

ANÁLISE COMPARATIVA DE MAPEAMENTOS DO USO E COBERTURA A PARTIR DE IMAGENS LANDSAT-8 E SENTINEL-2 ATRAVÉS DO ALGORITMO RANDOM FOREST NA PLATAFORMA GOOGLE EARTH ENGINE

COMPARATIVE ANALYSIS OF USAGE MAPPING AND COVERAGE FROM LANDSAT-8 AND SENTINEL-2 IMAGES USING THE RANDOM FOREST ALGORITHM ON THE GOOGLE EARTH ENGINE PLATFORM

 Rodrigo Gomes da Silva^A
 Felipe Fidelis Lira^A
 Jonas Ramos Pimentel^A
 Carla Bernadete Madureira Cruz^A

^A Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, RJ, Brasil

Recebido em: 15/05/2023 | 21/07/2023 DOI: 10.12957/tamoios.2023.76109

Correspondência para: Rodrigo Gomes da Silva (rgomms7@gmail.co)

Resumo

Com o advento do sensoriamento remoto, surgiram técnicas de mapeamento que contribuíram para o monitoramento e compreensão das mudanças que ocorrem na superfície terrestre. Nesse sentido, as análises de cobertura e uso da terra aparecem como um estudo indispensável na compreensão dos fenômenos que funcionam como principais fomentadores das alterações espaciais. O município de Itaboraí, localizado no leste metropolitano do estado do Rio de Janeiro, passou por diversas transformações em sua paisagem desde o anúncio de uma nova inserção em seu território: o Complexo Petroquímico do Rio de Janeiro (Comperj). Neste trabalho, objetivou-se verificar, comparativamente, a precisão de mapeamentos de cobertura e uso da terra desenvolvidos com o produto de dois distintos projetos espaciais: Landsat-8 (OLI) e Sentinel-2 (MSI). As classificações foram realizadas na plataforma Google Earth Engine (GEE) utilizando o algoritmo Random Forest e, para a avaliação do dado produzido, foi aplicado o índice Kappa, que resultou nos valores de 0,92 e 0,90 para os casos Sentinel-2 (MSI) e Landsat-8(OLI), respectivamente. Por fim, apesar de as duas classificações apresentarem entre si uma diferença inferior a 20%, os resultados comparativos apontam que as classes agropasto, área construída e floresta possuem as maiores confusões.

Palavras-chave: Sensoriamento remoto; Itaboraí; Google Earth Engine; Sentinel 2; Landsat 8.

Abstract

With the advent of remote sensing, mapping techniques have emerged that have contributed to monitoring and understanding changes occurring on the Earth's surface. In this context, Land Cover and Land Use analyses have become indispensable studies in understanding the phenomena that serve as the primary drivers of spatial alterations. The municipality of Itaboraí, located in the metropolitan east of the state of Rio de Janeiro, has undergone various landscape transformations since the announcement of a new insertion in its territory: the Rio de Janeiro Petrochemical Complex (Comperj). This study aimed to comparatively verify the accuracy of Land Cover and Land Use mappings developed using data from two distinct space projects: Landsat-8 (OLI) and Sentinel-2 (MSI). The classifications were performed on the Google Earth Engine (GEE) platform using the Random Forest algorithm, and for evaluating the produced data, the Kappa index was applied, resulting in values of 0.92 and 0.90 for Sentinel-2 (MSI) and Landsat-8 (OLI) cases, respectively. Finally, although the two classifications showed a difference of less than 20% between them, comparative results indicate that the agropasture, built-up area, and forest classes have the highest confusion rates.

Keywords: Remote sensing; Itaboraí; Google Earth Engine; Sentinel 2; Landsat 8.





INTRODUÇÃO

O crescente desenvolvimento de técnicas e práticas ligadas à geoinformação permitiram conhecer mais amplamente a superfície terrestre a partir das diversas formas de aquisição de dados espaciais (INPE). Por esse ângulo, com o acelerado avanço das geotecnologias - sobretudo a partir da década de 1990 (PANCHER, 2012) - e, além disso, com a ciência de que o conhecimento da organização territorial de uma determinada área é fundamental para identificar mazelas de cunho social, ambiental e econômico, cada vez mais são utilizadas formas de obtenção de dados e de representação da superfície terrestre com a finalidade de apoiar políticas públicas.

O sensoriamento remoto orbital, nesse contexto, inicia na década de 1970, e após passar por intensos processos de aprimoramento (BEZERRA et al., 2018) acaba por se tornar uma fonte de indubitável importância na obtenção de informações espaciais, principalmente em decorrência do detalhamento e abrangência das informações que são coletadas sobre a superfície terrestre. Um dos principais produtos do sensoriamento remoto, as imagens orbitais, pode ser adquirido de forma cada vez mais facilitada e, em alguns casos, gratuita. Atualmente tem-se um grande leque de imagens com diferentes características que devem ser consideradas a depender da aplicação. Com isso, incontáveis são as possibilidades analíticas viabilizadas a partir dos sensores remotos, como é o caso da análise de dinâmicas espaço-temporais que se dão sobre a superfície terrestre, e que são fundamentais para a tomada de decisão.

O acelerado avanço dos Sistemas de Informações Geográficas (SIG) e dos Sistemas de Processamento de Imagens impulsiona o surgimento de diversas formas de se adquirir e processar dados a partir do produto dos sensores remotos. Nesse viés, destaca-se o caso do Google Earth Engine (GEE), uma plataforma gratuita que realiza processamento computacional de dados geoespaciais, baseando-se completamente em nuvem. (GORELICK et al., 2017). Tal plataforma, o GEE, se destaca por apresentar um imenso inventário de dados, como informações de temperatura, de precipitação e imagens de sensores orbitais, por exemplo. A partir disso, é possível visualizar, manusear, alterar e compartilhar de forma facilitada diferentes dados geoespaciais, sem a necessidade de conhecimentos avançados em programação web, e, além disso, sem exigir elevado desempenho da máquina do usuário. Nesse sentido, o GEE é de indubitável utilidade para a criação e manipulação de dados espaciais que auxiliem na compreensão da organização territorial, como, por exemplo, no levantamento de cobertura e uso da terra, produto necessário para a análise de áreas que apresentaram/apresentam intensas modificações espaciais.

No entanto, outro desafio se faz presente: como lidar com as inúmeras e diferentes opções existentes? Consorciar escala e abrangência temporal, além dos custos, é um dos fatores a serem levados em consideração. No caso de mapeamentos em meso escala, considerando as opções gratuitas, é fato que as séries Landsat e Sentinel são as mais utilizadas na maioria das aplicações. Apesar da grande diferença de resolução espacial dos dois produtos (30 metros para o Landsat e 10 metros para o Sentinel), dentre outros fatores, em alguns estudos é prioritário avaliar a profundidade temporal do Programa de Imageamento.

Cenário de intensas mudanças estruturais e econômicas que reconfiguraram características socioambientais, a RMRJ, sobretudo por fomento da indústria petrolífera, sofreu diversas modificações em diferentes aspectos, com destaque para o entorno da Baía de Guanabara (OLIVEIRA, COSTA e FEVRIER, 2019). O município de Itaboraí, em especial, foi alvo da instalação do Complexo Petroquímico do Rio de Janeiro (Comperj), o que alterou as dinâmicas de uso do solo, relações sociais, econômicas, ambientais, dentre outras. Desse modo, entendendo que esta análise é apenas uma parte de um estudo mais amplo que busca



desenvolver uma examinação espaço-temporal das dinâmicas espaciais do município de Itaboraí frente à chegada do Comperj, fez-se necessário avaliar as diferenças na exatidão da classificação final através de dois importantes conjuntos de dados de diferentes características: Landsat-8 (OLI) e Sentinel-2 (MSI).

