



UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
CENTRO DE CIÊNCIAS MATEMÁTICAS E DA TERRA
INSTITUTO DE GEOCIÊNCIAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

JONAS RAMOS PIMENTEL

Estudo das transformações da paisagem do município de Itaboraí–RJ por meio do algoritmo Random Forest na plataforma do Google Earth Engine.

Rio de Janeiro
2023

JONAS RAMOS PIMENTEL

Estudo das transformações da paisagem do município de Itaboraí–RJ por meio do algoritmo Random Forest na plataforma do Google Earth Engine.

Dissertação apresentada ao Programa de Pós-Graduação em Geografia do Departamento de Geografia do Instituto de Geociências, Universidade Federal do Rio de Janeiro como requisito para a obtenção do título de mestre em Geografia.

Orientador: Prof.^a Dr. Carla Bernadete Madureira Cruz

Coorientador: Prof. Phillipe Valente Cardoso

Rio de Janeiro

2023

CIP - Catalogação na Publicação

R145e Ramos Pimentel, Jonas
Estudo das transformações da paisagem do município de Itaboraí - RJ por meio do algoritmo Random Forest na plataforma do Google Earth Engine / Jonas Ramos Pimentel. -- Rio de Janeiro, 2023.
227 f.

Orientador: Carla Bernadete Madureira Cruz.
Dissertação (mestrado) - Universidade Federal do Rio de Janeiro, Instituto de Geociências, Programa de Pós-Graduação em Geografia, 2023.

1. Itaboraí - RJ. 2. Uso e Cobertura da Terra. 3. Google Earth Engine. 4. Radom Forest . I. Bernadete Madureira Cruz, Carla, orient. II. Título.

Elaborado pelo Sistema de Geração Automática da UFRJ com os dados fornecidos pelo(a) autor(a), sob a responsabilidade de Miguel Romeu Amorim Neto - CRB-7/6283.

JONAS RAMOS PIMENTEL

Estudo das transformações da paisagem do município de Itaboraí–RJ por meio do algoritmo Random Forest na plataforma do Google Earth Engine.

Dissertação apresentada ao Programa de Pós-Graduação em Geografia do Departamento de Geografia do Instituto de Geociências, Universidade Federal do Rio de Janeiro como requisito para a obtenção do título de mestre em Geografia.

Aprovada em: 15/12/2023.

BANCA EXAMINADORA

Prof. Dr. Carla Bernadete Madureira Cruz (Orientador)
Universidade Federal do Rio de Janeiro (UFRJ)

Prof. Dr. Phillippe Valente Cardoso (Coorientador)
Faculdade de Formação de Professores da Universidade do Estado do Rio de Janeiro (FFP/UERJ)

Prof. Dr. Rafael Silva de Barros
Universidade Federal do Rio de Janeiro (UFRJ)

Prof. Dr. Raúl Sánchez Vicens
Universidade Federal Fluminense (UFF)

AGRADECIMENTOS

O mestrado certamente foi uma das melhores decisões para minha vida, fico muito feliz por ter feito parte da faculdade responsável por formar professores que foram minhas referências na graduação. Deixarei um breve agradecimento para algumas dessas pessoas que marcaram a minha trajetória.

Aos meus orientadores, Carla Madureira e Phillipe Valente, por todo apoio e suporte nos anos do mestrado. Todos os encontros foram essenciais para o desenvolvimento da dissertação. Além disso, todos os conselhos e instruções foram extremamente importantes para que todo esse processo ocorresse da forma mais tranquila possível. Certamente levarei todos os comentários, conselhos e dicas para a minha vida toda!

Gostaria de agradecer aos meus orientandos e amigos, Felipe Lira e Rodrigo Gomes por esses anos. Foram momentos de muito aprendizado e sem dúvidas resultaram em conclusões muito importantes para o resultado dessa dissertação. Além disso, não posso deixar de agradecer a paciência durante as orientações, visto que sou uma pessoa completamente enrolada e um pouco confusa na hora de delegar tarefas e explicar minhas ideias.

À minha mãe, Márcia Conceição, e ao meu pai, Elenildo Pimentel, pelo apoio e compreensão ao longo desta jornada. Vocês foram minha fonte constante de motivação e inspiração. Agradeço por acreditarem em mim e me apoiarem em todos os momentos. Não posso deixar de mencionar a minha noiva, Emily Dias, por aturar alguns dos meus surtos e não me deixar desistir em momentos que eu estava mentalmente saturado.

RESUMO

A cidade de Itaboraí – RJ esteve no centro das transformações de um dos maiores investimentos da Petrobras, o COMPERJ (Complexo Petroquímico do Estado do Rio de Janeiro). A especulação imobiliária agiu rapidamente, levando ao aumento das áreas residenciais e ao surgimento de regiões pouco ocupadas no município. Junto a isso, houve um grande fluxo de migrantes atraídos pela oportunidade de ocupar as vagas geradas pelo COMPERJ e pelos demais empreendimentos. Devido ao crescente aumento da disponibilidade de produtos do sensoriamento remoto e aumento da eficácia das técnicas de detecção dos elementos da superfície terrestre, os mapeamentos de Cobertura e Uso da Terra passaram a apresentar, com o tempo de produção reduzido, resultados que expressam a paisagem de forma mais completa. Há algum tempo o *Machine Learning* e o processamento em nuvem vem automatizando o processamento de imagens orbitais e, conseqüentemente, conquistando espaço nos estudos espaciais. O Random Forest é um dos vários algoritmos de classificação que surgiram para identificar os padrões espaciais de forma automatizada, sua eficácia foi comprovada por estudos que obtiveram excelentes resultados na identificação das feições em imagens orbitais. Junto à plataforma gratuita de processamento de dados em nuvem do Google Earth Engine (GEE) e com mapas de referência de SEA/RJ e do projeto MapBiomass, coleção 6, o presente estudo buscou elaborar classificações de Cobertura e Uso de Terra para os anos de 2005, 2007, 2011 e 2020. Buscou ainda justificar a necessidade de se elaborar novos mapeamentos do município, uma vez que o existente, produzido pelo MapBiomass, não atendeu à escala desejada. Os resultados apresentados apontam mudanças significativas no Cobertura e Uso da Terra, principalmente em classes relacionadas à infraestrutura urbana, como áreas urbanas, áreas de solo exposto e agropasto, bem como um possível crescimento das áreas vegetadas nos últimos anos. As classificações finais foram em sua maior parte automatizadas, com edição inferior a 10% da área total mapeada. Os mapeamentos apresentaram exatidão temática de aproximadamente 90% para as 4 datas, o que evidencia a eficácia do algoritmo.

Palavras-chave: Sensoriamento remoto; Comperj; Cobertura e Uso da Terra.

ABSTRACT

The city of Itaboraí – RJ was at the center of the transformations of one of Petrobras' largest investments, COMPERJ (Petrochemical Complex of the State of Rio de Janeiro). Real estate speculation acted quickly, leading to an increase in residential areas and the emergence of poorly occupied regions in the municipality. Along with this, there was a large flow of immigrants attracted by the opportunity to fill the vacancies created by COMPERJ and other projects. Due to the increasing availability of remote sensing products and the increased effectiveness of techniques for detecting elements of the Earth's surface, Land Cover and Use mappings began to present, with reduced production time, results that express the landscape of more complete form. For some time now, Machine Learning and cloud processing have been automating the processing of orbital images and, consequently, gaining ground in space studies. RandomForest is one of several classification algorithms that have emerged to identify spatial patterns in an automated way. Its effectiveness has been proven by studies that have obtained excellent results in identifying features in orbital images. Together with the free Google Earth Engine (GEE) cloud data processing platform and with reference maps of SEA/RJ and the MapBiomass project, collection six, this study sought to develop Land Cover and Use classifications for the years 2005, 2007, 2011 and 2020. It also sought to justify the need to create new mappings of the municipality, since the existing one, produced by MapBiomass, did not meet the desired scale. The results presented point to significant changes in Land Cover and Use, in classes related to urban infrastructure, such as urban areas, areas of exposed soil and agropasture, as well as a growth in vegetated areas in recent years. The final classifications were mostly automated, with editing of less than 10% of the total mapped area. The mappings showed thematic accuracy of approximately 90% for the four dates, which highlights the effectiveness of the algorithm.

Keywords: Itaboraí-RJ. Remote sensing. Google Earth Engine.

LISTA DE FIGURAS

Figura 1: Igreja São João Batista.....	22
Figura 2: Localização do município de Itaboraí -RJ.....	24
Figura 3: Principais vias do município de Itaboraí – RJ.	25
Figura 4: Localização do COMPERJ.....	27
Figura 5: Consórcio do Leste Metropolitano	28
Figura 6: Arco Metropolitano do Rio de Janeiro	30
Figura 7: Legenda Final.....	34
Figura 8: Caracterização da legenda criada para a comparação	35
Figura 9: Redimensionamento dos pixels de classificação do SEA de 2x2 para 30x30, respectivamente.	36
Figura 10: Localização das principais diferenças entre as classificações representadas pela cor roxa.	40
Figura 11: Classificação de Cobertura e Uso da Terra do MapBiomias para 2015.....	41
Figura 12: Classificação de Cobertura e Uso da Terra do SEA para 2015 redimensionado para 30x30.	42
Figura 13: Catálogo do GEE.....	46
Figura 14: Algoritmos de filtragem de nuvem para as imagens Landsat-8 e Landsat-5, respectivamente.	48
Figura 15: Classes de Cobertura e Uso da Terra.....	15
Figura 16: Parâmetros do RF.	17
Figura 17: Representação do NDVI na imagem Landsat – 5 (TM) ano 2005....	19
Figura 18: Representação do NDBI na imagem Landsat – 5 (TM) ano 2005....	20
Figura 19: Representação do NDWI na imagem Landsat – 5 (TM) ano 2005. .	21
Figura 20: Validação no Google Earth Pro.....	22
Figura 21: Mapa ano de 2005.	30
Figura 22: Mapa ano de 2007.	31
Figura 23: Mapa ano de 2011.	32
Figura 24: Mapa ano de 2020.	33
Figura 25: Mapa de 2020 com o surgimento da floresta e da Área Construída.	35
Figura 26 : Localização das principais variações do p1.....	40
Figura 27: Localização das principais variações do p2.....	42
Figura 28: Localização das principais variações do p3.....	44

Figura 29: Amostras das intensidades da Área Construída.	45
Figura 30: Área Construída em 2005.	46
Figura 31: Área Construída em 2007.	46
Figura 32: Área Construída em 2011.	47
Figura 33: Área Construída em 2020.	47

LISTA DE GRÁFICOS

Gráfico 1: Acurácia do Produtor.....	38
Gráfico 2: Acurácia do Usuário.....	39
Gráfico 3: Principais confusões entre classes encontradas.	40
Gráfico 4: Acurácia do produtor e Acurácia do usuário para 2005.....	25
Gráfico 5: Acurácia do produtor e Acurácia do usuário para 2007.....	25
Gráfico 6: Acurácia do produtor e Acurácia do usuário para 2011.....	26
Gráfico 7: Acurácia do produtor e Acurácia do usuário para 2020.....	26
Gráfico 8: Gráfico de árvores para os anos.	36
Gráfico 9: Diagrama de Sankey representando as transformações das classes de Uso e Cobertura da Terra nos três períodos.....	38
Gráfico 10: Diagrama de Sankey apresentado a variação das classes no P1..	39
Gráfico 11: Diagrama de Sankey apresentado a variação das classes no P2..	41
Gráfico 12: Diagrama de Sankey apresentado a variação das classes no P3..	43
Gráfico 13: Variação da intensidade da Área Construída entre 2005 e 2007 em hectares.	48
Gráfico 14: Variação da intensidade da Área Construída entre 2007 e 2011 em hectares.	49
Gráfico 15: Variação da intensidade da Área Construída entre 2011 e 2020 em hectares.	50

LISTA DE TABELAS

Tabela 1: Trechos do Arco Metropolitano do Rio de Janeiro	31
Tabela 2: Matriz de Confusão SEA x MapBiomias.	38
Tabela 3: Características das imagens e da classificação.	47
Tabela 4: Matriz de confusão de 2005.....	23
Tabela 5: Matriz de confusão de 2007.....	23
Tabela 6: Matriz de confusão de 2011.....	23
Tabela 7: Matriz de confusão de 2020.....	24
Tabela 8: resumo das matrizes de confusão.	27
Tabela 9: Matriz de confusão da edição ano de 2005.....	28
Tabela 10: Matriz de confusão da edição ano de 2007.	28
Tabela 11: Matriz de confusão da edição ano de 2011.	28
Tabela 12: Matriz de confusão da edição ano de 2020.	29

LISTA DE ABREVIATURAS E SIGLAS

AMRJ	Arco Metropolitano do Rio de Janeiro
COMPERJ	Complexo Petroquímico do Estado do Rio de Janeiro
CONLESTE	Consórcio do Leste Metropolitano
CPRM	Serviço Geológico do Brasil
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
GEE	Google Earth Engine
IBGE	Instituto Brasileiro de Geografia e Estatística
INPE	Instituto Nacional de Pesquisas Espaciais
LANDSAT	Land Remote Sensing Satellite
ML	Machine Learning
NDBI	Normalized Difference Built-Up Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
OLI	Operational Land Imager
RIMA	Relatório de impacto ambiental
RMRJ	Região Metropolitana do Estado do Rio de Janeiro
SEA	Secretaria de Estado do Ambiente e Sustentabilidade
TM	Thematic Mapper
UFRJ	Universidade Federal do Rio de Janeiro

SUMÁRIO

1. INTRODUÇÃO	14
2. OBJETIVOS E QUESTÕES	16
2.1. Objetivo Geral	16
2.2. Objetivos Específicos	16
3. REVISÃO CONCEITUAL	17
3.1. Geotecnologias aplicadas no mapeamento da Cobertura e Uso da Terra.	17
3.2. Sensoriamento remoto e Aprendizado Máquina	18
4. ÁREA DE ESTUDOS	22
4.1. História do município	22
4.2. Localização e População	23
4.3. Complexo petroquímico do Estado do Rio de Janeiro (COMPERJ)	26
5. AVALIAÇÃO DA EXATIDÃO TEMÁTICA E ADEQUAÇÃO DE ESCALA DOS DADOS DO MAPIOMAS PARA O MUNICÍPIO DE ITABORAÍ-RJ	32
5.1. Introdução	32
5.2. Materiais e métodos	33
5.3. Resultados e Discussões	37
5.4. Conclusão	43
6. ANÁLISE DAS MUDANÇAS DA COBERTURA E USO DA TERRA DO MUNICÍPIO DE ITABORAÍ ATRÁÉS DE CLASSIFICAÇÃO MULTITEMPORAL	45
6.1. Introdução	45
6.2. Materiais e métodos	46
6.3. Resultados e discussões	21
6.3.1. Mudanças na Cobertura e Uso da Terra de Itaboraí – RJ	29
6.4. Conclusão	50
7. CONSIDERAÇÕES FINAIS	52
REFERÊNCIAS	55

Anexo - Mapas de Uso e Cobertura da Terra dos anos de 2006, 2007, 2011 e 2020 (Sentinel-2 e Landsat-8). (Capítulo 2).....	61
--	----

1. INTRODUÇÃO

O município de Itaboraí foi intensamente afetado com os investimentos e obras destinadas a atender a demanda causada pelo Complexo Petroquímico do Estado do Rio de Janeiro (COMPERJ). A área urbana dos municípios influenciados pelo empreendimento cresceu significativamente desde o seu anúncio no final do ano de 2006, especialmente na cidade de Itaboraí, que passou a ser atingida pela especulação imobiliária em suas áreas centrais (BIENESTEIN, 2018).

A preocupação ambiental com a implementação do COMPERJ na região, fez com que sua criação adotasse uma postura de empreendedorismo sustentável, visando a criação de um corredor ecológico junto a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), com o intuito de minimizar os impactos ambientais (MOYSES, 2018).

Grande parte dos rios da baía de Guanabara sofreram algumas alterações em seu curso, além da piora da qualidade da água devido à chegada de novos empreendimentos e ao aumento das ocupações irregulares no município. Roberto (2009) comenta que as indústrias da região são as grandes responsáveis pela acumulação de resíduos sólidos nas bacias da região, isso leva à piora da qualidade da água com o aumento da concentração de fósforo, nitrogênio e metais pesados em algumas partes dos rios.

O aumento da complexidade dos estudos e da quantidade de dados relacionados à preservação ambiental e expansão urbana, fizeram com que novas estratégias tivessem que ser pensadas para acompanhar esse rápido crescimento. Os estudos de aprendizado de máquina (*Machine Learning*) começaram a ganhar mais espaço em pesquisas que envolvem a análise da superfície terrestre. A rápida expansão das áreas urbanas trouxe o desafio para as geotecnologias de conseguir acompanhar esse desenvolvimento, ou seja, ferramentas e metodologias que auxiliem no crescimento planejado das cidades.

Os algoritmos que são criados diariamente trazem, cada vez mais, inovações para o estudo do espaço, apresentando novos meios para compreender como os fenômenos humanos e naturais são transformadores importantes da paisagem terrestre. O *Classification and Regression Trees* (CART), *Minimum Distance - Euclidean* (MMD), *Random Forest* (RF), *Naive Bayes* (Bayes) e LIBSVM são exemplos de algoritmos com características distintas.

Para se compreender as transformações na Cobertura e Uso da Terra do município de Itaboraí, primeiro, será feita a avaliação dos dados da exatidão do MapBiomass, coleção 6, para a cidade de Itaboraí, a fim de identificar a necessidade de se produzir novas classificações da cobertura e uso da terra do município. Para tal, a Classificação de Cobertura da Terra do MapBiomass foi comparada com o Mapeamento de Cobertura e Uso e da Terra oficial da Secretaria do Estado do Rio de Janeiro (2015).

O segundo momento, consiste em apresentar as etapas metodológicas da criação do algoritmo para a Classificação de Cobertura e Uso da Terra do município de Itaboraí - RJ para os anos de 2005 (ano anterior ao anúncio do COMPERJ), 2007 (ano referente ao anúncio), 2011 (ano de intensificação das obras) e 2020 (representação atual) na plataforma do *Google Earth Engine*. Os resultados derivados desses mapeamentos foram avaliados, a fim de identificar como a Cobertura e Uso da Terra do município foi se transformando no decorrer dos anos.

As imagens a serem utilizadas nas classificações de Cobertura e Uso da Terra são dos satélites Landsat-5(TM) e Landsat-8(OLI). A etapa de análise e as demais serão auxiliadas pela plataforma *Google Earth Engine* (GEE).

A pesquisa focou suas análises no uso de dados e sistemas gratuitos, de modo que sua replicação seja mais acessível. Dessa forma, o estudo busca contribuir metodologicamente com o mapeamento, monitoramento e geração de cenários em uma área carente de dados e investigação.

2. OBJETIVOS E QUESTÕES

2.1. Objetivo Geral

Analisar as transformações do Uso e Cobertura da Terra do município de Itaboraí - RJ considerando o contexto de inserção do COMPERJ como agente dinamizador na região metropolitana do estado do Rio de Janeiro.

2.2. Objetivos Específicos

- Verificar o grau de exatidão da classificação de Cobertura e Uso da terra do projeto MapBiomass, em escala 1:100.000, para o município de Itaboraí - RJ, tendo como referência o mapeamento da Secretaria do Estado do Meio Ambiente e Sustentabilidade (SEA), escala: 1:25.000.
- Identificar as transições entre as classes de Cobertura e Uso da Terra do município de Itaboraí – RJ nos anos de 2005, 2007, 2011 e 2020, por meio do algoritmo Random Forest na plataforma *Google Earth Engine*.

