

CONCENTRAÇÕES DE NOX E CO ASSOCIADAS ÀS VARIÁVEIS METEOROLÓGICAS NAS CIDADES DE BRASÍLIA E GOIÂNIA

Heleno Proiss Slompo

Universidade de Brasília

Cássia Monalisa dos Santos Silva

Universidade Estadual de Goiás

Rafael Rodrigues da Franca

Universidade de Brasília

RESUMO

A poluição atmosférica é uma das principais consequências das atividades antrópicas, com efeitos sobre a qualidade do ar e o conforto térmico urbano. Foram utilizados dados do sensor TROPOMI, a bordo do satélite Sentinel-5P, e dados meteorológicos do INMET, para avaliar a qualidade do ar em Brasília e Goiânia, duas capitais do Cerrado brasileiro, entre 2019 e 2024. Modelos de regressão Ridge e Lasso foram comparados quanto ao desempenho preditivo (MSE e R^2) e à capacidade de seleção de variáveis, incorporando defasagens temporais de 1 e 2 dias. Goiânia apresentou concentrações médias de CO superiores às de Brasília no período estudado. Temperatura e umidade relativa foram as variáveis com maior contribuição para a explicação da variância dos poluentes. O aumento da pressão atmosférica esteve associado à redução das concentrações, enquanto velocidade do vento e precipitação apresentaram coeficientes de menor magnitude. O modelo Ridge apresentou desempenho preditivo ligeiramente superior ao Lasso (R^2 entre 0,01 e 0,06 mais alto, a depender do poluente e da cidade), enquanto o Lasso mostrou-se mais eficiente na seleção de variáveis, ao zerar coeficientes de menor contribuição.

Palavras-chave: Cerrado; Qualidade do ar; Regressão; Ridge; Lasso.

ABSTRACT

Air pollution is a major consequence of anthropogenic activities, affecting air quality and urban thermal comfort. Data from the TROPOMI sensor aboard the Sentinel-5P satellite and meteorological data from INMET were used to assess air quality in Brasília and Goiânia—two capitals in the Brazilian Cerrado—between 2019 and 2024. Ridge and Lasso regression models were compared based on predictive performance (MSE and R^2) and variable selection capability, incorporating 1- and 2-day time lags. Goiânia exhibited higher average CO concentrations than Brasília during the study period. Temperature and relative humidity were the variables that contributed most to explaining pollutant variance. Increased atmospheric pressure was associated with reduced concentrations, whereas wind speed and precipitation showed coefficients of lower magnitude. The Ridge model demonstrated slightly better predictive performance than the Lasso model (with R^2 values 0.01 to 0.06 higher, depending on the pollutant and city), while the Lasso model proved more efficient at variable selection by setting the coefficients of less significant variables to zero.

Key words: Cerrado; Air quality; Regression; Ridge; Lasso.

INTRODUÇÃO

A atmosfera é uma camada gasosa composta por diversas substâncias, que são importantes para a dinâmica dos fluxos biogeoquímicos da Terra. No entanto, a crescente urbanização intensificou a densidade industrial e o consumo de energia para produção, construção e expansão das redes viárias. Além disso, as atividades humanas elevaram o uso de combustíveis fósseis, o que contribuiu para alterações na composição química da atmosfera (Zarate, 2007). Inicialmente, acreditava-se que o enxofre liberado pela queima de carvão seria o principal poluente. Contudo, com o avanço da industrialização, o tráfego e as atividades industriais passaram a adicionar novos poluentes no ambiente urbano (Molina; Molina, 2004).

As áreas urbanas são grandes emissoras de poluentes, cuja distribuição espacial e evolução temporal são influenciadas por processos (termo)dinâmicos que ocorrem sobre as cidades (Sarrat et al., 2006). A Camada Limite Planetária (CLP) desempenha um papel fundamental nesses processos, atuando como reservatório dos poluentes e regulando sua dispersão, mistura, transformação, transporte e deposição (Oke, 2002). Sob esta camada, em áreas urbanas, ocorre a formação do chamado “smog fotoquímico”, resultante da emissão de poluentes por combustão interna e vapores industriais. Esses compostos interagem com a luz solar, promovendo reações que originam poluentes secundários a partir dos primários (Rani et al., 2011).

No contexto urbano, os veículos são responsáveis por aproximadamente 60% das emissões de monóxido de carbono (CO), 50% dos óxidos de nitrogênio (NOx) e 40% dos compostos orgânicos (HC) e do Material Particulado (MP) (UEPA, 1998). Tanto o NOx (NO + NO₂) quanto o CO passam por sucessivos processos químicos, o que inclui fotodissociações, reações e remoções por deposição seca e/ou úmida. O inventário de emissões do Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa SEEG (2024) indica que o setor de energia, que inclui a significativa influência de emissões urbanas, é a principal fonte de emissões em Brasília e Goiânia, as duas cidades mais populosas do Centro-Oeste brasileiro e que apresentam maiores dinâmicas do espaço urbano, como o transporte na queima de combustível.

Entretanto, as fontes de poluentes primários desempenham um papel essencial para as complexas reações químicas na atmosfera, contribuindo para a formação de poluentes secundários, como o ozônio troposférico (O₃). Seus precursores incluem CO, NO₂ e compostos orgânicos voláteis (COVs) (Seinfeld & Pandis, 2016). Quanto às fontes, Silva (2023), ao estudar o aporte de nitrogênio reativo (NOx) no Cerrado, identificou um desequilíbrio no seu balanço em áreas remotas, influenciado por variadas emissões antropogênicas. Nesse bioma, a intensificação das atividades agrícolas tem um impacto significativo nas emissões de NO₂, como o caso do Mato Grosso do Sul, decorrente de pastagens e queimadas nos meses secos (Souza et al., 2022). O monóxido de carbono (CO) também tem sido amplamente estudado nas variadas fitofisionomias do Cerrado, sobretudo em relação aos seus estoques e às mudanças decorrentes do uso do solo (Rezende et al., 2006).

Apesar da relevância desses processos para a qualidade do ar na região, ainda são escassos os estudos que relacionem diretamente as concentrações de poluentes atmosféricos às variáveis meteorológicas no Centro-Oeste brasileiro. A técnica de Sensoriamento Remoto (SR) permite a mensuração das condições naturais e da poluição atmosférica em grandes áreas por meio de satélites, o que reduz custos operacionais (Somvanshi, 2019). O uso de dados satelitais é comum em países em desenvolvimento, onde os recursos para monitoramento ambiental são mais limitados

(Halder et al., 2023), em conjunto com dados de reanálise, usados como fontes confiáveis para estudos de mudanças temporais na poluição (Castelhana et al., 2022)

Uma aplicação do uso desse método foi a comparação entre os sensores Ozone Monitoring Instrument (OMI) e TROPOMI para o monitoramento de NO₂ na China (Wang et al., 2020). Outros estudos utilizaram SR para análise do CO e indicaram que poluentes atmosféricos como este apresentam altas concentrações em regiões em desenvolvimento e com elevada densidade de ocupação, a exemplo da Índia (Borsdorff et al., 2018). No Centro-Oeste, um estudo comparou as cidades de Brasília, Goiânia e Anápolis usando o NO₂ pelo sensor TROPOMI para os anos de 2019 e 2021 em contexto de pandemia COVID-19, através de um estudo temporal-espacial, mas sem considerar variáveis meteorológicas e outros poluentes (Valadão et al., 2022). Diante dessa lacuna, hipotetiza-se que as variáveis meteorológicas explicam parte significativa da variabilidade espaço-temporal das concentrações de NO_x e CO em Brasília e Goiânia, ainda que estimadas indiretamente por sensoriamento remoto.