Assim, o presente estudo teve como objetivo realizar, a partir do uso do algoritmo Random Forest na plataforma GEE, um mapeamento de uso e cobertura da Terra para o município de Itaboraí. Baseado nisso, buscou-se analisar as diferenças de exatidão entre os resultados obtidos, considerando a utilização de dados oriundos de duas importantes missões de levantamento: Landsat-8 e Sentinel-2, que utilizam sensores com resoluções espaciais, temporais e espectrais distintas. Dessa forma, poder-se-á entender se há diferenças significativas nos resultados, e, conseqüentemente, se é seguro optar pelo sensor de menor resolução espacial e maior abrangência temporal.

Para isso, foi efetuada uma análise comparativa das duas classificações geradas, onde foi utilizado o mesmo método de classificação e uma mesma legenda temática, a fim de identificar e compreender os padrões das diferenças obtidas no mapeamento do uso e cobertura da terra para o município.

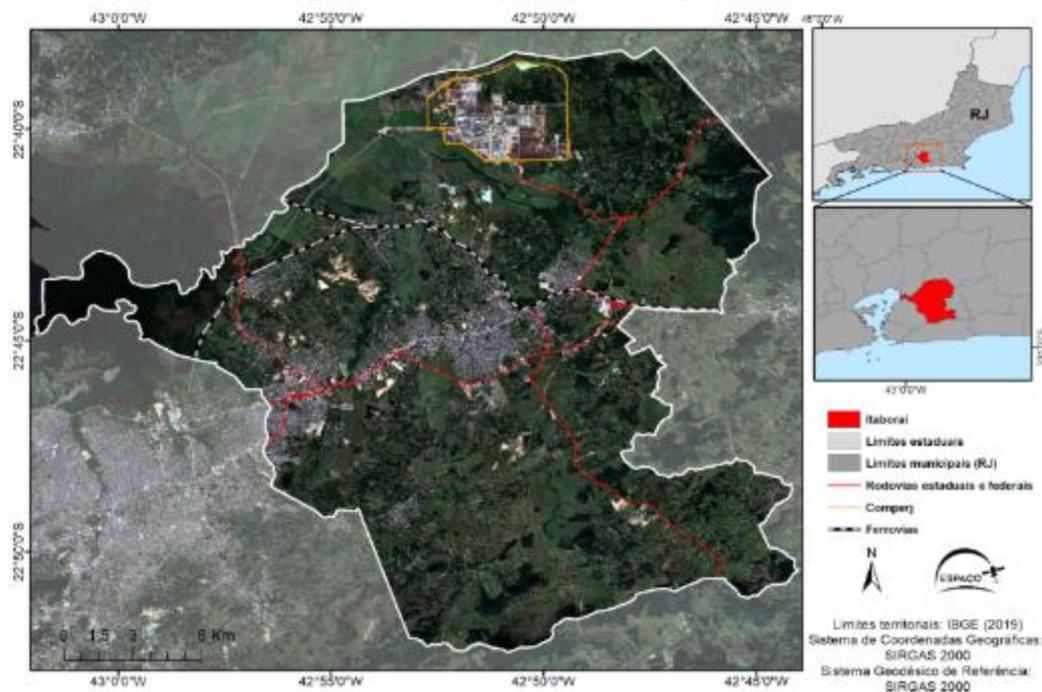
ÁREA DE ESTUDOS

Fundado em 1672, o município de Itaboraí (Figura 1) compõe o conjunto de municípios que apresentam maior centralidade no estado do Rio de Janeiro: a região metropolitana. Historicamente, a cidade já apresentava uma dinâmica econômica relevante desde o século XVIII, com a cultura da cana de açúcar, que era escoada para a capital através do porto, também localizado na cidade. Posteriormente, no século XX, já com a sua relevância consolidada, o município volta a se destacar com a produção de laranja, se tornando o maior produtor nacional da fruta.

Entretanto, o fato que, inicialmente, trouxe maior impacto em todas as dinâmicas do município, foi a decisão da construção do Comperj, atualmente, renomeado como Polo GasLub Itaboraí. Planejado em 2006 como sinônimo de desenvolvimento e modernidade, teve o início das obras em 2011, com o título de maior investimento da história da Petrobras, o que projetou um impulsionamento econômico na região (DIAS et al., 2013).



Figura 1- Mapa de Localização do município de Itaboraí/RJ.



Fonte: Autoria própria

Além disso, a localização do complexo havia sido pensada a partir da possibilidade de integração com outros municípios, o que também os traria benefícios, sobretudo com a construção do Arco Metropolitano do Rio de Janeiro (AMRJ), que conecta Itaboraí ao porto de Itaguaí (Figura 2), além de interligar diversos outros municípios, viabilizando também uma maior integração social. Os maiores empreendimentos do Comperj estão localizados em Itaboraí e São Gonçalo, mas muitos outros serão instalados nos municípios vizinhos e nas regiões atravessadas pelo Arco Metropolitano e na própria Baía de Guanabara (DIAS et al, 2013). Junto disso, uma obra dessa expressão, ocupando uma área de 45 milhões de metros quadrados, e ainda relacionada a um setor comumente próspero em alguns lugares do mundo, resultou em uma onda de especulações em todos os municípios vizinhos, sobretudo, mais intensamente em Itaboraí, o que criou a esperança de geração de duzentos mil empregos diretos e indiretos (DIAS et al, 2013).



Figura 2 - Mapa de municípios cortados pelo AMRJ.



Fonte: Autoria própria

Já no mercado imobiliário notou-se um aquecimento nesse período, visando responder a uma carência de infraestrutura no município. Em conjunto com a essa expansão da malha urbana, as áreas de floresta e pastagem também sofreram alteração, tanto nas obras para a construção do complexo, quanto nas medidas da tentativa de compensação dos impactos causados no contexto de inserção do Comperj em Itaboraí. Exemplo disso é mostrado no relatório de impacto ambiental (RIMA), produzido a partir da estimativa dos impactos que seriam causados em todo o processo de construção do Comperj, na tentativa de amenizar a expressiva perda ambiental, foram implementados corredores ecológicos que conectassem "ilhas" de vegetação e favorecessem a perpetuação das espécies, além de revitalizar os parques na região.

Por consequências adversas, o projeto passou por paralisações, e ainda nos dias atuais não foi concluído, o que desacelerou de forma expressiva os investimentos na região e ocasionou no abandono de alguns empreendimentos nos setores secundário e terciário. Essa mudança no ritmo da construção, impactou diretamente no comportamento das classes ao longo desse tempo, desde o período pré Comperj até os dias atuais, o que torna possível identificar as transições das classes de cobertura da terra.



MATERIAIS E MÉTODOS

No que tange todo o processo de classificação de cobertura e uso da terra para o município de Itaboraí e posterior análise comparativa dos resultados adquiridos, destaca-se que todos os dados orbitais usados como base para este estudo foram adquiridos gratuitamente a partir do acervo virtual do *Google Earth Engine*, plataforma aqui utilizada, onde se fez uso da API (*Application Programming Interface*) *JavaScript*. Assim, por intermédio da própria plataforma, foram utilizadas e manipuladas imagens orbitais que são fruto de dois satélites com resoluções espaciais, espectrais e temporais distintas: Landsat-8 (OLI) e Sentinel-2 (MSI).