3. REVISÃO CONCEITUAL

3.1. Geotecnologias aplicadas no mapeamento da Cobertura e Uso da Terra.

A paisagem é um conceito geográfico que nos permite compreender e interpretar o espaço geográfico a partir dos sentidos e, por estar vinculada à percepção visual, possibilita também entender como as diferentes culturas organizam sua sociedade. O avanço das geotecnologias no início dos anos 2000, foi um marco para a paisagem começar a ser estudada de forma integrada e ganhar um papel de importante relevância dentro da gestão territorial.

Com isso, a fim de compreender as transformações da paisagem frente às ações humanas, as técnicas de sensoriamento remoto orbital passaram a ganhar cada vez mais relevância, devido à capacidade de levantar dados da superfície terrestre em diferentes escalas e temporalidades. Os mapeamentos de uso e cobertura da terra são produtos do desenvolvimento do sensoriamento remoto e servem como instrumento para a gestão do território, pois auxiliam na interpretação e monitoramento dos elementos naturais e antrópicos contidos na paisagem.

A representação da paisagem dentro do espaço geográfico está muito sujeita à escala, podendo representar diferentes perspectivas e funções que variam de acordo com a escala de representação. Os aspectos da escala dentro da paisagem são determinantes para tornar plausíveis os estudos que envolvem a caracterização e o delineamento da paisagem no espaço geográfico (LANG e BLASCHKE, 2009). Bertrand (1971) acredita que as escalas temporais e espaciais são elementos importantes na descrição da paisagem por meio de uma representação cartográfica.

Nesse contexto, as geotecnologias vêm se mostrando cada vez mais importantes nos estudos da natureza e do homem, por fornecerem novas ferramentas e metodologias que ampliam a quantidade de dados que podem ser obtidos da superfície terrestre, sendo fundamentais para retratar a paisagem (AUGUSTO, 2016). Órgãos de preservação ambiental, responsáveis por garantir a conservação desses ambientes, têm utilizado as geotecnologias na gestão de áreas de preservação (COSTA, 2017).

Uma das ciências que compõem as geotecnologias como um importante campo de conhecimento na produção e reprodução de informações a respeito da paisagem, é o geoprocessamento. Segundo Câmara et. al. (2001), o geoprocessamento pode ser definido como:

“O termo Geoprocessamento denota a disciplina do conhecimento que utiliza técnicas matemáticas e computacionais para o tratamento da informação geográfica e que vem influenciando de maneira crescente as áreas de Cartografia, Análise de Recursos Naturais, Transportes, Comunicações, Energia e Planejamento Urbano e Regional” (CÂMARA et al.2001, p. 1)

As diferentes representações e temas de análise da paisagem geográfica são representados pela cartografia em um mundo digital através do geoprocessamento, por ter os mapas como principal produto para demonstrar as especificidades da paisagem, tais como a ação antrópica na natureza, as transformações que ocorrem ao longo do tempo e interpelações entre os elementos que compõem a paisagem (MENESES, 2000).

As séries temporais são produtos do sensoriamento remoto que surgiram como meios de se entender as transformações globais da superfície terrestre, especialmente na atualidade em que as mudanças nos ecossistemas e o grande aumento da urbanização estão cada vez mais acelerados (OLIVEIRA, 2019).

A observação contínua de uma determinada região ou do comportamento de um fenômeno na superfície terrestre, auxilia a identificar e entender as características principais, bem como seu comportamento e suas variações ao longo do tempo (PAIVA, 2021). Bonamigo et al. (2019) comentam uma das aplicações dos mapeamentos temporais em áreas de pastagem, que possibilita aos pesquisadores identificarem os diferentes tipos de manejo por meio de respostas espectrais. Além disso, há também a identificação do desmatamento em áreas florestadas e a expansão urbana nas cidades, exemplos tradicionais de aplicações recorrentes nos estudos do sensoriamento remoto.

3.2. Sensoriamento remoto e Aprendizado Máquina

Com o desenvolvimento do sensoriamento remoto, novas técnicas de produção de mapeamentos dos diferentes usos e coberturas da superfície terrestre

surgiram. Esses tipos de mapeamentos nos permitem monitorar as mudanças que vêm ocorrendo na paisagem, além de identificar quais são os agentes responsáveis por provocar essas mudanças, sejam eles naturais ou antrópicos.

O sensoriamento remoto é um termo científico relacionado ao desenvolvimento da fotografia e dos levantamentos orbitais, sendo a fotometria e a fotointerpretação termos que antecederam o sensoriamento remoto em si, explicam Novo e Ponzoni (2001). No ano de 1960 o termo sensoriamento remoto surgiu pela primeira vez ao se referir à captura de imagens dos objetos à distância e nessa mesma década os sistemas orbitais começaram a aparecer, tendo os primeiros sensores voltados para o uso meteorológico e também a utilização de câmeras fotográficas para gerar imagens da terra em missões da série Apolo.

O início da década de 70 é marcado pelo lançamento do primeiro satélite da série, atualmente conhecido como Landsat, que tinha como objetivo o levantamento de dados sobre os recursos terrestres, concluíram Novo e Ponzoni (2001). Os sensores dessa época conseguiam fazer varreduras e gerar imagens em várias faixas do espectro eletromagnético ao mesmo tempo.

As imagens de satélites possuem 4 tipos de resolução: Espacial, responsável por determinar o tamanho dos menores objetos apresentados nas imagens, ou seja, essa resolução está diretamente relacionada com o tamanho dos pixels que compõem a imagem. Espectral, relacionada à quantidade e largura das bandas que o sensor é capaz de adquirir, que está relacionada à capacidade de identificar e distinguir diferentes objetos em uma imagem. Radiométrica, relacionada à capacidade do sensor em distinguir os diferentes elementos que aparecem na paisagem através da quantidade de tons de cinzas presentes na imagem. E, por fim, a Temporal, relacionada ao período no qual um satélite demora a visitar uma mesma área já imaginada.

Os sensores, como nos apresenta Fitz (2008), podem ser classificados em sensores passivos, ativos, não imageadores e imageadores. Os sensores passivos e ativos estão diretamente relacionados à sua fonte de energia, sendo os sensores ativos capazes de gerar sua própria energia sem depender de uma fonte de energia externa para interagir com os objetos. Já os sensores passivos são aqueles que dependem da energia externa para interagir com os objetos, normalmente a energia solar.

Outros tipos de sensores apontados por Fitz (2008) são os sensores não imageadores que, diferente dos outros sensores que geram as informações através de imagens, reproduzem seus dados através de outros tipos de formato, como gráficos ou nuvem de pontos. Já os sensores imageadores são aqueles sensores que retratam a informação através de imagens.

Assim como o sensoriamento remoto, os algoritmos de aprendizado máquina (ML) começaram a ser aplicados em análises feitas a partir de dados multiespectrais gerados ao final da década de 60 (HOLLOWAY e MENGERSEN, 2018). À medida que novos sensores com características distintas começaram a surgir, técnicas de ML destinadas ao estudo espacial e espectral começaram a se desenvolver (HOLLOWAY e MENGERSEN, 2018).

A grande quantidade e variedade de dados espaciais produzidos diariamente, fez com que as técnicas computacionais tivessem que evoluir ao ponto de superar as limitações que eram empecilhos para o avanço dos estudos espaciais nos anos anteriores. Paralelamente, com a necessidade de se avançar estatisticamente e metodologicamente, a qualidade dos produtos a serem tratados surgiu como um fator determinante para o incremento dessas novas tecnologias. LI et al. (2015) comentam sobre a evolução do ML como uma das formas de se acompanhar as rápidas e dinâmicas transformações que os estudos espaciais vêm passando.

Os algoritmos de ML oferecem subsídios para pesquisas que buscam estudar os impactos da ação humana na superfície terrestre, como a aplicação na detecção de mudanças na cobertura vegetal por meio de imagens de satélites, seja ela causada pelo desmatamento florestal ou pelo aumento de áreas de pastagem ou ganho florestal (HOLLOWAY e MENGERSEN, 2018). Maxwell, Warner e Fang (2018) explicam que a eficiência do ML para a classificação de imagens do sensoriamento remoto se sustenta principalmente pela possibilidade de se mapear classes complexas em grandes áreas.

Maxwell, Warner e Fang (2018) justificam a maior exatidão dos classificadores tradicionais para classes complexas ao dizer que:

“(...) Algoritmos de aprendizado de máquina geralmente são capazes de modelar assinaturas de classes complexas, podem aceitar uma variedade de dados preditores de entrada e não fazem suposições sobre a distribuição de dados (ou seja, não são paramétricos) (...). (HOLLOWAY e MENGERSEN, 2018 p. 2784)

Atualmente, o sensoriamento remoto produz imagens que auxiliam no mapeamento de objetos na escala local, isso devido à resolução espectral vinda das bandas dos sensores e da alta resolução espacial que os mesmos possuem, podendo chegar a 1 metro (Meneses e Almeida, 2012). Além disso, os produtos de técnicas de ML estão cada vez mais populares, especialmente devido à popularização do GEE e a facilidade de se utilizar a plataforma para estudos espaciais por meio de algoritmos públicos de forma gratuita e com rapidez no processamento.

A vasta quantidade de algoritmos e métodos ML desenvolvidos, faz com que a aplicação dos mesmos dentro das pesquisas se torne algo tentador e ao mesmo tempo desafiante. Segundo Maxwell, Warner e Fang (2018) isso acontece devido às incertezas e contradições encontradas na própria literatura a respeito de como essas novas tecnologias funcionam dentro das propostas apresentadas, além de se buscar saber a melhor forma de aplicá-las a fim de se chegar a um produto que atenda à demanda exigida.

4. ÁREA DE ESTUDOS

4.1. História do município

A origem de Itaboraí está relacionada a história da Vila de Santo Antônio de Sá, localizada às margens do rio Macacu, rio muito importante na época, por onde era feito todo transporte de produtos produzidos na região, movimentando a economia local. Na Vila de Santo Antônio de Sá eram transportados, por barco, pelo rio Macacu até a Baía de Guanabara, produtos, principalmente açúcar, que depois eram exportados para a Europa. Havia muitas fazendas e engenhos de açúcar.

A Vila de Santo Antônio de Sá entra em decadência após uma epidemia de malária, denominada “febre de Macacu”, dizimando a maior parte da população. O transporte hidrográfico passa a ser substituído pelo transporte ferroviário, levando a Vila a decadência total, Porto das Caixas começa a se destacar.

Itaboraí, antes Freguesia de São João de Itaboraí e pertencente a Vila de Santo Antônio de Sá, passa a pertencer a Vila de Porto das Caixas. A Freguesia de São João de Itaboraí surge com a construção da capela de São João Batista (figura 1), hoje a igreja matriz, ainda no mesmo local, já que no passado esteve em ruínas e foi reconstruída. A Freguesia começa notável desenvolvimento, com mais capelas construídas, grandes propriedades agrícolas e aumento de povoado. Tornou-se a Freguesia mais importante devido à agricultura, produzindo açúcar, farinha, aguardente, feijão, milho, café, arroz, entre outros.

Figura 1: Igreja São João Batista.

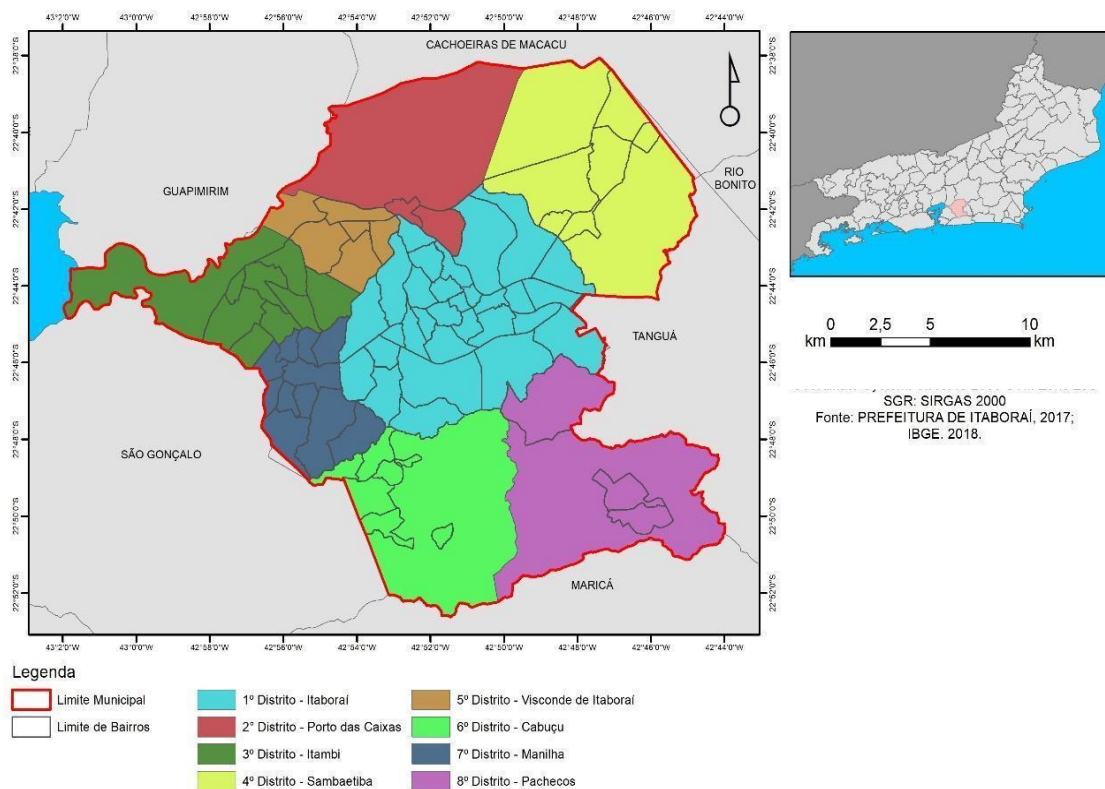


Fonte: IBGE, 2023.

4.2. Localização e População

O município de Itaboraí fica localizado na região leste metropolitana do estado do Rio de Janeiro, tendo Guapimirim, São Gonçalo, Cachoeiras de Macacu, Tanguá e Maricá como cidades vizinhas. A população encontra-se distribuída em 93 bairros e 8 distritos, sendo eles: Itaboraí, Porto das Caixas, Itambi, Sambaetiba, Visconde de Itaboraí, Cabuçu, Manilha e Pacheco (Figura 2). De acordo com o censo, em 2022 a população era de 224.267 pessoas e com 521,60hab/km² de densidade demográfica (IBGE, 2022).

Figura 2: Localização do município de Itaboraí -RJ.

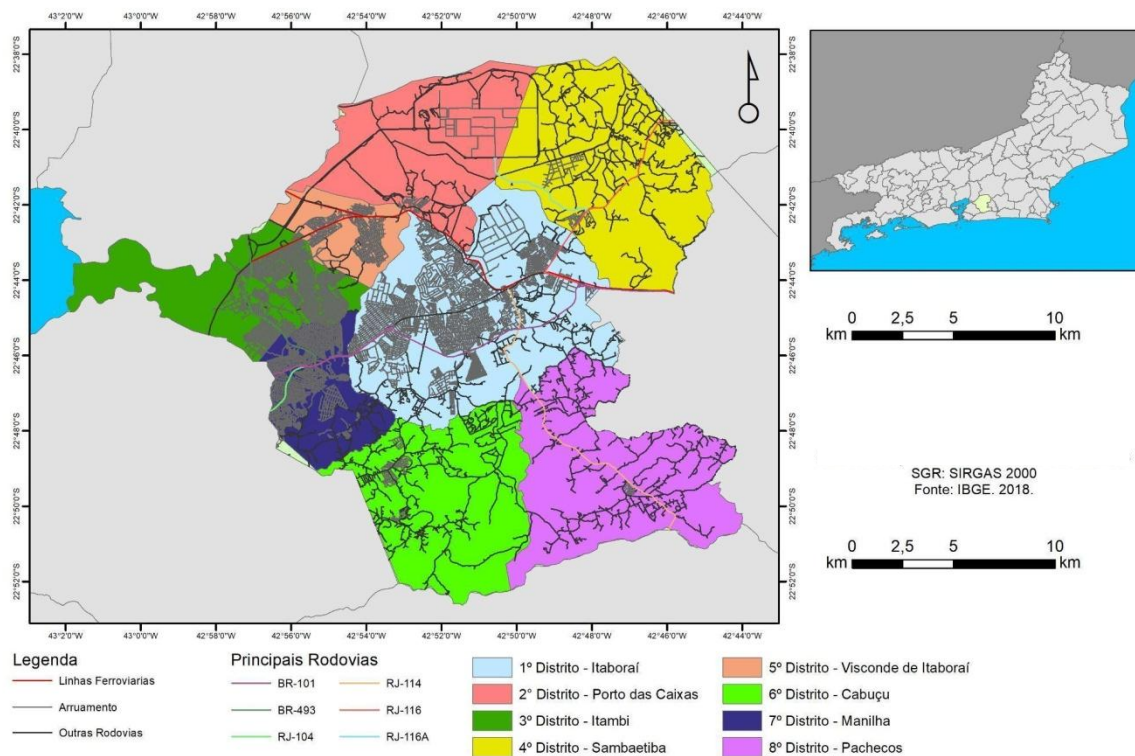


Fonte: Representação feita pelo autor.

Itaboraí junto aos municípios de Niterói, São Gonçalo, Rio Bonito, Maricá, Tanguá, Cachoeiras de Macacu, Casimiro de Abreu, Silva Jardim, Araruama, Saquarema, Cachoeiras de Macacu, Guapimirim, Magé, Nova Friburgo e Teresópolis formam o Consórcio do Leste Metropolitano (CONLESTE). Esse consórcio foi criado com intuito de gerir os impactos provocados pelo COMPERJ nesses municípios de forma cooperativa (SANDÁLIA, 2018).

O distrito de Itaboraí é onde a urbanização se encontra mais acentuada, principalmente ao longo da avenida 22 de Maio, única via arterial do município. Sua importância também se dá devido a ser a principal rota de transporte dos moradores e de mercadorias das áreas centrais para as cidades vizinhas. As demais vias que formam a rede viária do município são: a RJ – 116, a RJ – 114, a BR – 101, a BR – 493 e a RJ – 104 (Figura 3).

Figura 3: Principais vias do município de Itaboraí – RJ.



Fonte: Representação feita pelo autor.

Os dados do IBGE (2022) sobre a população do município mostram justamente a concentração dos moradores nos bairros próximos à avenida 22 de Maio. O bairro da Ampliação é um dos principais bairros residenciais do município, localizado próximo à área central e com fácil acesso para a BR-101. Por sua vez, o Bairro da Esperança pode ter a sua concentração populacional relacionada a sua proximidade com uma das entradas do COMPERJ.

A distribuição da população por distritos, feita a partir dos dados do Censo de 2010, apontaram a maior ocupação do primeiro distrito (Itaboraí) com quase metade da população total, já Manilha aparece como o segundo distrito mais ocupado. Ao longo da última década, o distrito de Itaboraí foi um dos que refletiram as mudanças no município, devido ao aumento da verticalização, residências particulares e empreendimentos. Por sua vez, o distrito de Manilha é um lugar de passagem, mais especificamente o bairro de Manilha, para as pessoas que vêm de cidades como Niterói, São Gonçalo e Rio Janeiro em direção às cidades da baixada litorânea.