O objetivo central do presente estudo foi analisar observacionalmente a qualidade do ar em duas cidades localizadas na região do Cerrado Central (Brasília e Goiânia), que são consideradas as duas maiores capitais do Centro-Oeste brasileiro. O uso do satélite Sentinel-5P é a ferramenta de investigação mais moderna do mundo para examinar proporções de poluentes atmosféricos, sobretudo o NO_x e CO (Bodah et al., 2022). Este estudo se atentou a incluir os parâmetros meteorológicos associados às concentrações de monóxido de carbono (CO) e óxidos de nitrogênio (NO_x), usando de dados de NO₂ como proxy para NO_x durante os meses de seca. A abordagem temporal e espacial auxiliou na discussão com o uso do sensoriamento remoto, a partir dos dados do TROPOMI, do Sentinel-5P, disponíveis em Google Earth Engine (GEE), combinados com aplicações estatísticas de regressão de penalização Ridge e Lasso, a fim de considerar as variáveis meteorológicas mais importantes para a concentração equivalente dos poluentes nas duas cidades do Centro-Oeste.

METODOLOGIA

Área de estudo

As capitais estudadas, Brasília (Distrito Federal) e Goiânia (Figura 1), localizam-se na região Centro-Oeste do Brasil. A escolha dessas áreas se justifica pela relevância regional que apresentam no contexto urbano e agrícola, pela crescente influência que exercem e pelo número ainda reduzido de pesquisas realizadas em comparação às cidades da região Sudeste do país.




Figura 1: Localização das duas áreas de estudo no Centro-Oeste do Brasil, Brasília e Goiânia.

Elaboração: os autores.

O Cerrado se encontra sob domínio climático das massas de ar equatoriais e tropicais. A predominância de atuação da Massa Tropical Atlântica (mTa) possui relevância durante todo o ano, já a Massa Equatorial Continental (mEc) tem maior atuação durante o período de primavera e verão (Silva et al., 2008). Além das massas de ar, Nimer (1989) aponta que esta região também recebe influência do sistema de correntes perturbadas de oeste (Linhas de Instabilidade Tropical) e eventualmente do sistema de correntes perturbadas de sul (Frente Polar Atlântica e Anticiclone Polar).

Novais (2020) em sua classificação climática define que o Planalto Central, onde se localiza Brasília, apresenta clima do tipo tropical semiúmido central. As características dessa área são a reduzida evapotranspiração potencial devido à altimetria que supera os 1.000 metros. Contudo, ambas as cidades da área de estudo estão sob influência do tipo climático megatérmico ou tropical úmido (A), com o subtipo clima de savana, com inverno seco e chuvas máximas de verão (w), pela classificação de Köppen.

Dados

Os dados de dióxido de nitrogênio (NO₂) e monóxido de carbono (CO) foram obtidos por meio da plataforma Google Earth Engine (GEE). A API (Application Programming Interface) do GEE disponibiliza o acesso a dados de SR de diversos sensores para extração de informações após a aplicação de filtros personalizados pelos próprios usuários, utilizando linguagens como JavaScript e Python (Armani et al., 2020). Essa plataforma facilita o processamento de grandes volumes de dados geoespaciais ao disponibilizar recursos de computação de alto desempenho, eliminando a necessidade de ferramentas externas de TI (Gorelick et al., 2017).

O Data Catalog do GEE abriga milhões de conjuntos de dados de acesso público, incluindo séries completas e atualizadas de imagens dos satélites Landsat-4, -5, -7 e -8, MODIS, Sentinel-1, -2, -3 e -5P, além de diversas bases voltadas para estudos atmosféricos, meteorológicos e geoespaciais (Zhao et al., 2021). Entre os programas de observação, destaca-se o Sentinel-5P, equipado com o espectrômetro Tropospheric Monitoring Instrument (TROPOMI), cujos sensores operam em

infravermelho de comprimento de onda próximo e curto, permitindo a detecção de diferentes poluentes atmosféricos, incluindo NO₂ e CO (Veefkind et al., 2012). Os dados do TROPOMI para esses poluentes estão disponíveis no Data Catalog do GEE (<https://developers.google.com/earth-engine/datasets>), com atividades operacionais desde junho de 2018.

O período analisado através dos dados disponíveis no dataset do Google Earth Engine foi de maio a setembro, entre 2019 e 2024, correspondente à estação seca das cidades de Brasília e Goiânia. Enquanto os mapas de distribuição espacial foram elaborados a partir de médias mensais, a análise estatística (testes de estacionariedade, defasagens e modelos de regressão) foi conduzida com séries diárias de NO₂, CO e as variáveis meteorológicas.

Para a coluna de densidade do dióxido de nitrogênio (NO₂) e o monóxido de carbono (CO) do TROPOMI, na plataforma GEE, são expressas em mol/m² para distribuição do gás na coluna vertical atmosférica. Resolução CONAMA nº 506/2024 (Brasil, 2024), para seus trabalhos de poluição do ar, recomenda o uso da unidade de medida micrograma por metro cúbico (µg/m³) para o caso do NO₂ (Equação 1), e a conversão em partes por milhão (ppm) do CO (Equação 2). As equações se aproximam da proposta de Savenets (2021) ao estudar CO, NO₂ e SO₂ na Ucrânia.

$$C_{NO_2}(\mu g/m^3) = \frac{n_{NO_2} \times M_{NO_2} \times 10^6}{h} \quad (1)$$

Em que:

C_{NO_2} (µg/m³): concentração de NO₂ em microgramas por metro cúbico.

n_{NO_2} (mol/m²) densidade da coluna de NO₂ em mol por metro quadrado.

M_{NO_2} = 46.0055g/mol: massa molar do NO₂.

H (m): altura efetiva da coluna em metros (estimativas atmosféricas da altura da coluna troposférica).

10⁶: fator de conversão de gramas para microgramas.

Para a conversão para partes por milhão (ppm) para o CO, utilizou-se a seguinte equação:

$$ppm = \frac{\mu g/m^3 \times 24.45}{Massa\ molar\ (g/mol)} \quad (2)$$

Em que:

µg/m³ é a concentração de CO em microgramas por metro cúbico.

Massa molar do CO, que é de 28.01 g/mol.

24.45 é o volume molar de um gás ideal para condições CTP (Condições Normais de Temperatura e Pressão), definidas por 25° C (vinte e cinco graus celsius) e a pressão de 760 mm (milímetros) de coluna de mercúrio (1.013,2 milibares).

Conforme descrito por Sun (2022), a densidade de coluna vertical de NO₂ representa a integral da concentração equivalente ao longo da troposfera, sendo a principal métrica obtida por sensores satelitais como, neste caso, TROPOMI. Ao se aplicar 11 mil metros para altitude (h), têm-se a quantificação total dos poluentes até a tropopausa assumindo-se homogeneidade e condições de CNTP, mas sem considerar a distribuição vertical e a variabilidade espacial a nível do solo da camada limite planetária (CLP). Para tanto, se complementaria com dados *in situ*.

A aplicação do sensoriamento remoto é uma alternativa viável, pois geralmente apresenta uma alta correlação com medições obtidas por estações de monitoramento fixo regulatório, como o método de inferência a partir de dados satelitais foi demonstrado por Lamsal et al. (2008) e validado por Chipura et al. (2024). O método de conversão da coluna observada satelital para unidade de concentração foi utilizada e correlacionada com sucesso por Freitas et al., (2026) para o NO₂ e formaldeído (HCHO).