Com quase uma dezena de gerações, a linha de satélites Landsat produz imagens orbitais da superfície terrestre desde 1972. De maneira mais específica, o Landsat-8 - utilizado neste estudo - abriga os sensores OLI (*Operational Land Imager*) e TIRS (*Thermal Infrared Sensor*), que geram imagens com resolução espacial de 30 metros (bandas 1, 2, 3, 4, 5, 6, 7), 15 metros (banda 8), 30 metros (banda 9) e 100 metros (bandas 10 e 11). Além disso, os sensores do satélite produzem imagens com 11 bandas, entre pancromática, multiespectral e termal, e detém uma resolução temporal de aproximadamente 16 dias. Por outro lado, o outro satélite utilizado para produção do mapeamento de uso e cobertura da terra, Sentinel-2, é de gestão europeia e abriga o sensor MSI (*Multispectral Instrument*). Nesse caso, são encontradas 13 bandas espectrais, resolução espacial de 10 metros (bandas 2, 3, 4 e 8), 20 metros (bandas 5, 6, 7, 8a, 11 e 12), 60 metros (bandas 1, 9 e 10), resolução temporal de aproximadamente 5 dias e disponibilidade de imagens desde 2015 (ESA, 2018). Dado o exposto, entre os dois projetos espaciais utilizados neste trabalho, Sentinel-2 e Landsat-8, vale ser discutido o impacto da supracitada diferença no que tange a resolução espacial - 30 metros, no caso do Landsat e 10 metros, do Sentinel - dos produtos gerados a partir de seus respectivos sensores.

Referente à dimensão dos pixels de uma imagem, a resolução espacial é um dos elementos que impactam diretamente na precisão de um determinado produto, análise ou medição a ser realizada a partir de uma imagem orbital. Isso se dá porque, quanto menor é a dimensão dos pixels de uma determinada imagem, maior será o detalhamento e, conseqüentemente, de forma geral, mais preciso será o delineamento dos objetos a serem classificados, principalmente considerando objetos de tamanhos menores (SERVIÇO FLORESTAL BRASILEIRO, 2021). Sendo assim, comparando-se a resolução espacial dos produtos orbitais aqui trabalhados, o sensor MSI (Sentinel-2) possui área do pixel 9 vezes menor, se comparado ao sensor OLI (Landsat-8), levando em consideração suas resoluções espaciais, de 10 e 30 metros, respectivamente - o que, conforme o que foi destacado anteriormente, impacta no detalhamento da imagem e seus produtos.

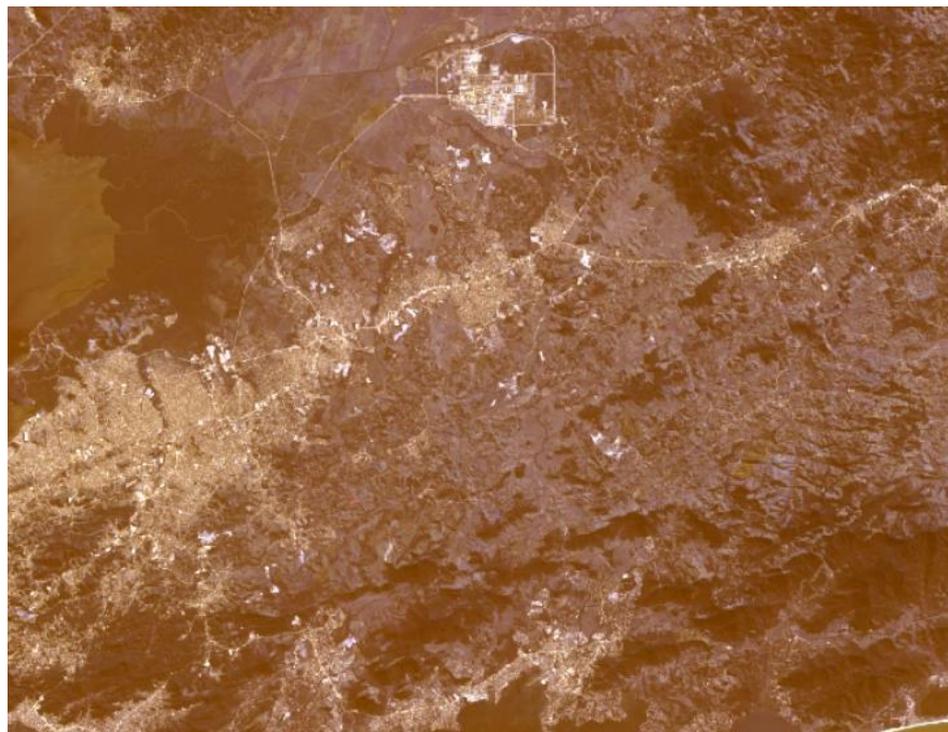
A partir do produto de cada um dos satélites destacados, foram produzidos mosaicos de imagens para 2020, ano escolhido por ser a melhor representação atual do município no momento em que o trabalho iniciou-se. Nessa lógica, a escolha do período do ano utilizado para produção do mosaico de imagens foi definido com base em dados pluviométricos e de temperatura de sensores meteorológicos do CHIRPS (Climate Hazards Group InfraRed Precipitation with Station data) e de evapotranspiração do MODIS (Moderate-Resolution Imaging Spectroradiometer). Selecionou-se o período do ano em que fossem constatados os menores valores pluviométricos e de temperatura, com a finalidade de que fossem selecionadas imagens com menor cobertura de nuvens possível, além de uma quantidade mais harmônica de iluminação e concentração de umidade no solo; assim, este período ficou definido entre os meses de abril e agosto.

Foram utilizados algoritmos disponíveis no "DOCS" do Google Earth Engine para realizar o processo de correção de nuvens. Durante esse processo, foram selecionadas apenas



imagens com até 20% de cobertura de nuvens, dentro do período anual pré definido. Em seguida, foram gerados mosaicos - tanto para as imagens Landsat-8, quanto para as imagens Sentinel-2 - para o período selecionado. Destaca-se que os algoritmos responsáveis pela geração de mosaicos utilizam os pixels com menor percentual de cobertura de nuvens (CRUZ, 2021). As figuras abaixo, 3 e 4, mostram os mosaicos das imagens depois da remoção de nuvens.

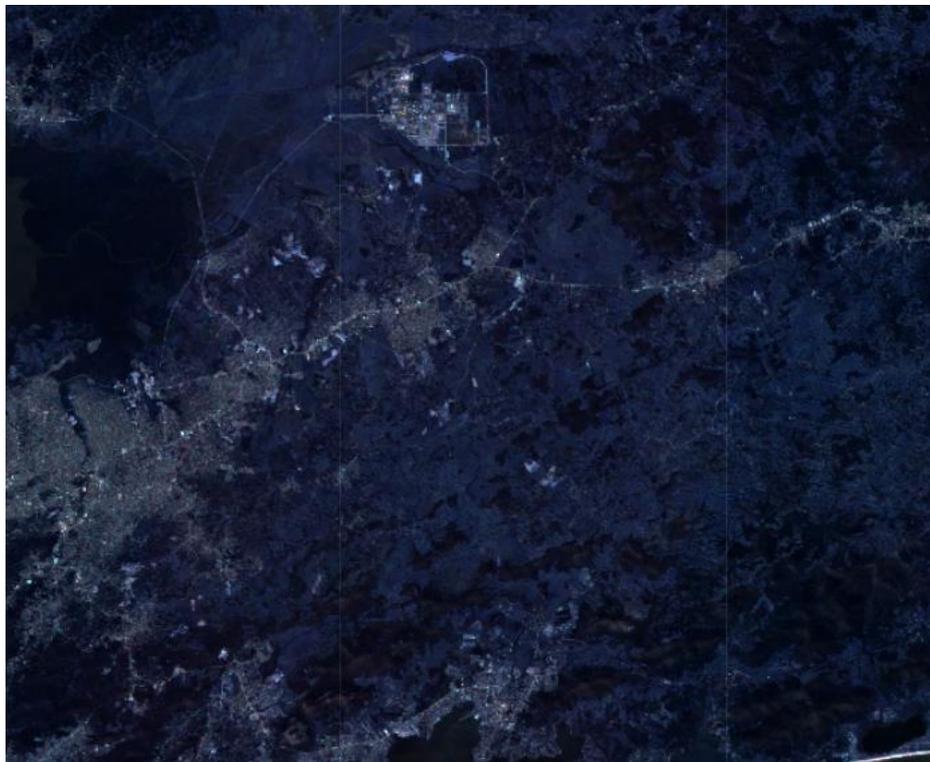
Figura 3 - Mosaico Landsat - 8.