4.3. Complexo petroquímico do Estado do Rio de Janeiro (COMPERJ)

Inicialmente concebido como um dos maiores projetos petroquímicos globais, o Complexo Petroquímico do Rio de Janeiro (COMPERJ) tinha como objetivo central a fabricação de produtos químicos e petroquímicos, bem como o suporte à indústria de petróleo e gás. Contudo, ao longo do tempo, o COMPERJ deparou-se com uma série de desafios, que culminaram em uma notável diminuição na capacidade de produção originalmente planejada para o empreendimento.

Segundo Vieira, Borges e Virginio (2023) os investimentos direcionados para a indústria do petróleo nos últimos anos têm representado uma oportunidade para reverter o esvaziamento econômico que afetou anteriormente o estado do Rio de Janeiro. Esses investimentos desempenharam um papel fundamental ao estimular o crescimento da indústria do petróleo e desencadear novos padrões de ocupação e uso do território (VIEIRA, BORGES e VIRGINIO, 2023).

Em 2006, a Petrobras anunciou um investimento de cerca de 15 bilhões de reais para a construção do Complexo Petroquímico do Rio de Janeiro (COMPERJ) com cerca de 45 milhões de m² (Figura 4) para o município de Itaboraí - RJ, um dos maiores projetos petroquímicos da época. O COMPERJ, considerado o maior empreendimento individual da história da Petrobras, resultou de um investimento estimado em R\$15 bilhões. Consta no RIMA do COMPERJ que seu principal objetivo era o refinamento de 150 mil barris diários de petróleo pesado da Bacia de Campos, mais especificamente do Campo de Marlim.

Figura 4: Localização do COMPERJ.



Fonte: Representação feita pelo autor.

De acordo com o RIMA do COMPERJ, ele representava a reentrada da Petrobras no setor petroquímico e era considerado uma alternativa altamente competitiva para impulsionar o crescimento da indústria petroquímica brasileira. A perspectiva era a de economizar mais de 4 bilhões de reais por ano para o país, principalmente devido à redução nas importações de matérias-primas petroquímicas e ao aumento das exportações de petróleo pesado. Esperava-se que o projeto impulsionasse a economia regional, proporcionando a criação de cerca de 200 mil empregos diretos e indiretos.

Apesar do Brasil ser amplamente reconhecido pela sua diversidade, a matriz energética brasileira é majoritariamente por fontes não renováveis, essa disparidade suscita preocupações em relação à sustentabilidade desse modelo de desenvolvimento (VIEIRA, BORGES e VIRGINIO, 2023).

Segundo Vieira, Borges e Virginio (2023) a exploração do petróleo demanda investimentos significativos, mas o retorno em termos de mão de obra é bastante limitado em comparação com outros recursos energéticos. Além disso, os autores ressaltam os impactos consideráveis no meio ambiente decorrentes da extração de petróleo, que resultam em danos substanciais nos ecossistemas localizados em áreas próximas a extração ou no transporte dos produtos e equipamentos

O período de instalação do COMPERJ foi caracterizado por esforços voltados para a criação de mecanismos que facilitassem a organização dos municípios

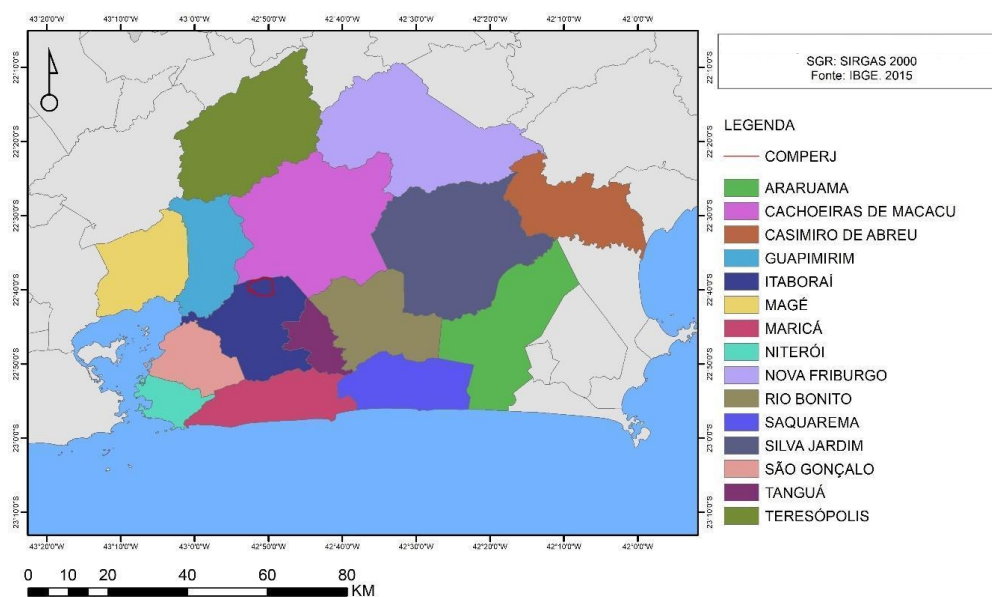
diretamente impactados pelo empreendimento. Uma das principais preocupações logísticas estava relacionada à mobilidade de equipamentos, pessoas e produtos para outras regiões do estado.

Atualmente, com o objetivo de dar continuidade às obras iniciadas, a Petrobras optou por transformar o COMPERJ em PoloGasLub Itaboraí. Este polo teria como principal finalidade a produção de lubrificantes e combustíveis, em parceria com a Refinaria de Duque de Caxias (REDUC). Há também a busca por novos investidores para a criação de uma termelétrica, a energia gerada por essa termelétrica seria produzida a partir do processamento do gás do pré-sal nas instalações do Polo. (PETROBRÁS, 2023).

Segundo Costa (2013) o anúncio da instalação do COMPERJ fez com que as onze cidades da região optassem por formar um consórcio intermunicipal. O CONLESTE (Consórcio do Leste Metropolitano) foi criado com o objetivo de supervisionar projetos nas esferas sociais, ambientais e econômicas, com a finalidade de fomentar um desenvolvimento local por meio da coordenação no planejamento e execução de ações. (COSTA, 2013)

Os municípios que compõem o consórcio atualmente são: Itaboraí, Niterói, São Gonçalo, Cachoeiras de Macacu, Casimiro de Abreu, Guapimirim, Magé, Maricá, Saquarema, Araruama, Rio Bonito, Silva Jardim, Tanguá, Teresópolis e Nova Friburgo (Figura 5).

Figura 5: Consórcio do Leste Metropolitano



Fonte: Representação feita pelo autor

O consórcio teve início com a Prefeitura de Niterói, que aprovou a Lei Ordinária nº 2423 em 05/01/2007, estabelecendo a colaboração entre este município e os outros mencionados na mesma lei. As principais finalidades do consórcio descritas pela lei são:

- “a) gestão associada de serviços públicos;
- b) promoção de apoio e fomento do intercâmbio de experiências bem sucedidas e de informações entre os entes consorciados;
- c) realização de planejamento, adoção e execução de ações, programas e projetos destinados a promover e acelerar o desenvolvimento regional e local;
- d) promoção do desenvolvimento econômico e social e combate à pobreza;
- e) realização de um planejamento estratégico, no sentido de equacionar e buscar soluções para problemática social, econômica, ambiental, físico-territorial, de circulação e de transporte, no território dos Municípios consorciados;
- f) promoção da ética, da paz, da cidadania, dos direitos humanos da democracia e de outros valores universais;
- g) realização de estudos e pesquisas, desenvolvimento de tecnologias alternativas, produção e divulgação de informações e conhecimentos técnicos e científicos;
- h) promoção da melhoria da qualidade de vida da população residente nos Municípios formadores do Consórcio Intermunicipal da Região Leste Fluminense.” -Lei Ordinária nº 2423

De acordo com Araújo e Rufino (2014) a região do consórcio se destaca por apresentar um notável déficit em termos sociais e urbanos, caracterizado por carências significativas no que diz respeito ao acesso à infraestrutura urbana, o que ocasiona a pressão nos recursos ambientais ameaçados pela especulação imobiliária e expansão desordenada das cidades.

O arco metropolitano foi uma das grandes obras que surgiram diante da necessidade de facilitar o transporte de mercadorias e de pessoas entre Itaboraí e os demais municípios do Estado. De acordo com Filho (2013), a construção do Arco Rodoviário (Figura 6) já era uma necessidade antiga no estado do Rio de Janeiro, com o objetivo de integrar os municípios periféricos fluminenses. Em 2007, foi realizada uma licitação para a construção do Arco Metropolitano, que ligará o Complexo Petroquímico do Rio de Janeiro (COMPERJ) ao Porto de Itaguaí,

utilizando as rodovias BR-101/norte e BR-101/sul como parte desse importante projeto de infraestrutura rodoviária.

Figura 6: Arco Metropolitano do Rio de Janeiro



Fonte: Silva, Lira, Pimentel e Cruz (2023).

O Arco Metropolitano do Estado do Rio de Janeiro (AMRJ) é segmentado em quatro partes distintas, conforme descrito no Relatório de Impactos Ambientais (RIMA). A tabela 2 abaixo mostra a qual trecho rodoviário o segmento pertence.

Tabela 1: Trechos do Arco Metropolitano do Rio de Janeiro

Segmento A	<ul style="list-style-type: none"> • Trecho da Rodovia BR-493/RJ • Localizada entre a BR-101, em Manilha (Itaboraí), e o entroncamento com a BR-116, em Santa Guilhermina (Magé)
Segmento B	<ul style="list-style-type: none"> • Trecho da Rodovia BR-101 (Rio – Santos) • Localizada entre Itacuruçá e a Avenida Brasil. Com duplicação da pista.
Segmento C	<ul style="list-style-type: none"> • RJ-109 • Localizado entre as entre as rodovias BR-040 (Rio – Juiz de Fora) e a BR-101/SUL.
Segmento D	<ul style="list-style-type: none"> • Trecho da BR-116/NORTE • Localizada entre a BR-493/RJ em Santa Guilhermina e a BR040/RJ em Saracuruna

Fonte: Tabela feita pelo autor

O Arco Metropolitano do Estado do Rio de Janeiro (AMRJ), segundo Filho (2013), desempenha três funções fundamentais: conectar o porto de Itaguaí à malha rodoviária; estabelecer ligações entre os cinco principais eixos rodoviários sem a necessidade de utilizar a Avenida Brasil e a ponte Rio Niterói; e melhorar significativamente a acessibilidade aos municípios situados nas proximidades do próprio arco metropolitano.

Conforme a "Avaliação dos Impactos Logísticos e Socioeconômicos da Implantação do Arco Metropolitano do Rio de Janeiro" realizada pela Firjan em 2008, os benefícios do AMRJ estão, em grande parte, relacionados ao aumento do fluxo de mercadorias que circulam entre as cidades. Os municípios nas imediações do arco metropolitano desfrutarão de custos de transporte mais baixos, além de haver um incremento substancial na circulação de mercadorias tanto entre os municípios do estado do Rio de Janeiro quanto entre este estado e outras unidades federativas do Brasil

No entanto, segundo Tinoco (2019) a região do arco metropolitano atualmente enfrenta um elevado índice de ocupações irregulares, consequência direta da crise urbana e político-econômica nacional e estadual. Isso ocorreu devido a vários dos potenciais investimentos e investidores não conseguirem projetar cenários econômicos favoráveis para o projeto do Arco Metropolitano (TINOCO, 2009).

5. AVALIAÇÃO DA EXATIDÃO TEMÁTICA E ADEQUAÇÃO DE ESCALA DOS DADOS DO MAPIOMAS PARA O MUNICÍPIO DE ITABORAÍ-RJ.

5.1. Introdução

O Cobertura e Uso da Terra é um importante elemento na gestão do território, pois ajuda na compreensão e monitoramento dos elementos naturais e antrópicos presentes na paisagem. Por meio dos mapeamentos de Uso e Cobertura da Terra é possível chegar a dados fundamentais na preservação da natureza e na organização territorial, por ser possível gerar indicadores que mostram como as classes de uso e cobertura estão atuando no espaço geográfico (Silva et. al, 2021).

A evolução das técnicas e metodologias associadas ao estudo da superfície terrestre por meio de processamento em nuvem e a possibilidade de se verificar a eficácia de uma delas de forma prática e conjunta, junto ao surgimento de imagens com cada vez mais detalhamento e menor tempo de revisita, comenta (Masek et. al (2006), fazem com que surjam diferentes formas de compreender o impacto da ação humana na paisagem.

O processamento em nuvem e as plataformas de análises espaciais provocaram enormes mudanças na forma como são produzidas esse tipo de classificação e seus produtos secundários. O grande volume de dados produzidos diariamente possibilita realizar análises por diferentes perspectivas e vertentes, que por sua vez, geram resultados distintos. A própria plataforma de GEE fez com que a aplicação dos algoritmos de classificação em pesquisas de Cobertura e Uso da Terra se tornasse algo mais acessível e aberto para que as novas ferramentas possam ser testadas, a fim de identificar aquelas que mais se adequem à realidade encontrada pelos pesquisadores. Carvalho, Filho e Santos (2021) puderam comprovar em sua pesquisa a efetividade dos diferentes algoritmos de classificação disponíveis para seu objeto de análise, os quais conseguiram mostrar por meio de análises estatísticas a eficácia de algoritmos baseados em árvores de atributos em suas análises.

O Projeto MapBiomass é responsável por importantes projetos e análises da superfície terrestre e das ações antrópicas no meio ambiente, utilizando abordagens cada vez mais inovadoras e que anualmente se atualizam para produzir dados cada vez mais detalhados. A adoção dessas novas metodologias contribui para a

produção de estudos que contribuem para a gestão do território brasileiro em diferentes escalas de tempo e espaço. No entanto, apesar do reconhecimento do MapBiomias no meio científico, é indispensável conhecer as limitações dos produtos gerados por essas novas tecnologias.

O presente capítulo teve como objetivo determinar se o produto desenvolvido pelo MapBiomias poderia servir como fundamento para análises no contexto do município de Itaboraí, no estado do Rio de Janeiro.

A avaliação da exatidão temática do Mapa de Cobertura e Uso da Terra (1:100.000) para o ano de 2015 da iniciativa MapBiomias proposta para esse trabalho, foi realizada por meio da comparação de cada pixel com a classificação do Projeto de Mapeamento da Cobertura da Terra e de Detecção de Mudanças na Cobertura Florestal do Estado do Rio de Janeiro (1:25.000), produzido pela SEA/UFRJ do mesmo ano. Para o processo foi feita a reamostragem do mapa do SEA/UFRJ, a fim de atender a escala 1:100.000 do MapBiomias.

5.2. Materiais e métodos

A verificação da exatidão temática e adequação da escala do recorte que contempla o município de Itaboraí - RJ da classificação de Cobertura e Uso da Terra do MapBiomias para o ano de 2015 foi feita pixel a pixel junto ao Mapa de Uso e Cobertura da Terra da SEA/UFRJ do mesmo ano, as escalas são respectivamente 1:100.000 e 1:25.000.

A definição da legenda temática nas classificações de Cobertura e Uso da terra deve ter seu detalhamento adequado à escala em que sua área de estudos será representada, buscando abranger áreas naturais e antrópicas da região representada (IBGE, 2013). Além disso, é preciso compreender e pensar a respeito de todos os elementos e agentes que impactam a área em questão de alguma forma, sejam eles resultantes das ações políticas, econômicas e sociais nas suas diferentes escalas de organização (IBGE, 2013).

O estudo presente no capítulo tem como o objetivo avaliar a exatidão temática e a escala espacial adotada pelo projeto MapBiomias no contexto do município de Itaboraí- RJ. Segundo o IBGE (2013) a identificação e caracterização das classes de Cobertura e Uso da Terra requerem procedimentos que garantam a

assertividade, podendo ser comparações, consultas bibliográficas e trabalhos de campo.

A definição das classes de Cobertura e Uso da Terra para esse trabalho comparativo foi realizada através comparação de padrões das imagens e revisões bibliográficas que apontavam as classes predominantes no município. Além disso, foi feita a adaptação da legenda temática de ambos os produtos, por meio da união das classes de Cobertura e Uso da Terra da Classificação do SEA/UFRJ e do MapBiomias, como é possível observar na figura 7.

Figura 7: Legenda Final.

SEA	MapBiomias	Legenda Final
Áreas Antrópicas Agropastoris (AAG) (21)	Pastagem (15) Mosaico de Agricultura e Pastagem (21)	Áreas Agropastoris
Áreas Naturais Florestais (ANF) (11) Silvicultura (31) Mangue (33)	Formação Florestal (3) Restinga Arborizada (beta) (49) Mangue (5)	Floresta
Áreas antrópicas Não Agropastoris (ANA) (22) Áreas Antrópicas não agropastoris Não Consolidadas (AGG_N_CONS) (210)	Área Urbana (24) mineração (30)	Área Construída
Água (41) Áreas Naturais Não Florestadas (NNF) (12)	Campo Alagado e Área Pantanosa (11) Apicum (32) Afloramento Rochoso (29) Outras áreas não vegetadas (25) Rio Lago e Oceano (33) Não observada (27)	Outros

Fonte: Representação feita pelo autor.

Nesse cenário, definiu-se que a Legenda Temática representaria as seguintes unidades de mapeamento: Áreas Agropastoris, Áreas Construídas, Floresta e Outros. A figura 8 apresenta a caracterização de cada uma das classes da legenda.

Figura 8: Caracterização da legenda criada para a comparação

Floresta	Áreas com algum tipo de cobertura vegetal	
Áreas Agropastoris	Áreas de pastagem ou Agricultura	
Áreas construídas	Áreas Urbanas ou de Mineração	
Outros	Áreas alagadas, Afloramentos rochosos, Água	

Fonte: Representação feita pelo autor

A escala é um elemento indispensável nos estudos geográficos, uma vez que permite estudar espacialmente os ambientes em que os fenômenos ocorrem na superfície terrestre e com diferentes níveis de detalhamento (Menezes e Neto, 1999). Sobre as diferentes formas de se visualizar os fenômenos, Menezes e Neto (1999) comentam que:


“A observação de fenômenos sob diferentes escalas pode causar significativas alterações na sua interpretação, gerando, portanto, questionamentos sobre o impacto da observação de um fenômeno, visualizado sobre mudanças de escala e possíveis alterações que possam ocorrer na visualização, na sua forma de representação e sobre o próprio

comportamento da escala com o fenômeno. “Pág. 2– Menezes e Neto, 1999.

Foi conduzida uma avaliação do método classificatório para examinar a precisão da escala do Mapa de Cobertura e Uso da Terra do Map Biomas para o ano de 2015, coleção 6, para o município de Itaboraí - RJ. O objetivo principal consistiu em identificar se a escala de análise está adequada quando aplicada para o município, levando em consideração a legenda temática estabelecida e a resolução espacial média dos satélites Landsat, com escala recomendada de 1:100.000 e pixels 30x30m.

Para isso, foi necessário realizar o redimensionamento dos pixels do mapeamento do SEA/UFRJ, por meio do ArcGIS 10.6, o qual foi reamostrado para atender a escala de 1:100.000, ou seja, os pixels foram transformados de 2x2m para 30x30m. Com isso, ambas as classificações passaram a apresentar pixels com as mesmas dimensões. A figura 9 apresenta parte da classificação do SEA/UFRJ antes e depois do redimensionamento.

