

FATORES QUE INFLUENCIAM A VULNERABILIDADE A $PM_{2,5}$ NOS MUNICÍPIOS DO MARANHÃO

Débora Joana Dutra ¹

¹ Discente da disciplina de População, Espaço e Ambiente do curso de pós-graduação em Sensoriamento Remoto do Instituto Nacional de Pesquisas Espaciais

RESUMO

A crescente preocupação com os impactos das queimadas na saúde pública e no meio ambiente, especialmente no Maranhão, evidencia a necessidade urgente de investigar a vulnerabilidade da população ao $PM_{2,5}$. Este estudo analisa a vulnerabilidade potencial da população maranhense às queimadas em 2022, com três objetivos principais: identificar as regiões mais expostas ao $PM_{2,5}$, quantificar a população afetada e avaliar as variáveis que mais influenciam a vulnerabilidade. Utilizando dados sobre infraestrutura, população e ambiente, e aplicando regressão logística, os resultados mostram que as regiões ao sul do Maranhão são as mais afetadas, com impactos significativos em crianças e idosos. A conclusão reforça a importância do monitoramento contínuo da qualidade do ar e da implementação de estratégias de mitigação. Recomenda-se também melhorar as políticas ambientais para enfrentar os desafios impostos pelas queimadas.

Palavras-chave — $PM_{2,5}$, Regressão Logística, Saúde Pública

1. INTRODUÇÃO

O $PM_{2,5}$ refere-se a partículas finas com diâmetro menor que 2,5 micrômetros, capazes de penetrar profundamente nos pulmões e na corrente sanguínea ¹. Essas partículas são frequentemente geradas por processos de combustão, como queimadas e incêndios florestais ².

A vulnerabilidade ao $PM_{2,5}$ está associada a diversos riscos à saúde humana. Estudos demonstram que a inalação dessas partículas pode causar problemas respiratórios, como asma e bronquite, e agravar condições cardiovasculares ³. Além disso, a vulnerabilidade prolongada ao $PM_{2,5}$ pode levar a doenças crônicas e reduzir a expectativa de vida ⁴. O impacto é particularmente grave para populações vulneráveis, como crianças, idosos e pessoas com condições preexistentes ⁵.

Nos últimos anos, o aumento das queimadas e incêndios florestais tem exacerbado a emissão de $PM_{2,5}$, especialmente em biomas brasileiros como a Amazônia e o Cerrado ⁶. Em 2024, um evento de grandes queimadas ocorrido em São Paulo é um exemplo recente de como esses processos têm intensificado a poluição do ar. Durante esse período, grandes áreas de vegetação foram queimadas, resultando em altas emissões de $PM_{2,5}$ e deterioração significativa da qualidade do ar na região.

A queima de biomassa em processos de desmatamento e práticas agrícolas libera uma série de poluentes

atmosféricos, incluindo o $PM_{2,5}$ ⁷. Esses poluentes não só afetam a qualidade do ar local, mas também podem ser transportados por grandes distâncias, afetando áreas distantes das fontes de queima ⁸.

Além dos impactos na saúde, a queimada de biomassa tem consequências ambientais graves⁹. A queima de grandes áreas de vegetação libera grandes quantidades de dióxido de carbono e outros gases de efeito estufa, contribuindo para as mudanças climáticas ¹⁰. Também causa perda de biodiversidade e degradação do solo, afetando a qualidade e a disponibilidade dos recursos naturais ¹¹. As emissões de $PM_{2,5}$ podem ser exacerbadas por condições meteorológicas, como ventos fortes e baixa umidade, que facilitam a dispersão das partículas e aumentam sua concentração em áreas urbanas e rurais.

No Maranhão, um estado que abriga partes desses biomas e áreas de transição, a queimada de biomassa é particularmente relevante. Esta prática é comum em regiões de desmatamento e áreas agrícolas, contribuindo para a emissão de $PM_{2,5}$ e agravando os problemas de poluição do ar ². O aumento da frequência e intensidade das queimadas no estado tem impactos diretos na qualidade do ar e na saúde da população local, especialmente em áreas com queima intensiva e regulamentação deficiente⁶.

Portanto, é essencial monitorar e analisar a emissão de $PM_{2,5}$ associada às queimadas de biomassa para compreender melhor os impactos ambientais e de saúde ¹². Isso inclui a avaliação da distribuição espacial das queimadas e das concentrações de $PM_{2,5}$, além de considerar a vulnerabilidade potencial da população aos riscos associados ⁷. Estratégias eficazes de mitigação e resposta podem ser desenvolvidas com base nesses dados, ajudando a proteger a saúde pública e a promover práticas agrícolas e de gestão florestal mais sustentáveis ¹².

Este estudo visa analisar a vulnerabilidade potencial da população maranhense às queimadas em 2022, com os seguintes objetivos: (i) Identificar as regiões com maior probabilidade de vulnerabilidade ao $PM_{2,5}$; (ii) Levantar a quantidade de população de 0 a 4 anos e maior que 65 anos exposta ao poluente nas regiões de maior probabilidade; (iii) Analisar como o conjunto de variáveis se comportam espacialmente no modelo de vulnerabilidade ao $PM_{2,5}$.

2. MATERIAL E MÉTODOS

2.1 ÁREA DE ESTUDO

A escala de estudo refere-se aos 217 municípios do estado do Maranhão (Figura 1). De acordo com o censo de 2022 ¹³, a região abriga uma população de 6.776.699 pessoas, com

3.447.276 mulheres e 3.329.423 homens, ao longo de uma área de ~329.651 km². Isso faz com que a região apresente 20,56 hab/km² com um crescimento populacional de 6417659 pessoas entre 1872 a 2022¹³. A região apresenta

uma população diversa compreendendo 1.361.865 pessoas que se declaram brancas, 854.424 pretas, 6.541 amarela, 4.499.018 pardas e 4.499.018 indígena¹³.