Fonte: Autoria própria



Figura 4 - Mosaico Sentinel - 2

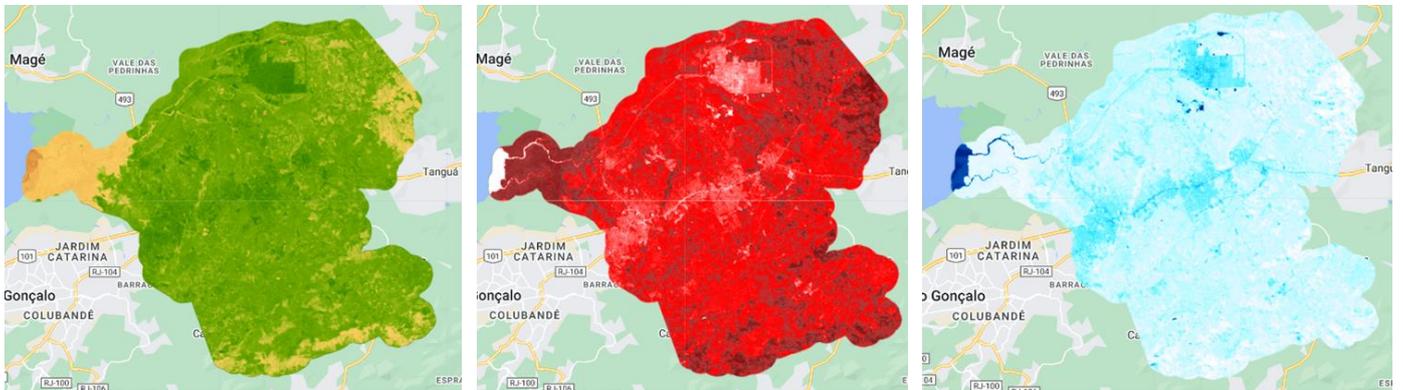


Fonte: Autoria própria

Com as imagens adquiridas e posteriormente mosaicadas na plataforma GEE, além da utilização das bandas RGB e IR (*infrared*), foram gerados e incorporados ao projeto alguns índices espectrais: o índice de vegetação NDVI (*Normalized Difference Vegetation Index*), o índice de áreas construídas NDBI (*Normalized Difference Built-up Index*) e o índice de corpos d'água NDWI (*Normalized Difference Water Index*). Estes procedimentos foram desenvolvidos para os dois mosaicos (figura 5). Os índices supracitados foram criados para facilitar a detecção e diferenciação de assinaturas espectrais de vegetação, áreas urbanas e corpos hídricos, o que ajuda no processo de classificação das imagens, já que os cálculos aumentam a sensibilidade à identificação das diferentes feições de uso e cobertura na área de estudo.



Figura 5 - NDVI, NDBI e NDWI vistos da imagem Landsat - 8



Fonte: Autoria própria

A partir de análises da atual organização espacial do município estudado, somado ao estudo do histórico das coberturas e usos encontrados no território, foram definidas as seguintes classes para a produção da classificação: mangue, corpo d'água, floresta, solo exposto, agropasto, área construída e área antropizada para mineração. A figura 6 apresenta uma chave de interpretação das classes definidas.

Figura 6 - Chave de interpretação das classes definidas para o mapeamento.



Fonte: Autoria própria



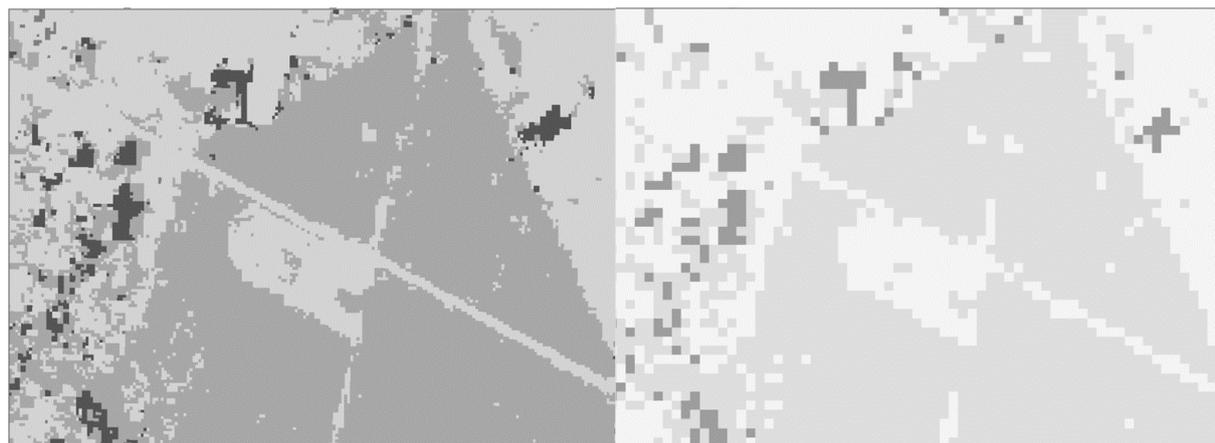
Definidas as classes, foram coletadas de 50 a 100 amostras em polígono para cada uma das classes em ambas as classificações, onde a quantidade de amostras de cada classe foi baseada na representatividade da feição retratada no município. As classes de “corpo d’água” e “área antropizada para a mineração” são as que, visualmente, apresentaram menores áreas totais e, por isso, possuíram menor quantidade de polígonos selecionados. A escolha de amostras por polígonos se deu a fim de facilitar a seleção das amostras, bem como diminuir os erros relacionados a seleção equivocada de amostras por pontos.

Para o processo de classificação dos mosaicos, a partir das classes definidas anteriormente, foi escolhido o método de classificação supervisionada. Este método consiste na maneira de classificar onde o usuário, a partir de análises, indica os tipos de cobertura/uso que deseja separar em classes com base na definição de características particulares - o que se dá através da coleta de amostras representativas de coberturas e/ou usos previamente definidos como classes de interesse. Ou seja, baseado na predefinição de uma determinada classe de uso e cobertura da terra, são selecionados pixels pertencentes a essa classe e, a partir disso, o algoritmo realiza a tarefa de localizar, por meio de métodos estatísticos, áreas (pixels) de comportamento similar (BERNARDI, 2007).

Selecionou-se o algoritmo de classificação *Random Forest*, que realiza a separação de classes a partir da construção de diversas árvores de decisão, onde são estabelecidos parâmetros que direcionam a nomeação de um determinado pixel, a uma determinada classe estabelecida. Como a plataforma do GEE permite a aplicação de diferentes parâmetros de forma rápida e dinâmica, pode-se realizar vários testes que definiram o limiar de 2000 árvores para alcançar um resultado satisfatório.

