

TARCISIO FERREIRA MARTINS

Relação Entre a Resposta Espectral da Vegetação e os Poluentes Atmosféricos em Unidades de Conservação na Região Metropolitana de São Paulo

Dissertação apresentada ao Instituto de Pesquisas Ambientais, da Secretaria de Meio Ambiente, Infraestrutura e Logística, como parte dos requisitos exigidos para a obtenção do título de MESTRE em BIODIVERSIDADE VEGETAL E MEIO AMBIENTE, na Área de Concentração de Plantas Vasculares em Análises Ambientais.

SÃO PAULO

2025

TARCISIO FERREIRA MARTINS

Relação Entre a Resposta Espectral da Vegetação e os Poluentes Atmosféricos em Unidades de Conservação na Região Metropolitana de São Paulo

Dissertação apresentada ao Instituto de Pesquisas Ambientais, da Secretaria de Meio Ambiente, Infraestrutura e Logística, como parte dos requisitos exigidos para a obtenção do título de MESTRE em BIODIVERSIDADE VEGETAL E MEIO AMBIENTE, na Área de Concentração de Plantas Vasculares em Análises Ambientais.

SÃO PAULO

2025

TARCISIO FERREIRA MARTINS

Relação Entre a Resposta Espectral da Vegetação e os Poluentes Atmosféricos em Unidades de Conservação na Região Metropolitana de São Paulo

Dissertação apresentada ao Instituto de Pesquisas Ambientais, da Secretaria de Meio Ambiente, Infraestrutura e Logística, como parte dos requisitos exigidos para a obtenção do título de MESTRE em BIODIVERSIDADE VEGETAL E MEIO AMBIENTE, na Área de Concentração de Plantas Vasculares em Análises Ambientais.

ORIENTADORA: DRA. SILVIA RIBEIRO DE SOUZA

BANCA EXAMINADORA

Dra. Silvia Ribeiro de Souza - Orientadora (Instituto de Pesquisas Ambientais)

Dra. Bruna Lüdtke Paim - Titular (Universidade de São Paulo)

Dra. Adalgiza Fornaro - Titular (Universidade de São Paulo)

Ficha Catalográfica elaborada pelo **Serviço de Biblioteca, Mapotecas, Museus, Acervos Arquivísticos e Iconográficos do Instituto de Pesquisas Ambientais**

M379r

MARTINS, Tarcisio Ferreira

Relação entre a resposta espectral da vegetação e os poluentes atmosféricos em unidades de conservação na região metropolitana de São Paulo. / Tarcisio Ferreira Martins. São Paulo, 2025.

106p.

Orientador : Silvia Ribeiro de Souza

Dissertação (Mestrado) -- Instituto de Pesquisas Ambientais da Secretaria de Meio Ambiente, Infraestrutura e Logística, 2025.

1.Floresta Urbana 2.Veículo Aéreo não Tripulado 3. Índices de vegetação .

I. Autor II. Título.

CDU: 504.06

*A câmera hoje passeia contigo pela Mata Atlântica
No que resta — ainda esplendor — da Mata Atlântica
Apesar do declínio histórico, do massacre
De formas latejantes de viço e beleza.
Mostra o que ficou e amanhã — quem sabe?
(Carlos Drummond de Andrade)*

Agradecimentos

À possibilidade de realização deste trabalho no Programa de Pós-Graduação do Instituto de Pesquisas Ambientais – Unidade Jardim Botânico, agradeço ao esforço coletivo para a sobrevivência de uma instituição, legatária da memória do Instituto de Botânica de São Paulo, atualizada no trabalho e dedicação de seus pesquisadores, professores e funcionários.

À CAPES, pela bolsa de Mestrado; à verba PROAP, pelo custeio de despesas na participação em congresso; e à FAPESP, pelo financiamento do projeto no qual este trabalho está inserido.

Agradeço à Dra. Silvia Ribeiro de Souza, pela orientação, dedicação e direcionamento durante a realização da pesquisa e na concepção do projeto. À Dra. Kátia Mazzei, pelo suporte na operação dos equipamentos e programas utilizados, e pela parceria desde meu estágio.

Aos membros da banca de defesa, Dra. Bruna Lüdtke Paim e Dra. Adalgiza Fornaro, pelo rigor na leitura da dissertação e pelas contribuições que estão incorporadas a esta versão final; à última também agradeço o auxílio na obtenção das autorizações de acesso e coleta dos dados no âmbito desta pesquisa.

Aos membros da banca de qualificação, Dr. Eduardo Pereira Cabral Gomes, em memória, pelas contribuições ao trabalho, pela ajuda na delimitação das parcelas, nas coletas de campo e por me apresentar a floresta do PEFI; e ao Dr. Renato Miazaki de Toledo, por oferecer seu conhecimento geoespacial e estatístico, pelas contribuições na banca de qualificação, e pelo entusiasmo em colaborar com este trabalho.

Ao Dr. Eduardo Luis Martins Catharino, ao Luciano dos Santos Santa Bárbara e à Dra. Fernanda Mendes de Rezende, envolvidos na delimitação das parcelas e coleta dos dados estruturais das áreas estudadas, pelo auxílio e disposição em compartilhar conhecimento.

Aos motoristas Anderson Faria Irmão e Alfredo Miguel da Paz, sem os quais não seria possível realizar esta pesquisa em diferentes áreas da Região Metropolitana de São Paulo.

Aos amigos do Labiap, fundamentais na realização deste trabalho: Dra. Fernanda Anselmo Moreira, Ms. Alex do Nascimento e Dr. Bruno Ruiz Brandão; pela troca, apoio nas coletas de campo e contribuições nas prévias das defesas. Também aos amigos da Ecologia, Darah, Léo, Matheus, Ruan, Carol, Renata, Letícia e Ganz, que tornaram meus dias mais leves e me ajudaram a comemorar as pequenas vitórias.

Agradeço aos meus pais, pelo apoio. À Hannah Itzicovitch Leventhal, pelo companheirismo, carinho e incentivo em parte desta jornada.

APRESENTAÇÃO

Este trabalho tem como objetivo a utilização de sensoriamento remoto multispectral, por veículo aéreo não tripulado (VANT), para a avaliação do impacto do ozônio troposférico (O_3) na saúde da vegetação de três fragmentos florestais localizados na Região Metropolitana de São Paulo (RMSP). Para atingir este objetivo, a dissertação foi segmentada em três capítulos.

O **Capítulo I** consiste em uma introdução teórica sobre a temática abordada. Partindo de um breve histórico do desenvolvimento do sensoriamento remoto, contextualiza-se sua aplicação na atualidade e sua importância para o monitoramento de fragmentos florestais urbanos da Mata Atlântica, apresentando a técnica como alternativa para o monitoramento ambiental de florestas urbanas expostas a níveis fitotóxicos de ozônio troposférico.

No **Capítulo II**, os dados de sensoriamento remoto por VANT, produzidos durante um ano, na forma de índices de vegetação, são relacionados às concentrações acumuladas de O_3 da RMSP. É feita uma caracterização da poluição por O_3 na RMSP, durante o período de estudo, e proposto um modelo para avaliar quanto da variação dos índices de vegetação podem ser explicadas pelos níveis de O_3 .

Já no **Capítulo III**, é aplicada a modelagem desenvolvida no capítulo anterior, segmentando os dados para três níveis de biomassa florestal, para avaliar como diferentes níveis de biomassa respondem à poluição por O_3 . Para isso são apresentados os dados de biomassa medidos em campo, a classificação proposta, e a relação de cada nível de biomassa com O_3 .

Na **Conclusão Geral** é feita uma breve avaliação, articulando as conclusões dos capítulos II e III e apontando para perspectivas futuras no estudo do impacto do O_3 na vegetação, por meio de sensoriamento remoto multispectral.

RESUMO

O sensoriamento remoto multiespectral é uma alternativa para a coleta de informações sobre perturbações na saúde de florestas tropicais ao captar dados de reflectância foliar das árvores, ligada à concentração de moléculas envolvidas na fase fotoquímica da fotossíntese. Os dados de reflectância são incorporados em razões matemáticas para gerarem índices de vegetação, utilizados em estudos de monitoramento ambiental. Na Região Metropolitana de São Paulo (RMSP), a vegetação pertencente ao bioma Mata Atlântica restringe-se à fragmentos florestais. Atualmente essas áreas estão expostas à poluentes fitotóxicos, especialmente o ozônio troposférico (O_3), que na RMSP, permanece acima dos níveis indicados como seguros à vegetação pela CETESB, desde o início de seu monitoramento. O presente trabalho tem como objetivo avaliar como a poluição por O_3 se relaciona com os índices de vegetação obtidos por sensoriamento remoto multispectral. Foram coletadas imagens durante 12 meses, por voos automatizados com o equipamento *DJI Phantom 4 Multispectral + GNSS DJI RTK-2*, sobre parcelas permanentes em três fragmentos de floresta nativa na RMSP. As imagens foram processadas em ortomosaicos retificados para cinco comprimentos de onda entre $450\text{ nm} \pm 16$ e $840\text{ nm} \pm 26\text{ nm}$, dos quais produziram-se índices de vegetação a partir de razões matemáticas. A avaliação da poluição por O_3 nas áreas de estudo foi feita utilizando-se dos dados de 17 estações de monitoramento da CETESB, aplicando metodologia *Accumulated Ozone exposure over a Threshold of 40 ppb* (AOT40) para o semestre, predizendo os valores de ozônio da área de estudo através da técnica de Krigagem. Foi aplicado um modelo linear de efeitos mistos para testar relação entre os índices de vegetação e AOT40, e foram selecionados os índices com maior performance no modelo. Para avaliar a sensibilidade ao O_3 de diferentes níveis de biomassa, o modelo foi aplicado para cada classe de biomassa: baixa, média e alta. Os índices *Green Leaf Index* (GLI), *Triangular Chlorophyll Index* (TCI) e *Plant Senescence Reflectance Index* (PSRI), apresentaram melhor performance para avaliar a relação da vegetação com a AOT40. No verão foi encontrada uma relação negativa significativa ($p < 0,05$) entre AOT40 e GLI e TCI, indicando que nesta estação, o O_3 pode comprometer a capacidade fotossintética da vegetação nativa. Para as estações outono e inverno, houve relação positiva entre AOT40 para os dois índices, mostrando que na estação seca o aumento da concentração de O_3 relaciona-se com o aumento da saúde da floresta. O PSRI, marcador de senescência foliar, captou um efeito positivo do O_3 sobre a senescência, no verão e um efeito negativo durante outono e inverno, mostrando a influência do O_3 no aumento da senescência foliar durante o período chuvoso. O GLI respondeu negativamente ao O_3 no verão e primavera, sobretudo em parcelas de alta biomassa, indicando maior absorção em árvores mais altas. A relação entre biomassa e índices de vegetação mostrou que o impacto do AOT40 foi mais evidente em áreas de biomassa média e alta, dos quais o GLI se mostrou um bom preditor. O TCI e o PSRI captaram impactos estruturais ligados à senescência, sendo o PSRI mais sensível em parcelas de baixa biomassa no verão. Já em outono e inverno, o GLI mostrou respostas positivas, sugerindo que há influência de outros fatores ambientais. Os resultados sugerem que a poluição por AOT40 no verão pode ser mais danosa à saúde da vegetação nativa, tornando a estação mais indicada para o monitoramento da sensibilidade ao poluente. Para as outras estações, são necessários estudos que avaliem como as variáveis abióticas como irradiação solar e composição do solo afetam a saúde da vegetação e a formação do O_3 . A diferença de sensibilidade dos diferentes tipos de biomassa, apontam para a necessidade de estudos que avaliem o efeito do O_3 sobre a Mata Atlântica considerando sua complexidade estrutural, ecológica e em como ocorrem diferentes respostas fisiológicas específicas.

Palavras-Chave: Floresta Urbana; Veículo Aéreo Não Tripulado; Índices de Vegetação.

ABSTRACT

Multispectral remote sensing is an alternative for collecting information on disturbances in the health of tropical forests by capturing leaf reflectance data from trees, which is linked to the concentration of molecules involved in the photochemical phase of photosynthesis. Reflectance data are incorporated into mathematical ratios to generate vegetation indices, which are used in environmental monitoring studies. In the Metropolitan Region of São Paulo (RMSP), vegetation belonging to the Atlantic Forest biome is restricted to forest fragments. Currently, these areas are exposed to phytotoxic pollutants, especially tropospheric ozone (O_3), which in the RMSP has remained above the levels indicated as safe for vegetation by CETESB since the beginning of its monitoring. This study aims to evaluate how O_3 pollution relates to vegetation indices obtained through multispectral remote sensing. Images were collected over a 12-month period using automated flights with a DJI Phantom 4 Multispectral + GNSS DJI RTK-2 over permanent plots in three fragments of native forest in the RMSP. The images were processed into rectified orthomosaics for five wavelength bands between $450\text{ nm} \pm 16$ and $840\text{ nm} \pm 26$ nm, from which vegetation indices were produced through mathematical ratios. O_3 pollution in the study areas was assessed using data from 17 CETESB monitoring stations, applying the Accumulated Ozone exposure over a Threshold of 40 ppb (AOT40) methodology for the semester, and predicting ozone values across the study area through kriging interpolation. A linear mixed-effects model was applied to test the relationship between vegetation indices and AOT40, and the indices with the best performance in the model were selected. To assess O_3 sensitivity at different biomass levels, the model was applied to each biomass class: low, medium, and high. The Green Leaf Index (GLI), Triangular Chlorophyll Index (TCI), and Plant Senescence Reflectance Index (PSRI) showed the best performance in evaluating the relationship between vegetation and AOT40. In summer, a significant negative relationship ($p < 0.05$) was found between AOT40 and GLI and TCI, indicating that during this season O_3 may compromise the photosynthetic capacity of native vegetation. For autumn and winter, a positive relationship was observed between AOT40 and the two indices, showing that in the dry season, increased O_3 concentrations are associated with improved forest health. The PSRI, a marker of leaf senescence, detected a positive effect of O_3 on senescence in summer and a negative effect during autumn and winter, highlighting the influence of O_3 in accelerating leaf senescence during the rainy season. GLI responded negatively to O_3 in summer and spring, especially in high-biomass plots, indicating greater absorption in taller trees. The relationship between biomass and vegetation indices showed that the impact of AOT40 was more evident in medium- and high-biomass areas, with GLI being a good predictor. TCI and PSRI captured structural impacts linked to senescence, with PSRI being more sensitive in low-biomass plots during summer. In autumn and winter, however, GLI showed positive responses, suggesting that other environmental factors may be influencing the results. The findings suggest that AOT40 pollution in summer may be more harmful to the health of native vegetation, making this season the most suitable for monitoring vegetation sensitivity to the pollutant. For the other seasons, further studies are needed to evaluate how abiotic variables such as solar radiation and soil composition affect vegetation health and O_3 formation. The difference in sensitivity across biomass types highlights the need for studies assessing the effects of O_3 on the Atlantic Forest while considering its structural and ecological complexity, as well as the occurrence of specific physiological responses.

Keywords: Urban Forest; Unmanned Aerial Vehicle; Vegetation Indices.

LISTA DE FIGURAS

Figura 1: Representação do espectro da radiação eletromagnética classificada por seu comprimento de onda (em metros).....	24
Figura 2: Representação da interação da radiação magnética com os materiais na superfície	24
Figura 3: Comportamento espectral de uma folha, no eixo x estão os comprimentos de onda da região do visível até o infravermelho, no eixo y a reflectância relativa à quantidade de energia refletida.....	26
Figura 4: Evolução do número de dias de ultrapassagens do padrão estadual de O ₃ e do número de estações de monitoramento. Retirado de CETESB, 2025	29
Figura 5: Mapa da localização das áreas de estudo dentro da Região Metropolitana da Cidade de São Paulo	43
Figura 6: Localização das estações de monitoramento de O ₃ troposférico da CETESB utilizadas no presente estudo	46
Figura 7: Variação da média mensal da temperatura nos três locais de estudo.....	49
Figura 8: Variação do acumulado da precipitação nos três locais de estudo	50
Figura 9: Boxplot da distribuição dos dados de concentração média horária O ₃ (em ppb) mensais, considerando as estações de monitoramento da CETESB utilizadas neste trabalho .	51
Figura 10: Boxplot da distribuição da média horária anual da concentração de O ₃ (em ppb), nas estações de monitoramento da CETESB utilizadas neste trabalho, no período de julho de 2023 a julho de 2024	52
Figura 11: Valores interpolados de AOT40 (ppb·h) nas três áreas de estudo em diferentes estações climáticas de 2023-2024. Linha pontilhada em vermelho simboliza o limite de exposição da concentração do poluente, determinado como seguro para a vegetação para o trimestre.....	53
Figura 12: Valores interpolados de AOT40 (ppb·h) nas três áreas de estudo em diferentes estações climáticas de 2023-2024. Linha pontilhada em vermelho simboliza o limite de exposição da concentração do poluente, determinado como seguro para a vegetação para o trimestre.....	54
Figura 13: Mapa de calor das Superfícies de tendência da AOT40 por trimestre onde: 1) inverno de 2023; 2) primavera de 2023; 3) verão de 2024; 4) outono de 2024.....	55
Figura 14: Boxplot da variação temporal das médias de GLI para subparcelas no PEFI entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.....	58
Figura 15: Boxplot da variação temporal das médias de TCI para subparcelas no PEFI entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.....	59
Figura 16: Boxplot da variação temporal das médias de PSRI para subparcelas no PEFI entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as	

transições entre as estações do ano.....	60
Figura 17: Boxplot da variação temporal das médias de NDVI para subparcelas no PEFI entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.....	61
Figura 18: Boxplot da variação temporal das médias de GLI para subparcelas na RFMG entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano	62
Figura 19: Boxplot da variação temporal das médias de TCI para subparcelas na RFMG entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.....	63
Figura 20: Boxplot da variação temporal das médias de PSRI para subparcelas na RFMG entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.....	64
Figura 21: Boxplot da variação temporal das médias de NDVI para subparcelas na RFMG entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.....	65
Figura 22: Boxplot da variação temporal das médias de GLI para subparcelas na RFIB entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano	66
Figura 23: Boxplot da variação temporal das médias de PSRI para subparcelas na RFIB entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.....	67
Figura 24: Boxplot da variação temporal das médias de TCI para subparcelas na RFIB entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano	68
Figura 25: Boxplot da variação temporal das médias NDVI para subparcelas na RFIB entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano	68
Figura 26: Curva de regressão representando a relação entre GLI e a AOT40 no Modelo Linear de Efeitos Mistos em diferentes estações do ano. As linhas contínuas representam as previsões dos modelos ajustados, enquanto as linhas tracejadas indicam os intervalos de confiança de 95% dessas previsões. Os pontos indicam os valores de AOT40 observados para as subparcelas amostradas	72
Figura 27: Curva de regressão representando a relação entre TCI e a AOT40 no Modelo Linear de Efeitos Mistos em diferentes estações do ano . As linhas contínuas representam as previsões dos modelos ajustados, enquanto as linhas tracejadas indicam os intervalos de confiança de 95% dessas previsões. Os pontos indicam os valores de AOT40 observados para as subparcelas amostradas	72
Figura 28: Curva de regressão representando a relação entre NDVI e a AOT40 no Modelo Linear de Efeitos Mistos em diferentes estações do ano. As linhas contínuas representam as previsões dos modelos ajustados, enquanto as linhas tracejadas indicam os intervalos de confiança de 95% dessas previsões. Os pontos indicam os valores de AOT40 observados para	

as subparcelas amostradas	73
Figura 29: - Curva de regressão representando a relação entre PSRI e a AOT40 no Modelo Linear de Efeitos Mistos em diferentes estações do ano. As linhas contínuas representam as predições dos modelos ajustados, enquanto as linhas tracejadas indicam os intervalos de confiança de 95% dessas predições. Os pontos indicam os valores de AOT40 observados para as subparcelas amostradas	74
Figura 30: - Boxplot da distribuição dos dados de biomassa por indivíduo arbóreo nas 3 áreas de estudo	92
Figura 31: Biomassa acumulada por parcela nas áreas de estudo	93
Figura 32: Curva de regressão representando a relação entre o AOT40 e GLI no Modelo Linear de Efeitos Mistos em diferentes estações do ano (1) primavera, (2) verão, (3) outono e (4) inverno.	96
Figura 33: Curva de regressão representando a relação entre o AOT40 e TCI no Modelo Linear de Efeitos Mistos em diferentes estações do ano (1) primavera, (2) verão, (3) outono e (4) inverno.	97
Figura 34: Curva de regressão representando a relação entre o AOT40 e GLI no Modelo Linear de Efeitos Mistos em diferentes estações do ano (1) primavera, (2) verão, (3) outono e (4) inverno.	98
Figura 35: Curva de regressão representando a relação entre o AOT40 e PSRI no Modelo Linear de Efeitos Mistos em diferentes estações do ano (1) primavera, (2) verão, (3) outono e (4) inverno.	99

LISTA DE TABELAS

Tabela 1: Lista dos índices de vegetação utilizados no estudo.....	45
Tabela 2: Divisão do período de coleta como forma de incorporar à sazonalidade ao GLMM	48
Tabela 3: Estatísticas descritivas para médias dos valores de índices de vegetação nas subparcelas estudadas	57
Tabela 4: Valores de coeficiente de determinação marginal, representando a variância explicada pelos efeitos fixos (R^2_m) e coeficiente de determinação condicional, representando a variância explicada pelos efeitos fixos e aleatórios combinados (R^2_c) obtidos a partir do modelo linear de efeitos mistos para a relação entre os índices de vegetação estudados e a AOT40.....	70
Tabela 5: Equações ajustadas do GLMM com a o valor-p para os índices GLI, PSRI, TCI e NDVI, nas estações estudadas durante o período.....	71
Tabela 6: Critério adotado para a classificação dos tipos de biomassa	90
Tabela 7: Biomassa total medida por área de estudo.....	91
Tabela 8: Gráfico da quantidade de parcelas por classe de biomassa nas áreas estudadas	93
Tabela 9: Valores de coeficiente de determinação marginal, representando a variância explicada pelos efeitos fixos (R^2_m) e coeficiente de determinação condicional, representando a variância explicada pelos efeitos fixos e aleatórios combinados (R^2_c) obtidos a partir do modelo linear de efeitos mistos para a relação entre os índices de vegetação estudados e a AOT40.....	95

LISTA DE ABREVIATURAS E SIGLAS

LiDAR	<i>Light Detection and Ranging</i>
RADAR	<i>Radio Detection and Ranging</i>
VANT	Veículo Aéreo Não Tripulado
RMSP	Região Metropolitana de São Paulo
CO	Monóxido de Carbono
HC	Hidrocarbonetos
NO _x	Óxidos de Nitrogênio
SO _x	Óxidos de Enxofre
MP	Material Particulado
VOCs	Compostos Orgânicos Voláteis
O ₃	Ozônio
NO ₃ ⁻	Nitrato
NO ₂ ⁻	Nitrito
CETESB	Companhia Ambiental do Estado de São Paulo
ATPI	Índice de Tolerância à Poluição Atmosférica
pH	Potencial Hidrogeniônico
OMS	Organização Mundial da Saúde
AOT40	<i>Accumulated Ozone exposure over a Threshold of 40 ppb</i>
NDVI	Normalized Difference Vegetation Index
PEFI	Parque Estadual Fontes do Ipiranga
RFIB	Reserva Florestal do Instituto de Biociências
RFMG	Reserva Florestal de Minas Gerais
USP	Universidade de São Paulo
GPS	<i>Global Positioning System</i>
GNSS	<i>Global Navigation Satellite System</i>
B	Azul
G	Verde
R	Vermelho

