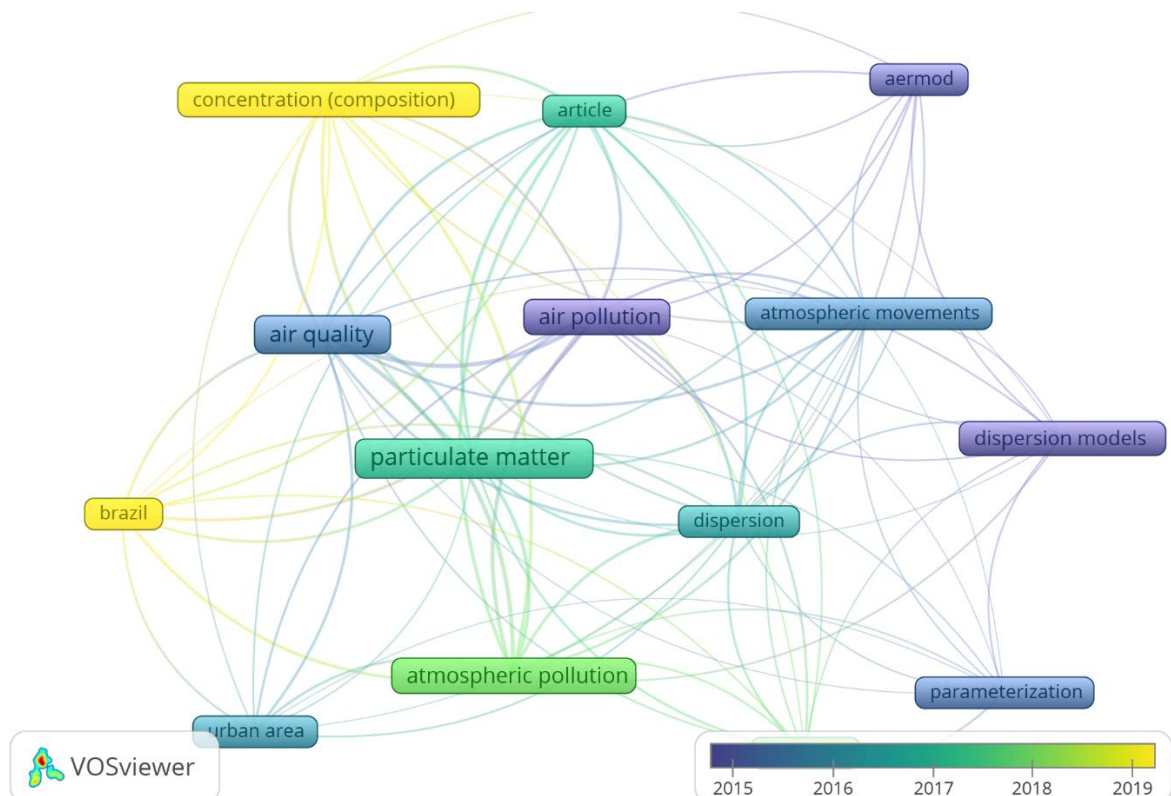


Fonte: Autoria Própria.

A análise das palavras-chave mais frequentes destaca termos que refletem a ênfase e a relevância do tema. Por exemplo, "*Particulate matter*" apareceu 41 vezes, ressaltando sua importância central. Além disso, termos como "*Air quality*" (31 ocorrências), "*Air pollution*" (29 ocorrências), "*Atmospheric Pollution*" (23 ocorrências) e "*Concentration (composition)*" (16 ocorrências) indicam uma atenção significativa à qualidade do ar e aos efeitos da poluição atmosférica. A presença frequente de termos como "*Dispersion models*" (16 ocorrências), "*pollution*" (14 ocorrências), "*dispersion*" (12 ocorrências) e "*AERMOD*" (10 ocorrências) válida a relevância da utilização de modelos de dispersão atmosférica na avaliação da concentração de MP. Esses termos estão em conformidade com os objetivos desta pesquisa, reforçando a aplicação prática de ferramentas para estimar e compreender a dispersão de poluentes na atmosfera.

Utilizando uma investigação bibliométrica e análise de rede para avaliar as interconexões temáticas e a evolução cronológica dos estudos, as visualizações geradas pelo *VOSviewer* (Figura 10 e Figura 11) fornecem um mapeamento sistemático das palavras-chave.

Figura 10. Análise Bibliométrica de Tendências e Conexões em Modelagem de Dispersão de Poluentes Atmosféricos (Temporal)



Fonte: Imagem gerada pelo autor utilizando o *software VOSViewer*, 2023.

A Figura 10 destaca revela *clusters* de pesquisa e o entrelaçamento e a progressão temporal das palavras-chave da RBS desenvolvida. É importante esclarecer que a análise temporal apresentada abrange o intervalo de 2015 a 2019, refletindo os anos de destaque para os termos que emergem na literatura estudada. O que é particularmente notável é o surgimento do Brasil como termo chave mais recente (a partir de 2019), insinuando um interesse crescente e com uma contribuição recente. Antes de 2019, embora “*Brazil*” tenha sido uma palavra-chave de busca, os artigos não se concentravam especificamente em estudos relacionados ao país. Enquanto termos técnicos como “*aermod*”, “*atmospheric movements*”, “*dispersion models*”, “*air pollution*”, “*parameterization*” e “*dispersion*” já estão mais estabelecidos no campo, tendo se consolidado antes de 2017.

Outro termo recente é o “*concentration (composition)*”, que demonstra um interesse na composição química do MP. Historicamente, a maior parte da atenção estava voltada para a concentração mássica de MP, mas avanços tecnológicos e científicos permitiram uma investigação mais aprofundada sobre a composição química destas partículas (LOUGH; SCHAUER; LAWSON, 2006). Esta mudança de foco é crucial, pois revelou que a composição química do MP pode variar consideravelmente de acordo com a localidade e a fonte de emissão. Estudos recentes têm mostrado que essa composição diversificada tem implicações significativas na saúde pública e no meio ambiente, variando não só geograficamente, mas também de acordo com as atividades humanas e fontes naturais na área estudada (Han *et al.*, 2012; Philip *et al.*, 2014; Sówka *et al.*, 2019). Portanto, a análise da composição química de MP representa um avanço importante na compreensão dos impactos da poluição do ar, fornecendo *insights* detalhados que vão além das medidas de concentração mássica.

Percebe-se que “*Brazil*”, “*particulate matter*” e “*concentration*” emergiram com mais proeminência após 2018. Isso sugere uma evolução no foco das pesquisas, com uma atenção particular às questões específicas da qualidade do ar no contexto brasileiro, o que pode refletir tanto um aumento na consciência ambiental quanto uma resposta às demandas por estudos locais mais detalhados, diante de desafios ambientais e de saúde pública únicos enfrentados pelo país.

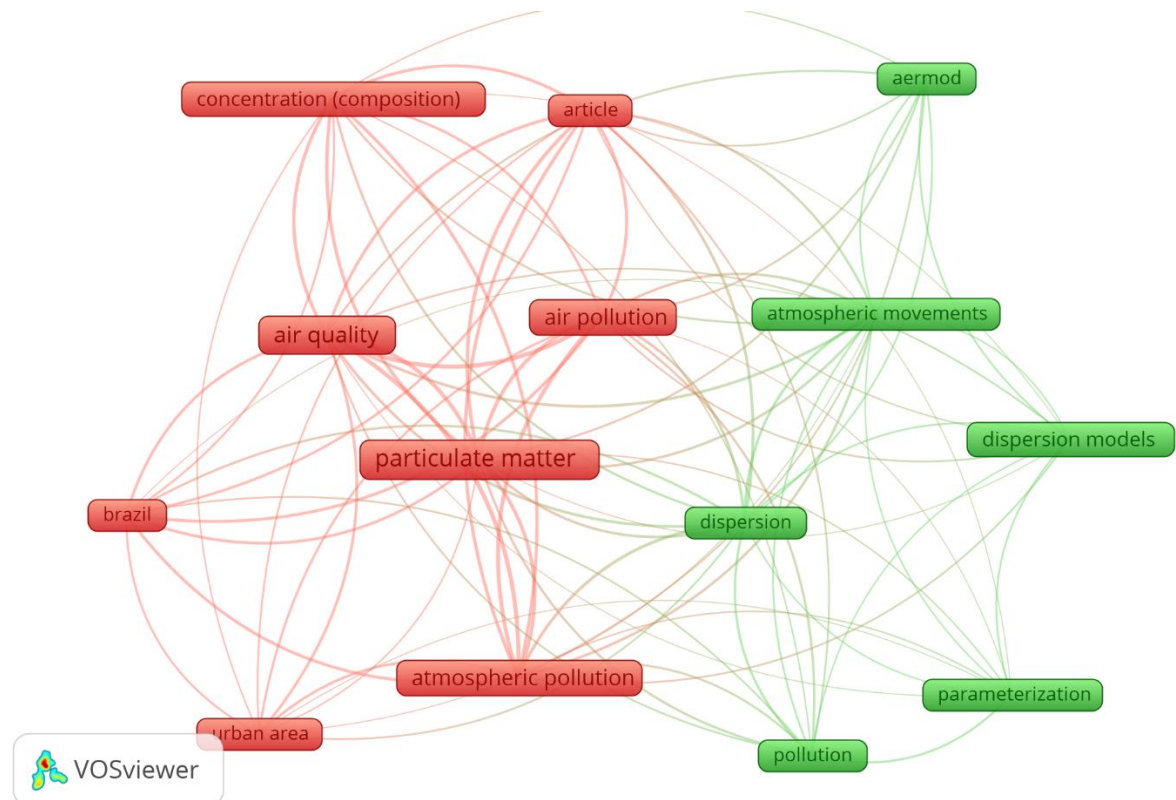
A prevalência do termo “*particulate matter*” pode refletir um aumento na preocupação global com a poluição do ar e seus efeitos adversos na saúde pública e no meio ambiente. A proximidade entre “*particulate matter*” e “*Brazil*” e a coloração amarela do termo “*Brazil*” indica um foco significativo no MP dentro do território brasileiro a partir de 2019, sugerindo

uma série de estudos que exploram as dinâmicas de poluentes específicos para o contexto brasileiro.

Dentro do cenário brasileiro, um exemplo relevante de legislação ambiental que poderia justificar um aumento na conscientização e na pesquisa sobre MP é a Resolução CONAMA 491/2018 (CONAMA, 2018). Esta resolução estabelece padrões de qualidade do ar, atualizando e tornando mais rigorosos os limites para poluentes atmosféricos, incluindo as MP₁₀ e MP_{2,5}. Destacando que, padrões de qualidade do ar nacionais para o MP_{2,5} somente foram estabelecidos a partir desta resolução.

Quanto à saúde pública relacionada ao crescente interesse neste poluente, estudos epidemiológicos no Brasil (Abe; Miraglia, 2016; Cortes *et al.*, 2023; Gouveia *et al.*, 2017) e no mundo (Kioumourtzoglou *et al.*, 2016; Pun *et al.*, 2017; Weichenthal *et al.*, 2017), consistentemente demonstraram que a exposição a longo prazo a essas partículas está associada a um aumento no risco de condições crônicas, como doenças cardíacas, derrames, doenças respiratórias crônicas e câncer de pulmão.

Figura 11. Análise Bibliométrica de Tendências e Conexões em Modelagem de Dispersão de Poluentes Atmosféricos (Nº de citações)



Fonte: Imagem gerada pelo autor utilizando o software VOSViewer, 2023.

A Figura 11 proporciona uma perspectiva complementar, agrupando termos técnicos e específicos do campo, como "aermod", "*dispersion models*", e "*atmospheric movements*" em um *cluster* verde, denotando uma convergência metodológica dentro dos estudos. O termo "aermod" surge como uma palavra-chave isolada, mas ainda interconectada, ressaltando seu papel como ferramenta específica dentro da modelagem de dispersão atmosférica. Interessante notar que, "aermod" não exibe uma conexão direta com "*Brazil*", implicando que, embora seja uma ferramenta prevalente, sua aplicação no contexto brasileiro pode não ser amplamente reportada ou pode estar emergindo nos estudos mais recentes.


Os termos "*dispersion*" e "*pollution*" servem como elos transversais entre os *clusters*, sublinhando a relação intrínseca entre a dispersão de poluentes e os modelos de dispersão atmosférica utilizados para entender e prever o fenômeno. A interdisciplinaridade e a complexidade do campo são evidenciadas pela diversidade de palavras-chave e sua sobreposição temática.

Do mesmo modo, a Figura 11 revela que o termo "*urban area*" emerge como uma palavra-chave significativa, refletindo a relevância crescente das zonas urbanas no estudo da poluição atmosférica. Em ambientes urbanos, a densidade populacional, a concentração de veículos e as atividades industriais contribuem substancialmente para a degradação da qualidade do ar. Essas áreas são, portanto, pontos críticos para a pesquisa em poluição do ar, dada a sua associação com questões de saúde pública e o impacto no ambiente construído. A compreensão das dinâmicas de dispersão e composição de poluentes em áreas urbanas é essencial para o desenvolvimento de estratégias eficazes de mitigação e políticas de planejamento urbano sustentável.

Após a aplicação do *VOSViewer* (VOSVIEWER, 2023) foi examinada a distribuição geográfica dos principais países envolvidos, ficando evidente que o Brasil lidera em termos de quantidade de documentos (31) e citações (384), visto que aplicamos a palavra-chave "*Brazil*", que direcionou a busca para artigos que fazem menção ao país. Além disso, a presença de países como China, Reino Unido, Israel e Estados Unidos ressalta a abrangência global da pesquisa nessa área, destacando a importância da qualidade do ar e dos impactos ambientais em nível internacional.

Em continuidade, a Figura 12 ilustra a distribuição geográfica das citações nos estudos analisados, mostrando a área que foi estudada, trazendo um panorama regional no contexto da dispersão de poluentes atmosféricos.

Figura 12. Distribuição Geográfica das Citações: Ênfase no Brasil e Comparação Global



Fonte: Autoria Própria.

As citações referentes ao Brasil são destacadas em verde, mostrando que o país acumula um total de 25 menções, com destaque para a região Sudeste com 13 citações. A região Sul vem em seguida com 6 menções, enquanto o Nordeste e o Norte recebem 4 e 1 citações, respectivamente. Esta distribuição colabora com a discussão sobre a relevância das abordagens regionalizadas, que são cruciais para entender as dinâmicas específicas da poluição do ar em diferentes partes do país.

Em contraste, os tons de laranja mapeiam as citações para o restante do mundo, com destaque de 27 citações que representam os artigos que não determinaram uma região específica, sugerindo um volume significativo de literatura que não se concentra em uma área especificada. Isso pode refletir uma tendência em focar em princípios universais, métodos e modelos que transcendem as fronteiras geográficas ou que são aplicáveis em vários contextos ambientais.

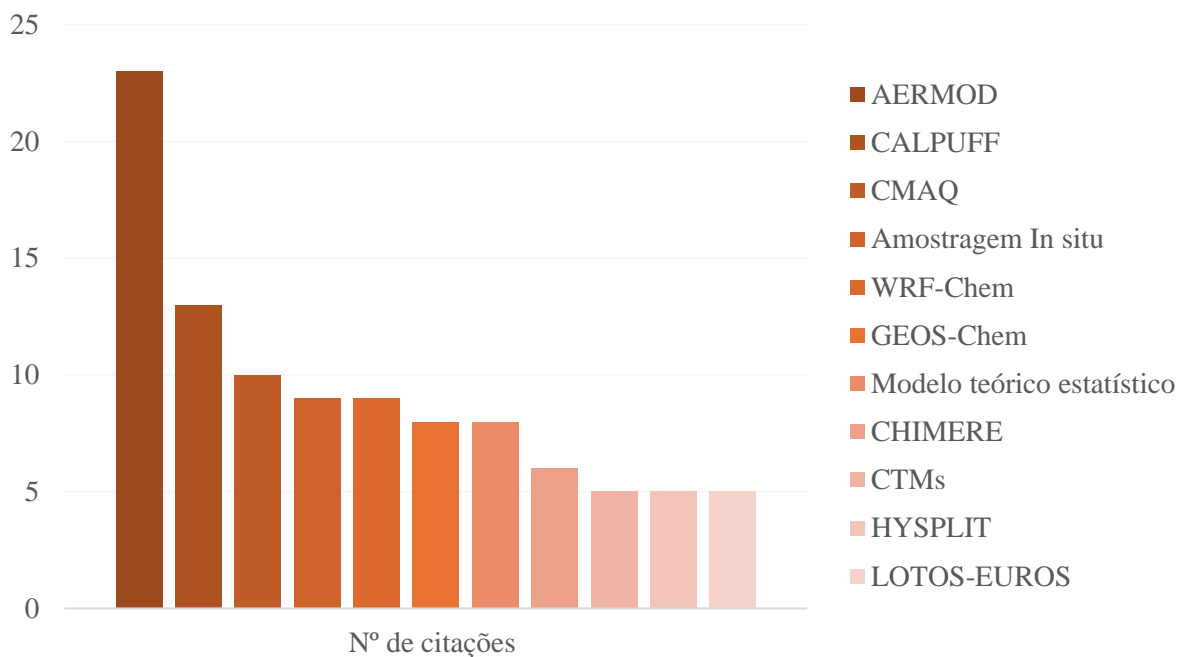
Seguindo em ordem decrescente de citações, os estudos de escopo global são notáveis, evidenciando uma abordagem comparativa ou abrangente entre diversas regiões. A presença significativa de estudos na Ásia e Europa pode ser interpretada pela intensificação das atividades industriais e urbanização nesses locais, enquanto as menções à América do Norte e ao Círculo Polar Ártico são mais modestas, esta observação pode ser atribuída ao delineamento geográfico da pesquisa, que priorizou a produção científica relacionada ao Brasil, levando a uma representação proporcionalmente menor.

4.1.1. Modelos de Dispersão Atmosférica e Aplicação no Brasil

Os resultados indicam que a aplicação de modelos e abordagens para avaliar a concentração de poluentes atmosféricos no Brasil ainda é limitada. Muitos estudos focam na mobilidade urbana, priorizando medições experimentais de poluentes. Apesar dos vários modelos de dispersão disponíveis, há preferência por métodos práticos, como o uso de estações de monitoramento fixas, devido à obtenção de dados locais confiáveis (Pinto *et al.*, 2020). Contudo, essa preferência destaca as limitações dos modelos, que requerem previsões meteorológicas precisas e estimativas confiáveis de emissões, além de que a implementação desses modelos frequentemente exige recursos computacionais substanciais (Seaman, 2000; Zhang *et al.*, 2012). No entanto, depender apenas de abordagens empíricas pode limitar a previsão e compreensão dos impactos da poluição em larga escala. Assim, equilibrar métodos práticos de medição de concentração e modelos de dispersão é essencial.

A escolha do modelo de dispersão a ser utilizado é uma decisão que depende de diversos fatores, como a disponibilidade de dados, o escopo da análise e a escala espacial e temporal desejada (Monks *et al.*, 2009) Dentre os artigos levantados, destaca-se o uso dos modelos AERMOD, CALPUFF, WRF-Chem e CMAQ (Figura 13), que oferecem diversas abordagens e podem ser adaptados a diferentes contextos.

Figura 13. Predominância de Modelos de Dispersão Atmosférica



Fonte: Autoria própria.

Na Figura 13, observa-se uma mistura de diferentes tipos de modelos utilizados em estudos de poluição atmosférica. Alguns modelos, como o AERMOD e o CALPUFF, são tradicionalmente classificados como "modelos de dispersão", focados principalmente no transporte e dispersão de poluentes na atmosfera. Por outro lado, modelos como o WRF-Chem e o CMAQ vão além da simples dispersão de poluentes; eles são modelos de química de transporte que tratam numericamente as reações químicas na fase gasosa e aquosa, bem como a formação e transformação de aerossóis. Esses modelos também incorporam processos físicos e parametrizações detalhadas, como aquelas necessárias para representar condições urbanas específicas, entre outros fatores.

Deste modo, a Figura 13 resume os modelos de dispersão atmosférica com mais de 5 citações na amostra, tendo como principais modelos o AERMOD e CALPUFF. Outros modelos, como WRF-Chem, CMAQ e GEOS-Chem, também são destacados, evidenciando a relevância dos modelos de química atmosférica. Modelos com menos citações, como CHIMERE e HYSPLIT, complementam o espectro de ferramentas utilizadas, demonstrando a diversidade necessária para abordar a complexidade da dispersão de poluentes atmosféricos.

Em uma análise das metodologias empregadas na literatura, observa-se uma diversidade de modelos de dispersão atmosférica que refletem as complexidades do estudo de poluentes no ar. Esses modelos variam desde abordagens Eulerianas, que fornecem uma visão da distribuição de poluentes em uma grade fixa, até modelos Lagrangianos, que acompanham o movimento de partículas individuais no espaço.

A Tabela 5 oferece uma classificação quantitativa dos modelos utilizados nos estudos analisados, sintetizando a frequência de adoção de cada modelo. Na tabela, além das quatro categorias principais de modelos de dispersão atmosférica (Modelos Eulerianos, Gaussianos, Lagrangianos e CFD - Dinâmica dos Fluidos Computacional), foram adicionadas categorias como "Modelos Estatísticos e de Aprendizado de Máquina" e "Modelos Químicos de Transporte (CTMs)". Essas inclusões ocorreram devido as categorias tradicionais não são suficientes para abranger todos os métodos utilizados para avaliar a dispersão de poluentes na atmosfera.

Modelos Eulerianos, comumente utilizados para simular o transporte e a dispersão de poluentes em grandes escalas, são os mais citados, seguidos de modelos CFD. Modelos estatísticos e de aprendizado de máquina emergem como ferramentas importantes, refletindo a tendência contemporânea de integrar técnicas de *big data* e inteligência artificial na modelagem ambiental. Observa-se ainda os modelos Gaussianos, tradicionalmente empregados para

simulações de dispersão em escala local, e os modelos químicos de transporte (CTMs), importantes para estudos detalhados de fluxos e dispersão em microescala, mantêm uma presença relevante na pesquisa atual.

Tabela 5. Classificação e Frequência de Modelos de Dispersão Atmosférica na Pesquisa Científica Atual

| Classificação | Descrição | Nº |
|--------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Modelos Eulerianos | <p>Estes modelos descrevem a dispersão de poluentes na atmosfera usando um sistema de coordenadas fixo. Eles são comumente usados para simular a concentração de poluentes em larga escala, levando em conta reações químicas e interações com variáveis meteorológicas (Maffia <i>et al.</i>, 2020).</p> <p>Exemplos: CMAQ (<i>Community Multiscale Air Quality</i>), CAMx (<i>Comprehensive Air Quality Model with extensions</i>), EMEP (<i>European Monitoring and Evaluation Program</i>)</p> | 53 |
| Modelos Estatísticos e de Aprendizado de Máquina | <p>Modelos que usam técnicas estatísticas ou algoritmos de aprendizado de máquina para prever a dispersão de poluentes. Eles podem analisar tendências históricas e dados ambientais para fazer previsões (Kelly <i>et al.</i>, 2021).</p> <p>Exemplos: Modelos de regressão, redes neurais artificiais, algoritmos de <i>machine learning</i> como <i>Random Forest</i> ou <i>Support Vector Machines</i>.</p> | 16 |
| Modelos Gaussianos | <p>Baseiam-se na distribuição gaussiana para modelar a dispersão de poluentes. São frequentemente utilizados para avaliações de impacto ambiental em curta distância e são relativamente simples em comparação com outros modelos (Maffia <i>et al.</i>, 2020).</p> <p>Exemplos: AERMOD (<i>American Meteorological Society/Environmental Protection Agency Regulatory Model</i>), CALINE4, Gaussian Plume Model.</p> | 16 |
| Modelos Químicos de Transporte (CTMs) | <p>Estes modelos simulam o transporte e a transformação química de poluentes na atmosfera. Eles são usados para entender a química atmosférica e o impacto de poluentes em diferentes escalas (LV <i>et al.</i>, 2020).</p> <p>Exemplos: GEOS-Chem (<i>Goddard Earth Observing System Chemistry Model</i>), MOZART (<i>Model for ozone and Related chemical Tracers</i>), WRF-Chem (<i>Weather Research and Forecasting model with Chemistry</i>).</p> | 14 |

Tabela 5. Classificação e Frequência de Modelos de Dispersão Atmosférica na Pesquisa Científica Atual (Continuação)

| | | |
|--------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Modelos CFD (Dinâmica dos Fluidos Computacional) | Estes modelos usam métodos numéricos e algoritmos para analisar e resolver problemas envolvendo fluxos de fluidos. Eles são úteis para simular a dinâmica de poluentes em ambientes complexos, como áreas urbanas com muitos edifícios (Sokhi <i>et al.</i> , 2022). Exemplos: ANSYS <i>Fluent</i> , OpenFOAM, Autodesk CFD | 11 |
| Modelos Lagrangianos | Diferentemente dos modelos eulerianos, os modelos lagrangianos seguem o movimento de poluentes individuais ou parcelas de ar através do espaço e do tempo, usando um sistema de referência que se move com o fluxo. São úteis para rastrear a trajetória de poluentes específicos (Maffia <i>et al.</i> , 2020). Exemplos: HYSPLIT (<i>Hybrid Single Particle Lagrangian Integrated Trajectory Model</i>), FLEXPART (<i>Flexible Particle dispersion model</i>). | 9 |
| Amostragem In situ | Não é um modelo de simulação, mas uma técnica de coleta de dados reais sobre a concentração de poluentes e condições atmosféricas. Envolve a medição direta de poluentes no local de interesse. Exemplos: Uso de estações de monitoramento de qualidade do ar, coleta de amostras de ar para análise laboratorial, uso de sensores portáteis para medições no campo. | 2 |

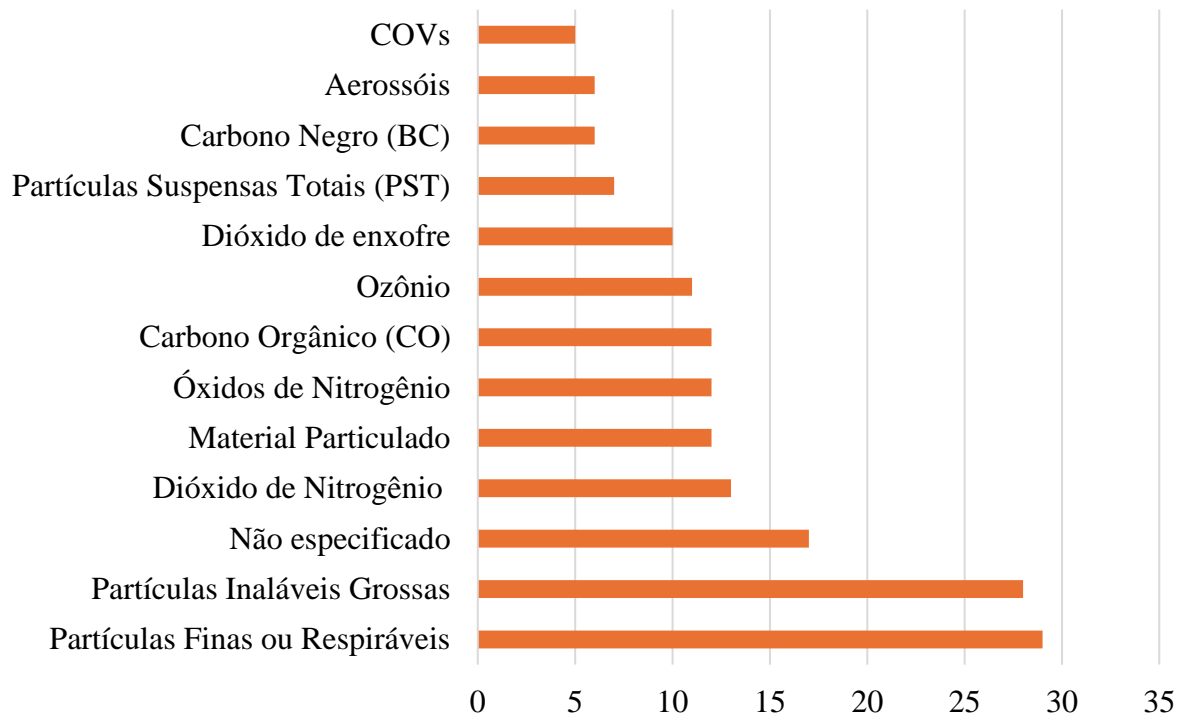
Fonte: Autoria Própria.

Entre os artigos analisados, destaca-se o trabalho de (Roberts; Wooster, 2021), que explora o uso dos dados do sistema CMAQ-CAMS para compreender as concentrações globais de $MP_{2,5}$ na superfície atmosférica. No Brasil, o estudo utiliza estações de monitoramento em Rio Branco, interior de São Paulo, e aponta que a qualidade do ar nessa região é impactada pelas emissões durante a temporada incêndios florestais. O CAMS tende ligeiramente a superestimar as concentrações de $MP_{2,5}$ no início do ano, porém concorda com as tendências ao longo da temporada de incêndios, exibindo uma boa correlação com medições *in situ* em Rio Branco. Isso sugere que o CAMS consegue modelar com razoável precisão as concentrações de $MP_{2,5}$ em Rio Branco, Brasil.

O foco nos impactos dos incêndios reflete uma preocupação crescente com eventos sazonais e suas consequências para a qualidade do ar em regiões específicas. A precisão do modelo CAMS, ao correlacionar-se positivamente com as medições em Rio Branco, ilustra o potencial de ferramentas de modelagem na previsão e compreensão das variações na

concentração de poluentes. Esta observação é reforçada pela Figura 14, que indica $MP_{2,5}$ como um dos poluentes mais frequentemente estudados, corroborando a importância de tais modelos na análise de padrões de dispersão de MP e outros compostos atmosféricos relevantes para a saúde pública e a gestão ambiental.

Figura 14. Frequência de Citações de Poluentes Atmosféricos



Fonte: Autoria Própria.

A distribuição de citações, destaca $MP_{2,5}$ (Partículas Finas ou Respiráveis) e MP_{10} (Partículas Inaláveis Grossas). Além disso destaca-se a categoria de formação de MP, que são artigos que abordam MP, mas não especificam a dimensão das partículas analisadas. A categoria "Não especificado" reflete uma parcela considerável das citações, que expõe trabalhos que tratam os poluentes atmosféricos de maneira mais abrangente e que não define qual poluente está sendo analisado, como por exemplo artigos de revisão, que tratam dos modelos de dispersão e qualidade do ar, mas não aborda especificamente um poluente.

As citações para $MP_{2,5}$, seguidas por MP_{10} , não apenas confirmam a predominância de estudos direcionados a este poluente na literatura de modelagem atmosférica, como sublinha sua significância em estudos ambientais. Vale ressaltar que isso é um reflexo da inclusão do termo "*Particulate Matter*" como palavra-chave na pesquisa. A frequente referência a precursores como NO_x (Óxidos de Nitrogênio), NO_2 (Dióxido de Nitrogênio) e COVs

(Compostos Orgânicos Voláteis) sugere sua relevância, já que através de reações químicas na atmosfera, formam os materiais particulados secundários.

O O₃ (Ozônio) e SO₂ (Dióxido de Enxofre) também são considerados, apesar de suas citações serem menos frequentes, acompanhados por PTS (Partículas Suspensas Totais), Carbono Negro, Aerossóis e COVs, que completam o espectro de contaminantes abordados, ainda que com menos referências.