Figura 1. Área de estudo e distribuição da população maranhense no território brasileiro

2.2 VARIÁVEIS

Para definir o período de análise do estudo, foi projetada a série histórica dos dados de PM_{2,5} e focos de calor, com o objetivo de identificar o intervalo em que as emissões de queimadas coincidem com os picos de emissão do composto. Utilizou-se o limiar proposto por Requia et al (2021)¹², que sugere a análise dos valores superiores ao 90 percentil da série histórica para a região. Assim, o período selecionado para a análise foi de julho a agosto de 2020, correspondendo ao período seco da região e também ao aumento das queimadas no Maranhão.

A seleção das variáveis foi baseada na adaptação da equação de risco advinda do conceito de vulnerabilidade¹⁴. A vulnerabilidade pode ser definida como o grau de dano infligido a uma estrutura ou região por um fenômeno de determinada magnitude¹⁵. Esse processo se associa a um dos ensaios da década de 1980 que define que a vulnerabilidade está associada ao grau de perdas e impactos adversos em conjunto com a população exposta ao processo.

A equação de Sherbinin et al¹⁶ indica que a vulnerabilidade é resultante de fatores associados ao ambiente físico, infraestrutura e condições socioeconômicas. Na seleção das variáveis, realizou-se uma adaptação dos fatores delimitados Sherbinin et al¹⁶. Utilizou-se nesse processo as categorias ambiente, população e infraestrutura (Tabela 1). A categoria de ambiente considera a interação fogo e PM_{2,5}, concentrando-se principalmente em fatores associados à emissão do particulado. A categoria de

população foi aplicada em substituição aos fatores socioeconômicos delimitados por Sherbinin et al¹⁶ como fator de exposição ao fenômeno. Por fim, a categoria de infraestrutura corresponde a estrutura presente em cada município para a resposta em relação ao enfrentamento de situações de alta vulnerabilidade de PM_{2,5}.

As variáveis de ambiente incluem a emissão de PM_{2,5}, que é fundamental para avaliar a poluição do ar gerada pela queima de biomassa e seu impacto na saúde. As Variáveis Demográficas e de Saúde abordam faixas etárias e grupos populacionais, como crianças e idosos em comunidades quilombolas e indígenas, além de morbidade hospitalar associada a doenças respiratórias e cardiovasculares.

As variáveis de Infraestrutura incluem dados sobre a capacidade de resposta dos estabelecimentos de saúde em diferentes níveis e o número de leitos disponíveis, o que é importante para a gestão de emergências de saúde relacionadas a incêndios e poluição. As variáveis de população referem-se aos dados de população total, indígena e quilombola fornecidos pelo censo do IBGE de 2022.

Além disso, variáveis como o perímetro, a área e a duração dos incêndios fornecem informações sobre a extensão e a persistência dos eventos de fogo, permitindo uma avaliação dos impactos ambientais. A variável PM_{2,5}, que indica a presença ou ausência de emissão de PM_{2,5}, será utilizada como a variável nominal na regressão logística para explorar como diferentes fatores influenciam a probabilidade de emissão de partículas finas e fornecer insights para estratégias de mitigação e políticas públicas.

Variável	Sigla	Importância	Resolução	Fonte	Categoria
PM _{2,5} (ton)	pm_25	Estimativa de PM _{2,5} , em toneladas, emitido pela queima de biomassa dos biomas da Amazônia e Cerrado. O PM _{2,5} em conjunto com o CO ₂ são um dos principais gases emitidos pela queimada e com grande impacto para saúde humana se sua concentração for elevada ⁶	500m	Mataveli et al (2023) ⁶	Ambiente
Focos (quantidade/km ²)	focos	Os focos de calor, geralmente resultantes de queimadas e incêndios florestais, estão diretamente relacionados ao aumento dos níveis de PM _{2,5} na atmosfera, devido à emissão de partículas finas durante a combustão ⁶	Vetorial	INPE ¹⁷	
População entre 0 a 4 anos (pop/km ²)	pop_0_4	A população de 0 a 4 anos e maior que 65 anos é mais suscetível ao PM _{2,5} porque seus sistemas respiratório e imunológico são mais frágeis. Isso os torna mais vulneráveis aos efeitos nocivos das partículas finas inaladas ¹²	-	IBGE ¹⁸	População
População maior que 65 anos (pop/km ²)	pop_65		-	IBGE ¹⁸	
População quilombola entre 0 a 4 anos (pop/km ²)	popq_0_4	A população quilombola de 0 a 4 anos e maior que 65 anos é mais suscetível ao PM _{2,5} devido à combinação de fatores de vulnerabilidade, como acesso limitado a serviços de saúde e condições socioeconômicas desfavoráveis. Esses fatores, juntamente com sistemas respiratórios mais frágeis, aumentam o risco de doenças respiratórias causadas pela vulnerabilidade às partículas finas ¹²	-	IBGE ¹⁹	
População quilombola maior que 65 anos (pop/km ²)	popq_65		-	IBGE ¹⁹	
População indígena entre 0 a 4 anos (pop/km ²)	popi_0_4	A população indígena de 0 a 4 anos e maior que 65 anos é mais suscetível ao PM _{2,5} devido à vulnerabilidade aumentada por fatores como isolamento geográfico, acesso limitado a serviços de saúde e maior vulnerabilidade a ambientes naturais afetados por queimadas. Esses fatores, combinados com sistemas respiratórios mais frágeis, aumentam o risco de doenças respiratórias causadas por partículas finas ¹²	-	IBGE ²⁰	
População indígena maior que 65 anos (pop/km ²)	popi_65		-	IBGE ²⁰	
CNES - Estabelecimento com médio nível de atenção em escala estadual (total/ km ²)	amb_ba_es	Para mitigar as demandas devido à vulnerabilidade ao PM _{2,5} , é essencial que estabelecimentos de saúde de baixa, média e alta complexidade (estadual e municipal) ofereçam atendimento especializado, diagnóstico precoce e tratamentos para doenças respiratórias causadas pela poluição do ar. Além disso, esses estabelecimentos devem promover campanhas de prevenção e conscientização sobre os riscos associados à vulnerabilidade às partículas finas ¹²	-	DATASUS ²¹	Infraestrutura
CNES - Estabelecimento com médio nível de atenção em escala municipal (total/ km ²)	amb_ba_mu		-	DATASUS ²¹	
CNES - Estabelecimento com médio nível de atenção em escala municipal (total/ km ²)	amb_me_mu		-	DATASUS ²¹	
CNES - Estabelecimento com alto nível de atenção em escala municipal (total/ km ²)	amb_al_mu		-	DATASUS ²¹	
CNES - Estabelecimento com alto nível de atenção em escala estadual (total/ km ²)	amb_al_es		-	DATASUS ²¹	
Morbidade hospitalar do SUS (Doenças cardiovasculares) - (doentes/km ²)	cardio	A quantidade de morbidade de doenças respiratórias e cardíacas pode influenciar no aumento do nível de vulnerabilidade ao PM _{2,5} porque indivíduos com essas condições são mais vulneráveis aos efeitos nocivos das	-	DATASUS ²²	População