Para as análises comparativas, foi realizado o redimensionamento de pixels, através da ferramenta “*resample*” no *software* ArcGis. O mosaico de imagens Sentinel-2 foi reamostrado para que o tamanho de suas células se equiparassem às do Landsat-8; ou seja, os pixels passaram de 10x10 para 30x30. A figura 7 apresenta a imagem Sentinel-2 antes e depois do procedimento (respectivamente).

Figura 7 - Imagem Sentinel-2 antes e depois da reamostragem



Fonte: Autoria própria



O redimensionamento é etapa indispensável, pois a etapa seguinte foi gerar uma combinação entre as duas classificações, utilizando a ferramenta *combine* no software ArcGIS. A combinação das imagens revela a proporção das confusões entre classes entre os dois mapeamentos gerados, onde, através da sobreposição entre os mapeamentos, é destacado como cada pixel foi classificado, tanto no caso Sentinel, quanto no Landsat.

RESULTADOS

O primeiro resultado foi a validação da classificação, produzida a partir da matriz de confusão (tabelas 1 e 2), que consiste em tabelas que são utilizadas para realizar o cruzamento de pixels nomeados pela classificação e o real, o que gera, posteriormente, as medidas de exatidão global, acurácia do usuário, acurácia do produtor e índice Kappa. Neste estudo, que utilizou 30 amostras de validação para cada uma das classes, o índice Kappa foi utilizado como principal ferramenta de verificação dos resultados por ser um tradicional método de medição de acurácia e, somado a isso, por ser amplamente aplicado em estudos ligados a Sistema de Informações Geográficas e Sensoriamento Remoto (WIGGERS e RIBEIRO, 2015).

Tabela 1 - MATRIZ DE CONFUSÃO LANDSAT 8 (OLI)

	Mangue	Corpo D'agua	Floresta	Agropasto	Solo Exp.	Área Cons.	AAPM	Total	Acurácia do produtor	
Mangue	30	0	0	0	0	0	0	30	100%	930
Corpo D'agua	0	30	0	0	0	0	0	30	100%	900
Floresta	1	0	29	0	0	0	0	30	97%	990
Agropasto	0	0	2	26	1	1	0	30	87%	870
Solo Exposto	0	0	1	2	24	3	0	30	80%	870
Área construída	0	0	1	1	4	24	0	30	80%	840
Área Antropizada Para Mineração	0	0	0	0	0	0	30	30	100%	900
Total	31	30	33	29	29	28	30	210		44100
Acurácia do usuário	97%	100%	88%	90%	83%	86%	100%			

Exatidão global	0,919
Aceitação relativa - PO	0,919
Taxa hipotética de aceitação - PE	0,1429
Kappa	0,9056

Fonte: Autoria própria



Tabela 2 - MATRIZ DE CONFUSÃO SENTINEL 2 (MSI)

	Mangue	Corpo D'agua	Floresta	Agropasto	Solo Exp.	Área Cons.	AAPM	Total	Acurácia do produtor	
Mangue	30	0	0	0	0	0	0	30	100%	930
Corpo D'agua	0	30	0	0	0	0	0	30	100%	900
Floresta	1	0	29	0	0	0	0	30	97%	900
Agropasto	0	0	1	26	0	3	0	30	87%	870
Solo Exposto	0	0	0	0	27	3	0	30	90%	900
Área Construída	0	0	0	3	3	24	0	30	80%	900
Área Antropizada Para Mineração	0	0	0	0	0	0	30	30	100%	900
Total	31	30	30	29	30	30	30	210		44100
Acurácia do usuário	97%	100%	97%	90%	90%	80%	100%			

Exatidão global	0,9333
PO	0,9333
PE	0,1429
Kappa	0,9222

Fonte: Autoria própria

Com base nas matrizes de confusão (tabelas 1 e 2), foi possível identificar as principais características da classificação gerada, com informações sobre acertos, confusões e, com base em tais informações, a acurácia do produto elaborado neste estudo. O índice Kappa, de acordo com as tabelas 1 e 2, apresentou valores de 0,92 e 0,90 para os casos Sentinel-2 e Landsat-8, respectivamente. O produto Sentinel-2 possuiu um maior número de acertos e, conseqüentemente, obteve um maior valor Kappa. Dessa forma, de acordo com Fonseca (2020), as duas classificações, que apresentaram acurácias com intensa similaridade, apresentam um desempenho “excelente”, uma vez que possuem valores do índice Kappa superiores a 0,8.

Tabela 3 - ÍNDICE KAPPA X DESEMPENHO

Índice Kappa	Desempenho
< 0	Péssimo
$0 < k \leq 0,2$	Ruim
$0,2 < k \leq 0,4$	Razoável
$0,4 < k \leq 0,6$	Bom
$0,6 < k \leq 0,8$	Muito Bom
$0,8 < k \leq 1,0$	Excelente

Fonte: Fernandes (2000)



O quadro abaixo (tabela 4) apresenta um comparativo entre o índice Kappa, acurácia do produtor, acurácia do usuário e acurácia global.

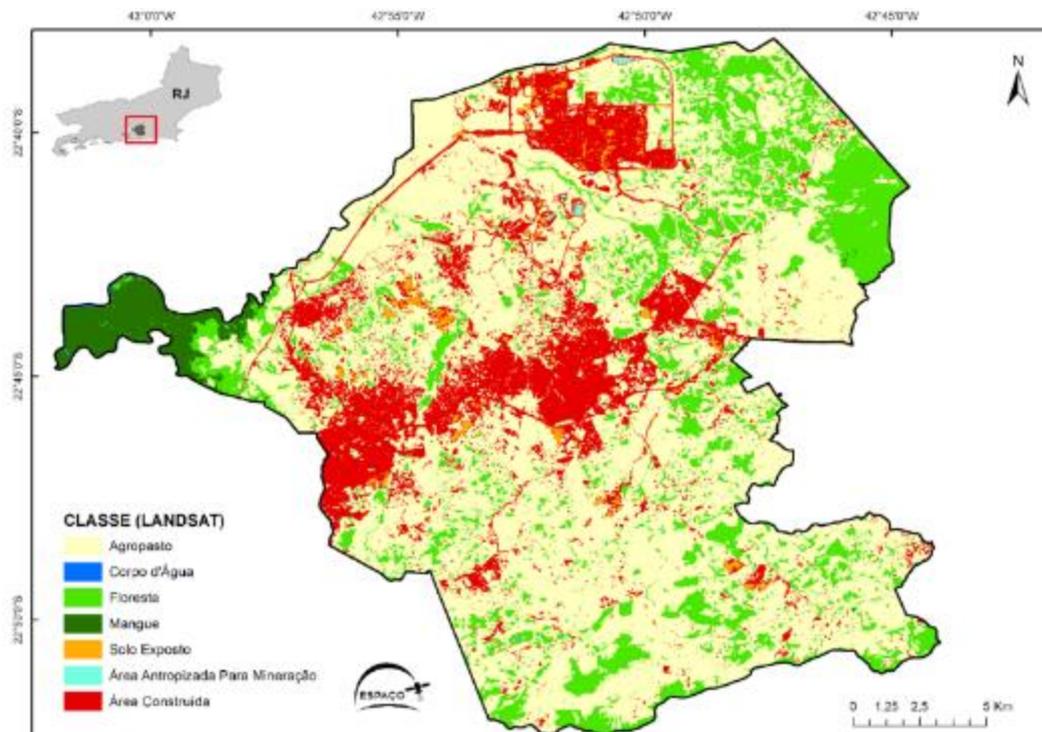
Tabela 4 - Quadro comparativo entre as classificações.