Os dados meteorológicos das médias – incluindo temperatura, umidade relativa, velocidade do vento (VV) e pressão atmosférica – foram obtidos da rede do Instituto Nacional de Meteorologia (INMET), com medições em estações de superfície para o período de estudo (maio a setembro, de 2019 a 2024). As séries temporais foram extraídas das estações meteorológicas automáticas de Brasília (Lat. -15.78, Long. -47.92) e Goiânia (Lat. -16.64, Long. -49.22). Os dados foram organizados para correlacionar as variáveis meteorológicas independentes com as variáveis dependentes dos poluentes atmosféricos.

ANÁLISE ESTATÍSTICA

As variáveis consideradas foram NO₂, CO para os gases extraídos do sensor TROPOMI e as variáveis meteorológicas do INMET, a citar variáveis de precipitação (PREC.), temperatura (TEMP.), umidade relativa (UR), velocidade do vento (VV m/s) e pressão em hectopascals (hPa) (PRES.). Para a análise estatística, optou-se por Ridge e Lasso, em vez de regressão linear simples (OLS), devido à colinearidade esperada entre variáveis meteorológicas e suas defasagens temporais. Para tanto, esta aplicação foi precedida por um tratamento prévio dos dados. Após a criação das variáveis defasadas e remoção das observações incompletas resultantes, o conjunto final totalizou 916 observações diárias por cidade, divididas em aproximadamente 733 para treino e 183 para teste.

Os modelos finais de Ridge e Lasso foram ajustados com as variáveis em suas escalas originais. Assim, a magnitude dos coeficientes reflete tanto a força da relação quanto a unidade de cada variável, não devendo ser interpretada como medida direta de importância relativa entre preditores de naturezas distintas.

Observou-se que o CO apresentou uma alta assimetria (skewness), caracterizada por caudas longas à direita na distribuição dos dados. Para lidar com essa assimetria, a transformação logarítmica foi adotada como alternativa, uma vez que esse método é frequentemente

utilizado em estudos onde as variáveis não seguem uma distribuição normal. Essa abordagem permite suavizar a distribuição dos dados e reduzir a influência de outliers, embora não resulte em uma normalidade perfeita (Zwiener et al., 2014).

Aplicou-se o Teste de Dickey-Fuller Aumentado (ADF) para avaliar a estacionariedade das séries temporais. Este teste verifica se os dados gravitam em torno de uma média constante. Ao rejeitar a hipótese nula (H_0), conclui-se que a série é estacionária, condição necessária para muitos modelos de regressão em séries temporais (Brownlee, 2024).

Para capturar efeitos defasados, foram atribuídos lags de 1 e 2 dias às variáveis meteorológicas independentes (TEMP., UR, PREC., VV (m/s), PRES.) em relação às variáveis dependentes (CO e NO₂). Essa abordagem diferencia este estudo ao incorporar a resposta temporal dos poluentes às condições meteorológicas ao longo do dia atual e dois dias anteriores para os lags. Posteriormente, os dados foram divididos em conjuntos de treino (80%) e teste (20%).

Cabe destacar que a divisão entre treino e teste foi realizada de forma aleatória, sem preservar a ordem cronológica das observações. Como as variáveis preditoras incluem defasagens temporais (lags de 1 e 2 dias), essa escolha pode gerar alguma proximidade estatística entre os conjuntos de treino e teste, favorecendo de forma otimista as métricas de desempenho (MSE e R²). Essa limitação afeta a magnitude exata dessas métricas, mas não compromete a estimação dos coeficientes de Ridge e Lasso nem a interpretação das relações entre as variáveis meteorológicas e as concentrações de poluentes, uma vez que os coeficientes são ajustados unicamente sobre o conjunto de treino.

Após o pré-processamento, os dados são usados em modelos de regressão para prever um valor y com base em variáveis explicativas z . O conjunto de treinamento é formado por pares (z_i, y_i) , onde z_i são os preditores e y_i , a variável resposta. Esses preditores podem ser transformados em um novo vetor de características x_i , e o modelo resulta de uma combinação linear dessas características, com um intercepto μ e coeficientes β que determinam a influência de cada preditor (Owen, 2007). A multicolinearidade, comum em regressões múltiplas, pode dificultar a interpretação dos resultados. Para mitigar esse problema, são utilizadas técnicas como coeficientes de correlação e pesos beta (Safi et al., 2023).

A regressão Ridge foi escolhida por sua eficiência em lidar com conjuntos de dados com efeito de alta dimensionalidade e colinearidade. Para isso, se incorpora um termo de penalização à função de custo da regressão linear. Essa abordagem reduz a variância do estimador ao aplicar uma penalização quadrática nos coeficientes, que tendem a ser valores próximos de zero, mas sem serem anulados (Masini et al., 2023). O parâmetro de ajuste λ controla o grau de penalização e deve ser maior que zero. Quanto maior o valor de λ , menores são os coeficientes, já que o termo λ multiplica o quadrado desses parâmetros (Hoerl & Kennard, 1970).



Por outro lado, a regressão Lasso, proposta por Tibshirani (1996), utiliza uma penalização que pode reduzir coeficientes irrelevantes a zero, simplificando o modelo e favorecendo a seleção de variáveis. No entanto, esse método pode sofrer com erros amostrais, comprometendo sua precisão. Comparado ao Ridge, o Lasso é mais eficaz na seleção de variáveis, mas o Ridge é mais estável em cenários onde variáveis irrelevantes são penalizadas sem serem completamente eliminadas. Ambos os métodos oferecem abordagens complementares para lidar com problemas de alta dimensionalidade e colinearidade em análises preditivas.







Para garantir a robustez dos modelos, utilizou-se a técnica de validação cruzada com 5 folds, conforme Melkumova e Shatskikh (2017). O conjunto de dados foi dividido aleatoriamente em 5 blocos de comprimento igual, onde, a cada iteração, um bloco foi utilizado como conjunto de teste (20%), enquanto os 4 blocos restantes formaram o conjunto de treino (80%). Para cada valor de α calcularam-se os coeficientes de regressão e a soma dos quadrados dos resíduos (RSS) em cada fold (Equação 6). A média desses valores foi então utilizada para calcular o erro quadrático médio.







O valor de α que resultou no menor MSE médio durante a validação cruzada foi selecionado como o melhor parâmetro de controle de regularização. Para otimizar ainda mais os modelos Ridge e Lasso, aplicou-se um ajuste dos melhores hiperparâmetros, garantindo o melhor desempenho com o menor MSE e o maior R^2 possível. O objetivo é que os modelos generalizem bem para novos dados, fornecendo previsões precisas e confiáveis. Além disso, otimiza a seleção dos melhores parâmetros de regularização e controle da penalização, resultando em modelos otimizados para a previsão das concentrações de NO_2 e CO.

RESULTADOS

Os filtros aplicados no código do GEE para intervalos mensais, contendo a média de NO_2 e CO do sensor TROPOMI entre 2019 e 2024 tiveram como resultado output mapas temporais e espaciais da concentração desses poluentes em Brasília e Goiânia. Goiânia apresentou maiores concentrações de ambos os poluentes comparada a Brasília. A concentração de NO_2 foi mais homogênea na parte central da capital, com picos em agosto e setembro. A porção Oeste de Brasília exibiu características semelhantes, mas em menor concentração. As concentrações de NO_2 ficaram em áreas urbanas, enquanto áreas menos populosas e áreas mais remotas, especialmente a Leste de ambas as cidades, que mostraram menores concentrações conforme (Figura 2).