Figura 9: Redimensionamento dos pixels de classificação do SEA de 2x2 para 30x30, respectivamente.



Fonte: Representação feita pelo autor.

A escala avaliada foi a de 1:100.000, juntamente com o tamanho de pixel de 30x30m, utilizando o critério do “vizinho mais próximo” para a generalização. Essas

medidas são importantes para igualar as características espaciais que formam os mapeamentos. A etapa seguinte consistiu em unir as duas classificações por meio da ferramenta “*combine*” no ArcGIS 10.6, a fim de realizar as comparações.

5.3. Resultados e Discussões

Por meio da matriz de confusão foi possível calcular os valores referentes a Acurácia Global, Acurácia do Usuário e Acurácia do produtor, os quais verificam a exatidão do mapeamento do MapBiomias para a área do município de Itaboraí – RJ.

A acurácia global refere-se à estimativa da taxa geral de acurácia dos classificadores, sendo encontrada através do (número de classificações corretas) / (número total de classificações) (MapBiomias, 2023).

A acurácia do produtor está relacionada ao erro de omissão, e sofre a influência dos pixels que a classificação deixou de incluir em cada classe. Ou seja, essa acurácia representa os pixels que foram atribuídos corretamente em suas classes pelos classificadores, pode ser calculada pela fórmula: (número de acertos) / (número de acertos + número de erros) (MapBiomias, 2023).

A Acurácia do usuário representa os pixels que no mapeamento foram corretamente classificados para cada classe, sofrendo a influência do erro de comissão, que está associado a inclusão de pixels indevidos a determinada classe. Para calcular a acurácia do usuário é necessário: (número de acertos) / (número total e amostras coletados para a verificação da classe) (MapBiomias, 2023)

A classificação do SEA foi usada como referência na comparação da matriz de confusão, como é possível ver na tabela 2. A comparação foi feita com os valores de cada pixel presentes em ambas as classificações, devidamente ajustados para a mesma escala.


Tabela 2: Matriz de Confusão SEA x MapBiomias.

		SEA				Total	acurácia do produtor
		Floresta	Áreas Agropastoris	Área Construída	Outros		
MapBiomias	Floresta	53206	3241	391	449	57287	92,88%
	Áreas Agropastoris	32132	245868	30542	549	309091	79,55%
	Área Construída	3097	10720	86740	13	100570	86,25%
	Outros	1608	4777	4826	1573	12784	12,30%
	Total	90043	264606	122499	2584	479732	
Acurácia do usuário		59,09%	92,92%	70,81%	60,87%		
Exatidão Global		0,8075071					
Aceitação Relativa - PO		0,8075071					
Taxa Hipotética de Aceitação - PE		0,4314642					
Kappa		0,6614234					

Fonte: Representação feita pelo autor.

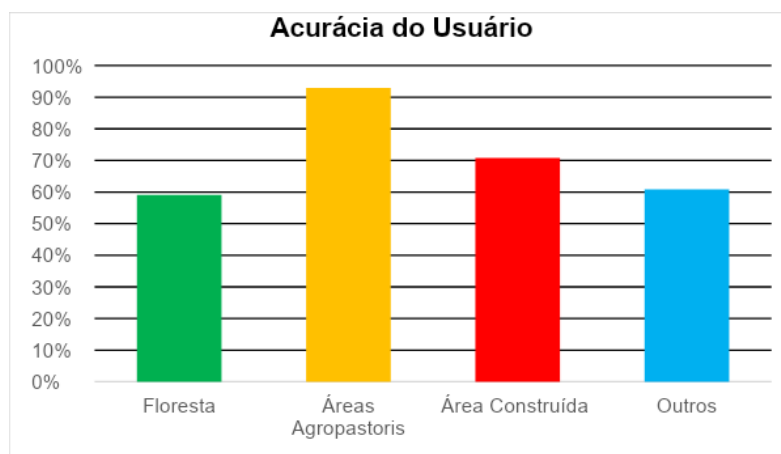
Por meio da matriz de confusão é possível constatar que o produto de MapBiomias apresentou para o município uma Exatidão global de 80%, quando comparado ao SEA. Por sua vez, o índice Kappa de 66% foi considerado como “Muito Bom” segundo Fonseca (2000). Os gráficos (gráfico 1 e 2) abaixo mostram os dados de acurácia do produtor e acurácia do usuário para cada uma das classes consideradas para a legenda final, bem como as classes que mais houveram confusões.

Gráfico 1: Acurácia do Produtor.



Fonte: Representação feita pelo autor

Gráfico 2: Acurácia do Usuário

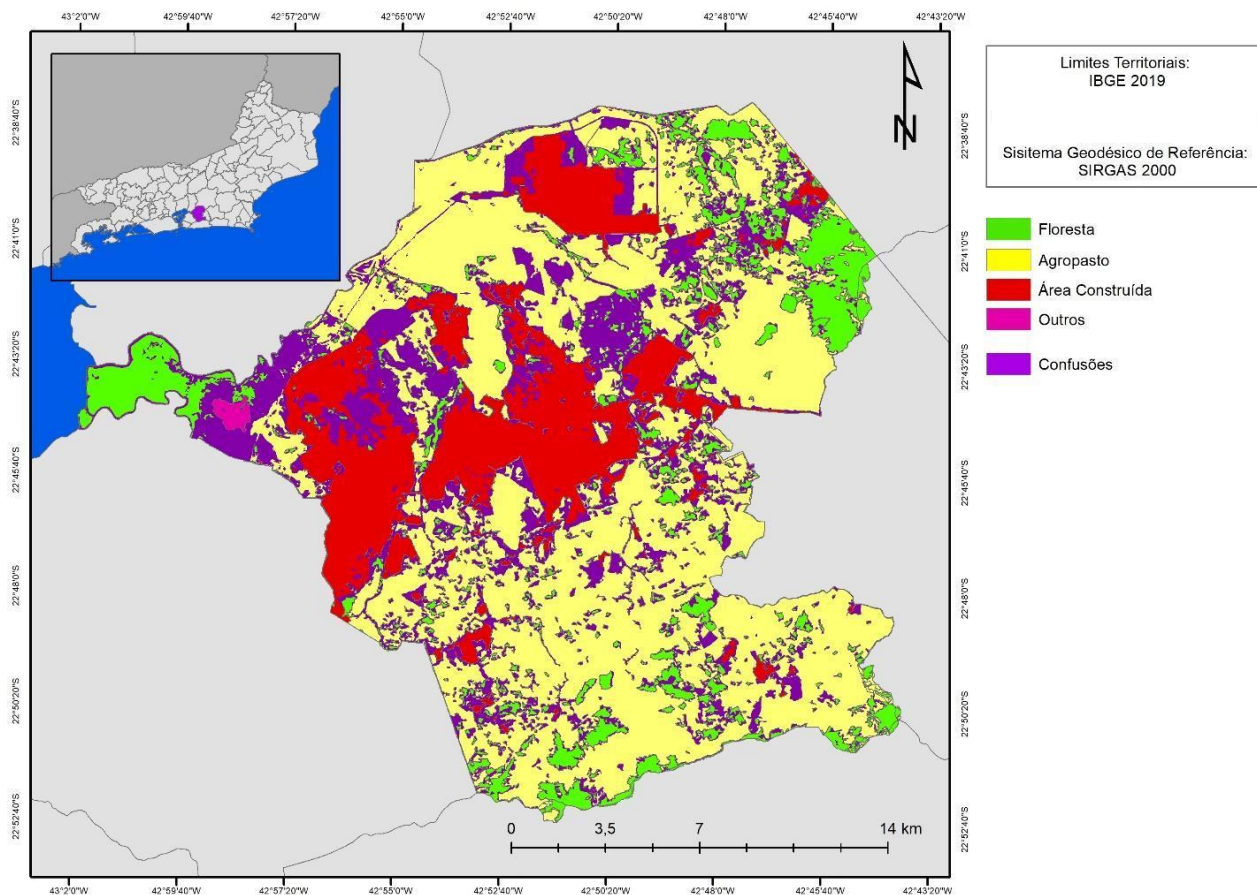


Fonte: Representação feita pelo autor.

As classes que obtiveram a maior acurácia do produtor na classificação foram respectivamente o Floresta (92,88%), Área Construída (86,25%), Áreas Agropastoris (79,55%) e Outros (12,30%). A Floresta e Outros aparecem como as classes com os maiores erros de comissão (diferença dos valores para o 100%), com a acurácia do usuário de 59,09% e 60,87% respectivamente. Acredita-se que o resultado ocorre devido a facilidade que a classificação do MapBiomas possui em identificar áreas com algum tipo de cobertura vegetal, por outro lado áreas, com urbanização recente, solo exposto e pouco vegetadas podem explicar a menor exatidão da classificação nas demais classes.


As confusões entre as classes aparecem em grande maioria associadas às classes de Área Construída com Agropasto, com mais de 51,95%, o Agropasto com Floresta aparece logo em seguida com 37,54% de todas as confusões encontradas na combinação das classificações, o mapa a seguir mostra onde estão localizadas as principais confusões associadas a classificação. É possível observar na figura 10 a localização das diferenças entre as classificações na cor roxa e no gráfico 3 o percentual das principais confusões.

Figura 10: Localização das principais diferenças entre as classificações representadas pela cor roxa.



Fonte: Representação feita pelo autor.

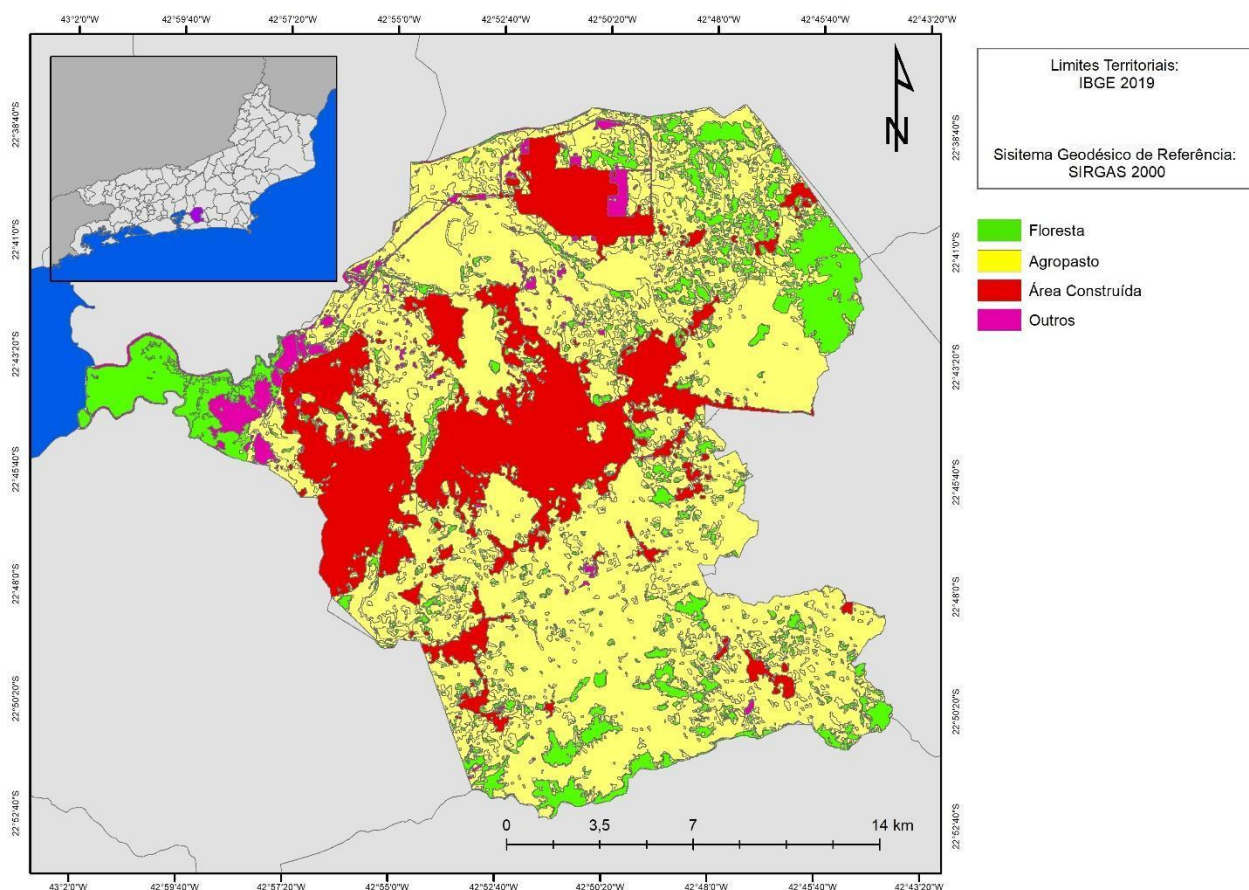
Gráfico 3: Principais confusões entre classes encontradas.



Fonte: Representação feita pelo autor.

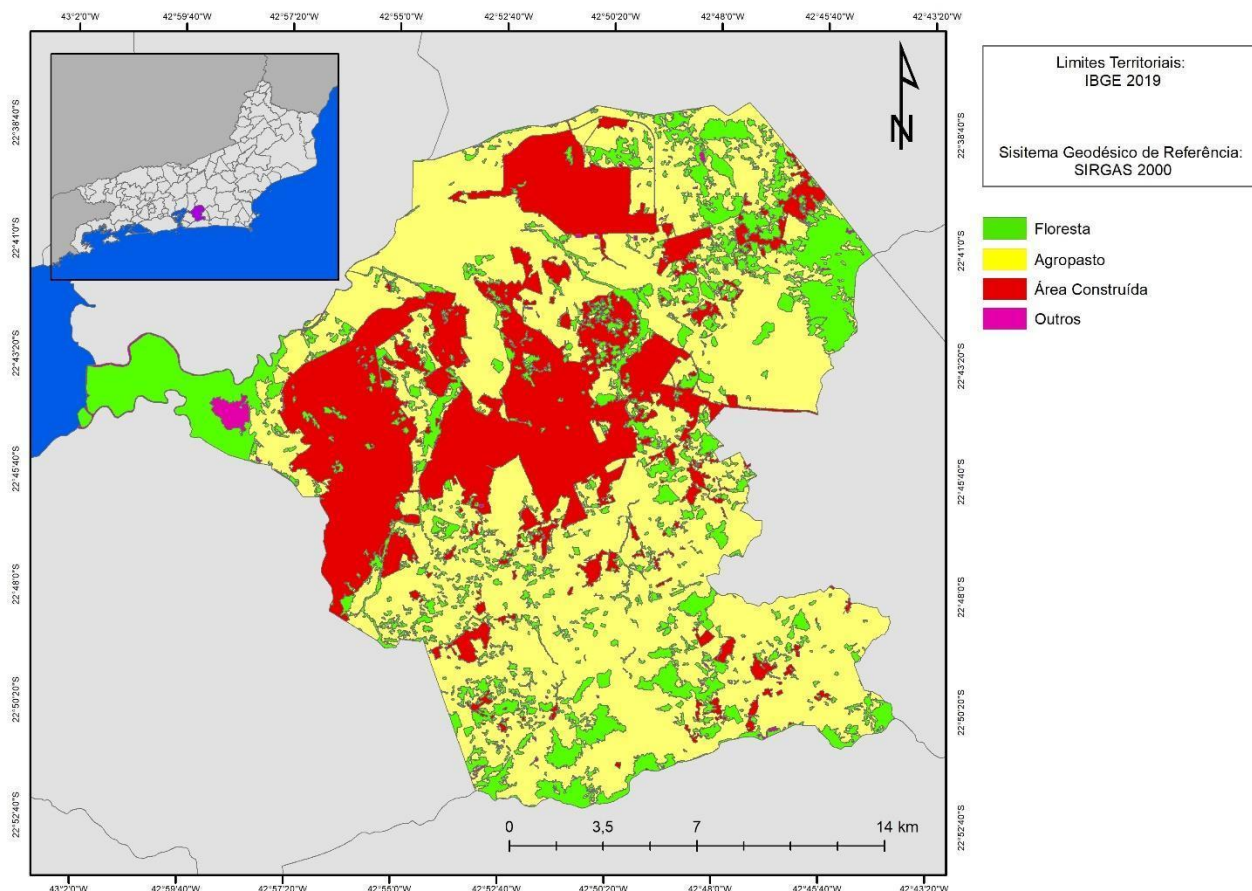
As grandes confusões aparecem muito concentradas em áreas que tiveram sua infraestrutura urbana densificada para comportar nas novas empresas e moradores que se estabeleceram próximas às vias de ligação para o COMPERJ. As figuras 11 e 12 apresentam os mapeamentos do MapBiomás e SEA (redimensionado) para o ano de 2015 com o recorte do município de Itaboraí – RJ, sua legenda está alterada para a apresentada na figura 7 para evidenciar o resultado das diferentes metodologias e materiais utilizados em cada um dos produtos.

Figura 11: Classificação de Cobertura e Uso da Terra do MapBiomás para 2015.



Fonte: Representação feita pelo autor.

Figura 12: Classificação de Cobertura e Uso da Terra do SEA para 2015 redimensionado para 30x30.



Fonte: Representação feita pelo autor.

A escolha da classificação do SEA para essa etapa de verificação se deu devido aos rigorosos testes de validação que foram submetidos à classificação. Devido a isso, o resultado dessa análise esteve menos sujeita a erros e generalização de um mapeamento que não atendesse as exigências esperadas para uma classificação temática.

É válido ressaltar a ausência de seleção de amostras como vantagem de uma análise cruzada para esse tipo de estudo, uma vez que considera todos os pixels presentes nas imagens como elementos para a verificação da precisão. Contudo, a generalização geométrica da classificação e das classes, por meio da legenda, devem acontecer de forma a evitar erros durante as comparações e ausência de similaridade entre as classes comparadas em cada uma das classificações.

5.4. Conclusão

O atual capítulo pretendeu identificar se o produto gerado pelo MapBiomias poderia ser utilizado como base para estudos do município de Itaboraí - RJ, através da verificação da exatidão temática, adequação da escala espacial junto ao mapa do SEA. A análise foi feita com a classificação de Cobertura e Uso da Terra para ano de 2015 do MapBiomias, referente a coleção 6 e adquirida através da plataforma do GEE, e o Mapa de Cobertura e Uso da terra do SEA, também referente ao ano de 2015.

O uso e cobertura da terra do município foi influenciado por diferentes dinâmicas ao longo do período entre os de 2006 e 2020. Os diferentes momentos que o município viveu no decorrer desses anos são expressos na paisagem, que passou a ser modificada significativamente à medida que as especulações e notícias se espalhavam. A matriz do município passou a ter sua extensão constantemente modificada, à medida que as novas áreas urbanas iam se estabelecendo e áreas vegetadas começavam a serem desmatadas para atender a necessidade de uma então cidade em expansão.

O tratamento das imagens antes da análise comparativa foi essencial para evitar erros que comprometessem o resultado final. Além disso, a criação de uma nova legenda que compreendesse os dois mapeamentos foi determinante para a identificação dos elementos que poderiam ser comparados e analisados.

O projeto do MapBiomias continuamente atualiza as suas bases cartográficas, adicionando novas classificações referentes aos anos recentes e atualizando as bases antigas para que os produtos estejam cada vez mais precisos com as metodologias e tecnologias vigentes. Atualmente a base conta com classificações que vão desde 1985 a 2022, podendo ser encontradas no website do projeto, junto a trabalhos que contribuem para enriquecer ainda mais os dados geoespaciais referentes ao território brasileiro. Para o município a classificação apresentou 80% de exatidão global e 66% de Kappa, o que indica que o mapeamento não atende a um nível aceitável para um estudo específico desse recorte.