	Produtor Landsat - 8	Produtor Sentinel - 2	Usuário Landsat - 8	Usuário Sentinel - 2	Landsat - 8	Sentinel - 2
Mangue	100,00%	100,00%	96,77%	96,77%		
Corpo D'agua	100,00%	100,00%	100,00%	100,00%		
Floresta	96,67%	96,67%	87,88%	96,67%		
Agropasto	86,67%	86,67%	89,66%	89,66%		
Solo Exp.	80,00%	90,00%	82,76%	90,00%		
Área Cons.	80,00%	80,00%	85,71%	80,00%		
AAPM	100,00%	100,00%	100,00%	100,00%		
Exatidão global					0,91	0,9
Kappa					0,9	0,92

Fonte: Autoria própria

Os mapeamentos de cobertura e uso da terra para o município de Itaboraí no ano de 2020 estão dispostos nas figuras 8 e 9, que correspondem ao produto do sensor dos satélites Landsat-8 e Sentinel-2, respectivamente. Como já destacado, a área de análise foi separada em 7 diferentes classes: agropasto, corpo d'água, floresta, mangue, solo exposto, área antropizada para mineração e área construída.

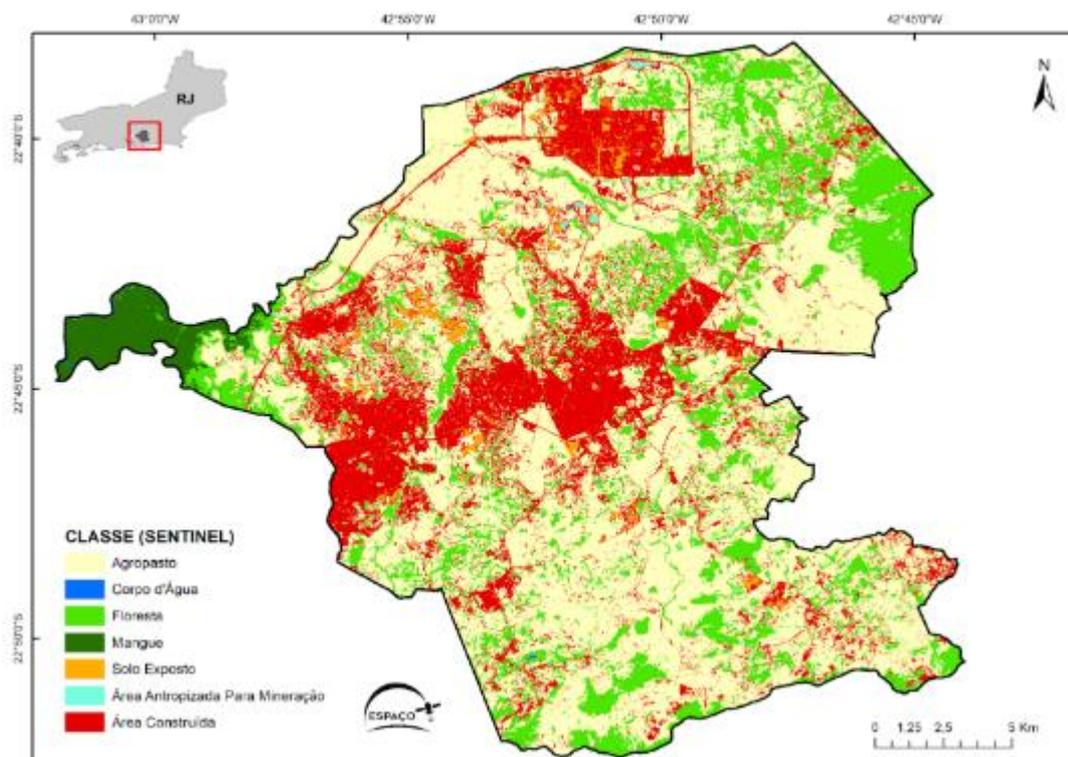
Figura 8 - Mapeamento de uso e cobertura para o município de Itaboraí (Landsat).



Fonte: Autoria própria



Figura 9 - Mapeamento de uso e cobertura para o município de Itaboraí (Sentinel).



Fonte: Autoria própria

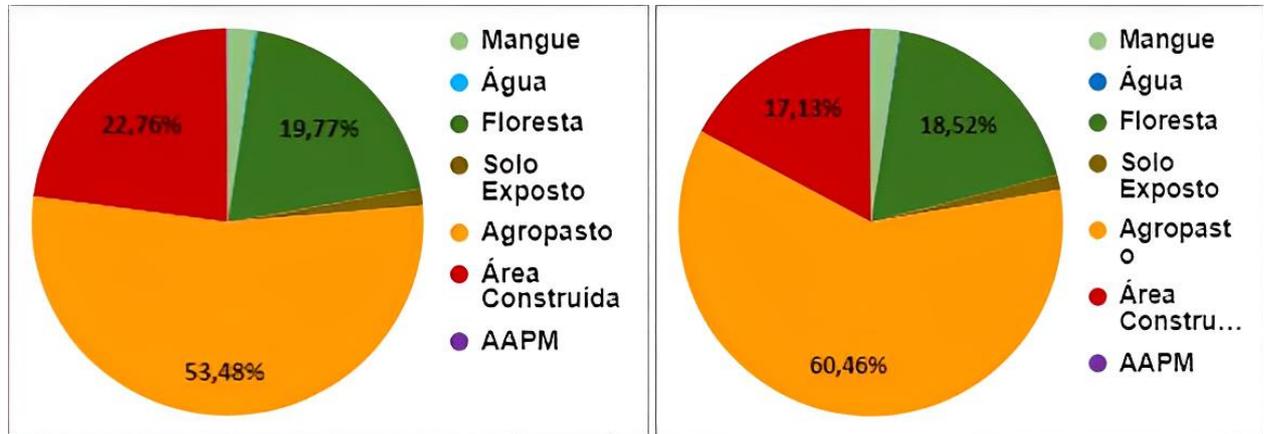
Inicialmente, observa-se que os dois mapeamentos se apresentam com intensa equivalência em relação à organização espacial das classes. Nos dois casos, a partir de uma análise visual dos mapas construídos, a classe agropasto, representada pela cor amarela, é predominante no mapeamento, seguida da classe de área construída, simbolizada pela cor vermelha e com maior concentração dessa classe sobretudo na parte central e norte do município. Além destas, a classe floresta também se mostra bem significativa, representada na cor verde claro e com maior presença à nordeste da área de estudo. Além desses aspectos gerais no que tange o mapeamento de uso e cobertura, pôde-se perceber a existência, nos dois casos, do efeito “*salt and pepper*”, que ocorre quando não há uma delimitação natural e/ou bem definida das bordas dos objetos classificados, gerando assim uma aparência “salpicada” no mapeamento (DA LUZ, et al., 2009). Assim, ocorre nos produtos gerados a existência de pontos aleatórios isolados, sobretudo na classe área construída no caso Sentinel-2.

O que é percebido de forma geral em relação a distribuição e proporção das classes, confirma-se a partir da contabilização e posterior representação em gráficos (figura 10, referentes a Sentinel e Landsat, respectivamente), que expressam a maior proporção de uma determinada classe em porcentagem para a área de todo o município. Com isso, fica clara a maior representatividade das classes agropasto, área construída e floresta, com destaque para o agropasto, que ocupa mais da metade da área total do município nos dois casos; destaca-se



também que nas classes área construída e agropasto são onde se expressam as maiores diferenças, de 5% e 7%, respectivamente, se comparados os dois mapeamentos.