No escopo da classificação dos modelos de dispersão atmosférica e da análise da relevância dos estudos conduzidos, observa-se que 40% dos modelos analisados são considerados de alta relevância para o tema da pesquisa. Além disso, 46% dos modelos são avaliados como tendo relevância moderada, sugerindo que, embora não sejam centralmente focados no contexto brasileiro, ainda fornecem *insights* valiosos que podem ser adaptados ou estendidos para a região em foco. Apenas 14% dos modelos são classificados como tendo baixa relevância, o que pode refletir uma menor aplicabilidade direta aos aspectos regionais de interesse ou uma orientação temática mais distante do foco da presente revisão.

Quanto à robustez metodológica dos estudos analisados, os resultados são divididos, com 50% dos modelos apresentando alta robustez metodológica e outros 49% demonstrando robustez metodológica moderada. Este equilíbrio indica que quase a metade dos modelos examinados possui uma metodologia sólida e bem fundamentada, enquanto a outra metade, apesar de ainda ser considerada robusta, pode requerer verificações adicionais ou complementações para atender aos padrões de alta confiabilidade. Apenas 1% dos estudos apresentam limitações metodológicas significativas, o que denota uma qualidade geralmente alta na metodologia empregada na pesquisa atual.

Estes dados, em conjunto, evidenciam que a maioria dos estudos incorporados nesta revisão contribui de maneira relevante para a compreensão da dispersão de poluentes atmosféricos e possuem uma metodologia que suporta a confiabilidade de seus resultados e conclusões. A consistência na relevância e na robustez metodológica reitera a importância de tais modelos para a elaboração de estratégias eficazes de monitoramento e mitigação da poluição atmosférica em contextos regionalizados, particularmente no Brasil.

Deste modo, regionalizar a concentração de poluentes apresenta desafios notáveis, é um processo complexo que exige a integração de dados observacionais e modelos de dispersão atmosférica em diversas escalas. Essa prática é crucial para aplicar resultados de modelos a

áreas específicas, levando em conta as características locais que afetam a dispersão de poluentes.

A Revisão Bibliográfica Sistemática (RBS) inicial não foi suficiente para identificar modelos de dispersão atmosférica especificamente aplicáveis à ACV. Diante dessa limitação, foi necessário realizar uma pesquisa adicional para explorar outras abordagens que pudessem atender aos requisitos do estudo, apresentada na seção 4.1.3. Essa pesquisa mais aprofundada levou à identificação de modelos de dispersão de baixa complexidade, que demonstraram potencial para serem adaptados e aplicados ao contexto da ACV, considerando suas características simplificadas, mas ainda relevantes para as análises de impacto ambiental no cenário brasileiro.

4.1.2. Modelos de Dispersão de Baixa Complexidade

Os modelos de dispersão de poluentes atmosféricos são ferramentas essenciais na avaliação e controle da poluição do ar, sendo amplamente utilizados em comunidades regulatórias e para pesquisa. Esses modelos variam em termos de complexidade, desde modelos simples e rápidos até modelos detalhados e altamente complexos. Entre os mais aplicados e complexos estão o AERMOD, CALPUFF, WRF-Chem e CMAQ, amplamente utilizados por sua capacidade de modelagem precisa em diversos cenários ambientais.

Para complementar a discussão sobre modelos de alta complexidade, é fundamental considerar o papel e a importância dos modelos de qualidade do ar de complexidade reduzida (MCR). Estes modelos oferecem soluções viáveis e eficientes em termos de recursos para diversas aplicações práticas, em que a simplicidade e a rapidez são importantes (HARMS et al., 2011; THIND et al., 2022).

Os MCRs podem basear-se em modelos de transporte químico (Buonocore et al., 2014; Tessum; Hill; Marshall, 2017; Zhang et al., 2012), gaussianos (Cimorelli et al., 2005; Cerqueira; Sousa, 2019; Zou et al., 2010), ou lagrangianos (Bai Et al., 2020; Draxler, 1997; Loeck; Schramm; Bodmann, 2018). Embora menos precisos que os Modelos Químicos de Transporte, os MCRs oferecem a flexibilidade necessária para realizar um número maior de análises de sensibilidade, abordagens de Monte Carlo, estudos sobre efeitos de fonte e receptor, e permitem o uso de células de grade menores e períodos de simulação mais longos (Hill *et al.*, 2019; Levy; Wilson; Zwack, 2007).

Modelos gaussianos são um exemplo clássico de abordagens simplificadas que utilizam a distribuição gaussiana para estimar a dispersão de poluentes. O CAREA, por exemplo, integra essa modelagem com sistemas de informações geográficas (GIS), proporcionando uma análise rápida e eficiente das concentrações de poluentes ao nível do solo e fluxos de deposição seca (Teggi *et al.*, 2018). Outro modelo notável é o InMAP (*Intervention Model for Air Pollution*), que estima os impactos na saúde decorrentes das mudanças nas emissões de poluentes. Utilizando uma grade computacional de resolução variável, o InMAP realiza simulações menos intensivas em termos de recursos, facilitando a análise de intervenções em larga escala (Tessum; Hill; Marshall, 2017).

A facilidade de implementação e uso é outra característica importante desses modelos. O UCD 2001, por exemplo, foi desenvolvido para simular concentrações de poluentes próximos a rodovias e é menos exigente em termos de dados de entrada e expertise técnica. Isso facilita sua implementação em cenários urbanos complexos, onde a necessidade de simulações rápidas e precisas é crítica (Held, 2003).

De acordo com Gilmore *et al.* (2019), três MCRs são comumente utilizados e fornecem estimativas abrangentes em alta resolução espacial: o *Air Pollution Emission Experiments and Policy* (APEEP/AP2) (Muller, 2014), o *Estimating Air Pollution Social Impacts Using Regression* (EASIUR) (Heo; Adams; Gao, 2016) e o InMAP (Tessum; Hill; Marshall, 2017).

Um estudo conduzido por Gilmore *et al.* (2019) explorou a comparação dos custos sociais da qualidade do ar a partir de modelos de complexidade reduzida. O estudo comparou os custos marginais por tonelada de emissões para vários poluentes, incluindo dióxido de enxofre (SO₂), óxidos de nitrogênio (NO_x), amônia (NH₃), e MP_{2,5} inerte primário, em cada condado dos Estados Unidos.

Os resultados mostraram que, apesar das diferenças nas metodologias dos três MCRs, eles produzem estimativas de custo que são consistentes dentro da mesma ordem de grandeza. Isso confirma que os MCRs, apesar de sua menor complexidade em comparação com modelos mais detalhados, fornecem uma base confiável para análises de políticas relacionadas à qualidade do ar, especialmente em níveis geográficos amplos e abrangentes.

4.2. Análise de inventários

Após a coleta dos inventários foi possível avaliar a disponibilidade de dados de emissão para MP_{2,5} e seus precursores (NH₃, NMVOC, SO_x e NO_x). A Tabela 6 apresenta a disponibilidade de dados nos inventários analisados e categorizados por setor.

Tabela 6. Tabela de Disponibilidade de Dados por Setor e Inventário

| Setor | Ano base | Inventário | NH ₃ | NMVOC | SO _x | NO _x | MP _{2,5} |
|---------------------|----------|------------|-----------------|-------|-----------------|-----------------|-------------------|
| Agricultura | 2022 | EDGAR | ✓ | ✓ | ✓ | ✓ | ✓ |
| | 2022 | EDGAR | ✓ | ✓ | ✓ | ✓ | ✓ |
| Industrial | 2019 | BRAIN | × | ✓ | ✓ | ✓ | ✓ |
| | 2022 | Rey (2023) | ✓ | × | ✓ | ✓ | ✓ |
| Transporte | 2019 | BRAVES | × | ✓ | ✓ | ✓ | ✓ |
| | 2022 | EDGAR | ✓ | ✓ | ✓ | ✓ | ✓ |
| Queima de biomassa | 2021 | FINN | ✓ | ✓ | ✓ | ✓ | ✓ |
| Emissões biogênicas | 2019 | MEGAN | × | ✓ | × | ✓ | × |

Fonte: Autoria própria.

A Tabela 6 será utilizada como base para a análise comparativa dos inventários de emissões nos setores industrial e de transporte, além das análises dos inventários do setor de agricultura, queima de biomassa e emissões biogênicas. Vale ressaltar que, o inventário de Rey, inicialmente, incluía dados para os poluentes NMVOC, SO_x, NO_x e MP_{2,5}. No entanto, ao realizar a espacialização, observou-se que os valores de NMVOC ficaram extremamente baixos, frequentemente iguais a zero. Durante o processo de espacialização, o software AnthroEmiss calculou a variável NH₃ com base nas emissões dos outros poluentes presentes. Diante dessa situação, neste estudo, para o inventário de Rey (2023) foi avaliado os poluentes NH₃, SO_x, NO_x e MP_{2,5}.

Por outro lado, o mesmo não ocorreu com o inventário do BRAIN, uma vez que esse inventário já possuía os dados devidamente distribuídos em um grid de 20 km x 20 km, eliminando a necessidade de uma espacialização.

No Apêndice A, são apresentadas as estatísticas descritivas das emissões por inventário e setor. A Tabela 8 apresenta as médias com respectivos desvios padrão para uma comparação mais detalhada. A análise desses dados revela que no setor de agricultura, as emissões de NMVOC no inventário EDGAR apresentam uma média muito alta (103,73 t/ano) em

comparação à mediana (2,48 t/ano), indicando uma distribuição assimétrica com possíveis outliers. Para NH_3 , NO_x , $\text{MP}_{2,5}$ e SO_x , as médias e medianas são muito baixas, sendo elas menores do que 1 tonelada por ano, sugerindo emissões geralmente pequenas e consistentes, com exceção de NO_x , que mostram uma variação maior de 16,05 t/ano.

Para emissões biogênicas, o inventário MEGAN mostra uma média alta (926,29 t/ano) e um desvio padrão elevado (1226,79 t/ano) nas emissões de NMVOC, indicando grande variabilidade. As emissões de NO_x têm média de 50,04 t/ano e uma variância significativa (3.614,35 t/ano), apontando para emissões altamente variáveis.

No setor industrial, as emissões de NH_3 e $\text{MP}_{2,5}$ no inventário Rey (2023) são relativamente baixas, com média de $7,23\text{E-}06$ t/ano e $7,84\text{E-}03$ t/ano, respectivamente, e com medianas iguais a zero, sugerindo dados esparsos ou valores muito pequenos na maioria dos casos. A variabilidade é alta em alguns casos, como NMVOC no inventário EDGAR, que possui variância de 4.438.790,43 t/ano. Isso evidencia diferenças significativas nos métodos de coleta e cálculo dos dados entre os dois inventários.

Para a queima de biomassa, as emissões de NMVOC no inventário FINN mostram uma média moderada (3,10 t/ano) com alta variabilidade (1.957,48 t/ano), refletida no desvio padrão (44,24) e amplitude (1.317,13). A mediana de NH_3 é zero, enquanto a média ($2,26\text{E-}01$ t/ano) e o desvio padrão (1,02 t/ano) são baixos, indicando a presença de valores extremos. As emissões de NO_x , $\text{MP}_{2,5}$ e SO_x têm baixas médias, $8,57\text{E-}01$ t/ano, 1,16 t/ano, $7,81\text{E-}02$ t/ano, respectivamente, com pequenas variações indicando baixas emissões desses poluentes.

No setor de transporte, os inventários EDGAR e BRAVES mostram variabilidade considerável nas emissões de NMVOC, com médias de 41,32 t/ano e 6,12 t/ano, respectivamente e desvios padrão de 80,51 t/ano e 158,32 t/ano, respectivamente. As emissões de NO_x no inventário BRAVES têm uma média alta (27,79 t/ano) e um desvio padrão substancial (242,94 t/ano), indicando a presença de emissões extremas ou *outliers*. As emissões de $\text{MP}_{2,5}$ no inventário BRAVES têm uma média de 3,48 t/ano com um desvio padrão de 12,56 t/ano, indicando baixa variabilidade nas emissões. Tanto os inventários BRAVES quanto EDGAR mostram baixas emissões médias de SO_x , $5,41\text{E-}01$ e $3,47\text{E-}01$ t/ano, respectivamente, mas com certa variabilidade nos dados, dentro de 21,69 t/ano para o BRAVES e 4,59 t/ano para o EDGAR.

Ademais, as estatísticas descritivas mostram que a identificação dos setores que mais emitem poluentes pode variar significativamente dependendo do inventário escolhido. Isso

pode ser observado avaliando a Tabela 8, que apresenta os valores médios e seus respectivos desvios padrão para emissões de NH₃, NMVOC, SO_x, NO_x e MP_{2,5} para os setores estudados neste trabalho. A tabela utiliza um gradiente de cores onde médias baixas de emissão são indicados em verde, médias intermediárias em amarelo e médias altas em vermelho.

Tabela 7. Comparação das médias (μ) e desvios padrão (σ) de emissão entre inventários.

| Setor | Inventário | | NH ₃ | NMVOC | SO _x | NO _x | MP _{2,5} |
|---------------------|------------|----------|-----------------|----------|-----------------|-----------------|-------------------|
| Agricultura | EDGAR | μ | 4,11E-03 | 103,73 | 7,33E-02 | 1,13 | 2,12E-04 |
| | | σ | 7,68E-03 | 442,78 | 3,63E-01 | 4,01 | 1,01E-03 |
| Industrial | EDGAR | μ | 2,45E-01 | 174,82 | 1,2490 | 1,80 | 1,93E-04 |
| | | σ | 2,90 | 2106,84 | 16,18 | 20,12 | 2,33E-03 |
| | BRAIN | μ | N/D | 1,16E-02 | 3,1043 | 2,08 | 9,48E-01 |
| | | σ | | 1,61 | 160,61 | 69,65 | 38,80 |
| Rey (2023) | μ | 7,23E-06 | N/D | 1,59E-01 | 3,07E-02 | 7,84E-03 | |
| | σ | 1,39E-04 | | 0 | 13,64 | 5,90E-01 | |
| Transporte | BRAVES | μ | N/D | 6,12 | 5,41E-01 | 27,79 | 2,51 |
| | | σ | | 80,51 | 4,66 | 242,94 | 22,92 |
| | EDGAR | μ | 3,49E-02 | 174,82 | 1,2490 | 1,80 | 1,93E-04 |
| | | σ | 1,64E-01 | 158,32 | 2,14 | 12,56 | 1,79E-04 |
| Queima de biomassa | FINN | μ | 2,26E-01 | 9,55 | 7,81E-02 | 8,57E-01 | 1,16 |
| | | σ | 1,02 | 44,24 | 3,17E-01 | 3,85 | 5,14 |
| Emissões biogênicas | MEGAN | μ | N/D | 926,29 | N/D | 50,03 | N/D |
| | | σ | | 1.226,79 | | 60,12 | |

Fonte: Autoria própria.

No caso do setor industrial, ele aparece como o maior emissor de NH₃, (média de 0,24 t/ano com o inventário EDGAR). Para o setor de transporte, este é identificado como o maior emissor de MP_{2,5}, com uma média de 2,51 t/ano, conforme o inventário BRAVES. Para os poluentes NMVOC e NO_x o setor de emissões biogênicas entra como o maior emissor e, por fim, para SO_x p setor industrial é o maior emissor pelo inventário BRAIN.

Por outro lado, os setores que menos emitem são predominantemente a agricultura para NH₃, MP_{2,5} e SO_x, e a queima de biomassa para NO_x e NMVOC.

Essa disparidade reflete diferentes dinâmicas e fontes de poluição. No setor industrial, os processos de combustão e produção química são responsáveis por grandes emissões de NH₃ e SO_x, enquanto o setor de transporte, devido à queima de combustíveis fósseis, contribui significativamente para as emissões de MP_{2,5}. As emissões biogênicas, apesar de serem naturais, podem ser exacerbadas por atividades humanas como desmatamento e mudanças no uso da

terra, contribuindo principalmente para a liberação de NMVOC, enquanto para NO_x é majoritariamente emitido por fontes antropogênicas, como veículos e processos industriais.

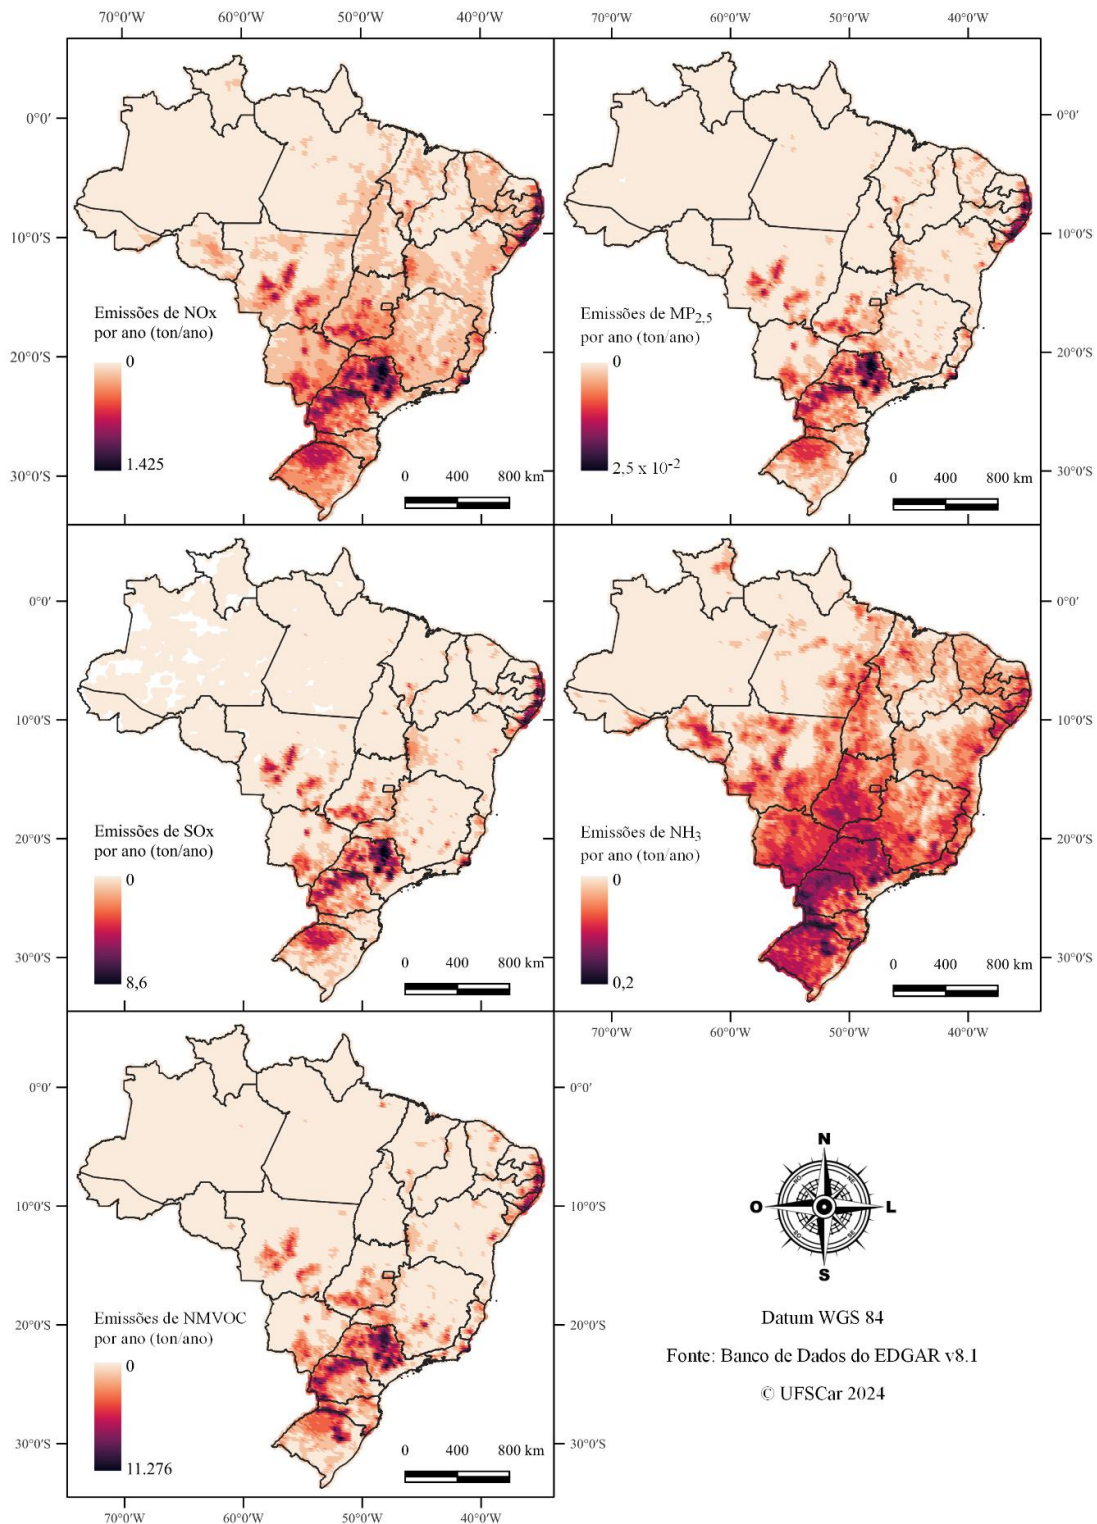
Em contraste, a agricultura, embora contribua para as emissões, faz isso em níveis muito menores para a maioria dos poluentes, exceto em situações específicas como o uso de fertilizantes nitrogenados que podem liberar NH_3 . A queima de biomassa, apesar de ser uma prática comum em algumas regiões, resulta em emissões relativamente menores de NO_x e NMVOC comparadas aos setores industriais e de transporte.

Em resumo, as estatísticas descritivas indicam significativa variabilidade nas emissões de poluentes entre os diferentes inventários e setores. Em muitos casos, as emissões apresentam distribuições assimétricas com medianas baixas e médias elevadas, sugerindo a presença de *outliers*. A grande variabilidade observada em inventários como MEGAN e BRAVES destaca a necessidade de uma análise cuidadosa dos métodos de coleta e processamento dos dados para garantir a precisão e a comparabilidade das emissões reportadas.

4.2.1. Análise de Inventário – Setor: Agricultura

O inventário de emissões do setor agrícola revela uma distribuição heterogênea das emissões de poluentes em todo o Brasil. Esta análise crítica se baseia nos dados obtidos a partir do mapa elaborado no QGIS (Figura 15) e na estatística descritiva apresentada no **Apêndice A**.

Figura 15. Mapa de Emissões do Inventário EDGAR para o setor de Agricultura



Fonte: Elaboração própria utilizando o banco de dados do EDGAR v8.1, com resolução espacial de 20km x 20km.

O mapa da Figura 15 mostra a distribuição espacial das emissões de MP_{2,5} e seus precursores (NO_x, SO_x, NH₃ e NMVOC). As áreas com maior intensidade de emissões são

destacadas em tons mais escuros, enquanto áreas com menores emissões aparecem em tons mais claros.

As emissões de NO_x são particularmente alta nas regiões Sul e Sudeste, com algumas áreas específicas também no Centro-Oeste apresentando valores elevados. Esses dados são consistentes com a média de emissões de NO_x , que é de 1,13 t/ano toneladas por ano, com um desvio padrão de 4,01 t/ano. A variabilidade nas emissões de NO_x pode ser atribuída ao uso intensivo de máquinas agrícolas que utilizam combustíveis fósseis nessas regiões (Mazzetto *et al.*, 2020).

As emissões de $\text{MP}_{2,5}$ são altas na região Sudeste, com focos intensos também na região Sul e em partes do Centro-Oeste. A média de emissões de $\text{MP}_{2,5}$ é praticamente nula, com um desvio padrão de $1,01\text{E-}03$ t/ano, indicando que essas emissões podem ser altamente localizadas e associadas a práticas específicas, como a queima de biomassa para preparo do solo (Meurer *et al.*, 2016).

As emissões de SO_x e de NMVOC seguem um padrão similar ao de NO_x , com maiores concentrações no Sul, Sudeste e partes do Centro-Oeste. As fontes de SO_x no setor agrícola incluem o uso de fertilizantes e pesticidas que contêm enxofre (Bhandari; Sessa, 2020). As emissões de NH_3 estão amplamente distribuídas, com uma concentração maior na região Sudeste e em partes do Sul. A aplicação de fertilizantes nitrogenados é uma fonte importante de emissão de NH_3 , refletindo a alta variabilidade observada nesses dados (Mazzetto *et al.*, 2020).

De mesmo modo, é possível observar altas emissões, para todos os poluentes no litoral nordestino, isso ocorre porque o litoral nordestino abriga áreas de produção agrícola intensiva, especialmente voltadas para culturas como cana-de-açúcar, frutas tropicais, e em alguns casos, atividades pecuárias. A produção agrícola nesta região é mecanizada e envolve o uso de insumos agrícolas em larga escala, como fertilizantes e pesticidas, que são fontes de emissões de NO_x , NH_3 , SO_x , $\text{MP}_{2,5}$ e NMVOC.

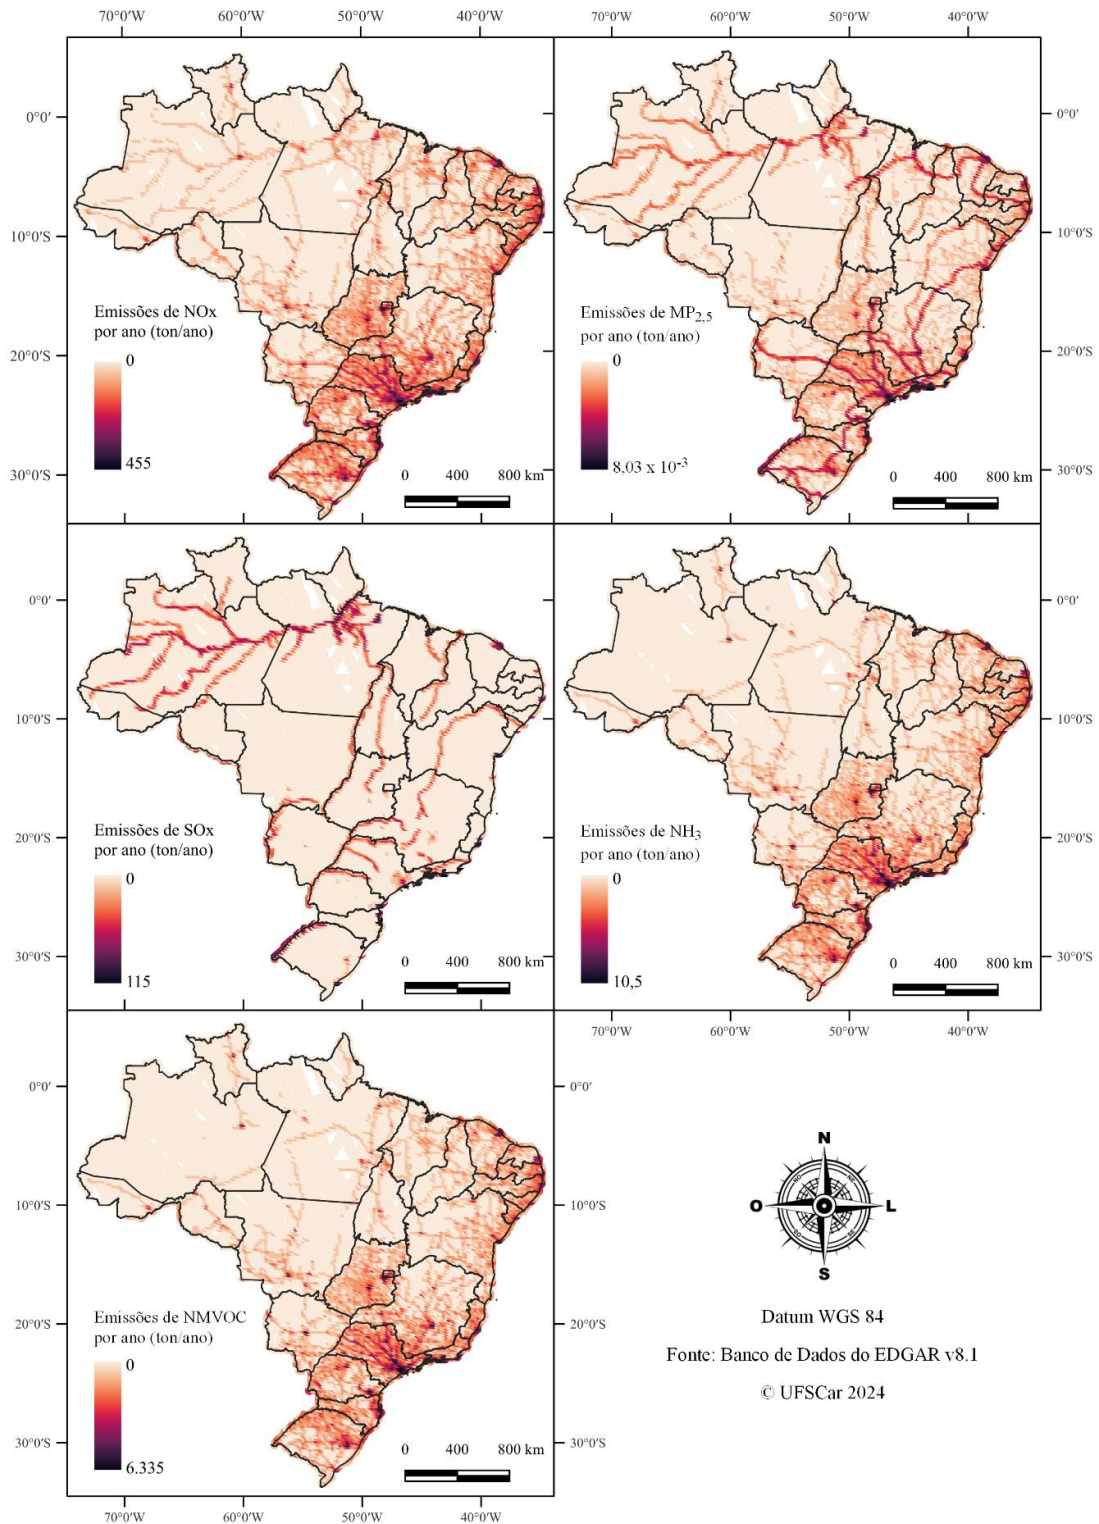
Segundo o relatório do *U.S. Department of Agriculture (USDA)*, a produção de cana-de-açúcar no Nordeste brasileiro tem registrado crescimento, com uma produção significativa, mesmo diante de desafios climáticos como períodos de seca. A região tem se beneficiado de investimentos em renovação de campos de cana e melhorias no rendimento, embora o clima adverso possa afetar futuras colheitas. Este relatório também destaca as políticas governamentais que incentivam práticas agrícolas sustentáveis, como o programa *RenovaBio*, que promove a produção de bioetanol, crucial para a economia do nordeste (USDA, 2024).

