



Mapeamento da perda de vegetação por urbanização na Barra da Tijuca (1984-2024) com o algoritmo LandTrendr e séries temporais Landsat

Mapping vegetation loss due to urbanization in Barra da Tijuca (1984–2024) using the LandTrendr algorithm and Landsat time series

Mapeo de la pérdida de vegetación por urbanización en Barra da Tijuca (1984–2024) con el algoritmo LandTrendr y series temporales Landsat

Matheus Augusto de Souza¹ e Debora da Paz Gomes Brandão Ferraz²

¹Universidade Federal do Rio de Janeiro, Av. Athos da Silveira Ramos, 274, Cidade Universitária, Rio de Janeiro/RJ, CEP: 21941-916, ORCID: 0009-0009-9759-6691, mataugusto1999@gmail.com

²Universidade do Estado do Rio de Janeiro - Instituto de Geografia Cabo Frio, Rua Arízio Gomes da Costa, 186, Jardim Flamboyant, Cabo Frio/RJ, CEP 28905-320, ORCID: 0000-0003-2826-1715, debora.ferraz93@gmail.com

Resumo

Volume
13

Edição
4

*Autor(a) correspondente
mataugusto1999@gmail.com

Submetido em 20 nov 2025

Aceito em 07 jan 2026

Publicado em 28 jan 2026

Como Citar?

SOUZA, M. A.; FERRAZ, D. P. G. B. Mapeamento da perda de vegetação por urbanização na Barra da Tijuca (1984-2024) com o algoritmo LandTrendr e séries temporais Landsat.

Coleção Estudos Cariocas, v. 13, n. 4, 2026.
DOI: 10.71256/19847203.13.4.196.2025

O artigo foi originalmente submetido em PORTUGUÊS.

As traduções para outros idiomas foram revisadas e validadas pelos autores e pela equipe editorial. No entanto, para a representação mais precisa do tema abordado, recomenda-se que os leitores consultem o artigo em seu idioma original.

OPEN  ACCESS



A detecção de mudanças em áreas naturais é essencial para sua preservação. Este estudo avaliou o desflorestamento associado à urbanização na Barra da Tijuca (RJ), utilizando o algoritmo LandTrendr em séries temporais de imagens Landsat (1985 - 2024). O método alcançou alta precisão, com acurácia global de 0,92, F1-score de 0,91 e Kappa de 0,83. Os resultados indicaram que o período de maior mudança ocorreu entre 1985 e 1990, com 22,5 km² alterados, valor três vezes superior ao período de 2010-2015 (7,4 km²). Estas transformações estão associadas à intensa expansão imobiliária e ao desenvolvimento urbano.

Palavras-chave: detecção de mudanças, sensoriamento remoto, NDVI, Google Earth Engine

Abstract

Detecting changes in natural areas is essential for their preservation. This study evaluated deforestation associated with urbanization in Barra da Tijuca (Rio de Janeiro), using the LandTrendr algorithm on a time series of Landsat images (1985-2024). The method achieved high precision, with an overall accuracy of 0.92, an F1-score of 0.91, and a Kappa of 0.83. The results indicated that the period of greatest change occurred between 1985 and 1990, with 22.5 km² altered, a value three times higher than the period of 2010-2015 (7.4 km²). These transformations are associated with intense real estate expansion and urban development.

Keywords: change detection, remote sensing, NDVI, Google Earth Engine

Resumen

Detectar los cambios en las áreas naturales es esencial para su conservación. Este estudio evaluó la deforestación asociada a la urbanización en Barra da Tijuca (Río de Janeiro), utilizando el algoritmo LandTrendr en series temporales de imágenes Landsat (1985-2024). El método alcanzó una alta precisión, con una exactitud global de 0,92, una puntuación F1 de 0,91 y un índice Kappa de 0,83. Los resultados indicaron que el periodo de mayor cambio se produjo entre 1985 y 1990, con 22,5 km² alterados, un valor tres veces superior al del periodo 2010-2015 (7,4 km²). Estas transformaciones están asociadas a la intensa expansión inmobiliaria y al desarrollo urbano.

Palabras clave: detección de cambios, teledetección, NDVI, Google Earth Engine

1 Introdução

A Região Administrativa XXIV - Barra da Tijuca, Rio de Janeiro (RJ), caracteriza-se por sua alta densidade populacional e intensa urbanização. O desenvolvimento desta região intensificou-se na década de 1970, impulsionado pelo Plano Piloto de Lúcio Costa (1969), que visava transformá-la em um grande centro urbano. O projeto incentivou a construção de grandes condomínios e a separação de setores urbanos, conforme destacado por Mendonça (2023). De acordo com Abreu (2006), a junção destas características atraiu empreendimentos imobiliários e consolidou a Barra como uma região de grande valorização e referência para a população de alta renda, alcançando, em 2010, o terceiro maior Índice de Desenvolvimento Humano Municipal (IDH-M) da cidade.

Apesar do desenvolvimento acelerado, o monitoramento da região é imprescindível, dada a presença de importantes Unidades de Conservação e Áreas de Proteção Ambiental (APA), tais como o Parque Estadual da Pedra Branca, a APA da Pedra Branca e o Parque Nacional da Tijuca, que abrigam remanescentes de Mata Atlântica, como florestas ombrófilas, restingas e manguezais. Este bioma é considerado prioritário para a conservação da biodiversidade mundial, como descrito por Mazzurana (2016). Contudo, evidências indicam crescente pressão sobre estas áreas protegidas. Sousa (2019) descreve a discussão sobre os impactos ambientais decorrentes do desmatamento e ocupações irregulares, tanto por populações de baixa renda quanto por empreendimentos de alto padrão.

A dinâmica de ocupação irregular é agravada pela atuação de grupos criminosos, como milícias, na promoção de construções ilegais e lavagem de dinheiro, fatos corroborados por reportagens locais como a de Peixoto e Nascimento (2023). Sousa (2019) destaca que, muitas vezes, a atuação desses grupos reage aos sinais do mercado imobiliário mais rapidamente que o poder público. Essas intervenções, somadas à expansão de comunidades periféricas em encostas e ao desenvolvimento imobiliário formal, resultam na supressão da vegetação e riscos geológicos. Adicionalmente, o despejo irregular de resíduos impacta a integridade ecológica dos manguezais, apesar da resiliência natural desse ecossistema, conforme destacado por Soffiati (2024).

Diante desse desafio socioambiental, é fundamental compreender a dinâmica dessa expansão de forma quantitativa para subsidiar a gestão territorial (Tahir *et al.*, 2025). A análise de séries temporais de imagens de sensoriamento remoto é uma ferramenta robusta para a observação de diversos fenômenos que alteram o uso e a cobertura do solo, sejam eles por dinâmicas ambientais ou intervenções humanas, como o desmatamento e a urbanização (Zhu; Woodcock, 2014, Gómez *et al.*, 2016). Essa análise permite uma maior compreensão sobre os fenômenos, fatores e impactos dessas alterações. Para uma análise de grandes volumes de dados de sensoriamento remoto (*Big EO Data*), o modelo de array tridimensional é o mais apropriado e permite a classificação temporal de duas formas: classificando cada série temporal individualmente e, após isso, unindo os resultados no espaço (abordagem que segue o paradigma *Time-First*, priorizando o tempo e depois o espaço); ou classificando cada imagem separadamente e, após isso, comparando as classificações resultantes ao longo do tempo (abordagem que segue o paradigma *Space-First*, priorizando o espaço e depois o tempo) (Vinhos *et al.*, 2016). Para Maus *et al.* (2016), uma análise de série temporal pode combinar ambas as classificações temporais, o que foi corroborado por Vinhos *et al.* (2016).