Morbidade hospitalar do SUS (Doenças respiratórias) - (doentes/km ²)	respirator	partículas finas. Isso pode resultar em um ciclo de agravamento da saúde e maior demanda por cuidados médicos, especialmente em áreas com alta poluição do ar ¹²	-	DATASUS ²²	
Números de leitos em hospitais que pertence ao SUS - (leitos/ km ²)	sus_leitos	A quantidade de leitos do SUS e não SUS presentes na cidade pode influenciar a capacidade dos municípios em atender as demandas devido à vulnerabilidade ao PM _{2.5} . Um número limitado de leitos pode dificultar o atendimento adequado de pacientes com doenças respiratórias e cardíacas agravadas pela poluição, aumentando a vulnerabilidade da população aos efeitos das partículas finas e mortalidade advindas de doenças respiratórias e cardíacas ¹²	-	DATASUS ²³	Infraestrutura
Números de leitos em hospitais que não pertence ao SUS - (leitos/ km ²)	n_sus_leit		-	DATASUS ²³	
Perímetro total do fogo para cada município do Maranhão (soma em km)	perimeters	O perímetro total do fogo para cada município do Maranhão, a área total do fogo e a duração do fogo influenciam a geração de PM _{2.5} . Grandes perímetros e áreas queimadas, associados a incêndios de longa duração, aumentam a liberação de partículas finas na atmosfera, elevando o risco de poluição e impactando a saúde respiratória da população ²⁴	250m	Global Fire Atlas ²⁵	Ambiente
Área total do fogo para cada município do Maranhão (soma em km ²)	sizesum		250m	Global Fire Atlas ²⁵	
Duração do fogo para cada município do Maranhão (valor máximo de duração do fogo na região)	durationma		250m	Global Fire Atlas ²⁵	
Dias secos (valor máximo de duração dos dias secos)	dry_days	O número de dias secos em cada município influencia a capacidade dos municípios em atender as demandas devido à vulnerabilidade ao PM _{2.5} . Períodos prolongados sem chuva podem intensificar a ocorrência e a propagação de incêndios, aumentando a quantidade de partículas finas liberadas na atmosfera e, conseqüentemente, o risco de poluição do ar e problemas de saúde respiratória para a população ²⁴	-	Rozante et al (2010) ²⁶	
Soma do comprimento de estradas presentes na região de estudo (km/km ²)	estrada	O comprimento de estradas em cada município pode influenciar a vulnerabilidade ao PM _{2.5} durante queimadas, pois estradas extensas podem facilitar a propagação do fogo e o acesso a áreas de incêndio, aumentando a extensão e a intensidade das queimadas. Isso resulta em maior liberação de partículas finas na atmosfera, elevando o risco de poluição do ar e impactos na saúde respiratória da população ²⁷	-	DNIT	

Tabela 1. Variáveis utilizadas no modelo de regressão logística

2.2 REGRESSÃO LOGÍSTICA

Baseado na metodologia de Requía et al (2021)¹², a análise de regressão logística foi utilizada para modelar a probabilidade de ocorrência de um evento binário, especificamente a presença de concentrações elevadas de PM_{2.5} (partículas finas de poluição) nos municípios. A regressão logística é uma técnica estatística que prevê a probabilidade de um evento binário com base em variáveis independentes.

O modelo foi utilizado para prever a probabilidade de ocorrência de concentrações elevadas de PM_{2.5} em todos os municípios. Essas probabilidades foram visualizadas em um mapa, por meio da aplicação da metodologia de Ye et al (2022)²⁸, e a matriz de confusão foi empregada para avaliar

a performance do modelo comparando previsões com valores reais.

A equação do modelo de regressão logística é dada por:

$$\text{logit}(P(Y = 1)) = \ln\left(\frac{P(Y=1)}{1-P(Y=1)}\right) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad (1)$$

onde:

- P(Y=1) é a probabilidade de ocorrência do evento (presença de concentrações elevadas de PM_{2.5})
- β_0 é o intercepto,
- $\beta_1, \beta_2, \dots, \beta_n$ são os coeficientes das variáveis independentes X_1, X_2, \dots, X_n

A probabilidade P(Y=1) pode ser calculada a partir da função logística:

$$P(Y = 1) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)}} \quad (2)$$

O ajuste do modelo foi avaliado com a métrica Pseudo-R² de McFadden:

$$R_{McF}^2 = 1 - \frac{\log - \text{verossimilhança do modelo}}{\log - \text{verossimilhança do modelo nulo}} \quad (3)$$

A qualidade das previsões foi analisada por meio da curva ROC e da métrica AUC (Área Sob a Curva). A curva ROC é um gráfico da taxa de verdadeiros positivos (TPR) versus a taxa de falsos positivos (FPR) e a AUC é calculada como:

$$AUC = \int_0^1 TRP(FPR)d(FPR) \quad (4)$$

onde:

- TRP é a taxa de verdadeiros positivos
- FRP é a taxa de falsos positivos

Com os resultados encontrados, selecionamos as regiões com potencial vulnerabilidade ao PM_{2.5} e realizamos a contagem de população vulnerável a esse composto.