Figura 2: Mapas de concentração mensais de NO₂ e CO nos meses de inverno para Brasília (esquerdo) e Goiânia (direito). Fonte: dados do TROPOMI. Elaboração: os autores.

Também foi realizado o *plot* de gráficos da série temporal dessas concentrações médias mensais (Figura 3). As maiores concentrações para cada ano mostram um padrão temporal para um aumento em setembro, com aumento gradual de ambos os poluentes até esse último mês. A cidade de Goiânia, tanto para o NO₂ como para o CO, teve maior concentração absoluta. 2021 foi o ano que apresentou maior concentração de NO₂, e 2024 para o CO, com tendências para valores mais elevados de NO₂ para este ano.




Figura 3: Série temporal entre os meses de maio a setembro de 2019 e 2024 para Brasília e Goiânia para concentração de CO e NO₂. Fonte: dados do TROPOMI. Elaboração: os autores.

Brasília e Goiânia apresentaram diferenças nas variáveis meteorológicas e na concentração de poluentes atmosféricos na estatística dos dados. Em Goiânia (Tabela 1), as médias de NO₂ (0,28 ppm) e CO (64,18 ppm) são ligeiramente superiores às de Brasília (Tabela 2) (0,24 ppm e 59,51 ppm, respectivamente). Além disso, Goiânia registra uma temperatura média mais alta (23,04°C contra 20,82°C em Brasília) e uma pressão atmosférica significativamente maior (934,24 hPa contra 889,28 hPa). Por outro lado, Brasília apresenta maior umidade relativa do ar (54,16% contra 52,00%) e maior precipitação média (0,37 mm comparado com 0,21 mm, de Goiânia). A velocidade média do vento em Brasília (2,27 m/s) é mais do que o dobro da registrada em Goiânia (1,05 m/s). Os valores máximos de vento em Brasília (4,40 m/s) também superam os de Goiânia (3,10 m/s), o que reforça essa tendência, apesar de ambas na estação terem uma média de VV baixa.

O Teste de Dickey-Fuller Aumentado (ADF), aplicado para avaliar a estacionariedade...dos dados avaliou que para a cidade de Goiânia, os resultados do teste ADF para NO₂ foram um ADF Statistic -3.9112 e um p-value de 0.00195, enquanto para CO foram um ADF Statistic de -3.9303 e um p-value de 0.00182. Esses valores indicam que ambas as séries temporais são estacionárias, uma vez que os p-values são menores que 0.05, permitindo a rejeição da hipótese nula (H0) de não-estacionariedade.

Para a cidade de Brasília, os resultados do teste ADF para NO₂ foram um ADF Statistic de -5.2900 e um p-value de 5.74e-06, enquanto para CO foram um ADF Statistic de -4.1100 e um p-value de 0.00093. Assim como em Goiânia, os valores negativos dos ADF Statistic e os p-values

menores que 0.05 indicam que as séries temporais de NO₂ e CO em Brasília também são estacionárias, o que permitiu os estudos de regressão.

PAR.	NO ₂	CO	PREC	PRES.	TEMP.	UR	VV (m/s)
mean	0.28	64.18	0.21	934.24	23.04	52.00	1.05
std	0.06	19.33	1.39	2.04	2.65	12.44	0.46
min	0.12	40.32	0.00	928.50	11.80	20.60	0.20
25%	0.23	52.45	0.00	933.00	21.30	42.97	0.70
50%	0.27	58.07	0.00	934.30	22.60	53.50	0.950
75%	0.32	67.24	0.00	935.60	24.60	61.50	1.30
max	0.58	187.44	20.00	939.90	29.90	84.90	3.10

Tabela 1: Estatística de variáveis para a cidade de Goiânia entre os meses de inverno de 2019 e 2024.

Fonte: Dados do INMET e TROPOMI.

PAR.	NO ₂	CO	PREC	PRES.	TEMP.	UR	VV (m/s)
mean	0.24	59.51	0.37	889.28	20.82	54.16	2.27
std	0.07	17.21	2.70	1.72	2.35	13.65	0.64
min	0.14	40.18	0.00	884.70	11.40	19.30	0.90
25%	0.19	49.33	0.00	888.10	19.20	44.92	1.80
50%	0.22	53.80	0.00	889.20	20.30	55.15	2.20
75%	0.27	62.52	0.00	890.40	22.20	64.37	2.70
max	0.70	173.88	39.20	894.30	27.50	88.70	4.40

Tabela 2: Estatística de variáveis para a cidade de Brasília entre os meses de inverno de 2019 e 2024.

Fonte: Dados do INMET e TROPOMI.

O uso do *GridSearchCV* minimizou o Erro Quadrático Médio (MSE) e identificou a combinação ideal de parâmetros para os modelos Ridge e Lasso nas cidades de Goiânia e Brasília. As melhores combinações de hiperparâmetros determinadas foram: Regressão Ridge (NO₂): {'alpha': 100.0}; Regressão Ridge (CO): {'alpha': 100.0}; Regressão Lasso (NO₂): {'alpha': 0.01}; Regressão Lasso (CO): {'alpha': 0.01}. As mesmas combinações de parâmetros de regularização observadas em Goiânia foram também identificadas para Brasília. Estas configurações permitiram que os modelos apresentassem o desempenho ideal dentro dos 5 folds estabelecidos no processo de validação cruzada, garantindo robustez e precisão nas previsões.

A análise dos modelos de regressão Ridge e Lasso com lags nas cidades de Goiânia e Brasília mostrou que ambos foram eficazes na previsão das concentrações de NO₂ e CO (Tabela 3). O modelo Ridge apresentou um desempenho superior, com um MSE de 0.0024 e R² Score de 0.4989 para NO₂ em Goiânia. Para Brasília o MSE foi de 0.0022 e R² Score de 0.5648. Ridge sugere que a regularização L2 capturou melhor os padrões dos dados. Para CO, a transformação logarítmica foi aplicada, melhorando significativamente o modelo. No geral ambos os modelos tiveram desempenhos próximos, com Ridge alcançando MSE de 0.0285 e R² Score de 0.6319 em Goiânia, e MSE de 0.0292 e R² Score de 0.6193 em Brasília, ligeiramente superior ao Lasso para a variável CO.

Cidades	Goiânia		Brasília	
Regressões com lags	Melhor MSE	Melhor R ² Score	Melhor MSE	Melhor R ² Score
Ridge (lags) – NO ₂	0.0024	0.4989	0.0022	0.5648
Ridge (lags) - CO	0.0285	0.6319	0.0292	0.6193
Lasso (lags) - NO ₂	0.0027	0.4433	0.0022	0.5496
Lasso (lags) - CO	0.0294	0.6204	0.0300	0.6086

Tabela 3: Resultados de melhor desempenho dos modelos de Regressão Ridge e Lasso, considerando os lags para poluentes de NO₂ e CO para as cidades de Goiânia e Brasília.

Elaboração: os autores.

Ao extrair os coeficientes de ambos os modelos aplicados com o objetivo de avaliar o impacto de cada variável independente sobre a variável dependente dos poluentes estudados, incluindo os lags, foi possível visualizar a escala temporal e os atrasos de resposta diária do NO₂ e CO (Tabela 4). Esta análise identificou como diferentes fatores meteorológicos influenciam a concentração dos poluentes ao longo do tempo e os padrões de resposta com base nos atrasos introduzidos pelas variáveis com defasagem.

