



UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE FLORESTAS
CURSO DE GRADUAÇÃO EM ENGENHARIA FLORESTAL

RENNAN DOS PRAZERES SOUZA

DINÂMICA DO FOGO E MUDANÇAS DE USO E COBERTURA DO SOLO NA MATA
ATLÂNTICA FLUMINENSE: ANÁLISE MULTITEMPORAL COM O GOOGLE EARTH
ENGINE (1985-2023)

Prof. Dr. BRUNO ARAUJO FURTADO DE MENDONÇA
Orientador

SEROPÉDICA, RJ
JULHO – 2025



UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE FLORESTAS
CURSO DE GRADUAÇÃO EM ENGENHARIA FLORESTAL

RENNAN DOS PRAZERES SOUZA

DINÂMICA DO FOGO E MUDANÇAS DE USO E COBERTURA DO SOLO NA MATA
ATLÂNTICA FLUMINENSE: ANÁLISE MULTITEMPORAL COM O GOOGLE EARTH
ENGINE (1985-2023)

Monografia apresentada ao Curso de
Engenharia Florestal, como requisito
parcial para a obtenção do Título de
Engenheiro Florestal, Instituto de Florestas
da Universidade Federal Rural do Rio de
Janeiro.

Prof. Dr. BRUNO ARAUJO FURTADO DE MENDONÇA
Orientador

SEROPÉDICA, RJ
JULHO – 2025



HOMOLOGAÇÃO Nº 12 / 2025 - DeptSil (12.28.01.00.00.00.00.31)

Nº do Protocolo: 23083.034607/2025-82

Seropédica-RJ, 02 de julho de 2025.

**DINÂMICA DO FOGO E MUDANÇAS DE USO E COBERTURA DO SOLO
NA MATA ATLÂNTICA FLUMINENSE: ANÁLISE MULTITEMPORAL
COM O GOOGLE EARTH ENGINE (1985-2023)**

RENNAN DOS PRAZERES SOUZA

APROVADA EM: 02/07/2025

BANCA EXAMINADORA:

Prof. Dr. Bruno Araujo Furtado de Mendonça – UFRRJ (Orientador)

Prof. Dr. Marcel Carvalho Abreu – UFRRJ (Membro)

Yuri Wanick Loureiro de Sousa – Doutorando PPGCAF/UFRRJ (Membro)

(Assinado digitalmente em 02/07/2025 15:49)

BRUNO ARAUJO FURTADO DE MENDONÇA
PROFESSOR DO MAGISTERIO SUPERIOR
DeptSil (12.28.01.00.00.00.00.31)
Matrícula: 2145654

(Assinado digitalmente em 02/07/2025 16:00)

MARCEL CARVALHO ABREU
PROFESSOR DO MAGISTERIO SUPERIOR
DeptCAmb (12.28.01.00.00.00.00.29)
Matrícula: 3040039

(Assinado digitalmente em 03/07/2025 11:13)

YURI WANICK LOUREIRO DE SOUSA
DISCENTE
Matrícula: 20231007078

Visualize o documento original em <https://sipac.ufrrj.br/public/documentos/index.jsp>
informando seu número: **12**, ano: **2025**, tipo: **HOMOLOGAÇÃO**, data de emissão: **02/07/2025** e
o código de verificação: **3c78c0cb9f**

Dedico às sementes que germinam em solo degradado, aos pesquisadores que lutam nas trincheiras da ciência, e a todos que ainda acreditam na reconciliação entre homem e natureza.

AGRADECIMENTOS

Agradeço primeiramente à Universidade Federal Rural do Rio de Janeiro (UFRRJ) e ao Instituto de Florestas, pela infraestrutura, formação acadêmica e oportunidades que possibilitaram este estudo.

Aos professores do curso de Engenharia Florestal, cujo conhecimento compartilhado ao longo destes anos constitui a base intelectual que sustenta minha formação. Suas aulas, orientações e exemplos de dedicação científica foram fundamentais para meu desenvolvimento acadêmico e profissional.

Ao Prof. Dr. Bruno Araujo Furtado de Mendonça, pela orientação incansável, expertise científica e apoio incondicional em todas as etapas desta pesquisa. Sua visão crítica e incentivo foram fundamentais para a concretização deste trabalho.

Às agências de fomento CAPES e CNPq, pelo financiamento que viabilizou recursos essenciais para esta pesquisa.

À equipe do MapBiomas e ao Google Earth Engine, pelo acesso aos dados e tecnologias que tornaram possível esta análise multitemporal em escala regional.

Ao Yuri Wanick Loureiro de Sousa, pela colaboração fundamental na obtenção, interpretação e análise dos dados na plataforma Google Earth Engine.

Por fim, à minha família, pelo amor, paciência e incentivo constante durante toda a jornada acadêmica. Em especial a Katia Cristina Soares dos Prazeres, minha mãe, e a Josimara Ferreira Teodoro, cuja inspiração fortaleceu minha perseverança.

"Sozinho vamos mais rápido, juntos vamos mais longe."
(Provérbio africano)

RESUMO

Este estudo investigou os efeitos da frequência de queimadas (1985-2023) na resposta espectral da vegetação (NDVI) na Mata Atlântica fluminense, utilizando dados do MapBiomas Fogo e imagens Landsat processadas no Google Earth Engine. Foram avaliadas quatro subclasses de cobertura vegetal (formação florestal, pastagem, restinga arbórea e mosaico de usos), com foco em pixels estáveis após ocorrência de incêndio (que mantiveram a mesma subclasse ao longo do período). A metodologia incluiu análise geoespacial da dinâmica de transição e estabilidade, distribuição da frequência de queimadas e cálculo do NDVI com e sem filtragem de nuvens, além de análises estatísticas em R. Os resultados mostraram que as pastagens queimadas apresentaram alta estabilidade (83,1% dos pixels inalterados), enquanto os mosaicos de uso foram os mais dinâmicos (apenas 33,7% de estabilidade). A frequência de queimadas foi predominantemente baixa (1-2 eventos) em todas as subclasses, porém com maior recorrência em mosaicos. Incêndios recorrentes (>5 eventos) reduziram significativamente o NDVI em formações florestais, enquanto as pastagens mantiveram estabilidade espectral mesmo sob alta recorrência. A filtragem de nuvens foi crítica para a acurácia, evitando subestimativas, especialmente em restingas. E houve tendência de aumento do NDVI em 2023, associada à regeneração natural e avanços nos sensores orbitais. Conclui-se que o NDVI é um indicador eficaz da degradação florestal induzida por queimadas, e a abordagem metodológica adotada, baseada em big data geoespacial, oferece dados valiosos para políticas de conservação e restauração ecológica na Mata Atlântica.

Palavras-chave: Incêndios florestais; NDVI; Degradação florestal; Mata Atlântica; Sensoriamento remoto.

ABSTRACT

This study investigated the effects of fire frequency (1985–2023) on the spectral response of vegetation (NDVI) in the Atlantic Forest of Rio de Janeiro state, using MapBiomass Fire data and Landsat images processed in Google Earth Engine. Four vegetation subclasses were evaluated: forest formation, pasture, arboreal restinga, and land-use mosaic, focusing on pixels that remained stable after fire events (maintaining the same subclass throughout the period). The methodology included geospatial analysis of transition dynamics and stability, fire frequency distribution, and NDVI calculation with and without cloud filtering, complemented by statistical analyses in R. Results showed that burned pastures exhibited high stability (83.1% of pixels unchanged), while land-use mosaics were the most dynamic (only 33.7% stability). Fire frequency was predominantly low (1–2 events) across all subclasses, with higher recurrence in mosaics. Recurrent fires (>5 events) significantly reduced NDVI in forest formations, whereas pastures maintained spectral stability even under high recurrence. Cloud filtering was critical for accuracy, preventing underestimation especially in restingas. An increasing NDVI trend was observed in 2023, associated with natural regeneration and improvements in orbital sensors. The study concludes that NDVI is an effective indicator of fire-induced forest degradation, and the adopted big geospatial data approach provides valuable information for conservation and ecological restoration policies in the Atlantic Forest.

Keywords: Forest fires; NDVI; Forest degradation; Atlantic Forest; Remote sensing.

SUMÁRIO

1	INTRODUÇÃO.....	1
2	REVISÃO DE LITERATURA	2
2.1	Sensoriamento Remoto.....	2
2.1.1	Índice de Vegetação por Diferença Normalizada (NDVI)	3
2.2	Google Earth Engine (GEE).....	3
2.3	MapBiomas – Cobertura e uso do solo e frequência de queimadas	4
3	MATERIAL E MÉTODOS.....	5
3.1	Área de estudo	5
3.2	Coleta e processamento de dados	6
3.2.1	Análise geoespacial	7
3.2.2	Análise dos eventos de queimadas	7
3.2.3	Extração do NDVI.....	7
3.2.4	Análise em R	8
4	RESULTADOS	9
4.1	Dinâmica das transições e estabilidade entre subclasses afetadas pelos incêndios	10
4.2	Distribuição da frequência de queimadas das subclasses estáveis	11
4.3	Dinâmica do NDVI das subclasses estáveis	12
5	DISCUSSÃO.....	16
5.1	Padrões de frequência de queimadas por subclasse de cobertura vegetal	16
5.2	Estabilidade após eventos de queimada e transições no uso e cobertura do solo	16
5.3	Resposta espectral da vegetação ao fogo (NDVI).....	17
6	CONCLUSÃO.....	18
7	REPEREÊNCIAS BIBLIOGRÁFICAS	18

LISTA DE FIGURAS

Figura 1. Interface do Google Earth Engine exibindo layers de processamento remoto para análise temporal de frequência de queimadas (1985-2023). Fonte: Autor.....	4
Figura 2. Mapa da distribuição espacial de pixels com ocorrência de incêndios (1985-2023) no estado do Rio de Janeiro, apresentando quatro escalas de análise: (a) Contexto regional com limites estaduais e delimitação do bioma Mata Atlântica; (b) Distribuição estadual de áreas queimadas; (c) Detalhamento da região metropolitana com foco nos municípios de Seropédica, e Itaguaí; (d) Classificação da frequência de queimadas (1 a 38 eventos) nos municípios destacados.....	6
Figura 3. Fluxograma Metodológico. Fonte: Autor.	7
Figura 4. Interface do RStudio v4.5.0 exibindo script de análise da matriz de transição de uso do solo e análise de proporção de estabilidade das subclasses. Fonte: Autor.....	9
Figura 5. Matriz de transição das subclasses uso do solo que foram queimadas (1985-2023) para o bioma Mata Atlântica no estado do Rio de Janeiro.....	10
Figura 6. Proporção de estabilidade por subclasse que foram queimadas (1985-2023). Barras representam percentual de pixels que mantiveram a mesma classificação após 38 anos.	11
Figura 7. Distribuição espacial de pixels por frequência de queimadas (1985-2023) em quatro subclasses de cobertura vegetal do Rio de Janeiro. Valores absolutos representam contagem de pixels (1 pixel = 0.09 ha).....	12
Figura 8. Estatísticas descritivas do NDVI das médias com desvia padrão do máximo, mediana e média, em áreas de formação florestal, conforme faixas de frequência de queimadas entre os anos de 1985 e 2023. Foram consideradas análises com e sem filtragem de cobertura de nuvem nas imagens orbitais.....	13
Figura 9. Estatísticas descritivas do NDVI das médias com desvia padrão do máximo, mediana e média, em áreas de pastagem, conforme faixas de frequência de queimadas entre os anos de 1985 e 2023. Foram consideradas análises com e sem filtragem de cobertura de nuvem nas imagens orbitais.	14
Figura 10. Estatísticas descritivas do NDVI das médias com desvia padrão do máximo, mediana e média, em áreas de mosaico de usos, conforme faixas de frequência de queimadas entre os anos de 1985 e 2023. Foram consideradas análises com e sem filtragem de cobertura de nuvem nas imagens orbitais.....	15
Figura 11. Estatísticas descritivas do NDVI — médias com desvio padrão dos valores máximos, médios e medianos, em áreas de restinga arbórea, conforme faixas de frequência de queimadas entre 1985 e 2023.	16

LISTA DE TABELAS

Tabela 1. Síntese das estatísticas descritivas aplicadas na análise geoespacial e espectral.....	9
---	---

1 INTRODUÇÃO

O fogo representa uma das maiores ameaças à integridade da vegetação remanescente da Mata Atlântica, especialmente no estado do Rio de Janeiro. Conforme alerta a SOS Mata Atlântica (2022), os incêndios surgem como fator recorrente de degradação, particularmente nas zonas de transição entre áreas naturais e ocupações humanas. Nesse cenário, dados do MapBiomias (2023) revelam que, entre 1985 e 2023, o território fluminense acumulou impressionantes 7,5 milhões de hectares afetados pelo fogo, com picos marcantes em períodos de seca intensa. Vale destacar que fragmentos pequenos e isolados, conforme Tabarelli et al. (2010), são os mais vulneráveis a esses eventos, enquanto Brando et al. (2020) vinculam sua intensificação à combinação perigosa entre ocupação desordenada e mudanças climáticas.