2.3 INFLUÊNCIA DAS VARIÁVEIS

Para entender a influência das variáveis foi realizada a normalização dos coeficientes para a faixa de -1 a 1, facilitando a comparação direta entre as variáveis. A equação de normalização dos coeficientes é dada por:

$$\bar{\beta}_j = \frac{\beta_j - \beta_{min}}{\beta_{max} - \beta_{min}} \quad (5)$$

onde:

- $\bar{\beta}_j$ é o coeficiente normalizado da variável X_j ,
- β_j é o coeficiente estimado para a variável X_j ,
- β_{max} e β_{min} são os valores mínimos e máximos dos coeficientes

Realizou-se a somatória de cada categoria de modo a identificar sua influência ao longo do estado do Maranhão e verificar se existe uma categoria específica que influencia nos resultados de probabilidade encontrados ou se a combinação do aspecto população, espaço e ambiente é responsável pelos resultados encontrados.

3. RESULTADOS E DISCUSSÕES

A região de estudo apresenta uma grande concentração de focos de calor e de PM_{2.5} no sul do estado do Maranhão, principalmente nas regiões de presença do bioma Cerrado (Figura 2). A dinâmica espacial demonstra uma correlação de 0.86 entre as variáveis dos focos e emissão de PM_{2.5}. Dessa forma, para estudos futuros pode ser interessante a realização de testes onde a variável nominal seja os focos de calor e o PM_{2.5} seja colocado dentro do conjunto de variáveis.

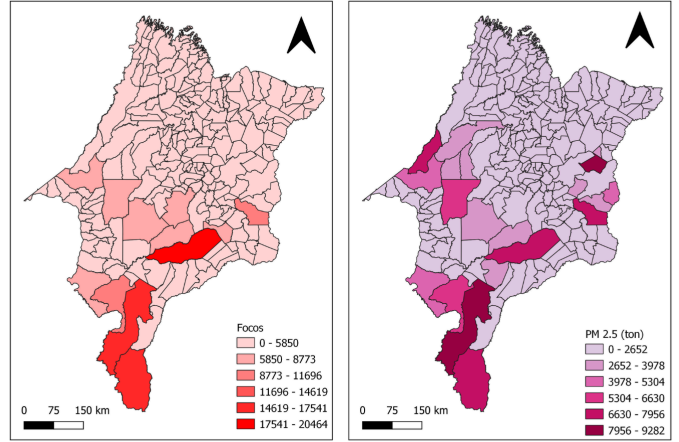


Figura 2. Ocorrência de focos de calor (esquerda) e de emissão de PM_{2.5} (direita) na região de estudo no período analisado

O modelo de regressão logística apresentou $R_{McF}^2 = 0.72$ e $AUC = 0.86$, em p-value <0.05, demonstrando eficiência na metodologia proposta e indicando algumas limitações no desempenho para esse tipo de análise. De acordo com a Figura 3, observamos que as regiões com maiores probabilidades de vulnerabilidade ao PM_{2.5} se concentram ao sul do estado do Maranhão. Essas regiões apresentam como característica comum a presença do bioma Cerrado. Esse bioma tem uma dependência ao fogo, sendo a sua ocorrência importante para o processo de rebrota das plantas²⁹. Entretanto, estudos de Mataveli et al (2023)⁷ e Bhattarai et al (2024)¹ mostram que o aumento das queimadas de origem antropogênica está associado a um incremento nas emissões de partículas finas. Apesar da redução das taxas de desmatamento nos últimos anos, o número de queimadas tem ocorrido em maior escala³⁰.

A análise de probabilidade vulnerabilidade a concentrações elevadas de PM_{2.5} revelou uma concentração significativa de populações vulneráveis nas áreas mais afetadas (Tabela 2). Nessas regiões, 110.735 crianças de 0 a 4 anos estão presentes, representando cerca de 20% da população total de 517.099 habitantes. A população acima de 65 anos é de 117.217 pessoas, o que corresponde a aproximadamente 20% da população total de 572.493 habitantes.

Entre a população indígena, 859 indivíduos de 0 a 4 anos residem nas áreas de alta vulnerabilidade, o que equivale a 10% da população indígena total de 8.534 pessoas. Além disso, 293 indígenas com mais de 65 anos estão localizados nessas áreas, representando cerca de 13% da população indígena nesta faixa etária, que totaliza 2.267 indivíduos.

Para a população quilombola, 725 crianças de 0 a 4 anos vivem nas áreas mais expostas, o que corresponde a 3% da população quilombola total de 21.496 pessoas. Além disso, 609 quilombolas com mais de 65 anos residem nessas áreas, representando aproximadamente 2,6% da população quilombola total de 23.595 habitantes.

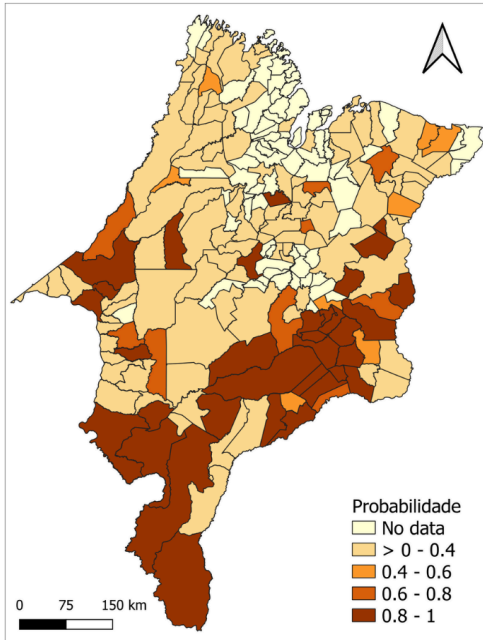


Figura 3. Resultado da probabilidade vulnerabilidade ao PM_{2.5} resultante do modelo de regressão logística

	Habitantes	População total
População de 0 a 4 anos	110735	517099
População maior que 65 anos	117217	572493
População indígena de 0 a 4 anos	859	8534
População indígena maior que 65 anos	293	2267
População quilombola de 0 a 4 anos	725	21496
População quilombola maior que 65 anos	609	23595

Tabela 2. Distribuição da população com maior probabilidade vulnerabilidade e vulnerabilidade às altas concentrações de PM_{2.5}

Esses resultados destacam a presença significativa de crianças pequenas e idosos, bem como de populações indígenas e quilombolas, em áreas com elevados níveis de PM_{2.5}. Isso ressalta a necessidade de criação de políticas públicas para reduzir os impactos da poluição do ar sobre esses grupos mais vulneráveis à vulnerabilidade por PM_{2.5}. Apesar do estudo não fazer uma separação de gênero entre a população mais vulnerável, os resultados encontrados corroboram com os encontrados por Ye et al. (2022)²⁸. Estes autores discutem que essas faixas de populações são mais

susceptíveis a complicações associadas a doenças respiratórias e cardiovasculares.