	Brasília				Goiânia			
Variáveis	Ridge CO	Lasso CO	Ridge NO ₂	Lasso NO ₂	Ridge CO	Lasso CO	Ridge NO ₂	Lasso NO ₂
Temp.	0.023519	0.026071	0.003240	0.003670	0.02282 0	0.02136 2	- 0.001147	0.00000 0
Temp_lag 1	0.007446	0.000716	0.001543	0.000000	0.00531 9	0.00468 3	0.000611	0.00000 0
Temp_lag 2	0.026056	0.031744	0.003127	0.003787	0.01336 5	0.01669 8	0.002785	0.00260 2
UR	0.000689	0.000254	-0.001661	-0.001386	0.00130 1	0.00031 8	- 0.001630	- 0.00143 6
UR_lag1	- 0.000308	- 0.000087	0.000438	-0.000000	- 0.00115 9	- 0.00055 8	- 0.000372	- 0.00013 6
UR_lag2	- 0.003071	- 0.003017	-0.001205	-0.001037	- 0.00429 9	- 0.00406 0	- 0.000866	- 0.00096 4
Prec.	0.004162	0.003387	0.001809	0.000885	0.00745 3	0.00422 3	0.002198	0.00000 0

Prec_lag 1	0.004297	0.003639	0.001440	0.001024	0.01007 4	0.00632 7	0.003858	0.00000 0
Prec_lag 2	0.006257	0.005480	0.001200	0.000203	0.01463 3	0.01181 4	0.002918	0.00000 0
VV (m/s)	0.008704	0.000000	-0.002761	-0.000000	0.01667 0	0.00000 0	- 0.007800	- 0.00000 0
VV_lag1	- 0.005380	0.000000	0.001311	-0.000000	0.01632 7	0.00000 0	0.000898	- 0.00000 0
VV_lag2	0.021032	0.000000	0.007339	0.000000	0.00208 2	0.00000 0	0.002115	0.00000 0
Pres.	- 0.003410	- 0.000000	-0.005392	-0.005570	0.00020 0	- 0.00000 0	- 0.005705	- 0.00582 2
Pres_lag 1	- 0.006758	- 0.007065	-0.002175	-0.000000	- 0.00591 9	- 0.00000 0	- 0.001862	- 0.00167 0
Pres_lag 2	- 0.011793	- 0.007213	-0.001549	-0.000000	- 0.02509 6	- 0.02713 9	- 0.001638	- 0.00000 0

Tabela 4: Coeficientes das componentes meteorológicas com lags para suas variáveis dependentes NO₂ e CO como resultado da Regressão Ridge e Lasso para as cidades de Brasília e Goiânia.

Elaboração: os autores.

A umidade relativa (UR) apresentou coeficientes negativos para NO₂ (Brasília: -0,001661; Goiânia: -0,001630), porém positivos para CO (Brasília: 0,000689; Goiânia: 0,001301), sugerindo relações de sinais opostos entre os dois poluentes. A temperatura mostrou associação positiva com CO em ambas as cidades (Brasília: 0,023519; Temp_lag2: 0,026056; Goiânia: 0,022820; Temp_lag2: 0,013365) e com NO₂ em Brasília (0,003240); em Goiânia, contudo, o coeficiente de NO₂ foi levemente negativo (-0,001147), indicando que essa relação pode variar entre as duas cidades. A velocidade do vento (VV) apresentou coeficientes positivos para CO (Brasília: 0,008704; Goiânia: 0,016670), mas negativos para NO₂ em ambas as cidades (Brasília: -0,002761; Goiânia: -0,007800). Já a pressão atmosférica apresentou relação negativa com CO em Brasília (-0,003410), porém positiva em Goiânia (0,000200), e negativa com NO₂ em Brasília (-0,005392), evidenciando que o efeito da pressão sobre as concentrações de poluentes não é uniforme entre as duas cidades.

DISCUSSÃO

O monóxido de carbono (CO), teve grandes variações espaciais e temporais em ambas as cidades, não seguindo um padrão linear em sua distribuição. Isso representa que as regiões

estudadas podem ter múltiplas fontes, além da queima de combustível fóssil em área urbana. O NO_2 , cuja principal emissão tem também essa origem, esteve concentrado em áreas urbanas. A porção norte do recorte do Distrito Federal se apresentou com maior concentração de CO durante todos os meses, além da porção oeste. Durante o inverno, para a capital federal, houve variações de concentrações mais representativas na porção leste, podendo representar uso e ocupação do solo, indicando que o CO não se restringe apenas nas áreas urbanas.

Para Goiânia, a porção centro-oeste e porção Sul apresentaram elevada poluição de forma mais dispersa. A porção centro-sul apresenta maior urbanização, e a porção leste, com menor concentração, embora durante os meses tivesse acontecido uma maior variação. As áreas urbanas de Goiânia são mais distribuídas no território, o que dificulta a identificação por fontes de emissão para o CO. Outro aspecto a ser citado é a capacidade de dispersão do CO, que acaba por ter um tempo de vida mais prolongado do que o NO_2 .

Em relação aos poluentes, o CO apresentou variações no período estudado, conforme ilustrado nos mapas de concentração. O NO_2 foi mais localizado, apesar de picos consideráveis. Dados do Terrabrasilis (2024), do Instituto Nacional de Pesquisas Espaciais (INPE) indicam ser o mês de setembro com maior número de queimadas, sendo 2024 o ano com mais queimadas desde 2012 no bioma Cerrado. A queima de biomassa é crucial para a química da atmosfera, incorporando gases traço como CO e NO_x , principalmente devido às queimadas nos trópicos durante a estação seca, causadas por atividades humanas (Crutzen et al., 1979). Valadão et al. (2022) também indicaram o período de queimadas com os valores extremos mais altos de NO_2 e de múltiplas fontes representativas deste poluente também em áreas remotas.

A comparação dos modelos Ridge e Lasso, para regressão por penalização, considerou as variáveis meteorológicas importantes e suas respectivas importâncias através dos coeficientes. O Ridge apresentou uma ligeira vantagem, provavelmente porque o modelo não desconsidera variáveis menos importantes, o que pode indicar correlações entre variáveis que não são necessariamente determinadas por colinearidade comum em estudos de natureza ambiental. O Lasso, por outro lado, capturou as variáveis mais relevantes, mas devido à penalização L1, pode não ter capturado todas as variações. No caso do CO, pode ter reduzido a eficiência do modelo, embora ele tivesse apresentado um bom resultado e explicado a variabilidade dos dados. Por isso, se utilizou no CO a transformação logarítmica, o que melhorou muito o modelo.

Além disso, os fatores de concentração de poluentes podem estar associados a diferenças na topografia e nos padrões climáticos das duas cidades e que afetam a dispersão. Além disso, a emissão veicular não segue significativa sazonalidade, diferente do uso do solo, como a queimada de florestas e a queima de resíduos agrícolas que já seguem um padrão sazonal (Jaffe et al., 1997). Houve picos representativos e aumento significativo no mês de setembro, indicando que fontes emissoras também precisariam ser consideradas no modelo ao se estudar a concentração em outros estudos.

O coeficiente associado à precipitação foi uma das variáveis meteorológicas menos relevantes para os dados de poluentes estudados nessas cidades. A falta de chuva é geralmente associada a temperaturas mais altas e maiores concentrações de poluentes no ar e a umidade está geralmente associada às ocasiões de chuva (Dominick et al., 2012). Contudo, os resultados aqui apresentados mostraram que, devido aos períodos de seca prolongada em Brasília e as

médias de chuvas com máximo de 39,20mm e de casos isolados, a precipitação não teve muita influência na concentração de poluentes. Essa perspectiva é corroborada por Lim et al. (2013), que destacam que a redução eficiente de poluentes ocorre apenas em eventos de precipitação acima de 100 mm.