Esta pressão é particularmente crítica quando consideramos a biodiversidade fluminense. O estado do Rio de Janeiro abriga mais de 8,000 espécies vegetais, das quais aproximadamente 33% são endêmicas (CNCFlora, 2023). Desse total, aproximadamente 650 espécies figuram na Lista Oficial de Espécies Ameaçadas (MMA, 2022), incluindo joias botânicas como o pau-brasil (*Paubrasilia echinata*) e o palmito-juçara (*Euterpe edulis*). Essa riqueza integra o patrimônio mais amplo da Mata Atlântica, reconhecida por abrigar cerca de 20 mil espécies vegetais sendo 8 mil endêmicas (Myers et al., 2000), e fauna emblemática como o mico-leão-dourado (ICMBio, 2018). Entretanto, esse patrimônio enfrenta redução drástica, restando apenas aproximadamente 20% da cobertura original em fragmentos desconectados (INPE, 2023), sendo que no Rio de Janeiro, os remanescentes concentram-se majoritariamente em encostas e unidades de conservação (TABARELLI et al., 20210; MAPBIOMAS 2023). As planícies, onde ocorrem importantes formações como restingas e florestas de baixada, ambientes críticos para espécies endêmicas como a *Clusia fluminensis* (REFLORA, 2023), foram amplamente convertidas para usos urbanos e agropecuários, fragmentando a paisagem e ampliando riscos ecológicos.

Os impactos das queimadas recorrentes transcendem a perda imediata de cobertura vegetal, comprometendo serviços ecossistêmicos cruciais. Como destaca o IPBES (2019), funções como regulação hídrica e sequestro de carbono são diretamente afetadas, ao passo que incêndios frequentes reduzem a capacidade de regeneração natural, intensificando vulnerabilidades socioecológicas (SHIMABUKURO et al., 2020). Felizmente, o avanço nas tecnologias de monitoramento por sensoriamento remoto oferece novas perspectivas para diagnóstico, embora a alta nebulosidade característica do bioma, que pode exceder 70% de cobertura de nuvens em certos períodos (ASNER, 2001), imponha desafios técnicos significativos que demandam protocolos rigorosos de filtragem para garantir a confiabilidade das análises (ZHU et al., 2015).

Nesse campo, o NDVI (Normalized Difference Vegetation Index) surge como ferramenta fundamental. Desenvolvido por Rouse et al. (1974), é um indicador sensível da quantidade e condição da vegetação o qual se relaciona diretamente com parâmetros fisiológicos como índice de área foliar e disponibilidade hídrica (LE PAGE; ZRIBI, 2019). Sua aplicação permite avaliar desde condições de estresse vegetativo até padrões de biomassa (PETTORELLI et al., 2011), além de detectar distúrbios ambientais com eficácia (KENNEDY et al., 2018). Contudo, em regiões de alta nebulosidade como a Mata Atlântica fluminense, a qualidade das análises de NDVI depende criticamente de métodos avançados de filtragem de nuvens, pois pixels contaminados podem distorcer valores espectrais e mascarar respostas da vegetação (ROY et al., 2014). Avanços recentes, como os demonstrados por Shimabukuro et al. (2020), combinam séries temporais de NDVI com imagens orbitais e técnicas robustas de máscara de nuvens para identificar trajetórias de degradação ou recuperação. Essas inovações são potencializadas por plataformas como o Google Earth Engine (GORELICK et al., 2017),

cujo expoente nacional é o Projeto MapBiomas. Seu módulo dedicado ao fogo (MapBiomas Fogo) integra dados multi-sensores, algoritmos de filtragem de nuvens baseados em QA e algoritmos de machine learning para mapear cicatrizes de queimadas desde 1985 (SOUZA, 2020). Dados recentes (MAPBIOMAS, 2023) revelam padrões preocupantes: no bioma Mata Atlântica, 70% das áreas queimadas ocorrem em zonas agropecuárias, contra apenas 14% em florestas, com fragmentos menores de 50 hectares sendo os mais atingidos.

Neste contexto, este trabalho justifica-se pela necessidade de compreender a relação entre frequência de queimadas e resposta espectral da vegetação na Mata Atlântica fluminense. Embora o NDVI seja consolidado em estudos de grandes domínios tropicais, sua aplicação sistemática em áreas fragmentadas do Rio de Janeiro ainda é limitada (PETTORELLI et al., 2011; KENNEDY et al., 2018; SCARANO, 2019). O objetivo é avaliar a influência da frequência de queimadas sobre os valores do NDVI em diferentes subclasses de cobertura vegetal, comparando 1985 e 2023, com e sem filtragem de nuvens no processamento de dados orbitais. A escolha desse intervalo visa identificar padrões de degradação e regeneração em escala temporal ampla, frente às pressões antrópicas e mudanças ambientais das últimas quatro décadas (HANSEN et al., 2013; MAPBIOMAS, 2023). Essa abordagem pode contribuir para a identificação de áreas críticas e estratégias de restauração (RIBEIRO et al., 2009; SOUZA et al., 2020), especialmente para espécies ameaçadas dependentes de habitats íntegros.

2 REVISÃO DE LITERATURA

2.1 Sensoriamento Remoto

Ao longo das últimas décadas, o sensoriamento remoto (SR) consolidou-se como uma das principais tecnologias para aquisição de dados ambientais em larga escala. Utilizando sensores embarcados em satélites e aeronaves, essa técnica permite a coleta de informações da superfície terrestre sem necessidade de contato físico direto, sendo essencial para estudos sobre uso da terra, desmatamento, mudanças climáticas e monitoramento de queimadas (JENSEN, 2016; LILLESAND et al., 2015). O princípio físico do SR está fundamentado na interação da radiação eletromagnética com os elementos da paisagem, sendo possível identificar alvos distintos com base em suas assinaturas espectrais (CAMPBELL; WYNNE, 2011). Isso inclui desde áreas urbanas e corpos hídricos até vegetação em diferentes estágios de desenvolvimento. Com sensores passivos, como MODIS e Sentinel-2, e o programa Landsat (com dados gratuitos e resolução espacial média, ideal para estudos regionais e de séries temporais longas desde os anos 1970), é possível observar a reflectância da radiação solar refletida, enquanto sensores ativos, como LiDAR e radar, operam com emissão própria de sinais, aumentando a capacidade de observação mesmo sob cobertura de nuvens (ZHANG et al., 2019).

A sofisticação dos sensores e a melhoria das resoluções espectral, espacial e temporal ampliaram o escopo das aplicações do SR. Por exemplo, sensores hiperespectrais como o Hyperion permitiram a identificação mais precisa de espécies vegetais e minerais (THENKABAIL et al., 2012), enquanto sistemas com alta resolução temporal, como o GOES-R, e a continuidade de missões como o Landsat, viabilizaram o acompanhamento de eventos extremos em tempo quase real e a construção de robustas séries históricas para análise de tendências (ZHANG et al., 2019; WULDER et al., 2016). Essas inovações tornam o SR indispensável para a análise de biomas dinâmicos e vulneráveis como a Mata Atlântica.

2.1.1 Índice de Vegetação por Diferença Normalizada (NDVI)

Entre os produtos gerados a partir do SR, o NDVI (Normalized Difference Vegetation Index) destaca-se como um dos índices mais amplamente aplicados em estudos ecológicos. Proposto por Rouse et al. (1974), o NDVI é calculado a partir da diferença normalizada entre as bandas do vermelho (RED) e do infravermelho próximo (NIR), refletindo a atividade fotossintética e a densidade da vegetação. Segundo Tucker (1979), sua aplicação inicial foi voltada ao monitoramento de produtividade agrícola, mas rapidamente expandiu-se para análises de ecossistemas naturais. Sua simplicidade conceitual, facilidade de cálculo e interpretação direta consolidaram-no como um padrão na comunidade científica, permitindo comparações temporais e espaciais em larga escala (PETTORELLI et al., 2005; KERR; OSTROVSKY, 2003).

A utilidade do NDVI reside na sua capacidade de captar alterações na biomassa e na cobertura vegetal em múltiplas escalas espaciais e temporais. Estudos como os de Pettorelli et al. (2005) e Kennedy et al. (2018) destacam sua importância na avaliação de padrões sazonais, distúrbios ecológicos e efeitos de estresse ambiental. Em sistemas agrícolas, o índice demonstra forte correlação com a produtividade de culturas como milho e trigo (SON et al., 2012), enquanto em regiões semiáridas tem sido eficaz na detecção de estresse hídrico (KOGAN, 1995). Além disso, a extensa série histórica de dados NDVI, disponível desde os primórdios do SR (e.g., missões Landsat desde 1972 e AVHRR desde 1981), o torna indispensável para análises de tendências de longo prazo (WULDER et al., 2016; TUCKER et al., 2005). A evolução dos sensores, como o OLI no Landsat-8, contribuiu para maior precisão radiométrica, reduzindo problemas como a saturação em áreas com alta densidade de biomassa (ROY et al., 2014). Desta forma, o NDVI mantém sua relevância devido à robustez, ampla aceitação na literatura e compatibilidade com séries temporais extensas, sendo frequentemente o ponto de partida para análises de dinâmica vegetal (PETTORELLI et al., 2011; ZHAO et al., 2007).

2.2 Google Earth Engine (GEE)

O desenvolvimento de plataformas computacionais em nuvem tem revolucionado o trabalho com dados de sensoriamento remoto, e o Google Earth Engine (GEE) é uma dessas ferramentas. Segundo Gorelick et al. (2017), o GEE oferece acesso gratuito e organizado a um extenso repositório de dados orbitais, com destaque para a coleção completa do Landsat, incluindo dados históricos georreferenciados desde 1972 e séries com correções radiométricas e atmosféricas padronizadas (USGS, 2019; WULDER et al., 2016), aliado a uma infraestrutura de processamento massivo capaz de executar tarefas complexas com grande eficiência. Sua arquitetura permite operações essenciais como, filtragem avançada de nuvens através de algoritmos embutidos (e.g., máscaras 'pixel QA' baseadas em Fmask) (ZHU et al., 2015), funções de redução temporal (*reducers*) para geração de composições sintéticas (mediana, percentis) que minimizam ruídos e anomalias (KENNEDY et al., 2018) e cálculo automatizado de índices espectrais (NDVI, EVI) diretamente nas coleções de imagens (GORELICK et al., 2017). Entre suas funcionalidades destacam-se ainda os algoritmos de aprendizado de máquina nativamente integrados, como Random Forest e Support Vector Machine, utilizados para classificação de uso e cobertura do solo em diferentes escalas (XIONG et al., 2017). Essa combinação de capacidades, particularmente a otimização para séries Landsat e o tratamento automatizado de interferências atmosféricas, torna o GEE indispensável para monitoramento contínuo de biomas tropicais (HANSEN et al., 2013; REICHE et al., 2021).

A figura 1 exemplifica a interface do GEE com um script de processamento aplicado à análise temporal entre 1985 e 2023, evidenciando sua aplicabilidade no tratamento de séries históricas de imagens orbitais. Entretanto, é necessário destacar que a adoção plena do GEE

exige conhecimentos em programação (JavaScript e Python), o que pode representar uma barreira para parte da comunidade científica e técnica. Donk et al. (2022) também apontam restrições quanto à capacidade de armazenamento e ao tempo máximo de execução por tarefa, fatores que exigem otimização cuidadosa nos projetos mais exigentes.