RE	Vermelho Limítrofe
Nir	Infravermelho Próximo
CCCI	<i>Canopy Chlorophyll Content Index</i>
CIG	<i>Chlorophyll Index Green</i>
CRE	<i>Chlorophyll Red-Edge</i>
CVI	<i>Chlorophyll Vegetation Index</i>
EVI	<i>Enhanced Vegetation Index</i>
GLI	<i>Green Leaf Index</i>
GNDVI	<i>Green Normalized Difference Vegetation Index</i>
LCI	<i>Leaf Chlorophyll Index</i>
MCARI	<i>Modified Chlorophyll Absorption in Reflectance Index</i>
NDRE	<i>Red-Edge Normalized Difference Vegetation Index</i>
PSRI	<i>Plant Senescence Reflectance Index</i>
RDVI	<i>Renormalized Difference Vegetation Index</i>
SIPI	<i>Structure Intensive Pigment Index</i>
SR NIR	<i>Nir Simple Ratio</i>
TCAR	<i>Transformed Chlorophyll Absorption Ratio</i>
TCI	<i>Triangular chlorophyll index</i>
TVI	<i>Triangular Vegetation Index</i>
WDRVI	<i>Wide Dynamic Range Vegetation Index</i>
QUALAR	Sistema de Informações de Qualidade do Ar
LMM	Modelo Linear Misto
DAP	Diâmetro na Altura do Peito

SUMÁRIO

CAPÍTULO I: INTRODUÇÃO GERAL E JUSTIFICATIVA.....	20
1. Introdução.....	21
2. Justificativa e Objetivos	31
Referências Bibliográficas	32
CAPÍTULO II: RELAÇÃO ENTRE OS ÍNDICES DE VEGETAÇÃO E POLUIÇÃO POR OZÔNIO TROPOSFÉRICO EM FRAGMENTOS FLORESTAIS DA REGIÃO METROPOLITANA DE SÃO PAULO.....	37
1 Introdução.....	38
2 Material e Métodos.....	41
2.1 Localização da área de estudo.....	41
2.2 Caracterização Climática	44
2.3 Coleta, processamento das imagens e produção dos Índices de Vegetação...	44
2.4 Caracterização da poluição por ozônio	45
2.5 Análise estatística	47
3. Resultados.....	49
3.1 Parâmetros Meteorológicos.....	49
3.2 Ozônio na RMSP	50
3.3 Interpolação dos valores de O ₃	52
3.4 Índices de Vegetação.....	56
3.5 Índices de Vegetação e AOT40	69
4. Discussão.....	74
4.1 Variação sazonal da estimativa média de Ozônio e AOT40 na RMSP	74
4.2 Índices de Vegetação nas Áreas de Estudo	76
4.3 Índices de Vegetação e Níveis de Ozônio.....	77
5. Conclusão	80
Referencias Bibliográficas	80

CAPÍTULO III: INFLUÊNCIA DOS NÍVEIS DE BIOMASSA DE FRAGMENTOS FLORESTAIS NA RESPOSTA DOS ÍNDICES DE VEGETAÇÃO À EXPOSIÇÃO AO OZÔNIO TROPOSFÉRICO	87
1. Introdução	88
2. Material e Métodos	90
2.1 Localização da área de estudo	90
2.2 Cálculo da Biomassa em Campo	90
3. Resultados.....	91
3.1 Biomassa nas áreas estudadas	91
3.2 Índices de Vegetação e Biomassa.....	94
4. Discussão	99
5. Conclusão	101
Referencias Bibliográficas	102
CONCLUSÃO GERAL	104

CAPÍTULO I: INTRODUÇÃO GERAL E JUSTIFICATIVA

1. Introdução

O sensoriamento remoto é uma tecnologia desenvolvida com o objetivo de coletar dados da superfície terrestre sem contato com o objeto de estudo (Fussell, Rundquist & Harrington, 1986). A terminologia criada por Evelyn L. Pruitt *et al.* (1960), utiliza a palavra sensoriamento como designação do processo de captação, armazenamento e análise da energia eletromagnética, emitida ou refletida pelos corpos na superfície terrestre, por meio de sensores (Cracknell, 2007), e por remoto, pressupõe-se uma atividade realizada à distância de sua área ou objeto de interesse, ou seja, os sensores são embarcados em plataformas de sensoriamento, que podem ser de nível terrestre, aéreo ou orbital. (Zhu, *et al.* 2018).

Os sensores podem ser divididos na forma com que obtêm a energia ou radiação eletromagnética da superfície terrestre. São considerados sensores passivos, os limitados à coleta da energia natural emitida ou refletida pelos alvos de estudo, como os sensores ópticos e térmicos. Os sensores ativos emitem energia própria e obtêm informações sobre a composição de um corpo comparando a diferença entre o sinal energético emitido pelo sensor, com o captado após a interação com a matéria e refletido para sua fonte, como exemplos temos as tecnologias LiDAR (*Light Detection and Ranging*), que consiste na análise da reflexão de um de um pulso a laser, emitido pelo sensor, para representação tridimensional da superfície de um objeto ou alvo de estudo; e RADAR (*Radio Detection and Ranging*), que também avalia a reflexão da energia emitida com os objetos de estudo, porém com ondas de rádio. A coleta dessas informações é viabilizada pelo acoplamento de sensores às plataformas de sensoriamento mais comumente os satélites, as aeronaves e, mais recentemente, os Veículos Aéreos Não Tripulados (VANTs) (Novo & Ponzoni, 2001).

Os primeiros sensores eram câmeras fotográficas e o sensoriamento remoto esteve prioritariamente ligado à fotografia aérea até 1957, ano de lançamento do primeiro satélite e surgimento do imageamento orbital (Liu, 2015). As primeiras fotografias aéreas datam do século XIX, em 1858 com câmeras conectadas a balões para fins topográficos na França, em 1880 acoplados a pombos e em 1900 à pipas (Elachi & Van Zyl, 2021). No século XX, durante conflitos da Primeira e Segunda Guerra Mundial, o surgimento de novas tecnologias implicaram no desenvolvimento do sensoriamento remoto na direção da produção extensiva de imagens sobre a superfície terrestre, com o uso de aviões como plataformas de sensoriamento, e com o surgimento de novos sensores, como o RADAR e o sensor de infravermelho, capaz de captar a energia refletida em comprimentos de onda relacionados a emissão de calor, tecnologia

que permitiu a distinção de alvos vegetacionais de soldados camuflados (Novo, 2010). Com o surgimento e lançamento dos satélites orbitais o sensoriamento remoto evoluiu para a escala global (Florenzano, 2007).

Outro marco para o sensoriamento remoto foi o desenvolvimento dos VANTs como plataforma de sensoriamento. A ausência de um tripulante torna esta técnica mais segura, possibilitando o monitoramento de áreas de difícil acesso e com maior flexibilidade operacional. Considera-se que o sensoriamento por VANT começou com o uso de balões e pipas para fotografar a superfície (Colomina & Molina, 2014). Durante a década de 1970 uma colaboração militar entre Estados Unidos da América e Israel, resultou no desenvolvimento de equipamentos menores e de baixo custo para reconhecimento de estruturas bélicas. Desde então a miniaturização dos componentes gerou aeronaves menores, mais leves, com a capacidade de obtenção de informações mais precisas, com maior resolução espacial, de forma automatizada, com autonomia sobre o momento de coleta e com baixo custo em comparação com o lançamento de satélites, e do aerolevanteamento (Longhitano, 2010).

Com o crescimento dos bancos de dados gerados pelo sensoriamento remoto ao longo do século XX, as aplicações da tecnologia expandiram-se significativamente, abrangendo diversas áreas do conhecimento e tornando o sensoriamento remoto uma ferramenta essencial para o monitoramento e análise de porções territoriais extensas, onde a coleta de dados de forma direta é dificultado por questões econômicas, amostrais, ambientais ou geográficas. Atualmente é indispensável para diversas atividades como o monitoramento das mudanças do uso e ocupação do solo, previsão de eventos climáticos, planejamento territorial, gerenciamento de recursos hídricos (Alves, Pereira & Florenzano, 2009).

Incorporado ao monitoramento ambiental, o sensoriamento remoto destaca-se pela capacidade de identificar padrões de transformação da paisagem ao longo do tempo, tornando-se uma ferramenta essencial para avaliar as mudanças nos ecossistemas naturais e a extensão das intervenções humanas neste processo (Jensen & Epiphany, 2009). Por meio da caracterização da área de ocorrência, da composição estrutural e da proximidade com potenciais fontes de impacto, o sensoriamento remoto possibilita a criação de métricas que avaliam a vulnerabilidade dos ecossistemas diante das mudanças climáticas e dos efeitos da antropização (Smith *et al.* 2014).

O uso de VANTs no sensoriamento remoto de ecossistemas naturais deriva do desenvolvimento da tecnologia na agricultura de precisão onde foi aplicado para gestão de

cultivos possibilitando a identificação de falhas nos plantios, correção de adubação, identificação de doenças e problemas de irrigação (Eltner, 2022). O uso de VANTs no monitoramento ambiental de ecossistemas nativos teve início na década de 2010 e possibilitou estudos sobre a biodiversidade e as mudanças do ecossistema ao longo do tempo, sendo uma ferramenta útil para a gestão e monitoramento áreas protegidas, gerando informações detalhadas, precisas, sem a necessidade de análises destrutivas (Raj *et al.* 2024).

Dentre os sensores aplicados ao estudo da vegetação por VANTs, podem ser citados os sensores fotográficos para a aerofotogrametria, que geram imagens sobre uma paisagem que podem ser utilizadas para a classificação das formações vegetacionais, e para a confecção de modelos 3D, através da tecnologia *Structure From Motion*, que conseguem avaliar parâmetros como altura e projeção de copa (Iglhaut *et al.*, 2019). A tecnologia LiDAR (*Light Detection and Ranging*) utiliza um sensor ativo que emite pulsos de laser em direção ao ambiente, esses pulsos interagem com os materiais ao longo do percurso, sendo refletidos de volta para o sensor, com base no tempo de retorno e na intensidade do sinal, o LiDAR fornece dados precisos sobre a estrutura da floresta. Essa tecnologia permite a obtenção de informações estruturais detalhadas da vegetação, substituindo as medidas dendrométricas feitas em campo como o diâmetro na altura do peito e altura das árvores (Ziegelmaier Neto, 2024). Por fim, há o sensoriamento remoto espectral, que capta a energia refletida em faixas específicas, ou bandas, do espectro eletromagnético. Pode ser feito com sensores multiespectrais, que coletam dados da reflectância de uma quantidade limitada de bandas, e hiperespectrais, que trabalham com dezenas a centenas de bandas espectrais (Mertikas, 2021).

O sensoriamento remoto espectral baseia-se na aquisição e análise da energia eletromagnética refletida por objetos, proveniente de um fluxo radiante emitido por uma fonte, para os ecossistemas naturais, o sol. Entre os anos de 1861 e 1862 James Clarck Maxwell, estudando a propagação da luz, descreveu a energia eletromagnética como uma oscilação ondulatória de campos elétricos e magnéticos no espaço, sem a necessidade de meio material para sua propagação. Segundo esse modelo, qualquer corpo com temperatura acima de 0 K emite energia eletromagnética, que pode ser representada como uma função de onda. A radiação eletromagnética é composta por ondas de diferentes comprimentos, formando um fluxo luminoso diversificado (Trintinalia, Orsini & Camargo, 2015). O conjunto desses comprimentos de onda é conhecido como espectro eletromagnético (Figura 1) . Cada material interage de maneira única com a radiação eletromagnética, seja transmitindo, absorvendo ou refletindo parte dessa radiação. Essas interações características permitem identificar objetos e

materiais com base em seus perfis espectrais específicos ao longo do espectro eletromagnético.




Figura 1 - Representação do espectro da radiação eletromagnética classificada por seu comprimento de onda (em metros).

A capacidade dos materiais de interagir com a radiação eletromagnética origina as propriedades físicas conhecidas como reflectância, absorbância e transmitância (Figura 2). Essas grandezas descrevem, respectivamente, a proporção da radiação incidente que é refletida, absorvida ou transmitida através da matéria por um determinado objeto. Essa interação característica dos materiais com a radiação eletromagnética ao longo do espectro eletromagnético é chamada de comportamento espectral (Sabins Jr & Ellis, 2020).




Figura 2 - Representação da interação da radiação magnética com os materiais na superfície.

O comportamento espectral da vegetação é determinado pelas estruturas teciduais envolvidas no processo de conversão da energia luminosa em energia química na fase

fotoquímica da fotossíntese (Ponzoni, Shimabukuro & Kuplich, 2015) (Figura 3). Assim, a folha é o principal órgão de interação das plantas com a radiação eletromagnética, quando exposta à radiação solar, que abrange o espectro desde o ultravioleta até o infravermelho distante, o tecido foliar apresenta diferentes perfis de absorção dependendo da anatomia foliar e da concentração de pigmentos fotossintetizantes, portanto, em uma folha saudável, espera-se uma absorção eficiente de energia nas regiões do espectro necessárias para a fotossíntese (Gitelson, Gritz & Merzlyak, 2003). Esse comportamento, resulta em baixa reflectância nas regiões do azul (0,43 μm para a Clorofila α e 0,45 μm para a Clorofila b) e do vermelho (0,66 μm para Clorofila α e 0,65 μm para a Clorofila b), pois a radiação neste comprimento de onda participa da transformação de energia eletromagnética para a energia química na molécula de clorofila e uma reflexão moderada na região do verde, determinada por pigmentos presentes nas folhas, em concentrações menores que as moléculas de clorofila, como o β -caroteno (aproximadamente 0,45 μm) (Gitelson & Merzlyak, 1998).

As plantas se adaptaram ao longo do tempo para regular a temperatura e evitar a produção excessiva de calor causada pela absorção de radiação na região do infravermelho próximo. O mesófilo, camada interna da folha, desempenha um papel crucial nesse processo devido à sua estrutura e função (Karabourniotis, Liakopoulos Bresta, & Nikolopoulos, 2021). Dividido entre parênquima paliádico, eficiente em captar radiação luminosa, com células ricas em cloroplastos; e parênquima lacunoso, onde há espaços intercelulares que facilitam o armazenamento de água e as trocas gasosas, esses espaços aumentam com a turgidez celular e são essenciais tanto para a fotossíntese quanto para a regulação térmica da planta (Slaton, Hunt & Smith, 2001). O espalhamento da radiação na região do infravermelho próximo (0,7 a 1,2 μm) reflete entre 40 e 60% da energia neste comprimento de onda e acontece nos espaços intercelulares do parênquima lacunoso, resultando em dissipação de calor que poderia levar à desnaturação de proteínas essenciais ao metabolismo celular, porém, este processo só ocorre adequadamente em folhas saudáveis, onde a disponibilidade de água promove maior turgidez celular, ampliando a interface célula-ar e favorecendo tanto as trocas gasosas e a reflexão da radiação no infravermelho próximo (Ponzoni & Disperati, 2001).




Figura 3 - Comportamento espectral de uma folha, no eixo x estão os comprimentos de onda da região do visível até o infravermelho, no eixo y a reflectância relativa à quantidade de energia refletida. Adaptado de Gitelson, Keydan & Merzlyak (2006).

Quando a resposta espectral de uma folha sadia é comparada com a de uma em processo de senescência, há diferenças entre os padrões de resposta dos alvos. As folhas danificadas ou senescentes apresentam um aumento da reflectância na região do visível, causada pela degradação das moléculas de clorofila, combinada a uma baixa reflectância na região do infravermelho próximo, onde o menor conteúdo relativo de água foliar causa a perda da pressão de turgor. Esses padrões podem caracterizar o *status* fisiológico de uma vegetação (Rossato *et al*, 2012).

O monitoramento da vegetação utilizando comprimentos de onda da região do infravermelho médio (entre 1,2 e 2,6 μm) tem diversas aplicações. Por exemplo, os picos de absorção da radiação relacionados à presença das moléculas de água (1,19 μm, 1,45 μm, 1,94 μm e 2,7 μm), estão relacionados com a reflectância nesta região do espectro eletromagnético, o que pode ser útil para determinar o teor relativo de água no tecido foliar. Assim, a análise da reflectância foliar da região do espectro eletromagnético, que inclui a luz visível e o

infravermelho, torna-se uma ferramenta importante para avaliar a capacidade fotossintetizante e a integridade do tecido foliar, tendo em vista que, um dos processos envolvidos na senescência das folhas é a desnaturação das moléculas pigmentares e diminuição da turgidez relativa no mesófilo (Morley, 2020).

O sensoriamento remoto espectral tem se mostrado uma ferramenta valiosa para auxiliar estudos sobre a integridade dos ecossistemas naturais, especialmente diante das atividades antrópicas às formações florestais (Pawar, 2014). No Brasil, com a progressiva mudança no uso e ocupação do solo pela ocupação humana há uma constante degradação dos ecossistemas naturais. Inicialmente, a ocupação humana ocorreu principalmente na região litorânea e proximidades, resultando em um impacto severo sobre o Bioma da Mata Atlântica, que perdeu 87,6% da sua área original. Atualmente, apenas 12,4 % dessa área remanescente é considerada a formação florestal maduras ou bem preservadas, distribuídas ao longo de 15% do território Brasileiro (Atlântica, 2016). No Estado de São Paulo , 32% do território original da Mata Atlântica ainda permanece, mas a maior parte dessa vegetação está restrita a pequenos fragmentos florestais (IPA, 2020).

A fragmentação dos ecossistemas ocorre quando barreiras limitam a biodiversidade endêmica, criando ilhas de vegetação natural. Isso resulta em menor variabilidade genética, extinção de espécies e maior vulnerabilidade do ecossistema (Giacon; Cardoso-Leite, 2022). No caso das florestas, essas áreas que se encontram ilhadas são chamadas de fragmentos florestais (Lindenmayer; Fischer, 2013). A existência de fragmentos florestais, garantem a preservação dos ecossistemas naturais, fornecendo benefícios na forma de serviços ecossistêmicos necessários para a manutenção da vida saudável, como a preservação de habitats, polinização, manutenção da integridade do solo, ciclagem de nutrientes (Livesley; McPherson; Calfapietra, 2016); e também para as comunidades humanas urbana, como a melhoria da qualidade do ar pela remoção dos poluentes (Martins *et al*, 2021. Cavanagh; Clemons, 2006. Tan, 2022), a dissipação das ilhas de calor e a atenuação das águas pluviais (Roy; Byrne; Pickering, 2012).

No Brasil, existem estudos que utilizam sensoriamento com VANTs para avaliar o impacto da pressão antrópica sobre os ecossistemas naturais. Através das respostas espectrais e dos parâmetros dendrométricos da vegetação, esses estudos indicam que a proximidade com fontes de estresse urbano pode prejudicar o pleno desenvolvimento dos ecossistemas florestais, especialmente na transição entre o Cerrado e a Mata Atlântica (Felix, *et al*. 2021). Tais impactos

comprometem a capacidade fotossintética das florestas e reduzem a biomassa das áreas em desenvolvimento, como observado em experimentos de restauração ecológica (Almeida, *et al.* 2019). Porém, esses trabalhos não avaliam uma fonte estressora particular, mas sim fontes de estresse difusas multicausais que, a partir da extrapolação dos dados gerados pelo sensoriamento remoto com VANTs geram informações sobre condições estruturais da floresta. Esses dados incluem a relação entre as respostas espectrais da vegetação e o conteúdo de clorofila e outros pigmentos, o índice de área foliar, a biomassa estimada e a capacidade de sequestro de carbono (Gupta; Pandey, 2021).

Ainda há uma escassez de estudos aprofundados sobre fragmentos florestais urbanos. Apesar de estarem sujeitos a pressões como compactação e impermeabilização do solo, introdução de espécies exóticas invasoras e poluição dos solos, águas e atmosfera, esses fragmentos atuam como importantes refúgios de biodiversidade endêmica (Carneiro *et al.*, 2023). Além disso, desempenham um papel essencial ao fornecer serviços ecossistêmicos, como regulação climática, filtragem de poluentes e manutenção da qualidade ambiental, contribuindo diretamente para a saúde e o bem-estar humano (Borges *et al.*, 2024; Kondrat, Aragaki & Gomes, 2020).

A poluição atmosférica é uma das principais consequências negativas acarretadas pela urbanização e pelo desenvolvimento industrial. O crescente aumento de poluentes no ar, refletem em danos diretos na vegetação e na saúde humana (de Brito; Silva; Fluminhan, 2019. Lelieveld *et al*, 2020. Khalid *et al*, 2019). De acordo com a legislação brasileira, por poluente atmosférico entende-se: “qualquer forma de matéria ou energia com intensidade e em quantidade, concentração, tempo ou características em desacordo com os níveis estabelecidos, e que tornem ou possam tornar o ar impróprio, nocivo ou ofensivo à saúde; inconveniente ao bem-estar público; danoso aos materiais, à fauna e flora; prejudicial à segurança, ao uso e gozo da propriedade e às atividades normais da comunidade.” (Brasil, 1990). A poluição atmosférica tem sido um problema em nível global e, no caso do ambiente urbano da Região Metropolitana de São Paulo (RMSP), após o deslocamento das indústrias para outras regiões do Estado, os veículos representam a maior fonte de produção de poluentes atmosféricos, sendo responsáveis por 95% das emissões de monóxidos de carbono (CO), 69% de hidrocarbonetos (HC), 60% de óxidos de nitrogênio (NO_x), 9% de óxidos de enxofre (SO_x) e 40% de material particulado (MP), e de acordo com o Relatório de emissões veiculares do Estado de São Paulo (CETESB, 2023), são um dos fatores responsáveis pela presença de substâncias como Compostos orgânicos voláteis (VOCs) e pelas concentrações de ozônio (O₃), acima das recomendadas pela

OMS. (Dias; Bales; Silva, 2015).

O O₃ troposférico é um gás poluente agressivo e a Organização Mundial da Saúde tem como padrão aceitável do gás na atmosfera uma concentração que não ultrapasse os 100 µg/m³, considerando a média móvel de 8 horas. Na RMSP, entre 2000 e 2023 os episódios de ultrapassagem da concentração de ozônio permanecem com uma média móvel que varia entre valores maiores que 120 µg/m³ e menores que 180 µg/m³ e, em 2023, houve um episódio onde a concentração de ozônio ultrapassou os valores de 200 µg/m³ para diversas estações de monitoramento. Entre os anos de 2015 a 2024, foram registrados 519 episódios de ultrapassagem da concentração de O₃, 64 episódios ocorrendo em 2024. (Figura 4) (Valdambrini; Ribeiro, 2022; CETESB 2025).