Desse modo, as emissões de $MP_{2,5}$ e seus precursores (NO_x , SO_x , NH_3 e NMVOC) no setor agrícola podem ser explicadas por vários fatores. As regiões com alta densidade de atividades agrícolas, como o Litoral do Nordeste, Sudeste e o Sul do Brasil, tendem a apresentar maiores emissões de poluentes devido ao uso de fertilizantes, pesticidas e queima de resíduos agrícolas. O uso intensivo de máquinas agrícolas que utilizam combustíveis fósseis contribui significativamente para as emissões de NO_x e SO_x . A aplicação de fertilizantes nitrogenados é uma fonte importante de emissão de NH_3 , enquanto a decomposição de resíduos vegetais pode liberar NMVOC. Em algumas regiões, a prática de queima de biomassa para preparo do solo contribui para a emissão de material particulado ($MP_{2,5}$) e outros poluentes. As condições locais, incluindo clima e topografia, também afetam a dispersão e concentração dos poluentes (Bhandari; Sessa, 2020; Mazzetto *et al.*, 2020; Meurer *et al.*, 2016).

4.2.1. Análise de Inventário – Setor: Transporte

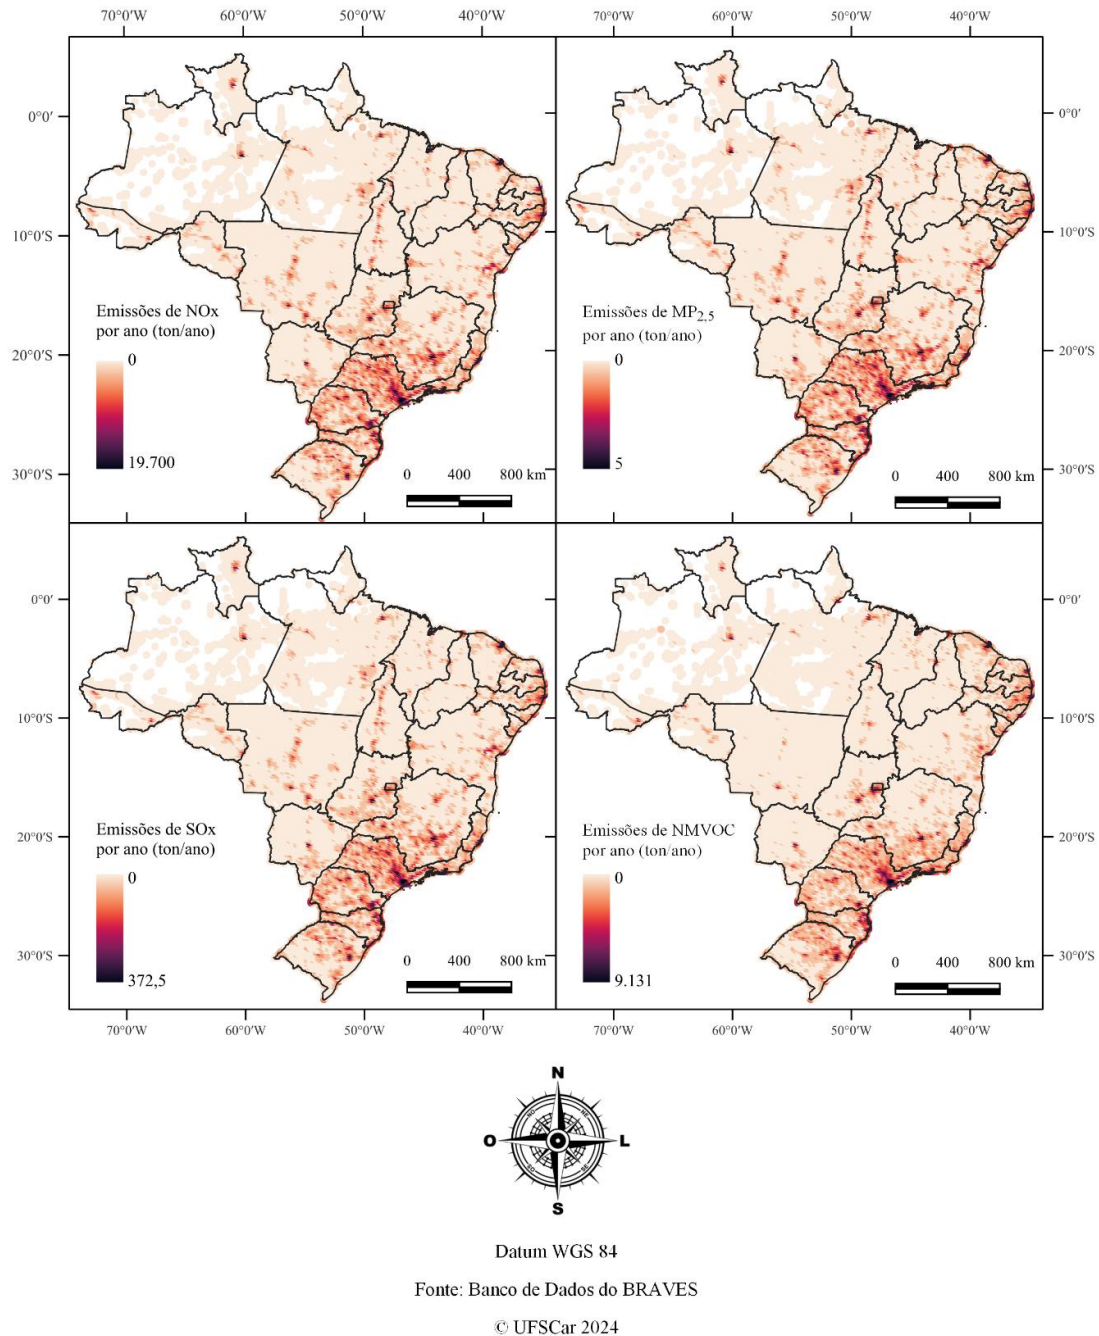
O inventário de emissões do setor de transporte no Brasil, com base nos dados dos inventários BRAVES e EDGAR v8.1, revela diferenças significativas nas emissões de poluentes em todo o território nacional. A análise crítica a seguir integra dados dos mapas, disponíveis nas Figuras 16 e 17, que correspondem aos inventários EDGAR v8.1 e BRAVES, respectivamente.

Figura 16. Mapa de Emissões do Inventário EDGAR para o setor de Transporte



Fonte: Elaboração própria utilizando o banco de dados do EDGAR v8.1, com resolução espacial de 20km x 20km.

Figura 17. Mapa de Emissões do de Inventário BRAVES,



Fonte: Elaboração própria utilizando o banco de dados do BRAVES, com resolução espacial de 20km x 20km.

Para as emissões de NO_x, tanto o BRAVES quanto o EDGAR, apresentam valores altos nas regiões sul e sudeste, entretanto enquanto o EDGAR deixa evidente as emissões nas principais rodovias do país, com menor variabilidade nos valores de emissão (média: 3,48 t/ano e desvio padrão: 12,56 t/ano), o BRAVES possui alta variabilidade, com média de 27,79 t/ano e desvio padrão de 242,94 t/ano.

Já para $MP_{2,5}$, o BRAVES apresenta emissões médias de 2,52 t/ano, enquanto o EDGAR apresenta valores extremamente baixos ($3,81E-05$ t/ano). Isso sugere que o BRAVES pode estar capturando fontes adicionais de $MP_{2,5}$ não incluídas no EDGAR.

As emissões médias de SO_x são semelhantes entre os dois inventários, mas o BRAVES apresenta maior variabilidade. Além disso, apenas o EDGAR inclui dados de NH_3 , com uma média de $3,49E-02$ t/ano.

Nas próximas seções serão apresentados os dados de teste de normalidade e de semelhança entre os inventários do setor de transporte, a fim de evidenciar melhor e quantificar as diferenças estatísticas entre os inventários BRAVES e EDGAR.

4.2.1.1. Análise Comparativa de Inventários do Setor de Transporte

A análise de normalidade dos dados utilizando o Teste de Kolmogorov-Smirnov para o setor de transporte revelou que todos os conjuntos de dados analisados não seguem uma distribuição normal (valor-p próximo de zero), os valores obtidos no teste e os gráficos Q-Q gerados a partir dos inventários de transporte estão no Apêndice B, Seção B.1.

Complementar ao teste de normalidade foram elaborados gráficos Q-Q para avaliar mais claramente a distribuição dos dados dos inventários EDGAR v8.1 e BRAVES (Apêndice B, Seção B.1, Figura 25 e Figura 26). Os gráficos demonstraram que os dados de emissões dos inventários BRAVES e EDGAR v8.1 no setor de transporte não seguem uma distribuição normal. Em cada gráfico, observa-se que os pontos se afastam significativamente da linha reta (linha de referência), especialmente nas caudas da distribuição, indicando a presença de *outliers* e uma distribuição altamente assimétrica. Esses resultados são consistentes com os valores de p inferiores a 0,05 obtidos no teste de Kolmogorov-Smirnov, validando a rejeição da hipótese nula de normalidade dos dados de emissões nos inventários analisados.

Desse modo, devido à ausência de normalidade nos dados, foi utilizado o teste de Mann-Whitney U para comparar os inventários BRAVES e EDGAR por meio de semelhança (Apêndice B, Seção B.1). Os resultados indicaram que há diferenças estatisticamente significativas nas emissões de todos os poluentes analisados entre os inventários BRAVES e EDGAR v8.1 (Apêndice B, Seção B.1, Tabela 13). Essas diferenças são evidenciadas pelos valores de p extremamente baixos (inferiores a 0,0001), o que leva à rejeição da hipótese nula em todos os casos. Isso sugere que os métodos de coleta e cálculo utilizados por cada inventário influenciam os resultados reportados nos inventários.

É importante ressaltar que um valor-p igual a zero pode ocorrer em algumas situações, especialmente em testes estatísticos com grandes conjuntos de dados. Quando se lida com um grande volume de dados, o teste estatístico pode tornar-se extremamente sensível a pequenas diferenças entre os grupos (Gómez-de-Mariscal *et al.*, 2021).

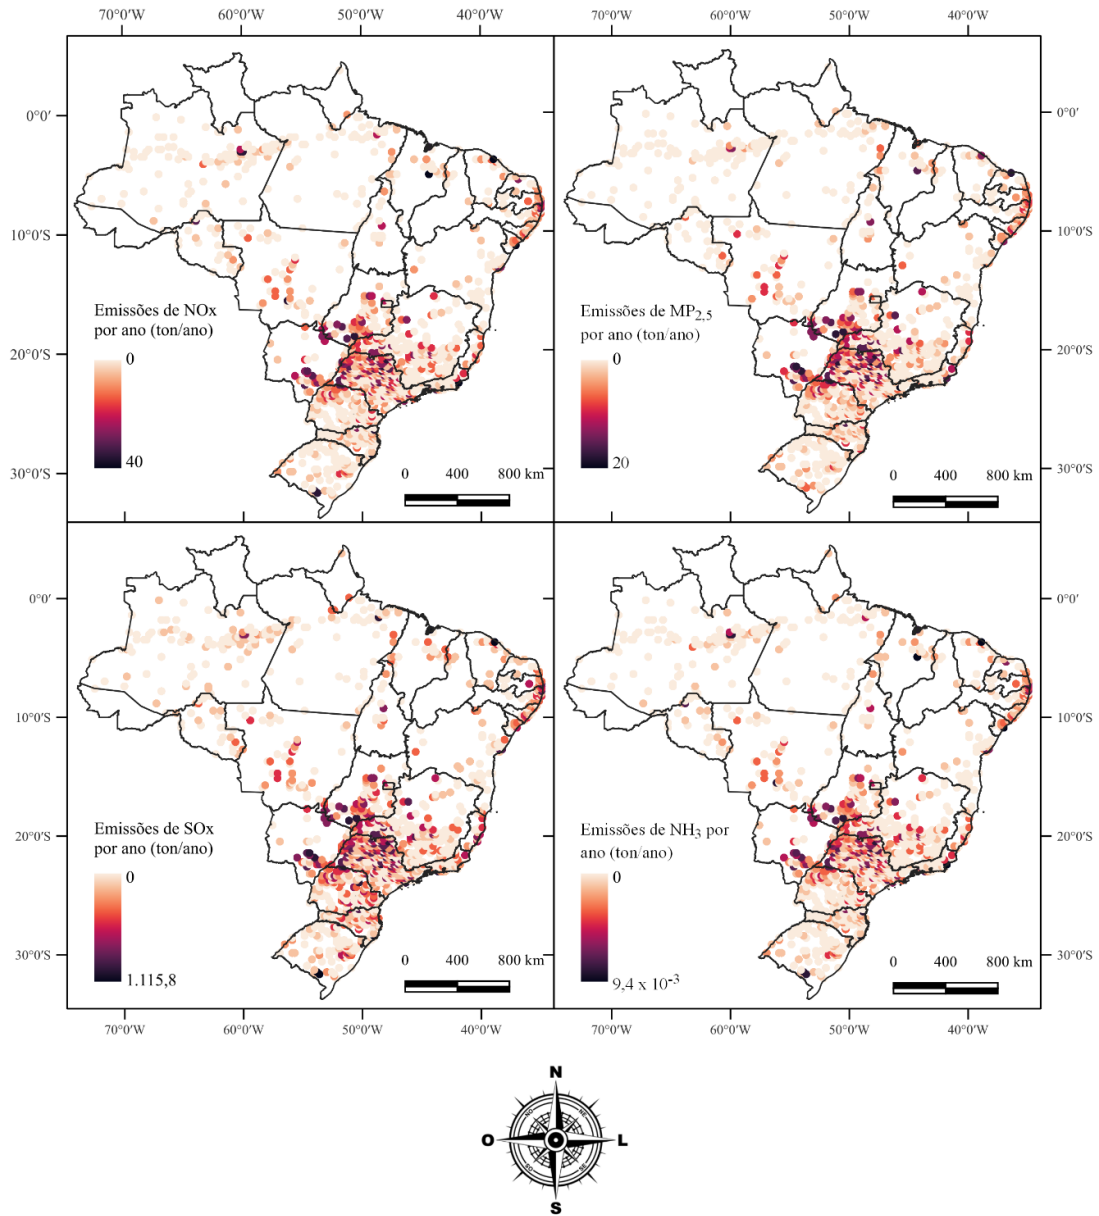
As diferenças observadas entre os inventários BRAVES e EDGAR podem ser atribuídas a várias razões. Primeiro, as metodologias utilizadas para estimar as emissões podem variar consideravelmente, resultando em diferentes níveis de precisão e abrangência. Além disso, o escopo temporal e espacial dos inventários pode influenciar as estimativas de emissões. O BRAVES, por exemplo, pode estar capturando emissões de fontes adicionais ou eventos específicos, por se tratar de um inventário nacional que possivelmente não são considerados pelo EDGAR, que é um inventário global.

Estudos recentes enfatizam a importância de metodologias precisas e abrangentes para estimar as emissões de poluentes no setor de transporte, destacando a necessidade de integrar dados de diferentes fontes e considerar variações regionais e temporais (Hoinaski *et al.*, 2022; Vedrenne *et al.*, 2016). A integração dessas diferentes abordagens pode fornecer uma visão mais holística das emissões e auxiliar no desenvolvimento de políticas públicas mais eficazes.

4.2.2. Análise de Inventário – Setor: Industrial

O inventário de emissões do setor industrial no Brasil, baseado nos dados dos inventários Rey (2023), BRAIN e EDGAR, revela diferenças significativas nas emissões de poluentes em todo o território nacional. A análise crítica integra dados dos mapas elaborados, disponíveis nas Figuras 18, 19 e 20, que correspondem aos inventários Rey (2023), BRAIN e EDGAR, respectivamente.

Figura 18. Mapa de Emissões do Inventário de Rey (2023)



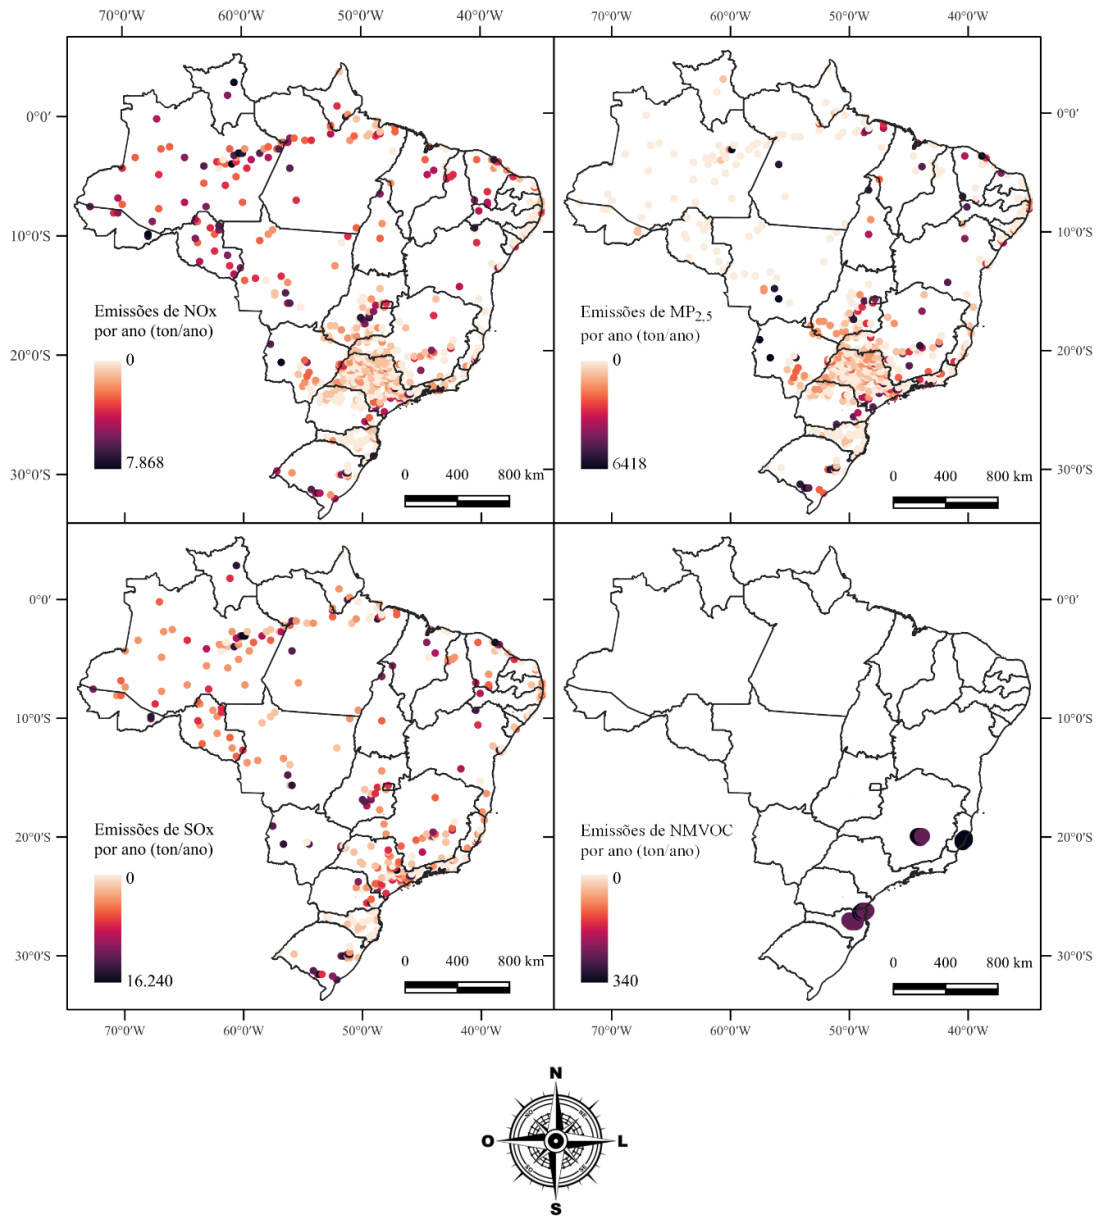
Datum WGS 84

Fonte: Banco de Dados de Rey (2023)

© UFSCar 2024

Fonte: Elaboração própria utilizando o banco de dados de Rey (2023), com resolução espacial de 20km x 20km.

Figura 19. Mapa de Emissões do Inventário BRAIN



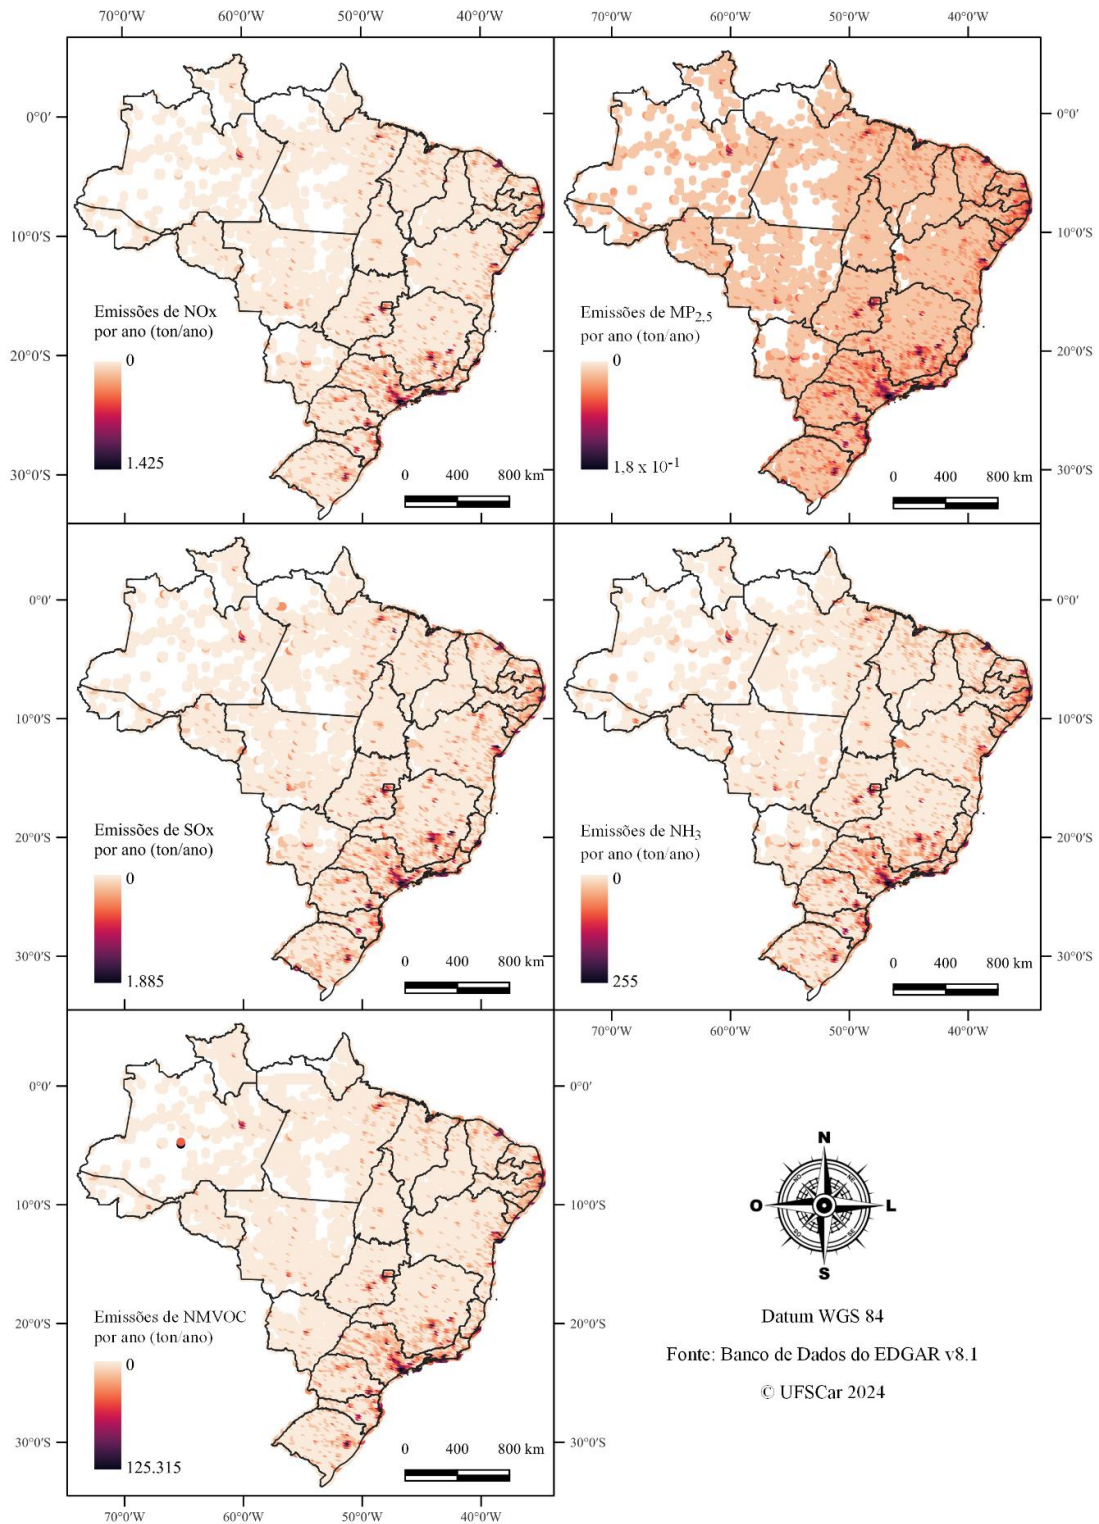
Datum WGS 84

Fonte: Banco de Dados do BRAIN

© UFSCar 2024

Fonte: Elaboração própria utilizando o banco de dados do BRAIN, com resolução espacial de 20km x 20km.

Figura 20. Mapa de Emissões do Inventário EDGAR para o setor Industrial



Fonte: Elaboração própria utilizando o banco de dados do EDGAR v8.1, com resolução espacial de 20km x 20km.

Para NO_x , as emissões são altas nas regiões sul e sudeste, especialmente em áreas industriais e centros urbanos. A média de emissões de NO_x é de $3,07\text{E-}02$ t/ano, com um desvio padrão de $0,59$ t/ano, indicando alta variabilidade. Em compensação, as emissões para o BRAIN são mais dispersas, com uma média de $2,08$ t/ano e um desvio padrão de $69,65$ t/ano. E para o inventário EDGAR, as emissões para esse poluente são mais uniformemente distribuídas.

O inventário BRAIN apresenta valores significativamente mais altos de emissões de NO_x ($2,08$ t/ano) comparado ao EDGAR ($1,80$ t/ano) e Rey (2023) ($3,07\text{E-}02$ t/ano). Esta diferença pode ser atribuída a diferentes metodologias de cálculo e escopos dos inventários.

Para $\text{MP}_{2,5}$, o inventário de Rey (2023) apresenta emissões mais concentradas em áreas industriais mais específicas, como por exemplo na região sudeste, mais especificamente no estado de São Paulo. Já no BRAIN, claramente possuem menos pontos de emissão, mas ainda permanecendo maior concentração de pontos no estado de São Paulo. O Rey (2023) apresenta emissões médias de $7,84\text{E-}03$ t/ano, enquanto o BRAIN apresenta valores maiores ($0,95$ t/ano) e o EDGAR apresenta valores menores ($1,93\text{E-}04$ t/ano). Isso sugere que o BRAIN pode estar capturando fontes adicionais de $\text{MP}_{2,5}$ não incluídas no EDGAR e Rey (2023).

De acordo com o mapa do inventário de Rey (2023), é possível observar que as emissões de SO_x são relativamente baixas, com uma média de $0,16$ t/ano e um desvio padrão de $13,64$ t/ano. Em contrapartida, o modelo BRAIN apresenta emissões de SO_x significativamente mais altas, com uma média de $3,10$ t/ano e um desvio padrão de $160,61$ t/ano. Já o modelo EDGAR mostra emissões de SO_x moderadas, com uma média de $1,25$ t/ano e um desvio padrão de $16,18$ t/ano.

Apenas o EDGAR inclui dados significativos de NH_3 , com uma média de $0,25$ toneladas por ano. O inventário Rey (2023) apresenta valores mínimos de NH_3 ($7,23\text{E-}06$ t/ano) e o BRAIN não inclui NH_3 . O EDGAR apresenta valores extremamente altos de emissões de NMVOC ($174,82$ t/ano) comparado ao BRAIN ($1,16\text{E-}02$ t/ano), indicando possíveis diferenças nas fontes consideradas.

As diferenças observadas entre os inventários Rey (2023), BRAIN e EDGAR podem ser atribuídas a várias razões. Assim como para o setor de transporte, as metodologias utilizadas para estimar as emissões variam consideravelmente, resultando em diferentes níveis de precisão e abrangência. Além disso, o escopo temporal e espacial dos inventários influencia as estimativas de emissões. O BRAIN, por exemplo, pode estar capturando emissões de fontes adicionais ou eventos específicos que não são considerados pelo EDGAR e Rey (2023).

Na próxima seção serão apresentados os dados de teste de normalidade e de semelhança entre os inventários do setor industrial, a fim de evidenciar melhor e quantificar as diferenças estatísticas entre os inventários Rey (2023), BRAIN e EDGAR.

4.2.2.1. Análise Comparativa de Inventários do Setor Industrial

A análise de normalidade dos dados utilizando o Teste de Kolmogorov-Smirnov para o setor industrial revelou que todos os conjuntos de dados analisados não seguem uma distribuição normal, com valores p próximos a zero (Apêndice B, Seção B.2). Complementar ao teste de normalidade, como no setor de transporte, foi elaborado gráficos Q-Q para avaliar mais claramente a distribuição dos dados dos inventários EDGAR v8.1, Rey (2023) e BRAIN.

Do mesmo modo que inventários do setor de transporte, os gráficos Q-Q demonstram que os dados de emissões dos inventários do setor industrial não seguem uma distribuição normal. Esses resultados são consistentes com os valores de p inferiores a 0,05 obtidos no teste de Kolmogorov-Smirnov, validando a rejeição da hipótese nula de normalidade dos dados de emissões nos inventários analisados.

Desse modo, devido à ausência de normalidade nos dados, foi utilizado o teste de Kruskal-Wallis para comparar os inventários EDGAR, Rey (2023) e BRAIN por meio de um teste de semelhança. Entretanto, quando há três ou mais grupos, um teste global (como o Kruskal-Wallis) é útil para determinar se há alguma diferença significativa entre os grupos como um todo. Se o teste global indicar significância, os testes post-hoc são, então, usados para identificar especificamente quais grupos diferem uns dos outros.

Desse modo, no setor industrial, além do teste de semelhança, foi realizado um teste post-hoc (teste de Dunn) para avaliar e identificar diferenças específicas entre os grupos. Após a análise inicial, neste teste obtém-se como resultado uma matriz de valores p do teste de Dunn post hoc, ajustados por Bonferroni para múltiplas comparações. Essa matriz mostra os resultados das comparações entre cada par de inventários (BRAIN, EDGAR e Rey (2023)) para o poluente específico analisado. Os resultados do teste Kruskal-Wallis e o teste de Dunn estão dispostos na Tabela 9.