É importante notar que o modelo de regressão logística apresenta uma limitação em relação ao estudo de Ye et al. (2022), que usou dados de doenças respiratórias e cardiovasculares. O período analisado por Ye et al. (2022) vai de 2000 a 2016, antes da pandemia de COVID-19, que começou no final de 2019. Este estudo foi realizado em 2020, e o DATASUS não diferencia entre doenças associadas a incêndios e aquelas associadas à pandemia. Assim, é possível que os dados de doenças cardíacas e respiratórias estejam elevados, apesar da aplicação do filtro de período para o 90th percentile de emissão de PM_{2.5}.

No que se refere à influência das variáveis no modelo, a normalização dos dados indicou que elas o afetam de maneira espacial, com efeitos positivos e negativos. Em relação às variáveis de infraestrutura (Figura 4), observamos que as variáveis que impactam de forma positiva o modelo estão associadas a presença de ambulatórios de média complexidade e quantidade de leitos.




Figura 4. Normalização dos coeficientes de estimativa de regressão logística para as variáveis de infraestrutura

A presença de ambulatórios de média complexidade e leitos pode influenciar positivamente o modelo de regressão logística ao fornecer dados mais representativos e estáveis para os municípios do Maranhão. Ambulatórios de média complexidade e maior quantidade de leitos geralmente estão localizados em áreas com maior densidade populacional e oferecem uma gama de serviços mais abrangente, o que melhora a precisão do modelo ao refletir de maneira mais fiel às necessidades de saúde da população³¹.

A presença de ambulatórios de média complexidade e leitos pode influenciar positivamente o modelo de regressão logística ao fornecer dados mais representativos e estáveis para os municípios do Maranhão. Ambulatórios de média complexidade e leitos geralmente estão localizados em áreas com maior densidade populacional e oferecem uma gama de serviços mais abrangente, o que melhora a precisão do modelo ao refletir de maneira mais fiel às necessidades de saúde da população³¹.

A presença de crianças de 0 a 4 anos na população geral tem um efeito positivo no modelo, assim como a presença de crianças quilombolas na mesma faixa etária (Figura 5). Essa influência positiva sugere que áreas com maior concentração dessas populações podem estar associadas a um maior risco de certas condições de saúde, possivelmente devido à vulnerabilidade prolongada e diferenças nas necessidades de cuidado³².

Em contraste, a presença de idosos (acima de 65 anos) na população geral e entre os quilombolas tende a impactar negativamente o modelo de regressão logística. Esses grupos etários são mais vulneráveis a condições crônicas e apresentam maior risco de complicações de saúde, o que pode aumentar a carga de doenças e, conseqüentemente, impactar negativamente o modelo ao indicar um maior risco de desfechos adversos, não necessariamente associados às emissões de $PM_{2.5}$ ³³.

A presença de idosos indígenas (acima de 65 anos) influencia positivamente o modelo. Isso pode ocorrer devido a fatores como menor concentração populacional em áreas mais afetadas por $PM_{2.5}$ ou diferentes padrões de vulnerabilidade e vulnerabilidade, que reduzem o risco de desfechos de saúde adversos relacionados ao modelo.

As doenças cardíacas têm um efeito negativo no modelo, o que indica que áreas com maior incidência dessas condições apresentam piores indicadores de saúde ou enfrentam maiores desafios no atendimento médico. Esse resultado está relacionado ao fato de que as doenças cardíacas não são causadas apenas pela vulnerabilidade a poluentes como o $PM_{2.5}$, mas também por fatores como dieta, estilo de vida, genética e condições preexistentes. Portanto, o impacto observado reflete uma combinação de fatores além da poluição do ar.

Por outro lado, a prevalência de doenças respiratórias tem um impacto positivo no modelo de regressão logística. Durante a pandemia de COVID-19, houve um aumento significativo nos casos de doenças respiratórias, o que pode ter levado a uma superestimação da prevalência dessas

condições nos dados. Assim, o impacto positivo observado reflete tanto a resposta ampliada do sistema de saúde durante a crise quanto os esforços intensificados para o manejo dessas doenças.

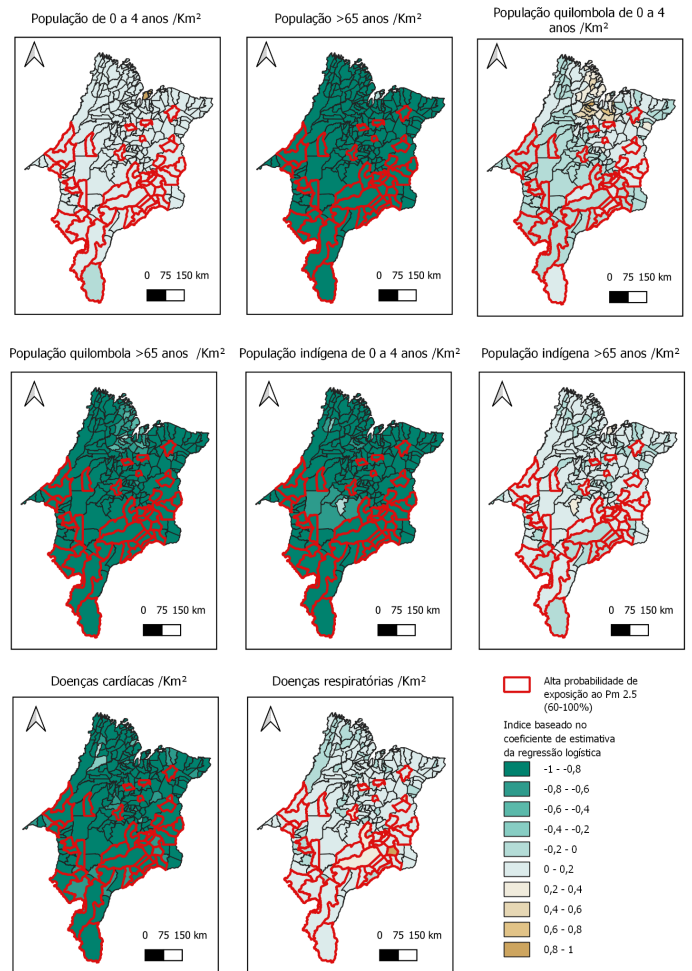


Figura 5. Normalização dos coeficientes de estimativa de regressão logística para as variáveis de população