Figura 4 - Evolução do número de dias de ultrapassagens do padrão estadual de O₃ e do número de estações de monitoramento. Retirado de CETESB, 2025.

Sendo considerado um poluente secundário em concentrações tóxicas, ou seja, não é emitido diretamente, mas sim produzido pela transformação química de outras substâncias presentes na atmosfera, o ozônio troposférico é formado em um processo denominado *smog* fotoquímico, que consiste na oxidação das moléculas de óxidos de nitrogênio (NO_x), compostos orgânicos voláteis (COV's) e hidrocarbonetos, na presença de radiação ultravioleta e radicais hidroxila, que por sua vez continuam a oxidar elementos atmosféricos, gerando uma concentração constante de compostos oxidantes no ar (Oliveira, 2008).

Com relação ao impacto na vegetação, os componentes do *smog* fotoquímico atuam sobre o tecido foliar, aderindo à superfície ou penetrando pela via estomática. Os NO_x têm caráter hidrofílico e, quando em contato com a água, ionizam em nitrato (NO₃⁻) e nitrito (NO₂⁻), acidificando o mesófilo e causando a plasmólise celular pela degradação dos lipídios de membrana; além de causarem alterações na estrutura dos plastídios e mitocôndrias (Husen, 2021). O O₃ por sua vez, é considerado um poderoso agente fitotóxico. A maior parte das moléculas do O₃ que entram pela via estomática são degradadas pelas paredes e membranas celulares, porém, uma pequena concentração destas moléculas que consegue penetrar nas células, pode desencadear a produção de espécies reativas de oxigênio, que são altamente tóxicas e ativam mecanismos de morte celular programada, com a posterior senescência celular prematura (Chauhan; Sharma, 2023; Baier *et al*, 2005). Os efeitos do O₃ em espécies nativas é descrito e pode ocorrer na forma de manifestações visíveis, como pequenas manchas: cloroses e necroses teciduais, ou até queimaduras nas folhas (Cassimiro; Souza; Moraes, 2015. Moura, *et al*. 2018).

As plantas intoxicadas por altas concentrações de ozônio podem apresentar a perda da capacidade fotossintética por danos às estruturas do parênquima foliar, ou por promover a queda das folhas de determinado indivíduo, além disso, sua toxicidade pode causar distúrbios na evapotranspiração, causando estresse hídrico, alterações na translocação e alocação de carboidratos, redução da biomassa radicular e em casos severos a morte da planta. (Domingos *et al*, 2002).

A relação entre a área fotossintética e a absorção de poluentes atmosféricos é bem conhecida (Lu *et al*, 2018), porém não há estudos que avaliam se há relação entre a resposta espectral obtida por drones e o efeito da poluição atmosférica na vegetação. A variação dos parâmetros bioquímicos dos pigmentos fotossintéticos está ligada à capacidade que as plantas têm de apresentarem tolerância ou sensibilidade à poluição atmosférica urbana. Juntamente com outros parâmetros como o conteúdo relativo de água, o teor de ácido ascórbico e o pH das folhas; o conteúdo de clorofila é um parâmetro importante inserido no Índice de Tolerância à Poluição Atmosférica (ATPI) (Sumangala, *et al* 2018) que pode indicar quais espécies são mais resistentes ao efeito do estresse por poluentes no seu aparato fotossintético, sendo um processo que ocorre nas folhas, resposta específica também pode ocorrer no padrão de reflectância ou na assinatura espectral das diferentes espécies arbóreas expostas as fontes de poluição urbana.

Com a descrição da fitotoxicidade do ozônio as plantas nativas, há a necessidade de avaliar

qual o impacto do poluente sobre a saúde da floresta, ou seja, se a ação localizada nas folhas pode causar danos às formações florestais nativas (Moura, de Souza & Alves, 2014), de forma que a exposição desses espécimes, em áreas protegidas urbanas, ao O₃, possa causar um impacto que represente um risco à manutenção da saúde e da diversidade dos espécimes arbóreos (Cailleret *et al*, 2018).

2. Justificativa e Objetivos

A análise dos dados de reflectância pode fornecer informações sobre a dinâmica da do dossel florestal durante o tempo (Tagliarini *et al*, 2021) e, comparado com o perfil sazonal das condições climáticas e da poluição atmosférica, poderia inferir se os poluentes são um dos fatores que alteram a dinâmica da vegetação local. Desta forma, a aplicação de técnicas de sensoriamento remoto, como o uso de imagens multiespectrais pode ser útil para revelar se há diferença no modo em que os indivíduos vegetais se comportam em relação à presença da poluição atmosférica.

O presente trabalho tem como objetivo geral utilizar o sensoriamento remoto com VANT para avaliar os impactos da poluição por ozônio troposférico na vegetação nativa. O trabalho foi dividido em capítulos visando atingir objetivos específicos: No capítulo dois, buscou-se determinar se a variação dos índices de vegetação pode ser explicada pelos diferentes níveis de concentração de O₃ durante o período estudado. Para tanto, avaliou-se a relação entre os Índices de Vegetação e os níveis de O₃ troposférico na RMSP, considerando na área de estudo, três fragmentos florestais delimitados em parcelas permanentes. Essa análise envolve a construção de uma série temporal, ao longo de um ano, com os dados de reflectância aplicados em índices de vegetação, concentrações de ozônio e parâmetros meteorológicos.

No terceiro capítulo, o objetivo foi analisar o efeito do ozônio em parcelas com diferentes quantidades de biomassa, permitindo inferir se há uma diferença na sensibilidade ao poluente em diferentes níveis de biomassa arbórea. Para isso, foram utilizados índices de vegetação e parâmetros estruturais da comunidade arbórea obtidos em campo, aplicando-se o tratamento de dados desenvolvido no segundo capítulo para verificar a resposta da vegetação ao O₃ em diferentes classificações de biomassa.

Referências Bibliográficas

- Al Mestiraihi, M. (2019). *Occupancy Estimation through Visible Light Sensing (VLS)* (Master's thesis, Oklahoma State University).
- Almeida, D. R. A. D., Stark, S. C., Chazdon, R., Nelson, B. W., César, R. G., Meli, P., ... & Brancalion, P. H. S. (2019). The effectiveness of lidar remote sensing for monitoring forest cover attributes and landscape restoration. *Forest Ecology and Management*, 438, 34-43.
- Alves, C. D., Pereira, M. N., & Florenzano, T. G. (2009). Mapeamento das novas formas de ocupação urbana por meio da análise orientada a objeto. Estudo de caso: Aglomeração Urbana de Piracicaba. *Simpósio Brasileiro de Sensoriamento Remoto*, 14, 569-576.
- Atlântica, S. M. (2016). Atlas dos remanescentes florestais. Mapas. URL: <https://www.sosma.org.br/iniciativas/atlas-da-mata-atlantica>.
- Baier, M., Kandlbinder, A., Gollack, D., & Dietz, K. J. (2005). Oxidative stress and ozone: perception, signalling and response. *Plant, Cell & Environment*, 28(8), 1012-1020.
- Borges, É. R., Altomare, M., Pyles, M. V., Bueno, M. L., dos Santos, R. M., Fontes, M. A. L., & de Oliveira-Filho, A. T. (2024). Long-term change in the tree community of a tropical forest remnant surrounded by human-modified landscapes. *Folia Geobotanica*, 59(1), 51-62.
- Brasil. Resolução CONAMA no 003, de 28 de junho de 1990. Disponível em: <http://conama.mma.gov.br/?option=com_sisconama&task=arquivo.download&id=100>. Acesso em: 10 abr. 2023.
- Cailleret, M., Ferretti, M., Gessler, A., Rigling, A., & Schaub, M. (2018). Ozone effects on European forest growth—Towards an integrative approach. *Journal of Ecology*, 106(4), 1377-1389.
- Carneiro, M. S., Ribeiro, B. R., Campos, C. C. F., de Souza Almeida, H., de Araujo, M. L., dos Santos, F. A. M., & Ramos, F. N. (2023). Small forest fragments and their importance for conservation of tree communities in Atlantic semideciduous forest. *Iheringia, Série Botânica*, 78.
- Cassimiro, J. C., Souza, S. R. D., & Moraes, R. M. D. (2015). Trocas gasosas e injúrias foliares visíveis em plantas jovens de *Astronium graveolens* Jacq. fumigadas com ozônio. *Hoehnea*, 42, 687-694.
- Cavanagh, J. E. (2006). Potential of vegetation to mitigate road generated air pollution Part I—Review of background information. *Landcare Research Contract Report: LC0506/00xx, Landcare Research, Lincoln*.
- CETESB (2023). Sistema QUALAR – Sistema de Informações da qualidade do ar da Companhia Ambiental do Estado de São Paulo. Disponível em: <https://qualar.cetesb.sp.gov.br/>. Acesso em: 17 jan. 2025.
- CETESB. (2025). *Qualidade do ar no estado de São Paulo 2024* [Recurso eletrônico]. CETESB. <https://cetesb.sp.gov.br/ar/publicacoes-relatorios/>

- Chauhan, P., & Sharma, N. (2023). Effect of elevated O₃ on plants growth, active constituents, and production. *Plants and their Interaction to Environmental Pollution*, 79-97.
- Colomina, I., & Molina, P. (2014). Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of photogrammetry and remote sensing*, 92, 79-97.
- Cracknell, A. P. (2007). Introduction to remote sensing. *CRC press*.
- de Brito, L., Silva, P. A., & Fluminhan, A. (2019). Alterações foliares sugerem efeitos da poluição veicular em plantas da família myrtaceae em áreas urbanas. *Revista Ibero-Americana de Ciências Ambientais*, 10(1), 223-231.
- Dias, C., Bales, M. P., & da Silva, S. R. (2015). A evolução das emissões veiculares no estado de São Paulo com a inclusão das emissões de abastecimento, no período de 2006 a 2014. *Blucher Engineering Proceedings*, 2(1), 82-98.
- Domingos, M., Bourotte, C., Klumpp, A., Klumpp, G., & Forti, M. C. (2002). Impactos de poluição atmosférica sobre remanescentes florestais. *Parque Estadual das Fontes do Ipiranga, unidade de conservação que resiste à urbanização de São Paulo*. DC Bicudo, MC Forti & CEM Bicudo (orgs.). Editora Secretaria do Meio Ambiente do Estado de São Paulo, São Paulo, 221-49.
- Drummond, Carlos. *Mata Atlântica*. 2nd ed., AC&M Ed: Sette Letras, 1997.
- Elachi, C., & Van Zyl, J. J. (2021). *Introduction to the physics and techniques of remote sensing*. John Wiley & Sons.
- Eltner, A., Hoffmeister, D., Kaiser, A., Karrasch, P., Klingbeil, L., Stöcker, C., & Rovere, A. (Eds.). (2022). *UAVs for the environmental sciences: Methods and applications*. wbg Academic in Wissenschaftliche Buchgesellschaft (WBG).
- Felix, F. C., Avalos, F. A., Lima, W. D., Candido, B. M., Silva, M. L., & Mincato, R. L. (2021). Seasonal behavior of vegetation determined by sensor on an unmanned aerial vehicle. *Anais da Academia Brasileira de Ciências*, 93.
- Florenzano, T. G. (2007). *Iniciação em sensoriamento remoto*. Oficina de textos.
- Fussell, J., Rundquist, D., & Harrington, J. A. (1986). On defining remote sensing. *Photogrammetric Engineering and Remote Sensing*, 52(9), 1507-1511.
- Giacon, V. P., Valente, R. A., & Cardoso-Leite, E. (2022). Relação entre urbanização e integridade biótica de remanescentes de Florestas Urbanas. *Ambiente & Sociedade*, 25, e00534.
- Gitelson, A. A., & Merzlyak, M. N. (1998). Remote sensing of chlorophyll concentration in higher plant leaves. *Advances in space research*, 22(5), 689-692.
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of plant physiology*, 160(3), 271-282.
- Gitelson, A.A., Keydan, G.P. and Merzlyak, M.N., 2006. Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher

- plant leaves. *Geophysical research letters*, 33(11).
- Gupta, S. K., & Pandey, A. C. (2021). Spectral aspects for monitoring forest health in extreme season using multispectral imagery. *The Egyptian Journal of Remote Sensing and Space Science*, 24(3), 579-586.
- Husen, A. (2021). Morpho-anatomical, physiological, biochemical and molecular responses of plants to air pollution. In *Harsh Environment and Plant Resilience: Molecular and Functional Aspects* (pp. 203-234). Cham: Springer International Publishing.
- Iglhaut, J., Cabo, C., Puliti, S., Piermattei, L., O'Connor, J., & Rosette, J. (2019). Structure from motion photogrammetry in forestry: A review. *Current Forestry Reports*, 5(3), 155-168.
- IPA – Instituto de Pesquisas Ambientais. Inventário Florestal (2020). Disponível em : <<https://indd.adobe.com/view/a5aba10f-0090-4109-ac1c-944c8260b1ff>>. Acesso em mar. 2024.
- Jensen, J. R. (2009). *Jensen, J. R. (2009). Sensoriamento remoto do ambiente: Uma perspectiva em recursos terrestres (J. C. N. Epiphanyo, A. R. Formaggio, A. R. Santos, B. F. T. Rudorff, C. M. Almeida, & L. S. Galvão, Trans.). Parêntese.*
- Karabourniotis, G., Liakopoulos, G., Bresta, P., & Nikolopoulos, D. (2021). The optical properties of leaf structural elements and their contribution to photosynthetic performance and photoprotection. *Plants*, 10(07), 1455.
- Khalid, N., Masood, A., Noman, A., Aqeel, M., & Qasim, M. (2019). Study of the responses of two biomonitor plant species (*Datura alba* & *Ricinus communis*) to roadside air pollution. *Chemosphere*, 235, 832-841.
- Kondrat, H., Aragaki, S., & Gomes, E. P. C. (2020). Plant community dynamics in an urban forest fragment of the São Paulo Metropolitan Area, Brazil. *Hoehnea*, 47, e342019.
- Lelieveld, J., Pozzer, A., Pöschl, U., Fnais, M., Haines, A., & Münzel, T. (2020). Loss of life expectancy from air pollution compared to other risk factors: a worldwide perspective. *Cardiovascular research*, 116(11), 1910-1917.
- Lindenmayer, D. B., & Fischer, J. (2013). *Habitat fragmentation and landscape change: an ecological and conservation synthesis*. Island Press.
- Liu, W. T. H. (2015). *Aplicações de sensoriamento remoto*. Oficina de Textos.
- Livesley, S. J., McPherson, E. G., & Calfapietra, C. (2016). The urban forest and ecosystem services: impacts on urban water, heat, and pollution cycles at the tree, street, and city scale. *Journal of environmental quality*, 45(1), 119-124.
- Longhitano, G. A. (2010). *VANTS para sensoriamento remoto: aplicabilidade na avaliação e monitoramento de impactos ambientais causados por acidentes com cargas perigosas* (Doctoral dissertation, Universidade de São Paulo).
- Lu, S., Yang, X., Li, S., Chen, B., Jiang, Y., Wang, D., & Xu, L. (2018). Effects of plant leaf surface and different pollution levels on PM_{2.5} adsorption capacity. *Urban Forestry & Urban Greening*, 34, 64-70.
- Martins, A. P. G., Ribeiro, A. P., Ferreira, M. L., Martins, M. A. G., Negri, E. M., Scapin,

- M. A., ... & Laforteza, R. (2021). Infraestrutura verde para monitorar e minimizar os impactos da poluição atmosférica. *Estudos Avançados*, 35, 31-57.
- Mertikas, S. P., Partsinevelos, P., Mavrocordatos, C., & Maximenko, N. A. (2021). Environmental applications of remote sensing. In *Pollution assessment for sustainable practices in applied sciences and engineering* (pp. 107-163). Butterworth-Heinemann.
- Morley, P. J., Jump, A. S., West, M. D., & Donoghue, D. N. (2020). Spectral response of chlorophyll content during leaf senescence in European beech trees. *Environmental Research Communications*, 2(7), 071002.
- Moura, B. B., Alves, E. S., Marabesi, M. A., de Souza, S. R., Schaub, M., & Vollenweider, P. (2018). Ozone affects leaf physiology and causes injury to foliage of native tree species from the tropical Atlantic Forest of southern Brazil. *Science of the Total Environment*, 610, 912-925.
- Moura, B. B., de Souza, S. R., & Alves, E. S. (2014). Response of Brazilian native trees to acute ozone dose. *Environmental Science and Pollution Research*, 21, 4220-4227.
- de Moraes Novo, E. M. (2010). *Sensoriamento Remoto: princípios e aplicações*. Editora Blucher.
- Novo, E. M. L. M., & Ponzoni, F. J. (2001). *Introdução ao sensoriamento remoto*. São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE).
- Oliveira, D. P. (2008). Poluentes da atmosfera. In *Fundamentos de toxicologia* (pp. 142-164).
- Pawar, G. V., Singh, L., Jhariya, M. K., & Sahu, K. P. (2014). Effect of anthropogenic disturbances on biomass and carbon storage potential of a dry tropical forest in India. *Journal of Applied and Natural Science*, 6(2), 383-392.
- Ponzoni, F. J., & Disperati, A. A. (2001). Comportamento espectral da vegetação. *Sensoriamento remotoreflectância dos alvos naturais*. Brasília, DF: Universidade de Brasília, 157-99.
- Ponzoni, F. J., Shimabukuro, Y. E., & Kuplich, T. M. (2015). *Sensoriamento remoto da vegetação*. Oficina de textos.
- Raj, E. F. I., Manimala, K., Rani, E. F. I., & Darwin, S. (2024). Environmental monitoring and conservation using drones. In *Drone Applications for Industry 5.0* (pp. 358-380). IGI Global Scientific Publishing.
- Rossato, O. B., Andrade-Sanchez, P., Guerra, S. P. S., & Crusciol, C. A. C. (2012). Sensores de reflectância e fluorescência na avaliação de teores de nitrogênio, produção de biomassa e produtividade do algodoeiro. *Pesquisa Agropecuária Brasileira*, 47, 1133-1141.
- Roy, S., Byrne, J., & Pickering, C. (2012). A systematic quantitative review of urban tree benefits, costs, and assessment methods across cities in different climatic zones. *Urban forestry & urban greening*, 11(4), 351-363.
- Sabins Jr, F. F., & Ellis, J. M. (2020). *Remote sensing: Principles, interpretation, and applications*. Waveland Press.
- Slaton, M. R., Raymond Hunt Jr, E., & Smith, W. K. (2001). Estimating near-infrared leaf

- reflectance from leaf structural characteristics. *American journal of botany*, 88(2), 278-284.
- Smith, A. M., Kolden, C. A., Tinkham, W. T., Talhelm, A. F., Marshall, J. D., Hudak, A. T., ... & Gosz, J. R. (2014). Remote sensing the vulnerability of vegetation in natural terrestrial ecosystems. *Remote sensing of environment*, 154, 322-337.
- Sumangala, H. P., Aswath, C., Laxman, R. H., & Namratha, M. R. (2018). Evaluation of Air Pollution Tolerance Index (APTI) of selected ornamental tree species of Bengaluru, India. *Int J Pure App Biosci*, 6(3), 366-73.
- Tagliarini, F. D. S. N., Rodrigues, M. T., Rodrigues, B. T., de Barros, A. C., Garcia, Y. M., & Campos, S. (2021). Índice radiométrico ndvi em área de preservação permanente obtido por meio de aeronave remotamente pilotada. *Irriga*, 26(3), 717-731.
- Tan, B. Y. (2022). Save a Tree and Save a Life: Estimating the Health Benefits of Urban Forests. *Environmental and Resource Economics*, 82(3), 657-680.
- Trintinalia, L., Orsini, L., & Camargo, J. (2015). *Eletromagnetismo*. Lexington.
- Valdambrini, N. M., & Ribeiro, F. N. D. (2022). Avaliação das Ultrapassagens dos Padrões de Ozônio Troposférico no Estado de São Paulo de 2014 a 2019. *Revista Brasileira de Meteorologia*, 36, 735-747.
- Zhu, L., Suomalainen, J., Liu, J., Hyypä, J., Kaartinen, H., & Haggren, H. (2018). A review: Remote sensing sensors. *Multi-purposeful application of geospatial data*, 19.
- Ziegelmaier Neto, B. H., Schimalski, M. B., Liesenberg, V., Sothe, C., Martins-Neto, R. P., & Floriani, M. M. P. (2024). Combining LIDAR and spaceborne multispectral data for mapping successional forest stages in subtropical forests. *Remote Sensing*, 16(9), 1523.

**CAPÍTULO II: RELAÇÃO ENTRE OS ÍNDICES DE
VEGETAÇÃO E POLUIÇÃO POR OZÔNIO TROPOSFÉRICO EM
FRAGMENTOS FLORESTAIS DA REGIÃO METROPOLITANA
DE SÃO PAULO**

1 Introdução

Atualmente a Mata Atlântica ocupa apenas 12,4 % de sua área de ocorrência original (Atlântica, 2016). No Estado de São Paulo, com o processo de transformação do perfil de uso ocupação do solo 32% do território original da Mata Atlântica ainda permanece, mas a maior parte dessa vegetação está restrita a pequenos fragmentos florestais (IPA, 2020).

A fragmentação florestal é um processo de interrupção do fluxo genético de uma comunidade biótica pela descontinuidade de uma área, causada por barreiras naturais ou antrópicas (Giacon; Cardoso-Leite, 2022) e representa um risco significativo à biodiversidade endêmica, uma vez que os fragmentos florestais passam a sofrer o efeito de borda, alterando a dinâmica de sucessão ecológica (Tabarelli *et al*, 2010) e tornando-se mais vulneráveis à colonização por espécies exóticas invasoras (Simberloff, 1992).

Variando com relação ao seu tamanho e nível de conectividade com outras áreas naturais, os fragmentos florestais são importantes para a manutenção da biodiversidade endêmica da Mata Atlântica e, mesmo áreas inferiores a 100 ha, mostram capacidade de preservação de espécies vulneráveis e ameaçadas de extinção (Carneiro *et al*, 2023). Fragmentos urbanos e pequenos fragmentos são relevantes ecologicamente: apresentam aumento da área basal, ganho de biomassa durante o tempo e florestas secundárias mantêm seu processo de sucessão para florestas maduras (Borges *et al*, 2024, Kondrat; Aragaki & Gomes, 2020). Essas formações florestais são provedoras de serviços ecossistêmicos para a população, mesmo em áreas diminutas, são importantes para o sequestro de carbono, a manutenção da integridade do solo e prevenção de enchentes (Mitchell & Devisscher, 2022). Grande parte dos fragmentos florestais da Mata Atlântica ocorrem à leste do Estado de São Paulo, associada à escarpa da Serra do Mar, mantendo um alto grau de endemismo mesmo que próximas ou inseridas em áreas densamente urbanizadas da Região Metropolitana de São Paulo (RMSP) (de Souza Werneck *et al*, 2011).