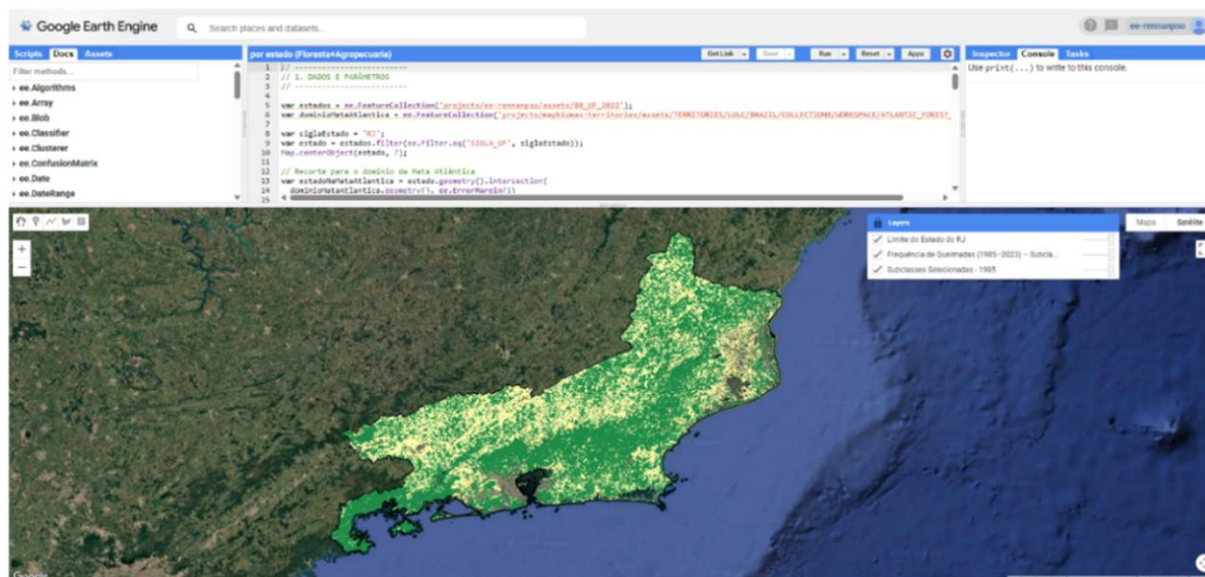


Figura 1. Interface do Google Earth Engine exibindo layers de processamento remoto para análise temporal de frequência de queimadas (1985-2023). Fonte: Autor.

2.3 MapBiomass – Cobertura e uso do solo e frequência de queimadas

O projeto MapBiomass é uma iniciativa brasileira que combina dados de sensoriamento remoto com algoritmos de classificação automática para produzir mapas anuais de uso e cobertura da terra desde 1985. Sua base é o GEE, que possibilita o processamento de grandes volumes de dados Landsat de forma contínua (SOUZA et al., 2020). Um aspecto desse processamento é a aplicação sistemática de algoritmos de filtragem de nuvens, como o Fmask (ZHU; WOODCOCK, 2015), que utiliza bandas termais e do infravermelho de ondas curtas (SWIR) para discriminar nuvens, sombras e vegetação, reduzindo interferências atmosféricas nas análises temporais (KENNEDY et al., 2018). Segundo Almeida et al. (2021), o MapBiomass atingiu acurácia média superior a 85% nas classificações mais recentes, cobrindo todos os biomas do país.

Uma das extensões mais importantes do projeto é o módulo 'MapBiomass Fogo', voltado à detecção de cicatrizes de queimadas. Utilizando sensores como VIIRS, MODIS e Landsat, este módulo estima a extensão e a frequência dos incêndios com periodicidade quinzenal (LIBONATI et al., 2021). De acordo com dados mais recentes, aproximadamente 7% das áreas queimadas no estado do Rio de Janeiro entre 1985 e 2023 estavam localizadas em formações florestais da Mata Atlântica, com predominância de fragmentos menores que 50 hectares (MAPBIOMASS, 2023). A integração dessas informações com métricas espectrais como o NDVI tem potencial para enriquecer o entendimento sobre os impactos do fogo na vegetação. Ribeiro et al. (2009) destacam que a fragmentação da paisagem fluminense torna a vegetação mais vulnerável a distúrbios antrópicos, enquanto Souza et al. (2020) argumentam que a análise da frequência de queimadas pode subsidiar políticas de restauração ambiental. Entretanto, a eficácia dessa integração depende criticamente da qualidade da filtragem prévia, pois pixels contaminados por nuvens podem distorcer valores de NDVI (ROY et al., 2014).

Apesar de seu valor, o MapBiomias apresenta limitações técnicas. A resolução espacial de 30 metros dos sensores Landsat pode não ser suficiente para detectar alterações em áreas menores, e a persistência de nuvens em certas regiões, mesmo após filtragem, ainda compromete a completude das séries temporais (ZHU et al. 2015). Além disso, a ausência de dados de sensores comerciais, como o PlanetScope, limita a resolução e a acurácia local das análises em ambientes urbanos ou agrícolas intensivos (ARAGÃO et al., 2022). Com a evolução do projeto, novas funcionalidades vêm sendo incorporadas. A versão 8.0 do MapBiomias promete utilizar sensores hiperespectrais, como o PRISMA, e aprimorar os algoritmos de filtragem atmosférica através de redes neurais convolucionais, além de incorporar técnicas de inteligência artificial para previsão do risco de incêndios (FONSECA et al., SANTOS et al., 2023).

3 MATERIAL E MÉTODOS

3.1 Área de estudo

O presente estudo foi conduzido no bioma Mata Atlântica do estado do Rio de Janeiro, localizado na Região Sudeste do Brasil, entre as coordenadas aproximadas 20°45'S a 23°21'S de latitude e 41°00'W a 44°53'W de longitude. Com área total de cerca de 43.750 km². Foram analisadas 9 subclasses de cobertura vegetal: formação florestal, savana, mangue, floresta alagável, restinga arbórea, pastagens, agricultura, silvicultura e mosaico de usos. O recorte espacial considerou os limites estaduais conforme definidos pelo IBGE e o Projeto MapBiomias. A base de dados utilizada abrangeu os anos de 1985 e 2023, com foco na relação entre a frequência de queimadas e a resposta espectral da vegetação.

Ao todo, foram analisados 4.841.596 pixels, equivalentes a aproximadamente 435.744 hectares, considerando a resolução de 30 metros das imagens Landsat (1 pixel = 0,09 ha). Esse conjunto representa cerca de 10,0% da área total do estado, correspondendo aos pixels mapeados com histórico de queimadas em pelo menos um dos anos do período avaliado, sendo os mesmos pixels analisados para os dois anos, os quais foram extraídos do Projeto MapBiomias Fogo Coleção 3 (ALENCAR et al., 2024). As análises geoespaciais foram realizadas na plataforma Google Earth Engine (GORE et al., 2023), utilizando como recorte territorial o estado do Rio de Janeiro, delimitado por feições vetoriais (IBGE, 2023). Essa base foi interseccionada com o polígono do domínio legal da Mata Atlântica, conforme o mapeamento e metodologia validados na Coleção 9 do Projeto MapBiomias (CRUSCO et al., 2024).

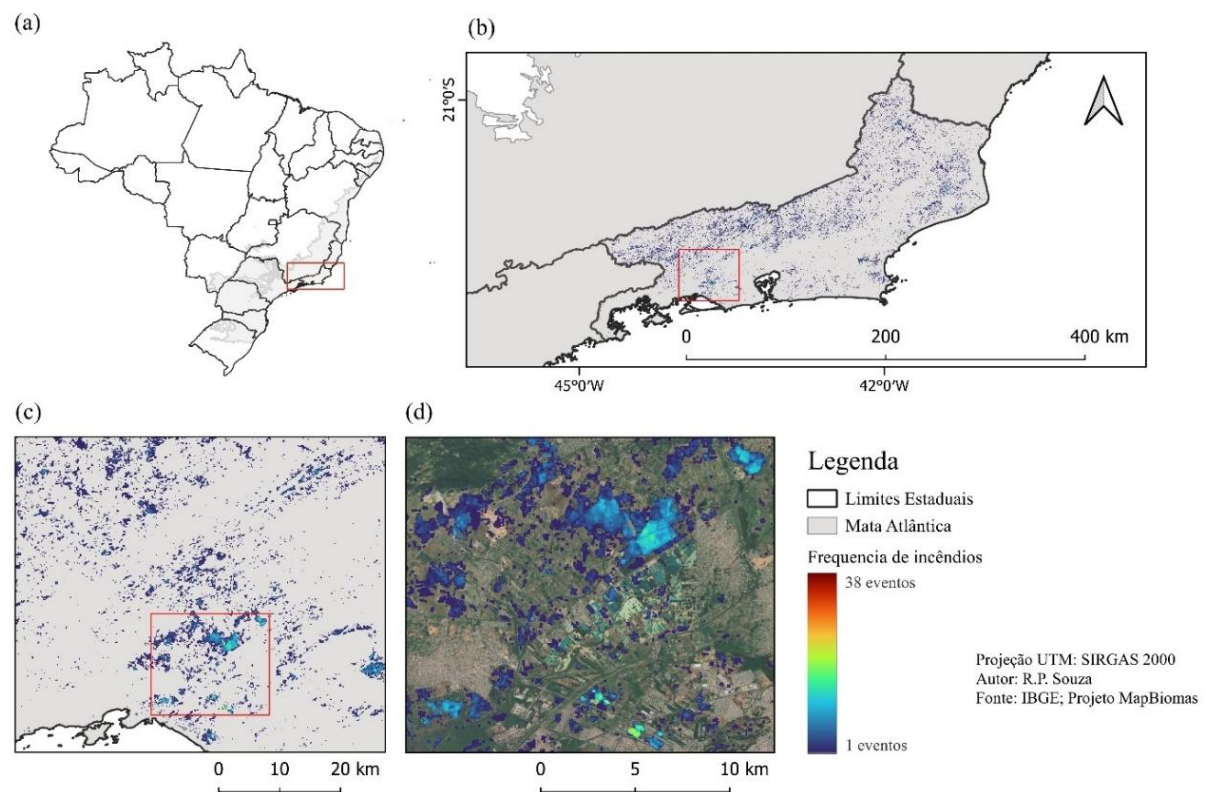


Figura 2. Mapa da distribuição espacial de pixels com ocorrência de incêndios (1985-2023) no estado do Rio de Janeiro, apresentando quatro escalas de análise: (a) Contexto regional com limites estaduais e delimitação do bioma Mata Atlântica; (b) Distribuição estadual de áreas queimadas; (c) Detalhamento da região metropolitana com foco nos municípios de Seropédica, e Itaguaí; (d) Classificação da frequência de queimadas (1 a 38 eventos) nos municípios destacados.

3.2 Coleta e processamento de dados

Os procedimentos de coleta e processamento adotaram uma abordagem integrada entre plataformas de geoprocessamento e análise estatística. A sequência metodológica envolveu: processamento geoespacial para quantificação de transições de uso, análise de recorrência de queimadas, extração de indicadores de vegetação e tratamento estatístico rigoroso. Os resultados extraídos na plataforma GEE foram organizados em tabelas de atributos contendo identificadores das subclasses, métricas de NDVI, contagens de pixels e valores de área, sendo posteriormente exportados para análise estatística no programa R (RSTUDIO TEAM, 2024). Complementarmente, os arquivos raster gerados foram importados nos ambientes QGIS, versão 3.42.3 (QGIS DEVELOPMENT TEAM, 2024) e ArcGIS, versão 10.5 (ESRI, 2016), com o objetivo de viabilizar a visualização espacial da área estudada.