Ambos os mapeamentos foram elaborados em escalas de detalhamento distintas, com isso, houve maior cautela para se fazer a comparação de forma que não houvesse fatores que comprometessem o resultado obtido. As classificações anuais de Cobertura e Uso da Terra produzidas pelo MapBiomias possuem enormes

vantagens e fornecem subsídios a trabalhos secundários, apesar de não apresentarem uma enorme exatidão para áreas bem específicas, como foi apresentado nesse estudo, através da análise pixel a pixel. A classe da vegetação foi a que apresentou o melhor resultado de exatidão, a Floresta, por outro lado as maiores confusões aparecem ligadas a matriz do município, Áreas Agropastoris, o qual esteve presente nas duas maiores confusões encontradas entre classes no município com mais de 80%.

Este capítulo, por fim, buscou compreender a aplicabilidade de uma classificação escala 1:100.000 já consolidada no meio acadêmico para o recorte de um município. Adoção do sensoriamento remoto no estudo nos estudos temporais, bem como as novas metodologias adotadas, contribuem para encontrar resultados que justifiquem as decisões de órgãos ambientais e de planejamento urbano, visando o aumento da qualidade de vida das pessoas e preservação do meio ambiente. Além disso, o presente trabalho busca contribuir para que outros pesquisadores possam estudar o espaço em diferentes escalas e pontos de vista.

6. ANÁLISE DAS MUDANÇAS DA COBERTURA E USO DA TERRA DO MUNICÍPIO DE ITABORAÍ ATRÁÉS DE CLASSIFICAÇÃO MULTITEMPORAL

6.1. Introdução

O uso de imagens de sensoriamento remoto na detecção das mudanças da superfície terrestre é algo recorrente nos estudos espaciais, especialmente com a democratização das imagens de satélites orbitais e com o surgimento de novas plataformas de processamento de dados. As análises de séries temporais de imagens de sensoriamento remoto possibilitam, por meio de ferramentas de visualização e interpretação, o monitoramento da superfície terrestre e a avaliação da evolução das mudanças de uso e cobertura do solo ao longo do tempo (DA COSTA, 2015). Dada sua relevância para o acompanhamento das transformações na superfície terrestre, visando a gestão e conservação de recursos naturais e um planejamento socioambiental eficaz, as imagens originárias de sensores remotos são a principal fonte informativa para rastrear modificações no uso e cobertura do solo (CRUZ, 2021).

Devido ao progresso tecnológico, a quantidade de informações geradas pelo sensoriamento remoto e pelas inovações tecnológicas aumentou consideravelmente, resultando em um grande volume de dados. Isso, por sua vez, impulsionou a busca por novas abordagens para transformar esses dados em informações significativas (NEVES, 2017). Nesse contexto, houve também um avanço na capacidade de processamento de dados através da automação de processos, os bancos de dados e a mineração surgiram com mecanismos estatísticos para tratar o volume de dados (NEVES, 2017).

O processo de mineração de dados busca revelar padrões e informações novas, e para isso, é necessário construir um modelo que englobe a identificação, treinamento, aprendizado e reconhecimento dos padrões fornecidos pelo algoritmo (CRUZ, 2021). Apesar de todas as vantagens que os novos algoritmos têm trazido para a descoberta de novas técnicas de geração de informações, ainda existem desafios em relação à maneira de extrair esse conhecimento (BARANAUSKAS, 2001).

Neste capítulo, objetivou-se desenvolver classificações de Cobertura e Uso da terra para o município de Itaboraí – RJ, a partir do algoritmo de aprendizado de

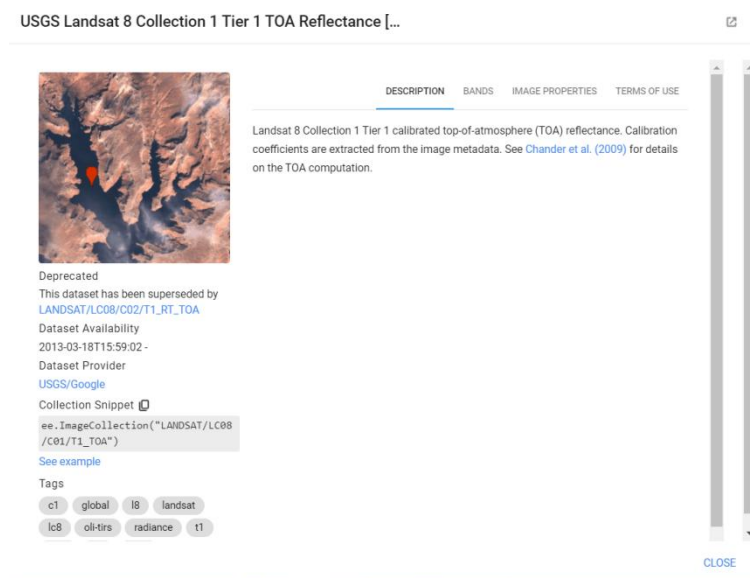
máquina Random Forest. Por meio das amostras de treinamento, o algoritmo constrói um classificador que pode determinar corretamente a classe de outras amostras ainda não definidas (BARANAUSKAS, 2001).

Após alguns testes para a identificação dos parâmetros ideais, iniciou-se a produção da classificação de Cobertura e Uso da Terra, por meio de imagens dos anos de 2005, 2007, 2011 e 2020 dos satélites Landsat-5 e Landsat-8, disponíveis do catálogo da plataforma do Google Earth Engine. As classes definidas como parâmetros para o algoritmo foram: Mangue, Água, Solo Exposto, Agropasto, Floresta, Área Construída e Outros.

6.2. Materiais e métodos

Foram utilizadas quatro imagens de satélites para análise da cobertura e uso da terra, no desenvolvimento deste capítulo. Três imagens foram adquiridas do satélite Landsat-5 (TM) para os anos de 2005, 2007 e 2011. Para o ano de 2020 foram uma do satélite Landsat-8 (OLI). Todas as imagens foram obtidas através do catálogo de imagens disponível na plataforma do GEE (Figura 13), eliminando a necessidade de pré-processamento delas.

Figura 13: Catálogo do GEE.



USGS Landsat 8 Collection 1 Tier 1 TOA Reflectance [...]

DESCRIPTION BANDS IMAGE PROPERTIES TERMS OF USE

Landsat 8 Collection 1 Tier 1 calibrated top-of-atmosphere (TOA) reflectance. Calibration coefficients are extracted from the image metadata. See [Chander et al. \(2009\)](#) for details on the TOA computation.

Deprecated
This dataset has been superseded by [LANDSAT/LC08/C02/T1_RT_TOA](#)

Dataset Availability
2013-03-18T15:59:02-

Dataset Provider
[USGS/Google](#)

Collection Snippet

```
ee.ImageCollection("LANDSAT/LC08/C01/T1_TOA")
```

[See example](#)

Tags

c1 global l8 landsat
lc8 oli-tirs radiance t1

CLOSE

Fonte: Google Earth Engine

O período de análise das imagens foi definido com base em dados climáticos provenientes dos sensores CHIRPS e TIRS. Esses dados indicaram que os períodos de 10/10/2005 a 10/11/2005, 10/10/2007 a 10/11/2007, 10/10/2011 a 10/11/2011 e 10/10/2020 a 10/11/2020 eram os mais adequados para a análise da cobertura e uso da terra, por apresentarem imagens com menor presença de nuvens.

As avaliações estatísticas e qualitativas foram realizadas no software ArcGIS 10.6. Já a criação do diagrama de Sankey foi feita utilizando a plataforma SankeyMATIC (<https://sankeymatic.com/>). Essas ferramentas foram utilizadas para a análise e visualização dos resultados obtidos.

Os anos de 2005, 2007 e 2011 foram classificados com imagens SR (Surface Reflectance) e, devido a disponibilidade de imagens para a região, o ano de 2020 foi classificado por uma imagem TOA (Top-of-Atmosphere), ou seja, todas as imagens já foram adquiridas com correções atmosféricas. Segundo Masek et.al (2006) os estudos sobre as mudanças da cobertura da terra vêm buscando cada vez mais formas de compreender o impacto das atividades humanas nos ecossistemas terrestres, por isso, mecanismos que agilizem e facilitem a obtenção de dados da superfície terrestre estão cada vez mais indispensáveis no sensoriamento remoto de alta resolução. A correção atmosférica, por sua vez, funciona como uma forma de ajustar a absorção e reflectância dos componentes atmosféricos, a fim de gerar uma imagem próxima ao ideal da refletância da superfície terrestre (MASEK et.al., 2006).

A Tabela 3 apresenta as algumas das características das imagens e bandas utilizadas nas etapas do algoritmo no Code Editor do GEE.

Tabela 3: Características das imagens e da classificação.

Área do Estudo	Itaboraí – RJ
Data das Imagens	2006: 10/10/2005 a 11/10/2006 2007: 10/10/2007 a 10/11/2007 2011:10/10/2011 a 10/11/2011 2020: 10/10/2020 a 10/11/2020

Bandas Espectrais	Landsat 5 (TM)– 5: 1, 2 ,3, 4, 5, 6 e 7 Landsat 8 (TOA) – 8: 1, 2 ,3, 4, 5, 6, 7, 10 e 11
Índices Espectrais	NDVI, NDBI e NDWI
Classes de Uso e Cobertura	Mangue, Água, Floresta, Solo Exposto, Agropasto, Área Construída e Outros.
Árvores de Decisão	2000

Fonte: Representação feita pelo autor.

Foi realizado o processo de redução da presença de nuvens na imagem por meio de algoritmos disponíveis no “DOC” do *Google Earth Engine* e, desta forma, dentro do período estipulado para cada ano não foram selecionadas imagens com mais de 20% de nuvens. A Figura 14 mostra os filtros de nuvem aplicados na imagem Landsat- 8 (2020) e Landsat-5 (2006, 2007 e 2011), respectivamente.

Figura 14: Algoritmos de filtragem de nuvem para as imagens Landsat-8 e Landsat-5, respectivamente.

```

1 var landsat = ee.ImageCollection("LANDSAT/LC08/C01/T1_TOA")
2 .filterDate("2020-10-10","2020-10-11")
3 .filterBounds(itaborai)
4 .filter(ee.Filter.lte("CLOUD_COVER_LAND",20));
5
6 print(landsat);
7
8 //////////////////////////////////////////////////filtro de nuvens////////////////////////////////////
9
10 // Function to mask clouds using the quality band of Landsat 8.
11 var maskL8 = function(image) {
12   var qa = image.select("BQA");
13   // Check that the cloud bit is off.
14   // See https://www.usgs.gov/land-resources/nli/landsat/landsat-collection-1-level-1-quality-assessment-band
15   var mask = qa.bitwiseAnd(1 << 4).eq(0);
16   return image.updateMask(mask);
17 }
18
19 // Map the function over one year of Landsat 8 TOA data and take the median.
20 var composite = ee.ImageCollection("LANDSAT/LC08/C01/T1_TOA")
21   .filterDate("2020-10-10","2020-10-11")
22   .map(maskL8)
23   .median();
24
25 var landsat_sn = landsat.map(maskL8);
26

```

```

1 var landsat = ee.ImageCollection("LANDSAT/LC08/C01/T1_TOA")
2 .filterDate("2020-10-10","2020-10-11")
3 .filterBounds(itaborai)
4 .filter(ee.Filter.lte("CLOUD_COVER_LAND",20));
5
6 print(landsat);
7
8 //////////////////////////////////////////////////filtro de nuvens////////////////////////////////////
9
10 // Function to mask clouds using the quality band of Landsat 8.
11 var maskL8 = function(image) {
12   var qa = image.select("BQA");
13   // Check that the cloud bit is off.
14   // See https://www.usgs.gov/land-resources/nli/landsat/landsat-collection-1-level-1-quality-assessment-band
15   var mask = qa.bitwiseAnd(1 << 4).eq(0);
16   return image.updateMask(mask);
17 }
18
19 // Map the function over one year of Landsat 8 TOA data and take the median.
20 var composite = ee.ImageCollection("LANDSAT/LC08/C01/T1_TOA")
21   .filterDate("2020-10-10","2020-10-11")
22   .map(maskL8)
23   .median();
24
25 var landsat_sn = landsat.map(maskL8);
26

```


Fonte: Google Earth Engine.

Como visto no capítulo anterior, a definição das classes que compõem um mapeamento de Cobertura da Terra não é trivial e envolve uma série de estudos sobre as características físicas, sociais, econômicas e históricas da região. A figura

15 representa a chave de classificação, que consiste na apresentação das classes definidas para todas as classificações e a localização onde são mais representativas no município de Itaboraí.

Figura 15: Classes de Cobertura e Uso da Terra

MANGUE	Classe caracterizada pela vegetação de mangue.	
ÁGUA	Presença de corpos hídricos.	
FLORESTA	Área com algum tipo de cobertura florestal.	
SOLO EXPOSTO	Solos destinados à construção civil ou extração de minerais.	
AGROPASTO	Área destinada para cultivo ou pastagem.	
ÁREAS CONSTRUÍDAS	Presença de construções.	

OUTROS	Outras classes com menor representatividade.	
---------------	---	--

Fonte: Representação feita pelo autor, Petrobrás (2016), ICMBIO.

Em seguida, foram selecionados polígonos correspondentes a cada uma das classes definidas através da Plataforma do GEE. As amostras foram diferentes para cada um dos anos, a quantidade de amostras para cada uma das classes foi entre 25 e 100 polígonos para cada um dos anos, as classes de Água e Outros foram as que apresentaram a menor quantidade de polígonos devido a sua pouca representatividade nessa escala.

De acordo com Da Cruz (2021), as Amostras de Treinamento, também conhecidas como Conjunto de Treinamento, são conjuntos de dados que consistem em atributos e rótulos de classes correspondentes a cada entidade. Em termos formais, especialmente na mineração de dados combinada com o aprendizado de máquina supervisionado, são fornecidas características do objeto que se pretende alcançar. Nesse contexto, essas características englobam padrões de assinatura espectral associados à sua localização no terreno. Em outras palavras, o algoritmo utiliza as informações de entrada fornecidas para atribuir um valor de saída, baseado nas características do objeto em questão.

O Random Forest é um algoritmo de aprendizado de máquina que utiliza múltiplas árvores de decisão para realizar classificações. Cada árvore individual emite um voto para a classe mais frequente, e esses votos são combinados para determinar o resultado (LIL, WHANG e ZHANG, 2012). O Random Forest apresenta uma alta precisão na classificação, além de ser capaz de lidar eficientemente com pontos atípicos e ruídos. Esse método tem ganhado destaque como uma abordagem de pesquisa muito popular tanto na área de mineração de dados quanto na área da biologia (LIL, WHANG e ZHANG, 2012).

Segundo Breiman (2001), o Random Forest é um tipo de classificador que consiste em diversas estruturas de classificação em formato de árvore $\{h(x, k), k = 1, \dots\}$. Cada uma dessas árvores é influenciada por vetores aleatórios independentes

e igualmente distribuídos, e cada árvore, de forma individual, emite um voto único para a classe mais prevalente associada à entrada x .

A classificação foi realizada pixel-a-pixel diretamente na plataforma, por meio do algoritmo de Aprendizado de Máquina *RandomForest*. A estrutura e parâmetros necessários para o treinamento do classificador foram os mesmos para os quatro anos. A figura 16, apresenta os parâmetros do classificador, definidos por meio de uma análise bibliográfica e experiência com testes feitos na área de estudo e período desejado.

Figura 16: Parâmetros do RF.

```

var classificador = ee.Classifier.smileRandomForest({
  numberOfTrees : 2000,
  variablesPerSplit : 4,
  bagFraction : 0.7,
  minLeafPopulation : 3,
  seed : 123,
}).train({
  features : amostras,
  classProperty : 'uso',
  inputProperties : bandas
});

```

The number of decision trees to create.

The number of variables per split. If unspecified, uses the square root of the number of variables.

Only create nodes whose training set contains at least this many points

The fraction of input to bag per tree.

Fonte: Representação feita pelo autor

Para realizar com eficácia a implementação do algoritmo Random Forest no contexto do mapeamento de séries temporais, é fundamental possuir parâmetros claramente definidos e bem compreendidos com antecedência. (LIAW e WIENER (2002). O receio de perder informações durante o processo de aprendizado muitas vezes leva à decisão de incluir todos os atributos, deixando para o algoritmo de Aprendizado de Máquina a tarefa de selecionar os mais relevantes. (BARANAUSKAS, 2021).

A seleção de atributos úteis é um dos desafios intrínsecos da Aprendizado de Máquina. Embora a maioria dos algoritmos de aprendizado tente realizar essa seleção ou atribuir graus de importância aos atributos, análises teóricas e estudos experimentais indicam que muitos algoritmos apresentam um desempenho insatisfatório na presença de muitos atributos irrelevantes (BARANAUSKAS, 2021).

De acordo com Da Cruz (2021), a alocação das amostras em conjuntos de treinamento (70%) e de avaliação de acurácia (30%), juntamente com a determinação aleatória dos parâmetros de entrada, orienta o algoritmo na criação da sua primeira árvore de decisão.

A construção da classificação teve como objetivo a criação de uma de classificação automatizada, que fosse gratuita e tivesse potencial aplicação para a área de interesse. A Plataforma Google Earth Engine foi a ideal para realizar as etapas de processamento e classificação, devido a ser uma plataforma de processamento em nuvem. Isso significa que há maior velocidade no processamento de imagens, bem como a disponibilização de algoritmos de forma gratuita. No entanto, o Google Earth Engine tem um limite de dez gigabytes de espaço de armazenamento de arquivos para upload. (DA CRUZ, 2021).

Ao iniciar as etapas de processamento, o primeiro passo foi selecionar as imagens referentes ao município de Itaboraí-RJ para os anos de 2005, 2007, 2011 e 2020. Em seguida, os conjuntos de amostras de treinamento para cada um desses anos foram selecionados utilizando a geometria disponível na própria plataforma. Os limites do município também foram exportados para a plataforma por meio dos *Assets*, no *Code Editor* da Google Earth Engine.

Essas etapas foram fundamentais para preparar os dados e permitir a execução do algoritmo de classificação. O uso da Google Earth Engine facilitou o processamento e análise dos dados em nuvem, tornando o processo mais ágil e eficiente. Além disso, a capacidade de compartilhar os resultados com outros pesquisadores possibilita a colaboração e a disseminação dos conhecimentos obtidos.