No contexto urbano como na RMSP, a biodiversidade dos remanescentes florestais é exposta à pressões ambientais decorridas das atividades antrópicas, como a impermeabilização e compactação do solo, introdução de espécies exóticas (Haddad *et al*, 2015) e a emissão de poluentes atmosféricos (de Brito *et al*, 2019). No caso específico da poluição do ar, destaca-se que, atualmente, na RMSP, a frota de aproximadamente 7 milhões de veículos automotores (CETESB, 2023) são responsáveis pela emissão de diversos compostos considerados nocivos à saúde humana e da comunidade biótica local como o monóxido de carbono (CO), os hidrocarbonetos (HC), os óxidos de nitrogênio (NOx), os óxidos de enxofre (SOx) e o material

particulado (MP); são responsáveis pela presença de substâncias como Compostos Orgânicos voláteis (VOCs) e pelas concentrações de ozônio (O_3), acima das recomendadas pela OMS. (Dias; Bales; Silva, 2015). Sendo considerado um poluente secundário, ou seja, não é emitido diretamente, mas sim formado por reações químicas de outras substâncias presentes na atmosfera, o O_3 troposférico depende de reações pertencentes a um fenômeno chamado *smog* fotoquímico, que consiste na oxidação das moléculas de óxidos de nitrogênio (NO_x), e compostos orgânicos voláteis (COV's), na presença de radiação solar para formação de ozônio e radicais hidroxila, que por sua vez continuam a oxidar elementos atmosféricos, gerando uma concentração constante de compostos oxidantes no ar (Oliveira, 2008).

Desde o início do monitoramento do O_3 em 1996, as concentrações deste poluente permanecem acima do padrão de qualidade do ar estabelecido pela CETESB, que considera como uma qualidade do ar ruim uma concentração O_3 acima dos 66 ppb (ou $130 \mu g/m^3$) para 8 horas para a proteção da saúde humana (de Fatima Andrade *et al.*, 2003;). O ozônio é considerado um gás poluente quando ocorre na troposfera (Valdambrini; Ribeiro, 2022) e nocivo à vegetação (Husen, 2021). Quando absorvido pela via estomática, pode penetrar nas células da folha, e rapidamente desencadear a produção de espécies reativas de oxigênio (Baier *et al.*, 2005) e a ativação de mecanismos de morte celular programada, resultando em danos teciduais para os indivíduos afetados (Chauhan; Sharma, 2023; Moura; Souza; Alves, 2014).

O efeito da exposição do O_3 em espécies nativas pode ocorrer na forma de manifestações visíveis, como pequenas manchas: cloroses e necroses, ou até queimaduras nas folhas (Cassimiro; Souza; Moraes, 2015. Moura, *et al.* 2018). As plantas expostas a altas concentrações de O_3 podem apresentar a perda da capacidade fotossintética por danos às estruturas do parênquima foliar ou por promover a senescência foliar (Francini, *et al* 2007). Além disso, sua toxicidade pode causar distúrbios na evapotranspiração, estresse hídrico, alterações na translocação e alocação de carboidratos, redução da biomassa radicular e em casos severos a morte da planta (Domingos *et al*, 2002).

As OMS estabelece valores-guia para padrões de qualidade do ar considerando o impacto do O_3 sobre a vegetação, nesse contexto, o índice AOT40 (*Accumulated Ozone Threshold Above 40 ppb*), dada em $ppb \cdot h$, é a principal metodologia aplicada para o monitoramento do O_3 como fator de impacto à saúde da vegetação (União Europeia, 2008). A metodologia consiste no cálculo da concentração do acumulado do O_3 para a qual a vegetação é exposta durante um intervalo de tempo determinado, considerando as médias horárias de concentração do poluente

que ultrapassam os 40 ppb, entre às 8:00 horas da manhã e às 8:00 horas da noite. Para o trimestre, o valor acumulado de AOT40 que ultrapassa os 3000 ppb·h é considerado um risco para a vegetação, pois indica um acúmulo de exposição ao O₃ capaz de causar danos fisiológicos e estruturais às plantas (Grünhage, *et al* 1999). Esse limite foi definido com base em estudos que demonstram que concentrações acumuladas de O₃ acima de 40 ppb·h durante o período de crescimento das plantas, podem comprometer sua saúde e produtividade primária (Jakovljević *et al*, 2021).

O conhecimento do impacto do O₃ troposférico à vegetação nativa é dificultado pela grande diversidade de espécies e de comportamentos em resposta à poluição ambiental (Jin, *et al* 2023). Inicialmente aplicados para o estudo de cultivos na agricultura de precisão (Eltner, 2022), o sensoriamento remoto espectral surge como uma ferramenta útil para o monitoramento dos distúrbios de formações florestais ao se relacionarem com parâmetros fisiológicos do tecido foliar (Sampaio *et al.* 2020). O sensoriamento remoto capta a reflectância da radiação eletromagnética em comprimentos de onda que interagem com o mesófilo foliar, permitindo verificar flutuações nos processos fotossintéticos causados por estresse ambiental (Dupuis *et al.* 2020).

Para a vegetação considerada saudável, ou não senescente, espera-se uma baixa reflectância na região do visível do espectro eletromagnético, faixa de comprimentos de onda que variam de 400 nm a 700 nm. Principalmente em comprimentos de onda na região do azul (430 a 450 nm) e do vermelho (650 a 700 nm), ocorre a absorção de radiação pelas moléculas de Clorofila α e β , presentes em altas concentrações nas folhas, utilizam a energia eletromagnética para realização das reações da fase fotoquímica da fotossíntese, nos centros de reação dos cloroplastos (Gitelson & Merzlyak, 1998). Pigmentos em menor concentração, como os pigmentos acessórios como as antocianinas e β -caroteno, participam da fotoproteção como forma de evitar o estresse oxidativo das estruturas foliares e absorvem de forma moderada comprimentos de onda na região do verde (450 nm) (Gitelson, Keydan & Merzlyak, 2006). A região do infravermelho próximo indica vigor foliar por ter sua reflectância aumentada pelos espaços intercelulares no mesófilo esponjoso, indicando pressão de turgor e capacidade de realização de trocas gasosas (Ponzoni & Disperati, 2001).

A combinação das bandas espectrais em equações ou razões de banda resultam em índices de vegetação, amplamente utilizados para estimar parâmetros como biomassa, taxa de fotossíntese, área foliar e níveis de estresse (Ponzoni; Shimabukuro, 2015). Esses índices

captam as diferenças no comportamento espectral da vegetação em contraste com outros elementos, sem a necessidade de interferência direta no ecossistema (Gao, 2024).

No caso do impacto do O_3 , seu efeito pode ser captado por sensores manuais no comportamento espectral e índices de vegetação em mudas de espécies arbóreas (Jones *et al*, 2024). Estudos com sensoriamento remoto por satélite demonstram que o O_3 se correlaciona negativamente com o Índice de Vegetação por Diferença Normalizada (NDVI) (Cheng *et al*, 2024). No entanto, ainda não existem estudos relevantes de sensoriamento remoto que avaliem os efeitos desse poluente sobre fragmentos urbanos no Bioma Mata Atlântica, e a lacuna de informações se estende ao uso de VANT's como ferramenta para aquisição de dados, fonte para análise do impacto desse poluente nesses fragmentos.

O presente trabalho tem como objetivo avaliar a aplicação do sensoriamento remoto multiespectral com VANTs como ferramenta para estudar o impacto da poluição atmosférica na vegetação nativa de fragmentos florestais em áreas urbanas da Região Metropolitana de São Paulo. Formulamos a hipótese de que há uma correlação causal entre os níveis de O_3 e os índices de vegetação obtidos por sensoriamento remoto, indicando que esse poluente impacta diretamente a saúde da vegetação. Por meio de uma produção de uma série histórica de índices de vegetação, buscou-se identificar os efeitos das variações de concentração do poluente no tecido foliar de fragmentos florestais nativos da Mata Atlântica.

2 Material e Métodos

2.1 Localização da área de estudo

Neste trabalho foram determinadas como Área de Estudo, três fragmentos de floresta secundária do Bioma Mata Atlântica na RMSP. Em cada fragmento, foram instaladas duas parcelas permanentes como área de amostragem. As parcelas possuem dimensões de 20 m x 50 m e foram subdivididas em 20 subparcelas de 10 m x 10 m. As parcelas instaladas encontram-se no âmbito do projeto temático Fapesp BIOMASP+ (Proc.20/07141-2).

As áreas de estudos são descritas a seguir: A) Parque Estadual das Fontes do Ipiranga (PEFI), constitui um dos mais significativos remanescentes de Mata Atlântica em área urbana do país. Apresenta uma área de aproximadamente 526,38 ha, e está localizado na porção sudoeste do município de São Paulo, fazendo limite com o município de Diadema, com altitudes médias entre 770 e 825m. Esse remanescente trata-se de uma ilha florestal cuja vegetação predominante é classificada como Ombrófila Densa (NASTRI *et al.*, 1992). A área de floresta

selecionada está localizada aproximadamente nos paralelos 23°38'30"S e 46°37'00"W; B) Reserva Florestal do Instituto de Biociências da Universidade de São Paulo - (RFIB), ou reserva Matão IAG, localizada dentro da Cidade Universitária "Armando Sales de Oliveira", é um dos raros remanescentes de floresta nativa dentro da cidade de São Paulo, tem a localização aproximada dentro dos paralelos 23°33'44" – 23°34'02" S e 46°43'38" – 46°43'49" W (Dislich *et al.*, 2002); C) Reserva Florestal do Morro Grande (RFMG), é uma das últimas áreas de Mata Atlântica de grande extensão presente na região metropolitana de São Paulo. Está situada no Planalto Atlântico Paulistano e abrange uma área de cerca de 10.870 ha no município de Cotia em São Paulo, em altitudes que variam de 860 a 1075m. Essa reserva é uma das poucas áreas a apresentar florestas em estágios mais avançados de sucessão, cuja vegetação predominante é a Floresta Ombrófila Densa Montana (Metzger *et al.*, 2006). A área de floresta selecionada está localizada aproximadamente nos paralelos 23°39'12" S e 46°58'10"W.

Foi realizado o georreferenciamento das parcelas a partir da coleta de pontos com GPS portáteis, aprimoradas com o uso de torre de posicionamento com Sistema Global de Navegação por Satélite (GNSS) *DJI RTK-2*. Com os pontos importados no software *ArcGis-Pro*, foram produzidos os polígonos com as áreas das parcelas permanentes onde seriam coletadas as imagens, para garantir que todas as coletas correspondessem ao mesmo local. As parcelas e subparcelas utilizadas como área de amostragem estão representadas no mapa da Figura 5.




Figura 5 - Mapa da localização das áreas de estudo dentro da Região Metropolitana da Cidade de São Paulo (RMSP). A) Reserva Florestal do Morro Grande (RFMG); B) Reserva Florestal do Instituto de Biociências da USP - (RFIB) / Matão IAG; C) Parque Estadual das Fontes do Ipiranga (PEFI).

2.2 Caracterização Climática

De acordo com Piñero Sánchez *et al.* (2020) na RMSP durante o inverno, em julho, as temperaturas mínimas médias são de aproximadamente 15,3 °C e 15,8 °C enquanto no verão, em fevereiro, as temperaturas máximas médias atingem cerca de 22 °C 22,4 °C. O regime de precipitação apresenta um mínimo em agosto, com valores em torno de 40,5 mm e 39,6 mm no, e um máximo em janeiro, entre 223 mm e 237 mm. A RMSP também é caracterizada por ventos superficiais fracos ao longo do ano, com direções predominantes de norte a nordeste no verão, sofrendo influência da entrada da brisa marítima, e de nordeste a leste no inverno, influenciadas por sistemas atmosféricos de grande escala.

Além disso, a RMSP é afetada por eventos de ilha de calor urbana que modificam adicionalmente os padrões meteorológicos. De forma geral, o clima da Região Metropolitana de São Paulo é marcado por um regime subtropical úmido, com padrões sazonais de temperatura e precipitação, sendo que a estação chuvosa pode variar entre cinco meses e meio e mais de seis meses, geralmente ocorre de outubro a abril e com os maiores volumes de precipitação ocorrendo entre janeiro e fevereiro; a estação seca normalmente ocorre entre maio e setembro tendo julho como mês de menor precipitação (Obregón, Marengo e Nobre, 2014).

Para o presente trabalho, os dados da média mensal de temperatura e precipitação acumulada mensal, referentes ao período de junho de 2023 a julho de 2024, foram obtidos junto ao Instituto Nacional de Meteorologia (INMET) e Instituto de Astronomia, Geofísica e Ciências Atmosféricas da Universidade de São Paulo (IAG-USP).

2.3 Coleta, processamento das imagens e produção dos Índices de Vegetação

Ao longo do período entre julho de 2023 e junho de 2024, foram feitos voos automatizados mensais sobre as parcelas da área de estudo com a aeronave Phantom 4 Pro Multispectral, equipado com GNSS DJI RTK-2, com sensores com filtros para os comprimentos de onda Azul (B) 450 nm $\pm$ 16 nm, Verde (G) 560 nm $\pm$ 16 nm, Vermelho (R) 650 nm $\pm$ 16 nm, Vermelho Limitrofe (RE) 730 nm $\pm$ 16 nm, Infravermelho Próximo (NIR) 840 nm $\pm$ 26 nm. Os voos foram realizados entre às 11:00 da manhã e 14:00 h da tarde.

As imagens brutas capturadas durante o voo foram importadas no programa *Agisoft Metashape*, no qual foram submetidas à calibração radiométrica utilizando como correção o valor de irradiância capturado pelo sensor solar do veículo. Após a calibração, as imagens passaram pelo processo de alinhamento, construção de nuvem de pontos e produção do modelo

digital de superfície e por final os ortomosaicos.

Com os ortomosaicos produzidos, foram selecionados na literaturas índices de vegetação e equações que poderiam ser aplicadas a partir dos comprimentos de onda sensorizados pelo VANT utilizado (Tabela 1). Com a ferramenta *Raster Calculator* do Programa *ArcGis Pro*, foram aplicadas às razões de banda e os valores médios para cada índice de vegetação foram extraídos a nível de subparcela.

Tabela 1: Lista dos índices de vegetação utilizados no estudo.

Índice	Sigla	Equação	Referência
<i>Canopy Chlorophyll Content Index</i>	CCCI	$(\text{Nir} - \text{RE} / \text{NIR} + \text{RE}) / (\text{Nir} - \text{R} / \text{NIR} + \text{R})$	Barnes <i>et al.</i> (2000)
<i>Chlorophyll Index Green</i>	CIG	$(\text{Nir} / \text{G}) - 1$	Gitelson <i>et al.</i> (2003)
<i>Chlorophyll Red-Edge</i>	CRE	$((\text{RE} / \text{Nir}) / [\text{R} / \text{RE}]) (-1)$	Maccioni <i>et al.</i> (2001)
<i>Chlorophyll Vegetation index</i>	CVI	$\text{Nir} (\text{R} / \text{G})^2$	Datt <i>et al.</i> (2003)
<i>Enhanced Vegetation Index</i>	EVI	$2.5 (\text{Nir} - \text{R}) / (\text{Nir} + 6\text{R} - 7.5\text{B}) + 1$	Huete <i>et al.</i> (1999)
<i>Green Leaf Index</i>	GLI	$(2\text{G} - \text{R} - \text{B}) / (2\text{G} + \text{R} + \text{B})$	Louhaichi <i>et al.</i> (2001)
<i>Green Normalized Difference Vegetation Index</i>	GNDVI	$(\text{Nir} - \text{G}) / (\text{Nir} + \text{G})$	Buschmann & Nagel. (1996)
<i>Leaf Chlorophyll Index</i>	LCI	$(\text{Nir} - \text{RE}) / (\text{Nir} + \text{R})$	Datt (1999)
<i>Modified Chlorophyll Absorption in Reflectance Index</i>	MCARI	$((\text{RE} - \text{R}) - 0.2 (\text{RE} - \text{G})) (\text{RE} / \text{R})$	Hunt <i>et al.</i> (2011)
<i>Red- Edge Normalized Difference Vegetation Index</i>	NDRE	$(\text{Nir} - \text{RE}) / (\text{Nir} + \text{RE})$	Barnes <i>et al.</i> (2000)
<i>Normalized Difference Vegetation Index</i>	NDVI	$(\text{Nir} - \text{R}) / (\text{Nir} + \text{R})$	Tucker (1979)
<i>Plant Senescence Reflectance Index</i>	PSRI	$(\text{R} - \text{G}) / \text{RE}$	Merzlyak <i>et al.</i> (1999)
<i>Renormalized Difference Vegetation Index</i>	RDVI	$(\text{Nir} - \text{R}) / \sqrt{(\text{Nir} + \text{R})}$	Roujean & Breon (1995)
<i>Structure Intensive Pigment Index</i>	SIPI	$(\text{Nir} - \text{G}) / (\text{Nir} - \text{R})$	Penuelas <i>et al.</i> (1995)
<i>Nir Simple Ratio</i>	SR NIR	Nir / R	Jordan (1969)
<i>Transformed Chlorophyll Absorption Ratio Index</i>	TCARI	$3 ((\text{RE} - \text{R}) - 0.2 (\text{RE} - \text{G})) / (\text{RE} \text{ R})$	Hunt <i>et al.</i> (2011)
<i>Triangular chlorophyll index</i>	TCI	$1.2 (\text{RE} - \text{G}) - 1.5 (\text{R} - \text{G}) * \sqrt{(\text{RE} \text{ R})}$	Hunt <i>et al.</i> (2011)
<i>Triangular Vegetation Index</i>	TVI	$0.5 (120 (\text{Nir} - \text{G}) - 200 (\text{R} - \text{G}))$	Broge & Leblanc (2000)
<i>Wide Dynamic Range Vegetation Index</i>	WDRVI	$(0.1\text{Nir} - \text{R}) / (0.1\text{Nir} + \text{R})$	Hunt <i>et al.</i> (2011)

2.4 Caracterização da poluição por ozônio

Para caracterizar a qualidade do ar durante o período experimental, foram utilizados dados

provenientes das estações automáticas de monitoramento operadas pela CETESB, disponíveis no sistema QUALAR (CETESB, 2023). Os dados, coletados por amostradores automáticos na no Estado São Paulo foram analisados e, considerando sua representatividade espacial e a relevância dos dados para o presente trabalho, 17 estações de monitoramento foram selecionadas e estão representadas na Figura 6, onde é possível ver a localização geográfica na das estações escolhidas, distribuídas na RMSP e no interior do Estado de São Paulo.




Figura 6 - Localização das estações de monitoramento de O_3 troposférico da CETESB utilizadas no presente estudo.

Foram utilizadas as médias das concentrações mensais para avaliar o perfil do O_3 ao longo do período estudado e o índice AOT40 foi aplicado como forma de avaliar risco representado à saúde da vegetação pelas concentrações acumuladas de O_3 na RMSP. A AOT40 utiliza a soma

das concentrações de O₃ que excedem 40 partes por bilhão (ppb), no período entre 8h e 20h, quando a luz solar é suficiente para a fotossíntese. A AOT40 foi calculada para cada trimestre: julho a setembro de 2023; outubro a dezembro de 2023; janeiro a março de 2024; abril a junho de 2024. Abaixo a fórmula utilizada para o Cálculo da AOT40:

$$AOT_{40} = \sum_{i=1}^n (C_i - 40) \cdot \Delta t \quad \text{para } C_i > 40$$

Em que AOT40 representa o acúmulo de O₃ acima do limite de 40 ppb. A variável C_i corresponde à concentração horária de O₃, em ppb, no instante i. A função max(C_i - 40, 0) assegura que apenas os valores de concentração que excedem 40 ppb sejam considerados no cálculo, de modo que, quando C_i é inferior a 40 ppb, o resultado dessa operação é zero. O termo Δt refere-se ao intervalo de tempo adotado na soma, que, na maioria dos casos, corresponde a uma hora. Por fim, n indica o número total de horas dentro do período analisado, que normalmente compreende as horas de luz solar, entre 8h e 20h, durante a estação de crescimento das plantas.

Para estimar a concentração de O₃ nas áreas de estudo, foram produzidas superfícies de tendência, utilizando-se da técnica de Krigagem que é um método estatístico de interpolação dos dados, onde, a partir dos valores mensais de concentração de poluentes das estações de monitoramento, as quais foram atreladas a uma informação geográfica do local de coleta, são produzidos semivariogramas, que relacionam a variância dos dados com a distância entre pontos e um modelo linear é ajustado para descrever a variação espacial do O₃. Os semivariogramas foram obtidos pelo programa *ArcGIS Pro*.

2.5 Análise estatística

Para avaliar os efeitos da concentração de O₃ na saúde da vegetação amostrada, foi aplicada uma abordagem de Modelos Lineares de Efeitos Mistos (LMM). O modelo considerou como variáveis preditoras a sazonalidade e a concentração acumulada de O₃ troposférico, através do índice AOT40. Os índices de vegetação foram definidos como a variável resposta. Para o efeito da sazonalidade no modelo, o período foi dividido em quatro estações (Tabela 2), como forma de incluir a variação sazonal do bioma Mata Atlântica, que influencia as características das folhas de acordo com a disponibilidade do recurso hídrico e do fotoperíodo. Como efeito aleatório, foram incluídas as seis parcelas pertencentes às três áreas de estudo, de forma a capturar a variação intrínseca entre as áreas e parcelas. Essa abordagem permitiu não apenas ajustar os efeitos fixos das variáveis preditoras, mas também controlar a influência da

autocorrelação espacial, assegurando estimativas mais robustas e confiáveis dos parâmetros.

Tabela 2: Divisão do período de coleta como forma de incorporar a sazonalidade ao GLMM.

Período	Nomenclatura adotada
julho a setembro de 2023	Inverno
outubro a dezembro de 2023	Primavera
janeiro a março de 2024	Verão
abril a junho de 2024	Outono

Dentre os índices relacionados na Tabela 1, todos foram testados, aqui serão apresentados apenas os índices com maior explicabilidade para o modelo, sendo eles: *Green Leaf Index* (GLI), *Triangular Chlorophyll Index* (TCI) e *Plant Senescence Reflectance Index* (PSRI); exceto o *Normalized Difference Vegetation Index* (NDVI), que foi utilizado como comparação devido ao seu amplo uso em métricas de monitoramento de vegetação por sensoriamento remoto. Os índices NDVI e PSRI foram submetidos à transformação exponencial na base 10, com o objetivo eliminar valores negativos, facilitando a padronização das escalas dos dados e a interpretação dos resultados no modelo aplicado.