Este estudo utiliza o algoritmo *LandTrendr* (LT) — *Landsat-based Detection of Trends in Disturbance and Recovery* — para identificar e caracterizar os períodos de mudança nas áreas naturalmente vegetadas e mensurar a magnitude das alterações ocorridas entre os anos de 1984 e 2024. O LT é uma ferramenta de segmentação espectro-temporal eficaz na detecção de padrões de mudança (Kennedy; Yang; Cohen, 2010). Embora desenvolvido para monitoramento florestal, o algoritmo tem sido amplamente empregado em análises urbanas. Yan e Wang (2021) utilizaram sete bandas/índices no LT para obter informações sobre a

mudança urbana em Karachi (Paquistão) no período de 2000 a 2020. Eles consideraram o valor majoritário da informação como resultado, em uma abordagem semelhante ao método de votação majoritária, o que, segundo os autores, permite superar de forma eficaz a incerteza na extração de informações sobre a expansão urbana, em comparação com o uso de uma única banda/índice. Hu *et al.* (2024) utilizaram a banda do infravermelho de ondas curtas (SWIR) no LT para extrair o tempo de construção de edifícios, a partir de dados mensais da série temporal Landsat. A abordagem foi utilizada para a detecção de mudanças na construção, demolição e reconstrução de edifícios na cidade de Pequim (China), no período de 1990 a 2020. Mugiraneza, Nascetti e Ban (2020) tiveram como objetivo o monitoramento contínuo das trajetórias de mudanças na cobertura do solo urbano. Para isso, eles mesclaram os resultados do LT, que utilizou múltiplos índices, para reconstruir mapas densos de cobertura do solo anuais para o período de 1990 a 2019.

Considerando este contexto, o objetivo do presente estudo consistiu em analisar as mudanças de uso e cobertura do solo na Barra da Tijuca, entre os anos de 1984 e 2024, por meio do algoritmo *LandTrendr*. A pesquisa busca quantificar e mapear a perda de áreas vegetadas em decorrência da expansão urbana, validando os resultados por meio de matriz de erro e métricas de acurácia, para garantir a precisão na detecção das mudanças mapeadas.

2 Material e métodos

2.1 Área de estudo

A Região Administrativa XXIV - Barra da Tijuca (Figura 1) corresponde a uma área de aproximadamente 165 km², localizada na Área de Planejamento 4 (AP4) - Zona Sudoeste do município do Rio de Janeiro (RJ). Este bioma, devido ao intenso processo de urbanização dos grandes centros urbanos — presentes em sua maioria nas regiões litorâneas brasileiras —, teve seu território devastado, sendo o bioma brasileiro que mais sofreu sob a influência da urbanização. Ressalta-se que mais de 60% da população brasileira residia no domínio desse bioma no ano de 2016, quando este representava cerca de 7% de suas florestas originais, como apresentado por Mazzurana (2016). Localmente, a Barra da Tijuca é a 8^a região mais populosa do município, segundo os dados preliminares do Censo de 2022 (Prefeitura da Cidade do Rio de Janeiro, 2024), e enfrenta de forma recorrente problemas relacionados à urbanização, como o desmatamento e ocupação de moradias irregulares em áreas de proteção ambiental, por parte de populações de todas as faixas de renda, como destacado por Sousa (2018). O processo de urbanização tardio, iniciado pouco antes da disponibilidade de dados *Landsat*, permitiu a escolha dessa área para a observação do avanço das áreas antrópicas sobre as regiões naturais. Apesar da extensão territorial limitada, a aplicação do algoritmo demonstrou-se viável dada a resolução espacial de 30 metros dos dados *Landsat*, uma vez que a ferramenta foi desenvolvida especificamente para operar com esses sensores. Além disso, o algoritmo tem sido amplamente empregado na análise de trajetórias de mudanças em áreas urbanas.

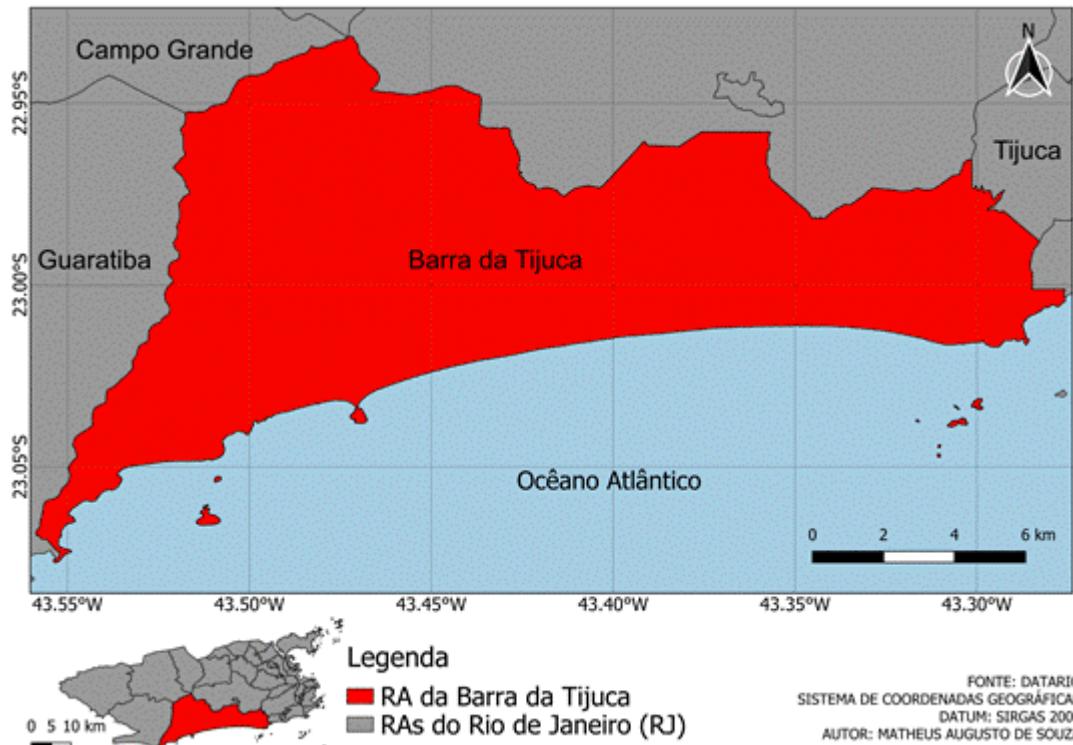


Figura 1: Área de Estudo - RA da Barra da Tijuca, Rio de Janeiro (RJ)

Fonte: Autores (2025)

2.2 Materiais

O algoritmo *LandTrendr* (*Landsat-based detection of Trends in Disturbance and Recovery*), desenvolvido por Kennedy, Yang e Cohen (2010) e implementado no *Google Earth Engine* (LT-GEE), é uma abordagem que permite uma análise abrangente e mais rápida do que a imagem atual (Kennedy *et al.*, 2018). O objetivo geral do *LandTrendr* é caracterizar uma trajetória temporal de valores de dados usando uma sequência de segmentos lineares conectados, delimitados por pontos de quebra ou nós. O algoritmo trabalha com um intervalo de análise de uma imagem por ano, cabendo ao usuário a parametrização para extrair as melhores informações de acordo com o objetivo, variando de acordo com a banda espectral e/ou índice utilizado.

Segundo Câmara *et al.* (2016), a abordagem em trajetórias representa um novo paradigma no estudo das mudanças, destacando o tempo como variável central, em vez do espaço, como muitos mapeamentos consideram. Isso é conhecido como "*time first vs space first*", onde a resposta temporal se torna o elemento central na identificação de determinados fenômenos (Weckmüller; Vicens, 2018).

Os dados temporais são analisados antes dos dados espaciais, e a análise da série temporal é priorizada. O LT foi originalmente desenvolvido para o monitoramento de mudanças florestais, como desmatamento, queimada e regeneração, e atualmente inclui novos índices espetrais, como o NDSI (*Normalized Difference Snow Index*) e o NDMI (*Normalized Difference Moisture Index*). O objetivo desta ferramenta é mapear as alterações em cada pixel ao longo do tempo, definindo eventos de mudanças quando houver. Os eventos mapeados geram bandas como 'ano da mudança', 'magnitude da mudança', 'valor pré-mudança' e 'duração da mudança'. Este estudo focou-se na utilização das bandas 'magnitude da mudança', 'ano da mudança' e "duração da mudança".

As imagens Landsat foram obtidas de forma gratuita da USGS (*United States Geological Survey*), através do catálogo de imagens do GEE (*Google Earth Engine Data Catalog*). Foram utilizados os produtos *Landsat Surface Reflectance Tier 1*, com resolução espacial de 30 metros e resolução temporal de 16 dias, para a

análise da série temporal de 40 anos de imagens. Apesar de os sensores TM (*Thematic Mapper*), a bordo do satélite *Landsat 5*, e ETM+ (*Enhanced Thematic Mapper Plus*), a bordo do satélite *Landsat 7*, serem diferentes, eles operam nas mesmas faixas espectrais, o que assegura a integração entre seus dados. Já o sensor OLI (*Operational Land Imager*), a bordo do satélite *Landsat 8*, cuja operação iniciou em 2013, também integrado ao LT, opera em mais faixas espectrais que seus antecessores, porém em regiões do espectro comuns a estes. Por se tratar de um método com base em séries temporais, é necessário que os dados sejam normalizados quanto a diferenças entre sensores e estejam livres de ruídos atmosféricos (como nuvens e sombras), assegurando a consistência dos dados ao longo dos anos. O GEE disponibiliza os dados de reflectância de superfície para os sensores *Landsat*, já com correção geométrica e atmosférica, normalizados em seu catálogo.