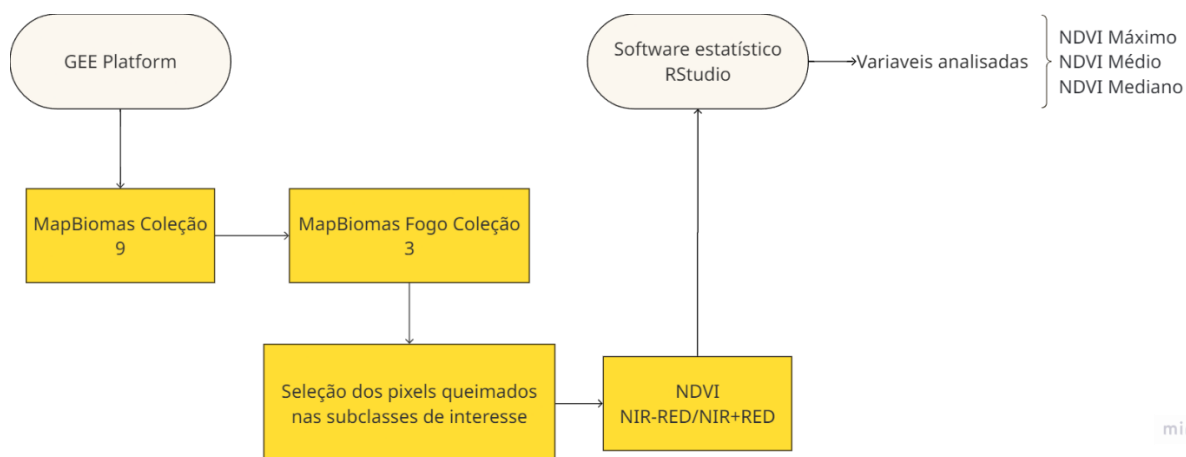


Figura 3. Fluxograma Metodológico. Fonte: Autor.

3.2.1 Análise geoespacial

Esta etapa baseou-se em metodologia por pixel, com conversão para área utilizando fator de 0,09 hectares por pixel (equivalente a 900 m²). As operações de redução espacial e agregação estatística foram implementadas com algoritmos nativos do GEE, aplicados sobre a geometria vetorial do estado do Rio de Janeiro. Para cada subclasse de uso em 1985, calculou-se a área total, a área submetida a cada faixa de frequência de queimadas, a proporção queimada em relação à área original, e as respectivas transições de uso identificadas em 2023. Foram processados dados anuais de uso e cobertura da terra da Coleção 9 do MapBiomas, com resolução espacial de 30 metros, para os anos de 1985 e 2023. Subclasses não vegetativas, como corpos hídricos, áreas urbanas e superfícies não vegetadas, foram excluídas por meio da aplicação de máscaras.

3.2.2 Análise dos eventos de queimadas

A análise da dinâmica temporal de queimadas baseou-se na imagem de frequência de fogo fornecida pela Coleção 3 do MapBiomas Fogo (ALENCAR et al., 2024), considerando cinco faixas de recorrência predefinidas: 1–2, 3–5, 6–12, 13–21 e 22–38 eventos, nos anos de 1985 e 2023. Essas faixas foram escolhidas pois de acordo com Alencar et al. (2024) as classes de 1 a 12 eventos englobam 95% das ocorrências de queimadas no Brasil representando eventos desde esporádicos até recorrentes enquanto as faixas superiores isolam anomalias extremas.

3.2.3 Extração do NDVI

O ambiente GEE também foi utilizado para calcular o NDVI e extrair variáveis temporais associadas a eventos de queimadas. Para cada combinação de subclasse de uso do solo e intervalo de recorrência de queimadas, calculamos os valores médios do máximo, da mediana e da média do NDVI, todos derivados dos pixels selecionados e acompanhados de seus respectivos desvios padrão amostrais, a partir de composições anuais das coleções Landsat específicas: Landsat 5 (coleção LANDSAT/LT05/C02/T1_L2) para 1985 e Landsat 8 (coleção LANDSAT/LC08/C02/T1_L2) para 2023 (ROY et al., 2014; USGS, 2023). Foram conduzidas duas abordagens distintas quanto ao controle de qualidade das imagens. Na primeira, aplicou-se uma filtragem atmosférica para considerar apenas imagens com até 10% de cobertura de nuvens, buscando garantir maior acurácia radiométrica nos valores do NDVI. Na segunda

abordagem, nenhuma filtragem de nuvens foi aplicada, permitindo avaliar o impacto da presença de cobertura atmosférica nas estatísticas derivadas.

3.2.4 Análise em R

Após a exportação dos dados geoespaciais processados no GEE, foram realizados procedimentos adicionais de filtragem e análises estatísticas no software RStudio versão 4.5.0 (R CORE TEAM, 2024), utilizando o ambiente RStudio (RSTUDIO TEAM, 2024). Primeiramente, foram excluídas da base todas as subclasses de cobertura com 100 ou menos pixels, com o objetivo de evitar vieses associados a amostras estatisticamente pouco representativas. Para as análises de NDVI, foram considerados exclusivamente os pixels das subclasses estáveis que mantiveram sua classificação original após 38 anos e apresentaram recorrência de queimadas entre 1 e 12 eventos, abrangendo formações florestais, restingas arbóreas, pastagens e mosaicos de usos. Esta delimitação amostral, fundamentada em inspeção visual e critérios de plausibilidade ecológica (SOUZA et al., 2020), assegurou que as análises focassem em pixels com consistência espectral e ambiental ao longo da série histórica.

As etapas subsequentes envolveram o tratamento dos dados em módulos específicos voltados à construção dos gráficos finais apresentados neste trabalho. A organização e estruturação dos dados tabulares foram conduzidas com os pacotes `dplyr` e `tidyr`, utilizados para filtragem, agrupamento, organização e reestruturação dos conjuntos de dados (WICKHAM et al., 2023; WICKHAM et al. 2024). A manipulação funcional e repetitiva dos objetos analíticos foi automatizada com o uso do pacote `purrr` (HENRY et al., 2025), e as transformações de texto foram realizadas com o pacote `stringr` (WICKHAM, 2023).

A geração dos gráficos foi conduzida majoritariamente com o pacote `ggplot2` (WICKHAM et al., 2024), responsável pela criação de visualizações em barras, linhas, matriz de calor e diagramas comparativos. Para composição e sobreposição de elementos gráficos, foram empregados os pacotes `cowplot` (WILKE, 2024) e `patchwork` (PEDERSEN, 2024). A paleta de cor da matriz de calor foi aplicada com `viridis` (GARNIER et al., 2024), garantindo contraste visual adequado e acessibilidade cromática. Para controle da tipografia e adaptação do layout às normas da ABNT, foram utilizados os pacotes `extrafont` (CHANG, 2023) e `showtext` (QIU et al., 2024). A figura 3 ilustra o ambiente de trabalho no RStudio durante a execução do script de análise da matriz de transição, destacando a estrutura dos dados e o código aplicado ao período entre 1985 e 2023.

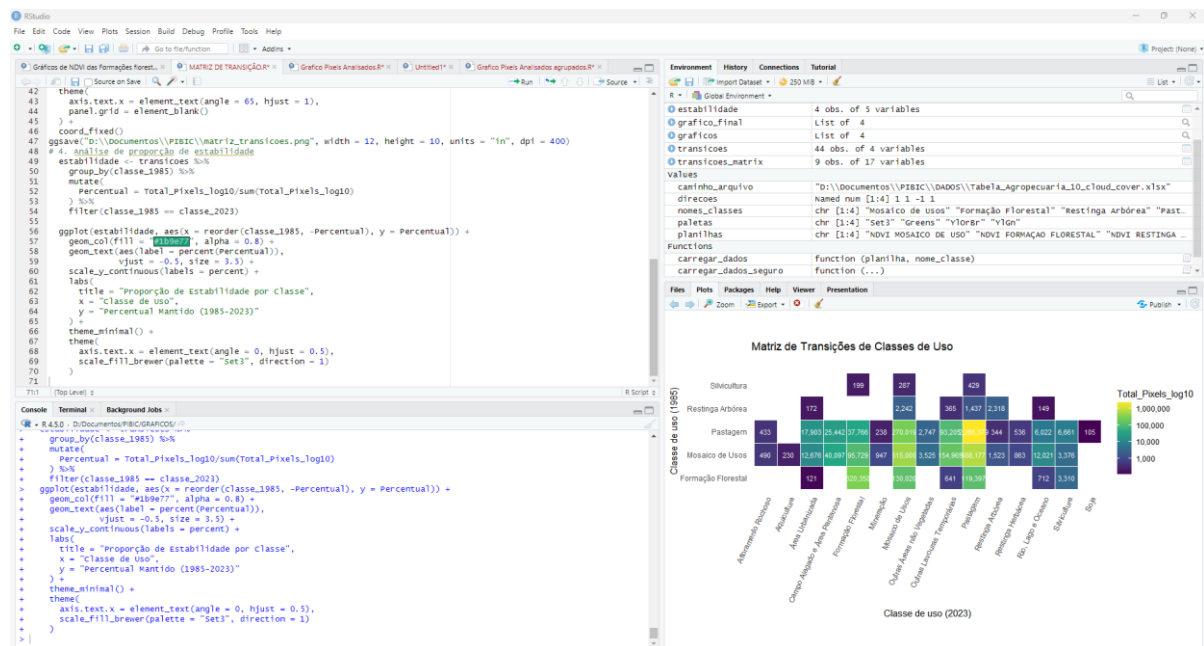


Figura 4. Interface do RStudio v4.5.0 exibindo script de análise da matriz de transição de uso do solo e análise de proporção de estabilidade das subclasses. Fonte: Autor.

4 RESULTADOS

Os resultados foram organizados em três eixos analíticos complementares, utilizando estatísticas descritivas e espaciais sobre o conjunto de 4.841.596 pixels (≈ 435.744 ha) com histórico de queimadas. Para as análises de transição e estabilidade (Seção 4.1), aplicou-se contagem absoluta de pixels e cálculo de proporções percentuais. Na caracterização da distribuição de frequência de fogo (Seção 4.2), aplicou-se análise de distribuição cumulativa com estratificação por classes de recorrência (1-2, 3-5, 6-12, 13-21 e 22-38 eventos), quantificada através de densidade de probabilidade empírica expressa em contagem absoluta de pixels por subclasse. Para avaliação da dinâmica espectral (Seção 4.3), foi realizado o cálculo das métricas de distribuição do NDVI (máximo amostral, mediana e média aritmética) e indicadores de dispersão (desvio padrão amostral), com controle experimental via comparação pareada implícita entre condições processadas com e sem filtragem de nuvens (limiar $\leq 10\%$ de cobertura).

Tabela 1. Síntese das estatísticas descritivas aplicadas na análise geoespacial e espectral.

Categoria Estatística	Métrica	Notação	Objetivo de Aplicação	Parâmetros Específicos
Centralidade	Média Aritmética	\bar{x}	Tendência central dos valores de NDVI	Subclasse/ano/frequência de fogo
	Mediana	Md	Valor central da distribuição do NDVI	Resistente a outliers espectrais
	Máximo Amostral	max(x)	Pico de vigor vegetativo	Indicador de recuperação pós-fogo
Dispersão	Desvio Padrão Amostral	s	Variabilidade interpixel dos valores de NDVI	$\sqrt{\frac{\sum (xi - \bar{x})^2}{n - 1}}$

Categoria Estatística	Métrica	Notação	Objetivo de Aplicação	Parâmetros Específicos
Distribuição	Contagem Absoluta	n	Quantificação de pixels por categoria	Base para cálculos de proporções (1px=0.09ha)
Associação	Proporção Percentual	%	Representatividade relativa de transições	Estabilidade vs. mudança de uso
	Densidade de Frequência	f(x)	Concentração espacial de eventos de queimada	Por classe de recorrência (1-2, 3-5,... eventos)
	Matriz de Contingência	-	Padrões de transição entre subclasses de uso	Origem (1985) vs. Destino (2023)

4.1 Dinâmica das transições e estabilidade entre subclasses afetadas pelos incêndios

Na análise comparativa das subclasses de uso vegetal impactadas por incêndios entre 1985 e 2023, os dados de 4,8 milhões de pixels revelaram padrões distintos de transição e estabilidade. Nas formações florestais queimadas, 320.350 pixels (55,8%) mantiveram sua classificação original entre 1985 e 2023. Por outro lado, 130.020 pixels (22,6%) foram convertidos para mosaico de usos e 119.397 pixels (20,8%) passaram a ser classificados como pastagem. Houve ainda conversões pontuais para silvicultura (3.310 pixels; 0,6%) e área urbanizada (121 pixels; 0,02%). Já para a restinga arbórea, 2.318 pixels (34,7%) permaneceram estáveis, enquanto os demais apresentaram transições relevantes: 2.242 pixels (33,6%) migraram para mosaico de usos, 1.437 pixels (21,5%) para pastagem, 365 pixels (5,5%) para lavouras temporárias, 172 pixels (2,6%) para áreas urbanas e 149 pixels (2,2%) para corpos hídricos.