A análise das variáveis ambientais revelou diferentes impactos nas concentrações de $PM_{2.5}$ e sua dispersão na atmosfera (Figura 6). Variáveis como o perímetro do fogo, a linha do fogo, o comprimento das estradas e o número de dias secos apresentaram uma influência negativa no modelo de regressão logística. Esses resultados indicam que, embora essas variáveis estejam associadas a áreas com incêndios, elas não refletem diretamente concentrações elevadas de $PM_{2.5}$.

O perímetro do fogo maior e uma linha de fogo extensa podem, paradoxalmente, levar a uma dispersão mais ampla das partículas de $PM_{2.5}$. A expansão da área queimada pode promover a diluição das partículas finas em uma área mais extensa, resultando em concentrações menores em pontos específicos em comparação com áreas com menor perímetro de fogo¹. O comprimento das estradas também desempenha

um papel importante, pois estradas bem desenvolvidas e acessíveis podem facilitar a resposta rápida aos incêndios, permitindo o controle mais eficaz das chamas e a redução das emissões de $PM_{2.5}$. O número de dias secos, embora favoreça a propagação dos incêndios, quando associado a condições, como o vento, reduz a concentração de $PM_{2.5}$ na região de emissão.

Portanto, a influência negativa dessas variáveis no modelo pode ser explicada pela forma como o $PM_{2.5}$ é disperso na atmosfera¹. A concentração de $PM_{2.5}$ não é necessariamente mais alta na área onde o incêndio ocorre, devido à dispersão das partículas e à eficácia das intervenções de controle. Isso sugere que a presença de um incêndio e variáveis associadas à sua extensão e propagação não se traduz diretamente em concentrações elevadas de $PM_{2.5}$.

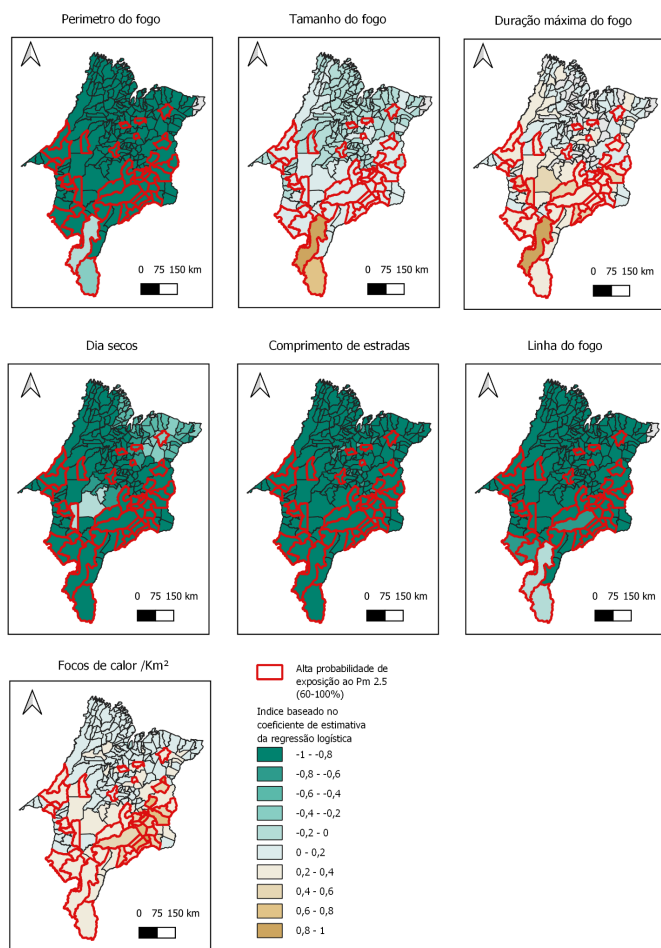


Figura 6. Normalização dos coeficientes de estimativa de regressão logística para as variáveis de ambiente

Ao somar os índices das categorias de infraestrutura, população e ambiente, observou-se que as variáveis

relacionadas à infraestrutura e ao ambiente influenciaram positivamente o modelo geral (Figura 7). Locais com menor infraestrutura por densidade populacional e maiores emissões de queimadas tendem a apresentar uma maior probabilidade de vulnerabilidade a concentrações elevadas de $PM_{2.5}$. Isso sugere que áreas com infraestrutura limitada e alta emissão de poluentes estão mais propensas a concentrações elevadas de $PM_{2.5}$ devido à falta de recursos para controlar e mitigar os impactos das queimadas.

Por outro lado, em relação às variáveis de população, identificou-se que, de forma geral, as tipologias analisadas apresentaram uma influência negativa no modelo. Contudo, regiões com alta densidade populacional, como a cidade de São Luís, e áreas com maior concentração de populações quilombolas tendem a mostrar um impacto espacial positivo no modelo. Isso indica que, enquanto a densidade populacional em si pode não influenciar fortemente o modelo, áreas de grande aglomeração e com comunidades quilombolas específicas têm uma maior probabilidade de apresentar níveis mais altos de vulnerabilidade a $PM_{2.5}$.