Em relação aos comprimentos de onda utilizados nos índices de vegetação, o GLI emprega exclusivamente comprimentos de onda da região do visível: vermelho, verde e azul e está associada à presença de clorofila, indicando a eficiência fotossintética. Sua aplicação inicial por Louhaichi *et al.* (2001), visava identificar falhas de plantios de trigo por meio da razão entre as três bandas. O PSRI, desenvolvido por Merzlyak *et al.* (1999), é um índice espectral utilizado para quantificar a senescência foliar, bem como mudanças na composição dos pigmentos (redução da clorofila e aumento de carotenóides), ele é calculado com base nas bandas do verde, vermelho e borda do vermelho, sendo sensível à razão entre carotenóides e clorofila. TCI faz parte de um conjunto de índices testados por Haboudane, *et al.* (2008) com o objetivo de prever a concentração de clorofila total, e consequentemente a eficiência fotossintética, em área foliar em cultivos. Esse índice utiliza as bandas do verde, vermelho e borda do vermelho. Já o NDVI foi desenvolvido para monitoramento da biomassa verde por satélite (Rouse *et al.*, 1974). Ele utiliza as bandas do infravermelho próximo e vermelho. Atualmente, o NDVI é amplamente aplicado na agricultura de precisão e monitoramento ambiental, sendo considerado como dominante por sua simplicidade e robustez. Ele é utilizado há tempo suficiente para permitir uma resolução temporal que acompanha a mudança da vegetação no planeta ao longo das últimas décadas (Liu, *et al.* 2015).

3. Resultados

3.1 Parâmetros Meteorológicos

A partir das médias mensais de temperatura e precipitação das áreas de estudo, foi possível caracterizar estes parâmetros para o período de julho de 2023 a junho de 2024.

A temperatura média mensal flutuou de 14,9 °C a 24 °C para o período (Figura 7). Na RFMG, foram encontradas as menores médias de temperatura, excetuando-se o mês de janeiro de 2024 que sua média superou a observada no PEFI. Já a RFIB registrou os maiores valores de temperatura para o período. Para os três locais estudados, o perfil sazonal indica menores temperaturas durante a estação seca, aumentando com a proximidade com os meses da estação úmida para os três locais estudados. Em outubro, houve um decréscimo no valor médio em relação ao registrado em setembro, retomando os aumentos de temperatura média em novembro para chegar ao valor mais alto em dezembro de 2023. As temperaturas caem ligeiramente em janeiro de 2024, exceto em RFMG. Em fevereiro de 2024 as temperaturas continuam muito próximas dos valores mais altos e para RFIB é a maior média registrada no ano. A partir de março as temperaturas começam a cair, até julho de 2024 para a faixa entre 15 e 16°C para RFMG e abaixo dos 20 °C para PEFI e RFIB.




Figura 7 - Variação da média mensal da temperatura nos três locais de estudo.

Os maiores valores de precipitação foram encontrados em janeiro e fevereiro de 2024, já nos meses de julho de 2023 e junho de 2024 foram encontrados os menores valores (Figura 8). O acumulado da precipitação variou ao longo do período de meses em que não foi registrada precipitação, até 286,5 mm no PEFI. Apesar de ser marcada a variação entre período seco (abril-setembro) e período chuvoso (outubro-abril), houve uma grande variação entre os meses da estação chuvosa, sendo encontrado valores relativamente baixos (67,3) mm para RFIB em dezembro de 2023. O PEFI obteve os maiores valores de precipitação para a estação chuvosa, com exceção de novembro onde RFMG registrou o maior valor.




Figura 8 - Variação do acumulado da precipitação nos três locais de estudo

3.2 Ozônio na RMSP

A partir da análise dos dados horários de rede monitoramento da CETESB, foi obtida a distribuição dos dados das concentrações de O_3 mensal para a RMSP de julho de 2023 a junho de 2024 (Figura 9). Em julho de 2023 foi registrado a menor média da série anual com 22,5 ppb. Os níveis de O_3 aumentaram, com a aproximação da transição da estação seca para a chuvosa, atingindo seu pico máximo em setembro, quando foram registrados os maiores valores horários. Nesse mês, a concentração máxima diária foi de 172,45 ppb, sendo também o maior valor horário observado durante o período, além de ser o mês com maior variabilidade dos dados. Do pico de concentração em setembro, segue-se uma queda no mês de outubro, com

média de 26,46 ppb, no início da estação chuvosa. Analisando os valores médios, novembro de 2023 e dezembro de 2023 apresentaram as maiores médias mensais do poluente com 37,30 ppb e 34,69 ppb, respectivamente. Nos meses seguintes há uma estabilização dos valores médios com uma queda durante a estação seca, alcançando 22,32 ppb para julho de 2024.




Figura 9 - Boxplot da distribuição dos dados de concentração média horária O_3 (em ppb) mensais, considerando as estações de monitoramento da CETESB utilizadas neste trabalho.

Os valores horários das estações de monitoramento foram compilados, obtendo-se a média horária anual dos poluentes por estação de monitoramento da CETESB na RMSP (Figura 10). A média horária anual por estação variou em valores que vão desde 20,88 ppb para Parelheiros, extremo sul do município de São Paulo, a 37,2 ppb em Jundiaí, localizada ao norte, fora da RMSP. Foram registradas altas concentrações horárias, tendo como maior valor o encontrado em São Bernardo com 172,45 ppb, seguem como estações que registraram altas concentrações horárias a estação Cidade Universitária e Ibirapuera.

Os dados demonstram que, nem sempre, a proximidade com estações que apresentaram altas concentrações de O_3 reflete em valores semelhantes, como ocorre com a estação de Pinheiros, próxima à Cidade Universitária, que apresenta uma média diminuída e baixa

distribuição dos dados de O_3 . Também é possível verificar uma alta concentração média em estações próximas ao ABC paulista, como Diadema e São Bernardo, o que também acontece em outras estações afastadas do centro da cidade de São Paulo, como Capão Redondo.




Figura 10 - Boxplot da distribuição da média horária anual da concentração de O_3 (em ppb), nas estações de monitoramento da CETESB utilizadas neste trabalho, no período de julho de 2023 a julho de 2024.

3.3 Interpolação dos valores de O_3

A concentração mensal de O_3 estimada foi obtida para as áreas de estudo, entre julho de 2023 e junho de 2024 por meio da Krigagem. Com base nos dados das estações de monitoramento, foi possível inferir a concentração acumulada O_3 estimada para a área das parcelas permanentes do presente trabalho e a partir da interpolação dos valores das estações de monitoramento, foi estimado a AOT40 para as áreas de estudo.

Na Figura 11 é apresentada a variação trimestral da AOT40. Verificou-se que há um forte componente sazonal na concentração de O_3 que representa um risco à vegetação nativa da

RMSP no período de julho de 2023 e junho de 2024, que se caracteriza pelos menores valores no período seco (inverno de 2023 e outono de 2024) e por alcançar valores mais altos durante o período chuvoso (primavera de 2023 e verão de 2024). O pico dos valores de AOT40 foi encontrado na primavera. Durante o ano, houve registro de ultrapassagem do limite dos 3000 ppb·h para as três áreas.

A ultrapassagem dos 3000 ppb·h da AOT40 durante o inverno para as três estações, indica que, a vegetação foi exposta a concentração de O₃ suficientemente elevadas para causar danos foliares aos indivíduos arbóreos. Na primavera, a AOT40 atingiu seus maiores valores, com 5.689,33 ppb·h, 5560,44 ppb·h e 4407,59 ppb·h para o PEFI, RFIB e RFMG, respectivamente. Após esse pico de exposição, os valores de AOT40 diminuíram progressivamente, atingindo os menores níveis do período estudado no outono de 2024, com a RFMG apresentando valores abaixo dos 3000 ppb·h para os trimestres de verão e outono de 2024, tornando uma área menos afetada pelo O₃ durante este período.




Figura 11 - Valores interpolados de AOT40 (ppb·h) nas três áreas de estudo para diferentes estações do ano no período de julho de 2023 a julho de 2024. Linha pontilhada em vermelho simboliza o limite de exposição da concentração do poluente, determinado como seguro para a vegetação para o trimestre.

A Figura 12 apresenta os valores de AOT40, onde há uma variação mensal dos valores dentro

de uma mesma estação. Dos valores encontrados no inverno para todas as estações, acima dos 3000 ppb podemos verificar que os dados obtidos em setembro compõem a maior parte dos valores encontrados no inverno. os meses onde é possível verificar que o acumulado de ozônio acontece em meses específicos e não mantém uma homogeneidade durante o ano. Indicando que a variabilidade espacial e temporal é relevante para a avaliação do ozônio em áreas distintas dentro da RMSP. Para o verão, o mês de outubro é o que apresenta a menor AOT40, seguido pelos picos de concentração acumulada para todas as áreas em novembro e dezembro. A variação encontrada no verão é menor, com a AOT40 acima de 1000 ppb para PEFI e RFMG e próximos ou menores que 1000 ppb·h para RFMG. Para outono de 2024 há um decréscimo na AOT40 a partir do valor encontrado em Abril de 2024 até a menor AOT40 da estação em Junho de 2024.




Figura 12 - Valores interpolados de AOT40 (ppb·h) nas três áreas de estudo em diferentes estações climáticas de 2023-2024. Linha pontilhada em vermelho simboliza o limite de exposição da concentração do poluente, determinado como seguro para a vegetação para o trimestre..

Através da estimativa das AOT40 por meio da técnica de Krigagem, foi construída uma superfície interpolada para a área estudada na RMSP (Figura 13), onde podemos ver as áreas mais afetadas pelas altas concentrações acumuladas do poluente durante o período de estudo.




Figura 13 - Mapa de calor das Superfícies de tendência da AOT40 por trimestre onde: 1) inverno de 2023; 2) primavera de 2023; 3) verão de 2024; 4) outono de 2024.

Durante o inverno, o índice AOT40 permaneceu na faixa entre 3000 e 4000 ppb·h para praticamente toda a área de estudo. É formado um gradiente discreto onde os valores tendem a aumentar em direção ao oeste, tornando o município de São Paulo e os municípios vizinhos à oeste, como São Bernardo e Diadema, ligeiramente mais afetados pela poluição do O₃.

Na primavera, o índice AOT40 alcançou valores superiores a 5000 ppb·h. para grande parte da área estudada e houve a formação de uma mancha de O₃ no centro no município de São Paulo, tornando PEFI e RFIB mais expostos a concentrações acumuladas de O₃, quando comparamos com RFMG.

No verão, a AOT40 foi menor que a primavera, atingindo até 4000 ppb·h. Nesse período, a mancha de concentração acumulada do poluente deslocou-se para região nordeste da RMSP, formando um gradiente crescente em direção ao leste e decrescente em direção ao oeste, onde está localizada a RFMG. No outono de 2024, os valores de AOT40 foram inferiores aos registrados nas demais estações do período estudado, mantendo-se abaixo de 3000 ppb·h, com exceção para algumas regiões na Cidade de São Paulo, como PEFI e RFIB.

3.4 Índices de Vegetação

A partir da coleta mensal dos dados de reflectância a com sensor Multiespectral acoplado a VANT, foram gerados os ortomosaicos para as áreas de estudo. Nas imagens para cada comprimento de onda, foram aplicados os índices de vegetação, apresentados no Gráfico 1 da Seção 2. Após a extração dos valores médios por parcela durante 1 ano, os índices GLI, PSRI e TCI apresentaram o maior valor de coeficiente de explicabilidade do modelo linear misto utilizado neste trabalho. Como forma de comparação com um índice mais comumente usado, também apresentamos aqui o resultado obtido com o NDVI.

Cada índice apresenta valores relativos à razão de bandas que compõem sua equação, dos quais obtiveram-se os valores médios para as 20 subparcelas em cada área de estudo. A variação temporal e espacial de um índice possibilitou a análise de como a vegetação das áreas de estudo respondem à sazonalidade e às diferenças intrínsecas de cada área, que influenciam a reflectância das bandas utilizadas nos índices, diretamente relacionadas pela concentração de pigmentos fotossintéticos foliares e pela estrutura do mesófilo esponjoso.

A escala numérica de variação dos índices diferiu de acordo com a equação aplicada e com a transformação dos dados utilizada para cada conjunto de dados. A Tabela 3 mostra a variação

dos valores encontrados nos índices de vegetação neste trabalho, como forma de embasar a comparação entre as áreas estudadas, entendendo que os valores pode variar e que as métricas obtidas podem ser utilizadas para a comparação de monitoramento com VANT em áreas de floresta secundária de Mata Atlântica.

Tabela 3 - Estatísticas descritivas para médias dos valores de índices de vegetação nas subparcelas estudadas:

	GLI	PSRI	TCI	NDVI
Mínima	0,09	0,62	1251,3	2,82
Máxima	0,58	1,25	11394,0	0,58
Média	0,35	0,86	5550,4	0,35
Mediana	0,37	0,84	5173,3	0,37

De forma geral os índices apresentaram uma variação sazonal que para os índices GLI, TCI e NDVI, apresentam menores valores durante o inverno e outono e os maiores valores durante a primavera e verão. O índice PSRI apresentou uma distribuição inversa, onde os maiores valores foram encontrados no inverno de 2023 e outono de 2024 e os menores valores na primavera de 2023 e verão de 2024.

A Figura 14, apresenta a distribuição dos valores do GLI para PEFI durante o período de Estudo. Para o primeiro mês do inverno de 2023, a distribuição dos valores do índice estiveram abaixo de 0,2, menor valor encontrado nesta área, seguido por um aumento nos meses subsequentes, atingindo os picos dos valores de GLI durante a primavera. No verão há uma queda nas médias de GLI, porém se mantém estável durante os 3 meses da estação, já no outono há uma queda nos valores de GLI, até valores abaixo de 0,3 para junho de 2024.




Figura 14 – Boxplot da variação temporal das médias de GLI para subparcelas no PEFI entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

O perfil dos resultados obtidos com TCI (Figura 15) acompanha o aumento do índice entre inverno e primavera, porém este não mostra o decréscimo encontrado no GLI no primeiro mês do Verão, janeiro. A queda nos valores do TCI ocorre apenas no mês de fevereiro e se mantém em valores próximos em março, até decrescer durante o inverno, voltando ao patamar encontrado no inverno onde a maior parte dos dados por parcela permaneceram restritos a uma faixa de 2000 a 4000 neste índice.




Figura 15 - Boxplot da variação temporal das médias de TCI para subparcelas no PEFI entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

Para o índice PSRI (Figura 16), relacionado à senescência foliar, é possível acompanhar que há um decréscimo na senescência à medida que as coletas se aproximam do período da primavera e verão, e um aumento da senescência para inverno e outono. Destaca-se que o índice apresenta um comportamento inverso na forma com que seus resultados são apresentados e há um discreto aumento da senescência nos dois primeiros meses do verão se compararmos com a primavera. Para março, os valores encontrados ficam majoritariamente abaixo de 0,8, como encontrado para dezembro e novembro de 2023. Já para o Outono, há um acréscimo no valor do índice chegando próximo ao valor de 1,0 para junho de 2024.




Figura 16 - Boxplot da variação temporal das médias de PSRI para subparcelas no PEFI entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

De forma geral, GLI e PSRI apresentaram uma distribuição mais restrita dos dados, ou seja, os resultados obtidos para o PEFI por esses dois índices, quando comparados com TCI, demonstram uma homogeneidade na obtenção de informações sobre as áreas estudadas. Destaca-se para o mês de outubro para GLI e mês de fevereiro para PSRI, momentos onde a distribuição é mais ampla se compararmos aos outros meses, mostrando que há maior variação nos valores de reflectância média obtidos por subparcela.

Já para o NDVI, a distribuição dos valores apresentados na Figura 17, foi mais ampla que GLI e PSRI. Quando comparado com os outros índices, destaca-se uma queda encontrada em dezembro de 2023, que ocorreu até janeiro de 2024. Sendo a diferença para os outros índices aplicados o uso de comprimento de onda NIR, algo na razão das bandas estudadas gerou uma queda que se refletiu apenas para este índice. Os valores voltaram a aumentar, para acima de 7,0 durante fevereiro de 2024, a partir daí, os valores apresentaram uma queda até o último mês do outono de 2024.




Figura 17 - Boxplot da variação temporal das médias de NDVI para subparcelas no PEFI entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

Na RFMG para o índice GLI (Figura 18), foi encontrada uma maior amplitude na distribuição dos dados em relação ao PEFI, com um maior número de valores atípicos. Meses como junho de 2024 obtiveram até 4 médias das parcelas consideradas como valores atípicos, ou seja, há uma maior variação nos valores do índice para esta área em comparação com o PEFI. Se para o PEFI o valor variou entre 0,2 a 0,5, a maior parte das médias de GLI por subparcela ultrapassou os 0,5 em fevereiro de 2024.




Figura 18 - Boxplot da variação temporal das médias de GLI para subparcelas na RFMG entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

Apesar de encontrarmos os menores valores de GLI no inverno e outono, a variação mensal do índice em direção à primavera não foi gradual na RFMG. Os valores permaneceram com medianas abaixo de 0,3 e no primeiro mês da primavera, a mediana ultrapassou 0,4. O primeiro entre outubro e novembro, a distribuição dos dados cai, aumentando apenas em janeiro e chegando ao seu pico em fevereiro de 2024, seguida por uma queda nos valores encontrados nos meses subsequentes, chegando aos menores valores de distribuição de 2024 em maio e junho.

Para o TCI, no caso da RFIB foi semelhante com o ocorrido no PEFI, onde o índice tende a apresentar uma distribuição maior como demonstrado na Figura 19. Suavizando as diferenças encontradas entre os meses e replicando o padrão encontrado no PEFI, dos menores valores ocorrendo no inverno e outono e os maiores valores na primavera e verão.




Figura 19 - Boxplot da variação temporal das médias de TCI para subparcelas na RFMG entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

No índice PSRI, (Figura 20) houve uma grande variação da distribuição dos dados no Inverno, permanecendo no patamar acima de 8,5. Em setembro há três subparcelas nos quais essa senescência foi diminuída, mostrando que não houve homogeneidade na resposta do índice para esta área de estudo. Há uma queda nos valores dos índices na primavera, com distribuição mais restrita, mostrando que quase todas as parcelas diminuiram seu índice de senescência, que continuou caindo durante o verão até o mês de fevereiro de 2024. A partir de Março de 2024, o índice de senescência volta a crescer, a diferença para maio é discreta. Em maio e junho de 2024 há um aumento do PSRI para as subparcelas estudadas.




Figura 20 - Boxplot da variação temporal das médias de PSRI para subparcelas na RFMG entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

Para esta área, a distribuição dos dados de NDVI (Figura 21), no inverno mostra uma maior variação no mês de setembro, ao contrário do que acontece nas outras áreas, a maior parte das médias do índice para este mês esteve a baixo do resultado do mês anterior, indicando que no mês de setembro houve alguma condição na área que alterou este índice de vegetação. Com relação à distribuição no verão, foi mais semelhante ao encontrado no TCI, não acompanhando a queda nos valores entre novembro e dezembro de 2023. Assim como, não acompanhou o pico de concentração ocorrido em fevereiro de 2024 na primavera. Entre primavera e outono, a distribuição apresenta valores de NDVI em queda, até atingir o menor valor para 2024 em junho.




Figura 21 - Boxplot da variação temporal das médias de NDVI para subparcelas na RFMG entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

Na RFIB, a quantidade de coletas foi menor que as realizadas nas outras duas áreas. Não havendo dados nos meses de dezembro de 2023 e de janeiro de 2024, há a impossibilidade de comparar a variação dos índices de vegetação entre os dois meses, entre primavera de 2023 e verão de 2024.

A Figura 22 ilustra a variação do índice GLI para as subparcelas estudadas. Em comparação com julho de 2023, o mês de agosto de 2023 apresenta uma distribuição mais restrita, seguida por um aumento no GLI em setembro, que chegará ao pico no mês de novembro, já na primavera. No verão, os valores diminuem em relação à novembro de 2023. No outono os valores voltam a cair, mas verifica-se que como ocorrido no inverno, há meses com distribuição mais ampla, como abril e maio, e com distribuição mais restrita dos dados, como junho, onde, ao contrário das outras áreas, é o mês onde são encontrados os maiores valores do índice.




Figura 22 - Boxplot da variação temporal das médias de GLI para subparcelas na RFIB entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

Para o PSRI (Figura 23), assim como o padrão encontrado para as outras áreas, a variação dos valores encontrados são o inverso do GLI, com o menor valor em novembro de 2023, com os maiores valores do índice para inverno de 2023 e outono de 2024, onde o pico foi encontrado em maio de 2024.




Figura 23 - Boxplot da variação temporal das médias de PSRI para subparcelas na RFIB entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

Para o TCI (Figura 24), as diferenças de distribuição dos dados foram atenuadas, e o padrão encontrado foi o aumento dos valores até a primavera, com o pico em outubro de 2023 e o decréscimo dos valores até outono de 2024.




Figura 24 - Boxplot da variação temporal das médias de TCI para subparcelas na RFIB entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

Já no NDVI (Figura 25), também há uma diferença no resultado de junho em relação a agosto de 2023, onde a distribuição dos dados indica uma diminuição do índice. Já em setembro de 2023 ocorre o aumento dos valores até o pico na primavera, em novembro, assim como o GLI. No verão, os valores estabilizam-se em uma faixa semelhante, com uma queda nos valores, mais acentuadamente em maio e junho de 2024.




Figura 25 - Boxplot da variação temporal das médias NDVI para subparcelas na RFIB entre julho de 2023 e junho de 2024. As linhas verticais tracejadas em vermelho delimitam as transições entre as estações do ano.

Ao observar o padrão encontrado na distribuição dos índices para as áreas de estudo, é possível verificar que o GLI foi capaz de captar a variação mensal da saúde da vegetação, tendendo a apresentar os resultados em uma faixa mais restrita, quando comparamos com o encontrado no TCI, que parece ser menos suscetível à variação mensal e sim, acompanhar o comportamento da vegetação, através do índice ao longo dos trimestres. O PSRI estabeleceu uma relação inversa, principalmente comparando-se com o GLI, indicando que ambos índices relacionam-se com os mesmos parâmetros foliares, apesar de as equações que geraram os dois índices serem diferentes. Vimos que o NDVI acompanhou a variação sazonal, com algumas diferenças na resposta de meses específicos, dos índices usados, é o único que utiliza o comprimento de onda Nir em sua equação.

3.5 Índices de Vegetação e AOT40

Os resultados do GLMM, mostram a relação entre os 4 principais índices de vegetação testados, e que apresentaram significância estatística, com o índice AOT40 e a sazonalidade para as três áreas de estudo (Tabela 4). GLI, PSRI e TCI foram os mais eficientes em explicar a relação com o AOT40 ao longo das estações do ano, representando 66%, 60% e 59%,

respectivamente, da variação do índice do poluente, sem considerar o efeito das variáveis aleatórias, que para o modelo utilizado estão relacionadas à diferença espacial entre as parcelas estudadas. Os outros índices testados encontram-se no anexo. Por outro lado, o NDVI foi capaz de explicar 46% da variação do AOT40 no modelo, enquanto outros índices baseados em diferenças normalizadas apresentaram os menores valores de coeficiente de determinação (R^2).

Tabela 4: Valores de coeficiente de determinação marginal, representando a variância explicada pelos efeitos fixos (R^2_m) e coeficiente de determinação condicional, representando a variância explicada pelos efeitos fixos e aleatórios combinados (R^2_c) obtidos a partir do modelo linear de efeitos mistos para a relação entre os índices de vegetação estudados e a AOT40.