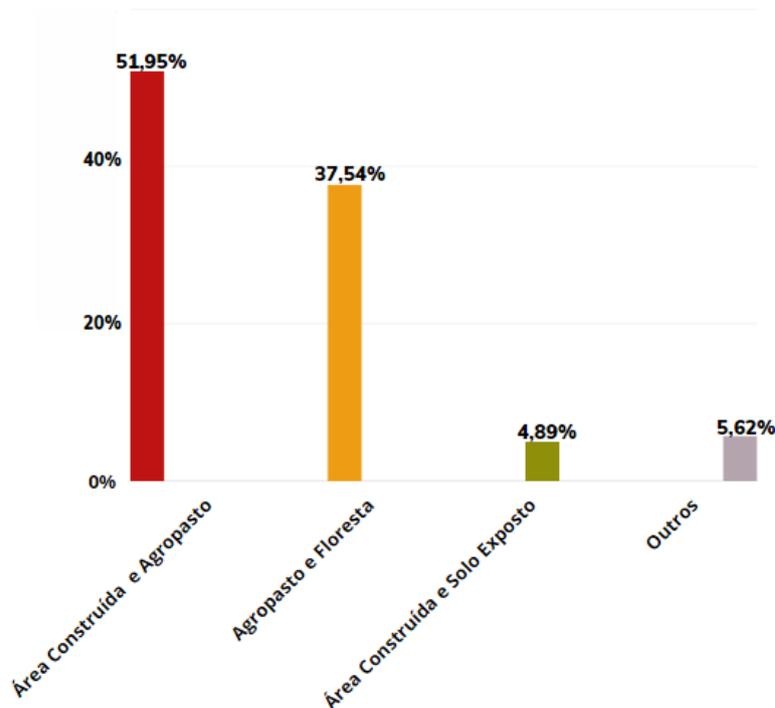
Figura 10 - representatividade percentual das classes em relação a área total de Itaboraí para o Sentinel-2 e Landsat-8 (respectivamente)



Fonte: Autoria própria

Para o desenvolvimento de uma análise comparativa dos mapeamentos produzidos, foi realizada a sobreposição de cada pixel dos mapeamentos produzidos. O resultado disso mostrou as confusões entre pixels mapeados que ocorreram na classificação. Em vista disso, a figura 11, exposta abaixo, expõe os resultados adquiridos a partir da elaboração do *Combine*, com destaque para as principais classes que possuíram as maiores diferenças.

Figura 11 - Gráfico de representação das maiores confusões entre classes considerando os dois mapeamentos.



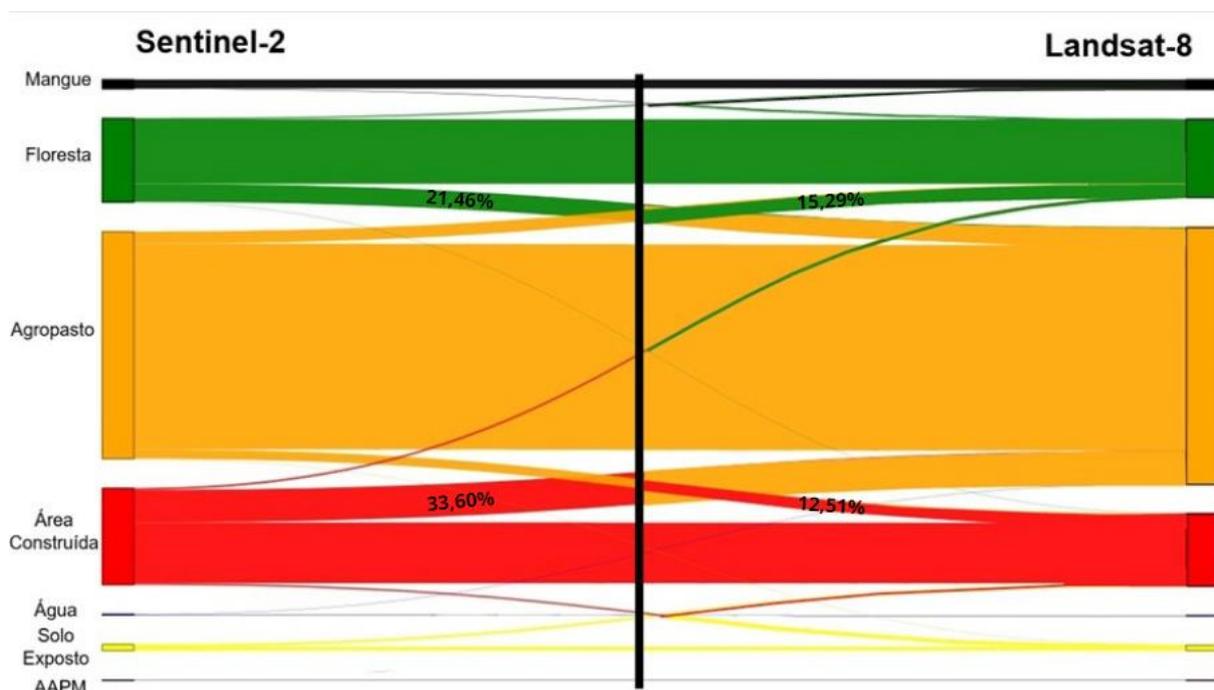
Fonte: Autoria própria



Ao todo, cerca de 19% dos pixels apresentaram confusões entre as classificações geradas pelos dois sensores, considerando todas as classes de toda a área mapeada. Assim, observa-se que as classes que mais se confundiram entre as classificações foram: Área construída e Agropasto, com 51,95%. A segunda maior confusão foi entre as classes de Agropasto e Floresta com 37,54%, seguida de Área construída e Solo exposto, com 5,49% e, por fim, outros, com 5,62%, que contabiliza as demais confusões menos representativas que ocorreram.

Além disso, de forma similar, o gráfico de Sankey (figura 12) também indica as confusões dos sensores com cada classe, mas, dessa vez, de maneira mais visual. Assim, é possível identificar a quantidade de confusões ou similaridades entre as classes do mapeamento. Logo, quando ocorre uma conexão direta entre as mesmas classes, significa que os pixels foram igualmente classificados no mapeamento; em contrapartida, quando a conexão entre as extremidades do gráfico sai de uma classe para outra, significa que ocorreu uma dessemelhança na definição da classe, que é quantificada a partir da espessura das linhas/faixas e, nesse sentido, também torna explícito como esses pixels de confusão são definidos nos dois mapeamentos.

Figura 12 - Gráfico de Sankey.



Fonte: Autoria própria



Por meio do gráfico é possível observar que o total de floresta classificada por ambos os sensores é quase o mesmo, no entanto 21,46% da floresta do Sentinel foi classificada como agropasto no landsat e 15,29% ao contrário. Também é perceptível a maior diferença entre as classificações, sendo entre as classes de área construída e a de agropasto, tendo 33,60% da área construída do sentinel sendo classificada como agropasto no landsat e apenas 12,51% da área construída do landsat como área agropasto no sentinel.

CONSIDERAÇÕES FINAIS

O trabalho em questão conseguiu mostrar algumas diferenças na utilização dos dois sensores para o município de Itaboraí. No que tange aos mapeamentos produzidos, conforme mostra a validação realizada, foi detectado um excelente resultado das classificações nos dois casos (FONSECA, 2000), com Kappa de valores próximos entre si e superiores a 0,8, representados por 0,90 para o Landsat-8 e 0,92 para o Sentinel-2.