Por outro lado, em relação às variáveis de população, identificou-se que, de forma geral, as tipologias analisadas apresentaram uma influência negativa no modelo. Contudo, regiões com alta densidade populacional, como a cidade de São Luís, e áreas com maior concentração de populações quilombolas tendem a mostrar um impacto espacial positivo no modelo. Isso indica que, enquanto a densidade populacional em si pode não influenciar fortemente o modelo, áreas de grande aglomeração e com comunidades quilombolas específicas têm uma maior probabilidade de apresentar níveis mais altos de vulnerabilidade a $PM_{2.5}$.

Em relação às variáveis ambientais, observou-se que a presença de grandes focos de incêndio, perímetro do fogo, linha de fogo, tamanho e duração do fogo tiveram um impacto positivo significativo no modelo. Isso reflete que áreas com maiores focos e mais extensos de incêndios, bem como incêndios de longa duração, estão associadas a concentrações mais elevadas de $PM_{2.5}$.

Por fim, ao considerar as variáveis de infraestrutura, notou-se que, apesar de suas influências individuais, elas não apresentam um padrão claro quando combinadas com outras variáveis. As regiões com maior densidade populacional tendem a possuir uma infraestrutura mais desenvolvida, mas essa infraestrutura tem pouco impacto na concentração de $PM_{2.5}$. Em resumo, a infraestrutura por si só não mostra uma correlação consistente com altas concentrações de $PM_{2.5}$, o que destaca a necessidade de uma análise mais aprofundada para entender melhor como a infraestrutura interage com as variáveis ambientais e populacionais para afetar a qualidade do ar.

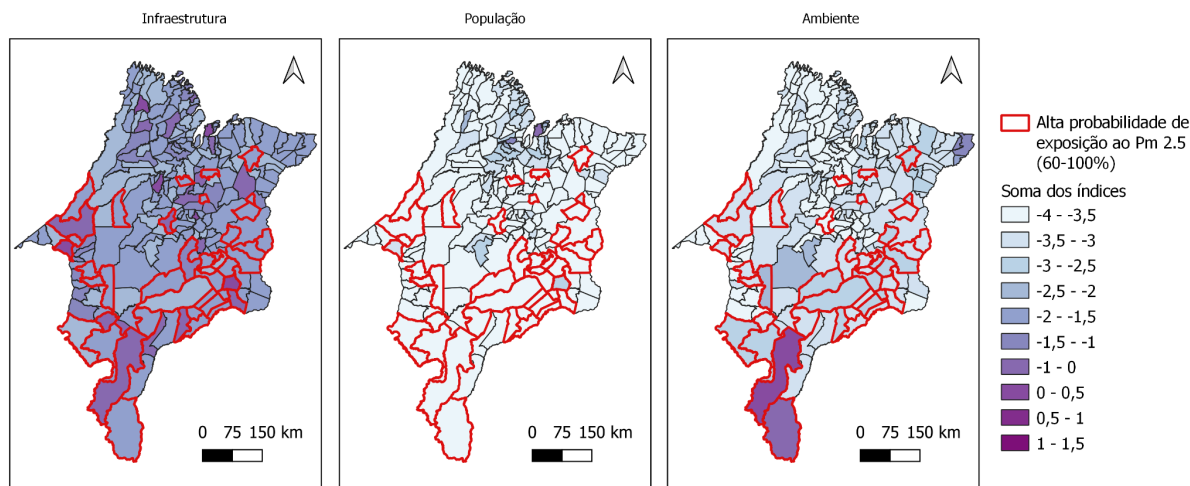


Figura 8. Somatório da contribuição de cada categoria de variáveis no modelo de regressão logística

4. CONCLUSÕES

A análise da vulnerabilidade ao $PM_{2.5}$ nas áreas afetadas por queimadas no Maranhão revela uma complexa interação entre fatores ambientais, demográficos e de infraestrutura, destacando a gravidade dos impactos para a saúde pública. As partículas finas de $PM_{2.5}$, resultantes das queimadas, têm implicações significativas para a saúde humana, especialmente em áreas onde a concentração dessas partículas é elevada. Os dados indicam que as regiões do sul do Maranhão, predominantemente no bioma Cerrado, são as mais vulneráveis à poluição do ar causada pelas queimadas.

A vulnerabilidade ao $PM_{2.5}$ está fortemente correlacionada com a presença de populações vulneráveis, incluindo crianças e idosos, que são mais suscetíveis aos efeitos adversos das partículas finas. A análise mostra que, nestas áreas, há uma alta concentração de crianças e idosos, que enfrentam riscos elevados devido à poluição atmosférica. Além disso, o estudo evidencia que a capacidade de resposta em termos de infraestrutura de saúde é crítica para lidar com as demandas decorrentes dos impactos das queimadas.

O modelo de regressão logística utilizado no estudo revelou uma boa eficiência na previsão das áreas mais expostas ao $PM_{2.5}$, com uma AUC de 0.86, indicando a robustez da metodologia para identificar regiões de risco. Contudo, a análise também ressalta a necessidade de medidas adicionais para aprimorar a gestão de queimadas e mitigar os efeitos da poluição do ar. Estratégias eficazes devem incluir o monitoramento contínuo das emissões de $PM_{2.5}$, o fortalecimento das políticas de controle de queimadas e a melhoria da infraestrutura de saúde para atender a população afetada.

Portanto, para enfrentar os desafios associados às queimadas e à emissão de $PM_{2.5}$, é essencial implementar políticas públicas e estratégias de mitigação que considerem a interdependência entre fatores ambientais e socioeconômicos. A proteção da saúde pública e a

promoção de práticas sustentáveis de gestão de biomassa são fundamentais para reduzir os impactos negativos das queimadas e melhorar a qualidade do ar no estado do Maranhão.