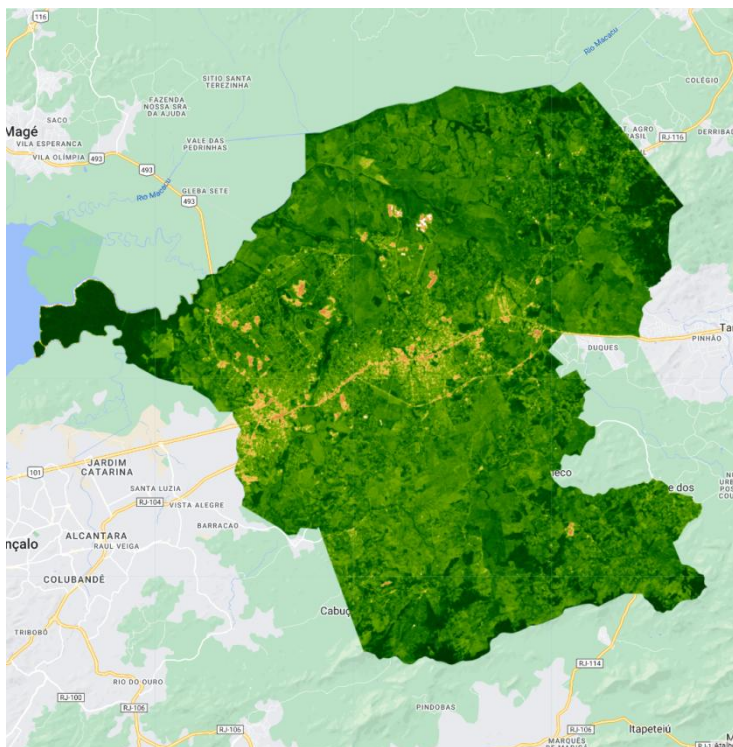
A utilização de dados de diferentes anos também é importante para acompanhar as mudanças ao longo do tempo na área de interesse e obter informações relevantes sobre a dinâmica das classes de uso e cobertura do solo. Ao final do processo, espera-se obter resultados precisos e confiáveis, que possam ser aplicados para a área de interesse e subsidiar a tomada de decisões em questões ambientais e socioeconômicas.

Essa disponibilização gratuita de códigos e recursos pelo Google Earth Engine e outros pesquisadores contribui para a democratização do acesso às técnicas de Aprendizado de Máquina, permitindo que mais pessoas possam se beneficiar dessas ferramentas poderosas para análise e processamento de dados geoespaciais. Além disso, a abordagem de compartilhamento de conhecimento e códigos promove a colaboração e o avanço da pesquisa científica nessa área, impulsionando a inovação e a geração de novos conhecimentos. A figura 44 mostra a função de compartilhamento do GEE.

Foram calculados três índices espectrais com finalidades distintas para cada um dos anos. Os índices espectrais são o resultado de operações matemáticas aplicadas aos valores numéricos dos pixels presentes nas diferentes bandas de uma imagem de satélite. Pesquisadores em todo o mundo utilizam as propriedades de absorção para avaliar os elementos retratados nas imagens de sensoriamento remoto, a fim de gerar índices que atendam às mais diferentes demandas dos estudos. (Shiratsuchi et al., 2014)

O NDVI ($(\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED})$) (figura 17) é um índice que possibilita a análise e diferenciação de diferentes tipos e densidades de cobertura vegetal. As tonalidades mais escuras representam áreas com maior densidade de vegetação. No algoritmo, o NDVI serviu como forma de destacar e diferenciar as classes de Floresta e Mangue. Ele é calculado a partir das propriedades espectrais de duas bandas: o infravermelho próximo (NIR), no qual a vegetação reflete intensamente, e a banda do vermelho visível (RED), que apresenta baixa reflexão da vegetação. (Oliveira, Neto e Silva, 2021)

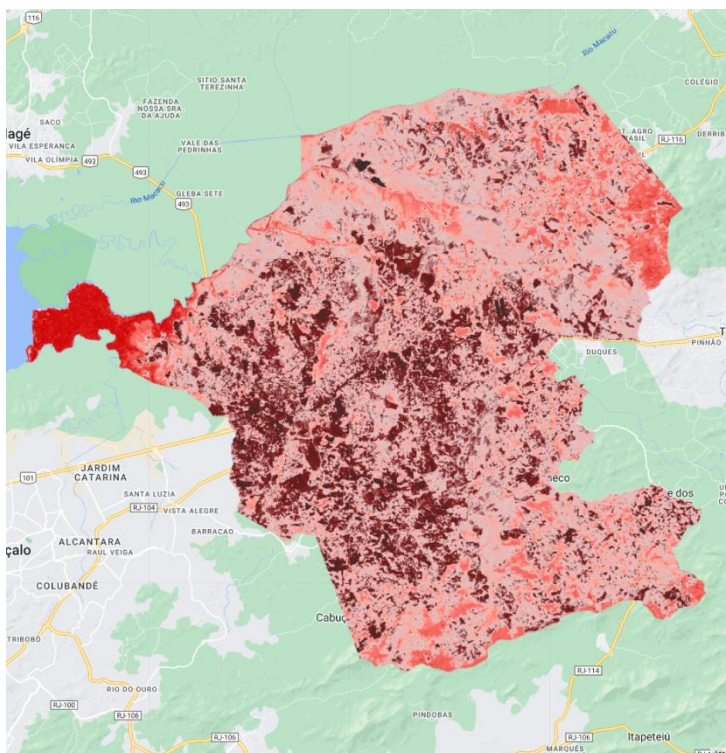
Figura 17: Representação do NDVI na imagem Landsat – 5 (TM) ano 2005.



Fonte: Representação feita pelo autor

O NDBI ($SWIR1 - NIR$) / ($SWIR1 + NIR$) (figura 18), por sua vez, utiliza as faixas espectrais do infravermelho médio (SWIR) e infravermelho próximo (NIR), facilitando a categorização do uso e ocupação da superfície em ambientes urbanos (vermelho escuro). As classes de Área Construída e Solo Exposto foram as que obtiveram maior destaque diante desse índice.

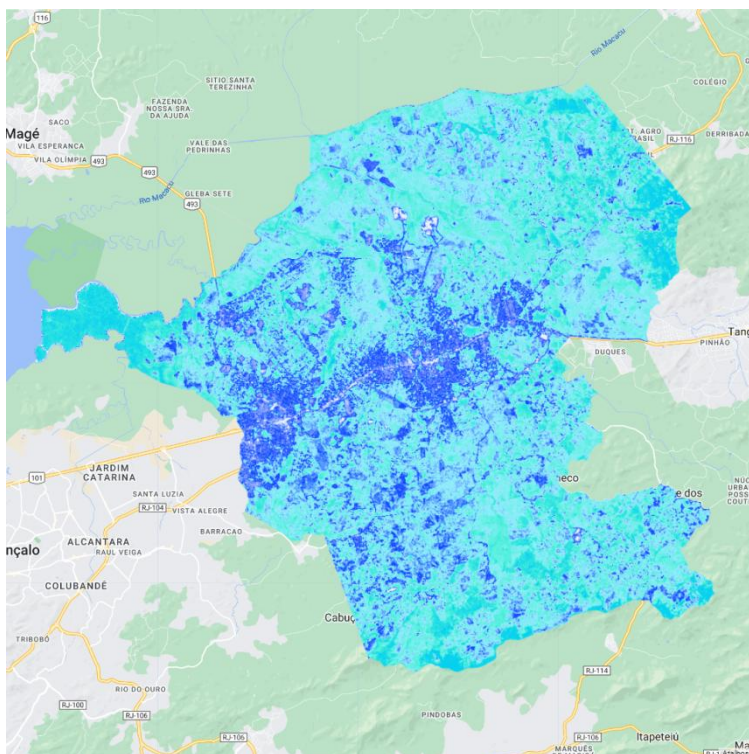
Figura 18: Representação do NDBI na imagem Landsat – 5 (TM) ano 2005.



Fonte: Representação feita pelo autor

A metodologia de aplicação do NDWI ($GREEN - NIR$) / ($GREEN + NIR$) (figura 19) realça características de água e minimiza outros elementos presentes na imagem. (Brenner e Guasselli, 2015). O índice foi utilizado para auxiliar na identificação da classe Água, principalmente em localidades próximas a vegetações densas.

Figura 19: Representação do NDWI na imagem Landsat – 5 (TM) ano 2005.



Fonte: Representação feita pelo autor

6.3. Resultados e discussões

Foi gerado o índice Kappa para cada classificação gerado por meio da matriz de confusão. O índice Kappa é um dos indicadores mais comuns para avaliação da precisão em estudos de verificação de mapeamentos temáticos. Este índice é conhecido por ser uma técnica discreta multivariada utilizada na avaliação da exatidão de mapas temáticos, considerando todos os elementos da matriz de confusão em seu cálculo (Nery et al., 2013).

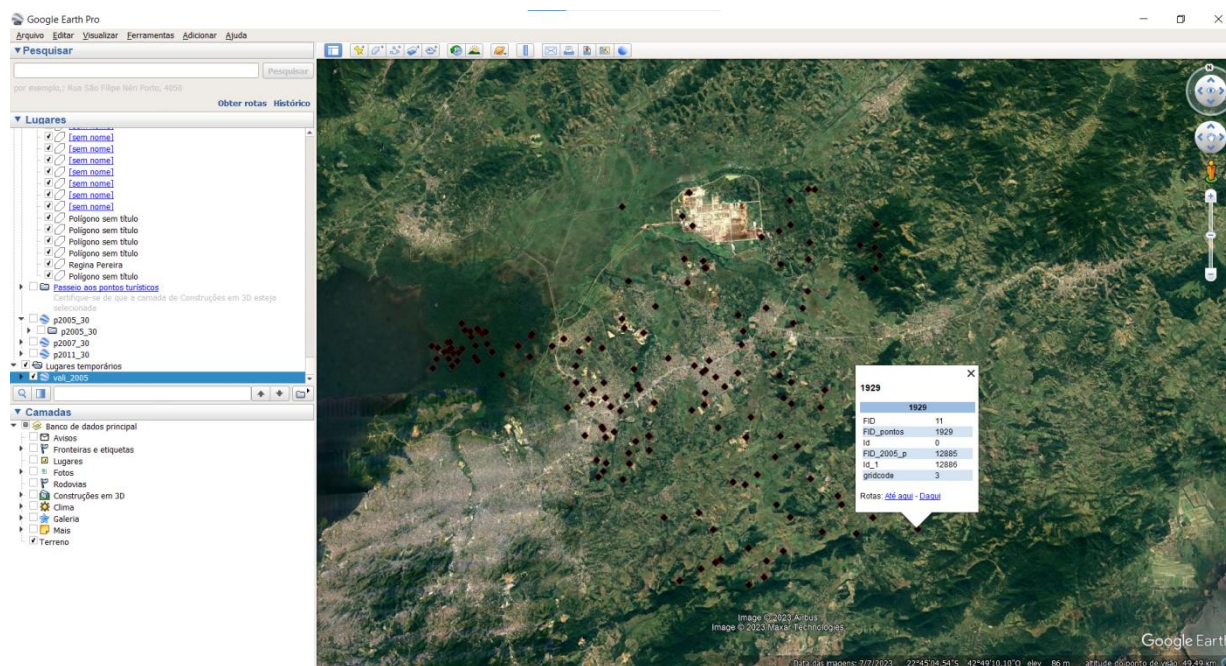
O método de validação adotado para as imagens produzidas envolveu a seleção de amostras aleatórias em cada uma das classes escolhidas para o mapeamento. Essas amostras foram utilizadas para comparar as classificações geradas pelo algoritmo com a realidade no terreno, com o auxílio do *Google Earth Pro*.

Para preparar os polígonos que seriam validados, foi empregado o *software ArcGIS 10.6*. Inicialmente, pontos aleatórios foram gerados para cada imagem classificada através da ferramenta "*Random Points*". Posteriormente, esses pontos foram associados ao *shapefile* correspondente à imagem classificada. A tabela de

atributos desse novo arquivo foi utilizada para selecionar 30 pontos aleatórios em cada classe, com o intuito de criar um arquivo separado contendo apenas os pontos selecionados.

Os 30 pontos selecionados para cada classe pela ferramenta foram exportados e convertidos para o formato "KMZ" para análise no *Google Earth Pro*. Durante o processo de validação, os resultados obtidos no *Google Earth Pro* (figura 20) eram colocados na matriz de confusão de acordo com a correspondência do ponto. Ou seja, em caso de concordância é acrescentando um acerto na classe correspondente, já em caso de discordância, o valor é colocado na classe sinalizada pelo ponto.

Figura 20: Validação no Google Earth Pro



Fonte: Representação feita pelo autor

Essa abordagem desempenha um papel fundamental na verificação da acurácia das classificações geradas pelo algoritmo e na garantia de que os resultados sejam confiáveis e aplicáveis para o propósito desejado. No entanto, é essencial compreender as limitações desse método e adotar cautela ao interpretar os resultados, levando em consideração a escala da análise e a adequação dos métodos utilizados. As Tabelas 4, 5, 6 e 7 estão apresentados os resultados das matrizes de confusão.

Fonte: Representação feita pelo autor

Tabela 7: Matriz de confusão de 2020.

	Mangue	Água	Floresta	Agropasto	Solo exp	Área Construída	Outros	Total	acurácia do produtor
Mangue	30	0	0	0	0	0	0	30	100%
Água	0	30	0	0	0	0	0	30	100%
Floresta	0	0	29	1	0	0	0	30	97%
Agropasto	0	0	1	27	0	2	0	30	90%
Solo exp	0	0	0	4	23	3	0	30	77%
Área Construída	0	0	0	2	3	25	0	30	83%
Outros	0	0	0	0	0	0	30	30	100%
Total	30	30	30	34	26	30	30	210	100%
Acurácia do usuário	100%	100%	97%	79%	88%	83%	100%		
Exatidão global	0,9238								
PO	0,9238								
PE	0,1224								
Kappa	0,9132								


Fonte: Representação feita pelo autor

Os resultados das classificações realizadas por meio do algoritmo *RandomForest* e da Plataforma GEE para Itaboraí são promissores. A acurácia global, que mede a proporção de todas as classificações corretas em relação ao total de amostras, atingiu cerca de 90% para ambos os anos.

Além disso, o índice Kappa, que é uma métrica que considera a concordância entre as classificações do modelo e as classificações esperadas ao acaso, apresentou valores elevados. Para os anos de 2005, 2007, 2011 e 2020, os índices Kappa foram respectivamente de 88%, 89%, 90% e 91%. De acordo com a classificação proposta por Fernandes (2000), esses valores são considerados "Excelentes", o que indica um alto nível de concordância e acurácia nas classificações.

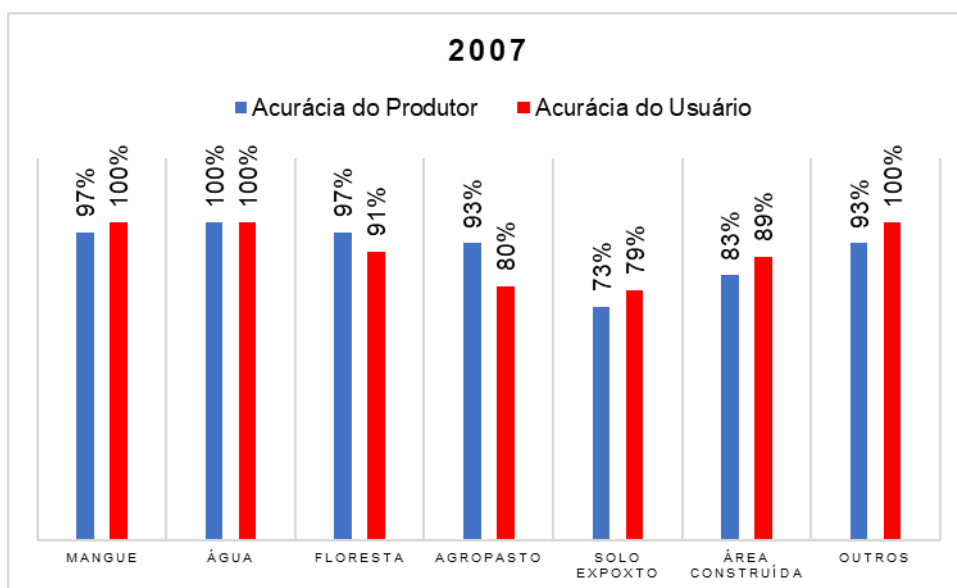
É interessante observar que as classes "Área Construída", "Solo Exposto" e "Agropasto" apresentaram as menores acurácias do produtor e do usuário em todos os anos. Isso significa que o algoritmo *RandomForest* teve mais dificuldade em identificar e classificar corretamente amostras pertencentes a essas classes específicas. Apesar disso, mesmo com as acurácias do produtor e do usuário relativamente mais baixas, os acertos não ficaram abaixo de 70%. Isso indica que o modelo ainda foi capaz de identificar uma proporção considerável de amostras corretamente, mesmo para as classes mais desafiadoras. Os gráficos 4, 5, 6 e 7 apresentam as acurácias do produtor e usuário para todas as classificações.

Gráfico 4: Acurácia do produtor e Acurácia do usuário para 2005.




Fonte: Representação feita pelo autor

Gráfico 5: Acurácia do produtor e Acurácia do usuário para 2007.




Fonte: Representação feita pelo autor

Gráfico 6: Acurácia do produtor e Acurácia do usuário para 2011.



Fonte: Representação feita pelo autor

Gráfico 7: Acurácia do produtor e Acurácia do usuário para 2020.



Fonte: Representação feita pelo autor

As classes “Floresta”, “Mangue” e “Água” se destacam pelo alto percentual de acerto, os valores para ambos os anos indicam que essas classes cometem baixíssimos erros de comissão e omissão, ou seja, recua e avança pouco sobre as outras classes. Em contrapartida, as classes de “Agropasto”, “Solo Exposto” e “Área Construída” apresentaram as maiores variações e menores acertos em ambas as datas.

No geral, os resultados mostram que o algoritmo *RandomForest* e a Plataforma GEE foram capazes de realizar classificações com um bom nível de acurácia para a maioria das classes. Essa análise permitirá direcionar esforços para melhorar a precisão da classificação e obter resultados ainda mais confiáveis no futuro. A Tabela 8 apresenta um resumo com todas as métricas calculadas na matriz de confusão.

Tabela 8: resumo das matrizes de confusão.

	2005		2007		2011		2020	
	AP	AU	AP	AU	AP	AU	AP	AU
Mangue	97%	97%	97%	100%	97%	97%	100%	100%
Água	100%	100%	100%	100%	100%	100%	100%	100%
Floresta	97%	91%	97%	91%	90%	90%	97%	97%
Agropasto	87%	70%	93%	80%	90%	84%	79%	90%
Solo Exposto	83%	96%	73%	79%	87%	87%	88%	77%
Área Construída	77%	96%	83%	89%	83%	83%	83%	83%
Outros	100%	97%	93%	100%	93%	100%	100%	100%
Kappa	88%		89%		91%		91%	
Acurácia Global	90%		91%		90%		89%	

Fonte: Representação feita pelo autor

Esses resultados podem ser úteis para direcionar futuras melhorias no algoritmo de classificação ou no processo de coleta de dados. É possível que a inclusão de mais amostras de treinamento e a utilização de técnicas de pré-processamento mais adequadas possam ajudar a melhorar a classificação dessas classes específicas.

É reconhecido que, independentemente da qualidade do treinamento do classificador, os resultados obtidos inevitavelmente incluem erros de classificação, decorrentes de várias fontes (DUARTE, 2004).

Foi feita a edição das classificações junto ao *ArcGIS 10.6* com o objetivo de corrigir as classes que obtiveram maiores confusões em suas acurácias do produtor, usuário e exatidão global. Além de ajustar alguns pontos interesse do município, como a área onde o COMPERJ fica situado. Para a validação das edições, foram novamente selecionados 30 amostras aleatórios para cada uma das classificações. As matrizes de confusão abaixo (Tabelas 9, 10, 11 e 112) expressam os valores obtidos em cada uma das classificações pós-edição.

Tabela 9: Matriz de confusão da edição ano de 2005.