Índice x AOT	R^2_m	R^2_c
GLI	0,66	0,72
PSRI	0,60	0,64
TCI	0,59	0,76
NDVI	0,46	0,71

As funções lineares obtidas pelo modelo GLMM, para os quatro índices estão apresentadas na Tabela 5. Os resultados mostraram que, em todos os índices testados, a relação entre os Índices de Vegetação e AOT40 na estação da primavera foi desprezível ($p > 0,05$). No verão, observou-se uma relação negativa significativa entre GLI ($p < 0,005$) e TCI ($p < 0,05$) com AOT40, indicando que, quanto maior o valor do índice de vegetação, menor a concentração acumulada de O_3 . Nas estações do período seco, o padrão encontrado para esses dois índices foi o aumento de seus valores acompanhando o aumento significativo de O_3 troposférico, o que, por sua vez, resultou em maior efeito sobre a vegetação ($p < 0,0001$). O PSRI demonstrou relação direta com a AOT40, sendo que no verão, o índice é positivamente correlacionado com o aumento do O_3 ($p < 0,005$). Já no outono e inverno ($p < 0,0001$) o marcador de senescência apresentou correlação negativa com o AOT40.

Tabela 5: Equações ajustadas do GLMM com a o valor-p para os índices GLI, PSRI, TCI e NDVI, nas estações estudadas durante o período.

Índice	Primavera	Verão	Outono	Inverno
GLI	$= 0.4256 + 0.0000085 * \text{AOT}$ $(p > 0,05)$	$= 0.4772 - 0.0000446 * \text{AOT}$ $(p < 0,005)$	$= 0.2190 + 0.0000751 * \text{AOT}$ $(p < 0,00001)$	$= 0.2310 + 0.0000435 * \text{AOT}$ $(p < 0,00001)$
PSRI	$= 0.7975 - 0.0000088 * \text{AOT}$ $(p < 0,05)$	$= 0.7348 + 0.0000471 * \text{AOT}$ $(p < 0,0005)$	$= 0.9986 - 0.0000707 * \text{AOT}$ $(p < 0,00001)$	$= 0.9717 - 0.0000328 * \text{AOT}$ $(p < 0,05)$
TCI	$= 8243.400 + 0.042 * \text{AOT}$ $(p > 0,05)$	$= 7342.349 - 0.718 * \text{AOT}$ $(p < 0,05)$	$= 2671.514 + 1.342 * \text{AOT}$ $(p < 0,00001)$	$= 3234.039 + 0.642 * \text{AOT}$ $(p < 0,00001)$
NDVI	$= 0.8368 + 0.0000041 * \text{AOT}$ $(p > 0,05)$	$= 0.8184 - 0.0000022 * \text{AOT}$ $(p > 0,05)$	$= 0.7164 + 0.0000428 * \text{AOT}$ $(p < 0,00001)$	$= 0.7478 - 0.0000058 * \text{AOT}$ $(p > 0,05)$

Assim como para os dados de O₃ acumulado para o semestre, os resultados obtidos pelos índices de vegetação indicam uma variação sazonal. Para os índices relacionados à concentração de componentes envolvidos na fotossíntese, saúde foliar e biomassa, como GLI, TCI e NDVI, apresentados respectivamente nas Figuras 26, 27 e 28 observou-se que os menores valores ocorreram na estação seca (outono e inverno), enquanto os maiores valores foram registrados na estação chuvosa (verão e primavera).




Figura 26 - Curva de regressão representando a relação entre GLI e a AOT40 no Modelo Linear de Efeitos Mistos em diferentes estações do ano. As linhas contínuas representam as previsões dos modelos ajustados, enquanto as linhas tracejadas indicam os intervalos de confiança de 95% dessas previsões. Os pontos indicam os valores de AOT40 observados para as subparcelas amostradas.




Figura 27 - Curva de regressão representando a relação entre TCI e a AOT40 no Modelo Linear de Efeitos Mistos em diferentes estações do ano. As linhas contínuas representam as previsões dos modelos ajustados, enquanto as linhas tracejadas indicam os intervalos de confiança de 95% dessas previsões. Os pontos indicam os valores de AOT40 observados para as subparcelas amostradas.




Figura 28 - Curva de regressão representando a relação entre NDVI e a AOT40 no Modelo Linear de Efeitos Mistos em diferentes estações do ano. As linhas contínuas representam as previsões dos modelos ajustados, enquanto as linhas tracejadas indicam os intervalos de confiança de 95% dessas previsões. Os pontos indicam os valores de AOT40 observados para as subparcelas amostradas.

Comparando-se a inclinação das curvas obtidas, há uma maior sensibilidade da vegetação no outono, quando todos os índices apresentam uma relação positiva mais clara com o aumento do AOT40. No verão, tanto o GLI quanto o TCI exibem uma tendência negativa, enquanto o NDVI permanece praticamente estável, indicando menor influência do ozônio sobre esse índice específico. Na primavera e no inverno, as tendências são mais sutis ou estáveis, com menor inclinação nas linhas de ajuste. Observando os intervalos de confiança nota-se que eles são mais estreitos para GLI em comparação com TCI e NDVI, o que indica maior precisão nas estimativas do modelo para este índice.

Por outro lado, para o índice que mede a senescência foliar, o PSRI, os menores valores foram observados na estação chuvosa e os maiores valores na estação seca (Figura 29). Sendo o índice que apresenta um comportamento inverso, aumenta com a senescência e a diminuição da saúde foliar, observa-se uma tendência de aumento dos valores de PSRI com o aumento da AOT40 para a primavera. Para o outono e inverno, há uma diminuição do índice conforme a AOT40 aumenta.




Figura 29 - Curva de regressão representando a relação entre PSRI e a AOT40 no Modelo Linear de Efeitos Mistos em diferentes estações do ano. As linhas contínuas representam as previsões dos modelos ajustados, enquanto as linhas tracejadas indicam os intervalos de confiança de 95% dessas previsões. Os pontos indicam os valores de AOT40 observados para as subparcelas amostradas.

4. Discussão

4.1 Variação sazonal da estimativa média de Ozônio e AOT40 na RMSP

As concentrações médias estimadas de O_3 aumentaram gradativamente no inverno, entre julho e setembro, nos três 3 locais estudados, levando a um acumulado de AOT40 superior a 3000 ppb.h. Carvalho *et al.* (2015) associa os altos índices de ozônio observados fora do período chuvoso às condições climáticas caracterizadas por baixa velocidade dos ventos, que dificultam a dispersão da pluma de ozônio na RMSP. Esses fatores podem ser intensificados por

características intrínsecas da urbanização, como a formação de ilhas de calor, ou por eventos meteorológicos em escala global, como o *El Niño*. Além disso, de acordo com a CETESB (2024), a formação de massas de calor em todo o estado de São Paulo, coincide com os valores de temperatura elevados para este período nas áreas de estudo, portanto podem contribuir para os aumentos da AOT40 neste período. A quantidade de dias sem nebulosidade também é apontada por Carvalho *et al.* (2015) como um fator que contribui para o aumento nos níveis de ozônio no período compreendido entre o período de transição inverno-primavera, setembro e novembro, e por Valdambrini e Ribeiro (2021) que relaciona a diminuição da nebulosidade e aumento da temperatura da atmosfera com altas concentrações mensais de O₃.

Há uma queda nos valores de concentração de O₃ no mês de outubro, coincidindo com um aumento da precipitação média e baixa da temperatura, exceto para a RFIB. Ressalta-se que outubro é um mês de transição entre o inverno e a primavera no Hemisfério Sul. Durante esse período, pode haver variações nas condições meteorológicas, com dias mais frios e nublados (reduzindo a formação de ozônio) intercalados com dias mais quentes e ensolarados (favorecendo picos de ozônio), o que pode explicar a média de ozônio baixa, mas ainda gerar episódios suficientes para aumentar o AOT40. Silva Júnior *et al.* (2009) encontraram o mesmo padrão de diminuição na concentração de ozônio entre setembro e outubro de 2004 e atribui os valores relativamente mais baixos em outubro à variação dos parâmetros meteorológicos, principalmente a queda na quantidade de radiação solar incidente em outubro, pelo aumento da nebulosidade no início da estação chuvosa. Por outro lado, Schuch *et al.* (2019) calcula a média mensal de concentração para as duas décadas entre 1996 a 2017 e o maior valor médio de concentração de O₃ corresponde ao mês de outubro, com o valor médio de precipitação chegando ao seu pico em janeiro. Apesar desses valores não seguirem um padrão determinado, é possível que as condições meteorológicas que favorecem a formação de nuvens e aumento da pluviosidade podem atuar como um fator que leva à queda da concentração do O₃ troposférico e do acumulado de AOT40 para a RMSP.

O pico dos valores de concentração média de O₃ foram registrados nos meses de novembro para PEFI e RFMG e dezembro para RFIB, coincidindo com os maiores valores da AOT40 para o trimestre referente à primavera. É esperado que, na RMSP, durante primavera sejam atingidas as maiores concentrações de O₃ troposférico devido ao aumento de irradiância solar, necessários ao processo de formação do poluente, seguidos pelos valores encontrados no verão, que podem ser atenuados pela formação de nuvens e de pluviosidade mais intensa, característica do período, que dissipa os poluentes da atmosfera (Schuch *et al.*, 2019)

As concentrações médias estimadas de O_3 decaíram na transição primavera e verão, nos meses de dezembro a janeiro, levando a menores valores de AOT40 no verão para todos os locais, destacando RFMG que apresentou valores de AOT40 inferiores a 3000 ppb·h. Esses valores corroboram a modelagem de superfície de tendência em que nas regiões densamente urbanizada, como PEFI e RFIB, registraram os maiores valores média de concentração de O_3 e de AOT40, enquanto nas áreas mais afastadas como RFMG apresentaram menores valores. Esse fenômeno pode ser explicado pela brisa marítima no verão que leva a pluma para o interior na direção noroeste, enquanto no inverno predominam os ventos fracos, favorecendo a manutenção das altas concentrações de O_3 . Esses resultados corroboram os achados pôr em Martins e Andrade (2008) que, por meio de modelagem das concentrações de O_3 para a RMSP, demonstraram que o deslocamento da mancha de alta concentração de ozônio ocorre devido aos ventos norte-noroeste durante o verão na região.

No outono houve uma queda significativa na concentração de ozônio. Esse comportamento é esperado devido ao término da estação chuvosa, à redução gradual da intensidade da radiação solar e a diminuição na quantidade de horas de sol disponíveis, que são fatores que contribuem para a redução das reações fotoquímicas responsáveis pela formação do ozônio troposférico.

4.2 Índices de Vegetação nas Áreas de Estudo

Os resultados da variação dos índices indicam para uma diferença na resposta dos parâmetros da saúde da vegetação com sensoriamento espectral para cada mês e estação do ano. Espera-se que devido às características da reflectância dos comprimento de onda sensorizados, cada índice esteja mais relacionado a um aspecto bioquímico ou fisiológico da vegetação.

O GLI só utiliza comprimentos da região do visível, portanto, está relacionado à presença de pigmentos foliares os quais estão diretamente relacionados à capacidade fotossintética das folhas na área de amostragem. O TCI utiliza comprimentos de onda da borda do vermelho e NDVI utiliza do infravermelho próximo. Essas duas faixas do espectro eletromagnético se relacionam às diferenças estruturais do mesófilo, podendo captar com mais eficiência uma variação causada por estresse hídrico, o que não necessariamente seria o caso para uma vegetação exposta ao ozônio. Portanto, para a mensuração dos efeitos de um poluente que atua diretamente sobre as folhas, o GLI pode mostrar maior performance por se relacionar com componentes foliares diretamente afetados por uma alta concentração de ozônio.

A diferença de resultados entre o TCI e NDVI como ocorrida em janeiro de 2024 e fevereiro

de 2024, pode ter relação com a presença do verde na equação do primeiro, mas também pela capacidade do comprimento de onda do Vermelho Limítrofe de penetrar as camadas de folhas sobrepostas (Horler *et al*, 1983), enquanto o Infravermelho Próximo, utilizado no NDVI, tende a gerar informações mais restritas sobre a camada mais alta de folhas do dossel florestal (Ponzoni & Disperati, 2015), de modo que ainda é necessário entender como o comportamento da vegetação em seus diversos extratos, se comporta com relação ao seu padrão de reflectância.

Para o índice de senescência, sua distribuição parece ser oposta à do GLI, utilizando o verde como inversamente proporcional à equação, neste trabalho foi um comprimento de onda determinante para avaliar os efeitos de um agente oxidante que atua diretamente no tecido foliar, tendo visto que os índices que apresentaram maior R^2m possuíam o verde como constituinte em sua equação.

Quando analisados os valores encontrados por subparcelas por mês, foi possível verificar momentos em que os resultados dos índices vegetação apresentavam uma distribuição mais restrita e outros momentos onde havia uma grande diversidade de respostas para uma mesma área em um mesmo mês. O que indica que é provável que exista uma heterogeneidade de comportamento espectral durante a série temporal, associada às características de uma vegetação diversa, onde as espécies apresentem comportamentos fenológicos diferentes e não necessariamente respondem da mesma forma a um agente estressor.

Todos os índices acompanharam uma variação sazonal, apontando para uma relação entre sazonalidade e os índices de vegetação aplicados. Tendo como a diferença principal a disponibilidade de água e de fotoperíodo nas áreas estudadas, é possível que os índices possam acompanhar o aumento da senescência da vegetação à medida que se afastam da estação chuvosa, notadamente primavera e verão, e diminuição da mesma na medida que se afasta da estação seca, porém houve variação dos valores dos índices entre os meses contidos em uma estação do ano, o que evoca a necessidade de relacioná-los com as variáveis meteorológicas para saber se esse comportamento pode ser justificado por condições climatológicas, ou se a saúde vegetação pode estar sendo afetada por fatores bióticos e abióticos, como a poluição ambiental, patologias ou outros fatores de estresse associados às áreas de estudo.

4.3 Índices de Vegetação e Níveis de Ozônio

Apesar da ampla aplicação dos índices comumente utilizados para a avaliação da vegetação, como o NDVI, NDRE e GNDVI, outros índices apresentaram melhor performance para

explicar o efeito do O₃ sobre a vegetação. No contexto florestal, devido à complexidade estrutural da vegetação, Gao *et al* (2024) sugerem que índices como o CVI e o TVI são mais adequados para avaliar o conteúdo de clorofila foliar e o índice de área foliar.

Observou-se que os índices de vegetação que utilizam múltiplos comprimentos de onda da região do visível apresentaram um desempenho superior na explicação dos modelos, especialmente em comparação ao índice tradicionalmente empregado para avaliar o ganho de biomassa verde e a saúde da vegetação, como o NDVI. Esses índices demonstraram maior sensibilidade para capturar tanto a variação sazonal quanto os impactos da poluição na vegetação. Em um estudo com espécies arbóreas, Gitelson, Gritz e Merzlyak (2003) evidenciaram que a razão utilizada no cálculo do NDVI pode superestimar os níveis de clorofila. Por outro lado, índices que incorporam bandas espectrais da região do verde e da borda do vermelho mostram-se mais eficazes para mitigar essa distorção, oferecendo uma representação mais precisa da saúde da vegetação. Jones *et al.* (2024) destaca a importância dos comprimentos de onda na região do visível como marcadores de estresse capazes de captar o efeito do O₃ nas folhas. Já Nakamura *et al* (2024) mostraram que razões entre comprimentos de onda da região do verde e vermelho são eficientes para a avaliação do estresse, por se relacionarem com o conteúdo pigmentar da folha, com menor dependência da luminosidade do momento da coleta, em comparação com os comprimentos de onda da região dos 800 nm, que é usado para o NDVI.

Todos os índices acompanharam uma variação sazonal, que assim como a concentração do poluente, possuem os maiores valores nas estações chuvosas, e os menores valores na estação seca, relacionando-se com o período de maior disponibilidade de água e luminosidade, como ideal para a planta acumular pigmentos fotossintetizantes e ganhar biomassa. Quando submetidos ao modelo com AOT40, os valores de GLI, NDVI, TCI determinaram que a alta concentração de O₃ na primavera não causou efeito significativo na vegetação, mas sim um efeito negativo moderado durante o verão, ou seja, durante este período da estação chuvosa, é possível que com o aumento das concentração acumulada de O₃ acima do padrão estabelecido, ocorra um dano sobre o tecido foliar da vegetação. A senescência pela poluição de O₃ pode ser um caso nesta estação, se assumirmos que após o aumento da disponibilidade de recurso hídrico, que acontece na primavera, a vegetação recupere sua capacidade fotossintética e aumente seu conteúdo relativo de água foliar, no verão, mesmo com condições de umidade e temperatura semelhantes, às folhas podem sofrer influência do estresse oxidativo.

O índice TCI é considerado adequado para estimar clorofila minimizando a influência das

camadas de folhas superpostas. Haboudane *et al* (2008) encontraram uma baixa relação entre os comprimentos de onda da borda do vermelho e o índice de área foliar, utilizando uma equação que considera a região do verde e infravermelho próximo e verificaram que o TCI pode ser um bom preditor de clorofila sem a saturação causada pelas folhas sobrepostas. No presente trabalho, o índice foi mais sensível à mudança sazonal que o GLI, além de apresentar um coeficiente de correlação maior com a AOT40 nas estações.

Modelando o efeito do O₃ troposférico em escala regional, o estudo de Shimizu (2019) encontrou relação entre o aumento da AOT40 e a diminuição da produtividade primária líquida em ecossistemas florestais, o contrário do resultado obtido neste trabalho em escala local, onde, para a estação seca, o O₃ acima dos valores permitidos, pode ter um efeito positivo sobre a vegetação nativa. Neste contexto, o índice com a segunda melhor performance para a explicabilidade com o modelo foi o PSRI, um indicador de senescência foliar. Segundo Merzlyak *et al.* (1999), o comportamento desta razão de bandas é inversamente proporcional ao conteúdo de clorofila, sendo assim, para o efeito de um fator de estresse que atua sobre o tecido foliar, um marcador relacionado a senescência pode ser mais adequado que os índices de vigor ou saúde vegetacional.

O PSRI teve relação positiva no verão, ou seja, a senescência foliar é aumentada com maiores concentrações de O₃ acima do permitido por legislação. Este resultado indica que durante os meses de janeiro a março, as altas concentrações de O₃ na RMSP, podem representar um risco ao tecido foliar, por promover provável diminuição na concentração de clorofila e pigmentos fotossintetizantes. Por outro lado, há uma relação negativa entre PSRI e AOT40 no outono e inverno, ou seja, nestas estações há diminuição da senescência foliar como resposta a altas concentrações de O₃. Esse fenômeno poderia ser explicado pelo aumento de composto protetores contra o estresse oxidativo em resposta à exposição ao poluente, como a produção de pigmentos protetores do ciclo da xantofila (Gielen, *et al*, 2007), fenólicos e antocianinas (de Rezende & Furlan, 2009). Gitelson, Keydan & Merzlyak (2006) relaciona a reflectância na região 540-560 nm a absorção da antocianina, que é diretamente proporcional aos valores de PSRI. Desta forma, mecanismos de proteção contra o estresse oxidativo podem estar envolvidos na relação positiva entre os índices de vegetação que se utilizam deste comprimento de onda, neste trabalho, TCI e PSRI.

Devido a relação positiva entre O₃ e variáveis meteorológicas como irradiância solar, intensidade e direção dos ventos, não é possível determinar se essas variáveis abióticas atuam

simultaneamente na saúde no tecido foliar da vegetação, tornando incerta a avaliação de quão representativa seria uma resposta fisiológica da planta na diminuição de senescência foliar captada pelos índices. Além disso, Pell *et al.* (1999) ressaltam que a resposta da planta a exposição ao O₃ não é determinada apenas pela quantidade absorvida do poluente, mas também por componentes espécie-específicos, o que torna necessária uma investigação mais detalhada sobre a sensibilidade espécie específica ao O₃, apontando para a necessidade de incorporar à modelagem de dados mais variáveis que possam explicar o comportamento da vegetação em áreas sob estresse abiótico causado pela urbanização.

5. Conclusão

Utilizando os índices de vegetação como métrica para avaliação da saúde da vegetação nativa, o presente trabalho encontrou uma influência do O₃, discriminado como AOT40, sobre as florestas urbanas estudadas na RMSP, que está condicionada pela variação sazonal do poluente. Enquanto na primavera a variação do O₃ acumulado teve pouca ou nenhuma relação com a variação dos índices de vegetação, no verão foi encontrado, um efeito significativo, sobre a saúde vegetação nativa. No outono e inverno o O₃ também influenciou a saúde da vegetação, diminuindo a senescência foliar.

Os índices de vegetação que utilizam comprimentos de onda na região do visível demonstraram sensibilidade ao efeito do poluente. Além disso, a inclusão de mais de duas faixas espectrais aumentou a capacidade explicativa do modelo, destacando o GLI e o TCI como bons preditores da saúde da vegetação. Os resultados obtidos com o PSRI ressaltam a importância da região do verde na avaliação do estresse abiótico, evidenciando a necessidade de estudos que investiguem a relação entre o O₃ e os pigmentos envolvidos na proteção contra o estresse. Isso pode ajudar a explicar a correlação positiva entre os índices de vegetação e as concentrações de O₃ observada na estação seca.

Referencias Bibliográficas

- Atlântica, S. M. (2016). Atlas dos remanescentes florestais. Mapas. URL: <https://www.sosma.org.br/iniciativas/atlas-da-mata-atlantica>.
- Baier, M., Kandlbinder, A., Gollmack, D., & Dietz, K. J. (2005). Oxidative stress and ozone: perception, signalling and response. *Plant, Cell & Environment*, 28(8), 1012-1020.
- Barnes, E. M., Clarke, T. R., Richards, S. E., Colaizzi, P. D., Haberland, J. U. L. I. O., Kostrzewski, M., ... & Moran, M. S. (2000, July). Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In

Proceedings of the fifth international conference on precision agriculture, Bloomington, MN, USA (Vol. 1619, No. 6).