O algoritmo foi implementado na plataforma GEE, como proposto por Kennedy *et al.* (2018). Sua execução requer a definição de três grupos de parâmetros: parâmetros da coleção, parâmetros de execução e parâmetros de mudança (Figura 2). O índice utilizado na análise da série temporal, para observação de áreas naturalmente vegetadas que sofreram supressão, foi o *Normalized Difference Vegetation Index* (NDVI, Índice de Vegetação por Diferença Normalizada - Equação 1).

$$NDVI = \frac{NIR-Red}{NIR+Red} \quad (1)$$

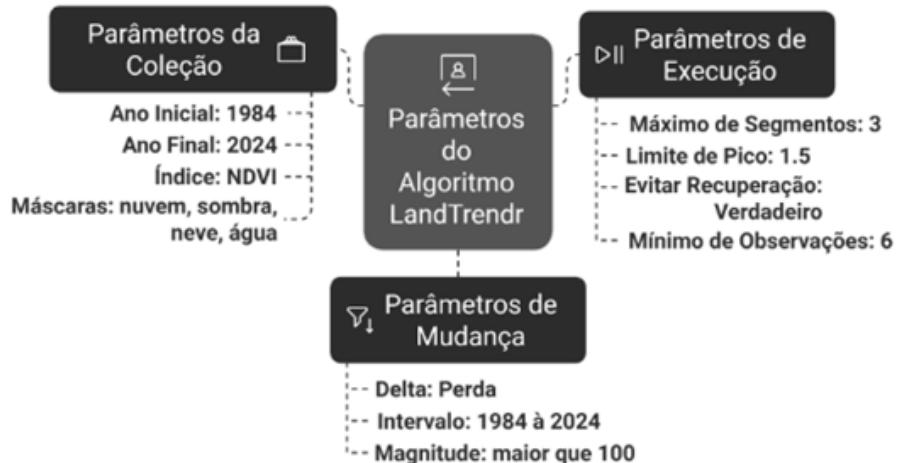


Figura 2: Parâmetros de Entrada do Algoritmo LT-GEE
Fonte: Autores (2025)

2.2.1 Parametrização do LT

Como parâmetro da coleção, foi utilizado o índice NDVI. É importante ressaltar que o LandTrendr pode ser aplicado a diferentes métricas espectrais, incluindo bandas individuais e outros índices espectrais, como, por exemplo, o índice NBR (Normalized Burn Ratio, ou Índice de Queimada Normalizado). A seleção deste parâmetro é determinante para a interpretação da mudança detectada. Por exemplo, enquanto no uso do NDVI uma diminuição no valor do pixel implica a substituição ou supressão da vegetação, em bandas como o infravermelho de ondas curtas (SWIR), uma diminuição indicaria o processo inverso (como recuperação de biomassa, perda de área construída ou de solo exposto), visto que superfícies não vegetadas tendem a apresentar maior reflectância neste comprimento de onda. A escolha deste índice se justifica por sua importância na análise de uma região naturalmente coberta por Mata Atlântica. Além disso, historicamente é um dos índices mais utilizados em análises de Sensoriamento Remoto, devido a sua formulação simples e a disponibilidade de séries temporais

longas de satélites, permitindo monitorar fenologia, produtividade (biomassa/produção primária), detecção de secas e degradação, avaliação agrícola e estudos ecológicos em grandes escalas (Rouse *et al.*, 1974; Ponzoni; Shimabukuro, 2010; Huang *et al.*, 2021).

No contexto da área de estudo, as variações nos valores de NDVI, apesar de não representarem diretamente o impacto da urbanização, podem ser associadas à sua dinâmica, já que sua variação ao longo do tempo pode refletir mudanças nos elementos da superfície terrestre, como cobertura vegetal, solo exposto, corpos d'água ou áreas construídas. Assim, reduções persistentes nos valores de NDVI podem indicar processos de substituição da vegetação por superfícies antrópicas.

Adicionalmente, aplicou-se um filtro sazonal selecionando apenas imagens adquiridas entre maio e junho. Esse intervalo, que corresponde ao final da estação de transição do outono e antecede o inverno, tende a apresentar condições mais secas e frias, reduzindo a instabilidade atmosférica e, consequentemente, a ocorrência de nuvens, o que contribui para diminuir o ruído na série temporal. Embora o algoritmo permita trabalhar com diversos períodos ao longo do ano, a escolha por esse recorte sazonal visa garantir maior consistência espectral entre os anos analisados, o que visa evitar algumas limitações, como o risco de gerar áreas sem dados (*No-Data*) devido à presença eventual de sombras, nuvens ou outros ruídos nas poucas imagens disponíveis neste período.

Nos parâmetros de execução, foi definido o máximo de 3 segmentos, com o objetivo de detectar apenas mudanças que permaneceram. Nessa configuração, o período de estabilidade anterior à mudança é definido como um segmento, a transição da mudança como um segundo segmento, e o último segmento representa o período posterior à mudança, no qual o índice se mantém estável e em nível inferior ao anterior. Essa configuração permite caracterizar transições como, por exemplo, uma área com vegetação que se torna desmatada e, posteriormente, transforma-se em solo exposto preparado para um loteamento, a partir da mudança registrada no ano 2000. Isso facilita a interpretação dos processos de transformação observados. O parâmetro de 'mínimo de 6 observações' destaca a necessidade de o modelo analisar, no mínimo seis vezes, os resultados para a realização de ajustes das suas saídas. Como o objetivo do estudo foi somente observar áreas que sofreram mudanças relacionadas a perda de vegetação para se tornarem de outro uso, foi aplicado o parâmetro para evitar a detecção de recuperação do índice no período de um ano; ou seja, se houvesse recuperação do índice neste período, o evento não seria classificado como uma mudança.

A segmentação do algoritmo é feita dividindo a trajetória espectral de cada pixel ao longo do tempo. O LT divide essa trajetória em segmentos lineares, representando fases de estabilidade ou momentos de mudança. Períodos prolongados de estabilidade são caracterizados por segmentos de baixa inclinação, enquanto perturbações abruptas, como desmatamentos, geram segmentos curtos e íngremes, refletindo variações expressivas nos valores espetrais dos pixels, como demonstrado na Figura 3.

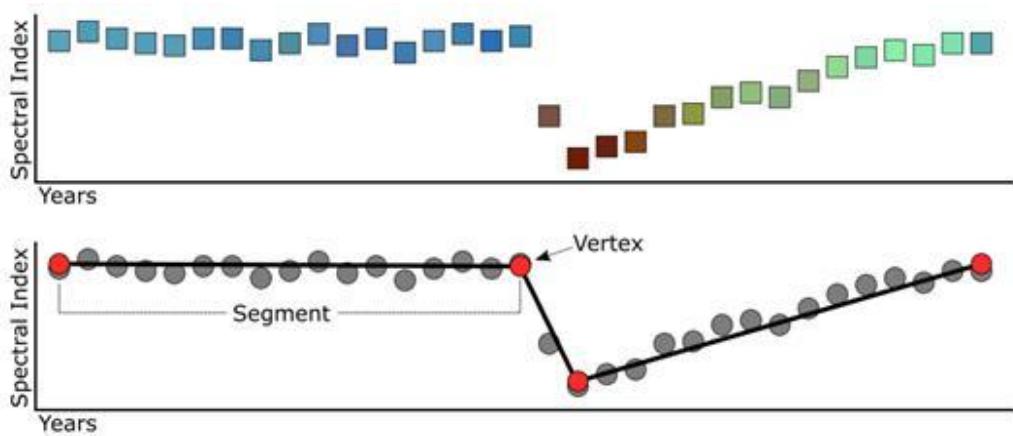


Figura 3. Segmentação de séries temporais de pixels do LandTrendr. Os dados da imagem são reduzidos a uma única banda ou índice espectral e, em seguida, divididos em uma série de segmentos de linha reta por identificação de ponto de interrupção (vértice).