Tabela 8. Teste Kruskal-Wallis e teste de Dunn para o setor Industrial

| Teste para MP_{2,5}: | | | |
|--------------------------------------------------|--------------|--------------|-------------------|
| Estatística de Kruskal-Wallis: 99.108,72 | | | |
| Valor de p: 0,000 | | | |
| Valores de p pós-teste (teste de Dunn): | | | |
| | BRAIN | EDGAR | Rey (2023) |
| BRAIN | 1 | | |
| EDGAR | 0 | 1 | |
| Rey (2023) | 6,47E-03 | 0 | 1 |
| Teste para NO_x: | | | |
| Estatística de Kruskal-Wallis: 93.339,22 | | | |
| Valor de p: 0,000 | | | |
| Valores de p pós-teste (teste de Dunn): | | | |
| | BRAIN | EDGAR | Rey (2023) |
| BRAIN | 1 | | |
| EDGAR | 0 | 1 | |
| Rey (2023) | 8,66E-03 | 0 | 1 |
| Teste para SO_x: | | | |
| Estatística de Kruskal-Wallis: 98.596,29 | | | |
| Valor de p: 0,000 | | | |
| Valores de p pós-teste (teste de Dunn): | | | |
| | BRAIN | EDGAR | Rey (2023) |
| BRAIN | 1 | | |
| EDGAR | 0 | 1 | |
| Rey (2023) | 5,90E-04 | 0 | 1 |
| Teste para NMVOC: | | | |
| Estatística de Kruskal-Wallis: 497.921,70 | | | |
| Valor de p: 0,000 | | | |
| Valores de p pós-teste (teste de Dunn): | | | |
| | BRAIN | EDGAR | Rey (2023) |
| BRAIN | 1 | | |
| EDGAR | 0 | 1 | |
| Rey (2023) | 1 | 0 | 1 |

Fonte: Autoria própria.

A análise dos resultados dos testes de Kruskal-Wallis e post-hoc (teste de Dunn) revela diferenças estatisticamente significativas nas distribuições de emissões reportadas. O teste de Kruskal-Wallis demonstra que, para todos os poluentes analisados, existe uma variação

significativa entre os inventários, com valores p consistentemente iguais a 0,0000, indicando a rejeição da hipótese de igualdade de distribuições.

Nos resultados post-hoc, padrões distintos entre os poluentes foram observados. Para NMVOC e SO_x, existe uma clara divisão, em que os inventários BRAIN e Rey (2023) não apresentam diferenças significativas entre si (valor p = 1), mas ambos mostram diferenças significativas quando comparados com EDGAR. Esse resultado sugere que as metodologias ou os dados subjacentes utilizados por EDGAR para NMVOC e SO_x são substancialmente diferentes dos adotados por BRAIN e Rey (2023), que compartilham maior consistência metodológica.

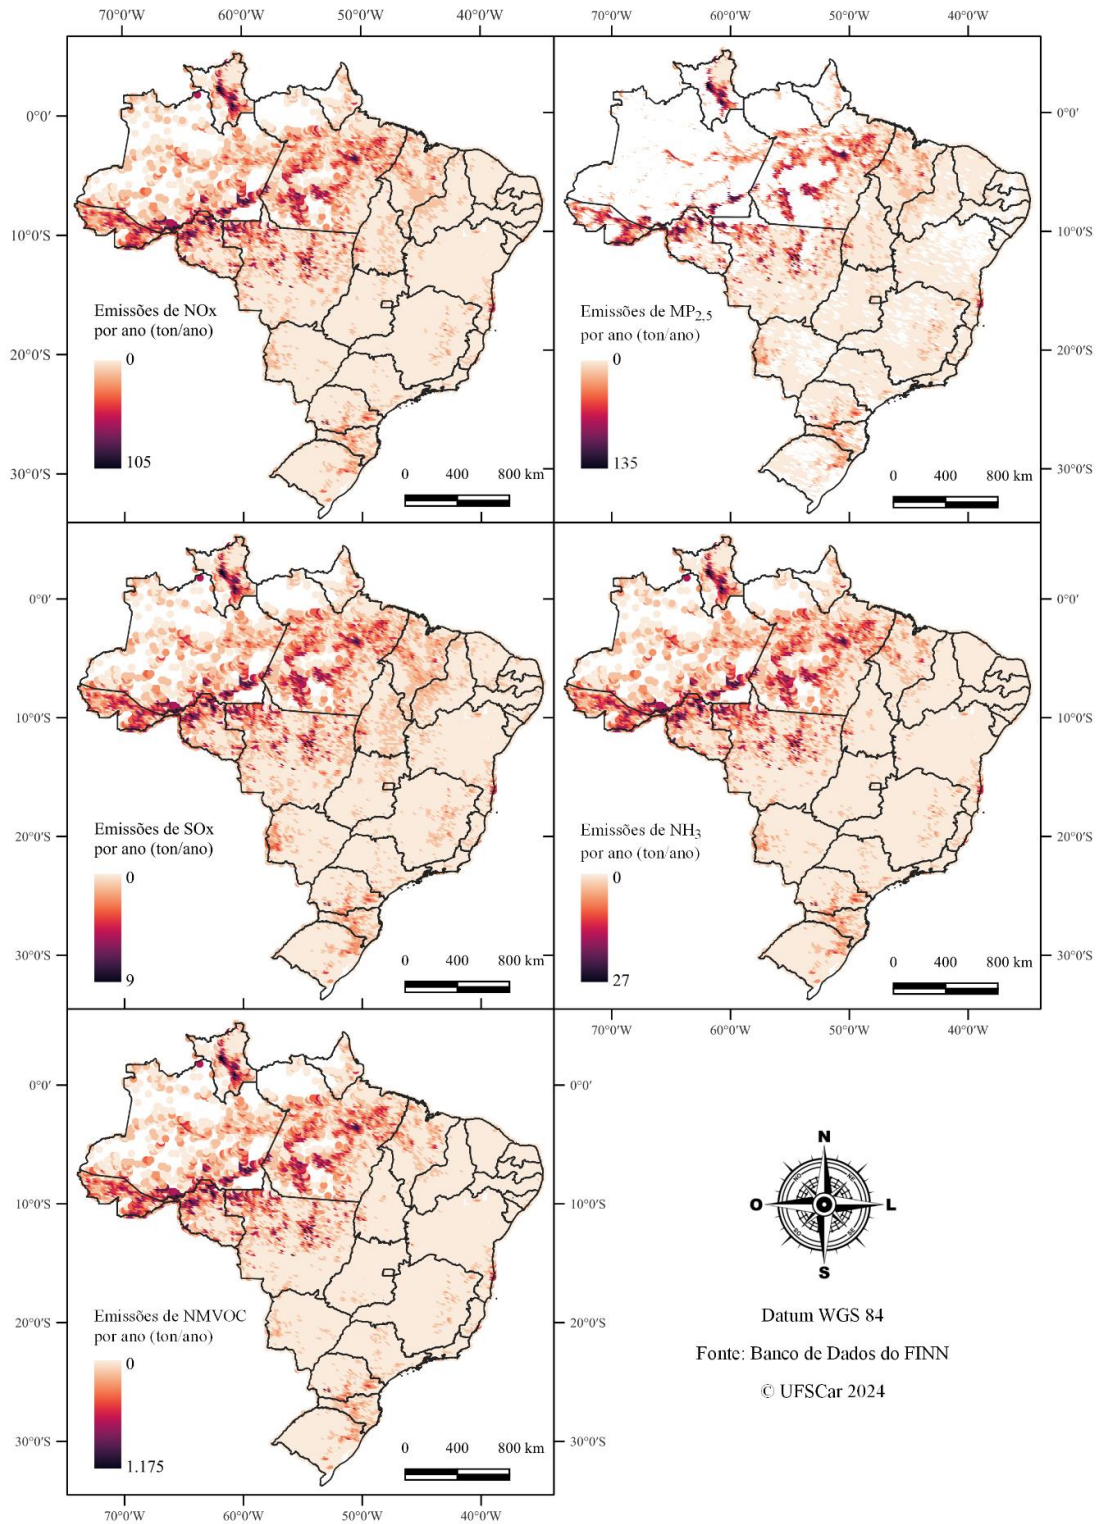
Para NO_x e MP_{2,5}, os resultados do teste post-hoc são diferentes. BRAIN e Rey (2023) mostram uma diferença para NO_x (valor p = 0,00866) e MP_{2,5} (valor p = 0,006472), indicando variações menores, mas ainda estatisticamente relevantes. Para SO_x, observa-se uma diferença mínima, mas estatisticamente significativa entre BRAIN e Rey (2023) (valor p = 0,00059), enquanto as comparações com EDGAR resultam em diferenças significativas (valor p = 0) para todos os poluentes.

Essas diferenças sublinham a existência de variações substanciais nas abordagens de inventário entre BRAIN, EDGAR e Rey (2023), especialmente no que tange à coleta, processamento e representação dos dados de emissões. Para NMVOC e SO_x, a consistência entre BRAIN e Rey (2023) sugere uma metodologia similar, em contraste com EDGAR que parece utilizar abordagens divergentes. Por outro lado, as diferenças observadas em NO_x e MP_{2,5} entre BRAIN e Rey (2023), embora menores, reforçam a necessidade de harmonização nas práticas de inventário para assegurar análises comparativas precisas e efetivas na formulação de políticas de controle da poluição atmosférica.

4.2.3. Análise de Inventário – Setor: Queima de Biomassa (FINN)

A análise do inventário de emissões para o setor de queima de biomassa no Brasil revela importantes discussões sobre a distribuição espacial e a intensidade das emissões de poluentes. Com base no mapa gerado (Figura 21), padrões distintos na distribuição das emissões foram observados.

Figura 21. Mapa de Emissões do Inventário FINN



Fonte: Elaboração própria utilizando o banco de dados do FINN, com resolução espacial de 20km x 20km.

O mapa evidencia que as emissões de NO_x e $\text{MP}_{2,5}$ estão concentradas principalmente nas regiões Norte e Centro-Oeste, com pontos de alta intensidade também no Sudeste e Sul. As emissões de SO_x e NH_3 são menos intensas em comparação com outros poluentes, mas ainda mostram concentrações notáveis nas regiões Norte e Centro-Oeste. As emissões de NMVOC são bastante elevadas no Norte, especialmente na região amazônica.

Essas áreas coincidem com regiões de intensa atividade agrícola e práticas de desmatamento, em que a queima de biomassa é frequentemente utilizada para a limpeza de terras. A proximidade das emissões com áreas de reserva natural e habitats sensíveis indica um risco elevado de impactos ambientais adversos, incluindo a degradação da qualidade do ar e danos à biodiversidade.

Diferentes tipos de biomassa (resíduos agrícolas, madeira etc.) emitem diferentes quantidades de poluentes, e regiões com maior uso de biomassa de alta emissão tendem a ter maiores concentrações de poluentes. Além disso, a eficiência e os métodos de queima variam significativamente, afetando a quantidade de emissões. Métodos de queima⁵ menos eficientes resultam em maiores emissões de poluentes. A presença (ou ausência) de políticas ambientais rigorosas também pode influenciar as emissões, com regiões mais regulamentadas tendendo a ter menores emissões (Chen *et al.*, 2017).

Observa-se que a média das emissões de NMVOC é de 9,55 toneladas por ano, com um desvio padrão de 44,24, indicando uma grande variabilidade. Esse alto desvio padrão sugere que há picos significativos de emissões em determinadas regiões, o que é confirmado pelo mapa que mostra altas concentrações de NMVOC no Norte.

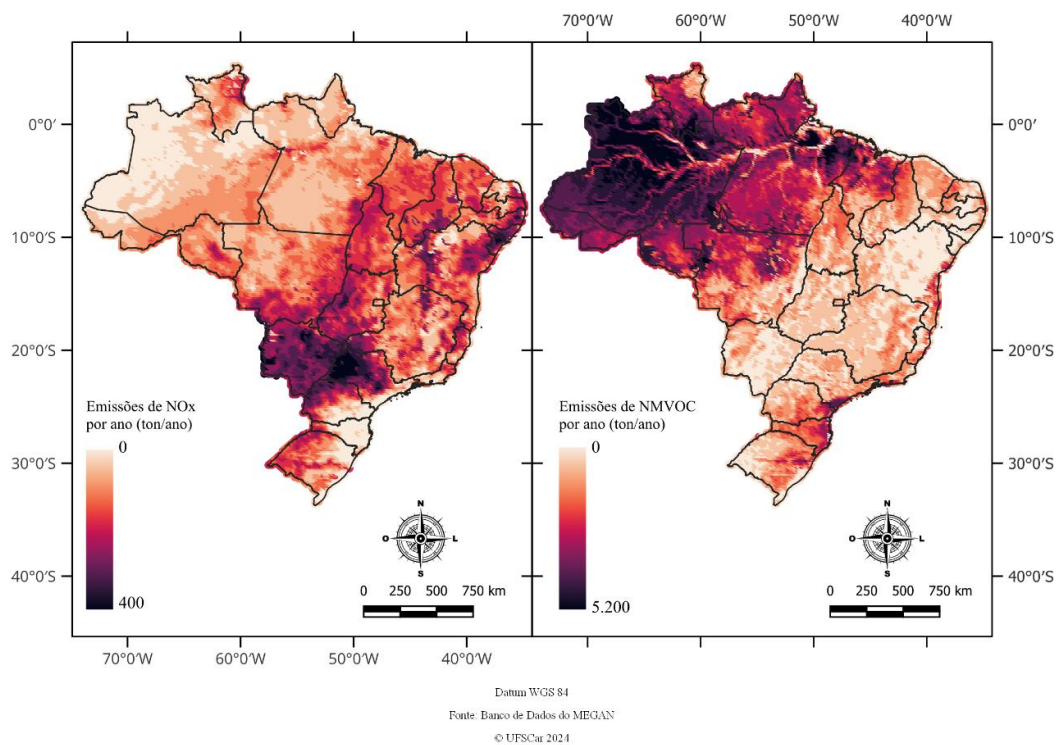
Para NH_3 , a média das emissões é de 0,23 toneladas por ano, com um desvio padrão de 1,02. Embora as emissões de NH_3 sejam relativamente baixas, a variabilidade é significativa, o que também é refletido no mapa com dispersão em várias regiões.

⁵ Os métodos de queima de biomassa variam em eficiência e impacto ambiental. A queima a céu aberto e o uso de fogões tradicionais são métodos ineficientes que liberam grandes quantidades de poluentes, como material particulado, monóxido de carbono e compostos orgânicos voláteis. Em contraste, métodos como fogões melhorados, pirólise e gaseificação, usados em contextos mais controlados, são mais eficientes e emitem menos poluentes (INMET, 2022).

4.2.4. Análise de Inventário – Setor: Emissões biogênicas (MEGAN)

A análise do inventário de emissões para o setor de emissões biogênicas no Brasil revela pontos importantes a serem analisados, a discussão tem como base o mapa gerado (Figura 22), em que padrões distintos na distribuição das emissões de NMVOC e NO_x foram observados.

Figura 22. Mapa de Emissões do Inventário MEGAN



Fonte: Elaboração própria utilizando o banco de dados do MEGAN, com resolução espacial de 20km x 20km.

O mapa evidencia que as emissões de NO_x estão concentradas principalmente nas regiões Centro-Oeste e Sudeste, com pontos de alta intensidade também no Sul e em partes do Norte. As emissões de NMVOC são particularmente elevadas na região amazônica, mostrando uma clara distinção na distribuição em relação a outros poluentes.

Essas áreas coincidem com regiões de intensa atividade biológica e florestal, onde a emissão de compostos orgânicos voláteis não metano (NMVOC) é elevada devido à presença abundante de vegetação. Diferentes tipos de vegetação emitem diferentes quantidades de compostos orgânicos voláteis, e regiões com maior densidade florestal tendem a ter maiores concentrações de NMVOC. Além disso, a atividade fotossintética e a decomposição de matéria orgânica são fontes significativas de NMVOC.

Estudos recentes avaliam a variabilidade das emissões biogênicas e seus impactos. Como por exemplo, Wang et al. (2020) analisaram os efeitos das emissões de compostos orgânicos voláteis biogênicos (BVOCs) e suas interações com o ozônio (O_3) na região do Delta do Rio Yangtzé. Os autores descobriram que as emissões de isopreno (ISOP) são restritas nas áreas urbanas devido ao *feedback* negativo para a exposição ao O_3 em florestas decíduas. A estimativa de emissões de BVOCs depende fortemente dos fatores de emissão e dos dados de cobertura do solo, mostrando variações significativas com diferentes conjuntos de dados de cobertura vegetal.

Sendo assim, as práticas de uso da terra, como a conversão de florestas em terras agrícolas, têm um impacto significativo nas emissões de N_2O e NO . Mudanças na disponibilidade de nitrogênio e no espaço poroso preenchido com água são fatores críticos que devem ser monitorados ao estudar as emissões de N_2O e NO após a mudança no uso da terra (Lent; Hergoualc'h; Verchot, 2015).

A distribuição das emissões de NMVOC e NO_x no Brasil varia significativamente conforme a cobertura vegetal e a atividade biológica. Isso destaca a necessidade de abordagens regionais específicas ao desenvolver políticas de mitigação. Políticas ambientais devem considerar a densidade da vegetação e a atividade biológica local para serem eficazes.

4.3. Análise e Interpretação dos Resultados do Modelo InMAP

Nesta seção, serão apresentados os resultados obtidos pelo modelo InMAP, divididos em seis conjuntos distintos de dados, detalhados na Tabela 10. Esses conjuntos resultaram em seis arquivos *shapefiles*, cada um representando dados de concentração em microgramas por metro cúbico ($\mu g/m^3$) de $MP_{2,5}$.

Cada arquivo foi gerado a partir dos dados de entrada específicos para cada conjunto, refletindo as diferentes combinações de fontes emissoras. Por exemplo, o conjunto C_01 inclui dados de emissões agrícolas e industriais provenientes do inventário EDGAR, emissões de transporte do inventário BRAVES, queima de biomassa do inventário FINN e emissões biogênicas do modelo MEGAN.

Além da apresentação da concentração de $MP_{2,5}$ obtida pelo modelo, será apresentada uma análise comparativa dos dados de monitoramento disponíveis pela CETESB com os dados de concentração estimados pelo modelo InMAP utilizando a raiz do erro quadrático médio.

4.3.1. Mapas de concentração de MP_{2,5}

Os mapas de concentração, representados em microgramas por metro cúbico ($\mu\text{g}/\text{m}^3$), permitem uma visualização clara das áreas de maior e menor concentração de MP_{2,5} em todo o Brasil. Relembrando, os seis conjuntos estão dispostos na Tabela 10.

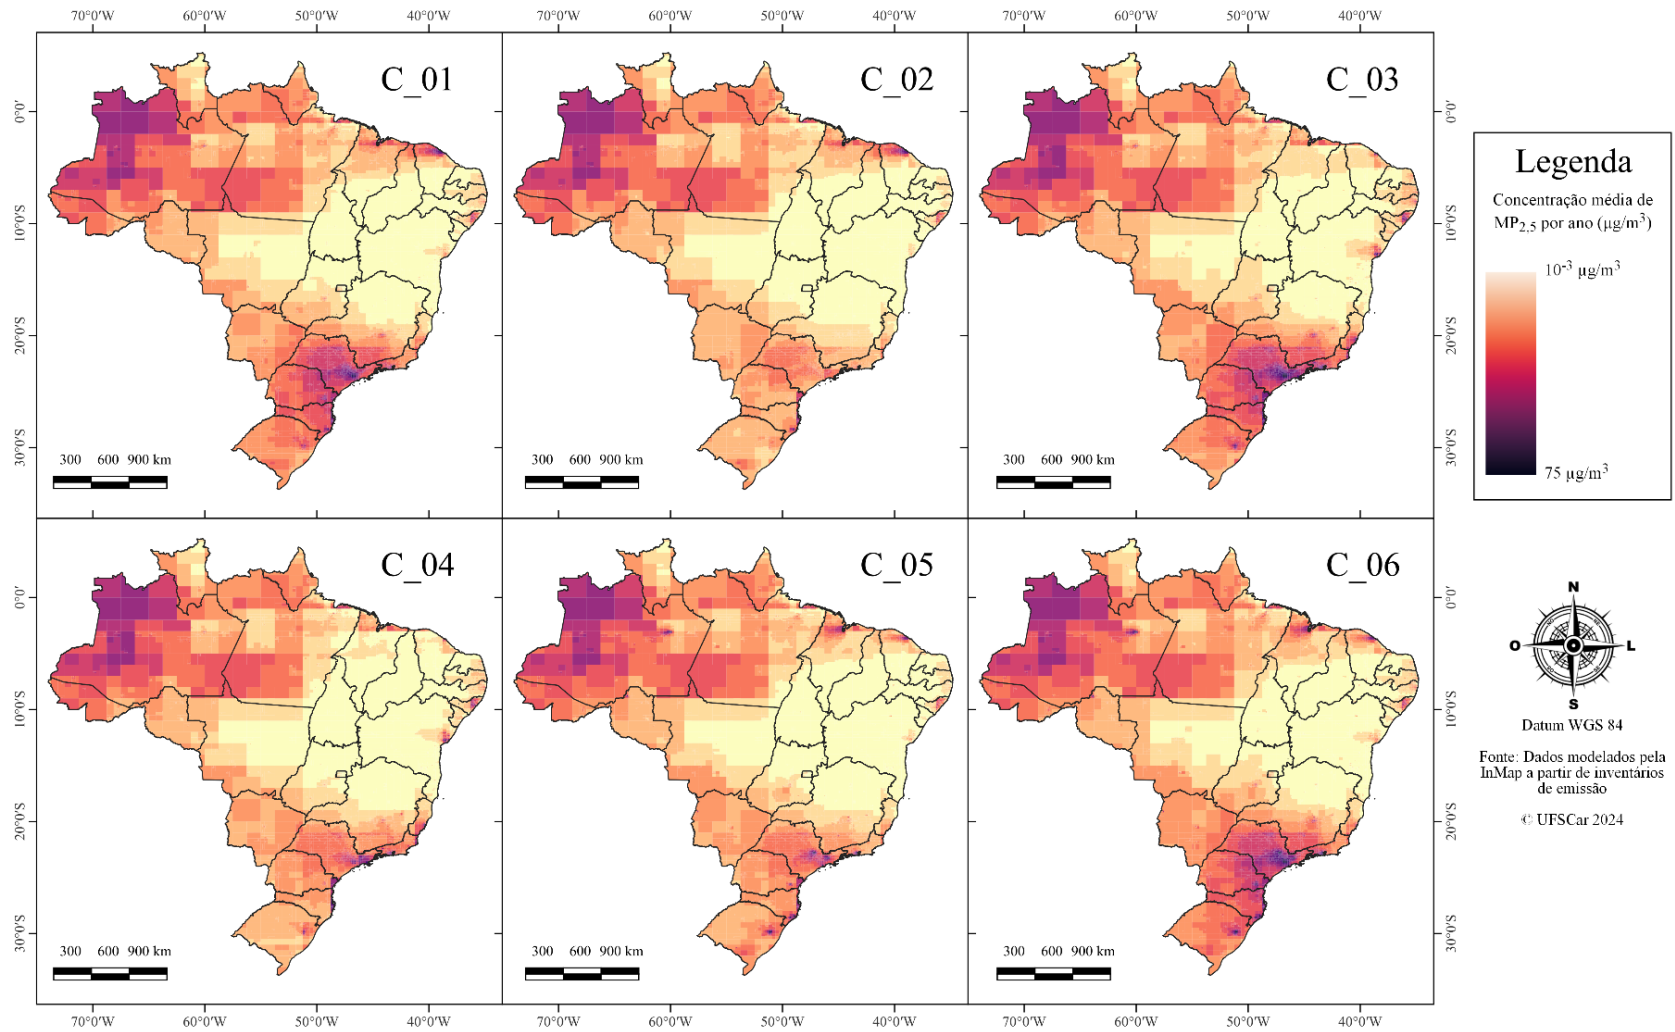
Tabela 9. Conjunto de inventários

| Conjuntos | Agricultura | Industrial | Transporte | Queima de biomassa | Emissões biogênicas |
|-----------|-------------|------------|------------|--------------------|---------------------|
| C_01 | | Rey (2023) | BRAVES | | |
| C_02 | | Rey (2023) | EDGAR | | |
| C_03 | EDGAR | EDGAR | BRAVES | FINN | MEGAN |
| C_04 | | EDGAR | EDGAR | | |
| C_05 | | IND_BRAIN | BRAVES | | |
| C_06 | | IND_BRAIN | EDGAR | | |

Fonte: Autoria própria.

Desse modo, após a realização das etapas de coleta e padronização dos dados de inventário, análise e configuração do modelo InMAP, foram rodados os seis conjuntos apresentados na Tabela 10 no modelo de dispersão. A Figura 23 ilustra os resultados obtidos após processamento dos inventários pelo InMAP, apresentando a distribuição espacial das concentrações de poluentes, em $\mu\text{g}/\text{m}^3$, para cada conjunto de dados, permitindo uma análise visual comparativa.

Figura 23. Distribuição Espacial das Concentrações de MP_{2,5} nos Seis Conjuntos de Dados



Fonte: Autoria própria.

Em todos os conjuntos, há uma tendência de concentrações mais altas de poluentes nas regiões norte e sudeste do Brasil, com variações menores em outras regiões. Isso pode ser atribuído a fatores como a densidade populacional, atividade industrial e, no caso do norte, queimadas na região amazônica. Conjuntos como o C_01 e o C_03 apresentam padrões de concentração similares, indicando possíveis semelhanças nas combinações de inventários utilizados, o que sugere que certas fontes emissoras têm um impacto consistente independentemente das combinações específicas.

Na região norte, as altas concentrações de $MP_{2,5}$ podem ser explicadas pela falta de alternativas tecnológicas e infraestrutura adequada para o manejo de terras, o que torna as queimadas uma prática comum na Amazônia. Muitas dessas queimadas são intencionais, realizadas para limpar áreas destinadas à agricultura e pecuária. O desmatamento contínuo, frequentemente associado a essas queimadas, também contribui significativamente para a emissão de partículas. Quando grandes porções de floresta são derrubadas, o material orgânico resultante é geralmente queimado, liberando $MP_{2,5}$ na atmosfera (MCTI, 2023).

A expansão do agronegócio, especialmente nas culturas de soja e na pecuária, é um dos principais fatores que impulsionam o desmatamento e as queimadas na região. A prática da agricultura de corte e queima, em que a floresta é derrubada e queimada para preparar o solo, libera grandes quantidades de MP no ar (Aragão *et al.*, 2018; Brando *et al.*, 2020).

Além disso, as condições meteorológicas em certas épocas do ano na Amazônia, como durante a estação seca, podem favorecer a estabilidade atmosférica, dificultando a dispersão dos poluentes. Isso resulta em uma maior concentração de $MP_{2,5}$ próximo ao solo, exacerbada pela intensificação das queimadas nesse período (Brando *et al.*, 2020)

As altas concentrações de $MP_{2,5}$ na região sudeste podem ser explicadas por uma combinação de fatores relacionados à urbanização, industrialização, tráfego de veículos e condições meteorológicas específicas. A Região Metropolitana de São Paulo, uma das maiores e mais populosas do mundo, com mais de 20 milhões de habitantes, apresenta uma demanda intensa por transporte, energia e outros serviços, o que leva a emissões significativas de poluentes atmosféricos, incluindo $MP_{2,5}$. A expansão urbana desordenada, marcada pela construção de rodovias, indústrias e moradias, amplia as fontes de poluição e intensifica a liberação de MP (Wikuats *et al.*, 2023).

São Paulo é o estado mais industrializado do Brasil, abrigando indústrias petroquímicas, siderúrgicas, de cimento, entre outras, que são grandes emissores de $MP_{2,5}$. A proximidade

dessas indústrias das áreas urbanas aumenta a concentração de poluentes no ar. Durante o inverno, a Região Metropolitana de São Paulo frequentemente enfrenta inversões térmicas, um fenômeno em que uma camada de ar quente aprisiona os poluentes próximos ao solo, dificultando sua dispersão. Além disso, a topografia da região, cercada por serras, contribui para a acumulação de $MP_{2,5}$ na atmosfera, intensificando os problemas de qualidade do ar (CETESB, 2023).

Em compensação, na região nordeste as concentrações são consideravelmente baixas, entretanto nos estados da Bahia e de Alagoas, mais precisamente na região das cidades de Salvador e Maceió, respectivamente, é possível observar concentrações mais elevadas de $MP_{2,5}$ em todos os conjuntos de dados. Isso pode ocorrer por diversos fatores, em primeiro lugar, o Polo Industrial de Camaçari, próximo a Salvador, é um dos maiores complexos industriais da América Latina, abrigando indústrias petroquímicas, químicas e automobilísticas, que são grandes emissoras de poluentes atmosféricos (Santos, 2024). Maceió, por sua vez, possui áreas industriais relacionadas à produção de açúcar e álcool, além de indústrias químicas e metalúrgicas, que também contribuem para a emissão de MP na atmosfera (Albuquerque Jr., 2023).

As emissões de transporte também são um fator, Salvador, sendo a terceira maior cidade do Brasil em termos de população, possui uma alta densidade populacional e uma frota de veículos significativa, sendo muitos deles movidos a diesel, um dos principais responsáveis pela emissão de $MP_{2,5}$. Maceió, mesmo sendo menor, também apresenta uma frota considerável para a região. O tráfego intenso e os congestionamentos constantes nessas cidades contribuem diretamente para o aumento das emissões de MP (Albuquerque Jr., 2023).

Além disso, as atividades portuárias nas duas cidades têm impacto nas concentrações de $MP_{2,5}$. O Porto de Salvador, um dos mais movimentados do Brasil, e o Porto de Maceió, embora em menor escala, geram emissões significativas de poluentes devido ao tráfego marítimo, que utiliza combustíveis de alta emissão, como o óleo bunker (Albuquerque Jr., 2023; Santos, 2024).

Esses fatores combinados, mais a queima de biomassa como cana-de-açúcar na região, mais o crescimento urbano desordenado explicam as concentrações mais elevadas de $MP_{2,5}$ nas regiões de Salvador e Maceió em comparação com o restante do nordeste.

Já a região sul, é possível observar concentrações mais homogêneas, sendo mais elevadas que a região nordeste e centro-oeste, porém menos intensas que as concentrações do norte e do sudeste. Entretanto, existem áreas de maior concentração de $MP_{2,5}$ no Sul,

principalmente na região Leste do Paraná, próximo a região de Curitiba, em Santa Catarina, na região dos municípios de Gravatal, Capivari de Baixo e Tubarão e no Rio Grande do Sul próximo a região metropolitana de Porto Alegre.

A região leste do Paraná, especialmente nas proximidades de Curitiba, é caracterizada por uma intensa atividade industrial, incluindo setores petroquímico, metalúrgico e de papel e celulose, que são fontes significativas de emissões de $MP_{2,5}$. A proximidade dessas indústrias a áreas urbanas densamente povoadas, aliada a uma grande frota de veículos a diesel, como caminhões e ônibus, contribui substancialmente para as elevadas concentrações de MP. Como um dos principais polos industriais do sul do Brasil e uma das cidades mais populosas do país, Curitiba enfrenta uma alta demanda por transporte e energia, fatores que intensificam as emissões de $MP_{2,5}$ (Gidhagen *et al.*, 2021). Além disso, as frequentes inversões térmicas durante o inverno aprisionam os poluentes próximos ao solo, dificultando a dispersão e resultando em concentrações mais elevadas de $MP_{2,5}$ na região (Andrade *et al.*, 2012).

Já em Santa Catarina, tem-se o Complexo Termoelétrico Jorge Lacerda, localizado na região de Capivari de Baixo, é um dos maiores do Brasil e é conhecido por utilizar carvão mineral como fonte de energia. A queima de carvão é uma das principais fontes de emissão de $MP_{2,5}$, contribuindo significativamente para as altas concentrações de partículas na região. A região também é conhecida pela extração e beneficiamento de carvão, o que resulta em emissões adicionais de $MP_{2,5}$ (Honscha *et al.*, 2022).