- Borges, É. R., Altomare, M., Pyles, M. V., Bueno, M. L., dos Santos, R. M., Fontes, M. A. L., & de Oliveira-Filho, A. T. (2024). Long-term change in the tree community of a tropical forest remnant surrounded by human-modified landscapes. *Folia Geobotanica*, 59(1), 51-62.
- Buschmann, C., & Nagel, E. (1993). In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. *International Journal of Remote Sensing*, 14(4), 711-722.
- Carneiro, M. S., Ribeiro, B. R., Campos, C. C. F., de Souza Almeida, H., de Araujo, M. L., dos Santos, F. A. M., & Ramos, F. N. (2023). Small forest fragments and their importance for conservation of tree communities in Atlantic semideciduous forest. *Iheringia, Série Botânica*, 78.
- Carvalho, V. S. B., Freitas, E. D., Martins, L. D., Martins, J. A., Mazzoli, C. R., & de Fátima Andrade, M. (2015). Air quality status and trends over the Metropolitan Area of São Paulo, Brazil as a result of emission control policies. *Environmental Science & Policy*, 47, 68-79.
- Cassimiro, J. C., Souza, S. R. D., & Moraes, R. M. D. (2015). Trocas gasosas e injúrias foliares visíveis em plantas jovens de *Astronium graveolens* Jacq. fumigadas com ozônio. *Hoehnea*, 42, 687-694.
- CETESB (2023). Sistema QUALAR – Sistema de Informações da qualidade do ar da Companhia Ambiental do Estado de São Paulo. Disponível em: <https://qualar.cetesb.sp.gov.br/>. Acesso em: 17 jan. 2025.
- CETESB (2024). Sistema QUALAR – Sistema de Informações da qualidade do ar da Companhia Ambiental do Estado de São Paulo. Disponível em: <https://qualar.cetesb.sp.gov.br/>. Acesso em: 17 jan. 2025.
- Chauhan, P., & Sharma, N. (2023). Effect of elevated O₃ on plants growth, active constituents, and production. *Plants and their Interaction to Environmental Pollution*, 79-97.
- Cheng, S., Zhang, G., Yang, X., & Lei, B. (2024). A multiscale geographically weighted regression kriging method for spatial downscaling of satellite-based ozone datasets. *Frontiers in Environmental Science*, 11, 1267752.
- Datt, B. (1999). Remote sensing of water content in Eucalyptus leaves. *Australian Journal of botany*, 47(6), 909-923.
- Datt, B., McVicar, T. R., Van Niel, T. G., Jupp, D. L., & Pearlman, J. S. (2003). Preprocessing EO-1 Hyperion hyperspectral data to support the application of agricultural indexes. *IEEE Transactions on Geoscience and Remote Sensing*, 41(6), 1246-1259.
- de Brito, L., Silva, P. A., & Fluminhan, A. (2019). Alterações foliares sugerem efeitos da poluição veicular em plantas da família myrtaceae em áreas urbanas. *Revista Ibero-Americana de Ciências Ambientais*, 10(1), 223-231.
- de Fatima Andrade, M., Kumar, P., de Freitas, E. D., Ynoue, R. Y., Martins, J., Martins,

- L. D., ... & Zhang, Y. (2017). Air quality in the megacity of São Paulo: Evolution over the last 30 years and future perspectives. *Atmospheric environment*, 159, 66-82.
- de Rezende, F. M., & Furlan, C. M. (2009). Anthocyanins and tannins in ozone-fumigated guava trees. *Chemosphere*, 76(10), 1445-1450.
- de Souza Werneck, M., Sobral, M. E. G., Rocha, C. T. V., Landau, E. C., & Stehmann, J. R. (2011). Distribution and endemism of angiosperms in the Atlantifatic Forest. *Nat. Conserv*, 9, 188-193.
- Dias, C., Bales, M. P., & da Silva, S. R. (2015). A evolução das emissões veiculares no estado de São Paulo com a inclusão das emissões de abastecimento, no período de 2006 a 2014. *Blucher Engineering Proceedings*, 2(1), 82-98.
- Dislich, R. (2002). *Análise da vegetação arbórea e conservação na Reserva Florestal da Cidade Universitária Armando de Salles Oliveira, São Paulo, SP* (Doctoral dissertation, Universidade de São Paulo).
- Domingos, M., Bourotte, C., Klumpp, A., Klumpp, G., & Forti, M. C. (2002). Impactos de poluição atmosférica sobre remanescentes florestais. *Parque Estadual das Fontes do Ipiranga, unidade de conservação que resiste à urbanização de São Paulo*. DC Bicudo, MC Forti & CEM Bicudo (orgs.). Editora Secretaria do Meio Ambiente do Estado de São Paulo, São Paulo, 221-49.
- Dupuis, C., Lejeune, P., Michez, A., & Fayolle, A. (2020). How can remote sensing help monitor tropical moist forest degradation?—a systematic review. *Remote Sensing*, 12(7), 1087.
- Eltner, A., Hoffmeister, D., Kaiser, A., Karrasch, P., Klingbeil, L., Stöcker, C., & Rovere, A. (Eds.). (2022). *UAVs for the environmental sciences: Methods and applications*. wbg Academic in Wissenschaftliche Buchgesellschaft (WBG).
- Francini, A., Nali, C., Picchi, V., & Lorenzini, G. (2007). Metabolic changes in white clover clones exposed to ozone. *Environmental and Experimental Botany*, 60(1), 11-19.
- Gao, S., Yan, K., Liu, J., Pu, J., Zou, D., Qi, J., ... & Yan, G. (2024). Assessment of remote-sensed vegetation indices for estimating forest chlorophyll concentration. *Ecological Indicators*, 162, 112001.
- Giacon, V. P., Valente, R. A., & Cardoso-Leite, E. (2022). Relação entre urbanização e integridade biótica de remanescentes de Florestas Urbanas. *Ambiente & Sociedade*, 25.
- Gielen, B., Löw, M., Deckmyn, G., Metzger, U., Franck, F., Heerdt, C., ... & Ceulemans, R. (2007). Chronic ozone exposure affects leaf senescence of adult beech trees: a chlorophyll fluorescence approach. *Journal of experimental botany*, 58(4), 785-795.
- Gitelson, A. A. (2004). Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. *Journal of plant physiology*, 161(2), 165-173.
- Gitelson, A. A., & Merzlyak, M. N. (1998). Remote sensing of chlorophyll concentration in higher plant leaves. *Advances in space research*, 22(5), 689-692.
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of plant physiology*, 160(3), 271-

282.

- Gitelson, A. A., Viña, A., Arkebauer, T. J., Rundquist, D. C., Keydan, G., & Leavitt, B. (2003). Remote estimation of leaf area index and green leaf biomass in maize canopies. *Geophysical research letters*, 30(5).
- Gitelson, A.A., Keydan, G.P. and Merzlyak, M.N., 2006. Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher plant leaves. *Geophysical research letters*, 33(11).
- Grünhage, L., Jäger, H. J., Haenel, H. D., Löpmeier, F. J., & Hanewald, K. (1999). The European critical levels for ozone: improving their usage. *Environmental pollution*, 105(2), 163-173.
- Haboudane, D., Tremblay, N., Miller, J. R., & Vigneault, P. (2008). Remote estimation of crop chlorophyll content using spectral indices derived from hyperspectral data. *IEEE Transactions on Geoscience and remote Sensing*, 46(2), 423-437.
- Haddad, N. M., Brudvig, L. A., Clobert, J., Davies, K. F., Gonzalez, A., Holt, R. D., ... & Townshend, J. R. (2015). Habitat fragmentation and its lasting impact on Earth's ecosystems. *Science advances*, 1(2), e1500052.
- Horler, D. N. H., Dockray, M., & Barber, J. J. I. J. O. R. S. (1983). The red edge of plant leaf reflectance. *International journal of remote sensing*, 4(2), 273-288.
- Huete, A., Justice, C., & Van Leeuwen, W. (1999). MODIS vegetation index (MOD13). *Algorithm theoretical basis document*, 3(213), 295-309.
- Hunt Jr, E. R., Daughtry, C. S. T., Eitel, J. U., & Long, D. S. (2011). Remote sensing leaf chlorophyll content using a visible band index. *Agronomy journal*, 103(4), 1090-1099.
- Husen, A. (2021). Morpho-anatomical, physiological, biochemical and molecular responses of plants to air pollution. In *Harsh Environment and Plant Resilience: Molecular and Functional Aspects* (pp. 203-234). Cham: Springer International Publishing.
- IPA – Instituto de Pesquisas Ambientais. Inventário Florestal (2020). Disponível em: <<https://indd.adobe.com/view/a5aba10f-0090-4109-ac1c-944c8260b1ff>>. Acesso em mar. 2024.
- Jakovljević, T., Lovreškov, L., Jelić, G., Anav, A., Popa, I., Fornasier, M. F., ... & De Marco, A. (2021). Impact of ground-level ozone on Mediterranean forest ecosystems health. *Science of the Total Environment*, 783, 147063.
- Jin, Z., Yan, D., Zhang, Z., Li, M., Wang, T., Huang, X., Xie, M., Li, S. and Zhuang, B., 2023. Effects of elevated ozone exposure on regional meteorology and air quality in China through ozone-vegetation coupling. *Journal of Geophysical Research: Atmospheres*, 128(8), p.e2022JD038119.
- Jones, A. L., Ormondroyd, A., Hayes, F., & Jeffers, E. S. (2024). Reflections of stress: Ozone damage in broadleaf saplings can be identified from hyperspectral leaf reflectance. *Environmental Pollution*, 360, 124642.
- Jordan, C. F. (1969). Derivation of leaf-area index from quality of light on the forest floor. *Ecology*, 50(4), 663-666.

- Kondrat, H., Aragaki, S., & Gomes, E. P. C. (2020). Plant community dynamics in an urban forest fragment of the São Paulo Metropolitan Area, Brazil. *Hoehnea*, 47, e342019.
- Liu, W. T. H. (2015). *Aplicações de sensoriamento remoto*. Oficina de Textos.
- Louhaichi, M., Borman, M. M., & Johnson, D. E. (2001). Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International*, 16(1), 65-70.
- Maccioni, A., Agati, G., & Mazzinghi, P. (2001). New vegetation indices for remote measurement of chlorophylls based on leaf directional reflectance spectra. *Journal of Photochemistry and Photobiology B: Biology*, 61(1-2), 52-61.
- Martins, L. D., & Andrade, M. D. F. (2008). Ozone formation potentials of volatile organic compounds and ozone sensitivity to their emission in the megacity of São Paulo, Brazil. *Water, Air, and Soil Pollution*, 195, 201-213.
- Merzlyak, M. N., Gitelson, A. A., Chivkunova, O. B., & Rakitin, V. Y. (1999). Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologia plantarum*, 106(1), 135-141.
- Metzger, J. P., Alves, L. F., Goulart, W., Teixeira, A. M. D. G., Simões, S. J. C., & Catharino, E. L. M. (2006). Uma área de relevante interesse biológico, porém pouco conhecida: a Reserva Florestal do Morro Grande. *Biota neotropica*, 6.
- Mitchell, M. G., & Devisscher, T. (2022). Strong relationships between urbanization, landscape structure, and ecosystem service multifunctionality in urban forest fragments. *Landscape and Urban Planning*, 228, 104548.
- Moura, B. B., Alves, E. S., Marabesi, M. A., de Souza, S. R., Schaub, M., & Vollenweider, P. (2018). Ozone affects leaf physiology and causes injury to foliage of native tree species from the tropical Atlantic Forest of southern Brazil. *Science of the Total Environment*, 610, 912-925.
- Moura, B. B., de Souza, S. R., & Alves, E. S. (2014). Response of Brazilian native trees to acute ozone dose. *Environmental Science and Pollution Research*, 21, 4220-4227.
- Nakamura, Y., Tsujimoto, K., Ogawa, T., Noda, H. M., & Hikosaka, K. (2024). Correction of photochemical reflectance index (PRI) by optical indices to predict non-photochemical quenching (NPQ) across various species. *Remote Sensing of Environment*, 305, 114062.
- Nastri, V. D. F., Catharino, E. L. M., Rossi, L., Barbosa, L. M., Pirré, É., Bedinelli, C., ... & da Costa, M. P. (1992). Estudos fitossociológicos em uma área do Instituto de Botânica de São Paulo utilizados em programas de educação ambiental. *Revista do Instituto Florestal*, 4(1), 219-225.
- Obregón, G. O., Marengo, J. A., & Nobre, C. A. (2014). Rainfall and climate variability: long-term trends in the Metropolitan Area of São Paulo in the 20th century. *Climate research*, 61(2), 93-107.
- Oliveira, D. P. (2008). Poluentes da atmosfera. In *Fundamentos de toxicologia* (pp. 142-164).
- Pell, E. J., Sinn, J. P., Brendley, B. W., Samuelson, L., Vinten-Johansen, C., Tien, M., & Skillman, J. (1999). Differential response of four tree species to ozone-induced

- acceleration of foliar senescence. *Plant, Cell & Environment*, 22(7), 779-790.
- Penuelas, J., Baret, F., & Filella, I. (1995). Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance. *Photosynthetica*, 31(2), 221-230.
- Piñero Sánchez, M., de Oliveira, A. P., Varona, R. P., Tito, J. V., Codato, G., Ribeiro, F. N. D., ... & Silveira, L. C. D. (2020). Rawinsonde-based analysis of the urban boundary layer in the metropolitan region of São Paulo, Brazil. *Earth and Space Science*, 7(2), e2019EA000781.
- Ponzoni, F. J., & Disperati, A. A. (2001). Comportamento espectral da vegetação. *Sensoriamento remotoreflectância dos alvos naturais*. Brasília, DF: Universidade de Brasília, 157-99.
- Ponzoni, F. J., Shimabukuro, Y. E., & Kuplich, T. M. (2015). *Sensoriamento remoto da vegetação*. Oficina de textos.
- Roujean, J. L., & Breon, F. M. (1995). Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote sensing of Environment*, 51(3), 375-384.
- Rouse Jr, J. W., Haas, R. H., Deering, D. W., Schell, J. A., & Harlan, J. C. (1974). *Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation* (No. E75-10354).
- Sampaio, H. S., Bourscheidt, V., Sarracini, L. H., Jorge, L. D. C., Bettiol, G. M., & Bernardi, A. D. C. (2020). Comparação entre índices de vegetação obtidos por imagens aéreas com veículo aéreo não tripulado (VANT) e satélite. *Revista Brasileira de Engenharia de Biosistemas*, 14(2), 111-124.
- Schuch, D., de Freitas, E. D., Espinosa, S. I., Martins, L. D., Carvalho, V. S. B., Ramin, B. F., ... & de Fatima Andrade, M. (2019). A two decades study on ozone variability and trend over the main urban areas of the São Paulo state, Brazil. *Environmental Science and Pollution Research*, 26, 31699-31716.
- Shimizu, Y., Lu, Y., Aono, M., & Omasa, K. (2019). A novel remote sensing-based method of ozone damage assessment effect on Net Primary Productivity of various vegetation types. *Atmospheric Environment*, 217, 116947.
- Silva Júnior, R. S. D., Oliveira, M. G. L. D., & Andrade, M. D. F. (2009). Weekend/weekday differences in concentrations of ozone, nox, and non-methane hydrocarbon in the metropolitan area of São Paulo. *Revista Brasileira de Meteorologia*, 24, 100-110.
- Simberloff, D. (1992). Do species-area curves predict extinction in fragmented forest. *Tropical deforestation and species extinction*, 75-89.
- Tabarelli, M., Aguiar, A. V., Girao, L. C., Peres, C. A., & Lopes, A. V. (2010). Effects of pioneer tree species hyperabundance on forest fragments in northeastern Brazil. *Conservation Biology*, 24(6), 1654-1663.
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150.
- União Europeia (2008). *Diretiva 2008/50/CE do Parlamento Europeu e do Conselho, de*

21 de maio de 2008, relativa à qualidade do ar ambiente e a um ar mais limpo na Europa. Jornal Oficial da União Europeia, L 152, 1-44.

Valdambrini, N. M., & Ribeiro, F. N. D. (2021). Avaliação das Ultrapassagens dos Padrões de Ozônio Troposférico no Estado de São Paulo de 2014 a 2019. *Revista Brasileira de Meteorologia*, 36(4), 735-747.

**CAPÍTULO III: INFLUÊNCIA DOS NÍVEIS DE BIOMASSA
DE FRAGMENTOS FLORESTAIS NA RESPOSTA DOS ÍNDICES
DE VEGETAÇÃO À EXPOSIÇÃO AO OZÔNIO TROPOSFÉRICO**

1. Introdução

O sensoriamento remoto surge como uma alternativa para superar as limitações das medições em campo, permitindo uma avaliação mais abrangente da floresta (Costa, Quintanilha, 2024). A integração dos dados coletados em campo aos obtidos por sensoriamento remoto possibilita uma caracterização mais precisa da floresta, combinando as informações sobre a biodiversidade obtidas em campo, com as medidas estruturais do componente florestal, obtida por equipamentos sem o contato direto com a vegetação, facilitando o processo de obtenção dos dados, com maior flexibilidade operacional (Foody, 2003).

Estudos indicam que diferentes formas de sensoriamento remoto, como imagens de satélite e fotografias aéreas, têm sido eficazes no monitoramento de florestas úmidas (Dupuis *et al.*, 2020). Equipamentos simples, como câmeras RGB embarcadas em Veículos Aéreos Não Tripulados (VANTs), têm demonstrado potencial na obtenção de informações sobre padrões do dossel e sobre a biomassa acima do solo de indivíduos arbóreos (Chianucci *et al.*, 2016; Shimabuku; Konoshima & Ota, 2023).

No Brasil, estudos recentes têm utilizado VANTs para avaliar a flutuação da biomassa florestal, em pequena escala, capturando alterações na floresta em função da sazonalidade e de mudanças nos padrões climáticos (Simonetti *et al.*, 2023). Na Mata Atlântica, o sensoriamento remoto já é utilizado para capturar mudanças na dinâmica vegetacional ao longo do tempo e pesquisas indicam que florestas em amadurecimento apresentam aumento no sequestro de carbono (Machado *et al.*, 2019).

Além dos fatores climáticos, a qualidade do ar também influencia a capacidade das florestas de acumular biomassa. O ozônio troposférico, em particular, pode causar estresse oxidativo nas plantas, reduzindo a fotossíntese e afetando o crescimento da vegetação, abscisão acelerada das folhas, causando distúrbios na alocação de carbono e redução na capacidade de ganho de biomassa (Agrawal *et al.* 2021). O índice AOT40 (Accumulated Ozone over a Threshold of 40 ppb) é amplamente utilizado para avaliar o impacto da exposição ao ozônio na vegetação e tem sido associado à redução da produtividade florestal (Mills *et al.*, 2011). Assim, a exposição prolongada ao ozônio pode limitar a capacidade das florestas secundárias da Mata Atlântica de sequestrar carbono e recuperar sua biomassa.

Os fragmentos de florestas secundárias, que residem em áreas urbanas, desempenham um papel crucial na manutenção da biodiversidade endêmica do bioma e no fornecimento de

serviços ecossistêmicos (Carneiro *et al*, 2023). Além do sequestro de carbono, contribuem para a regulação térmica, preservação da integridade do solo, ciclagem de nutrientes e remoção de poluentes atmosféricos (Mitchell & Devisscher, 2022). No entanto, quando submetidas a impactos antrópicos contínuos, como o aumento da poluição atmosférica e o estresse causado pelo ozônio, sua capacidade de acúmulo de biomassa pode ser comprometida (Pawar *et al*, 2014), reforçando a necessidade de ferramentas eficazes para o monitoramento da saúde da floresta, como o sensoriamento remoto.

O uso de sensoriamento remoto permite monitorar a resposta da vegetação ao ozônio, o que pode identificar alterações na estrutura do dossel e na produtividade da floresta. Como apresentado no Capítulo II, índices de vegetação podem auxiliar na detecção de sintomas de estresse na vegetação relacionados ao ozônio, oferecendo uma visão detalhada da dinâmica da floresta e ajudando a modelar e definir os melhores períodos para o monitoramento, especialmente em áreas urbanas, onde a concentração de ozônio é elevada devido às emissões antropogênicas (Martins *et al*, 2025)

Nesse contexto, foi demonstrado no capítulo II que os índices de vegetação GLI, PSRI e TCI apresentam forte correlação com a AOT40, possibilitando a formulação de um modelo preditivo para estimar o impacto do ozônio (O_3) na taxa fotossintética e na senescência foliar. Com base nesses resultados, o presente estudo buscou avançar na compreensão desses efeitos ao investigar se a quantidade de biomassa interfere na sensibilidade da vegetação ao poluente. Para isso, empregou-se o modelo preditivo previamente desenvolvido para avaliar como diferentes níveis de biomassa influenciam as respostas dos índices de vegetação à exposição ao ozônio.

Dado que plantas jovens e maduras podem responder de maneira distinta ao estresse oxidativo causado pelo O_3 , este estudo analisou a influência da AOT40 sobre os índices de vegetação em parcelas permanentes com diferentes quantidades de biomassa. Foram comparadas áreas com baixa biomassa, compostas por árvores menores e mais jovens; biomassa intermediária; e biomassa elevada, representando parcelas dominadas por indivíduos de maior porte e idade avançada. Essa abordagem permitiu verificar se florestas mais densas e maduras apresentam maior resiliência ou, ao contrário, se estão mais suscetíveis aos efeitos da poluição atmosférica.

2. Material e Métodos

2.1 Localização da área de estudo

As áreas de estudo analisadas neste capítulo são as mesmas utilizadas por Martins *et al.* (2025), descritas no Capítulo II, subitem 2.1 e ilustrada na Figura 5 desta dissertação, descritas como Parque estadual das Fontes do Ipiranga (PEFI), Reserva Florestal do Instituto de Biociências da Universidade de São Paulo (RFIB) / Matão IAG e Reserva Florestal do Morro Grande (RFMG).

2.2 Cálculo da Biomassa em Campo

Foi feita a amostragem dos dados de altura e diâmetro na altura do peito (DAP) de todos os indivíduos arbóreos das parcelas da área de estudo, com perímetro na altura do peito a partir de 15 cm, além da identificação botânica a partir de consulta em literatura especializada. A biomassa foi calculada a partir da equação disponível em Chave *et al* (2014):

$$AGB_{est} = 0.0673 \times (\rho D^2 H)^{0.976}$$

onde “ ρ ” é a densidade específica da madeira em g/cm³ consultada em Chave *et al.* (2009), “D” o DAP em cm e “H” a altura em metros.

Os dados de biomassa foram calculados ao nível de subparcela, que foram classificadas como de baixa biomassa, média e alta biomassa, de acordo com a distribuição estatística dos dados, de acordo com a Tabela 6.

Tabela 6: Critério adotado para a classificação dos tipos de biomassa.

Divisão estatística	Classificação
Primeiro quartil (Q1): 25% dos dados mais baixos	Biomassa Baixa
Segundo quartil (Q2)	Biomassa Média
Terceiro quartil (Q3): 75% dos dados mais baixos.	Biomassa Alta

2.3 Análise de Dados

Para a produção dos índices de vegetação para serem utilizados como forma de avaliação da saúde de vegetacional, seguiu-se a metodologia descrita no Capítulo II desta dissertação, gerando-se os ortomosaicos para cada banda espectral, aplicando-se a eles os índices de vegetação com maior capacidade explicativa, utilizados neste trabalho. Também constam no capítulo citado, a produção dos dados referentes à modelagem espacial da concentração de O₃ troposférico para a obtenção da AOT40.

Para verificar qual a sensibilidade dos diferentes níveis de biomassa à poluição por O₃, foi aplicado o Modelo Linear de Efeitos Mistos (GLMM), para as classes de baixa, média e alta biomassa, obtidas através da amostragem em campo, onde o valor do índice de vegetação foi definido como variável resposta e, como variável explicativa a AOT40 e sazonalidade. Como efeito aleatório, foram incluídas as seis parcelas pertencentes às três áreas de estudo, de forma a capturar a variação intrínseca entre as áreas e parcelas.