Fonte: Adaptado de LT-GEE Guide (disponível em: <https://emapr.github.io/LT-GEE/landtrendr.html>)

A magnitude da mudança é mensurada pela comparação entre os valores do índice utilizado antes e depois da ocorrência da alteração. Por exemplo, um pixel que apresentava $NDVI = 0,8$ (floresta) e passou para $NDVI = -0,1$ (solo exposto, água, etc.) exibe uma magnitude de mudança de $-0,9$.

Nesta pesquisa, uma variação negativa de no mínimo 0,1 foi definida como mudança, desde que não houvesse recuperação do índice no período de um ano. Como o LT armazena o valor absoluto do delta espectral, a alteração do exemplo (um delta de 0,9) é apresentada com uma magnitude de 900, o que indica uma forte perda da característica natural. Os parâmetros de mudança utilizados no modelo foram configurados para observar ocorrências que apresentassem apenas perda da vegetação. Estas ocorrências só seriam consideradas caso a sua magnitude (diferença entre o valor pré-mudança e o valor pós-mudança do índice) fosse maior que 100.

A partir da modelagem e ajustes dos parâmetros no código, o algoritmo LT-GEE forneceu uma imagem contendo informações sobre a perda de vegetação, com as seguintes bandas: 1) Ano de detecção da mudança; 2) Magnitude da mudança; 3) Duração da mudança; 4) Valor espectral do evento anterior à mudança; 5) Taxa de mudança espectral para o evento (magnitude/duração); e 6) DSNR (Distúrbio de sinal-ruído) (Cohen et al., 2018). Para o presente trabalho, foram considerados os seguintes resultados: “Ano de Detecção da Mudança”, “Magnitude da Mudança” e “Duração da Mudança”. Estes dados são apresentados em formato matricial (grade de pixels) e contém informações sobre o ano, magnitude e duração da mudança. O LT também permite observar a resposta do índice NDVI de pixels selecionados ao longo da série temporal, por meio de gráficos.

2.3 Validação

A validação dos resultados provenientes do LT foi conduzida em duas etapas complementares. Primeiramente, utilizou-se a ferramenta “Pontos Aleatórios em Polígonos” no software de geoprocessamento QGis para gerar 202 pontos aleatórios, divididos igualmente (101 pontos) entre as classes de ‘Mudança’ e ‘Não Mudança’. Esses pontos serviram de base para a produção da matriz de erro, para o cálculo do Coeficiente Kappa (que indica o grau de concordância do modelo, Cohen, 1960) e para o cômputo das métricas de acurácia, validando os resultados obtidos com a modelagem no algoritmo.

O número total de pontos foi definido com base em recomendações metodológicas para validação de mapeamento de mudanças, que sugerem amostras entre 150 e

250 pontos para garantir robustez estatística sem comprometer a exequibilidade operacional (Congalton; Green, 2019). A amostragem aleatória dentro de cada classe assegura a independência das observações e permite inferências válidas sobre a acurácia global do modelo.

Em seguida, para a análise de mudança, foi utilizado um código no GEE, o *Time Series Inspector* (Yin et al., 2020), que permitiu a observação paralela de imagens dos anos de 1985, 2010 e 2024, e dos gráficos da série temporal para o índice NDVI. Posteriormente a essa análise, cada ponto foi interpretado como 'Mudança' ou 'Não Mudança', de acordo com a referência (realidade) observada. Ao final, uma matriz de erro foi criada e as acuráncias e indicadores foram calculadas para a validação da classificação.

3 Resultados

Os resultados da segmentação executada pelo algoritmo *LandTrendr* (LT) geraram os mapeamentos das bandas "Magnitude da Mudança" (Figura 4), "Ano de Detecção da Mudança" (Figura 5) e "Duração da Mudança" (Figura 6). Para o mapa de magnitude das mudanças, as classes foram divididas em cinco intervalos; a primeira classe (100-200) foi definida para abranger a maior proporção das magnitudes observadas, enquanto as demais classes seguiram intervalos de 200 (Figura 4). Para o mapa do período de ocorrência da mudança, o intervalo de 40 anos foi subdividido em oito classes regulares de cinco anos (Figura 5).

A análise da magnitude (Figura 4) mostra que as classes menores de menor impacto (100-200 e 200-400) foram predominantes, representando 46,7% e 38% das alterações, respectivamente. Mudanças de alta magnitude (800-961) foram raras, correspondendo a apenas 0,08% dos eventos.

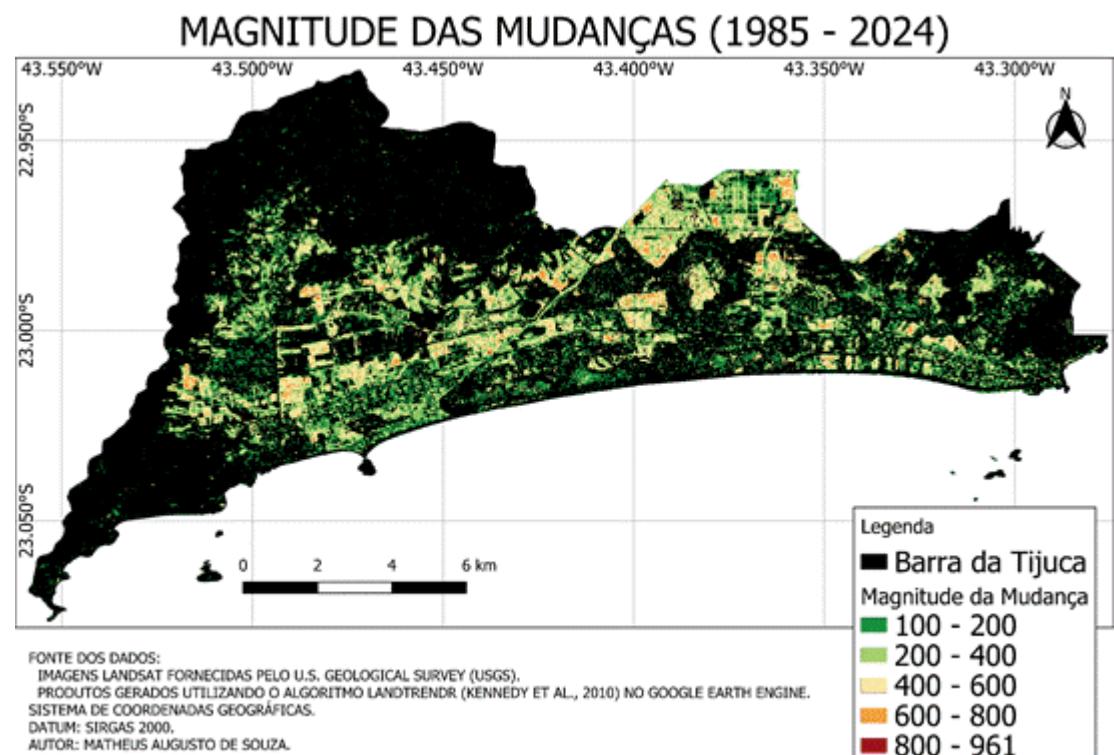


Figura 4: Mapa de magnitude da mudança - Região Administrativa XXIV (Barra da Tijuca, Rio de Janeiro, RJ), de 1984 a 2024.

Fonte: Autores, com dados de U.S Geological Survey (USGS) e Google Earth Engine.

A análise temporal (Figura 5) identificou que o período de maior transformação ocorreu entre 1985 e 1990, quando 22,5 km² foram alterados, o que equivale a 40,65% de toda a mudança detectada. Este valor é aproximadamente três vezes

superior ao do segundo período com maior ocorrência de mudanças (2010-2015), que registrou 7,4 km² de mudança (13,33% do total). O período de 1985-1990 também concentrou a maior proporção da soma das magnitudes de mudança (25,2% do total), seguido por 2010-2015 (16%).