A umidade relativa (UR) demonstrou um papel relevante na redução das concentrações de NO₂, embora tenha apresentado relação positiva com o CO, sugerindo mecanismos distintos de interação entre esse elemento meteorológico e cada poluente. Os resultados sugerem que a umidade relativa desempenha um papel crucial na diminuição das concentrações de poluentes, reforçando estudos anteriores, como o de González et al. (2019). Elminir et al. (2005) também observaram um ligeiro aumento nas concentrações de NO₂ em condições de baixa umidade relativa, devido à redução da reação entre NO₂ e radicais OH. Isso indica que a umidade relativa influencia não apenas a dispersão dos poluentes, mas também as reações químicas na atmosfera, embora de forma indireta.

As condições ambientais da estação seca no Cerrado reforçam a relevância da umidade relativa (UR) como variável explicativa fundamental para a variabilidade do NO₂ como observado na Tabela 4. A complexidade da resposta atmosférica, observada por meio da defasagem temporal (*lags*), revela processos distintos: o coeficiente negativo em lag 0 reflete o efeito imediato da umidade na remoção de poluentes por deposição úmida (Souza et al., 2022). O sinal positivo em lag 1 pode sugerir a competição entre as emissões locais e o envelhecimento fotoquímico de compostos transportados (Campos da Rocha et al., 2023). O retorno ao sinal negativo em lag 2 decorre de uma escala temporal mais ampla, de predomínio da umidade como um agente redutor da carga poluidora na atmosfera regional (Souza et al., 2022).

A temperatura mostrou influência positiva nas concentrações de CO em ambas as cidades, e também no NO₂ em Brasília; em Goiânia, contudo, o efeito da temperatura sobre o NO₂ foi discretamente negativo, o que pode refletir dinâmicas locais específicas de dispersão ou fontes emisoras, o que merece uma investigação futura. Esse fenômeno é particularmente comum nas condições climáticas de céu limpo e estáveis. Entretanto, a velocidade do vento também tem um papel importante nesse processo. A relação entre o vento e a concentração de poluentes depende das condições locais e da concentração original dos poluentes (Luo et al., 2011). Elminir et al. (2005) destacam que a velocidade e a direção do vento, por si só, não explicam totalmente a variabilidade nas concentrações de poluentes, devendo considerar também a umidade atmosférica, como aqui foi discutido como uma variável importante na variação da concentração.

Além disso, a baixa velocidade do vento observada nas duas cidades pode ter um efeito reduzido na dispersão. Liu et al. (2020) observaram que, em contextos altamente poluídos, como na China, a velocidade do vento tem um efeito mais pronunciado na redução das concentrações de NO₂, o que não foi verificado neste estudo, possivelmente devido às diferenças nas condições climáticas e de concentração de poluentes entre as regiões. A baixa velocidade média do vento nas cidades estudadas (< 3 m/s) pode limitar a capacidade de dispersão, permitindo que pequenos incrementos na velocidade do vento coincidam com a chegada de poluentes acumulados em áreas adjacentes. Contudo, o presente estudo não contemplou direção do vento para verificar a origem dos poluentes para modelagem em dispersão.

Um aumento na pressão atmosférica esteve associado à redução nas concentrações de CO e NO₂ em Brasília; em Goiânia, contudo, a relação com o CO foi discretamente positiva, o que reforça a necessidade de interpretar a pressão em conjunto com o contexto sinótico local, como a estabilidade atmosférica, altura da camada limite planetária e padrões de circulação, em vez de como uma variável isolada. Entretanto, apesar dessas características serem indicadas de forma direta, o uso de variáveis meteorológicas individuais apresenta um dilema diferente, isso porque as concentrações de poluição do ar respondem à totalidade de todas as variáveis meteorológicas em vez dos elementos meteorológicos individuais (Lam; Cheng, 1998). Ao se analisar as variáveis como isoladas, é necessário também analisar seu contexto climático e ambiental.

A pressão atmosférica em condições de alta pressão leva a uma maior subsidência na troposfera superior, impulsionando para a superfície os poluentes NO₂ e CO na camada de inversão térmica (Baumbach; Vogt, 2003), e isso pode retirar os poluentes em alta altitude que são considerados em métodos com SR, como o sensor TROPOMI. Baixa velocidade média do vento (< 3 m/s) em ambas as cidades e dominância de alta pressão atmosférica no inverno sofrem apenas algumas variações, o que pode estar associado à entrada de massas de ar pós-frontais mais limpas e a ventilação que dispersa o material acumulado (Rozante et al., 2017). Ao medir a coluna total da atmosfera, o TROPOMI pode não capturar totalmente o aprisionamento de poluentes próximos à superfície durante inversões térmicas. Portanto, seria necessário utilizar dados complementares de medições *in situ* para corroborar essa hipótese.

Outro fator mais possível é a radiação solar, que pode influenciar as reações fotoquímicas na atmosfera. Um céu sem nebulosidade aumenta os valores de [OX] e cria condições propícias para reações fotoquímicas mais intensas (Mazzeo et al., 2005). No caso do NO₂, em condições de baixa concentração de NO_x, a radiação solar pode levar à fotodissociação do NO₂ e a reações com radicais livres, reduzindo suas concentrações. No entanto, em cenários com excesso de NO_x, a química atmosférica se altera, e a redução do NO₂ pode não ocorrer da mesma forma (Kleinman, 1991). Apesar da grande variação térmica observada no estudo, a maior temperatura média tropical pode ter contribuído para a queda nas concentrações médias de NO₂ devido às reações químicas, considerando a alta reatividade desse poluente.

CONSIDERAÇÕES FINAIS

O foco do estudo foi a análise da concentração de poluentes atmosféricos CO e NO₂ nas cidades de Brasília e Goiânia durante os meses de maio a setembro, considerando a estação do inverno e de favorável ocorrência de subsidência atmosférica desses gases e suas reações nesta estação, levando em consideração as variáveis meteorológicas *in situ*. Para trabalhos futuros se considera também incluir períodos transitórios e de intersazonalidade, contemplando as demais estações do ano para ampliar o recorte da análise e permitindo comparações. Embora os poluentes emissores em áreas urbanas mantenham uma certa estacionariedade, eles podem apresentar picos de concentração, tanto devido às fontes de emissões quanto às mudanças bruscas em variáveis meteorológicas não capturadas pelos modelos e análise de regressão usados.

A falta de dados intradiários e de medições *in situ*, que permitem uma análise mais local e próxima da camada de fricção abaixo da camada limite planetária (CLP), impediu uma comparação direta com os dados *top-down* do sensoriamento remoto TROPOMI. Entretanto, o estudo apresentou essa alternativa viável de maior escala espacial, mostrando correlações de regressão moderadas com as variáveis meteorológicas e abrindo discussões para futuros estudos. Apesar de ser uma ferramenta crucial, a construção de uma rede de monitoramento de poluição atmosférica para as duas cidades e para o Cerrado, em geral, poderia melhorar a precisão dos modelos e captar novos detalhes que não são identificados nas escalas analisadas.