	Mangue	Água	Floresta	Agropasto	Solo exp	Área Construída	Total	acurácia do produtor
Mangue	29	0	1	0	0	0	30	97%
Água	0	29	1	0	0	0	30	97%
Floresta	1	0	29	0	0	0	30	97%
Agropasto	0	0	2	28	0	0	30	93%
Solo exp	0	0	0	2	24	4	30	80%
Área Construída	0	0	0	3	2	25	30	83%
Total	30	29	33	33	26	29	180	
Acurácia do usuário	97%	100%	88%	85%	92%	86%		
Exatidão global	0,91111							
PO	0,91111							
PE	0,16667							
Kappa	0,89333							

Fonte: Representação feita pelo autor

Tabela 10: Matriz de confusão da edição ano de 2007.

	Mangue	Água	Floresta	Agropasto	Solo Exposto	Área Construída	Outros	Total	Acurácia do Produtor
Mangue	30	0	0	0	0	0	0	30	100%
Água	0	30	0	0	0	0	0	30	100%
Floresta	0	0	30	0	0	0	0	30	100%
Agropasto	0	0	0	29	0	1	0	30	97%
Solo Exposto	0	0	0	4	24	2	0	30	80%
Área Construída	0	0	0	3	2	25	0	30	83%
Outros	0	0	0	0	0	0	30	30	100%
Total	30	30	30	36	26	28	30	210	
Acurácia do Usuário	100%	100%	100%	81%	92%	89%	100%		
Exatidão global	0,9429								
PO	0,9429								
PE	0,1429								
Kappa	0,9333								

Fonte: Representação feita pelo autor

Tabela 11: Matriz de confusão da edição ano de 2011.

	Mangue	Água	Floresta	Agropasto	Solo Exposto	Área Construída	Outros	Total	Acurácia do Produtor
Mangue	30	0	0	0	0	0	0	30	100%
Água	0	30	0	0	0	0	0	30	100%
Floresta	1	0	28	1	0	0	0	30	93%
Agropasto	0	0	0	28	0	2	0	30	93%
Solo Exposto	0	0	0	0	27	3	0	30	90%
Área Construída	0	0	0	1	2	27	0	30	90%
Outros	0	0	0	0	2	0	28	30	93%
Total	31	30	28	30	31	32	28	210	
Acurácia do Usuário	97%	100%	100%	93%	87%	84%	100%		
Exatidão global	0,9429								
PO	0,9429								
PE	0,1429								
Kappa	0,9333								

Fonte: Representação feita pelo autor

Tabela 12: Matriz de confusão da edição ano de 2020.

	Mangue	Água	Floresta	Agropasto	Solo Exposto	Área Construída	Outros	Total	Acurácia do Produtor
Mangue	30	0	0	0	0	0	0	30	100%
Água	0	30	0	0	0	0	0	30	100%
Floresta	0	0	30	0	0	0	0	30	100%
Agropasto	0	0	1	28	0	1	0	30	93%
Solo Exposto	0	0	0	2	26	2	0	30	87%
Área Construída	0	0	0	3	3	24	0	30	80%
Outros	0	0	0	0	0	0	30	30	100%
Total	30	30	31	33	29	27	30	210	
Acurácia do Usuário	100%	100%	97%	85%	90%	89%	100%		
Exatidão global	0,9429								
PO	0,9429								
PE	0,1224								
Kappa	0,9349								

Fonte: Representação feita pelo autor

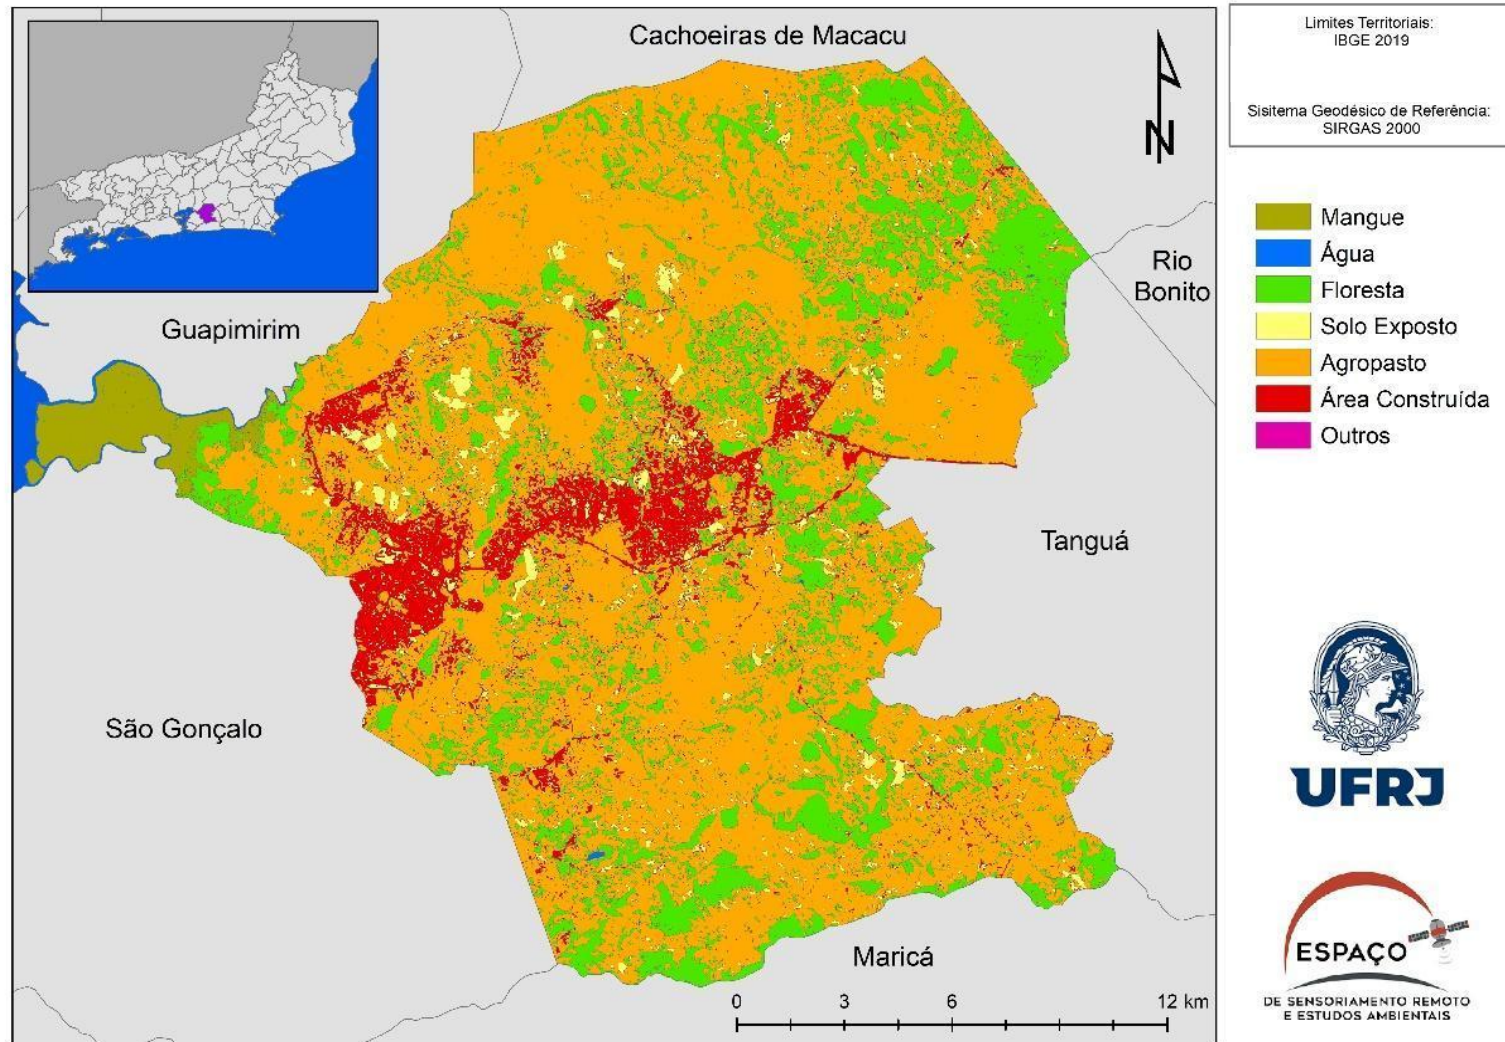
Ao todo os mapeamentos tiveram menos de 10% de sua área total editados, sendo respectivamente 2%, 7% ,8% e 6% para os anos de 2005, 2007, 2010 e 2020. As classes do “Solo Exposto” e “Área Construída” foram as mais alteradas, principalmente devido a confusão mútua entre elas.

6.3.1. Mudanças na Cobertura e Uso da Terra de Itaboraí – RJ

Os mapas a seguir ilustram a distribuição das classes de cobertura e uso da terra nos anos de 2005, 2007 2011 e 2020 (figuras 21, 22, 23 e 24), as classificações também podem ser acessados na plataforma do GEE através do link: https://code.earthengine.google.com/?accept_repo=users/jonaspimentel97/Dissertacao. É evidente a transformação de determinadas regiões do município devido à expansão urbana, especialmente nas áreas centrais e nas proximidades do COMPERJ. Além disso, os mapas correspondentes aos anos de 2011 e 2020 destacam claramente as fases de terraplanagem e implementação da infraestrutura na região destinada ao empreendimento.

1

Figura 21: Mapa ano de 2005.

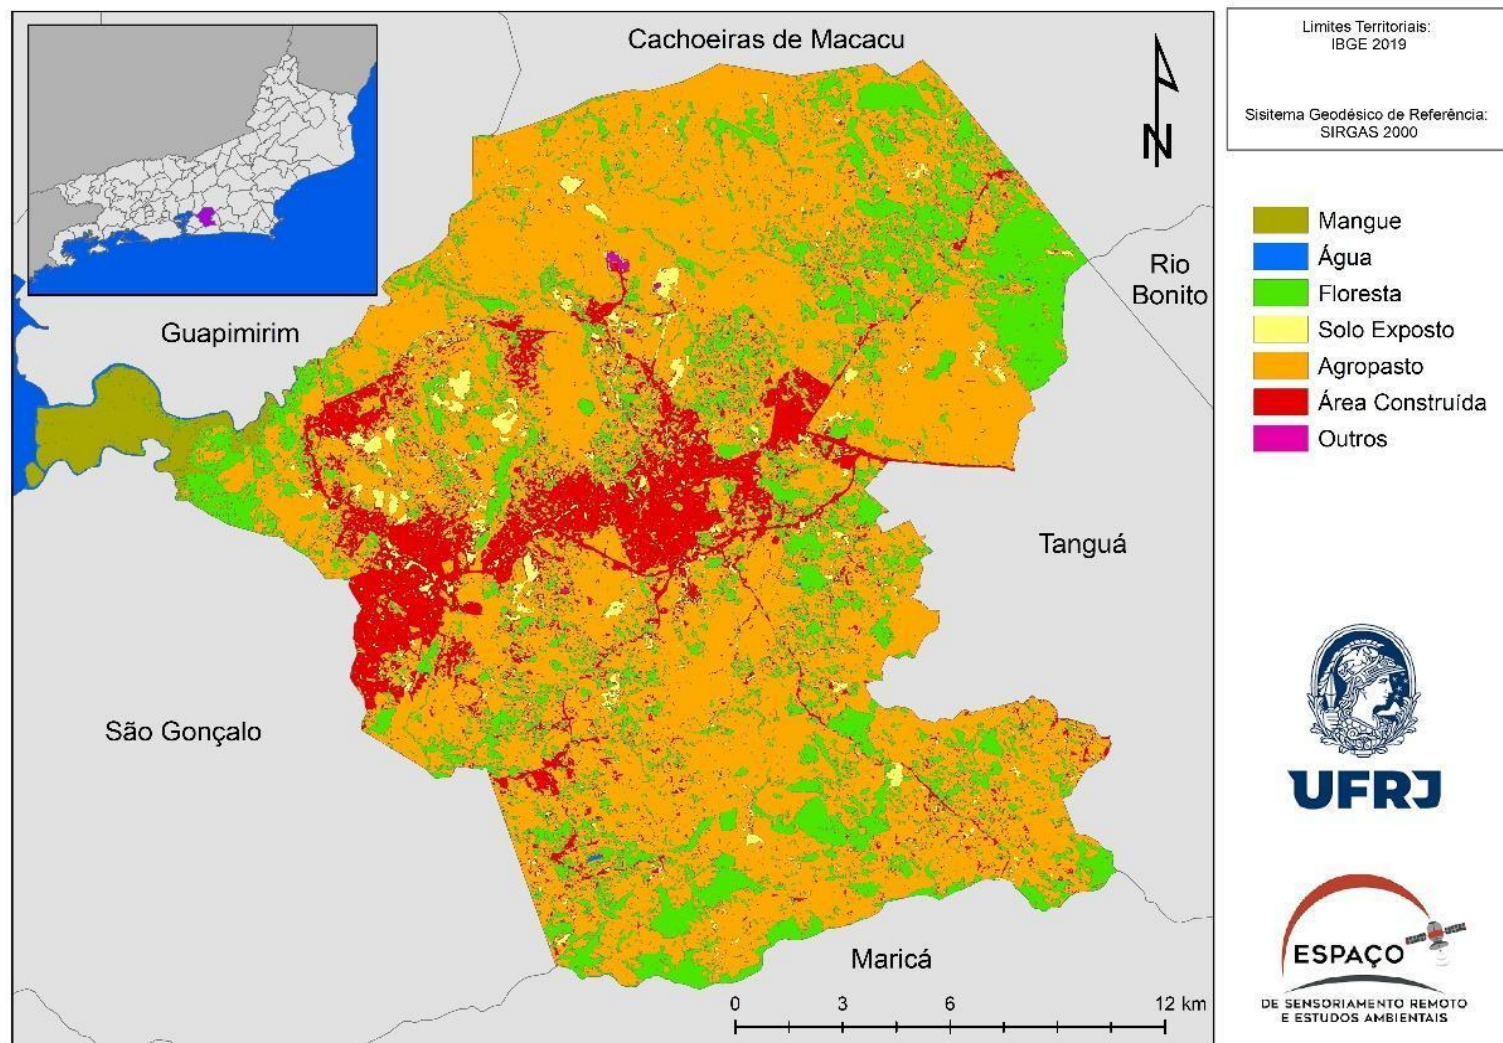


2

3

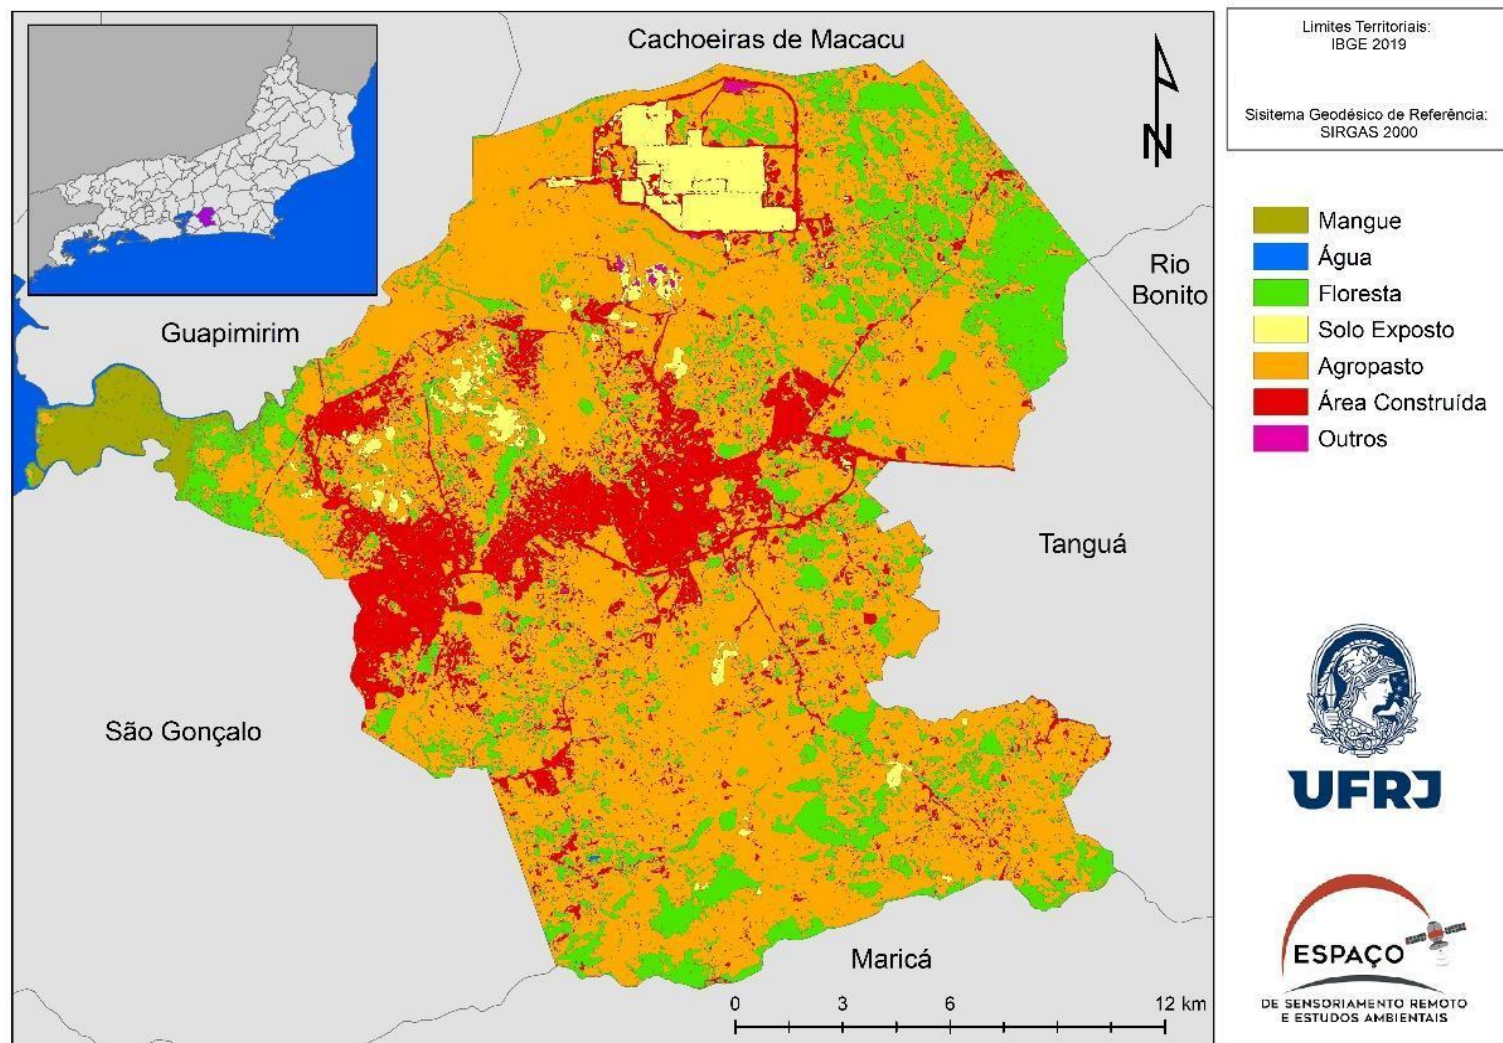
Fonte: Representação feita pelo aut

Figura 22: Mapa ano de 2007.