A subclasse pastagem apresentou alta estabilidade (2.266.379 pixels; 83,1%). No entanto, foram registradas reconversões para mosaico de usos (270.019 pixels; 9,9%) e regenerações para formações florestais (38.110 pixels; 1,4%). O mosaico de usos foi a subclasse mais dinâmica, com 688.177 pixels (50,0%) convertidos para pastagem e 154.965 pixels (10,1%) para lavouras temporárias. Ainda assim, observou-se regeneração florestal em 95.729 pixels (6,3%). No caso da silvicultura, predominou a transição para pastagem (429 pixels; 46,9%), seguida por mosaico de usos (287 pixels; 31,4%) e formações florestais (199 pixels; 21,8%). A figura 4 apresenta a matriz de transição entre as subclasses analisadas, evidenciando padrões distintos da dinâmica de conversão da cobertura e uso do solo.

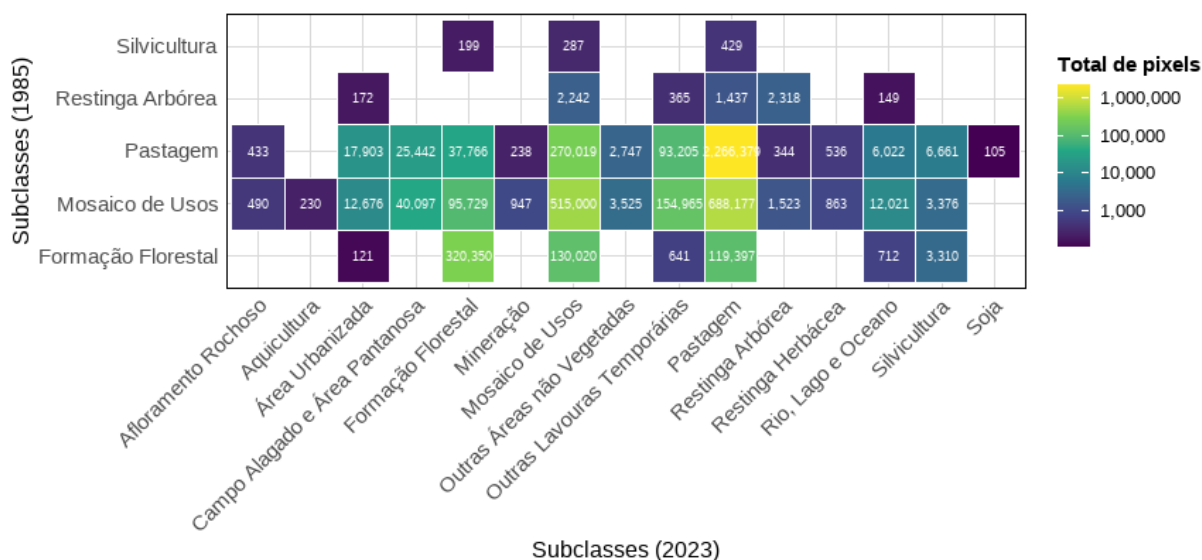


Figura 5. Matriz de transição das subclasses uso do solo que foram queimadas (1985-2023) para o bioma Mata Atlântica no estado do Rio de Janeiro.

A proporção de estabilidade por subclasse, demonstrada na figura 5, revela padrões contrastantes. Enquanto as pastagens demonstraram marcante estabilidade (83,1% dos pixels inalterados), as formações florestais mantiveram 55,8% de sua área original. Em posição intermediária, as restingas arbóreas registraram 34,7% de estabilidade, e com 1% de diferença, os mosaicos de usos apresentaram a menor permanência (33,7%).




Figura 6. Proporção de estabilidade por subclasse que foram queimadas (1985-2023). Barras representam percentual de pixels que mantiveram a mesma classificação após 38 anos.

4.2 Distribuição da frequência de queimadas das subclasses estáveis

A frequência de queimadas por subclasse de uso e cobertura vegetal foi analisada com base na série histórica comparativa dos anos 1985 e 2023, revelando a predominância da faixa de 1–2 eventos em todas as subclasses avaliadas (Figura 6). Ao todo, foram analisados 3.104.047 pixels, equivalentes a aproximadamente 279.364 hectares, representando cerca de 6,4% da área total do estado, correspondendo aos pixels mapeados das subclasses que se mantiveram as mesmas após 38 anos.

Na subclasse formação florestal, foram registrados 286.151 pixels (25.753,59 ha) na faixa de 1–2 eventos, representando 89,32% do total de área queimada desta subclasse, mapeada em 2023. As demais faixas apresentaram reduções sucessivas: 3–5 eventos (30.063 pixels; 2.705,67 ha; 9,38%), 6–12 eventos (3.213 pixels; 289,17 ha; 1,00%), 13–21 eventos (747 pixels; 67,23 ha; 0,23%) e 22–38 eventos (176 pixels; 15,84 ha; 0,05%). Em proporções menores que as formações florestais, nas restingas arbóreas, observou-se padrão semelhante, com 1.960 pixels (176,40 ha) concentrados na faixa de 1–2 eventos (84,56%), seguidos por 194 pixels (17,46 ha; 8,37%) na faixa 3–5 e 164 pixels (14,76 ha; 7,08%) na faixa 6–12.

As áreas de pastagens apresentaram o maior volume absoluto de queimadas, com 1.998.658 pixels (179.879,22 ha) na faixa 1–2 (88,19%). Houve ainda registro de 237.983 pixels (21.418,47 ha; 10,50%) na faixa 3–5, 28.146 pixels (2.533,14 ha; 1,24%) na faixa 6–12 e 1.592 pixels (143,28 ha; 0,07%) na faixa 13–21. Já no mosaico de usos, apesar da maior variabilidade, a concentração também recaiu sobre a menor faixa de recorrência: 392.314 pixels

(35.308,26 ha; 76,18%). As faixas seguintes apresentaram os seguintes valores: 3–5 eventos (95.007 pixels; 8.550,63 ha; 18,45%), 6–12 eventos (25.194 pixels; 2.267,46 ha; 4,89%), 13–21 eventos (2.184 pixels; 196,56 ha; 0,42%) e 22–38 eventos (301 pixels; 27,09 ha; 0,06%). Destaca-se ainda na figura 6, que apenas as formações florestais e mosaicos de usos obtiveram alta frequência de queimadas, acima de 22 queimadas no período, mesmo que em áreas pontuais.

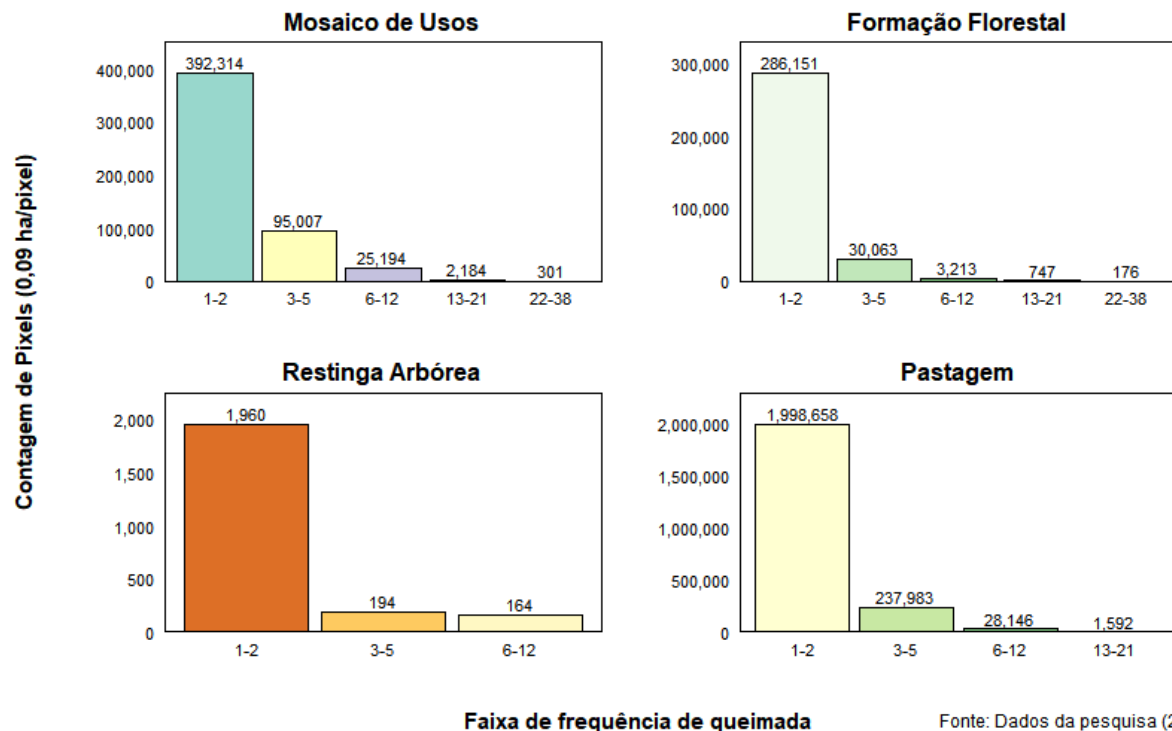


Figura 7. Distribuição espacial de pixels por frequência de queimadas (1985-2023) em quatro subclasses de cobertura vegetal do Rio de Janeiro. Valores absolutos representam contagem de pixels (1 pixel = 0.09 ha).

4.3 Dinâmica do NDVI das subclasses estáveis

As figuras 7, 8, 9 e 10 apresentam os gráficos que comparam métricas do NDVI com e sem filtragem de nuvens para diferentes subclasses estáveis após os incêndios (floresta, pastagem, restinga arbórea e mosaico de usos), nos anos de 1985 e 2023, estratificadas por faixas de frequência de incêndios (ex.: áreas que queimaram 1–2 vezes, 3–5 vezes, etc.). Para cada condição analisada, foram calculadas três estatísticas descritivas do NDVI: valores máximos, valores médios e valores medianos. Ao longo do texto, os valores apresentados correspondem às médias dessas estatísticas, agregadas por subclasse e faixa de frequência de queimadas.

A subclasse Formação Florestal apresentou redução nos valores médios de NDVI com o aumento da frequência de incêndios em ambos os anos analisados (Figura 7). Em 1985, os valores foram menores em todas as faixas de queimada em comparação com 2023. Nas faixas de menor frequência (1–2 e 3–5 eventos), observou-se os maiores valores médios. Por exemplo, a média dos valores máximos de NDVI em 2023 foi $0,56 \pm 0,09$ com filtragem e $0,44 \pm 0,05$ sem filtragem, aumento absoluto de 0,12 e relativo de 27%. Na mesma faixa, a média dos valores médios passou de $0,23 \pm 0,05$ (sem filtragem) para $0,28 \pm 0,09$ (com filtragem), diferença de aproximadamente 22%, enquanto as medianas aumentaram de $0,23 \pm 0,05$ para $0,29 \pm 0,09$. A filtragem de nuvens teve efeito mais evidente nas faixas intermediárias e baixas,

com diminuição das diferenças em faixas de alta frequência (ex.: 22–38 eventos), onde os valores foram mais homogêneos e baixos: por exemplo, máximos de $0,17 \pm 0,02$ (com filtragem) e $0,16 \pm 0,02$ (sem filtragem).