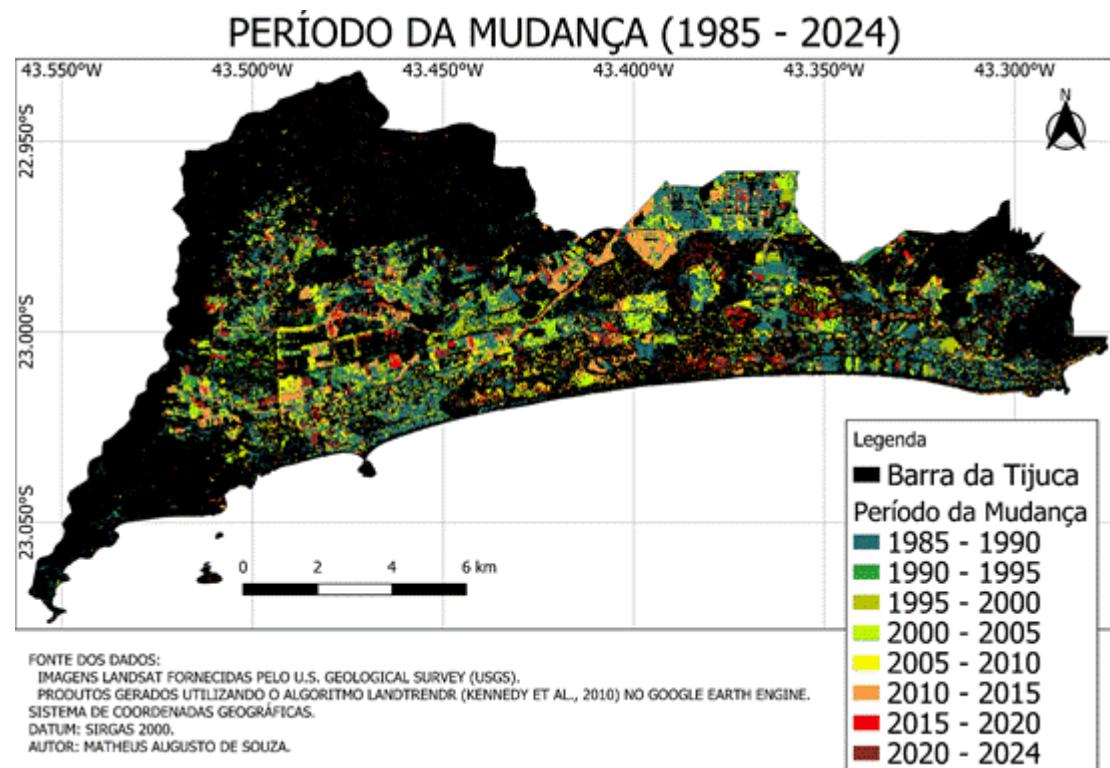


Figura 5: Mapa de período da mudança - Região Administrativa XXIV (Barra da Tijuca, Rio de Janeiro, RJ), de 1984 a 2024.

Fonte: Autores, com dados de U.S Geological Survey (USGS) e Google Earth Engine.

A análise da duração das mudanças para a área da Barra da Tijuca, visualizada no mapeamento da Figura 6, indicou padrões complexos. Observou-se uma concentração de mudanças com durações entre 1 e 9 anos, o que pode representar eventos de supressão de vegetação que se concluem e se estabilizam em um novo tipo de cobertura (como solo exposto ou o início de uma construção) dentro desse intervalo.

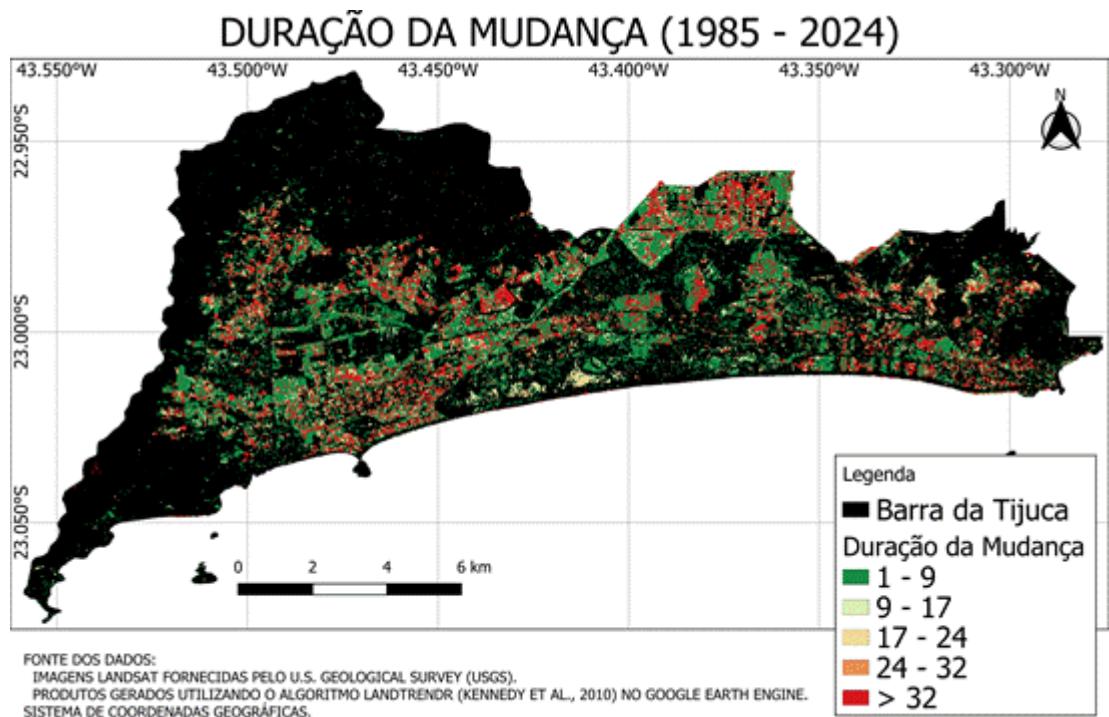


Figura 6: Mapa de duração da mudança - Região Administrativa XXIV (Barra da Tijuca, Rio de Janeiro, RJ), de 1984 a 2024.

Fonte: Autores, com dados de U.S Geological Survey (USGS) e Google Earth Engine.

No entanto, um segundo padrão com mais mudanças se destacou, com durações muito longas, superiores a 34 anos. Os dados sugerem que as mudanças iniciadas no principal período de transformação (1985-1990) permanecem "ativas" até os dias atuais. Em vez de serem interpretados como eventos abruptos e pontuais de desmatamento, o algoritmo detecta esses pixels como um processo gradual e contínuo de supressão de vegetação. Nesses casos, o índice NDVI provavelmente nunca se estabilizou em um novo patamar baixo, continuando a decair lentamente ao longo de toda a série temporal analisada.

Após a análise e classificação dos pontos de validação, foi gerada a matriz de erro (Tabela 1). A análise dessa matriz, em conjunto com o índice Kappa, é essencial para identificar a principal fonte de erros do modelo, que podem ser gerados tanto pelo pesquisador quanto pelo algoritmo, e é necessária para avaliar a qualidade do mapeamento (Zebende; Weckmüller; Vicens, 2020).

Os erros de comissão e omissão resultantes da validação do modelo foram, respectivamente, de 0,12 e 0,05. O erro de comissão (12%), obtido pela razão entre os falsos positivos (12) e o total de pontos classificados como mudança (101), indica que o algoritmo classificou incorretamente algumas áreas como "Mudança". A principal causa identificada para estes erros foi a influência topográfica. Como identificado por Ferraz e Vicens (2025), em regiões de encosta, a influência da sombra nos pixels provoca uma variação irregular do NDVI na série temporal, o que dificulta a compreensão visual e leva o modelo a detectar mudanças inexistentes, conforme apresentado na Figura 7. Além deste fator, também foram notadas algumas regiões de afloramentos rochosos sendo classificadas erroneamente como mudança, provavelmente pelo mesmo motivo de sombreamento. Já o erro de omissão (5%), calculado a partir da relação entre os falsos negativos (5) e o total de mudanças reais de referência (94), concentrou-se em algumas regiões de manguezal. Nesses locais, a detecção de mudanças reais foi dificultada pela complexa assinatura espectral, que sofre influência tanto da mistura de vegetação (restinga e mangue) quanto da condição hídrica das lagoas, conforme apresentado

na Figura 8. Infere-se que o algoritmo falhou em detectar essas mudanças reais devido à regeneração lenta da vegetação nessas áreas, que pode não ter sido capturada pelos parâmetros definidos no modelo.