Por fim, Porto Alegre, a capital do estado e maior cidade da região sul, possui uma alta densidade populacional e condições meteorológicas que favorecem a estabilidade atmosférica, como as inversões térmicas típicas do inverno. Essas inversões dificultam a dispersão dos poluentes, resultando em elevadas concentrações de $MP_{2,5}$ próximas ao solo. A cidade e seus arredores abrigam indústrias significativas, incluindo os setores petroquímico, metalúrgico e alimentício, que são grandes emissoras de MP (Teixeira *et al.*, 2012).

Em compensação é possível observar que a região centro-oeste possui baixas concentrações de $MP_{2,5}$ mesmo diante da ocorrência de queimadas, intensa atividade agrícola e períodos de seca que acontecem na região (Santos *et al.*, 2019). Isso pode ser justificado por uma combinação de fatores que incluem menores emissões de precursores, condições meteorológicas favoráveis à dispersão de poluentes e limitações nos inventários de emissões utilizados na modelagem pelo InMAP.

A região Centro-Oeste, possui menores emissões de precursores de $MP_{2,5}$, como NO_x , SO_x , NH_3 e $NMVOC$, em comparação com outras regiões do país, como o Sudeste. Por exemplo, segundo o inventário de Rey (2023), as emissões de NO_x no Centro-Oeste são de 2.466,44 t/ano ($\mu = 6,29E-02$ t/ano; $\sigma = 5,37E-01$), enquanto no Sudeste atingem 7.873,98 t/ano ($\mu = 3,34E-01$ t/ano; $\sigma = 1,44$ t/ano). Isso, possivelmente, se deve à menor concentração de atividades industriais e urbanas intensivas, que são grandes fontes desses poluentes.

Essa região é caracterizada por uma topografia plana e extensa, sem barreiras naturais significativas que impeçam a circulação atmosférica. Durante a estação seca, comum na região, ocorrem temperaturas elevadas e baixos índices de umidade relativa do ar, frequentemente abaixo de 30% (INMET, 2022). Essas condições favorecem a formação de correntes térmicas ascendentes, que aumentam a mistura vertical na atmosfera.

Outra justificativa para essa discrepância são as possíveis deficiências na coleta de dados, como subnotificação de queimadas ilegais ou emissões difusas na agricultura, que podem levar à subestimação das emissões reais. A falta de atualizações frequentes nos inventários e a ausência de dados locais detalhados contribuem para essa limitação.

Sendo assim, comparando os diferentes conjuntos, embora existam variações, a diferença nos padrões de concentração não é drasticamente distinta entre os mapas. Esse fenômeno pode indicar que as principais fontes emissoras e as condições ambientais exercem uma influência similar nos resultados dos diferentes conjuntos. Além disso, a consistência nos padrões sugere que as atividades industriais e a densidade populacional são fatores predominantes que contribuem para as emissões de poluentes. As áreas com maior densidade populacional e atividades industriais, como esperado, tendem a apresentar as maiores concentrações de poluentes.

4.3.2. Comparação das concentrações simuladas no InMAP com dados monitorados

Ao aplicar a Equação 16 e calcular a Raiz do Erro Quadrático Médio entre os dados simulados pelo InMAP e os dados de monitoramento obteve-se que os valores de RMSE obtidos para cada conjunto de inventários variaram de 7,40 até 12,90. A Tabela 10 apresenta o RMSE para cada combinação de inventários, sendo que em todas as combinações, o inventário de emissões agrícolas foi o EDGAR, queima de biomassa foi o FINN e emissões biogênicas foi o MEGAN.

Tabela 10. RMSE dos conjuntos de inventários modelados no InMAP

| Conjuntos | Industrial | Transporte | RMSE |
|------------------|-------------------|-------------------|-------------|
| C_01 | Rey (2023) | BRAVES | 8,78 |
| C_02 | Rey (2023) | EDGAR | 12,90 |
| C_03 | EDGAR | BRAVES | 7,40 |
| C_04 | EDGAR | EDGAR | 11,09 |
| C_05 | IND_BRAIN | BRAVES | 9,30 |
| C_06 | IND_BRAIN | EDGAR | 12,04 |

Fonte: Autoria própria.

Os valores de RMSE indicam a precisão do modelo InMAP em relação aos dados de monitoramento. Os menores valores de RMSE, observados nos conjuntos C_03 e C_01, sugerem que essas combinações de fontes emissoras fornecem as estimativas mais precisas. Em contraste, os conjuntos C_06 e C_02 apresentaram os maiores valores de RMSE, indicando maior discrepância entre os dados de modelagem e os dados de monitoramento.

Com um RMSE de 7,40, o C_03 apresentou a melhor performance, sugerindo que a combinação de fontes emissoras utilizadas (EDGAR para agricultura e industrial, BRAVES para transporte, FINN para queima de biomassa e MEGAN para emissões biogênicas) é a mais precisa para a modelagem de concentração de poluentes no cenário brasileiro.

Em compensação, os C_01 e C_05 apresentaram RMSE de 8,78 e 9,30, respectivamente. Esses valores, ainda que entre os três mais baixos, indicam uma boa precisão, mas com ligeiras variações em comparação ao conjunto C_03.

A análise do RMSE fornece uma medida quantitativa das diferenças entre os valores estimados pelo modelo e os valores de monitoramento. Nos conjuntos de dados como C_03 e C_01, em que diferentes inventários são comparados, a análise post-hoc ajuda a entender a origem das variações significativas que contribuem para o RMSE. Por esse motivo, foi realizado o teste Kruskal-Wallis, e posteriormente o teste de Dunn novamente, entretanto avaliando os conjuntos de inventário, com o objetivo de entender qual a origem da diferença entre eles. As tabelas com as matrizes post-hoc estão dispostas no Apêndice C.

Observando o RMSE mais baixo para o conjunto C_03 e o mais alto para o C_02, pode-se concluir que as estimativas de concentrações de MP_{2,5} para C_03 estão mais próximas dos valores reais de monitoramento. Em comparação com a análise post-hoc, este conjunto apresentou menos variações significativas entre os diferentes inventários para os poluentes analisados. Isso sugere que as estimativas de emissões desses inventários são mais homogêneas e consistentes, contribuindo para a precisão do conjunto. Por exemplo, a análise post-hoc para

NO_x mostra valores-p altos entre BRAVES e EDGAR (valor p: 7,10E-03) e BRAVES e FINN (valor p: 2,53E-01), indicando pouca diferença estatística entre as emissões estimadas por esses inventários, o que reforça a precisão geral das estimativas.

Em compensação, para o C_02, um RMSE de 12,90, indica que as estimativas de concentrações do conjunto C_02 divergem significativamente dos dados de monitoramento, refletindo a menor precisão deste conjunto. Quando comparado com os dados obtidos na post-hoc, esse conjunto apresenta variações significativas entre os inventários para cada poluente, como ilustrado pelos valores p extremamente baixos (próximos de zero) em muitas comparações. Por exemplo, as comparações entre EDGAR para o setor de transporte e outros inventários frequentemente mostram diferenças significativas, com valor p igual a zero, mostrando apenas semelhança quando comparado ao MEGAN para os poluentes NO_x (valor p: 6,25E-30) e NMVOC (valor p: 4,44E-34) e comparado ao inventário EDGAR para o setor de agricultura, porém com valores muito menores de p (NMVOC: 3,30E-46; NH₃: 1,62E-95; NO_x: 6,74E-82; MP_{2,5}: 5,55E-78; SO_x: 1,96E-231), o que possivelmente indica disparidades na metodologia ou nos dados utilizados que podem contribuir para o alto RMSE.

Quando se trata dos conjuntos C_01 e C_05 que apresentam inventários industriais nacionais, o RMSE indica um nível moderado de precisão nas estimativas de emissões em comparação com os dados de monitoramento.

Para o C_01, a análise post-hoc apontou que para NMVOC, é possível observar diferenças significativas entre o BRAVES e os outros inventários, com valores p extremamente baixos, com exceção somente quando comparado ao FINN, sugerindo variações nas metodologias ou nos dados usados no BRAVES.

Similarmente, o conjunto C_05 exibe uma precisão aceitável nas estimativas de concentrações de MP_{2,5}. Entretanto, as diferenças significativas entre os inventários, especialmente com as estimativas do BRAIN, que apresentou valor p igual a zero comparado a todos os outros inventários e poluentes, destacam uma possível falta de harmonização nos dados ou nas abordagens metodológicas usadas. Isso sugere que alinhar melhor as metodologias ou revisar os dados usados nos inventários do BRAIN poderia melhorar a precisão das estimativas de emissão para este conjunto.

Ambos os conjuntos (C_01 e C_05) se beneficiariam de uma revisão nas metodologias de coleta e processamento de dados para reduzir a variabilidade entre os inventários e aproximar

as estimativas de concentração de $MP_{2,5}$ dos valores reais de monitoramento, como demonstrado pelos resultados do RMSE e do teste post-hoc.

A composição dos inventários nos conjuntos também influencia essas variações, com o C_01 incorporando uma diversidade de fontes que pode contribuir para a variabilidade observada, enquanto o C_05, embora similar, mostra diferenças nas escolhas de inventários que podem impactar a precisão das estimativas.

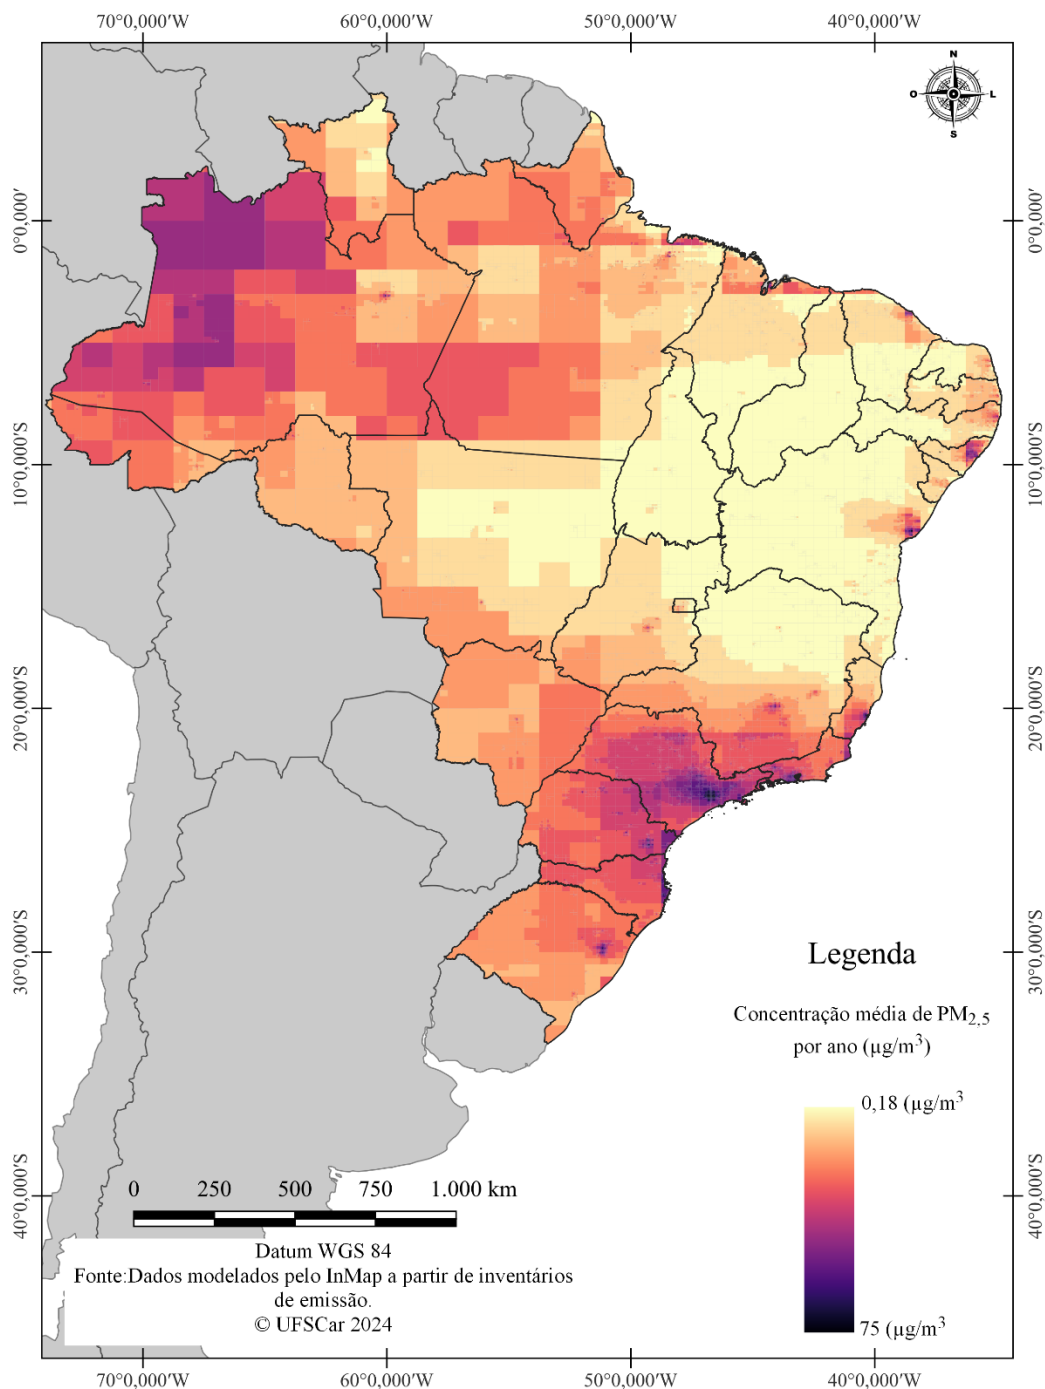
Em suma, o C_03 se destaca por utilizar abordagens mais robustas e harmonizadas, enquanto C_01 e C_05 necessitam de melhorias metodológicas para alcançar uma precisão comparável. Desse modo, sugere-se o uso da combinação de inventários C_03 para estimativa de concentração de $MP_{2,5}$. Este resultado está representado na Figura 24.

Além da comparação entre os conjuntos, é válido fazer uma comparação entre as concentrações de $MP_{2,5}$ obtidas pelo modelo InMAP e os dados da Organização Mundial da Saúde (OMS), da qual é possível observar discrepâncias significativas que merecem atenção. A OMS recomenda que a concentração média anual de $MP_{2,5}$ não exceda $5 \mu\text{g}/\text{m}^3$, como referência para proteger a saúde humana. No entanto, as concentrações modeladas pelo InMAP, como mostrado na Figura 24, são significativamente superior a esse limite em várias regiões do Brasil.

No sul e sudeste do Brasil, especialmente em áreas do Paraná, Santa Catarina e no entorno de regiões metropolitanas, as concentrações de $MP_{2,5}$ chegam a quase $75 \mu\text{g}/\text{m}^3$, do qual estão muito acima das recomendações da OMS, indicando um cenário de poluição crítica que pode afetar severamente a saúde da população local.

Em outras regiões, como o centro-oeste e norte do Brasil, as concentrações modeladas pelo InMAP variam entre, aproximadamente, 10 e $30 \mu\text{g}/\text{m}^3$, também excedendo os limites recomendados pela OMS. Estes valores sugerem a persistência de problemas relacionados à qualidade do ar, tanto em áreas urbanas quanto rurais, e reforçam a necessidade de monitoramento contínuo e intervenções locais específicas.

Figura 24. Distribuição das concentrações médias de $MP_{2,5}$ para o C_03



Fonte: Autoria própria.

4.4. Implicações para pesquisas futuras

Ao abordar os desafios e limitações regionais nos modelos de dispersão atmosférica, é crucial considerar as especificidades do território brasileiro. A diversidade climática e geográfica do Brasil impõe desafios significativos na aplicação de modelos padronizados de

dispersão atmosférica (ALVES et al., 2014). Estudos mostram que a turbulência atmosférica pode afetar significativamente a relação entre a concentração máxima e média em modelos de dispersão, influenciando a avaliação do impacto de odores e outros poluentes (DOURADO et al., 2012). Em São Paulo, a aplicação de diferentes parametrizações de turbulência em modelos de qualidade do ar mostrou impactos significativos nas concentrações previstas de poluentes, destacando a complexidade de modelar a dispersão em ambientes urbanos densos (ULKE; ANDRADE, 2001).

Variações em altitude, umidade, temperatura e padrões de vento entre diferentes regiões podem afetar significativamente a precisão dos modelos (ICHIKAWA; SADA, 2002). Além disso, a heterogeneidade socioeconômica e a distribuição desigual de infraestruturas industriais e urbanas criam padrões complexos de emissão de poluentes (ADAMATTI et al., 2015). Esses fatores, juntamente com a limitação de dados ambientais regionais específicos, dificultam a calibração e a validação efetiva dos modelos para uso no contexto brasileiro (MOHAN; GUPTA, 2018).

Por conseguinte, é fundamental desenvolver abordagens adaptativas que considerem essas variáveis regionais, para garantir uma modelagem atmosférica mais precisa e eficaz no Brasil. A determinação de um modelo de dispersão atmosférica adaptado às condições brasileiras beneficia uma variedade de políticas e legislações, desde a melhoria da qualidade do ar e gestão de impactos ambientais até o desenvolvimento de estratégias eficazes de saúde pública e mitigação das mudanças climáticas.

Quando falado de políticas de qualidade do ar, os modelos de dispersão atmosférica são essenciais para investigar padrões de dispersão de poluentes, prever comportamentos de emissões e estimar riscos potenciais à saúde humana, beneficiando por exemplo a Resolução CONAMA N° 491 de 2018 (CONAMA, 2018).

Para legislações ambientais focadas em indústrias, podem auxiliar na avaliação do impacto ambiental de novas instalações industriais. Ferramentas de simulação são utilizadas para calcular a concentração de poluentes atmosféricos e auxiliar na tomada de decisões estratégicas sobre a localização e operação de indústrias, conforme regulamentado pelas diretrizes do CONAMA pelo Programa Nacional de Controle da Qualidade do Ar (PRONAR) (CONAMA, 1990b, 1990c, 1981, 2011).

Além disso, os modelos de dispersão atmosférica são essenciais para compreender e gerenciar o impacto das emissões veiculares em áreas urbanas. Eles fornecem informações

cruciais sobre como as emissões afetam a qualidade do ar e são fundamentais para o desenvolvimento de regulamentações de tráfego e emissões eficazes, alinhadas às diretrizes do CONAMA, auxiliando na aplicação do PROCONVE.

Esses modelos também são vitais na Avaliação de Impacto Ambiental (AIA) de grandes projetos, como usinas de energia e complexos industriais, ajudando a prever a dispersão de poluentes e avaliar seus impactos na qualidade do ar local. Essas avaliações são importantes para decisões sobre a aprovação ou modificação de projetos, seguindo as normas do CONAMA e do IBAMA (CONAMA, 1986, 1998).

Nesse contexto, os MCRs desempenham um papel fundamental nas avaliações ambientais, especialmente em contextos em que exigem rapidez e eficiência, como em emergências ambientais ou avaliações preliminares de impacto. A aplicação desses modelos permite análises rápidas e intervenções eficazes, sendo ideais para situações em que decisões rápidas são necessárias (GILMORE *et al.*, 2019; TESSUM; HILL; MARSHALL, 2017).

O estudo de Gilmore *et al.* (2019) investiga três MCRs: AP2, EASIUR e InMAP. Esses modelos, apesar de suas abordagens distintas, convergem nas estimativas de custos sociais das emissões de poluentes, reforçando a confiança na sua aplicação. No entanto, as diferenças também são evidentes, especialmente na forma como cada modelo trata a química atmosférica e as emissões de poluentes. Por exemplo, o AP2 utiliza uma abordagem baseada em matrizes S-R para mapear as emissões diretamente às concentrações, enquanto o EASIUR utiliza regressões baseadas em dados de CTM, e o InMAP combina representações simplificadas com dados do WRF-Chem. Essas diferenças metodológicas podem levar a variações nas estimativas, particularmente para poluentes secundários cujas formações dependem de processos químicos complexos.

Tessum, Hill e Marshall (2017) também exploram o InMAP, destacando sua capacidade de fornecer estimativas precisas dos impactos na saúde devido às mudanças nas emissões de $MP_{2,5}$. Já Heo, Adams e Gao (2016) se concentram no modelo EASIUR, que estima os custos sociais marginais de poluentes como $MP_{2,5}$, SO_x , NO_x e NH_3 . Este modelo se destaca por fornecer estimativas de alta resolução espacial, permitindo intervenções rápidas e eficazes em contextos de formulação de políticas públicas e regulamentações ambientais.

As vantagens desses modelos incluem a rapidez e eficiência na realização de simulações e a acessibilidade, já que requerem menos recursos computacionais e são mais fáceis de usar. No entanto, há limitações, como menor precisão em situações com alta variabilidade espacial e

temporal e capacidade limitada de capturar fenômenos complexos. Mesmo assim, sua importância na gestão da qualidade do ar e no apoio às políticas públicas é inegável, complementando os modelos de alta complexidade e proporcionando uma abordagem balanceada e prática para enfrentar os desafios da poluição atmosférica no Brasil (GILMORE et al., 2019; THIND et al., 2022).

Em resumo, a utilização de modelos de dispersão atmosférica ao contexto brasileiro proporciona uma ferramenta valiosa para o aprimoramento de políticas e legislações ambientais, além de obtenção de dados que podem ser utilizados na regionalização de FCs da AICV, contribuindo significativamente para a gestão da qualidade do ar, a saúde pública e a proteção ambiental no Brasil.

4.5. Perspectivas de trabalhos futuros

Este trabalho estabelece uma base importante para futuras pesquisas que visem o desenvolvimento de FCs para a formação de material particulado no Brasil. A abordagem adotada pode ser expandida para desenvolver metodologias mais precisas de regionalização dos FCs, utilizando modelos de dispersão atmosférica adaptados às peculiaridades de diferentes municípios brasileiros. Adicionalmente, futuros estudos poderiam integrar dados locais, como variáveis meteorológicas específicas e inventários de emissões detalhados, para melhorar a acurácia dos modelos. Essa evolução permitiria uma avaliação mais robusta dos impactos ambientais nas cidades brasileiras, contribuindo para o desenvolvimento de políticas públicas mais eficazes e para a promoção de estratégias locais de mitigação da poluição do ar.

5. Considerações Finais

Ao longo deste estudo, foi possível identificar e analisar os principais desafios e oportunidades relacionados ao cálculo da concentração de $MP_{2,5}$ no contexto brasileiro, aplicando modelos de dispersão atmosférica. Por meio da RBS, foram mapeados e selecionado o modelo de dispersão atmosférica mais adequado ao contexto brasileiro e aos objetivos do trabalho, destacando-se pela capacidade de regionalizar os fatores de caracterização em AICV e melhorar a precisão das estimativas de impacto ambiental. O processo incluiu a seleção dos principais modelos de dispersão que pudessem ser integrados à AICV, levando em conta a complexidade das emissões e as particularidades das diversas regiões brasileiras.

A análise dos inventários de emissões disponíveis para o Brasil revelou uma escassez de dados específicos, especialmente no que diz respeito a setores-chave da economia nacional,

como o agronegócio. Embora o Brasil seja reconhecido mundialmente como uma potência neste setor, ainda não dispõe de inventários de emissão de poluentes para tal.

No contexto dos inventários industriais, o Brasil conta com três levantamentos principais: o BRAIN, o inventário realizado por Rey (2023) e o de Kawashima *et al.* (2015). Embora esses inventários representem um avanço importante na caracterização das emissões industriais no país, eles ainda apresentam limitações significativas quando comparados aos inventários globais, como o EDGAR. Como exemplo, o inventário elaborado por Rey (2023) possui algumas limitações como por exemplo inventariar somente 4 setores industriais ao invés de todo o setor, além disso as emissões de NMVOC se apresentaram nulas dentro do cenário adotado de resolução espacial de 20km x 20km, enquanto o BRAIN, não possui emissões para a amônia (NH₃), ambos considerados no inventário global EDGAR.

Ao separar os inventários em conjuntos para estabelecer o cenário simulado que mais se aproxima dos dados reais de monitoramento, foi possível observar que o inventário BRAVES, que abrange o setor de transporte nacional, demonstra uma representatividade superior em comparação com os inventários globais. Essa conclusão é evidenciada pelo fato de que, entre os três melhores conjuntos simulados, o BRAVES foi utilizado como o inventário de referência para o setor de transporte em todos. Isso sugere que o BRAVES capta, de maneira mais precisa, as características específicas das emissões do transporte no Brasil, refletindo melhor as condições reais e contribuindo para a acuracidade das simulações de concentração de MP.

A melhor representatividade do BRAVES em relação aos inventários globais pode ser atribuída à sua capacidade de incorporar dados mais detalhados e regionalizados sobre a frota de veículos, padrões de consumo de combustíveis e características operacionais que são particulares ao contexto brasileiro. Enquanto os inventários globais tendem a generalizar os parâmetros de emissão, o BRAVES oferece uma visão adaptada às peculiaridades locais.

Ainda assim, foi possível observar diferenças significativas na representatividade e qualidade dos dados. Dentre os seis conjuntos estabelecidos, o C_03 mostrou-se o mais robusto, por combinar inventários que incluem dados de agricultura (EDGAR), indústria (EDGAR), transporte (BRAVES), queima de biomassa (FINN), e emissões biogênicas (MEGAN). Essa combinação proporcionou uma estimativa mais precisa das concentrações de MP, alinhando-se com os dados de monitoramento existentes.

A análise do conjunto C_03 destacou a importância de estabelecer um padrão rigoroso de coleta de dados, para garantir a precisão na modelagem dos inventários de emissões. O C_03 não apenas apresentou o menor RMSE, indicando maior precisão nas simulações, mas também demonstrou consistência e semelhança entre os inventários utilizados. Essa coerência entre os inventários reflete a eficácia de um padrão uniforme de coleta de dados, que permite integrar informações de diferentes fontes de maneira mais harmoniosa e precisa.

A uniformidade na metodologia de coleta de dados contribui diretamente para a redução das incertezas nas simulações de concentração de MP. No entanto, uma das limitações deste estudo é a comparação das concentrações de MP_{2,5} modeladas pelo InMAP com os dados de monitoramento da CETESB, que abrangem exclusivamente o estado de São Paulo. Essa limitação impede uma validação robusta das concentrações simuladas para o restante do Brasil, já que as condições atmosféricas e emissões variam significativamente em diferentes regiões do país. Isso reforça a necessidade de desenvolver inventários de emissões mais completos para aprimorar a modelagem e as avaliações de impacto ambiental no contexto brasileiro, bem como o investimento em monitoramento da qualidade do ar em todas as regiões do país.

No caso do C_03, o fato dos inventários utilizados serem semelhantes entre si auxiliou na determinação de resultados que se alinham mais estreitamente aos dados reais de monitoramento. Isso sugere que, para aprimorar ainda mais a modelagem de inventários no contexto brasileiro, é essencial adotar e implementar padrões de coleta de dados em todas as etapas do processo.

Sem dados de emissão mais detalhados e específicos para setores essenciais, as análises de impacto ambiental ficam sujeitas a um grau maior de incerteza, o que pode comprometer a eficácia das políticas públicas e das estratégias de mitigação ambiental. Portanto, é imprescindível que o Brasil invista na criação e atualização de inventários de emissões que reflitam mais acuradamente as realidades econômicas e ambientais do país, alinhando-se às melhores práticas internacionais.

A aplicação do modelo de dispersão InMAP, modificado para incluir inventários brasileiros, permitiu calcular as concentrações de MP, refletindo a realidade das condições atmosféricas e de emissão no Brasil. A comparação entre as concentrações modeladas e os dados de monitoramento confirmou a superioridade do C_03 em termos de precisão e adequação ao contexto brasileiro, validando a escolha deste inventário como a melhor opção para estudos futuros de AICV no país.

REFERÊNCIAS

- ABE, Karina; MIRAGLIA, Simone. Health Impact Assessment of Air Pollution in São Paulo, Brazil. **International Journal of Environmental Research and Public Health**, [s. l.], v. 13, n. 7, p. 694, 2016.
- ABNT, ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR ISO 14040: Gestão ambiental – Avaliação do ciclo de vida – Princípios e estrutura** . Brasil : 2009a.
- ABNT, ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR ISO 14044: Gestão ambiental — Avaliação do ciclo de vida — Requisitos e orientações** . 2009b.
- ADAMATTI, Diana Francisca *et al.* Simulation Tools to Analyze the Impact of Industries Installation. **INTERNATIONAL JOURNAL OF COMPUTERS & TECHNOLOGY**, [s. l.], v. 14, n. 12, p. 6310–6325, 2015.
- ADAMS, Kate *et al.* Particulate matter components, sources, and health: Systematic approaches to testing effects. **Journal of the Air & Waste Management Association**, [s. l.], v. 65, n. 5, p. 544–558, 2015.
- ALBUQUERQUE JR., Durval Muniz de. **Capitalismo e meio ambiente: Maceió como caso exemplar dessa relação**. [S. l.], 2023. Disponível em: <https://diariodonordeste.verdesmares.com.br/opiniao/colunistas/durval-muniz-de-albuquerque-jr/capitalismo-e-meio-ambiente-maceio-como-caso-exemplar-dessa-relacao-1.3451692>. Acesso em: 12 ago. 2024.
- ALI, Zain *et al.* Organic waste-to-bioplastics: Conversion with eco-friendly technologies and approaches for sustainable environment. **Environmental Research**, [s. l.], v. 244, p. 117949, 2024.
- ALVES, Ivan P. *et al.* Eddy Diffusivity to North Wind Phenomenon in Southern Brazil: Application in an Analytical Dispersion Model. *In*: [S. l.: s. n.], 2014. p. 623–627.
- AMIRI, Azita *et al.* The Impact of Chronic Ambient Exposure to PM_{2.5} and Ozone on Asthma Prevalence and COPD Mortality Rates in the Southeastern United States. **Annual Review of Nursing Research**, [s. l.], v. 38, n. 1, p. 15–34, 2019.
- ANDRADE, Maria de Fatima *et al.* Air quality forecasting system for Southeastern Brazil. **Frontiers in Environmental Science**, [s. l.], v. 3, 2015.
- ANDRADE, Maria de Fatima *et al.* Vehicle emissions and PM_{2.5} mass concentrations in six Brazilian cities. **Air Quality, Atmosphere & Health**, [s. l.], v. 5, n. 1, p. 79–88, 2012.
- ANDREÃO, Willian Lemker *et al.* Quantifying the impact of particle matter on mortality and hospitalizations in four Brazilian metropolitan areas. **Journal of Environmental Management**, [s. l.], v. 270, p. 110840, 2020.
- APPEL, K. Wyatt *et al.* Description and evaluation of the Community Multiscale Air Quality (CMAQ) modeling system version 5.1. **Geoscientific Model Development**, [s. l.], v. 10, n. 4, p. 1703–1732, 2017.

APPEL, K. Wyat *et al.* The Community Multiscale Air Quality (CMAQ) model versions 5.3 and 5.3.1: system updates and evaluation. **Geoscientific Model Development**, [s. l.], v. 14, n. 5, p. 2867–2897, 2021.

ARAGÃO, Luiz E. O. C. *et al.* 21st Century drought-related fires counteract the decline of Amazon deforestation carbon emissions. **Nature Communications**, [s. l.], v. 9, n. 1, p. 536, 2018.

AZAPAGIC, Adisa; PETTIT, Carol; SINCLAIR, Phil. A life cycle methodology for mapping the flows of pollutants in the urban environment. **Clean Technologies and Environmental Policy**, [s. l.], v. 9, n. 3, p. 199–214, 2007.