A análise visual dos gráficos representados na figura 7 revela a redução progressiva nas três métricas de NDVI à medida que aumenta a frequência de queimadas. Observa-se valores consistentemente mais elevados em 2023 em comparação com 1985 em todas as faixas de frequência. Também é possível notar a divergência marcante entre os resultados com e sem filtragem de nuvens nas faixas de menor frequência de incêndios, diferença que se atenua gradualmente até tornar-se mínima nas faixas de maior frequência. As curvas de 2023 com filtragem mantêm o padrão de decaimento característico, porém deslocadas para valores superiores

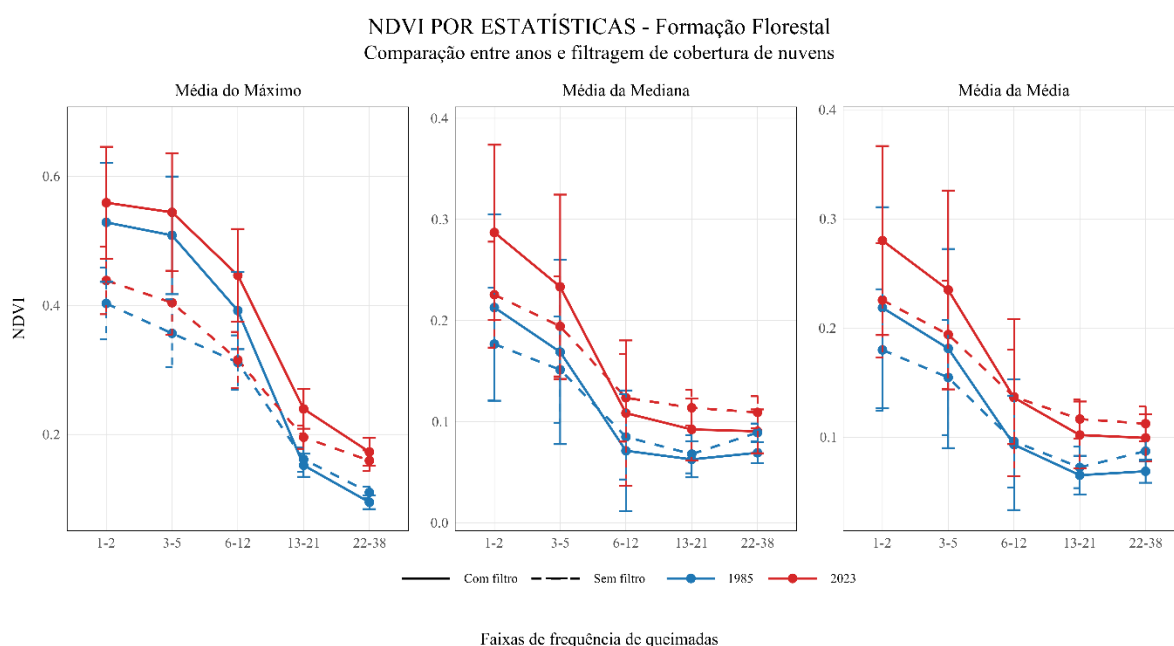


Figura 8. Estatísticas descritivas do NDVI das médias com desvia padrão do máximo, mediana e média, em áreas de formação florestal, conforme faixas de frequência de queimadas entre os anos de 1985 e 2023. Foram consideradas análises com e sem filtragem de cobertura de nuvem nas imagens orbitais.

As áreas classificadas como pastagem mostraram estabilidade nos valores de NDVI entre as faixas de frequência e entre os anos (Figura 8). A média dos valores máximos variou pouco: em 2023, manteve-se entre $0,49 \pm 0,05$ (faixa 3–5) e $0,42 \pm 0,07$ (faixa 13–21) com filtragem, e entre $0,38 \pm 0,03$ e $0,38 \pm 0,05$ sem filtragem. A média dos valores médios foi $0,28 \pm 0,07$ com filtragem e $0,25 \pm 0,05$ sem, na faixa 13–21, com diferença de 12%. As medianas oscilaram de forma semelhante ($0,29 \pm 0,07$ com filtragem; $0,27 \pm 0,05$ sem). A filtragem resultou em ganhos discretos nas métricas centrais, com variações de desvio padrão sempre entre 0,03 e 0,07.

A figura 8 revela, através de gráficos, o comportamento estável e constante das curvas ao longo de todas as faixas de frequência de queimadas, sem inclinação ascendente ou descendente perceptível. Também é possível observar a sobreposição marcante entre as linhas de 1985 e 2023. As condições com e sem filtragem mantêm distâncias paralelas consistentes, enquanto as barras de erro apresentam amplitude uniformemente reduzida em todo o espectro, confirmando visualmente a baixa dispersão dos dados e a homogeneidade da resposta espectral independentemente da recorrência de fogo.

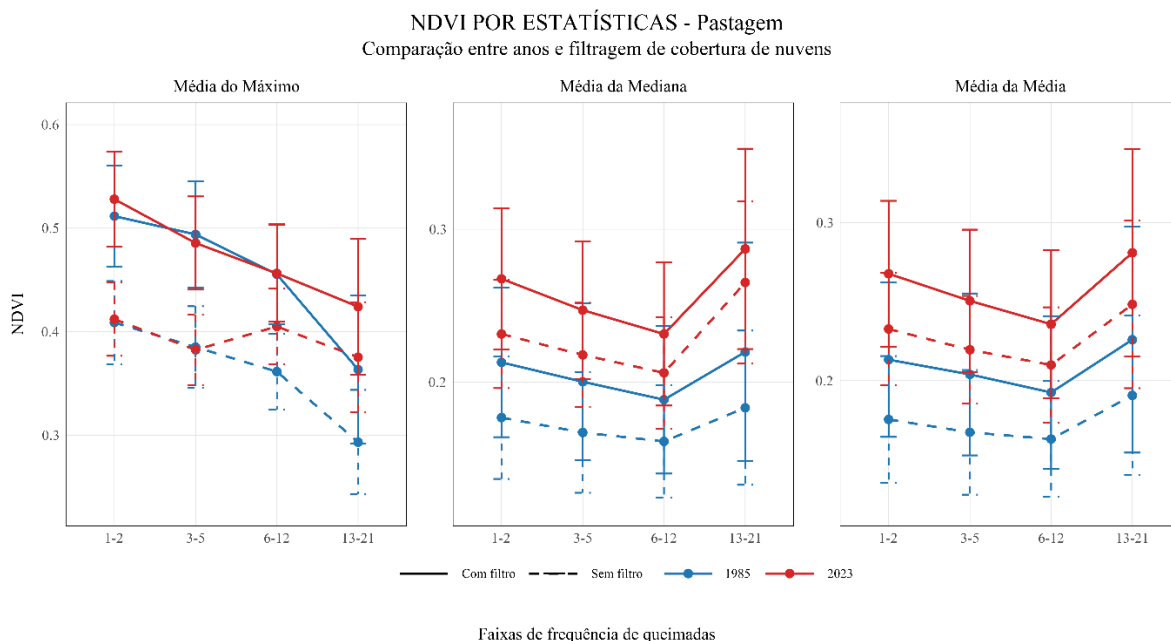


Figura 9. Estatísticas descritivas do NDVI das médias com desvia padrão do máximo, mediana e média, em áreas de pastagem, conforme faixas de frequência de queimadas entre os anos de 1985 e 2023. Foram consideradas análises com e sem filtragem de cobertura de nuvem nas imagens orbitais.

A subclasse mosaico de usos apresentou redução gradual nas métricas de NDVI com o aumento da frequência de incêndios, mais acentuada em 1985 (Figura 9). Em 2023, os valores foram mais elevados em todas as faixas, com efeito consistente da filtragem de nuvem. Na faixa 22–38, a média dos valores máximos foi $0,39 \pm 0,07$ com filtragem e $0,28 \pm 0,04$ sem, um aumento de 39,3%. A média dos valores médios subiu de $0,18 \pm 0,04$ para $0,18 \pm 0,07$, e as medianas de $0,17 \pm 0,04$ para $0,15 \pm 0,07$, sem alteração significativa nos valores centrais, mas com pequena variação na dispersão. As faixas de menor frequência apresentaram valores mais elevados, como na faixa 1–2: $0,55 \pm 0,06$ (máximos com filtragem) versus $0,44 \pm 0,04$ (sem), e $0,28 \pm 0,06$ vs. $0,23 \pm 0,04$ nas médias. Visualmente, a figura 9 evidencia o padrão decrescente do NDVI com o aumento da frequência de queimadas. Nota-se que as curvas de 2023 com filtragem mantêm a forma da distribuição, mas estão deslocadas para cima em todas as estatísticas, indicando que a filtragem elevou os valores absolutos sem alterar a tendência geral.




Figura 10. Estatísticas descritivas do NDVI das médias com desvia padrão do máximo, mediana e média, em áreas de mosaico de usos, conforme faixas de frequência de queimadas entre os anos de 1985 e 2023. Foram consideradas análises com e sem filtragem de cobertura de nuvem nas imagens orbitais.

A subclasse restinga arbórea apresentou os menores valores absolutos de NDVI entre todas as subclasses analisadas (Figura 10). A filtragem de nuvens causou forte impacto em algumas faixas. Em 2023, por exemplo, na faixa 1–2, a média dos valores médios de NDVI com filtragem foi $0,05 \pm 0,07$, enquanto sem filtragem foi $0,26 \pm 0,05$, uma redução de 80,8%. Essa diferença se refletiu também nos valores máximos: $0,29 \pm 0,07$ com filtragem e $0,41 \pm 0,05$ sem filtragem. Já nas medianas, os valores foram $0,33 \pm 0,07$ (com) e $0,27 \pm 0,05$ (sem), sugerindo que a filtragem afetou mais as métricas de média e máximo do que os valores centrais. Nas faixas de maior frequência (6–12 eventos), os valores foram mais baixos e estáveis: médias de $0,01 \pm 0,01$ (com filtragem) e $0,25 \pm 0,01$ (sem), mostrando novamente a forte influência da filtragem sobre o comportamento espectral dessa vegetação.

Essa diferença também pode ser observada graficamente na figura 10, onde o painel da média dos valores médios mostra uma queda acentuada em 2023 com filtragem na faixa 1–2, enquanto as medianas se mantêm mais constantes. Os erros-padrão mais elevados nessa faixa indicam maior variabilidade nas respostas espectrais da vegetação, especialmente sob efeito da filtragem.

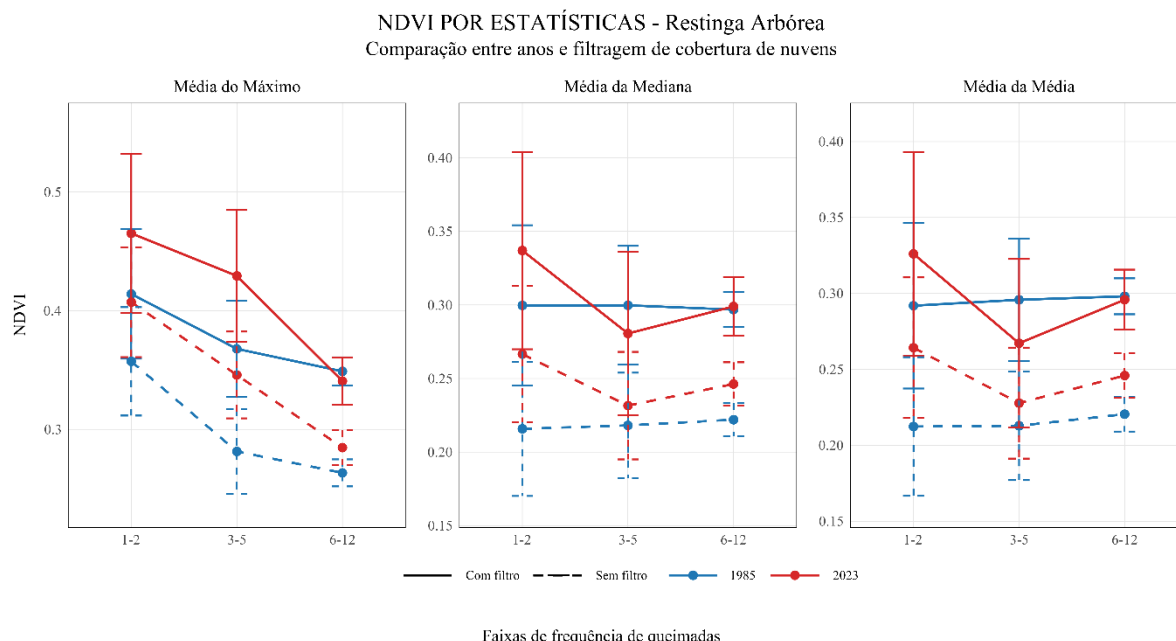


Figura 11. Estatísticas descritivas do NDVI — médias com desvio padrão dos valores máximos, médios e medianos, em áreas de restinga arbórea, conforme faixas de frequência de queimadas entre 1985 e 2023.