Tabela 1: Matriz de erro, mudança (positivo) e não mudança (negativo) e métricas aplicadas

Referência	LandTrendr		
	Mudança	Não mudança	Total
Mudança	89	5	94
Não mudança	12	96	108
Total	101	101	202
Acurácia global		0,92	
Kappa		0,83	
F1-score		0,91	
Acurácia do usuário		0,88	0,12
Acurácia do produtor		0,95	0,05

Fonte: Autores (2025)

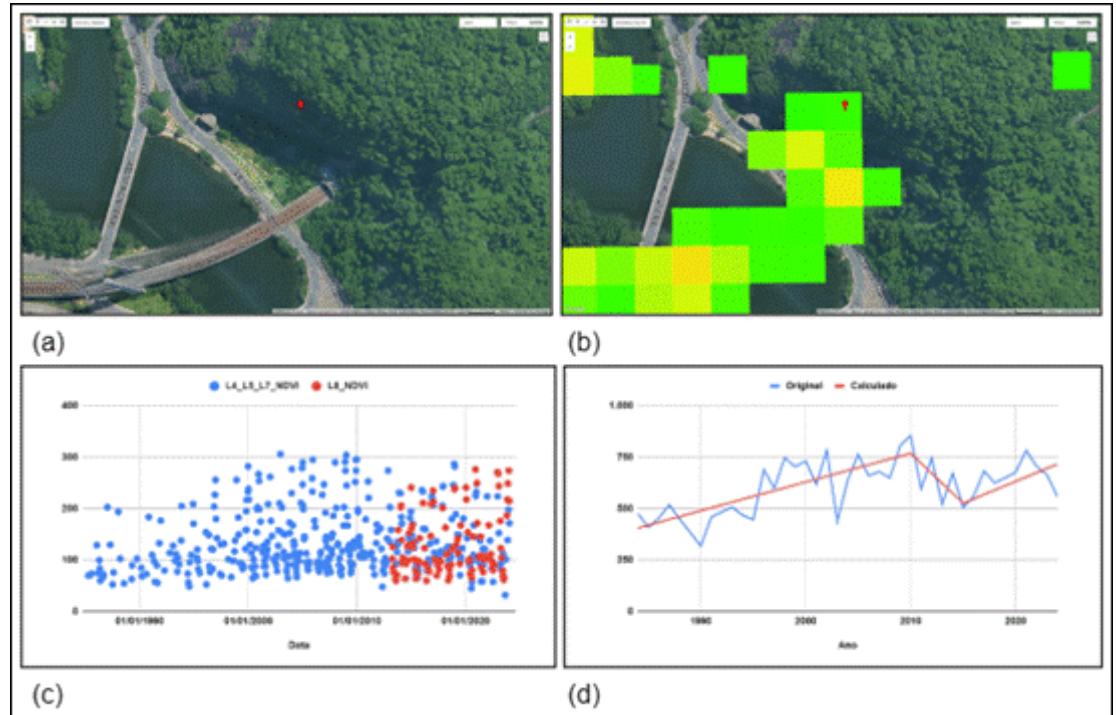


Figura 7: Exemplo de Erro de Comissão (Falso Positivo). (a) Imagem em cor verdadeira com o ponto de referência. (b) Classificação do LT. (c) Série histórica do índice NDVI para Landsat 4, 5, 7 e 8. (d) Série temporal da classificação do LT, com queda no segundo segmento.

Fonte: Autores (2025)

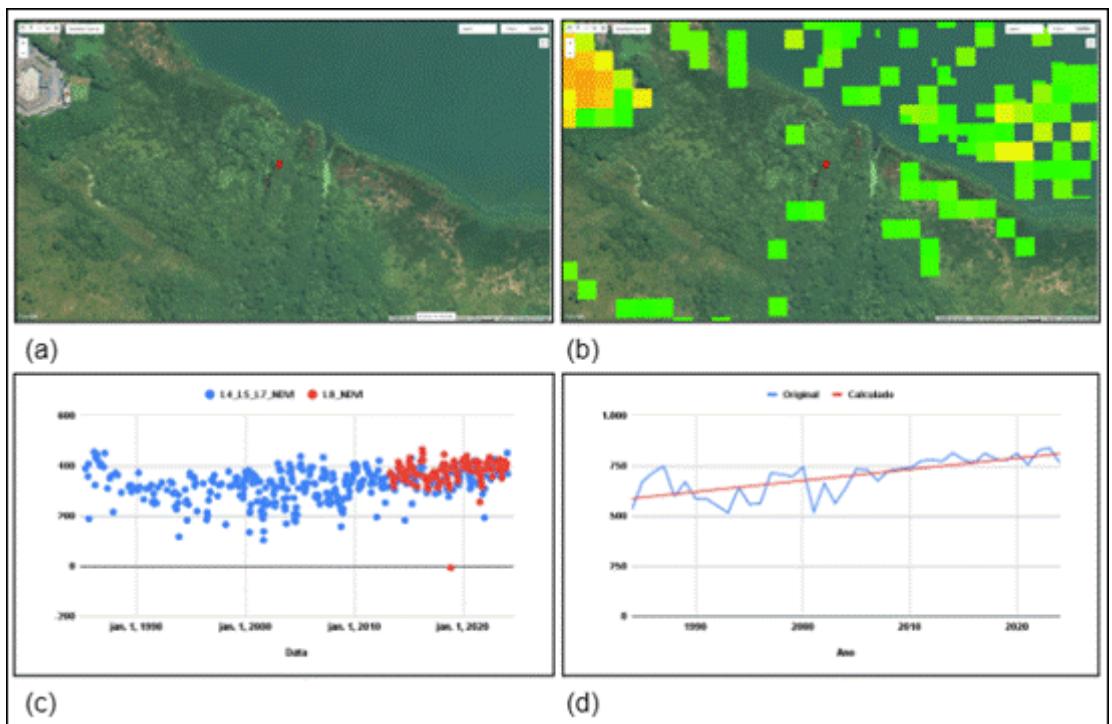


Figura 8: Exemplo de Erro de Omissão (Falso Negativo). (a) Imagem em cor verdadeira com o ponto de referência. (b) Classificação do LT. (c) Série histórica do índice NDVI para Landsat 4, 5, 7 e 8. (d) Série temporal da classificação do LT, com um único segmento.

Fonte: Autores (2025)

4 Discussão

A aplicação do *LandTrendr* possibilitou identificar padrões de variação no NDVI ao longo da série temporal e localizar áreas com alterações na cobertura vegetal. Como a magnitude corresponde à diferença entre o valor do índice no início e no final de um segmento de mudança, valores entre 100 e 200, equivalentes a variações de aproximadamente 0,1 a 0,2 unidades de NDVI, não representam necessariamente uma supressão efetiva e robusta da vegetação. Tais variações podem refletir apenas mudanças sutis no vigor vegetativo ou a presença de formações mais baixas e esparsas. Por esse motivo, o estudo adotou deliberadamente um limiar mais conservador, de modo a não excluir essas transições mais suaves. Além disso, a análise do comportamento espectral da curva dos pixels ao longo do tempo é fundamental para interpretar adequadamente as dinâmicas observadas e distinguir variações naturais de processos de alteração real da cobertura vegetal.

Enquanto Yan e Wang (2021) adotaram uma abordagem de votação majoritária com o uso de sete bandas/índices para superar incertezas na malha urbana de Karachi, os resultados deste estudo demonstram que, para o objetivo específico de detectar a supressão da vegetação na Barra da Tijuca, o uso isolado do índice NDVI apresentou desempenho satisfatório (Acurácia Global de 0,92). Isso sugere que, em áreas de transição floresta-cidade bem marcadas, modelos menos complexos podem ser tão eficientes quanto abordagens multi-índices.

Foram considerados dois limiares de detecção no estudo, sendo eles: a área mínima de análise e o limiar de magnitude de mudança. Por terem sido utilizadas imagens Landsat, o limiar de área mínima de análise é representado por pixels de 900 m², tendo em vista a resolução espacial dessa série de 30 m, ou seja, cada pixel mede 30 m x 30 m. O limiar de magnitude da mudança define a variação mínima do índice de vegetação NDVI necessária para ser considerada uma alteração relevante. Alterações que cobrem uma área muito menor que a do pixel

(sub-pixel) podem não ser detectadas, visto que sua contribuição espectral pode não ser representativa nesta resolução. Consequentemente, essa escala pode não ser representativa para mudanças "finas", como a expansão de favelas em encostas ou alterações no interior de condomínios (por exemplo, a remoção de jardins para a expansão de casas). Alterações em intervalos menores que um ano também não são detectadas pelo modelo, visto que estas são análises de alterações que durem mais que um ano e, neste estudo, sem a recuperação deste índice em um período de pelo menos um ano.