BAI, Shubin *et al.* Single-Vessel Plume Dispersion Simulation: Method and a Case Study Using CALPUFF in the Yantian Port Area, Shenzhen (China). **International Journal of Environmental Research and Public Health**, [s. l.], v. 17, n. 21, p. 7831, 2020.

BARBER, Victoria P.; KROLL, Jesse H. Chemistry of Functionalized Reactive Organic Intermediates in the Earth's Atmosphere: Impact, Challenges, and Progress. **The Journal of Physical Chemistry A**, [s. l.], v. 125, n. 48, p. 10264–10279, 2021.

BARBERO, Daniela *et al.* A microscale hybrid modelling system to assess the air quality over a large portion of a large European city. **Atmospheric Environment**, [s. l.], v. 264, p. 118656, 2021.

BARE, Jane C. Life cycle impact assessment research developments and needs. **Clean Technologies and Environmental Policy**, [s. l.], v. 12, n. 4, p. 341–351, 2010.

BARE, Jane. TRACI 2.0: the tool for the reduction and assessment of chemical and other environmental impacts 2.0. **Clean Technologies and Environmental Policy**, [s. l.], v. 13, n. 5, p. 687–696, 2011.

BHANDARI, Ramchandra; SESSA, Vittorio. Energy in agriculture in Brazil. **REVISTA CIÊNCIA AGRONÔMICA**, [s. l.], v. 51, n. 5, 2020.

BÖHM, G M *et al.* Biological effects of air pollution in São Paulo and Cubatão. **Environmental research**, [s. l.], v. 49, n. 2, p. 208–16, 1989.

BÖHM, G M *et al.* Comparative toxicity of alcohol and gasoline fueled automobile exhaust fumes. **Developments in toxicology and environmental science**, [s. l.], v. 11, p. 479–82, 1983.

BONYADI, Ziaeddin *et al.* Cardiovascular, respiratory, and total mortality attributed to PM2.5 in Mashhad, Iran. **Environmental Monitoring and Assessment**, [s. l.], v. 188, n. 10, p. 570, 2016.

BRANDO, P. M. *et al.* The gathering firestorm in southern Amazonia. **Science Advances**, [s. l.], v. 6, n. 2, 2020.

BRASIL. LEI Nº 14.850, DE 2 DE MAIO DE 2024: Política Nacional de Qualidade do Ar . **DIÁRIO OFICIAL DA UNIÃO**: Brasil , n. 14.850, 2 maio 2024.

BULLE, Cécile *et al.* IMPACT World+: a globally regionalized life cycle impact assessment method. **The International Journal of Life Cycle Assessment**, [s. l.], v. 24, n. 9, p. 1653–1674, 2019.

BUONOCORE, Jonathan J. *et al.* Using the Community Multiscale Air Quality (CMAQ) model to estimate public health impacts of PM_{2.5} from individual power plants. **Environment International**, [s. l.], v. 68, p. 200–208, 2014.

CASTRO, Ana Lídia de Almeida *et al.* Applicability and relevance of water scarcity models at local management scales: Review of models and recommendations for Brazil. **Environmental Impact Assessment Review**, [s. l.], v. 72, p. 126–136, 2018.

CETESB, Companhia Ambiental do Estado de São Paulo. **Padrões de Qualidade do Ar**. [S. l.], 2024a. Disponível em: <https://cetesb.sp.gov.br/ar/padroes-de-qualidade-do-ar/>. Acesso em: 3 maio 2024.

CETESB, Companhia Ambiental do Estado de São Paulo. **Qualidade do ar no estado de São Paulo**. São Paulo: [s. n.], 2023. Disponível em: <https://cetesb.sp.gov.br/ar/publicacoes-relatorios/>. Acesso em: 12 ago. 2024.

CETESB, Companhia Ambiental do Estado de São Paulo. **Qualidade do Ar: Poluentes**. [S. l.], 2024b. Disponível em: <https://cetesb.sp.gov.br/ar/poluentes/>. Acesso em: 25 jan. 2024.

CHAN, Yatfei *et al.* Analysis of the Synergies of Cutting Air Pollutants and Greenhouse Gas Emissions in an Integrated Iron and Steel Enterprise in China. **Sustainability**, [s. l.], v. 15, n. 17, p. 13231, 2023.

CHEN, Jianmin *et al.* A review of biomass burning: Emissions and impacts on air quality, health and climate in China. **Science of The Total Environment**, [s. l.], v. 579, p. 1000–1034, 2017.

CIMORELLI, Alan J. *et al.* AERMOD: A Dispersion Model for Industrial Source Applications. Part I: General Model Formulation and Boundary Layer Characterization. **Journal of Applied Meteorology**, [s. l.], v. 44, n. 5, p. 682–693, 2005.

CIUFFO, Biagio; SALA, Serenella. Climate-based archetypes for the environmental fate assessment of chemicals. **Journal of Environmental Management**, [s. l.], v. 129, p. 435–443, 2013.

COMISSÃO EUROPÉIA. **EDGAR - Emissions Database for Global Atmospheric Research**. [S. l.], 2024. Disponível em: https://edgar.jrc.ec.europa.eu/dataset_ap81. Acesso em: 30 maio 2024.

CONAMA, CONSELHO NACIONAL DO MEIO AMBIENTE. RESOLUÇÃO CONAMA Nº 001, de 23 de janeiro de 1986. **Diário Oficial da União**: Brasil, n. 001, 23 jan. 1986.

CONAMA, Conselho Nacional de Meio Ambiente. RESOLUÇÃO CONAMA nº 3, de 28 de junho de 1990. **Diário Oficial da União**: Brasil, n. 3, p. 15937–15939, 22 ago. 1990a.

CONAMA, Conselho Nacional do Meio Ambiente. **RESOLUÇÃO CONAMA nº 5, de 15 de junho de 1989**. Brasil: Diário Oficial da União, 15 jun. 1981.

CONAMA, Conselho Nacional de Meio Ambiente. RESOLUÇÃO CONAMA nº 8, de 6 de dezembro de 1990. **Diário Oficial da União** : Brasil, n. 8, p. 25539–25539, 28 dez. 1990b.

CONAMA, CONSELHO NACIONAL DO MEIO AMBIENTE. RESOLUÇÃO CONAMA nº 237, de 19 de dezembro de 1997. **Diário Oficial da União**: Brasil, n. 237, p. 30841–30843, 19 dez. 1998.

CONAMA, Companhia Ambiental do Estado de São Paulo. **RESOLUÇÃO Nº 3, DE 28 DE JUNHO DE 1990**. Brasil : Diário Oficial da União, 28 jun. 1990. Disponível em: https://www.ibram.df.gov.br/images/resol_03.pdf. Acesso em: 3 maio 2024.

CONAMA, Conselho Nacional do Meio Ambiente. Resolução Nº 436, de 22 de dezembro de 2011. **Diário Oficial da União** : Brasil , n. 436, p. 304–311, 26 nov. 2011.

CONAMA, CONSELHO NACIONAL DO MEIO AMBIENTE. RESOLUÇÃO Nº 491, DE 19 DE NOVEMBRO DE 2018. **Ministério do Meio Ambiente/Conselho Nacional do Meio Ambiente**: n. 491, p. 155–155, 21 nov. 2018.

CORTES, Taísa Rodrigues *et al.* Short-term association between ambient air pollution and cardio-respiratory mortality in Rio de Janeiro, Brazil. **PLOS ONE**, [s. l.], v. 18, n. 2, p. e0281499, 2023.

DANTAS, Guilherme *et al.* Using mobility restriction experience for urban air quality management. **Atmospheric Pollution Research**, [s. l.], v. 12, n. 8, p. 101119, 2021.

DICKS, Andrew P.; HENT, Andrei. An Introduction to Life Cycle Assessment. *In*: [S. l.: s. n.], 2015. p. 81–90.

DOS SANTOS CERQUEIRA, Joaci; DE ALBUQUERQUE, Helder Neves; DE ASSIS SALVIANO DE SOUSA, Francisco. Atmospheric pollutants: modeling with Aermod software. **Air Quality, Atmosphere & Health**, [s. l.], v. 12, n. 1, p. 21–32, 2019.

DOURADO, Harerton *et al.* The Effects of Atmospheric Turbulence on Peak-to-Mean Concentration Ratio and its Consequence on the Odour Impact Assessment Using Dispersion Models. **Chemical Engineering Transactions**, [s. l.], v. 30, p. 163–168, 2012.

DRAXLER, Roland R.; HESS, G.D. **Description of the HYSPLIT4 modeling system**. [S. l.: s. n.], 1997.

DUAN, Ruirui *et al.* Adverse effects of short-term personal exposure to fine particulate matter on the lung function of patients with chronic obstructive pulmonary disease and asthma: a longitudinal panel study in Beijing, China. **Environmental Science and Pollution Research**, [s. l.], v. 28, n. 34, p. 47463–47473, 2021.

ERVENS, Barbara. Modeling the Processing of Aerosol and Trace Gases in Clouds and Fogs. **Chemical Reviews**, [s. l.], v. 115, n. 10, p. 4157–4198, 2015.

ESPÍRITO SANTO. DECRETO Nº 3463-R DE 16 DE DEZEMBRO 2013 . **Diário Oficial** : Brasil, n. 3463-R, 16 dez. 2013.

EUROPEAN COMMISSION, Joint Research Centre *et al.* GHG emissions of all world countries. **EU Publications**, [s. l.], 2023. Disponível em: https://edgar.jrc.ec.europa.eu/emissions_data_and_maps. Acesso em: 28 jul. 2024.

FANTKE, Peter *et al.* Characterizing Aggregated Exposure to Primary Particulate Matter: Recommended Intake Fractions for Indoor and Outdoor Sources. **Environmental Science & Technology**, [s. l.], v. 51, n. 16, p. 9089–9100, 2017.

FANTKE, Peter *et al.* Global Effect Factors for Exposure to Fine Particulate Matter. **Environmental Science & Technology**, [s. l.], v. 53, n. 12, p. 6855–6868, 2019.

FANTKE, Peter *et al.* Health effects of fine particulate matter in life cycle impact assessment: findings from the Basel Guidance Workshop. **The International Journal of Life Cycle Assessment**, [s. l.], v. 20, n. 2, p. 276–288, 2015.

FINNVEDEN, Göran *et al.* Recent developments in Life Cycle Assessment. **Journal of Environmental Management**, [s. l.], v. 91, n. 1, p. 1–21, 2009.

FNAIS, Abdulrahman *et al.* The application of life cycle assessment in buildings: challenges, and directions for future research. **The International Journal of Life Cycle Assessment**, [s. l.], v. 27, n. 5, p. 627–654, 2022.

GALLAGHER, Ciaran L. *et al.* Combining Satellite-Derived PM_{2.5} Data and a Reduced-Form Air Quality Model to Support Air Quality Analysis in US Cities. **GeoHealth**, [s. l.], v. 7, n. 5, 2023.

GIDHAGEN, Lars *et al.* An integrated assessment of the impacts of PM_{2.5} and black carbon particles on the air quality of a large Brazilian city. **Air Quality, Atmosphere & Health**, [s. l.], v. 14, n. 9, p. 1455–1473, 2021.

GILMORE, Elisabeth A *et al.* An inter-comparison of the social costs of air quality from reduced-complexity models. **Environmental Research Letters**, [s. l.], v. 14, n. 7, p. 074016, 2019.

GISCH, D. L.; BODMANN, B. E. J.; VILHENA, M. T. B. Two Reasons Why Pollution Dispersion Modeling Needs Sesquilinear Forms. *In*: INTEGRAL METHODS IN SCIENCE AND ENGINEERING. Cham: Springer International Publishing, 2015. p. 257–266.

GIUSTI, Gabriela *et al.* Health effects of particulate matter formation in Life Cycle Impact Assessment: critical review and recommendation of models for Brazil. **The International Journal of Life Cycle Assessment**, [s. l.], v. 27, n. 6, p. 868–884, 2022.

GIUSTI, Gabriela *et al.* Human health impacts of particulate matter emitted from different milk production systems in Brazil: a regionalized LCA sensitivity analysis. **The International Journal of Life Cycle Assessment**, [s. l.], v. 28, n. 11, p. 1466–1480, 2023.

GIUSTI, Gabriela. **Regionalização no contexto brasileiro de modelos de avaliação de impacto do ciclo de vida para a categoria de formação de material particulado**. 2021. Dissertação (Mestrado) - Universidade Federal de São Carlos - campus Sorocaba, Sorocaba, 2021.

GIUSTI, Gabriela. **Regionalização no contexto brasileiro de modelos de avaliação de impacto do ciclo de vida para a categoria de formação de material particulado**. . 2021. Dissertação (Mestrado) - Universidade Federal de São Carlos, campus Sorocaba, Sorocaba, SP, 2021.

GÓMEZ-DE-MARISCAL, Estibaliz *et al.* Use of the p-values as a size-dependent function to address practical differences when analyzing large datasets. **Scientific Reports**, [s. l.], v. 11, n. 1, p. 20942, 2021.

GOUVEIA, Nelson *et al.* Poluição do ar e hospitalizações na maior metrópole brasileira. **Revista de Saúde Pública**, [s. l.], v. 51, p. 117, 2017.

GROCHANKE, Bethania Salamoni. **Efeito da exposição crônica ao material particulado fino nos parâmetros de estresse oxidativo em pulmões de camundongos submetidos ao consumo de dieta hiperlipídica**. 2015. Dissertação (Mestrado em Ciências da Saúde) - Fundação Universidade Federal de Ciências da Saúde de Porto Alegre, [s. l.], 2015.

GRZYWA-CELIŃSKA, Anna *et al.* Relationship between concentration of air pollutants and frequency of hospitalisations due to respiratory diseases. **Annals of Agricultural and Environmental Medicine**, [s. l.], v. 31, n. 1, p. 13–23, 2024.

GUENTHER, A. B. *et al.* The Model of Emissions of Gases and Aerosols from Nature version 2.1 (MEGAN2.1): an extended and updated framework for modeling biogenic emissions. **Geoscientific Model Development**, [s. l.], v. 5, n. 6, p. 1471–1492, 2012.

GUO, Cui *et al.* Effect of long-term exposure to fine particulate matter on lung function decline and risk of chronic obstructive pulmonary disease in Taiwan: a longitudinal, cohort study. **The Lancet Planetary Health**, [s. l.], v. 2, n. 3, p. e114–e125, 2018.

HAAS, D. *et al.* The concentrations of culturable microorganisms in relation to particulate matter in urban air. **Atmospheric Environment**, [s. l.], v. 65, p. 215–222, 2013.

HAN, Inkyu *et al.* Assessment of heterogeneity of metal composition of fine particulate matter collected from eight U.S. counties using principal component analysis. **Journal of the Air & Waste Management Association**, [s. l.], v. 62, n. 7, p. 773–782, 2012.

HARMS, F. *et al.* Validating LES-based flow and dispersion models. **Journal of Wind Engineering and Industrial Aerodynamics**, [s. l.], v. 99, n. 4, p. 289–295, 2011.

HAUSCHILD, Michael Z. *et al.* Identifying best existing practice for characterization modeling in life cycle impact assessment. **The International Journal of Life Cycle Assessment**, [s. l.], v. 18, n. 3, p. 683–697, 2013.

HAUSCHILD, Michael; POTTING, José. Spatial Differentiation in Life Cycle Impact Assessment – The EDIP 2003 Methodology. **Environ news**, [s. l.], v. 80, 2005.

HAUSCHILD, Michael Z.; ROSENBAUM, Ralph K.; OLSEN, Stig Irving. **Life Cycle Assessment**. Cham: Springer International Publishing, 2018.

HAWKINS, D.; MUMOVIC, D. Evaluation of life cycle carbon impacts for higher education building redevelopment: an archetype approach. **Energy and Buildings**, [s. l.], v. 147, p. 113–122, 2017.

HE, Hankun; SCHÄFER, Benjamin; BECK, Christian. Spatial heterogeneity of air pollution statistics in Europe. **Scientific Reports**, [s. l.], v. 12, n. 1, p. 12215, 2022.

HELD, T. UCD 2001: an improved model to simulate pollutant dispersion from roadways. **Atmospheric Environment**, [s. l.], v. 37, n. 38, p. 5325–5336, 2003.

HEO, Jinhyok; ADAMS, Peter J.; GAO, H. Oliver. Reduced-form modeling of public health impacts of inorganic PM 2.5 and precursor emissions. **Atmospheric Environment**, [s. l.], v. 137, p. 80–89, 2016.

HILL, Jason *et al.* Air-quality-related health damages of maize. **Nature Sustainability**, [s. l.], v. 2, n. 5, p. 397–403, 2019.

HOFSTETTER, Patrick. **Perspectives in Life Cycle Impact Assessment**. Boston, MA: Springer US, 1998.

HOINASKI, Leonardo. **Industrial emissions**. [S. l.]: BRAIN, 2022. Disponível em: <https://hoinaski.prof.ufsc.br/BRAIN/EMISinventoryForm>. Acesso em: 28 jul. 2024.

HOINASKI, Leonardo *et al.* Multispecies and high-spatiotemporal-resolution database of vehicular emissions in Brazil. **Earth System Science Data**, [s. l.], v. 14, n. 6, p. 2939–2949, 2022.

HONSCHA, Laiz Coutelle *et al.* Health impact assessment of air pollution in an area of the largest coal mine in Brazil. **Environmental Science and Pollution Research**, [s. l.], v. 29, n. 10, p. 14176–14184, 2022.

HUIJBREGTS, Mark A. J. *et al.* ReCiPe2016: a harmonised life cycle impact assessment method at midpoint and endpoint level. **The International Journal of Life Cycle Assessment**, [s. l.], v. 22, n. 2, p. 138–147, 2017.

HUMBERT, Sebastien *et al.* Intake Fraction for Particulate Matter: Recommendations for Life Cycle Impact Assessment. **Environmental Science & Technology**, [s. l.], v. 45, n. 11, p. 4808–4816, 2011.

HUMBERT, S.; FANTKE, P.; JOLLIET, O. **Life Cycle Assessment: LCA Compendium – The Complete World of Life Cycle Assessment**. 1. ed. New York: Springer, 2015-. ISSN 2214-3513.

IBGE, Instituto Brasileiro de Geografia e Estatística. **Indicadores de desenvolvimento sustentável**. Rio de Janeiro: Ministério do Planejamento, Orçamento e Gestão, 2015-. ISSN 1517-1450.

ICHIKAWA, Yoichi; SADA, Koichi. An Atmospheric Dispersion Model for the Environmental Impact Assessment of Thermal Power Plants in Japan—A Method for Evaluating Topographical Effects. **Journal of the Air & Waste Management Association**, [s. l.], v. 52, n. 3, p. 313–323, 2002.

IMA, Instituto do Meio Ambiente de Santa Catarina. **Legislação**. [S. l.], 2024. Disponível em: <https://www.ima.sc.gov.br/index.php/qualidade-ambiental/menu-qualidade-ar/legislacao>. Acesso em: 3 maio 2024.

IMORI, Denise *et al.* Regional Development and Greenhouse Gases Emission: The Case of the Amazon Region. **SSRN Electronic Journal**, [s. l.], 2011.

INMET, Instituto Nacional de Meteorologia. **NORMAIS CLIMATOLÓGICAS DO BRASIL (1991-2020)**. Brasília: [s. n.], 2022. Disponível em: <https://portal.inmet.gov.br/normais#>. Acesso em: 14 set. 2024.

IQBAL, Asif; AFROZE, Shirina; RAHMAN, Mizanur. Probabilistic total PM_{2.5} emissions from vehicular sources in Australian perspective. **Environmental Monitoring and Assessment**, [s. l.], v. 193, n. 9, p. 575, 2021.

ISO, INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 14040: Environmental management — Life cycle assessment — Principles and framework**. 2006.

ISWARA, A P *et al.* A Comparative Study of Life Cycle Impact Assessment using Different Software Programs. **IOP Conference Series: Earth and Environmental Science**, [s. l.], v. 506, n. 1, p. 012002, 2020.

ITSUBO, Norihiro; INABA, Atsushi. **Outline of LIME2**. Tokyo: [s. n.], 2012.

JACOBS, Lotte *et al.* Acute changes in pulse pressure in relation to constituents of particulate air pollution in elderly persons. **Environmental Research**, [s. l.], v. 117, p. 60–67, 2012.

JIN, Qinjian; CRIPPA, P.; PRYOR, S.C. Spatial characteristics and temporal evolution of the relationship between PM_{2.5} and aerosol optical depth over the eastern USA during 2003–2017. **Atmospheric Environment**, [s. l.], v. 239, p. 117718, 2020.

JOLLIET, Olivier *et al.* IMPACT 2002+: A new life cycle impact assessment methodology. **The International Journal of Life Cycle Assessment**, [s. l.], v. 8, n. 6, p. 324, 2003.

KAWASHIMA, Ana Beatriz *et al.* Development of a spatialized atmospheric emission inventory for the main industrial sources in Brazil. **Environmental Science and Pollution Research**, [s. l.], v. 27, n. 29, p. 35941–35951, 2020.

KELLY, James T. *et al.* Examining PM_{2.5} concentrations and exposure using multiple models. **Environmental Research**, [s. l.], v. 196, p. 110432, 2021.

KELLY, Frank J.; FUSSELL, Julia C. Size, source and chemical composition as determinants of toxicity attributable to ambient particulate matter. **Atmospheric Environment**, [s. l.], v. 60, p. 504–526, 2012.

KIM, Ki-Hyun; KABIR, Ehsanul; KABIR, Shamin. A review on the human health impact of airborne particulate matter. **Environment International**, [s. l.], v. 74, p. 136–143, 2015.

KIOUMOURTZOGLOU, Marianthi-Anna *et al.* Long-term PM_{2.5} Exposure and Neurological Hospital Admissions in the Northeastern United States. **Environmental Health Perspectives**, [s. l.], v. 124, n. 1, p. 23–29, 2016.

KOPEL, Jonathan; BROWER, Gregory L. Impact of fossil fuel emissions and particulate matter on pulmonary health. **Baylor University Medical Center Proceedings**, [s. l.], v. 32, n. 4, p. 636–638, 2019.

KOPP, Mira; PÉREZ DEL PULGAR FROWEIN, Carmen. Overestimated environmental benefits of short-term changes in mobility behaviour: The case of Berlin during COVID-19. **Sustainable Cities and Society**, [s. l.], v. 101, p. 105137, 2024.

KOUNINA, Anna *et al.* Global spatial analysis of toxic emissions to freshwater: operationalization for LCA. **The International Journal of Life Cycle Assessment**, [s. l.], v. 24, n. 3, p. 501–517, 2019.

KOUNINA, Anna *et al.* Spatial analysis of toxic emissions in LCA: A sub-continental nested USEtox model with freshwater archetypes. **Environment International**, [s. l.], v. 69, p. 67–89, 2014.

KÜNZLI, Nino; PEREZ, Laura; RAPP, Regula. **Air Quality and Health**. Basel, Switzerland: [s. n.], 2010.

LAMBRECHTS, Johannes; SINHA, Saurabh. Modelling of Air and Water Pollution Sources. *In*: [S. l.: s. n.], 2016. p. 63–99.

LAWRENCE, M. G. *et al.* Regional pollution potentials of megacities and other major population centers. **Atmospheric Chemistry and Physics**, [s. l.], v. 7, n. 14, p. 3969–3987, 2007.

LEE, Jae-Eun; LIM, Hyun Joung; KIM, Young-Youl. Publication trends in research on particulate matter and health impact over a 10-year period: 2009–2018. **Environmental Analysis Health and Toxicology**, [s. l.], v. 36, n. 1, p. e2021005, 2021.

LENT, van J.; HERGOUALC'H, K.; VERCHOT, L. V. Reviews and syntheses: Soil N<sub>2&lt;/sub> and NO emissions from land use and land-

use change in the tropics and subtropics: a meta-analysis. **Biogeosciences**, [s. l.], v. 12, n. 23, p. 7299–7313, 2015.

LEVY, Jonathan I.; WILSON, Andrew M.; ZWACK, Leonard M. Quantifying the Efficiency and Equity Implications of Power Plant Air Pollution Control Strategies in the United States. **Environmental Health Perspectives**, [s. l.], v. 115, n. 5, p. 743–750, 2007.

LI, Tiantian *et al.* Ambient fine particulate matter and cardiopulmonary health risks in China. **Chinese Medical Journal**, [s. l.], v. 136, n. 3, p. 287–294, 2023.

LIN, Chih-Chung *et al.* Water-soluble ions in nano/ultrafine/fine/coarse particles collected near a busy road and at a rural site. **Environmental Pollution**, [s. l.], v. 145, n. 2, p. 562–570, 2007.

LOECK, Jaqueline Fischer; SCHRAMM, Juliana; BODMANN, Bardo. Modelo para dispersão de poluentes com condições de contorno reflexivas e simulação de dados no CALPUFF. **Ciência e Natura**, [s. l.], v. 40, p. 257, 2018.

LOSACCO, Caterina; PERILLO, Antonella. Particulate matter air pollution and respiratory impact on humans and animals. **Environmental Science and Pollution Research**, [s. l.], v. 25, n. 34, p. 33901–33910, 2018.

LOUGH, G.C.; SCHAUER, J.J.; LAWSON, D.R. Day-of-week trends in carbonaceous aerosol composition in the urban atmosphere. **Atmospheric Environment**, [s. l.], v. 40, n. 22, p. 4137–4149, 2006.

LV, Yang *et al.* Sources, concentrations, and transport models of ultrafine particles near highways: a Literature Review. **Building and Environment**, [s. l.], v. 186, p. 107325, 2020.

MAFFIA, Jacopo *et al.* PM emissions from open field crop management: Emission factors, assessment methods and mitigation measures – A review. **Atmospheric Environment**, [s. l.], v. 226, p. 117381, 2020.

MAO, Jia *et al.* Meteorological mechanism for a large-scale persistent severe ozone pollution event over eastern China in 2017. **Journal of Environmental Sciences**, [s. l.], v. 92, p. 187–199, 2020.

MASSAD, Eduardo *et al.* Acute toxicity of gasoline and ethanol automobile engine exhaust gases. **Toxicology Letters**, [s. l.], v. 26, n. 2–3, p. 187–192, 1985.

MAZZETTO, Andre M. *et al.* Region-specific emission factors for Brazil increase the estimate of nitrous oxide emissions from nitrogen fertiliser application by 21%. **Atmospheric Environment**, [s. l.], v. 230, p. 117506, 2020.

MCTI, Ministério da Ciência, Tecnologia e Inovação. **Nota Técnica PRODES Amazônia 2023**. [S. l.: s. n.], 2023. Disponível em: 13/08/2024<https://www.gov.br/inpe/pt-br/assuntos/ultimas-noticias/estimativa-de-desmatamento-na-amazonia-legal-para-2023-e-de-9-001-km2>. Acesso em: 12 ago. 2024.

MEE, Ministry of Ecology and Environmental the People's Republic of China. **Ambient air quality standards**. China: 1 jan. 2016. Disponível em: <https://www.chinesestandard.net/PDF.aspx/GB3095-2012>. Acesso em: 12 ago. 2024.

MEURER, Katharina H E *et al.* Direct nitrous oxide (N₂O) fluxes from soils under different land use in Brazil—a critical review. **Environmental Research Letters**, [s. l.], v. 11, n. 2, p. 023001, 2016.

MMA, Ministério do Meio Ambiente. **Poluentes atmosféricos**. [S. l.], 2024a. Disponível em: <https://antigo.mma.gov.br/cidades-sustentaveis/qualidade-do-ar/poluentes-atmosf%C3%A9ricos.html>. Acesso em: 4 maio 2024.

MMA, Ministério do Meio Ambiente. **Qualidade do Ar**. [S. l.], 2024b. Disponível em: <https://antigo.mma.gov.br/cidades-sustentaveis/qualidade-do-ar.html#:~:text=De%20uma%20forma%20geral%2C%20a,n%C3%A3o%20%C3%A0%20dispers%C3%A3o%20dos%20poluentes>. Acesso em: 22 abr. 2024.

MOHAN, Manju; GUPTA, Medhavi. Sensitivity of PBL parameterizations on PM10 and ozone simulation using chemical transport model WRF-Chem over a sub-tropical urban airshed in India. **Atmospheric Environment**, [s. l.], v. 185, p. 53–63, 2018.

MOHER, David *et al.* Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015 statement. **Systematic Reviews**, [s. l.], v. 4, n. 1, p. 1, 2015.

MONKS, P.S. *et al.* Atmospheric composition change – global and regional air quality. **Atmospheric Environment**, [s. l.], v. 43, n. 33, p. 5268–5350, 2009a.

MONKS, P.S. *et al.* Atmospheric composition change – global and regional air quality. **Atmospheric Environment**, [s. l.], v. 43, n. 33, p. 5268–5350, 2009b.

MORAES, M. R. **Implementação de um sistema de modelos para a qualidade do ar**. 2001. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Federal de Santa Catarina, Florianópolis, 2001.

MORAKINYO, Oyewale *et al.* Health Outcomes of Exposure to Biological and Chemical Components of Inhalable and Respirable Particulate Matter. **International Journal of Environmental Research and Public Health**, [s. l.], v. 13, n. 6, p. 592, 2016.

MORALES, Michele *et al.* Regionalized inventory data in LCA of public housing: A comparison between two conventional typologies in southern Brazil. **Journal of Cleaner Production**, [s. l.], v. 238, p. 117869, 2019.

MOSTAFA, Ehab *et al.* Physical properties of particulate matter from animal houses—empirical studies to improve emission modelling. **Environmental Science and Pollution Research**, [s. l.], v. 23, n. 12, p. 12253–12263, 2016.

MULLER, Nicholas Z. Boosting GDP growth by accounting for the environment. **Science**, [s. l.], v. 345, n. 6199, p. 873–874, 2014.

MUTEL, Chris *et al.* Overview and recommendations for regionalized life cycle impact assessment. **The International Journal of Life Cycle Assessment**, [s. l.], v. 24, n. 5, p. 856–865, 2019.

NCAR, Atmospheric Chemistry Observations & Modeling. **WRF-Chem Tools for the Community**. [S. l.], 2024. Disponível em: <https://www2.aocom.ucar.edu/wrf-chem/wrf-chem-tools-community>. Acesso em: 29 jul. 2024.

OBERSCHELP, Christopher; PFISTER, Stephan; HELLWEG, Stefanie. Globally Regionalized Monthly Life Cycle Impact Assessment of Particulate Matter. **Environmental Science & Technology**, [s. l.], v. 54, n. 24, p. 16028–16038, 2020.

OEDER, S. *et al.* Toxicity and elemental composition of particulate matter from outdoor and indoor air of elementary schools in Munich, Germany. **Indoor Air**, [s. l.], v. 22, n. 2, p. 148–158, 2012.

OLIVEIRA, José Augusto de *et al.* **Life Cycle Engineering and Management of Products: Theory and Practice**. 1. ed. [S. l.]: Springer, 2021. v. 1

ORTIZ-ROJAS, Adrián-Enrique *et al.* Comparison of the environmental impacts of heating systems in Chile by life cycle assessment. **Cleaner Environmental Systems**, [s. l.], v. 13, p. 100192, 2024.

PAGANI, Regina Negri; KOVALESKI, João Luiz; RESENDE, Luis Mauricio. Methodi Ordinatio: a proposed methodology to select and rank relevant scientific papers encompassing the impact factor, number of citation, and year of publication. **Scientometrics**, [s. l.], v. 105, n. 3, p. 2109–2135, 2015.