Comportamento semelhante também é encontrado em outros estudos que comparam a classificação de cobertura e uso da terra produzido com os produtos Landsat-8 e Sentinel-2. Machado (2020), realiza um estudo comparativo das classificações geradas com imagens dos sensores OLI e MSI, Landsat e Sentinel, respectivamente, para a Ilha do Maranhão. Nesse caso, bem como no estudo aqui desenvolvido, o índice Kappa apresentou valores próximos, representado por 0,91 no caso Landsat e 0,86 no caso Sentinel. No estudo de Machado (2020), apesar do autor ter utilizado software e algoritmo de classificação diferentes, também foi desenvolvido o NDVI e a classificação também foi supervisionada, com classes idênticas e pré-definidas para a classificação das duas imagens.

Por outro lado, Freires et al. (2019) encontram resultados que divergem do padrão encontrado neste estudo e no de Machado (2020). No contexto do trabalho desenvolvido por Freires et al. (2019), os autores realizam um estudo também similar, onde utilizam imagens dos mesmos sensores - OLI e MSI - para uma análise comparativa de mapeamentos de uso e cobertura da terra, dessa vez no Maciço de Uruburetama (CE). Os valores do Kappa, neste caso, são de 0,42 para o produto Landsat-8 e 0,83, para o produto Sentinel-2, o que mostra uma diferença bem mais significativa se comparado ao exemplo anterior. Neste caso, além de software e algoritmo de classificação diferentes em relação a este estudo, os autores não realizam uma classificação pixel a pixel; ou seja, é utilizado um segmentador.

Neste estudo, as principais diferenças analisadas são nas classes do agropasto e da área construída, principalmente em locais próximos às áreas de transição entre uma ou mais classes, ou seja, as bordas. As confusões aparecem pouco associadas a locais centrais do município. Este entrave, mesmo que não tenha influenciado na definição de um mapeamento excelente, poderia ser sanado a partir da segmentação da imagem ou aplicação de filtros - processos que também podem ser desenvolvidos na plataforma GEE.

A decisão sobre qual sensor seria mais adequado para o desenvolvimento de pesquisas varia muito de acordo com a proposta do estudo. O Landsat oferece a possibilidade de um vasto estudo temporal, sendo melhor adequado especialmente se o objetivo da pesquisa está associado a um estudo temporal. Assim, neste caso, apesar de o Sentinel-2 possuir uma melhor resolução espacial, como os resultados não apresentaram diferenças muito significativas para o município, a resolução temporal do Landsat se adequa melhor para o estudo das transformações do município.

O *Google Earth Engine* a bastante tempo vem se mostrando como uma plataforma com grande potencial para os estudos espaciais, devido a sua versatilidade em combinar diferentes algoritmos e seu banco de dados. O compartilhamento de *scripts* e de trabalhos feitos dentro da



plataforma, auxiliam na busca por metodologias que seriam mais adequadas para sua área de estudos. Além disso, a plataforma é gratuita e diminui a necessidade de se ter um hardware potente para o processamento.

Por fim, destaca-se que esta pesquisa propõe uma metodologia comparativa das diferenças entre os sensores, no entanto, existem outras metodologias, softwares e algoritmos dentro ou fora do próprio GEE que permitem chegar a conclusões conflitantes ou não com os resultados do presente artigo.

REFERÊNCIAS

AGÊNCIA ESPACIAL EUROPEIA (ESA). Introduzindo o Sentinel-2. [2018]. Disponível em:

<

https://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Sentinel2/Introducing_Sentinel-2>. Acesso em: 28 de abril de 2022.

APOSTILA INTRODUÇÃO AO SENSORIAMENTO REMOTO, Divisão de Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais (INPE). Disponível em: <<http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>>.

BEZERRA, U. A. et al. Comparativo do Índice de Vegetação de Diferença Normalizada (NDVI) entre os Sensores OLI-Satélite Landsat-8 e MSI-Satélite Sentinel-2 em Região Semiárida. Anuário do Instituto de Geociências, v. 41, n. 3, p. 167-177, 2018.

BERNARDI, H. V. F.; DZEDZEJ, M.; CARVALHO, L. M. T.; ACERBI JÚNIOR, F. W. Classificação digital do uso do solo comparando os métodos “pixel a pixel” e orientada ao objeto em imagem QuickBird. Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, INPE, Florianópolis, Brasil, p. 5595-5602, 2007.

BRASILEIRO, S. F. Ministério da Agricultura, Pecuária e Abastecimento. 2021.

CARVALHO, W. S.; FILHO, F. J. C. M.; SANTOS, T. L. Uso e cobertura do solo utilizando Google Earth Engine (GEE): Estudo de caso em uma unidade de conservação. Brazilian Journal of Development. v.7, n.2, fev. 2021.

CRUZ, C. L. Z. Análise do Classificador RandomForest na Classificação da Cobertura e Uso da terra no contexto da Mata Atlântica no estado do Rio de Janeiro. Dissertação - Universidade Federal do Rio de Janeiro, 2021.

DA LUZ, N. B.; DOS SANTOS, D. J.; ANTUNES, A. F. B. Segmentação de imagens e classificação baseada em regras de conhecimento como novas abordagens para o mapeamento do uso da terra no Estado do Paraná. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, INPE, p. 989-996, 2009.

DIAS, A. P., SOUZA, A. A., MAIA, A. B., BERZINS, J. A. F. Complexo Petroquímico do Rio de Janeiro (Comperj): Impactos socioambientais, violação de direitos e conflitos na Baía de Guanabara. Revista Ética e Filosofia Política – Nº 16 –Volume 1 – junho de 2013



FREIRES, E. V., SILVA NETO, C. Â. D., CUNHA, D. S. R., DUARTE, C. R., VERÍSSIMO, C. U. V., GOMES, D. D. M. Comparação de Imagens OLI/Landsat-8 e MSI/Sentinel-2 no mapeamento de cobertura e uso da terra no Maciço de Uruburetama, Ceará. 2019.

FONSECA, L. M. G. Processamento digital de imagens. Instituto Nacional de Pesquisas Espaciais (INPE), 2000. 105p.

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

MACHADO, A. M. B. Comparação de imagens OLI/landsat-8 e MSI/sentinel-2 no mapeamento de uso e cobertura da terra na ilha do Maranhão. Revista Equador, v. 9, n. 3, p. 209-232, 2020.

OLIVEIRA, M., COSTA, V. C., FEVRIER, P. R. Monitoramento do uso e cobertura da vegetação na Área de Proteção Ambiental Suruí (Magé - RJ), uma atualização tecnológica - aplicação da plataforma Google Earth Engine. Anais Simpósio Brasileiro de Sensoriamento Remoto. Santos-SP. 2019.

PANCHER, A. M. Os Reflexos dos Avanços das Geotecnologias no Estudo da Evolução da Ocupação Urbana. REVISTA GEONORTE, v. 3, n. 5, p. 1694–1706-1694–1706, 2012.

RIMA. Projeto de Implantação do Arco Metropolitano do Rio de Janeiro BR-493/RJ-109. p. 58, 2007.

WIGGERS, K. L., RIBEIRO, S. R. A. Validação da classificação do uso e cobertura da terra mediante visita “in loco” e imagem de VANT. X Congresso Brasileiro de Agroinformática. Ponta Grossa-PR. 2015.

COMO CITAR ESTE TRABALHO

SILVA, R. G, LIRA, F. F, PIMENTEL, J. R, CRUZ, C. B. M. Análise comparativa de mapeamentos do uso e cobertura a partir de imagens Landsat-8 e Sentinel-2 através do algoritmo Random Forest na plataforma Google Earth Engine. Revista Tamoios, São Gonçalo, v. 19, n. 2, p. 61-79, 2023. Disponível em: <https://doi.org/10.12957/tamoios.2023.76109>. Acesso em: DD MMM. AAAA.