5. REFERÊNCIAS

- Bhattarai, H., Tai, A. P. K., Val Martin, M. & Yung, D. H. Y. Responses of fine particulate matter ($PM_{2.5}$) air quality to future climate, land use, and emission changes: Insights from modeling across shared socioeconomic pathways. *Science of The Total Environment* **948**, 174611 (2024).
- Schill, G. P. *et al.* Widespread biomass burning smoke throughout the remote troposphere. *Nat. Geosci.* **13**, 422–427 (2020).
- Coker, E. S. *et al.* Association between $PM_{2.5}$ and respiratory hospitalization in Rio Branco, Brazil: Demonstrating the potential of low-cost air quality sensor for epidemiologic research. *Environmental Research* **214**, 113738 (2022).
- Nawaz, M. O. & Henze, D. K. Premature Deaths in Brazil Associated With Long-Term Exposure to $PM_{2.5}$ From Amazon Fires Between 2016 and 2019. *GeoHealth* **4**, e2020GH000268 (2020).
- Silva, P. R. D. S. *et al.* High risk of respiratory diseases in children in the fire period in Western Amazon. *Rev. Saúde Pública* **50**, (2016).
- Mataveli, G. *et al.* Daily Emission of Fine Particulate Matter ($PM_{2.5}$) Associated with Biomass Burning in South America During 2002-2020. Zenodo <https://doi.org/10.5281/ZENODO.10037352> (2023).
- Mataveli, G. *et al.* Updated Land Use and Land Cover Information Improves Biomass Burning Emission Estimates. *Fire* **6**, 426 (2023).
- Johnston, H. J. *et al.* How Harmful Is Particulate Matter Emitted from Biomass Burning? A Thailand Perspective. *Curr Pollution Rep* **5**, 353–377 (2019).
- Campanharo, W. A., Morello, T., Christofoletti, M. A. M. & Anderson, L. O. Hospitalization Due to Fire-Induced Pollution in the Brazilian Legal Amazon from 2005 to 2018. *Remote Sensing* **14**, 69 (2021).
- IPCC. *IPCC Guidelines for National Greenhouse Gas Inventories: SUMMARY OF EQUATIONS*. https://www.ipcc-nggip.iges.or.jp/public/2006gl/pdf/4_Volume

- 4/V4_14_An2_SumEqua.pdf (2006).
11. Barlow, J. *et al.* Quantifying the biodiversity value of tropical primary, secondary, and plantation forests. *Proc. Natl. Acad. Sci. U.S.A.* **104**, 18555–18560 (2007).
 12. Requia, W. J., Amini, H., Mukherjee, R., Gold, D. R. & Schwartz, J. D. Health impacts of wildfire-related air pollution in Brazil: a nationwide study of more than 2 million hospital admissions between 2008 and 2018. *Nat Commun* **12**, 6555 (2021).
 13. IBGE. Cidades. <https://cidades.ibge.gov.br/brasil/ac/panorama> (2023).
 14. Oliveira, E. L. D. A. Vulnerabilidade: a questão central da equação de risco. *REGEP* **22**, 19 (2018).
 15. Giupponi, C. & Biscaro, C. Vulnerabilities—bibliometric analysis and literature review of evolving concepts. *Environ. Res. Lett.* **10**, 123002 (2015).
 16. De Sherbinin, A., Schiller, A. & Pulsipher, A. The vulnerability of global cities to climate hazards. *Environment and Urbanization* **19**, 39–64 (2007).
 17. INPE. BD Queimadas. <https://terrabrasil.dpi.inpe.br/queimadas/bdqueimadas/> (2024).
 18. IBGE. Tabela 1209 - População, por grupos de idade. <https://sidra.ibge.gov.br/tabela/1209> (2022).
 19. IBGE. Tabela 8176 - População quilombola, por localização do domicílio, grupos de idade e sexo. <https://sidra.ibge.gov.br/Tabela/8176> (2022).
 20. IBGE. Tabela 8175 - População indígena, por localização do domicílio, grupos de idade e sexo. <https://sidra.ibge.gov.br/Tabela/8175> (2022).
 21. DATASUS. CNES - ESTABELECIMENTOS POR NÍVEL DE ATENÇÃO. <http://tabnet.datasus.gov.br/cgi/deftohtm.exe?cnes/cnv/atencma.def> (2024).
 22. DATASUS. Morbidade Hospitalar do SUS (SIH/SUS). <https://datasus.saude.gov.br/aceso-a-informacao/morbidade-hospitalar-do-sus-sih-sus/> (2024).
 23. DATASUS. CNES - Recursos físicos. <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?sih/cnv/nima.def> (2024).
 24. Ribeiro, M. R. *et al.* Amazon Wildfires and Respiratory Health: Impacts during the Forest Fire Season from 2009 to 2019. *IJERPH* **21**, 675 (2024).
 25. Andela, N. & Jones, M. W. Update of: The Global Fire Atlas of individual fire size, duration, speed and direction. Zenodo <https://doi.org/10.5281/ZENODO.11400062> (2024).
 26. Rozante, J. R., Moreira, D. S., De Goncalves, L. G. G. & Vila, D. A. Combining TRMM and Surface Observations of Precipitation: Technique and Validation over South America. *Weather and Forecasting* **25**, 885–894 (2010).
 27. Poorter, L. *et al.* Biomass resilience of Neotropical secondary forests. *Nature* **530**, 211–214 (2016).
 28. Ye, T. *et al.* Short-term exposure to wildfire-related PM_{2.5} increases mortality risks and burdens in Brazil. *Nat Commun* **13**, 7651 (2022).
 29. Pivello, V. R. The Use of Fire in the Cerrado and Amazonian Rainforests of Brazil: Past and Present. *fire ecol* **7**, 24–39 (2011).
 30. Mataveli, G. *et al.* Deforestation falls but rise of wildfires continues degrading Brazilian Amazon forests. *Global Change Biology* **30**, e17202 (2024).
 31. Brasil. PORTARIA Nº 4.279, DE 30 DE DEZEMBRO DE 2010. (2010).
 32. Andrade Filho, V. S. D., Artaxo, P., Hacon, S., Carmo, C. N. D. & Cirino, G. Aerossóis de queimadas e doenças respiratórias em crianças, Manaus, Brasil. *Rev. Saúde Pública* **47**, 239–247 (2013).
 33. Andrade Filho, V. S. D., Artaxo Netto, P. E., Hacon, S. D. S. & Carmo, C. N. D. Distribuição espacial de queimadas e mortalidade em idosos em região da Amazônia Brasileira, 2001 – 2012. *Ciênc. saúde coletiva* **22**, 245–253 (2017).