PAGE, Matthew J *et al.* The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **BMJ**, [s. l.], p. n71, 2021.

PARVATKER, Abhijeet G.; ECKELMAN, Matthew J. Comparative Evaluation of Chemical Life Cycle Inventory Generation Methods and Implications for Life Cycle Assessment Results. **ACS Sustainable Chemistry & Engineering**, [s. l.], v. 7, n. 1, p. 350–367, 2019.

PAVAN, Ana Laura Raymundo; OMETTO, Aldo Roberto. Regionalization of land use impact models for life cycle assessment: Recommendations for their use on the global scale and their applicability to Brazil. **Environmental Impact Assessment Review**, [s. l.], v. 60, p. 148–155, 2016.

PFISTER, Gabriele. **EPA_ANTHRO_EMIS User Guide**. [S. l.: s. n.], 2014. Disponível em: https://www.aocom.ucar.edu/wrf-chem/EPA_ANTHRO_EMIS_UserGuide.pdf. Acesso em: 29 jul. 2024.

PHILIP, Sajeev *et al.* Global Chemical Composition of Ambient Fine Particulate Matter for Exposure Assessment. **Environmental Science & Technology**, [s. l.], v. 48, n. 22, p. 13060–13068, 2014.

PINTO, Janaina Antonino *et al.* Traffic data in air quality modeling: A review of key variables, improvements in results, open problems and challenges in current research. **Atmospheric Pollution Research**, [s. l.], v. 11, n. 3, p. 454–468, 2020.

PORTUGAL-PEREIRA, Joana *et al.* Life cycle assessment of conventional and optimised Jatropha biodiesel fuels. **Renewable Energy**, [s. l.], v. 86, p. 585–593, 2016.

PU, Weiwei *et al.* Potential source regions of air pollutants at a regional background station in Northern China. **Environmental Technology**, [s. l.], v. 40, n. 26, p. 3412–3421, 2019.

PUN, Vivian C *et al.* Long-Term PM_{2.5} Exposure and Respiratory, Cancer, and Cardiovascular Mortality in Older US Adults. **American Journal of Epidemiology**, [s. l.], v. 186, n. 8, p. 961–969, 2017.

RAICV, Rede de Pesquisa de Avaliação do Impacto do Ciclo de Vida. **Recomendação de modelos de Avaliação de Impacto do Ciclo de Vida para o contexto brasileiro**. Brasília: [s. n.], 2019.

RAMANANTENASOA, Maharavo Marie Julie *et al.* A new framework to estimate spatio-temporal ammonia emissions due to nitrogen fertilization in France. **Science of The Total Environment**, [s. l.], v. 645, p. 205–219, 2018.

REY, Camila Andrea Ibagué. **DESENVOLVIMENTO DE INVENTÁRIO DE EMISSÕES ATMOSFÉRICAS PARA QUATRO SETORES INDUSTRIAIS DO BRASIL COM ABORDAGEM BOTTOM-UP**. 2023. Dissertação (Mestrado) - Universidade Tecnológica Federal do Paraná, Londrina, 2023.

RICHARDSON, Katherine *et al.* Earth beyond six of nine planetary boundaries. **Science Advances**, [s. l.], v. 9, n. 37, 2023.

ROBERTS, G.; WOOSTER, M.J. Global impact of landscape fire emissions on surface level PM_{2.5} concentrations, air quality exposure and population mortality. **Atmospheric Environment**, [s. l.], v. 252, p. 118210, 2021.

ROCKSTRÖM, Johan *et al.* A safe operating space for humanity. **Nature**, [s. l.], v. 461, n. 7263, p. 472–475, 2009.

RODRIGUEZ, Luna M.; BIERINGER, Paul E.; WARNER, Tom. Urban transport and dispersion model sensitivity to wind direction uncertainty and source location. **Atmospheric Environment**, [s. l.], v. 64, p. 25–39, 2013.

ROSENBAUM, Ralph K. *et al.* USEtox—the UNEP-SETAC toxicity model: recommended characterisation factors for human toxicity and freshwater ecotoxicity in life cycle impact assessment. **The International Journal of Life Cycle Assessment**, [s. l.], v. 13, n. 7, p. 532–546, 2008.

SALDIVA, Paulo H. N. *et al.* Air Pollution and Mortality in Elderly People: A Time-Series Study in Sao Paulo, Brazil. **Archives of Environmental Health: An International Journal**, [s. l.], v. 50, n. 2, p. 159–163, 1995.

SALDIVA, P.H.N. *et al.* Association between Air Pollution and Mortality Due to Respiratory Diseases in Children in São Paulo, Brazil: A Preliminary Report. **Environmental Research**, [s. l.], v. 65, n. 2, p. 218–225, 1994.

SANTOS, Fábio Soares dos *et al.* Avaliação da influência das condições meteorológicas na concentração de material particulado fino (MP2,5) em Belo Horizonte, MG. **Engenharia Sanitaria e Ambiental**, [s. l.], v. 24, n. 2, p. 371–381, 2019.

SANTOS, Sonilton. **Moradores de Camaçari sofrem com mau cheiro e culpam poluição industrial**. [S. l.], 2024. Disponível em: <https://projecolabora.com.br/ods3/moradores-de-camacari-sofrem-com-mau-cheiro-e-culpam-poluicao-industrial/>. Acesso em: 12 ago. 2024.

SÃO PAULO. DECRETO Nº 59.113, DE 23 DE ABRIL DE 2013. **Assembleia Legislativa do Estado de São Paulo**: Brasil, n. 59113, 23 abr. 2013.

SARANGI, Chandan *et al.* Impact of light-absorbing particles on snow albedo darkening and associated radiative forcing over high-mountain Asia: high-resolution WRF-Chem modeling and new satellite observations. **Atmospheric Chemistry and Physics**, [s. l.], v. 19, n. 10, p. 7105–7128, 2019.

SCHIMMEL, H. Evidence for possible acute health effects of ambient air pollution from time series analysis: methodological questions and some new results based on new york city daily mortality, 1963-1976. **Bulletin of the New York Academy of Medicine**, [s. l.], v. 54, n. 11, p. 1052–108, 1978.

SEAMAN, N. Meteorological modeling for air-quality assessments. **Atmospheric Environment**, [s. l.], v. 34, n. 12–14, p. 2231–2259, 2000.

SEKULA, Piotr *et al.* Random Forests Assessment of the Role of Atmospheric Circulation in PM10 in an Urban Area with Complex Topography. **Sustainability**, [s. l.], v. 14, n. 6, p. 3388, 2022.

SHANG, Haoran *et al.* Life cycle assessment of atmospheric environmental impact on the large-scale promotion of electric vehicles in China. **Resources, Environment and Sustainability**, [s. l.], v. 15, p. 100148, 2024.

SICARD, Pierre *et al.* High spatial resolution WRF-Chem model over Asia: Physics and chemistry evaluation. **Atmospheric Environment**, [s. l.], v. 244, p. 118004, 2021.

SICILIANO, A.M.; SILVA, C. E. F. C.; CORRÊA, S.M. Ozone Forming Potential at Rio de Janeiro Petrochemical Complex, Brazil. **Revista Virtual de Química**, [s. l.], v. 8, 2016.

SIDDAWAY, Andy P.; WOOD, Alex M.; HEDGES, Larry V. How to Do a Systematic Review: A Best Practice Guide for Conducting and Reporting Narrative Reviews, Meta-Analyses, and Meta-Syntheses. **Annual Review of Psychology**, [s. l.], v. 70, n. 1, p. 747–770, 2019.

SILVA, M. G. da. **AVALIAÇÃO DO CICLO DE VIDA DO METANOL PRODUZIDO PELA COGASEIFICAÇÃO DO CARVÃO MINERAL E BIOMASSA RESIDUAL DO**

ARROZ. 2018. 193 f. Tese (Doutorado) - Universidade Estadual de Campinas, Campinas, 2018.

SIMONI, WALTER FIGUEIREDO DE *et al.* **O ESTADO DA QUALIDADE DO AR NO BRASIL**. São Paulo: [s. n.], 2021. Disponível em: https://www.wribrasil.org.br/sites/default/files/wri-o-estado-da-_qualidade-do-ar-no-brasil.pdf. Acesso em: 5 maio 2024.

SOKHI, Ranjeet S. *et al.* Advances in air quality research – current and emerging challenges. **Atmospheric Chemistry and Physics**, [s. l.], v. 22, n. 7, p. 4615–4703, 2022.

SÓWKA *et al.* Analysis of Particulate Matter Concentration Variability and Origin in Selected Urban Areas in Poland. **Sustainability**, [s. l.], v. 11, n. 20, p. 5735, 2019.

STEFFEN, Will *et al.* Planetary boundaries: Guiding human development on a changing planet. **Science**, [s. l.], v. 347, n. 6223, 2015.

TANG, Longlong *et al.* Development of human health damage factors for PM_{2.5} based on a global chemical transport model. **The International Journal of Life Cycle Assessment**, [s. l.], v. 23, n. 12, p. 2300–2310, 2018.

TEGGI, Sergio *et al.* A GIS-based atmospheric dispersion model for pollutants emitted by complex source areas. **Science of The Total Environment**, [s. l.], v. 610–611, p. 175–190, 2018.

TEIXEIRA, Elba Calesso *et al.* Source identification and seasonal variation of polycyclic aromatic hydrocarbons associated with atmospheric fine and coarse particles in the Metropolitan Area of Porto Alegre, RS, Brazil. **Atmospheric Research**, [s. l.], v. 118, p. 390–403, 2012.

TESSUM, Christopher W.; HILL, Jason D.; MARSHALL, Julian D. InMAP: A model for air pollution interventions. **PLOS ONE**, [s. l.], v. 12, n. 4, p. e0176131, 2017.

THAKRAR, Sumil K. *et al.* Global, high-resolution, reduced-complexity air quality modeling for PM_{2.5} using InMAP (Intervention Model for Air Pollution). **PLOS ONE**, [s. l.], v. 17, n. 5, p. e0268714, 2022.

THIND, Maninder P.S. *et al.* Characterization factors and other air quality impact metrics: Case study for PM_{2.5}-emitting area sources from biofuel feedstock supply. **Science of The Total Environment**, [s. l.], v. 822, p. 153418, 2022.

TRAN, Phuong T.M. *et al.* Assessment and mitigation of personal exposure to particulate air pollution in cities: An exploratory study. **Sustainable Cities and Society**, [s. l.], v. 72, p. 103052, 2021.

TURGEON, Katrine *et al.* Empirical characterization factors to be used in LCA and assessing the effects of hydropower on fish richness. **Ecological Indicators**, [s. l.], v. 121, p. 107047, 2021.

U. S. EPA, United States Environmental Protection Agency. **National Ambient Air Quality Standards for Particulate Matter**. United States: Health and Environmental Impacts Division, 15 jan. 2013. Disponível em: <https://www.epa.gov/naaqs/particulate-matter-pm-air-quality-standards>. Acesso em: 12 ago. 2024.

U. S. EPA, U.S. Environmental Protection Agency. **Particulate Matter (PM) Pollution**. [S. l.], 2020. Disponível em: <https://www.epa.gov/pm-pollution/particulate-matter-pm-basics>. Acesso em: 25 jan. 2024.

UKHOV, Alexander *et al.* Improving dust simulations in WRF-Chem v4.1.3 coupled with the GOCART aerosol module. **Geoscientific Model Development**, [s. l.], v. 14, n. 1, p. 473–493, 2021.

ULKE, Ana G.; ANDRADE, M.Fátima. Modeling urban air pollution in São Paulo, Brazil: sensitivity of model predicted concentrations to different turbulence parameterizations. **Atmospheric Environment**, [s. l.], v. 35, n. 10, p. 1747–1763, 2001.

UNIÃO EUROPÉIA. **Directive 2008/50/EC of the European Parliament and of the Council of 21 May 2008 on ambient air quality and cleaner air for Europe**. União Européia: Official Journal of the European Union, 21 maio 2008.

U.S. EPA, U.S. Environmental Protection Agency. **Risk Assessment Guidance for Superfund (RAGS)**. [S. l.], 2024. Disponível em: <https://www.epa.gov/risk/risk-assessment-guidance-superfund-rags-part>. Acesso em: 4 maio 2024.

U.S. EPA, Environmental Protection Agency. **User's Guide for the AMS/EPA Regulatory Model (AERMOD)**. North Carolina: [s. n.], 2023.

USDA, United States Department of Agriculture. **Sugar Annual**. Brasília: [s. n.], 2024. Disponível em: <https://fas.usda.gov/data/brazil-sugar-annual-10>. Acesso em: 12 ago. 2024.

VALDEZ-CASTILLO, Mariana *et al.* Steady-state operation of a biofilter coupled with photocatalytic control of bacterial bioaerosol emissions. **Environmental Science and Pollution Research**, [s. l.], v. 28, n. 11, p. 13970–13980, 2021.

VAN ZELM, Rosalie *et al.* European characterization factors for human health damage of PM10 and ozone in life cycle impact assessment. **Atmospheric Environment**, [s. l.], v. 42, n. 3, p. 441–453, 2008.

VAN ZELM, Rosalie *et al.* Regionalized life cycle impact assessment of air pollution on the global scale: Damage to human health and vegetation. **Atmospheric Environment**, [s. l.], v. 134, p. 129–137, 2016.

VEDRENNE, Michel *et al.* A comprehensive approach for the evaluation and comparison of emission inventories in Madrid. **Atmospheric Environment**, [s. l.], v. 145, p. 29–44, 2016.

VENKATRAM, Akula *et al.* Analysis of air quality data near roadways using a dispersion model. **Atmospheric Environment**, [s. l.], v. 41, n. 40, p. 9481–9497, 2007.

VERONES, Francesca *et al.* LC-IMPACT: A regionalized life cycle damage assessment method. **Journal of Industrial Ecology**, [s. l.], v. 24, n. 6, p. 1201–1219, 2020.

VOSVIEWER. Holanda: Universidade de Leiden, 2023.

WANG, Yutong *et al.* Modified regional biogenic VOC emissions with actual ozone stress and integrated land cover information: A case study in Yangtze River Delta, China. **Science of The Total Environment**, [s. l.], v. 727, p. 138703, 2020.

WANG, Xiaoping *et al.* Persistent organic pollutants in the polar regions and the Tibetan Plateau: A review of current knowledge and future prospects. **Environmental Pollution**, [s. l.], v. 248, p. 191–208, 2019.

WANG, Zongshuang *et al.* Temporospatial variations and Spearman correlation analysis of ozone concentrations to nitrogen dioxide, sulfur dioxide, particulate matters and carbon monoxide in ambient air, China. **Atmospheric Pollution Research**, [s. l.], v. 10, n. 4, p. 1203–1210, 2019.

WEICHENTHAL, Scott *et al.* Long-term exposure to ambient ultrafine particles and respiratory disease incidence in Toronto, Canada: a cohort study. **Environmental Health**, [s. l.], v. 16, n. 1, p. 64, 2017.

WHO, World Health Organization. **Air Pollution**. [S. l.], 2024. Disponível em: https://www.who.int/health-topics/air-pollution#tab=tab_1. Acesso em: 22 abr. 2024.

WHO, World Health Organization. **Air quality database: Update 2016**. [S. l.: s. n.], 2018. Disponível em: https://cdn.who.int/media/docs/default-source/air-quality-database/aqd-2016/aap_database_summary_results_2016_v02.pdf?sfvrsn=384beb23_3. Acesso em: 7 maio 2024.

WHO, World Health Organization. **What are the WHO Air quality guidelines?**. [S. l.], 2021. Disponível em: <https://www.who.int/news-room/feature-stories/detail/what-are-the-who-air-quality-guidelines>. Acesso em: 22 abr. 2024.

WHO, World Health Organization. **WHO ambient air quality database: 2022 update**. Geneva: [s. n.], 2023. Disponível em: <https://iris.who.int/bitstream/handle/10665/368432/9789240047693-eng.pdf?sequence=1>. Acesso em: 12 ago. 2024.

WIEDINMYER, Christine *et al.* The Fire Inventory from NCAR version 2.5: an updated global fire emissions model for climate and chemistry applications. **Geoscientific Model Development**, [s. l.], v. 16, n. 13, p. 3873–3891, 2023.

WIKUATS, Caroline Fernanda Hei *et al.* Health Risk Assessment of Exposure to Air Pollutants Exceeding the New WHO Air Quality Guidelines (AQGs) in São Paulo, Brazil. **International Journal of Environmental Research and Public Health**, [s. l.], v. 20, n. 9, p. 5707, 2023.

WU, Ruili *et al.* Reduced-complexity air quality intervention modeling over China: the development of InMAPv1.6.1-China and a comparison with CMAQv5.2. **Geoscientific Model Development**, [s. l.], v. 14, n. 12, p. 7621–7638, 2021.

XIE, Zhiyong *et al.* Legacy and emerging organic contaminants in the polar regions. **Science of The Total Environment**, [s. l.], v. 835, p. 155376, 2022.

XIE, Wenwen *et al.* The source and transport of bioaerosols in the air: A review. **Frontiers of Environmental Science & Engineering**, [s. l.], v. 15, n. 3, p. 44, 2021.

ZARGAR, Shiva; YAO, Yuan; TU, Qingshi. A review of inventory modeling methods for missing data in life cycle assessment. **Journal of Industrial Ecology**, [s. l.], v. 26, n. 5, p. 1676–1689, 2022.

ZHANG, W. *et al.* Development of the high-order decoupled direct method in three dimensions for particulate matter: enabling advanced sensitivity analysis in air quality models. **Geoscientific Model Development**, [s. l.], v. 5, n. 2, p. 355–368, 2012.

ZHANG, Tianhao *et al.* Estimation of ultrahigh resolution PM_{2.5} concentrations in urban areas using 160 m Gaofen-1 AOD retrievals. **Remote Sensing of Environment**, [s. l.], v. 216, p. 91–104, 2018.

ZHANG, Yang *et al.* Real-time air quality forecasting, part I: History, techniques, and current status. **Atmospheric Environment**, [s. l.], v. 60, p. 632–655, 2012.

ZHANG, Shaojun *et al.* Spatial and Cross-Sectoral Transfer of Air Pollutant Emissions from the Fleet Electrification in China by 2030. **Environmental Science & Technology**, [s. l.], v. 57, n. 50, p. 21249–21259, 2023.

ZHOU, Mimi *et al.* Anthropogenic emission inventory of multiple air pollutants and their spatiotemporal variations in 2017 for the Shandong Province, China. **Environmental Pollution**, [s. l.], v. 288, p. 117666, 2021.

ZHU, Yanhong *et al.* Iron solubility in fine particles associated with secondary acidic aerosols in east China. **Environmental Pollution**, [s. l.], v. 264, p. 114769, 2020.

ZOU, Bin *et al.* Performance of AERMOD at different time scales. **Simulation Modelling Practice and Theory**, [s. l.], v. 18, n. 5, p. 612–623, 2010.

APÊNDICE

Apêndice A. Estatísticas Descritivas das Emissões por Inventário e Setor.

Tabela 11. Estatísticas Descritivas das Emissões por Inventário e Setor em toneladas por ano

| Setor | Inventário | Poluente | Média | Mediana | Desvio Padrão | Variância | Amplitude |
|---------------------|-------------------|-------------------|----------|----------|---------------|--------------|------------|
| Agricultura | EDGAR | NMVOC | 103,73 | 2,48 | 442,78 | 196.053,73 | 11.275,66 |
| | | NH ₃ | 4,11E-03 | 3,03E-04 | 7,68E-03 | 5,90E-05 | 1,89E-01 |
| | | NO _x | 1,13 | 4,43E-02 | 4,01 | 16,05 | 94,29 |
| | | MP _{2,5} | 2,12E-04 | 1,02E-06 | 1,01E-03 | 1,02E-06 | 2,46E-02 |
| | | SO _x | 7,33E-02 | 7,45E-05 | 3,63E-01 | 1,32E-01 | 8,60 |
| Emissões Biogênicas | MEGAN | NMVOC | 926,29 | 304,03 | 1.226,79 | 1.505.017,35 | 7.496,47 |
| | | NO _x | 50,04 | 33,98 | 60,12 | 3.614,35 | 471,03 |
| Industrial | Rey (2023) | NMVOC | - | - | - | - | - |
| | | NH ₃ | 7,23E-06 | - | 1,39E-04 | 1,93E-08 | 1,26E-02 |
| | | NO _x | 3,07E-02 | - | 5,90E-01 | 3,48E-01 | 53,44 |
| | | MP _{2,5} | 7,84E-03 | - | 1,79E-01 | 3,20E-02 | 19,58 |
| | | SO _x | 1,59E-01 | - | 13,64 | 186,15 | 2.182,92 |
| | EDGAR | NMVOC | 174,82 | 4,17 | 2.106,84 | 4.438.790,43 | 125.842,48 |
| | | NH ₃ | 2,45E-01 | - | 2,90 | 8,43 | 254,54 |
| | | NO _x | 1,80 | - | 20,12 | 404,92 | 1.424,20 |
| | | MP _{2,5} | 1,93E-04 | - | 2,33E-03 | 5,44E-06 | 1,74E-01 |
| | | SO _x | 1,25 | - | 16,18 | 261,86 | 1.881,03 |
| BRAIN | NMVOC | 1,16E-02 | - | 1,61 | 2,61 | 338,84 | |
| | NO _x | 2,08 | - | 69,65 | 4.851,19 | 7.867,98 | |
| | MP _{2,5} | 9,48E-01 | - | 38,80 | 1.505,76 | 6.418,11 | |
| | SO _x | 3,10 | - | 160,61 | 25.795,68 | 16.240,99 | |

Tabela 11. Estatísticas Descritivas das Emissões por Inventário e Setor em toneladas por ano (Continuação)

| | | | | | | | |
|-----------------------|--------|-------------------|----------|----------|----------|-----------|-----------|
| Queima de biomassa | FINN | NMVOC | 9,55 | - | 44,24 | 1.957,48 | 1.317,13 |
| | | NH ₃ | 2,26E-01 | - | 1,02 | 1,03 | 30,01 |
| | | NO _x | 8,57E-01 | - | 3,85 | 14,82 | 114,64 |
| | | MP _{2,5} | 1,16 | - | 5,14 | 26,47 | 151,49 |
| | | SO _x | 7,81E-02 | - | 3,17E-01 | 1,00E-01 | 9,07 |
| Transporte | BRAVES | NMVOC | 6,12 | - | 80,51 | 6.482,26 | 9.131,87 |
| | | NO _x | 27,79 | - | 242,94 | 59.020,43 | 19.699,94 |
| | | MP _{2,5} | 2,52 | - | 22,92 | 525,11 | 1.928,56 |
| | | SO _x | 5,41E-01 | - | 4,66 | 21,69 | 372,37 |
| | EDGAR | NH ₃ | 3,49E-02 | 5,18E-04 | 1,64E-01 | 2,67E-02 | 10,45 |
| | | NMVOC | 41,32 | 1,26 | 158,32 | 25.066,33 | 6.870,77 |
| | | NO _x | 3,48 | 5,03E-01 | 12,56 | 157,72 | 833,96 |
| | | MP _{2,5} | 3,81E-05 | 6,40E-06 | 1,79E-04 | 3,22E-08 | 1,46E-02 |
| | | SO _x | 3,47E-01 | 1,72E-02 | 2,14 | 4,59 | 137,63 |

Fonte: Autoria própria.

Apêndice B. Teste de Normalidade e Teste de Semelhança de Inventários

Mesmo diferenças muito pequenas, que podem não ser significativas do ponto de vista prático, podem se mostrar estatisticamente significativas. Em muitas implementações de software estatístico, um valor-p extremamente baixo pode ser arredondado para zero. Isso não significa que o valor-p é literalmente zero, mas sim que é tão pequeno que está abaixo do limite de precisão do software. Se um grupo apresenta valores consistentemente mais altos ou mais baixos do que o outro e os dados são suficientemente desbalanceados, isso pode resultar em um valor-p muito baixo. Softwares estatísticos podem não conseguir calcular valores-p extremamente pequenos devido às limitações na precisão numérica. Por exemplo, valores menores que 10^{-308} são frequentemente tratados como zero em computadores devido à precisão de ponto flutuante (Gómez-de-Mariscal *et al.*, 2021).

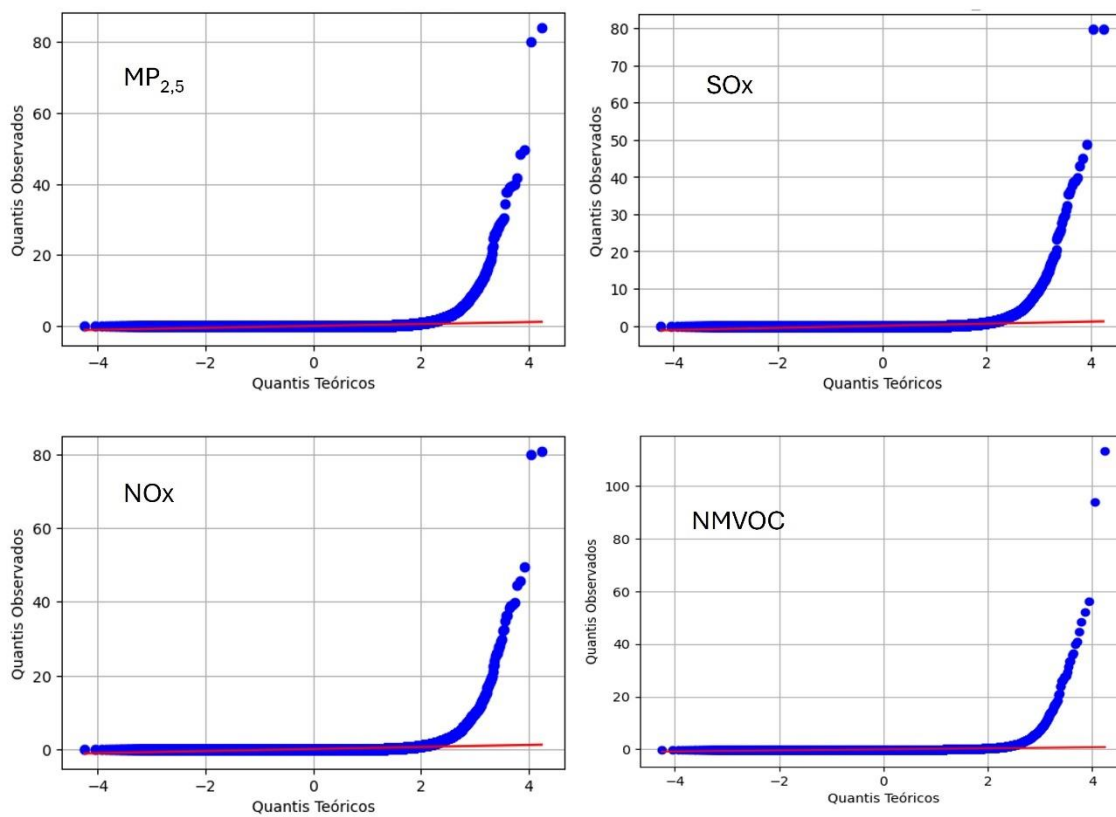
Seção B.1. Teste de Normalidade e Teste de Semelhança para o setor de transporte

Tabela 12. Resultados do Teste de Normalidade (Kolmogorov-Smirnov) para Emissões do Setor de Transporte

| Inventário | Variável | Estatística KS | valor p | Conclusão Estatística |
|------------|-------------------|----------------|---------|----------------------------------------------|
| BRAVES | NMVOC | 0,4697 | 0,000 | Os dados não seguem uma distribuição normal. |
| | NO _x | 0,4545 | 0,000 | |
| | SO _x | 0,4538 | 0,000 | |
| | MP _{2,5} | 0,4563 | 0,000 | |
| EDGAR | NH ₃ | 0,4156 | 0,000 | |
| | NMVOC | 0,3970 | 0,000 | |
| | NO _x | 0,3907 | 0,000 | |
| | SO _x | 0,4356 | 0,000 | |
| | MP _{2,5} | 0,4159 | 0,000 | |

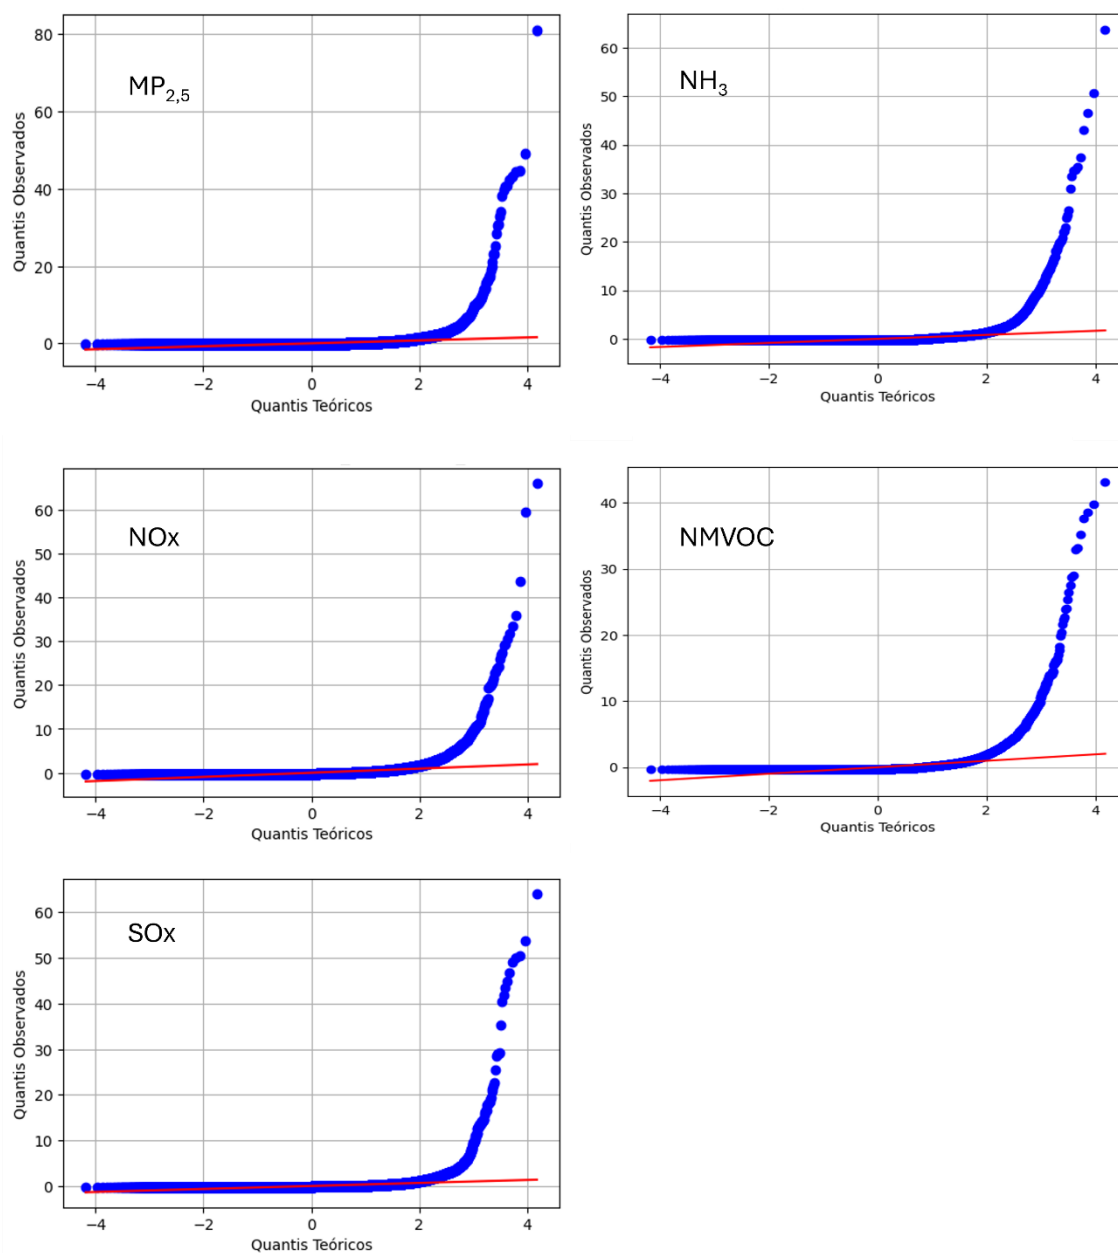
Fonte: Autoria própria.