5 DISCUSSÃO

5.1 Padrões de frequência de queimadas por subclasse de cobertura vegetal

A predominância de eventos de baixa recorrência (1-2 eventos) nas subclasses estudadas reflete um padrão de uso esporádico do fogo (MAPBIOMAS, 2023), porém com causas distintas entre as subclasses. Nas formações florestais, a concentração em 1-2 eventos (89,3%) associa-se principalmente a incêndios acidentais em fragmentos isolados, amplificados pela proximidade de áreas urbanizadas (RIBEIRO et al., 2009). Nas pastagens (88,2%), o padrão vincula-se a práticas de manejo pecuário para renovação de biomassa (EMBRAPA, 2020), enquanto nas restingas (84,6%) relaciona-se a pressões de urbanização costeira (REZENDE et al., 2018). Contrastando com essas subclasses, os mosaicos exibiram maior recorrência de queimadas (4,9% acima de 6 eventos versus 1,3% nas florestas), padrão característico de zonas de expansão agrícola onde o fogo é instrumentalizado para conversão ativa de terras (ARAGÃO; SHIMABUKURO, 2010). Essa variabilidade confirma que os mecanismos locais são modulados pelo contexto socioeconômico e ecológico (IBAMA et al., 2023), com implicações diferenciadas para a conservação.

5.2 Estabilidade após eventos de queimada e transições no uso e cobertura do solo

A estabilidade das pastagens, com 83,1% dos pixels inalterados após 38 anos, configura um fenômeno socioecológico complexo onde o fogo atua como agente de manutenção do sistema produtivo. Conforme demonstrado por Cochrane (2003), esse padrão reflete a sinergia entre fatores estruturais como solos degradados com baixa competitividade para regeneração florestal e dinâmicas econômicas que privilegiam a pecuária extensiva de baixo investimento.

Contudo, essa aparente estabilidade mascara processos progressivos de empobrecimento edáfico e perda de biodiversidade (STRASSBURG et al., 2021).

Em nítido contraste, a instabilidade dos mosaicos de uso, com apenas 33,7% de permanência, revela sua função como paisagens de fronteira agrícola. Nessas áreas, 50,0% das transições direcionaram-se para pastagens e 10,1% para lavouras temporárias, padrão que segundo Aragão e Shimabukuro (2010) está intrinsecamente ligado à lógica de expansão periférica do agronegócio. A regeneração florestal observada nesses ambientes, alcançando 6,3%, concentrou-se justamente nessas zonas de tensão, corroborando o princípio estabelecido por Rodrigues et al. (2009) de que áreas em transição oferecem oportunidades para restauração passiva quando há redução da pressão antrópica. Nas formações florestais, a perda líquida de 43,4% da área original supera significativamente as taxas observadas em restingas, evidenciando maior vulnerabilidade de ecossistemas continentais. Essa diferença, conforme Ribeiro et al. (2009), deriva da combinação entre valor fundiário mais elevado em regiões interiores, conectividade viária que facilita o acesso a fragmentos, e menor proteção institucional comparada a zonas costeiras sob proteção federal.

5.3 Resposta espectral da vegetação ao fogo (NDVI)

A resposta diferencial do NDVI ao histórico de queimadas revela padrões contrastantes entre subclasses, evidenciando como características estruturais e estratégias ecofisiológicas modulam a resiliência espectral. Enquanto formações florestais sofrem reduções drásticas (>50%) nos valores máximos de NDVI após queimadas recorrentes (de 0.56 para 0.17 após 22-38 eventos), as pastagens mantêm estabilidade notável (NDVI máximo: 0.42-0.49; médio: 0.28), mesmo sob alta frequência de fogo. Esse contraste radical reflete diferenças funcionais essenciais: florestas experimentam perda progressiva de biomassa estratificada e simplificação estrutural do dossel (BARLOW; PERES, 2008), enquanto pastagens exibem rápida recuperação via proteção de meristemas basais e rebrota eficiente (FIDELIS et al., 2010). As restingas apresentam comportamento distinto, com assinatura espectral estruturalmente baixa (valores médios <0.30) devido à combinação de cobertura vegetal esparsa, solo exposto e alta reflexividade luminosa (VILA NOVA, 2013). Essa característica as torna particularmente sensíveis à interferência atmosférica, evidenciado pela queda de 80.8% nos valores médios após filtragem (0.26 → 0.05), redução significativamente maior que a observada em florestas (27%) ou pastagens (12%). Conforme Zhu e Woodcock (2012), essa vulnerabilidade singular deriva de interações entre partículas atmosféricas e propriedades ópticas de solos quartzosos, fenômeno menos crítico em subclasses com dossel contínuo.

Notavelmente, florestas, mosaicos e restingas convergem para NDVI <0.20 após altas frequências de fogo (22-38 eventos), patamar que equivale a solos expostos ou áreas urbanas degradadas (WENG, 2012). Essa convergência bioespectral, documentada por Aragão et al. (2018) em múltiplos biomas, sinaliza perda crítica de funções ecossistêmicas, independentemente do tipo vegetacional original. Em contraste, as pastagens mantêm NDVI >0.35 mesmo nessas condições extremas, reforçando seu papel como sistemas antrópicos resilientes.

A discrepância temporal entre 1985 e 2023, apresentando valores de NDVI mais elevados nas imagens orbitais dos pixels analisados em 2023, pode ser atribuída a múltiplos fatores inter-relacionados: avanços técnicos nos sensores orbitais, com a transição do Landsat 5 (TM) para o Landsat 8 (OLI), que proporcionaram melhor resolução radiométrica e correção atmosférica (ROY et al., 2014; USGS, 2023); processos de regeneração secundária; e a filtragem seletiva de nuvens ($\leq 10\%$ de cobertura), aplicada consistentemente a ambos os anos, que reduziu interferências atmosféricas nas análises comparativas.

6 CONCLUSÃO

Este estudo demonstrou que o aumento na frequência de queimadas (>5 eventos) reduz o NDVI em formações florestais da Mata Atlântica fluminense, indicando perda de vigor vegetativo e degradação. Em contraste, as pastagens mantiveram estabilidade espectral mesmo sob maior recorrência de fogo, refletindo a resiliência das gramíneas. A análise multitemporal (1985-2023) revelou tendência geral de elevação do NDVI, atribuída tanto à regeneração secundária em áreas abandonadas quanto a avanços tecnológicos na aquisição de imagens.

Os resultados validam o NDVI como indicador sensível à degradação florestal induzida por incêndios recorrentes, ressaltando a importância da filtragem de nuvens para maior confiabilidade das análises. Esses achados fornecem dados que podem ser utilizados a favor de políticas de restauração ecológica, sugerindo priorização de áreas florestais com alta frequência de queimadas. A abordagem metodológica, baseada em Google Earth Engine e séries históricas do MapBiomas, mostra-se eficaz para o monitoramento de ecossistemas fragmentados.

7 REFEERÊNCIAS BIBLIOGRÁFICAS

ALENCAR, A. A. C. et al, MapBiomas Fire Brazil Collection 3: Annual Burned Area Maps of Brazil (1985-2023). Algorithm Theoretical Basis Document (ATBD), **MapBiomas Data**, v. 2, 2024.

ALMEIDA, C. A. de et al. Accuracy assessment of land cover and land use maps produced with TerraClass system: The Brazilian Amazon case. **Remote Sensing**, v. 13, n. 3, p. 420, 2021.

ALMEIDA, C. A. de et al. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. **Acta Amazonica**, v. 49, n. 1, p. 1–12, 2019.

ARAGÃO, L. E. O. C. et al. 21st Century drought-related fires counteract the decline of Amazon deforestation carbon emissions. **Nature Communications**, v. 9, n. 536, 2018.

ARAGÃO, L. E. O. C. et al. 30 years of land use dynamics in the Brazilian Amazon: classification of Landsat time series using the Google Earth Engine platform. **Remote Sensing**, v. 14, n. 14, p. 3346, 2022.

ARAGÃO, L. E. O. C.; SHIMABUKURO, Y. E. The incidence of fire in Amazonian forests with implications for REDD. **Science**, v. 328, p. 1275–1278, 2010.

ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, [S. l.], v. 22, n. 18, p. 3855-3862, 2001.

BALCH, J. K. et al. The susceptibility of southeastern Amazon forests to fire: insights from a large-scale burn experiment. **BioScience**, v. 65, n. 9, p. 893–905, 2015.

BARLOW, J.; PERES, C. A. Fire-mediated dieback and compositional cascade in an Amazonian forest. **Philosophical Transactions of the Royal Society B**, v. 363, n. 1498, p. 1787–1794, 2008.

BELWARD, A. S.; SKØIEN, J. O. Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 103, p. 115–128, 2015.

BRANDO, P. M. et al. The gathering firestorm in southern Amazonia. **Science Advances**, v. 6, n. 2, eaay1632, 2020.

- CAMPBELL, J. B.; WYNNE, R. H. Introduction to remote sensing. 5. ed. New York: **Guilford Press**, 2011.
- CHANG, W. extrafont: Tools for Using Fonts. **Comprehensive R Archive Network**, 2023. Disponível em: <https://CRAN.R-project.org/package=extrafont>. Acesso em: 7 fev. 2025.
- CHUVIECO, E. Fundamentals of satellite remote sensing. 3. ed. Boca Raton: **CRC Press**, 2020.
- CNCFLOA. Centro Nacional de Conservação da Flora. **Brasil**, 2023.
- COCHRANE, M. A. Fire science for rainforests. **Nature**, v. 421, n. 6926, p. 913-919, 2003.
- CRUSCO, N. et al. Mapeamento e monitoramento da cobertura vegetal do bioma Mata Atlântica: Documento de Base Teórica do Algoritmo (ATBD) - Coleção 9. **MapBiomias**, 2024.
- DONK, B. et al. Teaching the use of Google Earth Engine: Barriers, opportunities and recommendations. **Remote Sensing**, v. 14, n. 3, p. 627, 2022.
- EMBRAPA. Guia para uso do fogo no manejo de pastagem em nível de fazenda. Corumbá, MS: **Embrapa Pantanal**, 2020.
- ESRI. ArcGIS Desktop: Release 10.5. Redlands: **Environmental Systems Research Institute**, 2016.
- FIDELIS, A. et al. Fire intensity and severity in Brazilian campos grasslands. **Interciencia**, v. 35, n. 10, p. 739-745, 2010.
- FONSECA, L. M. G. et al. Deep learning for mapping fire-prone areas in the Brazilian Amazon. **Sensors**, v. 23, n. 5, p. 2432, 2023.
- FRANKLIN, J. et al. Global change and terrestrial plant community dynamics. **Proceedings of the National Academy of Sciences of the United States of America**, v. 113, n. 14, p. 3725–3734, 2015.
- GALLETTI, M. et al. Ecological consequences of defaunation in the Atlantic Forest. **Biotropica**, v. 45, n. 3, p. 273–281, 2013.
- GARNIER, S. et al. viridis: Colorblind-Friendly Color Maps for R. **Comprehensive R Archive Network**, 2024. Disponível em: <https://CRAN.R-project.org/package=viridis>. Acesso em: 7 jun. 2025.
- GITELSON, A. A. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. **Journal of Plant Physiology**, v. 161, n. 2, p. 165–173, 2004.
- GORE, N. et al. Google Earth Engine Code Editor: A cloud-based geospatial analysis platform. Version 1.0. Mountain View: **Google**, 2023.
- GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017.
- HANSEN, M. C. et al. High-resolution global maps of 21st-century forest cover change. **Science**, v. 342, n. 6160, p. 850–853, 2013.
- HENRY, L. et al. purrr: Functional Programming Tools. 2025. **Comprehensive R Archive Network**, Disponível em: <https://CRAN.R-project.org/package=purrr>. Acesso em: 7 jun. 2025.
- HOUGHTON, R. A. et al. The spatial and temporal distribution of carbon emissions from forest clearing and burning in Brazil. **Global Change Biology**, v. 28, n. 2, p. 556–572, 2022.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988.
- HUETE, A. R. et al. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, n. 3, p. 440–451, 1997.
- HUETE, A. R. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195–213, 2002.