Essa limitação de escala é um desafio comum em estudos baseados em Landsat, diferindo de abordagens que utilizam dados mensais para detectar ciclos rápidos de construção e demolição, como proposto por Hu et al. (2024) em Pequim. Diferentemente do estudo chinês, que focou na dinâmica intraurbana de edifícios, a presente análise priorizou a conversão definitiva de áreas naturais em áreas antrópicas, onde a resolução temporal anual se mostrou adequada.

A análise da expansão urbana na Região Administrativa XXIV - Barra da Tijuca, no período de 1984 a 2024, por meio do LT, revelou um crescimento acentuado. Este foi observado principalmente no período de 1985 a 1990, que correspondeu a 40,65% da área total das mudanças classificadas pelo algoritmo, sendo impulsionado pela intensa atividade imobiliária na região. Na década de 80, a Área de Planejamento 4 (AP4), que engloba os bairros da Barra da Tijuca, Jacarepaguá e Cidade de Deus, apresentou uma taxa de crescimento anual da população residente em favelas muito superior às observadas nas áreas já consolidadas (AP1, AP2 e AP3), ficando atrás somente da AP5, que engloba bairros como Campo Grande, Bangu e Guaratiba (Lago, 1999). No ano de 2004, a AP4 era a área que mais crescia na cidade e representava o vetor de expansão urbana, partindo da Zona Sul em direção à Barra da Tijuca (Camarano et al., 2004).

No período de 2010 a 2015, o segundo com maior proporção de área alterada, de acordo com os resultados essa proporção caiu para 13,33%. Este fato está relacionado aos preparativos para os Jogos Olímpicos de 2016, ocorridos na cidade do Rio de Janeiro, indicando uma desaceleração da urbanização nesta região. As principais alterações deste período foram as obras de saneamento básico nas lagoas da região, a criação do Campo Olímpico de Golfe (inaugurado em 2015) e a construção do Grand Hyatt Hotel Rio de Janeiro (inaugurado em 2016).

Embora o *LandTrendr* seja eficaz na detecção dessas perdas, a confusão espectral gerada pela topografia continua sendo um desafio. A identificação de falsos positivos em áreas de sombra de encosta neste estudo reforça as observações de Ferraz e Vicens (2025) sobre a influência do relevo na variabilidade do NDVI, indicando que a aplicação do algoritmo em regiões de relevo acidentado, comuns no Rio de Janeiro, requer validação cuidadosa das áreas sombreadas.

A análise da série temporal dos sensores Landsat demonstrou que o período de 1985 a 1990 foi o mais impactante, com uma área total de alteração de aproximadamente 22,5 km², sendo esse resultado reflexo da intensa expansão imobiliária nesta região. Apesar de a abordagem ser diferente dos estudos já citados para a análise de áreas urbanas com o LT, a segmentação temporal do algoritmo também foi capaz de detectar a expansão urbana tendo como base a degradação das áreas vegetadas, observada por meio do índice de vegetação NDVI. Isso se deve à característica natural da região, que em suas condições originais pertencia ao bioma da Mata Atlântica, uma floresta tropical.

5 Conclusão

O presente estudo demonstrou a eficácia do algoritmo ao detectar a evolução das áreas antrópicas, tanto para as regiões já urbanizadas quanto para as periféricas, ao utilizar a abordagem de perda de área naturalmente vegetada como metodologia. Isso evidenciou a perda destas áreas vegetadas devido à urbanização.

A segmentação temporal mostrou-se uma poderosa ferramenta para a análise das trajetórias individuais de cada pixel e para a identificação de mudanças sutis ao longo do tempo.

Os índices de acurácia demonstram a aplicabilidade do modelo em estudos futuros, sob condições parecidas, e sugerem a revisão do valor mínimo de magnitude para uma modelagem que detecte de forma mais eficaz as regiões de áreas construídas. Além disso, surge como possibilidade a implementação do índice de área construída NDBI (*Normalized Difference Built-up Index*, ou em português Índice de Construção por Diferença Normalizada) para correlação com os dados resultantes da modelagem com o índice NDVI.

Com uma acurácia global de 0,92, F1-score de 0,91 e Kappa de 0,83, o estudo demonstrou a robustez do algoritmo na identificação de padrões de mudança, apontando, contudo, a necessidade de se reavaliar os parâmetros da classificação para identificar as áreas construídas em decorrência das áreas desflorestadas.

Ao analisar os mapas, foi possível identificar padrões de forma pertinentes a áreas construídas, o que corrobora a possibilidade de se utilizar esta abordagem na identificação do avanço das áreas urbanas em regiões anteriormente vegetadas.

A validação da classificação, utilizando a matriz de erro e o índice Kappa, reforça a robustez dos resultados e sugere a aplicabilidade do LT em outros contextos urbanos. Desta forma, recomenda-se a utilização desta ferramenta para o monitoramento de mudanças ambientais, pois ela pode servir como subsídio para estratégias de políticas públicas que visem à conservação, à preservação ambiental e ao desenvolvimento sustentável nesta região.

Como tema para pesquisas futuras, recomenda-se a implementação do índice NDBI diretamente no algoritmo. O objetivo seria permitir a análise de correlações entre os resultados obtidos nesta classificação (baseada no NDVI) e aqueles provenientes do índice específico para áreas construídas (NDBI). Adicionalmente, recomenda-se a análise de correlações por meio do cruzamento dos dados obtidos com séries históricas de dados socioeconômicos, demográficos ou de planejamento urbano para a região.

Referências

- ABREU, M. A. **Evolução Urbana do Rio de Janeiro**. 4a Edição. Instituto Municipal de Urbanismo Pereira Passos (IPP), Rio de Janeiro, RJ, 2006.
- CÂMARA, G. et al. Using dynamic geospatial ontologies to support information extraction from big Earth observation data sets. **International Conference on GIScience Short Paper Proceedings**, v. 1, n. 1, 2016.
- CAMARANO, A. A. et al. Tendências demográficas no município do Rio de Janeiro. **Coleção Estudos Cariocas**, v. 4, n. 1, p. 47-47, 2004.
- COHEN, J. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, v. 20, n. 1, p. 37-46, 1960.
- COHEN, W. B. et al. A LandTrendr multispectral ensemble for forest disturbance detection. **Remote Sensing of Environment**, v. 205, p. 131-140, 2018.
- CONGALTON, R. G.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. 3^a edição. Boca Raton: CRC Press, 2019.
- COSTA, L. **Plano Piloto para urbanização da baixada compreendida entre a Barra da Tijuca, o Pontal de Sernambetiba e Jacarepaguá**. Agência Jornalística Image, Rio de Janeiro, 1969.
- FERRAZ, D. P. G. B.; VICENS, R. S. Comparison between machine learning classification and trajectory-based change detection for identifying eucalyptus areas in Landsat time series. **Remote Sensing Applications: Society and Environment**, v. 37, [s.n.], 2025.