Figura 25. Gráfico Q-Q para o inventário BRAVES para o setor de transporte



Fonte: Autoria própria.

Figura 26. Gráfico Q-Q para o inventário EDGAR v8.1 para o setor de transporte



Fonte: Autoria própria.

Tabela 13. Teste Mann-Whitney U para o setor de transporte

| Poluente | Estatística do Teste | Valor-p |
|-------------------|----------------------|---------|
| SO _x | 720.988.712,5 | 0,0000 |
| NMVOC | 547.580.407,5 | 0,0000 |
| NO _x | 791.685.355,5 | 0,0000 |
| MP _{2,5} | 883.780.240,5 | 0,0000 |

Fonte: Autoria própria.

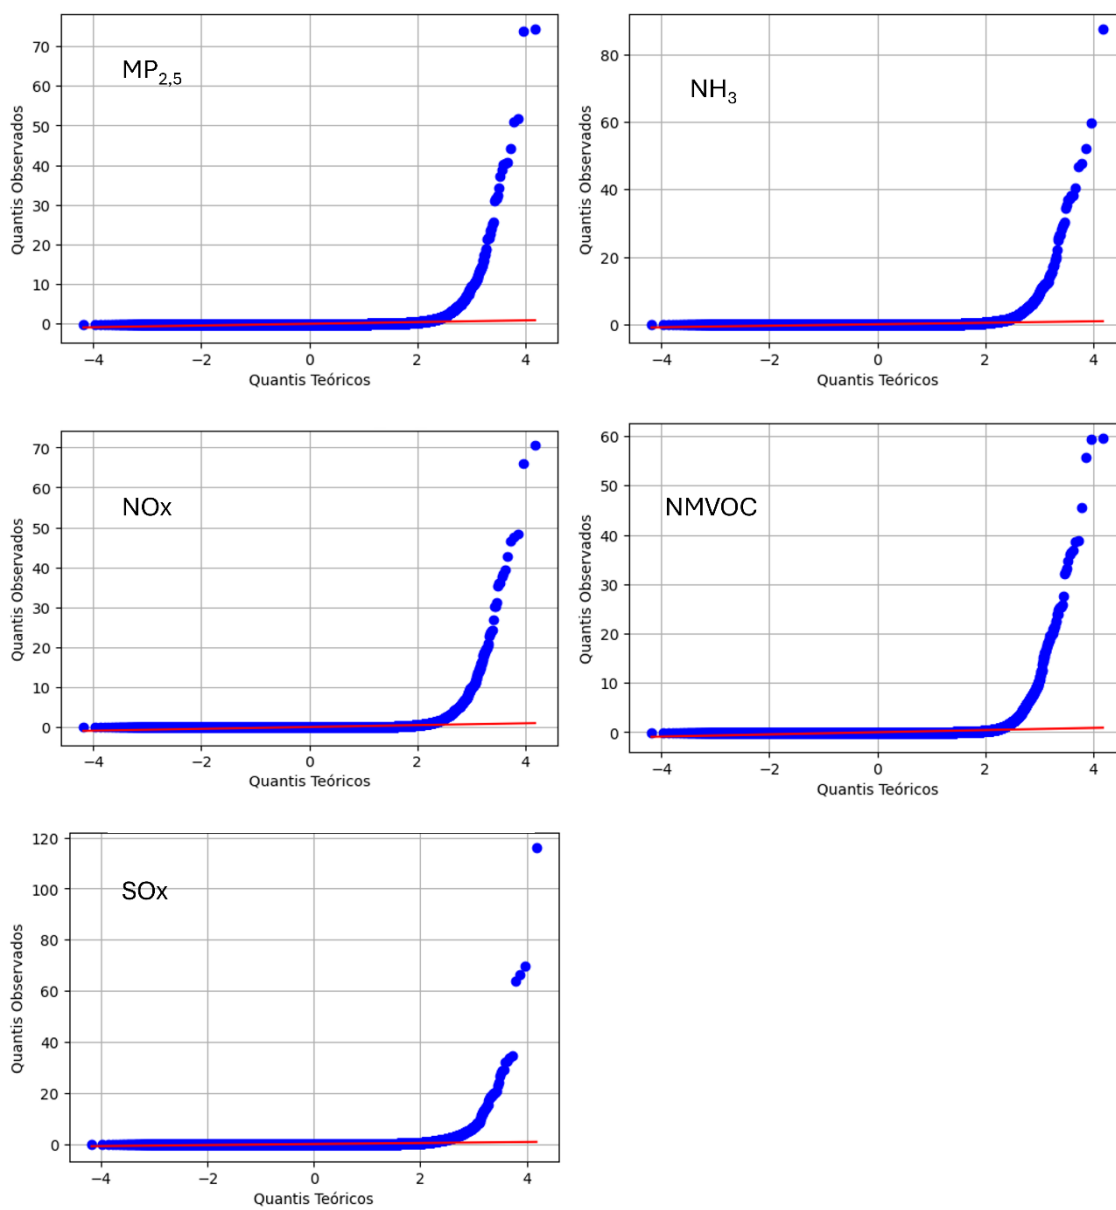
Seção B.2. Análise de Normalidade e Teste de Semelhança para o setor de industrial

Tabela 14. Resultados do Teste de Normalidade (Kolmogorov-Smirnov) para Emissões do Setor Industrial

| Inventário | Variável | Estatística KS | valor p | Conclusão estatística |
|-------------------|-------------------|-----------------------|----------------|----------------------------------------------|
| EDGAR | NH ₃ | 0,4664 | 0,0000 | Os dados não seguem uma distribuição normal. |
| | NMVOC | 0,4669 | 0,0000 | |
| | NO _x | 0,4644 | 0,0000 | |
| | SO _x | 0,4692 | 0,0000 | |
| | MP _{2,5} | 0,4670 | 0,0000 | |
| Rey (2023) | NH ₃ | 0,4952 | 0,0000 | |
| | NO _x | 0,4953 | 0,0000 | |
| | SO _x | 0,4953 | 0,0000 | |
| | MP _{2,5} | 0,4952 | 0,0000 | |
| BRAIN | NMVOC | 0,5025 | 0,0000 | |
| | NO _x | 0,5021 | 0,0000 | |
| | SO _x | 0,5024 | 0,0000 | |
| | MP _{2,5} | 0,5001 | 0,0000 | |

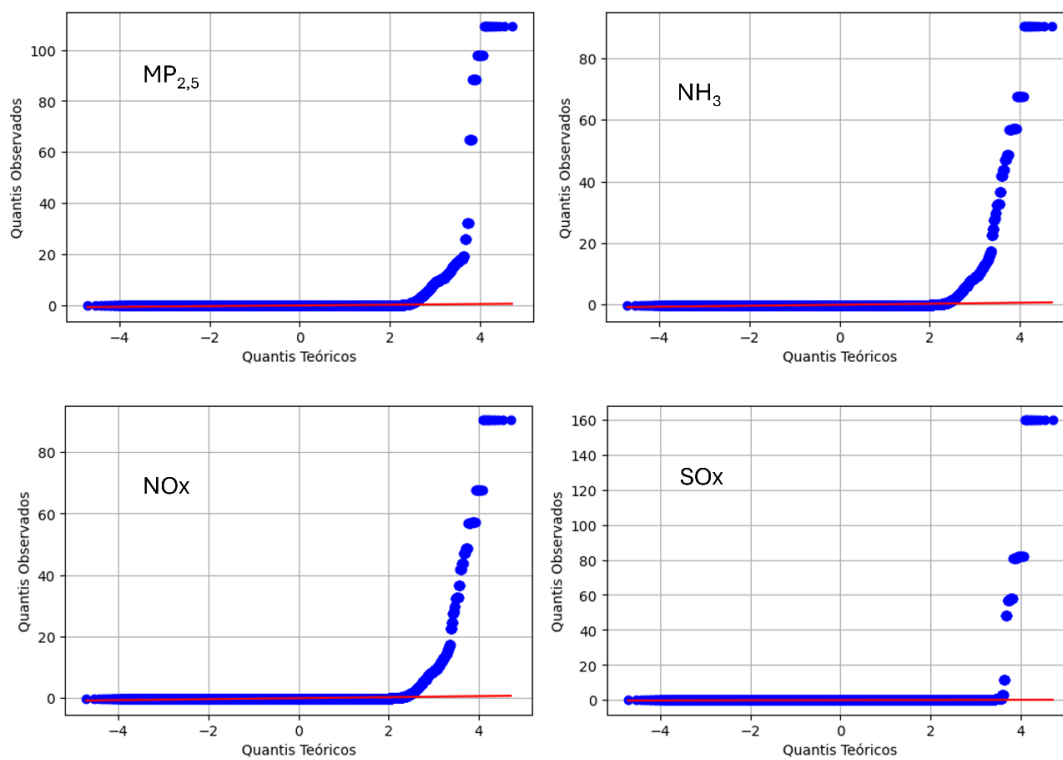
Fonte: Autoria própria.

Figura 27. Gráfico Q-Q para o inventário EDGAR v8.1 para o setor industrial



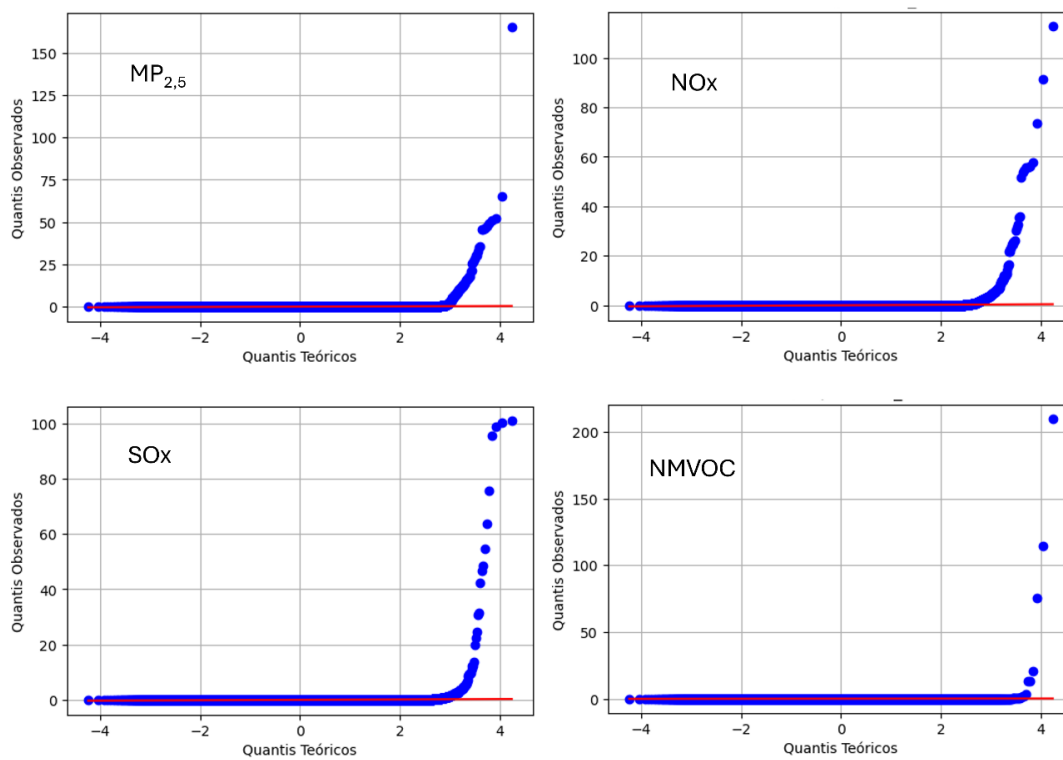
Fonte: Autoria própria.

Figura 28. Gráfico Q-Q para o inventário Rey (2023) para o setor industrial



Fonte: Autoria própria.

Figura 29. Gráfico Q-Q para o inventário BRAIN para o setor industrial



Fonte: Autoria própria.

Apêndice C. Matrizes post-hoc para os conjuntos simulados no InMAP

Seção C.1. Matriz post-hoc para o conjunto C_01

1. Teste para NMVOC

- Estatística Kruskal-Wallis: 390.512,26
- valor p: 0,000

Tabela 15. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_01

| | BRAVES | EDGAR | FINN | MEGAN | Rey (2023) |
|-------------------|---------------|--------------|-------------|--------------|-------------------|
| BRAVES | 1,00 | | | | |
| EDGAR | 6,68E-240 | 1,00 | | | |
| FINN | 1,05E-21 | 1,57E-112 | 1,00 | | |
| MEGAN | 0 | 8,25E+04 | 2,46E-164 | 1,00 | |
| Rey (2023) | 6,12E-181 | 0 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

2. Teste para NH₃

- Estatística Kruskal-Wallis: 260.129,95
- valor p: 0,000

Tabela 16. Valores de p da matriz post-hoc (teste de Dunn) para NH₃ para o C_01

| | EDGAR | FINN | Rey (2023) |
|-------------------|--------------|-------------|-------------------|
| EDGAR | 1,00 | | |
| FINN | 1,17E-170 | 1,00 | |
| Rey (2023) | 0 | 0 | 1,00 |

Fonte: Autoria própria.

3. Teste para NO_x

- Estatística Kruskal-Wallis: 319.799,29
- valor p: 0,000

Tabela 17. Valores de p da matriz post-hoc (teste de Dunn) para NO_x para o C_01

| | BRAVES | EDGAR | FINN | MEGAN | Rey (2023) |
|-------------------|---------------|--------------|-------------|--------------|-------------------|
| BRAVES | 1,00 | | | | |
| EDGAR | 1,50E-174 | 1,00 | | | |
| FINN | 3,93E-10 | 3,16E-90 | 1,00 | | |
| MEGAN | 1,27E-298 | 2,90E-02 | 2,53E-177 | 1,00 | |
| Rey (2023) | 2,12E-189 | 0 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

4. Teste para $MP_{2,5}$

- Estatística Kruskal-Wallis: 228.384,59
- valor p: 0,000

Tabela 18. Valores de p da matriz post-hoc (teste de Dunn) para $MP_{2,5}$ para o C_01

| | BRAVES | EDGAR | FINN | Rey (2023) |
|-------------------|---------------|--------------|-------------|-------------------|
| BRAVES | 1,00 | | | |
| EDGAR | 3,25E-221 | 1,00 | | |
| FINN | 3,09E-35 | 4,57E-79 | 1,00 | |
| Rey (2023) | 1,26E-259 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

5. Teste para SO_x

- Estatística Kruskal-Wallis: 197.781,38
- valor p: 0,000

Tabela 19. Valores de p da matriz post-hoc (teste de Dunn) para SO_x para o C_01

| | BRAVES | EDGAR | FINN | Rey (2023) |
|-------------------|---------------|--------------|-------------|-------------------|
| BRAVES | 1,00 | | | |
| EDGAR | 1,70E-137 | 1,00 | | |
| FINN | 1,15E-26 | 3,33E-40 | 1,00 | |
| Rey (2023) | 3,91E-249 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

Seção C.2. Matriz post-hoc para o conjunto C_02

1. Teste para NMVOC

- Estatística Kruskal-Wallis: 492.725,27
- valor p: 0,000

Tabela 20. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_02

| | EDGAR_AGR | EDGAR_T | FINN | MEGAN | Rey (2023) |
|------------|-----------|----------|-----------|-------|------------|
| EDGAR_AGR | 1,00 | | | | |
| EDGAR_T | 3,30E-46 | 1,00 | | | |
| FINN | 1,95E-111 | 0 | 1,00 | | |
| MEGAN | 2,21E+03 | 6,25E-30 | 6,78E-177 | 1,00 | |
| Rey (2023) | 0 | 0 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

2. Teste para NH₃

- Estatística Kruskal-Wallis: 404.761,57
- valor p: 0,000

Tabela 21. Valores de p da matriz post-hoc (teste de Dunn) para NH₃ para o C_02

| | EDGAR_AGR | EDGAR_T | FINN | Rey (2023) |
|------------|-----------|---------|------|------------|
| EDGAR_AGR | 1,00 | | | |
| EDGAR_T | 1,62E-95 | 1,00 | | |
| FINN | 9,56E-94 | 0 | 1,00 | |
| Rey (2023) | 0 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

3. Teste para NO_x

- Estatística Kruskal-Wallis: 434.412,77
- valor p: 0,000

Tabela 22. Valores de p da matriz post-hoc (teste de Dunn) para NO_x para o C_02

| | EDGAR_AGR | EDGAR_T | FINN | MEGAN | Rey (2023) |
|------------|-----------|----------|-----------|-------|------------|
| EDGAR_AGR | 1,00 | | | | |
| EDGAR_T | 6,74E-82 | 1,00 | | | |
| FINN | 3,26E-86 | 0 | 1,00 | | |
| MEGAN | 2,50E-08 | 4,44E-34 | 1,08E-198 | 1,00 | |
| Rey (2023) | 0,00 | 0,00 | 0,00 | 0,00 | 1,00 |

Fonte: Autoria própria.

4. Teste para MP_{2,5}

- Estatística Kruskal-Wallis: 369.032,37
- valor p: 0,000

Tabela 23. Valores de p da matriz post-hoc (teste de Dunn) para MP_{2,5} para o C_02

| | EDGAR_AGR | EDGAR_T | FINN | Rey (2023) |
|-------------------|------------------|----------------|-------------|-------------------|
| EDGAR_AGR | 1,00 | | | |
| EDGAR_T | 5,55E-78 | 1,00 | | |
| FINN | 4,72E-70 | 0 | 1,00 | |
| Rey (2023) | 0 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

5. Teste para SO_x

- Estatística Kruskal-Wallis: 374.032,37
- valor p: 0,000

Tabela 24. Valores de p da matriz post-hoc (teste de Dunn) para SO_x para o C_02

| | EDGAR_AGR | EDGAR_T | FINN | Rey (2023) |
|-------------------|------------------|----------------|-------------|-------------------|
| EDGAR_AGR | 1,00 | | | |
| EDGAR_T | 1,96E-231 | 1,00 | | |
| FINN | 6,39E-33 | 0 | 1,00 | |
| Rey (2023) | 0 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

Seção C.3. Matriz post-hoc para o conjunto C_03

1. Teste para NMVOC

- Estatística Kruskal-Wallis: 58.984,99
- valor p: 0,000

Tabela 25. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_03

| | BRAVES | EDGAR_AGR | EDGAR_IND | FINN | MEGAN |
|------------------|---------------|------------------|------------------|-------------|--------------|
| BRAVES | 1,00 | | | | |
| EDGAR_AGR | 0 | 1,00 | | | |
| EDGAR_IND | 0 | 9,28E-27 | 1,00 | | |
| FINN | 1,46E-218 | 0 | 0 | 1,00 | |
| MEGAN | 0 | 0 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

2. Teste para NH₃

- Estatística Kruskal-Wallis: 2.106,65
- valor p: 0,000

Tabela 26. Valores de p da matriz post-hoc (teste de Dunn) para NH₃ para o C_03

| | EDGAR_AGR | EDGAR_IND | FINN |
|------------------|------------------|------------------|-------------|
| EDGAR_AGR | 1,00 | | |
| EDGAR_IND | 7,35E-290 | 1,00 | |
| FINN | 1,30E-52 | 3,40E-111 | 1,00 |

Fonte: Autoria própria.

3. Teste para NO_x

- Estatística Kruskal-Wallis: 45.021,13
- valor p: 0,000

Tabela 27. Valores de p da matriz post-hoc (teste de Dunn) para NO_x para o C_03

| | BRAVES | EDGAR_AGR | EDGAR_IND | FINN | MEGAN |
|------------------|---------------|------------------|------------------|-------------|--------------|
| BRAVES | 1,00 | | | | |
| EDGAR_AGR | 0 | 1,00 | | | |
| EDGAR_IND | 7,10E-03 | 0,0 | 1,00 | | |
| FINN | 2,53E-01 | 0,0 | 9,08E-23 | 1,00 | |
| MEGAN | 0 | 0,0 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

4. Teste para $MP_{2,5}$

- Estatística Kruskal-Wallis: 7.399,49
- valor p: 0,000

Tabela 28. Valores de p da matriz post-hoc (teste de Dunn) para $MP_{2,5}$ para o C_03

| | BRAVES | EDGAR_AGR | EDGAR_IND | FINN |
|------------------|---------------|------------------|------------------|-------------|
| BRAVES | 1,00 | | | |
| EDGAR_AGR | 0 | 1,00 | | |
| EDGAR_IND | 5,25E-10 | 0 | 1,00 | 0 |
| FINN | 0 | 5,78E-55 | 0 | 1,00 |

Fonte: Autoria própria.

5. Teste para SO_x

- Estatística Kruskal-Wallis: 3.305,74
- valor p: 0,000

Tabela 29. Valores de p da matriz post-hoc (teste de Dunn) para SO_x para o C_03

| | BRAVES | EDGAR_AGR | EDGAR_IND | FINN |
|------------------|---------------|------------------|------------------|-------------|
| BRAVES | 1,00 | | | |
| EDGAR_AGR | 0 | 1,00 | | |
| EDGAR_IND | 1,19E-114 | 5,35E-111 | 1,00 | |
| FINN | 1,12E-115 | 8,22E-145 | 6,58E+05 | 1,00 |

Fonte: Autoria própria.

Seção C.4. Matriz post-hoc para o conjunto C_04

1. Teste para NMVOC

- Estatística Kruskal-Wallis: 36.957,53
- valor p: 0,000

Tabela 30. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_04

| | EDGAR_AGR | EDGAR_IND | EDGAR_T | FINN | MEGAN |
|-----------|-----------|-----------|---------|------|-------|
| EDGAR_AGR | 1,00 | | | | |
| EDGAR_IND | 1,40E-23 | 1,00 | | | |
| EDGAR_T | 2,48E-49 | 156,53 | 1,00 | | |
| FINN | 0 | 0 | 0 | 1,00 | |
| MEGAN | 0 | 0 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

2. Teste para NH₃

- Estatística Kruskal-Wallis: 12.291,15
- valor p: 0,000

Tabela 31. Valores de p da matriz post-hoc (teste de Dunn) para NH₃ para o C_04

| | EDGAR_AGR | EDGAR_IND | EDGAR_T | FINN |
|-----------|-----------|-----------|---------|------|
| EDGAR_AGR | 1,00 | | | |
| EDGAR_IND | 5,59E-277 | 1,00 | | |
| EDGAR_T | 0 | 0 | 1,00 | |
| FINN | 2,23E-40 | 1,72E-120 | 0 | 1,00 |

Fonte: Autoria própria.

3. Teste para NO_x

- Estatística Kruskal-Wallis: 57.391,35
- valor p: 0,000

Tabela 32. Valores de p da matriz post-hoc (teste de Dunn) para NO_x para o C_04

| | EDGAR_AGR | EDGAR_IND | EDGAR_T | FINN | MEGAN |
|-----------|-----------|-----------|----------|------|-------|
| EDGAR_AGR | 1,00 | | | | |
| EDGAR_IND | 0 | 1,00 | | | |
| EDGAR_T | 0 | 0 | 1,00 | | |
| FINN | 0 | 4,61E-13 | 0 | 1,00 | |
| MEGAN | 0 | 0 | 2,33E-93 | 0 | 1,00 |

Fonte: Autoria própria.

4. Teste para $MP_{2,5}$

- Estatística Kruskal-Wallis: 12.291,89
- valor p: 0,000

Tabela 33. Valores de p da matriz post-hoc (teste de Dunn) para $MP_{2,5}$ para o C_04

| | EDGAR_AGR | EDGAR_IND | EDGAR_T | FINN |
|------------------|------------------|------------------|----------------|-------------|
| EDGAR_AGR | 1,00 | 0 | | |
| EDGAR_IND | 0 | 1,00 | | |
| EDGAR_T | 6,27E-256 | 0 | 1,00 | |
| FINN | 3,95E-03 | 0 | 0 | 1,00 |

Fonte: Autoria própria.

5. Teste para SO_x

- Estatística Kruskal-Wallis: 27.275,87
- valor p: 0,000

Tabela 34. Valores de p da matriz post-hoc (teste de Dunn) para SO_x para o C_04

| | EDGAR_AGR | EDGAR_IND | EDGAR_TRANSP | FINN |
|---------------------|------------------|------------------|---------------------|-------------|
| EDGAR_AGR | 1,00 | | | |
| EDGAR_IND | 1,83E-10 | 1,00 | | |
| EDGAR_TRANSP | 0 | 0 | 1,00 | 0 |
| FINN | 6,96E-37 | 7,66 | 0 | 1,00 |

Fonte: Autoria própria.

Seção C.5. Matriz post-hoc para o conjunto C_05

1. Teste para NMVOC

- Estatística Kruskal-Wallis: 94.199,38
- valor p: 0,000

Tabela 35. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_05

| | BRAIN | BRAVES | EDGAR_AGR | FINN | MEGAN |
|------------------|--------------|---------------|------------------|-------------|--------------|
| BRAIN | 1,00 | | | | |
| BRAVES | 0,00 | 1,00 | | | |
| EDGAR_AGR | 0,00 | 0,00 | 1,00 | | |
| FINN | 0,00 | 0,00 | 0,00 | 1,00 | |
| MEGAN | 0,00 | 0,00 | 0,00 | 0,00 | 1,00 |

Fonte: Autoria própria.

2. Teste para NO_x

- Estatística Kruskal-Wallis: 80.901,15
- valor p: 0,000

Tabela 36. Valores de p da matriz post-hoc (teste de Dunn) para NO_x para o C_05

| | BRAIN | BRAVES | EDGAR_AGR | FINN | MEGAN |
|------------------|--------------|---------------|------------------|-------------|--------------|
| BRAIN | 1,00 | | | | |
| BRAVES | 0,00 | 1,00 | | | |
| EDGAR_AGR | 0,00 | 0,00 | 1,00 | | |
| FINN | 0,00 | 7,36E-28 | 0,00 | 1,00 | |
| MEGAN | 0,00 | 0,00 | 0,00 | 0,00 | 1,00 |

Fonte: Autoria própria.

3. Teste para MP_{2,5}

- Estatística Kruskal-Wallis: 42.486,51
- valor p: 0,000

Tabela 37. Valores de p da matriz post-hoc (teste de Dunn) para MP_{2,5} para o C_05

| | BRAIN | BRAVES | EDGAR_AGR | FINN |
|------------------|--------------|---------------|------------------|-------------|
| BRAIN | 1,00 | | | |
| BRAVES | 0 | 1,00 | | |
| EDGAR_AGR | 0 | 0 | 1,00 | |
| FINN | 0 | 0 | 5,26E-273 | 1,00 |

Fonte: Autoria própria.

4. Teste para SO_x

- Estatística Kruskal-Wallis: 38.550,45
- valor p: 0,000

Tabela 38. Valores de p da matriz post-hoc (teste de Dunn) para SO_x para o C_05

| | BRAIN | BRAVES | EDGAR_AGR | FINN |
|------------------|--------------|---------------|------------------|-------------|
| BRAIN | 1,00 | | | |
| BRAVES | 0,00 | 1,00 | | |
| EDGAR_AGR | 0,00 | 0,00 | 1,00 | |
| FINN | 0,00 | 1,64E-241 | 3,04E-289 | 1,00 |

Fonte: Autoria própria.

Seção C.6. Matriz post-hoc para o conjunto C_06

1. Teste para NMVOC

- Estatística Kruskal-Wallis: 100.551,02
- valor p: 0,000

Tabela 39. Valores de p da matriz post-hoc (teste de Dunn) para NMVOC para o C_06

| | BRAIN | EDGAR_AGR | EDGAR_T | FINN | MEGAN |
|-----------|-------|-----------|----------|------|-------|
| BRAIN | 1,00 | | | | |
| EDGAR_AGR | 0 | 1,00 | | | |
| EDGAR_T | 0 | 2,91E-191 | 1,00 | | |
| FINN | 0 | 0 | 0 | 1,00 | |
| MEGAN | 0 | 0 | 1,94E-77 | 0 | 1,00 |

Fonte: Autoria própria.

2. Teste para NH₃

- Estatística Kruskal-Wallis: 6.618,15
- valor p: 0,000

Tabela 40. Valores de p da matriz post-hoc (teste de Dunn) para NH₃ para o C_06

| | EDGAR_AGR | EDGAR_TRANSP | FINN |
|--------------|-----------|--------------|------|
| EDGAR_AGR | 1,00 | | |
| EDGAR_TRANSP | 0 | 1,00 | |
| FINN | 7,57E-26 | 0 | 1,00 |

Fonte: Autoria própria.

3. Teste para NO_x

- Estatística Kruskal-Wallis: 104.788,35
- valor p: 0,000

Tabela 41. Valores de p da matriz post-hoc (teste de Dunn) para NO_x para o C_06

| | BRAIN | EDGAR_AGR | EDGAR_T | FINN | MEGAN |
|-----------|-------|-----------|----------|------|-------|
| BRAIN | 1,00 | | | | |
| EDGAR_AGR | 0 | 1,00 | | | |
| EDGAR_T | 0 | 0 | 1,00 | | |
| FINN | 0 | 0 | 0 | 1,00 | |
| MEGAN | 0 | 0 | 5,14E-12 | 0 | 1,00 |

Fonte: Autoria própria.

4. Teste para $MP_{2,5}$

- Estatística Kruskal-Wallis: 70.165,27
- valor p: 0,000

Tabela 42. Valores de p da matriz post-hoc (teste de Dunn) para $MP_{2,5}$ para o C_06

| | BRAIN | EDGAR_AGR | EDGAR_T | FINN |
|------------------|--------------|------------------|----------------|-------------|
| BRAIN | 1,00 | | | |
| EDGAR_AGR | 0 | 1,00 | | |
| EDGAR_T | 0 | 0 | 1,00 | |
| FINN | 0 | 3,04E-105 | 0 | 1,00 |

Fonte: Autoria própria.

5. Teste para SO_x

- Estatística Kruskal-Wallis: 89.165,27
- valor p: 0,000

Tabela 43. Valores de p da matriz post-hoc (teste de Dunn) para SO_x para o C_06

| | BRAIN | EDGAR_AGR | EDGAR_TRANSP | FINN |
|---------------------|--------------|------------------|---------------------|-------------|
| BRAIN | 1,00 | | | |
| EDGAR_AGR | 0 | 1,00 | | |
| EDGAR_TRANSP | 0 | 0 | 1,00 | |
| FINN | 0 | 1,10E-97 | 0 | 1,00 |

Fonte: Autoria própria.