- IBAMA. Plano de Ação para o Manejo Integrado do Fogo no Pantanal. **Brasília**, 2023.
- IBGE. Base Cartográfica Contínua do Brasil ao Milionésimo - BCIM: Rio de Janeiro. Escala 1:1.000.000. Versão 2023. Rio de Janeiro: **Instituto Brasileiro de Geografia e Estatística**, 2023.
- ICMBIO. Livro Vermelho da Fauna Brasileira Ameaçada de Extinção. **Brasil**, 2018.
- IPBES. Global assessment report on biodiversity and ecosystem services of the Intergovernmental Science-Policy Platform on Biodiversity and Ecosystem Services. Bonn: **IPBES Secretariat**, 2019.
- JENSEN, J. R. Remote sensing of the environment: an earth resource perspective. 2. ed. Boston: **Pearson**, 2016.
- JIANG, Z. et al. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833–3845, 2006.
- JOLY, C. A. et al. Biodiversity conservation research, training, and policy in São Paulo. **Science**, v. 345, n. 6202, p. 1270–1271, 2014.
- KENNEDY, R. E. et al. Bringing an ecological perspective to the problem of change detection. **Remote Sensing of Environment**, v. 210, p. 522–535, 2018.
- KENNEDY, R. E. et al. Implementation of the LandTrendr algorithm in Google Earth Engine. **Remote Sensing**, v. 10, n. 5, p. 691, 2018.
- KERR, J. T.; OSTROVSKY, M. From space to species: ecological applications for remote sensing. *Trends in Ecology & Evolution*, v. 18, n. 6, p. 299–305, 2003.
- KOGAN, F. Application of vegetation index and brightness temperature for drought detection. **Advances in Space Research**, v. 15, n. 11, p. 91–100, 1995.
- LE PAGE, M.; ZRIBI, M. Analysis and predictability of drought in Northwest Africa using optical and microwave satellite remote sensing products. **Scientific reports**, v. 9, n. 1, p. 1466, 2019.
- LIBONATI, R. et al. Assessment of burned area detection and mapping using MODIS data. **Remote Sensing of Environment**, v. 206, p. 74–88, 2021.
- LILLESAND, T. et al. Remote sensing and image interpretation. 7. ed. New York: **Wiley**, 2015.
- MAPBIOMAS. Projeto MapBiomass – Coleção 8.0 da Série Anual de Mapas de Cobertura e Uso da Terra do Brasil. **MapBiomass**, 2023.
- MAPBIOMAS. Projeto MapBiomass – Coleção 9 da Série Anual de Mapas de Cobertura e Uso do Solo do Brasil. **MapBiomass**, 2023.
- MAPBIOMAS. Relatório anual de áreas queimadas: Brasil 1985–2022. São Paulo: **MapBiomass**, 2023.
- MARQUES, M. C. M. et al. The Atlantic Forest: An Introduction to the Megadiverse Forest of South America. Cham: **Springer**, 2021.
- MMA. Livro Vermelho da Flora do Brasil. **Brasil**, 2022.
- MYERS, N. et al. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853–858, 2000.
- PEDERSEN, T. L. patchwork: The Composer of ggplots. **Comprehensive R Archive Network**, 2024. Disponível em: <https://CRAN.R-project.org/package=patchwork>. Acesso em: 7 jun. 2025.
- PETTORELLI, N. et al. The Normalized Difference Vegetation Index (NDVI): unforeseen successes in animal ecology. **Climate Research**, v. 46, n. 1, p. 15–27, 2011.
- PETTORELLI, N. et al. Using the satellite-derived NDVI to assess ecological responses to environmental change. **Trends in Ecology & Evolution**, v. 20, n. 9, p. 503–510, 2005.
- QGIS DEVELOPMENT TEAM. QGIS Geographic Information System. Versão 3.42.3. **Open Source Geospatial Foundation**, 2024.

- QIU, Y. et al. showtext: Using Fonts More Easily in R Graphs. **Comprehensive R Archive Network**, 2024. Disponível em: <https://CRAN.R-project.org/package=showtext>. Acesso em: 7 jun. 2025.
- R CORE TEAM. R: Uma linguagem e ambiente para computação estatística. Versão 4.5.0. Viena: **R Foundation for Statistical Computing**, 2024.
- Flora e Funga do Brasil (REFLORA). Jardim Botânico do Rio de Janeiro. Disponível em: < <http://floradobrasil.jbrj.gov.br/> >. Acesso em: 02 abr 2025
- REICHE, J. et al. Forest disturbance alerts for the Congo Basin using Sentinel-1. **Environmental Research Letters**, v. 16, n. 2, p. 024005, 2021.
- REICHENBACH, M. et al. Radar-based monitoring of tropical forest degradation using Sentinel-1. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 176, p. 281–294, 2021.
- REZENDE, C. L. et al. From hotspot to hopespot: An opportunity for the Brazilian Atlantic Forest. **Perspectives in Ecology and Conservation**, v. 16, n. 4, p. 208–214, 2018.
- RIBEIRO, M. C. et al. The Brazilian Atlantic Forest: How much is left, and how is the remaining forest distributed? **Biological Conservation**, v. 142, n. 6, p. 1141–1153, 2009.
- RODRIGUES, R. R. et al. Large-scale ecological restoration of high-diversity tropical forests in SE Brazil. **Forest Ecology and Management**, v. 261, n. 10, p. 1605–1613, 2009.
- RODRIGUES, R. R. et al. On the restoration of high diversity forests: 30 years of experience in the Brazilian Atlantic Forest. **Biological Conservation**, v. 142, n. 6, p. 1242–1251, 2009.
- ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. In: Third Earth Resources Technology Satellite-1 Symposium. Washington: **NASA SP-351**, 1974. p. 309–317.
- ROY, D. P. et al. Characterization of Landsat-7 to Landsat-8 reflective wavelength and normalized difference vegetation index continuity. **Remote Sensing of Environment**, v. 185, p. 57-70, 2016.
- ROY, D. P. et al. Landsat-8: Science and product vision for terrestrial global change research. **Remote Sensing of Environment**, v. 145, p. 154–172, 2014.
- RSTUDIO TEAM. RStudio: Ambiente de Desenvolvimento Integrado para R. Versão 2024.09.0. Boston: **Posit Software, PBC**, 2024.
- SANTOS, F. F. et al. Wildfires as a major challenge for natural regeneration in Atlantic Forest. **Science of The Total Environment**, v. 650, p. 809-821, 2019.
- SANTOS, J. M. et al. Predictive modeling of fire-prone areas using convolutional neural networks. **Remote Sensing**, v. 15, n. 2, p. 380, 2023.
- SCARANO, F. R. Structure, function and floristic relationships of plant communities in stressful habitats marginal to the Brazilian Atlantic rainforest. **Annals of Botany**, v. 90, n. 4, p. 517–524, 2002.
- SHIMABUKURO, Y. E. et al. (2020). Mapping Burned Areas of Mato Grosso State Brazilian Amazon Using Multisensor Datasets. **Remote Sens**, 12(22), 3827, 2020.
- SILVA JUNIOR, C. H. L. et al. The Brazilian Amazon deforestation rate in 2020 is the greatest of the decade. **Nature Ecology & Evolution**, v. 5, p. 144-145, 2020.
- SON, N. T. et al. Crop yield estimation using multitemporal remote sensing data. **International Journal of Applied Earth Observation and Geoinformation**, v. 61, p. 175–184, 2017.
- SON, N. T. et al. Monitoring agricultural drought in the Lower Mekong Basin using MODIS NDVI and land surface temperature data. **International Journal of Applied Earth Observation**, v. 18, p. 417-427, 2012.
- SOS MATA ATLÂNTICA. Atlas da Mata Atlântica: Remanescentes florestais. São Paulo: **Fundação SOS Mata Atlântica**, 2022.

SOUZA, C. M. et al. Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and Earth Engine. **Remote Sensing**, v. 12, n. 17, p. 2735, 2020.

STRASSBURG, B. B. N. et al. Global priority areas for ecosystem restoration. **Nature**, v. 586, p. 724-729, 2021.

TABARELLI, M. et al. Prospects for biodiversity conservation in the Atlantic Forest: Lessons from aging human-modified landscapes. **Biological Conservation**, v. 143, p. 2328-2340, 2010.

THENKABAIL, P. S. et al. Hyperspectral remote sensing of vegetation and agricultural crops. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 7, p. 715-735, 2012.

TUCKER, C. J. et al. An extended AVHRR 8-km NDVI dataset compatible with MODIS and SPOT vegetation NDVI data. **International Journal of Remote Sensing**, v. 26, n. 20, p. 4485-4498, 2005.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127-150, 1979.

UNITED NATIONS. Global forest goals report 2021. New York: **Department of Economic and Social Affairs**, 2019.

UNITED STATES GEOLOGICAL SURVEY (USGS). Landsat 8-9 OLI/TIRS Collection 2 Level 2 Data Format Control Book. Reston: **USGS**, 2019.

UNITED STATES GEOLOGICAL SURVEY (USGS). Landsat Collections: U.S. Geological Survey Data Documentation. Reston, VA: **USGS**, 2023.

VERMOTE, E. et al. LaSRC (Land Surface Reflectance Code): Overview, application and validation using MODIS, VIIRS, LANDSAT and Sentinel 2 data. In: International Society for Optics and Photonics. **Earth Observing Systems XXIII**. v. 10781, p. 107810E, 2018.

VILA NOVA, Fátima Verônica Pereira et al. Aplicação do índice de vegetação por diferença normalizada no monitoramento dos manguezais: Litoral sul de Pernambuco-Brasil. **Geografares**, n. 15, 2013.

WENG, Q. Remote sensing of impervious surfaces in the urban areas: requirements, methods, and trends. **Remote Sensing of Environment**, v. 117, p. 34-49, 2012.

WICKHAM, H. et al. dplyr: A Grammar of Data Manipulation. **Comprehensive R Archive Network**, 2023. Disponível em: <https://CRAN.R-project.org/package=dplyr>. Acesso em: 7 jun. 2025.

WICKHAM, H. et al. ggplot2: Create Elegant Data Visualisations Using the Grammar of Graphics. **Comprehensive R Archive Network**, 2025. Disponível em: <https://CRAN.R-project.org/package=ggplot2>. Acesso em: 7 jun. 2025.

WICKHAM, H. et al. readxl: Read Excel Files. **Comprehensive R Archive Network**, 2025. Disponível em: <https://CRAN.R-project.org/package=readxl>. Acesso em: 7 jun. 2025.

WICKHAM, H. et al. tidyr: Tidy Messy Data. **Comprehensive R Archive Network**, 2024. Disponível em: <https://CRAN.R-project.org/package=tidyr>. Acesso em: 7 jun. 2025.

WICKHAM, H. stringr: Simple, Consistent Wrappers for Common String Operations. **Comprehensive R Archive Network**, 2023. Disponível em: <https://CRAN.R-project.org/package=stringr>. Acesso em: 7 jun. 2025.

WILKE, C. O. cowplot: Streamlined Plot Theme and Plot Annotations for ggplot2. **Comprehensive R Archive Network**, 2024. Disponível em: <https://CRAN.R-project.org/package=cowplot>. Acesso em: 7 jun. 2025.

WULDER, M. A. et al. The global Landsat archive: Status, consolidation, and direction. **Remote Sensing of Environment**, v. 185, p. 271-283, 2016.

XIONG, J. et al. Automated cropland mapping of continental Africa using Google Earth Engine cloud computing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 126, p. 225-244, 2017.

XIONG, J. et al. Automated cropland mapping of continental Southeast Asia using Google Earth Engine. **Remote Sensing**, v. 9, n. 3, p. 238, 2017.

ZHANG, C. et al. Review of remote sensing technologies for forest fire monitoring. **Remote Sensing of Environment**, v. 232, p. 111297, 2019.

ZHAO, D. et al. A comparative analysis of broadband and narrowband derived vegetation indices in predicting LAI and CCD of a cotton canopy. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 62, p. 25-33, 2007.

ZHU, Z. et al. Benefits of the free and open Landsat data policy. **Remote Sensing of Environment**, v. 122, p. 2–10, 2015.

ZHU, Z.; WOODCOCK, C. E. Improvement and expansion of the Fmask algorithm: cloud, cloud shadow, and snow detection for Landsats 4–7, 8, and Sentinel 2 images. **Remote Sensing of Environment**, [S. l.], v. 159, p. 269-277, 2015.

ZHU, Z.; WOODCOCK, C. E. Object-based cloud and cloud shadow detection in Landsat imagery. **Remote Sensing of Environment**, v. 118, p. 83–94, 2012.