Além disso, os modelos de regressão Ridge e Lasso se mostraram úteis na identificação de coeficientes para avaliar seus papéis isolados e em conjunto. O modelo Lasso foi mais eficaz na seleção das variáveis mais importantes, embora apresentasse uma leve desvantagem em relação ao modelo Ridge. Destaca-se ainda que os coeficientes foram estimados sobre variáveis em unidades originais, sem padronização prévia, o que preserva a interpretabilidade em unidades físicas, mas limita comparações diretas de magnitude entre preditores de naturezas distintas. Estudos futuros poderão empregar coeficientes padronizados (β) para essa finalidade.

Foi observado que o aumento da pressão atmosférica está associado à redução das concentrações de NO₂ e CO, enquanto a velocidade do vento e a precipitação apresentaram coeficientes de menor magnitude. Esses resultados sugerem a necessidade de avaliar a situação meteorológica específica da estação. Aqui se reforça a importância de uma análise multi-estacional e da implementação de uma rede de monitoramento contínuo para obter dados mais granulares e precisos. Isso inclui considerar outros poluentes atmosféricos, como SO₂ e O₃, altamente poluidores, reativos e participantes da química atmosférica em áreas urbanas e naturais, como por exemplo, nas queimadas.

Submetido em 24 de fevereiro de 2025.

Aceito para publicação em 24 de agosto de 2026

REFERÊNCIAS

- AMANI, M.; GHORBANIAN, A.; AHMADI, S. A.; KAKOOEI, M.; MOGHIMI, A.; MIRMAZLOUMI, S. M.; BRISCO, B. Google Earth Engine cloud computing platform for remote sensing big data applications: a comprehensive review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 5326-5350, 2020.
- BAUMBACH, G.; VOGT, U. Influence of inversion layers on the distribution of air pollutants in urban areas. **Water, Air, & Soil Pollution: Focus**, v. 3, p. 65-76, 2003.
- BODAH, Brian William et al. Sentinel-5P TROPOMI satellite application for NO₂ and CO studies aiming at environmental valuation. *Journal of Cleaner Production*, v. 357, p. 131960, 2022.
- BORSODORFF, T.; AAN DE BRUGH, J.; HU, H.; ABEN, I.; HASEKAMP, O.; LANDGRAF, J. Measuring carbon monoxide with TROPOMI: First results and a comparison with ECMWF-IFS analysis data. **Geophysical Research Letters**, v. 45, n. 6, p. 2826-2832, 2018.
- BRASIL. Conselho Nacional do Meio Ambiente (CONAMA). Resolução nº 491, de 19 de novembro de 2018. Dispõe sobre padrões de qualidade do ar. **Diário Oficial da União: seção 1**, Brasília, DF, 21 nov. 2018. Disponível em: https://www.in.gov.br/web/guest/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/51058895/do1-2018-11-21-resolucao-n-491-de-19-de-novembro-de-2018-51058603. Acesso em: 27 dez. 2024.
- BRASIL. Conselho Nacional do Meio Ambiente (CONAMA). Resolução nº 506, de 5 de julho de 2024. Estabelece padrões nacionais de qualidade do ar e fornece diretrizes para sua aplicação. **Diário Oficial da União: seção 1**, Brasília, DF, 9 jul. 2024, p. 133. Disponível em: https://conama.mma.gov.br/index.php?id=827&option=com_sisconama&task=arquivo.download. Acesso em: 27 dez. 2024.
- BROWNLEE, J. **How to Check if Time Series Data is Stationary with Python**. Disponível em: <https://machinelearningmastery.com/time-series-data-stationarypython/>. Acesso em: 24 jan. 2024.
- CAMPOS DA ROCHA, Franciele O. et al. Concentration levels of atmospheric contaminants in Brazilian cities measured by passive sampling. *Urban Climate*, v. 52, p. 101739, 2023.
- CHIPURA, Orlando Eduardo et al. Spatiotemporal Analysis of Air Pollution by NO₂ in Urban and Rural Areas of Brazil Using Google Earth Engine and R. *Theoretical and Applied Engineering*, v. 8, n. 4, 2024.
- CASTELHANO, Francisco Jablinski et al. The impact of long-term weather changes on air quality in Brazil. *Atmospheric Environment*, v. 283, p. 119182, 2022.
- CRUTZEN, P. J.; HEIDT, L. E.; KRASNEC, J. P.; POLLOCK, W. H.; SEILER, W. Biomass burning as a source of atmospheric gases CO, H₂, N₂O, NO, CH₃Cl e COS. **Nature**, v. 282, n. 5736, p. 253-256, 1979.

DOMINICK, D.; JUAHIR, H.; LATIF, M. T.; ZAIN, S. M.; ARIS, A. Z. Spatial assessment of air quality patterns in Malaysia using multivariate analysis. **Atmospheric Environment**, v. 60, p. 172-181, 2012.

ELMINIR, H. K. Dependence of urban air pollutants on meteorology. **Science of the Total Environment**, v. 350, n. 1-3, p. 225-237, 2005.

GONZÁLEZ-ENRIQUE, J.; TURIAS, I. J.; RUIZ-AGUILAR, J. J.; MOSCOSO-LÓPEZ, J. A.; FRANCO, L. Spatial and meteorological relevance in NO₂ estimations: a case study in the Bay of Algeciras (Spain). **Stochastic Environmental Research and Risk Assessment**, v. 33, n. 3, p. 801-815, 2019.

FREITAS, Arthur Dias et al. Investigating Ozone Formation Regimes in the Metropolitan Area of São Paulo Using Five Years of TROPOMI HCHO/NO₂ Ratios. *Remote Sensing*, v. 18, n. 10, p. 1603, 2026.

GORELICK, N.; HANCHER, M.; DIXON, M., ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18-27, 2017.

HALDER, B. et al. Machine learning-based country-level annual air pollutants exploration using Sentinel-5P and Google Earth Engine. *Scientific Reports*, Nature Publishing Group UK London, v. 13, n. 1, p. 7968, 2023.

HOERL, A. E.; KENNARD, R. W. Ridge regression: biased estimation for nonorthogonal problems. **Technometrics**, v. 12, n. 1, p. 55-67, 1970.

INPE. **Estatísticas de queimadas no Brasil**. Disponível em: https://terrabrasilis.dpi.inpe.br/queimadas/situacao-atual/estatisticas/estatisticas_estados/. Acesso em: 03 fev. 2025.

JAFFE, D.; MAHURA, A.; KELLEY, J.; ATKINS, J.; NOVELLI, P. C.; MERRILL, J. Impact of Asian emissions on the remote North Pacific atmosphere: Interpretation of CO data from Shemya, Guam, Midway e Mauna Loa. *Journal of Geophysical Research: Atmospheres*, v. 102, n. D23, p. 28627-28635, 1997.

KLEINMAN, L. I. Seasonal dependence of boundary layer peroxide concentration: The low and high NO_x regimes. *Journal of Geophysical Research: Atmospheres*, v. 96, n. D11, p. 20721-20733, 1991.

LAM, K. C.; CHENG, S. A synoptic climatological approach to forecast concentrations of sulfur dioxide and nitrogen oxides in Hong Kong. **Environmental Pollution**, v. 101, n. 2, p. 183-191, 1998.

LAMSAL, L. N.; MARTIN, R. V.; VAN DONKELAAR, A.; STEINBACHER, M.; CELARIER, E. A.; BUCSELA, E.; PINTO, J. P. Ground-level nitrogen dioxide concentrations inferred from the satellite-borne Ozone Monitoring Instrument. *Journal of Geophysical Research: Atmospheres*, v. 113, n. D16, 2008.

LIM, D.; LEE, T. J.; KIM, D. S. Development and Validation Test of Effective Wet Scavenging Contribution Regression Models Using Long-term Air Monitoring and Weather Database. *Korean Society for Atmospheric Environment*, v. 29, p. 297-306, 2013.