3. Resultados

3.1 Biomassa nas áreas estudadas

A partir da amostragem dos indivíduos arbóreos nas parcelas estudadas, aplicou-se a equação de Chave *et al.* (2014) para o cálculo da biomassa para as subparcelas nas áreas de estudo. De acordo com a Tabela 7, RFMG apresenta maior biomassa acima do solo, apresentando mais que o dobro da biomassa encontrada na RFIB. No PEFI, foi encontrado um valor intermediário de biomassa.

Tabela 7: Biomassa total medida por área de estudo.

Área de Estudo	PEFI	RFMG	RFIB
Biomassa (t/ha)	165,38	283,38	136,38

Com relação aos valores de biomassa por indivíduo arbóreo, de acordo com a Figura 30, tanto PEFI quanto RFMG apresentam uma distribuição dos dados mais restrita que a RFIB, além de apresentarem as médias distantes das medianas, revelando que poucos indivíduos são responsáveis pelo alto valor de biomassa nas duas áreas, já na RFIB, uma maior quantidade de indivíduos arbóreos é responsável pela obtenção dos valores de biomassa absoluta, portanto

composta por um conjunto de indivíduos de porte médio.




Figura 30 - Boxplot da distribuição dos dados de biomassa por indivíduo arbóreo nas 3 áreas de estudo.

Para a classificação da biomassa, verificou-se a distribuição dos dados de biomassa por parcela, onde a média é de 200 t/ha. Como ilustrado na Figura 31, a biomassa encontrada nas parcelas da RFMG ultrapassou valores de 400 t/ha para algumas parcelas, chegando a 905,06 t/ha para a parcela 12, apresentando uma grande disparidade nas biomassas encontradas entre as parcelas de uma mesma área. Para PEFI e RFIB, os valores não ultrapassaram os 400 t/ha, porém também demonstram uma variação ao apresentarem parcelas com a biomassa acima dos 300 t/ha e outras com valor inferior a 50 t/ha.




Figura 31 - Biomassa acumulada por parcela nas áreas de estudo.

Após a classificação das parcelas de acordo com sua quantidade de biomassa, como demonstrado na Tabela 8, foi possível verificar a predominância de parcelas de alta e média biomassa na RFMG, ocorrendo apenas duas parcelas de biomassa baixa. No PEFI, há mais parcelas com biomassa alta e média, com quatro e 14 parcelas, respectivamente. Na RFIB, parcelas com a biomassa média e baixa ocorrem em mesmo número, com apenas duas parcelas de baixa biomassa.

Tabela 8: Gráfico da quantidade de parcelas por classe de biomassa nas áreas estudadas.

Classe de Biomassa	PEFI	RFMG	RFIB
Alta	4	6	2
Média	10	12	9
Baixa	6	2	9

3.2 Índices de Vegetação e Biomassa

Para avaliação da relação entre a biomassa e a poluição por O_3 , foi aplicado um modelo linear de efeitos mistos, visando testar como cada classe de biomassa é afetada pelo poluente. Como métrica de saúde vegetacional, os índices de vegetação foram definidos como variável resposta, enquanto AOT40 e sazonalidade foram consideradas variáveis fixas. Foram selecionados os índices que melhor representaram a relação entre AOT40 e a saúde da vegetação conforme apresentado no Capítulo II desta dissertação, a saber GLI, PSRI, TCI e NDVI.

A Tabela 9 apresenta os resultados da capacidade explicativa do modelo para os três níveis de biomassa nos diversos índices testados. Observa-se uma variação na interação entre AOT40 e os índices de vegetação, dependendo do nível de biomassa que está sendo estudado. Os maiores valores encontrados para o R^2_m , indicam que o efeito da AOT40 ao longo das estações é explicado em valores superiores a 65% nos índices TCI para parcelas de alta e média biomassa. No entanto, esse efeito é menos expressivo em parcelas de baixa biomassa, onde o modelo explica apenas 44% dos dados.

Tabela 9: Valores de coeficiente de determinação marginal, representando a variância explicada pelos efeitos fixos (R^2m) e coeficiente de determinação condicional, representando a variância explicada pelos efeitos fixos e aleatórios combinados (R^2c) obtidos a partir do modelo linear de efeitos mistos para a relação entre os índices de vegetação estudados e a AOT40.

Índice	Nível de Biomassa	R^2m	R^2c
TCI	Biomassa Alta	0.71	0.79
	Biomassa Média	0.67	0.78
	Biomassa Baixa	0.44	0.76
GLI	Biomassa Média	0.70	0.75
	Biomassa Alta	0.68	0.69
	Biomassa Baixa	0.66	0.74
PSRI	Biomassa Média	0.62	0.68
	Biomassa Baixa	0.61	0.68
	Biomassa Alta	0.61	0.62
NDVI	Biomassa Média	0.53	0.71
	Biomassa Alta	0.49	0.63
	Biomassa Baixa	0.37	0.79

Para o GLI, o modelo explica a variação nos índices de vegetação entre 66 e 70% para todas as classes de biomassa, com uma diferença discreta entre os índices. O modelo de biomassa média obteve o maior valor no R^2m , seguido pelas parcelas de alta e baixa biomassa. Já PSRI obteve valores entre 61 e 66% de explicabilidade do modelo, porém a média e baixa biomassa obtiveram os maiores valores. O NDVI apresentou os menores valores de explicação e teve uma performance melhor quando utilizado para as parcelas de maior biomassa.

Foi aplicado o Modelo Linear de Efeitos onde foi verificada a relação entre os índices de vegetação e a AOT40 para os diferentes níveis de biomassa, separados pelas 4 estações do ano. Identificou-se uma variação sazonal nos índices de vegetação TCI, GLI e NDVI, onde no verão e primavera, os valores refletem maior vigor da vegetação e capacidade fotossintética, e no outono e inverno há a diminuição dos valores dos índices de vegetação pela diminuição da disponibilidade de água e luminosidade.

As retas ajustadas separando as classes de biomassa demonstram que há uma resposta diversa em relação a AOT40 durante as estações do ano. Para o GLI (Figura 32), durante a primavera, observa-se uma influência negativa da AOT40 nas parcelas de alta biomassa, enquanto nas parcelas de baixa e média biomassa esse efeito é mais discreto. No verão. A influência negativa se torna acentuada, especialmente nas parcelas de média e alta biomassa. Para inverno e outono, a relação AOT40 e GLI é positiva, destacando que, no inverno, o efeito positivo é maior nas parcelas de baixa biomassa e menor para as de média e baixa biomassa.




Figura 32: Curva de regressão representando a relação entre o AOT40 e GLI no Modelo Linear de Efeitos Mistos em diferentes estações do ano (1) primavera, (2) verão, (3) outono e (4) inverno.

Para o TCI (Figura 33), a relação na primavera apresenta pouca variação, com a AOT40 influenciando positivamente as parcelas de baixa biomassa. No verão, observa-se um efeito negativo da AOT40 em todas as classes de biomassa, sendo mais intenso nas parcelas de baixa

e média biomassa em comparação com as de alta biomassa. No outono, as parcelas com biomassa alta e média são mais positivamente afetadas pela AOT40. Já no inverno, os resultados são semelhantes aos do GLI, com uma relação fortemente positiva para as parcelas de baixa biomassa, seguido por média e alta biomassa, respectivamente.




Figura 33: Curva de regressão representando a relação entre o AOT40 e TCI no Modelo Linear de Efeitos Mistos em diferentes estações do ano (1) primavera, (2) verão, (3) outono e (4) inverno.

Para o NDVI (Figura 34), as parcelas de baixa e média biomassa apresentaram uma relação positiva com a AOT40 na primavera, verão e outono. Já as parcelas de alta biomassa correlacionaram negativamente com AOT40 no verão e primavera, apresentando uma relação positiva no outono. No inverno, apenas as parcelas de baixa biomassa mantiveram uma relação positiva com AOT40 enquanto a relação para as parcelas de alta foi fortemente negativa.




Figura 34: Curva de regressão representando a relação entre o AOT40 e NDVI no Modelo Linear de Efeitos Mistos em diferentes estações do ano (1) primavera, (2) verão, (3) outono e (4) inverno.

Já no índice PSRI (Figura 35), a resposta do modelo é inversa, pois trata-se de um índice que mede a senescência da vegetação. Na primavera, o modelo indica que a senescência é menos pronunciada para as parcelas de baixa biomassa, seguidas pelas de média biomassa, enquanto nas parcelas de alta biomassa, a relação entre AOT40 e a senescência foliar é discreta. No verão, as parcelas com baixa biomassa são as mais afetadas pela senescência foliar. No outono, a relação é semelhante para as três classes de biomassa, com uma diminuição da senescência. No inverno, a relação entre senescência e AOT40 é negativa, com as parcelas de baixa e média biomassa apresentando uma maior redução da senescência foliar com o aumento da AOT40, em comparação com as parcelas de alta biomassa.




Figura 35: Curva de regressão representando a relação entre o AOT40 e PSRI no Modelo Linear de Efeitos Mistos em diferentes estações do ano (1) primavera, (2) verão, (3) outono e (4) inverno.

4. Discussão

A distribuição da biomassa por indivíduo arbóreo revelou padrões distintos entre as áreas estudadas. No PEFI e na RFIB, poucos indivíduos foram responsáveis pelos altos valores de biomassa, enquanto na RFMG a distribuição foi mais homogênea entre os indivíduos. Essas diferenças podem estar associadas a características ecológicas específicas de cada área, incluindo a densidade de árvores, a idade da floresta e as pressões ambientais (Chave *et al.* 2014) Além disso, a grande variação entre as parcelas da RFMG sugere uma heterogeneidade estrutural significativa dentro da área.

A relação entre a biomassa e os índices de vegetação indicou que a influência da AOT40 depende do nível de biomassa das parcelas. O modelo linear de efeitos mistos mostrou que os índices TCI e GLI foram os mais sensíveis à variação sazonal e à presença do poluente, explicando mais de 65% da variação nas parcelas de biomassa média e alta. Esses resultados sugerem que tais índices são indicadores eficazes do impacto O_3 na vegetação, especialmente em áreas com maior biomassa, onde o efeito da AOT40 foi mais pronunciado. Corroborando os resultados obtidos no capítulo anterior, o GLI demonstrou maior eficiência que o TCI e o

NDVI na detecção dos efeitos do O_3 , apresentando uma alta capacidade de explicação para todas as classes de biomassa estudadas. O TCI, por sua vez, mostrou-se mais eficiente apenas na detecção dos impactos do O_3 em áreas de biomassa média e alta.

Os índices de vegetação responderam de forma distinta à exposição ao O_3 ao longo das estações do ano. No GLI, a AOT40 teve um impacto negativo mais acentuado nas parcelas de alta biomassa durante o verão, e nas parcelas de biomassa média e alta durante a primavera. Estudos como Kolb *et al.* (1997), indicam que para florestas maduras, as formações arbóreas mais altas, apresentam maior capacidade de absorção de O_3 troposférico em comparação com formações florestais mais baixas. Considerando que a altura das árvores é um fator importante na equação de cálculo da biomassa, e é possível inferir que parcelas com menor biomassa sejam menos afetadas pelo O_3 , uma vez que árvores mais baixas absorvem menos do poluente.

O estudo de Kinose *et al.* (2017), explica que há maior exposição às concentrações de ozônio no alto do dossel, ao encontrar uma relação entre a altura das folhas e a sensibilidade ao O_3 , sugerindo que folhas mais expostas à luz também estão mais suscetíveis à absorção cumulativa de O_3 . Esse efeito pode contribuir para o impacto mais pronunciado do poluente em vegetação mais antiga, composta por árvores mais altas.

No verão, o TCI apresentou um efeito negativo mais intenso nas parcelas de biomassa média e baixa. Nesta mesma estação, os resultados do PSRI indicam que a senescência foi acelerada em parcelas de baixa biomassa, o que difere do encontrado para o GLI. Além disso, para todas as demais estações, as parcelas de biomassa baixa foram as menos impactadas pelo O_3 .

Os índices TCI e PSRI incluem em suas equações o comprimento de onda da borda do vermelho, que, segundo com Horler *et al.* (1983), possui maior capacidade de penetração na camada de folhas sobrepostas que os comprimentos de onda do visível e infravermelho próximo, utilizados no GLI e NDVI. Essa característica permite que o TCI e o PSRI sejam mais sensíveis a alterações estruturais dentro do dossel, como variações na senescência foliar.

O estudo de Brendley e Pell (1998) sugere que a tolerância ao O_3 pode estar relacionada à eficiência na alocação de compostos proteicos associados à fotossíntese. Segundo os autores, uma maior abscisão foliar nas camadas internas do dossel pode gerar um efeito compensatório, realocando recursos de folhas mais velhas para folhas novas em ramos externos, o que aumenta a capacidade fotossintética desses ramos. Esse fenômeno poderia explicar o efeito observado no verão, em que o aumento da AOT40 intensificou a senescência nas parcelas de baixa

biomassa (segundo os resultados do PSRI) e reduziu os valores do TCI.

No inverno e no outono, a relação positiva entre AOT40 e GLI sugere que outros fatores ambientais podem estar compensando os efeitos negativos do O₃, especialmente em parcelas de baixa biomassa. Nessas parcelas, o modelo apresentou menor capacidade de explicação, permitindo inferir que árvores mais jovens são mais afetadas por outras variáveis que não a AOT40, possivelmente por variáveis meteorológicas do que árvores de maior biomassa.

O NDVI, por sua vez, apresentou menor capacidade explicativa no modelo, sugerindo que esse índice pode não ser o mais adequado para avaliar os impactos do O₃ em diferentes classes de biomassa. No entanto, seu comportamento sazonal revelou diferenças importantes entre as áreas, com impactos negativos nas parcelas de alta biomassa na primavera, verão e inverno. Esse padrão pode estar relacionado à fisiologia das plantas e à disponibilidade sazonal de recursos como luz e água.

5. Conclusão

A complexidade da interação entre biomassa, poluição por O₃ e resposta vegetacional é claramente evidenciada pelos resultados apresentados. As variações observadas nos índices de vegetação ressaltam a importância de se utilizar múltiplas métricas para avaliar os impactos da AOT40 na vegetação, uma vez que cada índice oferece uma perspectiva distinta dos efeitos do poluente. Além disso, as diferenças sazonais indicam que fatores ambientais, como temperatura, umidade do solo e disponibilidade de luz, influenciam de forma significativa a resposta das plantas ao O₃ troposférico.

Para um entendimento mais profundo desses mecanismos, estudos futuros devem integrar variáveis ecológicas, fisiológicas e bioquímicas adicionais, como a estrutura da comunidade arbórea, sua diversidade e a classe sucessional das espécies, trocas gasosas e medidas metabólicas bem como variáveis ambientais mais detalhadas. Tais abordagens poderiam ajudar a desvendar os processos que regulam as reações da vegetação à poluição atmosférica, ampliando nossa compreensão sobre os efeitos do O₃ nos ecossistemas tropicais e subtropicais, por meio de aplicação de sensoriamento remoto.

Referências Bibliográficas

- Agrawal, S. B., Agrawal, M., & Singh, A. (Eds.). (2021). *Tropospheric Ozone: A hazard for vegetation and human health*. Cambridge Scholars Publishing.
- Brendley, B. W., & Pell, E. J. (1998). Ozone-induced changes in biosynthesis of Rubisco and associated compensation to stress in foliage of hybrid poplar. *Tree Physiology*, 18(2), 81-90.
- Carneiro, M. S., Ribeiro, B. R., Campos, C. C. F., de Souza Almeida, H., de Araujo, M. L., dos Santos, F. A. M., & Ramos, F. N. (2023). Small forest fragments and their importance for conservation of tree communities in Atlantic semideciduous forest. *Iheringia, Série Botânica*, 78.
- Chave, J., Coomes, D., Jansen, S., Lewis, S. L., Swenson, N. G., & Zanne, A. E. (2009). Towards a worldwide wood economics spectrum. *Ecology letters*, 12(4), 351-366.
- Chave, J., Réjou-Méchain, M., Búrquez, A., Chidumayo, E., Colgan, M. S., Delitti, W. B., ... & Vieilledent, G. (2014). Improved allometric models to estimate the aboveground biomass of tropical trees. *Global change biology*, 20(10), 3177-3190.
- Chianucci, F., Disperati, L., Guzzi, D., Bianchini, D., Nardino, V., Lastri, C., ... & Corona, P. (2016). Estimation of canopy attributes in beech forests using true colour digital images from a small fixed-wing UAV. *International journal of applied earth observation and geoinformation*, 47, 60-68.
- Costa, J. D. M. D., & Quintanilha, J. A. (2024). Uso das Geotecnologias na Estimativa de Biomassa e Carbono Florestal: uma revisão. *Revista Brasileira de Geografia Física*, 17(2), 1127-1146.
- Dupuis, C., Lejeune, P., Michez, A., & Fayolle, A. (2020). How can remote sensing help monitor tropical moist forest degradation?—a systematic review. *Remote Sensing*, 12(7), 1087.
- Foody, G. M. (2003). Remote sensing of tropical forest environments: towards the monitoring of environmental resources for sustainable development. *International journal of remote sensing*, 24(20), 4035-4046.
- Horler, D. N. H., Dockray, M., & Barber, J. J. I. J. O. R. S. (1983). The red edge of plant leaf reflectance. *International journal of remote sensing*, 4(2), 273-288.
- Kinose, Y., Fukamachi, Y., Okabe, S., Hiroshima, H., Watanabe, M. and Izuta, T., 2017. Photosynthetic responses to ozone of upper and lower canopy leaves of *Fagus crenata* Blume seedlings grown under different soil nutrient conditions. *Environmental Pollution*, 223, pp.213-222.
- Kolb, T. E., Fredericksen, T. S., Steiner, K. C., & Skelly, J. M. (1997). Issues in scaling tree size and age responses to ozone: a review. *Environmental Pollution*, 98(2), 195-208.
- Machado, A., Martins, A. P. M., Sanquetta, C. R., Dalla Corte, A. P., Wojciechowski, J., do Amaral Machado, S., ... & de Mattos Landim, I. A. (2019). Dinâmica do volume, biomassa e carbono na mata atlântica por ferramenta de detecção de mudanças. *Nativa*, 7(4), 437-444.

- Mills, G., Hayes, F., Simpson, D., Emberson, L., Norris, D., Harmens, H., & Büker, P. (2011). Evidence of widespread effects of ozone on crops and (semi-) natural vegetation in Europe (1990–2006) in relation to AOT40-and flux-based risk maps. *Global Change Biology*, 17(1), 592-613.
- Mitchell, M. G., & Devisscher, T. (2022). Strong relationships between urbanization, landscape structure, and ecosystem service multifunctionality in urban forest fragments. *Landscape and Urban Planning*, 228, 104548.
- Pawar, G. V., Singh, L., Jhariya, M. K., & Sahu, K. P. (2014). Effect of anthropogenic disturbances on biomass and carbon storage potential of a dry tropical forest in India. *Journal of Applied and Natural Science*, 6(2), 383-392.
- Pell, E. J., Sinn, J. P., Brendley, B. W., Samuelson, L., Vinten-Johansen, C., Tien, M., & Skillman, J. (1999). Differential response of four tree species to ozone-induced acceleration of foliar senescence. *Plant, Cell & Environment*, 22(7), 779-790.
- Shimabuku, F., Konoshima, M., & Ota, I. (2023). Diameter and stem volume estimation based on under canopy UAV-SfM-MVS survey approach in subtropical forest of Okinawa Island, Japan. *FORMATH*, 22, 22-004.
- Simonetti, A., Araujo, R. F., Celes, C. H. S., da Silva e Silva, F. R., dos Santos, J., Higuchi, N., ... & Magnabosco Marra, D. (2023). Canopy gaps and associated losses of biomass—Combining UAV imagery and field data in a central Amazon forest. *Biogeosciences*, 20(17), 3651-3666.

CONCLUSÃO GERAL

Os resultados desta dissertação evidenciam a relação entre os índices de vegetação gerados por sensoriamento remoto por VANT e as concentrações de ozônio potencialmente danosas ao ecossistema florestal na RMSP. No Capítulo II, verificou-se que a sazonalidade afeta a resposta da vegetação pela influência da disponibilidade de recurso hídrico, variação de temperatura e poluentes que são responsáveis pela integridade do tecido foliar. Foi encontrado um efeito significativo da AOT40 sobre a vegetação nativa, com intensidades diferentes ao longo do ano. Para o verão um efeito negativo e para outono e inverno um efeito positivo, permitindo sugerir que existe um período do ano em que a vegetação nativa é mais vulnerável às altas concentrações de O_3 , seja pela exposição direta a níveis acima dos considerados seguros, seja por fatores fisiológicos, como maior condutância estomática ou menor capacidade de defesa contra o estresse oxidativo.

Os resultados do Capítulo III permitiram inferir que o ozônio afeta de maneira diferenciada as áreas florestais conforme a quantidade de biomassa presente. Além disso, os índices de vegetação analisados mostraram respostas distintas em cada classe de biomassa. Os achados reforçam a necessidade de compreender quais as características florestais determinam a variabilidade dos índices de vegetação em relação ao efeito do poluente, em especial ao poluente mais fitotóxico da atualidade, o ozônio. Além disso, recomenda-se uma investigação detalhada de como os índices de vegetação atuam em um ecossistema florestal complexo como a Mata Atlântica, levando em conta parâmetros como a biomassa, altura, projeção de copa, índice de área foliar e a biodiversidade local.

Embora se esperasse que o ozônio exercesse um efeito negativo sobre o tecido foliar, em ambos os capítulos foi identificada uma relação positiva entre O_3 e os índices de vegetação. Os fatores que explicam essa resposta no modelo ainda não estão totalmente esclarecidos e podem incluir tanto variáveis externas à planta, como características do solo e influência da radiação solar, quanto fatores intrínsecos, como mecanismos de proteção contra estresse oxidativo e estratégias fisiológicas, incluindo a realocação de recursos, conforme discutido na Seção 4 do Capítulo II.

Os resultados indicam que aproximadamente 35% da variabilidade observada nos índices de vegetação, mesmo nos modelos de melhor desempenho, ainda não foi explicada. Além de incorporar as variáveis abióticas mencionadas, a resposta dos índices de vegetação podem ser explicadas de forma mais adequada se as características da biodiversidade local forem consideradas. Uma abordagem com relação a quantidade de biomassa foi utilizada no Capítulo

III, porém outras características da vegetação poderiam ser utilizadas como o estágio sucessional e a famílias botânicas que ocorrem nas áreas estudadas.

Por fim espera-se que os dados obtidos possam embasar estudos que avaliem a interação da poluição em áreas maiores, de forma a extrapolar as informações obtidas nas parcelas para fragmentos florestais inteiros. Um melhor entendimento das relações entre os dados gerados por VANT, medições de campo e imagens de satélite, poderá contribuir para aprimorar a estimativa dos impactos do ozônio na vegetação, especialmente no que se refere à capacidade das florestas de prover serviços ecossistêmicos e à manutenção da biodiversidade endêmica.