- GÓMEZ, C.; WHITE, J. C.; WULDER, M. A. Optical remotely sensed time series data for land cover classification: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 116, p. 55-72, 2016.
- HU, T. *et al.* Extraction of Building Construction Time Using the LandTrendr Model With Monthly Landsat Time Series Data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 17, p. 18335-18350, 2024.
- HUANG, S. *et al.* A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. **Journal of Forestry Research**, v. 32, n. 1, p. 1-6, 2021.
- KENNEDY, R. E.; YANG, Z.; COHEN, W. B. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr—Temporal segmentation algorithms. **Remote Sensing of Environment**, v. 114, n. 12, p. 2897-2910, 2010.
- KENNEDY, R.E. *et al.* Implementation of the LandTrendr Algorithm on Google Earth Engine. **Remote Sensing**, [s.l.], v. 10, n. 691, p. 1-10, 2018.
- LAGO, Luciana Corrêa. Desigualdade socioespacial e mobilidade residencial: a metrópole do Rio de Janeiro nos anos 80. **Cadernos Metrópole**, [S. I.], n. 02, p. 11-40, 1999.
- MAUS, V. *et al.* A Time-Weighted Dynamic Time Warping Method for Land-Use and Land-Cover Mapping. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 8, p. 3729-3739, 2016.
- MAZZURANA, E. R. Mata Atlântica: patrimônio natural, cultural e biológico do Brasil. **Revista Encontros Teológicos**, [S. I.], v. 31, n. 3, 2016.
- MENDONÇA, V. C. **Do Sertão Carioca aos condomínios da Barra da Tijuca: uma viagem em torno dos territórios**. Tese (Doutorado em Psicologia Social) – Instituto de Psicologia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, RJ. 247 p. 2023.
- MUGIRANEZA, T.; NASCETTI, A.; BAN, Y. Continuous monitoring of urban land cover change trajectories with landsat time series and landtrendr-google earth engine cloud computing. **Remote Sensing**, v. 12, n. 18, p. 2883, 2020.
- PEIXOTO, G.; NASCIMENTO, R. Prédio irregular avaliado em R\$ 4 milhões é demolido na Ilha da Gigoia. **G1 Rio de Janeiro**, 15/08/2023. Disponível em: <https://g1.globo.com/rj/rio-de-janeiro/noticia/2023/08/15/predio-irregular-e-demolido-na-ilha-da-gigoia.ghml>. Acesso em: 10 nov. 2025.
- PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos/SP: Instituto Nacional de Pesquisas Espaciais – INPE, 2010.
- Prefeitura da Cidade do Rio de Janeiro. **Censo 2022: População e domicílios por bairros** (dados preliminares). Disponível em: https://www.data.rio/datasets/fd354740f1934bf5bf8e9b0e2b509aa9_2/explore?showTable=true. Acesso em: 18 out. 2024.
- Prefeitura da Cidade do Rio de Janeiro. **IDH-M: Uma análise do Índice de Desenvolvimento Humano Municipal para a Cidade do Rio de Janeiro**. Disponível em: http://rio.rj.gov.br/dlstatic/10112/6165511/4162028/analise_idhm_rio_v4_compur.pdf. Acesso em: 18 out. 2024.
- ROUSE, J. W. *et al.* Monitoring Vegetation systems in the Great Plains with ERTS, Proceedings. **Third Earth Resources Technology Satellite-1 Symposium**, Greenbelt: NASA SP-351, p. 3010-3017, 1974.
- SOFFIATI, A. Manguezais do Estado do Rio de Janeiro. **Revista Visão Socioambiental**, 2024. Disponível em: <https://visao socioambiental.com.br/manguezais-do-estado-do-rio-de-janeiro/>.

Acesso em: 10 nov. 2025.

SOUSA, A. V. de. **Do peixe ao lixo:** transformações urbanas e seus efeitos na produção de espaços sociais no Itanhangá. 2018. 23f. Trabalho de Conclusão de Curso (Especialização em Política e Planejamento Urbano) – IPPUR/UFRJ, Rio de Janeiro, 2018.

SOUSA, A. V. Transformações urbanísticas, práticas estatais e mercado imobiliário na Lagoa da Tijuca/RJ. **XIII Reunião de Antropologia do Mercosul.** Porto Alegre, RS. 20 p. 2019.

TAHIR, Z. *et al.* Predicting land use and land cover changes for sustainable land management using CA-Markov modelling and GIS techniques. **Scientific Reports**, v. 15, n. 1, p. 3271, 2025.

VINHAS, L. *et al.* Web Services for Big Earth Observation data. **Geoinfo**, p. 166-177, 2016.

WECKMÜLLER, R.; VICENS, R. S. As geotecnologias e a detecção de trajetórias evolutivas da paisagem: possibilidades metodológicas e aplicações. **Revista Brasileira de Geografia Física**, v. 11, n. 6, p. 2140-2159, 2018.

YAN, X.; WANG, J. Dynamic monitoring of urban built-up object expansion trajectories in Karachi, Pakistan with time series images and the LandTrendr algorithm. **Scientific reports**, v. 11, n. 1, p. 23118, 2021.

YIN, H. *et al.* Monitoring cropland abandonment with Landsat time series. **Remote Sensing of Environment**, v. 246, p. 111873, 2020.

ZEBENDE, J. V.; WECKMÜLLER, R.; VICENS, R. S. Análise da Trajetória Evolutiva da Cobertura Florestal do Município de Teresópolis/RJ utilizando o Algoritmo LandTrendr. **Anuário do Instituto de Geociências - UFRJ**. p. 316-324, 2020.

ZHU, Z.; WOODCOCK, C. E. Continuous change detection and classification of land cover using all available Landsat data. **Remote Sensing of Environment**, v. 144, p. 152-171, 2014.

Sobre os Autores

Matheus Augusto de Souza é graduando em Ciências Matemáticas e da Terra pela Universidade Federal do Rio de Janeiro (UFRJ), com ênfase em Sensoriamento Remoto e Geoprocessamento. Desde junho de 2024, atua como pesquisador de Iniciação Científica no Laboratório ESPAÇO de Sensoriamento Remoto e Estudos Ambientais (UFRJ). Durante sua formação, foi monitor das disciplinas de Geoprocessamento e Projeto de Sensoriamento Remoto na UFRJ. Sua experiência acadêmica concentra-se na análise de dados espaciais e séries temporais de imagens de satélite, utilizando softwares como ArcGIS, QGIS e Google Earth Engine, com ênfase no algoritmo LandTrendr para detecção de mudanças. Possui competências em linguagens de programação como Python, R e JavaScript. Atualmente, trabalha como Assistente de Desenvolvimento em empresa da área de geotecnologias.

Debora da Paz Gomes Brandão Ferraz é doutora em Geografia pela Universidade Federal Fluminense (UFF). Possui graduação (2014) e mestrado (2017) em Geografia pela mesma instituição. Durante sua formação, esteve vinculada ao Laboratório de Geografia Física da UFF, onde desenvolveu atividades ligadas ao sensoriamento remoto e ao geoprocessamento. Sua experiência concentra-se no mapeamento e na análise de dinâmicas florestais no estado do Rio de Janeiro, utilizando imagens de satélite e softwares como ArcGIS, QGIS, eCognition e Google Earth Engine, com ênfase no algoritmo LandTrendr para detecção de mudanças. Atuou como professora substituta na Universidade Federal do Rio de Janeiro (UFRJ), na área de Geotecnologias, em 2024. Atualmente, é professora substituta na Universidade Estadual do Rio de Janeiro (UERJ), no campus de Cabo Frio.

Contribuições dos Autores

Conceituação, [D.P.G.B.F, M.A.S]; metodologia, [D.P.G.B.F, M.A.S]; software [M.A.S]; validação, [M.A.S]; análise formal, [M.A.S, D.P.G.B.F]; investigação, [M.A.S, D.P.G.B.F]; curadoria de dados, [M.A.S, D.P.G.B.F]; redação—preparação do rascunho original, [M.A.S]; redação—revisão e edição [D.P.G.B.F]; supervisão, [D.P.G.B.F]. Todos os autores leram e concordaram com a versão publicada do manuscrito.

Disponibilidade de Dados

Os scripts de processamento e os dados resultantes deste estudo encontram-se disponíveis publicamente no repositório do GitHub, acessível em: https://github.com/mattaugustt/landtrendr_barra_da_tijuca_cec.

Agradecimentos

Os autores reconhecem as contribuições da Universidade Federal do Rio de Janeiro (UFRJ), em especial ao Laboratório ESPAÇO de Sensoriamento Remoto e Estudos Ambientais, pela disponibilização da infraestrutura necessária para o desenvolvimento desta pesquisa.

Conflitos de Interesse

Os autores declaram não haver conflitos de interesse.

Sobre a Coleção Estudos Cariocas

A Coleção Estudos Cariocas (ISSN 1984-7203) é uma publicação de estudos e pesquisas sobre o Município do Rio de Janeiro, vinculada ao Instituto Pereira Passos (IPP) da Secretaria Municipal da Casa Civil da Prefeitura do Rio de Janeiro.

Seu objetivo é divulgar a produção técnico-científica sobre temas relacionados à cidade do Rio de Janeiro, bem como sua vinculação metropolitana e em contextos regionais, nacionais e internacionais. Está aberta a quaisquer pesquisadores (sejam eles servidores municipais ou não), abrangendo áreas diversas - sempre que atendam, parcial ou integralmente, o recorte espacial da cidade do Rio de Janeiro.

Os artigos também necessitam guardar coerência com os objetivos do Instituto, a saber:

1. Promover e coordenar a intervenção pública sobre o espaço urbano do Município;
2. Prover e integrar as atividades do sistema de informações geográficas, cartográficas, monográficas e dados estatísticos da Cidade;
3. Subsidiar a fixação das diretrizes básicas ao desenvolvimento socioeconômico do Município.

Especial ênfase será dada no tocante à articulação dos artigos à proposta de desenvolvimento econômico da cidade. Desse modo, espera-se que os artigos multidisciplinares submetidos à revista respondam às necessidades de desenvolvimento urbano do Rio de Janeiro.