LIU, Y.; ZHOU, Y.; LU, J. Exploring the relationship between air pollution and meteorological conditions in China under environmental governance. *Scientific Reports*, v. 10, n. 1, p. 14518, 2020.

LUO, Z.; LI, Y.; WEI-ZHEN, L. Effects of urban ventilation patterns on the carbon monoxide concentration in a high-rise mega city. *International Journal of Ventilation*, v. 10, n. 3, p. 239-250, 2011.

MASINI, R. P.; MEDEIROS, M. C.; MENDES, E. F. Machine learning advances for time series forecasting. *Journal of Economic Surveys*, v. 37, n. 1, p. 76-111, 2023.

MAZZEO, N. A.; VENEGAS, L. E.; CHOREN, H. Analysis of NO, NO₂, O₃ and NO_x concentrations measured at a green area of Buenos Aires City during wintertime. *Atmospheric Environment*, v. 39, n. 17, p. 3055-3068, 2005.

MELKUMOVA, L. E.; SHATSKIYKH, S. Y. Comparing Ridge and LASSO estimators for data analysis. *Procedia Engineering*, v. 201, p. 746-755, 2017.

MOLINA, M. J.; MOLINA, L. T. Megacities and atmospheric pollution. *Journal of the Air & Waste Management Association*, v. 54, n. 6, p. 644-680, 2004.

NIMER, E. A circulação atmosférica e as condições de tempo como fundamento para compreensão do clima. In: *Geografia do Brasil: Região Centro-Oeste*, Rio de Janeiro, v. 1, p. 23-34, 1989.

NOVAIS, G. T. Classificação Climática aplicada ao Estado de Goiás e ao Distrito Federal, Brasil. *Boletim Goiano de Geografia*, v. 40, n. 1, p. 1-29, 2020.

OKE, T. R. Boundary layer climates. *Routledge*, 2002.

OWEN, A. B. A robust hybrid of lasso and ridge regression. *Contemporary Mathematics*, v. 443, n. 7, p. 59-72, 2007.

RANI, B.; SINGH, U.; CHUHAN, A. K.; SHARMA, D.; MAHESHWARI, R. Photochemical smog pollution and its mitigation measures. *Journal of Advanced Scientific Research*, v. 2, n. 4, p. 28-33, 2011.

- REZENDE, A. V.; VALE, A. D.; SANQUETTA, C. R.; FIGUEIREDO FILHO, A.; FELFILI, J. M. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado sensu stricto em Brasília, DF. **Scientia Forestalis**, v. 71, n. 2, p. 65-73, 2006.
- ROZANTE, José Roberto et al. Variations of carbon monoxide concentrations in the megacity of São Paulo from 2000 to 2015 in different time scales. *Atmosphere*, v. 8, n. 5, p. 81, 2017.
- SAFI, S.; ALSHERYANI, M.; ALRASHDI, M.; SULEIMAN, R.; AWWAD, D.; ABDALLA, Z. Optimizing linear regression models with lasso and ridge regression: a study on UAE financial behavior during COVID-19. **Migration Letters**, v. 20, n. 6, p. 139-153, 2023.
- SARRAT, C.; LEMONSU, A.; MASSON, V.; GUÉDALIA, D. Impact of urban heat island on regional atmospheric pollution. **Atmospheric Environment**, v. 40, n. 10, p. 1743-1758, 2006.
- SAVENETS, M. Air pollution in Ukraine: a view from the Sentinel-5P satellite. **IDŐJÁRÁS – Quarterly Journal of the Hungarian Meteorological Service**, v. 125, n. 2, p. 271-290, 2021.
- SEINFELD, J. H.; PANDIS, S. N. Atmospheric chemistry and physics: from air pollution to climate change. **John Wiley & Sons**, 2016.
- SILVA, F. A. M.; ASSAD, E. D.; STEINKE, E. T.; MÜLLER, A. G. Clima do bioma Cerrado. In: ALBUQUERQUE, A. C. S. (Ed.). Agricultura tropical: quatro décadas de inovações tecnológicas, institucionais e políticas. **Brasília: Embrapa**, p. 93-148, 2008.
- SOUZA, Amaury de et al. Spatio-temporal variations of tropospheric nitrogen dioxide in South Mato Grosso based on remote sensing by satellite. *Meteorology and Atmospheric Physics*, v. 134, n. 1, p. 19, 2022.
- SUN, Kang. Derivation of emissions from satellite-observed column amounts and its application to TROPOMI NO₂ and CO observations. **Geophysical Research Letters**, v. 49, n. 23, p. e2022GL101102, 2022.
- SILVA, C.M.S. **A expansão agrícola e suas relações com as concentrações atmosféricas do nitrogênio reativo sobre o cerrado brasileiro**. Tese (Doutorado em Geografia) - Universidade de Brasília, Brasília, 2023.
- SOMVANSI, S. S.; VASHISHT, A.; CHANDRA, U.; KAUSHIK, G. Delhi air pollution modeling using remote sensing techniques. **Handbook of Environmental Materials Management**, p. 1-27, 2019.
- TIBSHIRANI, R. Regression shrinkage and selection via the lasso. **Journal of the Royal Statistical Society Series B: Statistical Methodology**, v. 58, n. 1, p. 267-288, 1996.
- TRINH, T. T.; TRINH, T. T.; LE, T. T.; NGUYEN, T. D. H.; TU, B. M. Temperature inversion and air pollution relationship, and its effects on human health in Hanoi City, Vietnam. **Environmental Geochemistry and Health**, v. 41, n. 2, p. 929-937, 2019.
- UEPA. National air pollutant emission trends 1990-1996. **EPA-454/R-98-008**, 1998.

VALADÃO, L. V.; TAVARES, A. S.; SOLLACI, C. B.; CUNHA, C. S.; MPONGO, F. B. Z.; BAPTISTA, G. M. de M. Avaliação dos efeitos do isolamento social nos níveis de NO₂, durante a pandemia de COVID-19, em áreas urbanas de Brasília, Anápolis e Goiânia, por meio de sensoria-mento remoto. **Revista Brasileira de Cartografia**, v. 74, n. 3, 2022.

VEEFKIND, J. P.; ABEN, I.; MCMULLAN, K.; FÖRSTER, H.; DE VRIES, J.; OTTER, G.; LEVELT, P. F. TROPOMI on the ESA Sentinel-5 Precursor: A GMES mission for global observa-tions of the atmospheric composition for climate, air quality and ozone layer applications. **Remote Sensing of Environment**, v. 120, p. 70-83, 2012.

WANG, C.; WANG, T.; WANG, P.; RAKITIN, V. Comparison and Validation of TROPOMI and OMI NO₂ Observations over China. **Atmosphere**, v. 11, n. 6, p. 636, 2020.

ZARATE, Erika. **Understanding the origins and fate of air pollution in Bogota, Colombia**. 2007. Tese (Doutorado em Ciências) – École Polytechnique Fédérale de Lausanne, Lausanne, 2007.

ZHAO, Q.; YU, L.; LI, X.; PENG, D.; ZHANG, Y.; GONG, P. Progress and trends in the applica-tion of Google Earth and Google Earth Engine. **Remote Sensing**, v. 13, n. 18, p. 3778, 2021.

ZWIENER, I.; FRISCH, B.; BINDER, H. Transforming RNA-Seq data to improve the performance of prognostic gene signatures. **PLoS One**, v. 9, n. 1, e85150, 2014.