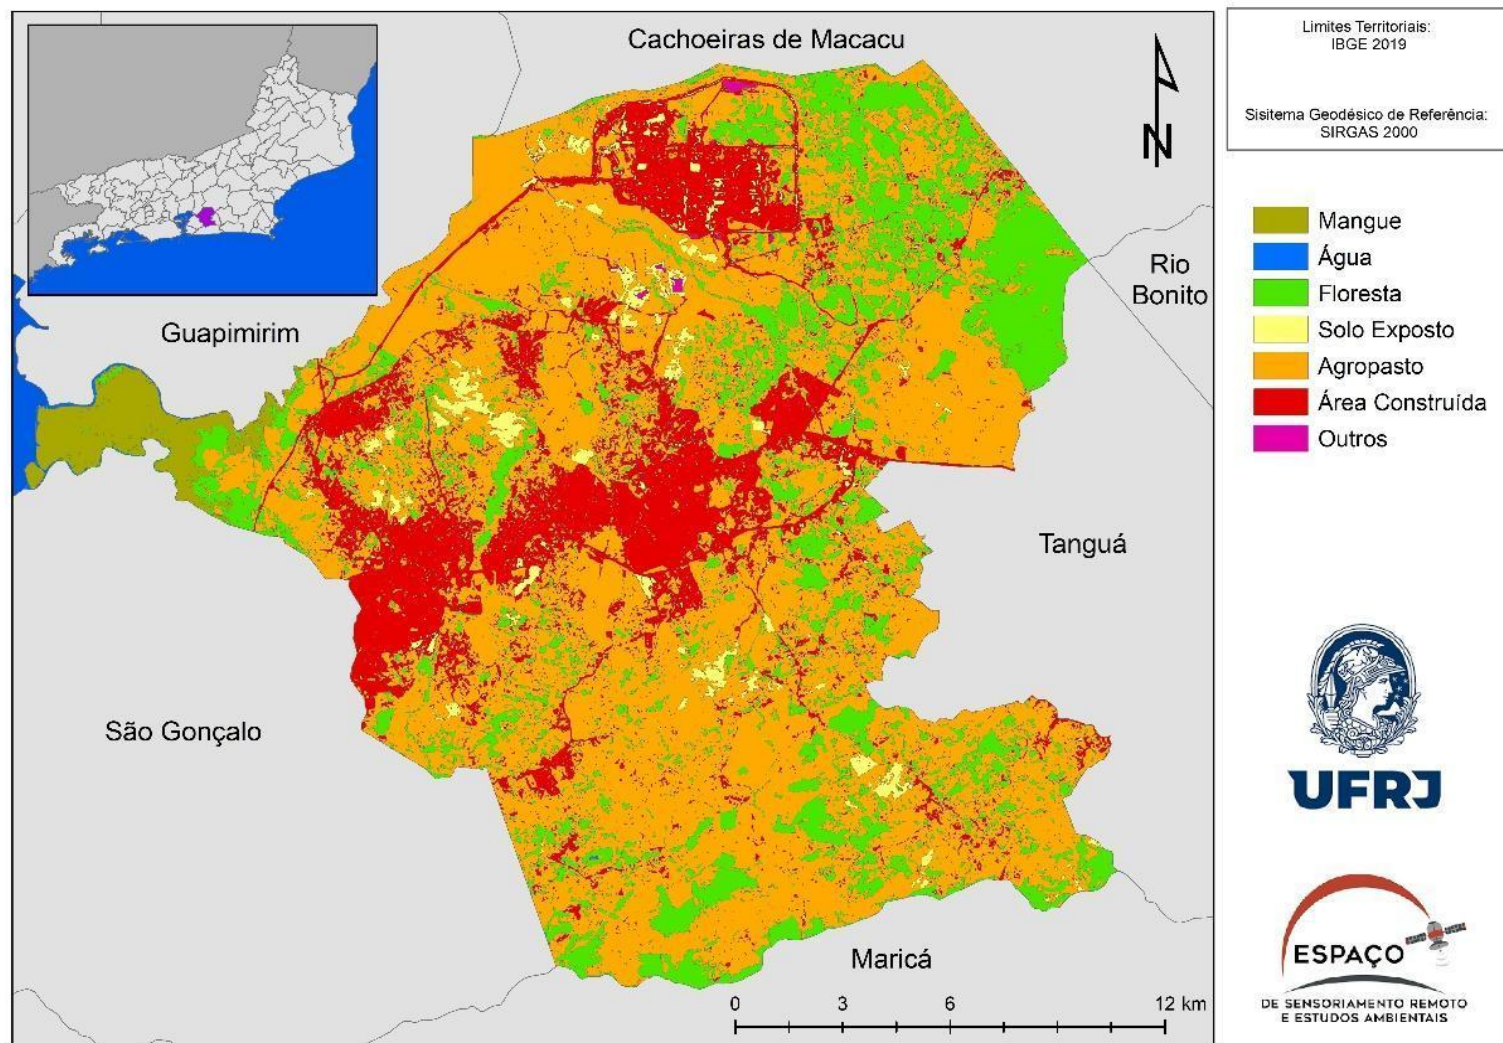
Fonte: Representação feita pelo autor

Figura 23: Mapa ano de 2011.



Fonte: Representação feita pelo autor

Figura 24: Mapa ano de 2020.



Fonte: Representação feita pelo autor.

No período anterior ao anúncio do COMPERJ, a configuração do município revela uma concentração significativa de “Áreas Construídas” no bairro de Manilha, próximo ao município de São Gonçalo, bem como nos demais bairros adjacentes à Avenida 22 de Maio, a principal via do município. A classe florestal ocupa a segunda posição em predominância, ficando atrás apenas da categoria “Agropasto”, que constitui a matriz do município.

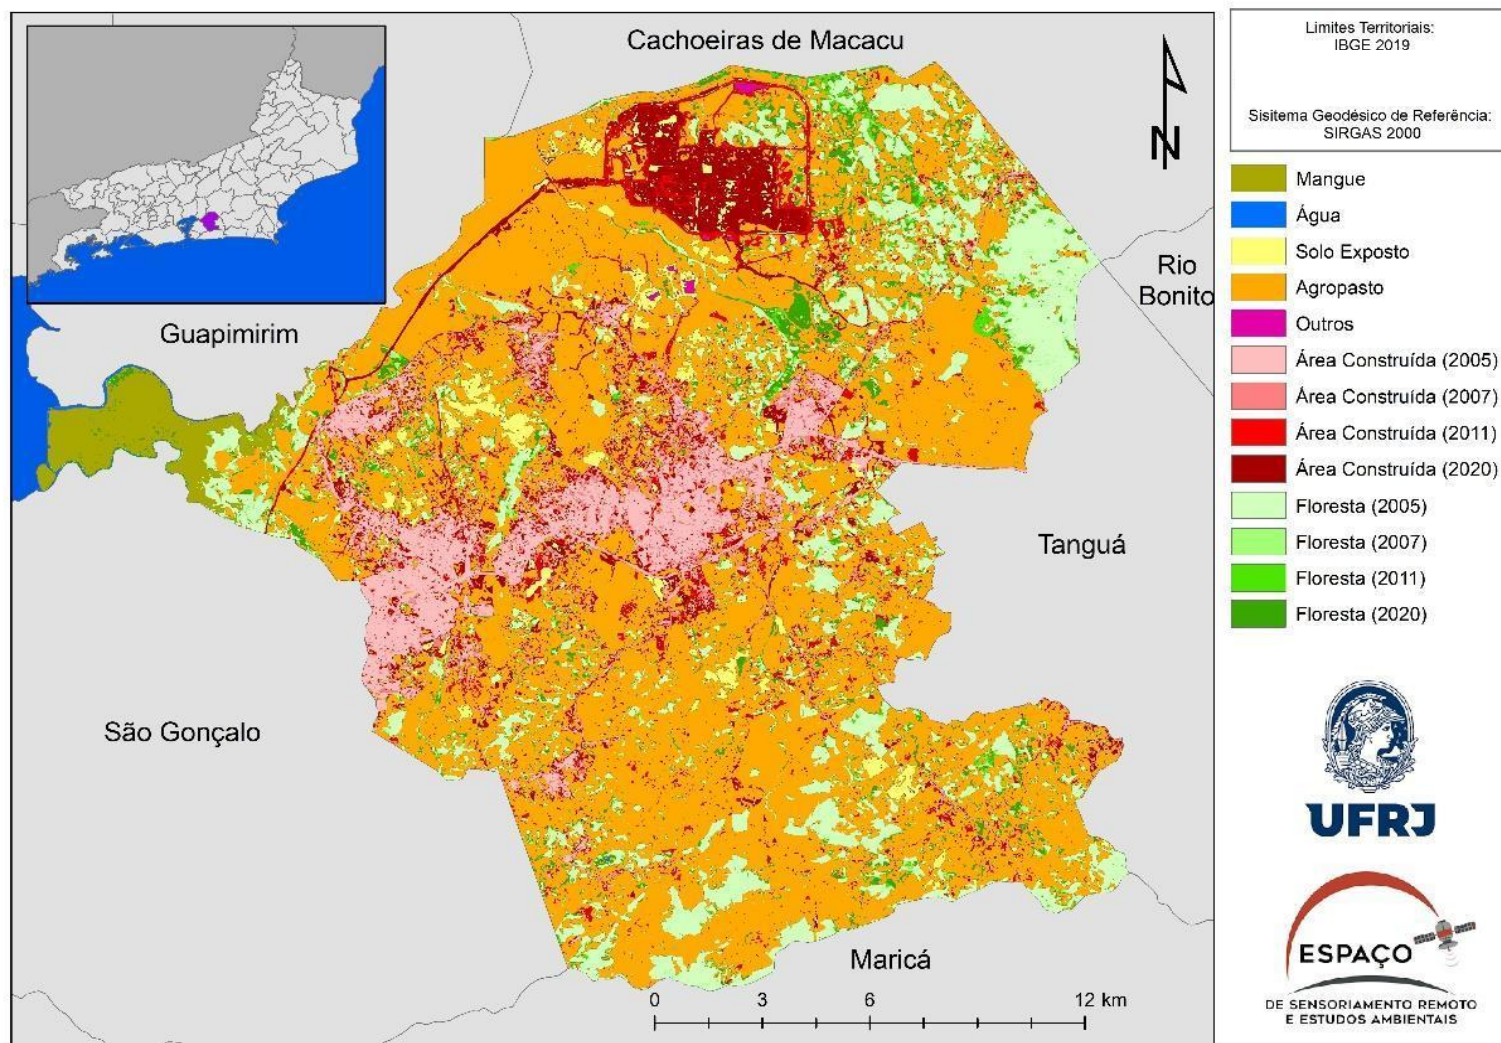
No ano de 2007, observa-se um leve aumento na extensão da classe de “Área Construída”, ainda focalizado principalmente nas áreas centrais. Além disso, outras alterações se tornam aparentes em comparação ao ano anterior. A classe "Outros", que inclui predominantemente áreas de extração de areia, começa a expandir-se na região adjacente ao COMPERJ.

No ano de 2011, as áreas urbanas passaram a se expandir de maneira mais intensa no município, agora em direção a Itambi, bairro mais próximo à estrada do COMPERJ (construída posteriormente) e ao Arco Metropolitano do Rio de Janeiro. Além disso, é perceptível o início do processo de terraplanagem na região destinada ao COMPERJ.

Na imagem de 2020, a presença da Área Construída se torna mais predominante no município. A região correspondente ao COMPERJ agora é classificada como “Área Construída”, sugerindo que as obras progrediram. Além disso, é possível observar a presença de estradas próximas ao COMPERJ. Entre os anos de 2011 e 2020, houve uma retomada das obras nas áreas centrais de Itaboraí, o que pode explicar o considerável aumento da área urbana no município.

O mapa (figura 29) a seguir ilustra a evolução da classe “Floresta” e da classe “Área Construída” nos intervalos de tempo de 2005 a 2007, 2007 a 2011 e 2011 a 2020. Adicionalmente, estão incluídos dois gráficos que representam as variações dessas classes entre o início e o final de cada período.


Figura 25: Mapa de 2020 com o surgimento da floresta e da Área Construída.



Fonte: Representação feita pelo autor.

A classe de “Floresta” passou por variações significativas no período de 2007 a 2020. Entre os anos de 2007 e 2011, há uma redução de 24% na área total da floresta, que posteriormente será relacionada a uma conversão para a classe “Agropasto”. No intervalo de 2011 a 2020, observa-se um aumento de 13% na área da classe de “Floresta”, possivelmente impulsionado por iniciativas como a criação de um corredor ecológico e o crescimento de vegetação em áreas abandonadas devido a problemas associados ao COMPERJ. O gráfico 8, apresenta um gráfico de árvores contendo a área de cada uma das classes nos anos das classificações.

Gráfico 8: Gráfico de árvores para os anos.



Fonte: Representação feita pelo autor

A classe do “Agropasto” desde 2005 representa aproximadamente 60% do toda a área do município, mesmo com uma pequena redução de 7% quando comparado o primeiro ano com o último.

A “Área Construída” do município teve um aumento significativo entre os anos, de 8% para 18% da área total do município, e teve influência direta na redução

do “Solo Exposto” e do “Agropasto “no último período. Essa classe é que mais representa a especulação imobiliária e o avanço das políticas públicas que intensificaram a infraestrutura industrial do município.


Apesar da representatividade da “Área Construída” ser muito maior no ano de 2020, o seu período de maior crescimento acontece entre os anos de 2005 e 2011, 6%, período em que o COMPERJ estava atuando mais intensamente no município. O intervalo de 9 anos entre, 2011 e 2020, significou um aumento de apenas 4% da área total, o que talvez tenha sido ocasionado pela redução de investimentos no município e o pouco interesse das empresas e pessoas diante da situação do COMPERJ.

O aumento da “Floresta” no último período pode ser outro indicativo desse desinteresse, uma vez que no auge do processo de implantação do COMPERJ a Floresta representava 16% da área municipal, uma redução de 4% em relação aos outros anos. Já no momento seguinte a Floresta tem um crescimento de 2%, o que indicaria não só a implantação de políticas de compensação ambiental, mas também o avanço da vegetação em áreas agropastoris, o que será justificado nos diagramas mais abaixo.

As classes de “Mangue”, “Água”, “Outros” e “Solo exposto”, não possuem grande representatividade no município, juntas chegaram próximo dos 7% em 2011. No entanto é interessante ressaltar que a classe “Outros” começa a ganhar espaço dentro da representação com o anúncio do COMPERJ, devido a ser majoritariamente formada por áreas de extração de areia, e o “Solo Exposto” tem sua maior representatividade em 2011, ano da terraplanagem da área do COMPERJ.

Para se descobrir e quantificar as transições de uma classe para outra, foi elaborado o diagrama de Sankey (gráfico 9). Com o intuito de simplificar o diagrama, cada período foi analisado separadamente. Sendo assim, o primeiro período (P1) analisa a transição entre os anos de 2005 e 2007 o segundo período (P2) os de 2007 a 2011 e o último (P3) mostra como as classes se transacionam entre o ano de 2011 para 2020.

Gráfico 9: Diagrama de Sankey representando as transformações das classes de Uso e Cobertura da Terra nos três períodos.




Fonte: Representação feita pelo autor

O Sankey utiliza a totalidade de pixels classificados em todas as classes dos mapeamentos, por isso, os fluxos gerados estão diretamente relacionados com a precisão do mapeamento. Devido a isso, existe uma pequena margem de erros em cada um desses fluxos, o que ocasiona principalmente o surgimento de transições menores ou algumas transições equivocadas.

Como visto no gráfico 9, a área total de quase todas as classes não se modifica entre os anos de 2005 e 2007, porém, por meio do Sankey do P1 (gráfico 10) é possível observar que algumas classes transacionaram para outras.

Gráfico 10: Diagrama de Sankey apresentado a variação das classes no P1.



Fonte: Representação feita pelo autor

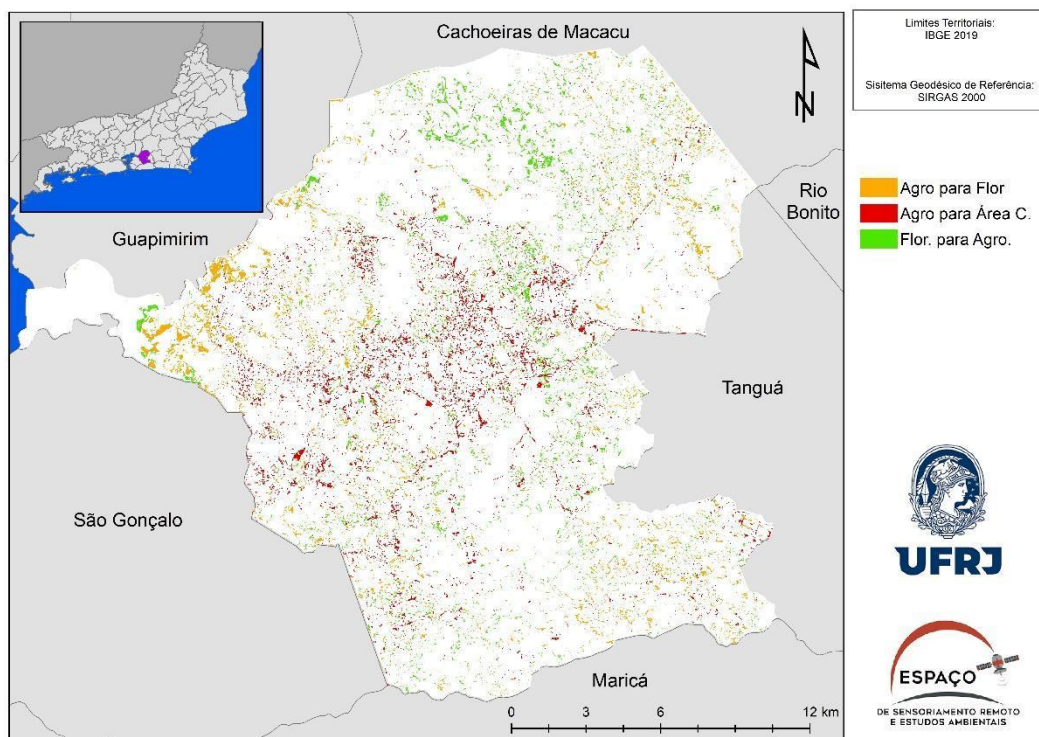
As variações retratadas no primeiro período apresentam maiores valores nas transições entre a “Floresta” e o “Agropasto,” ao todo 2479 ha de área foram alterados entre ambas as classes. O valor de “Floresta” perdido na classificação de 2005, representa cerca 14,15% (1210 ha) da área total que a classe tinha nesse

ano. Por outro lado, a perda do “Agropasto” representa uma redução de apenas 4,24% (1269 ha) de sua área total em relação ao ano de 2005.

Em relação a 2007, os ganhos da “Floresta” vindos do “Agropasto” equivalem a 14,94% (1269 ha) da área total da classe no ano. Já o aumento do “Agropasto” vindos da transição com a “Floresta” representam apenas 4,39% (1210 ha) de sua área total.

As variações entre “Floresta” e o “Agropasto” não modificaram muito a área total que as classes possuíam no município. No entanto, a área construída obteve um aumento de 25,73% (1214 ha) vindos do “Agropasto”, esse grande aumento ocorreu devido à área total da “Área Construída” ser quase 6 vezes menor que a área do “Agropasto”. O mapa (figura 26) abaixo apresenta a distribuição dessas três principais mudanças para o primeiro período.

Figura 26 : Localização das principais variações do p1.

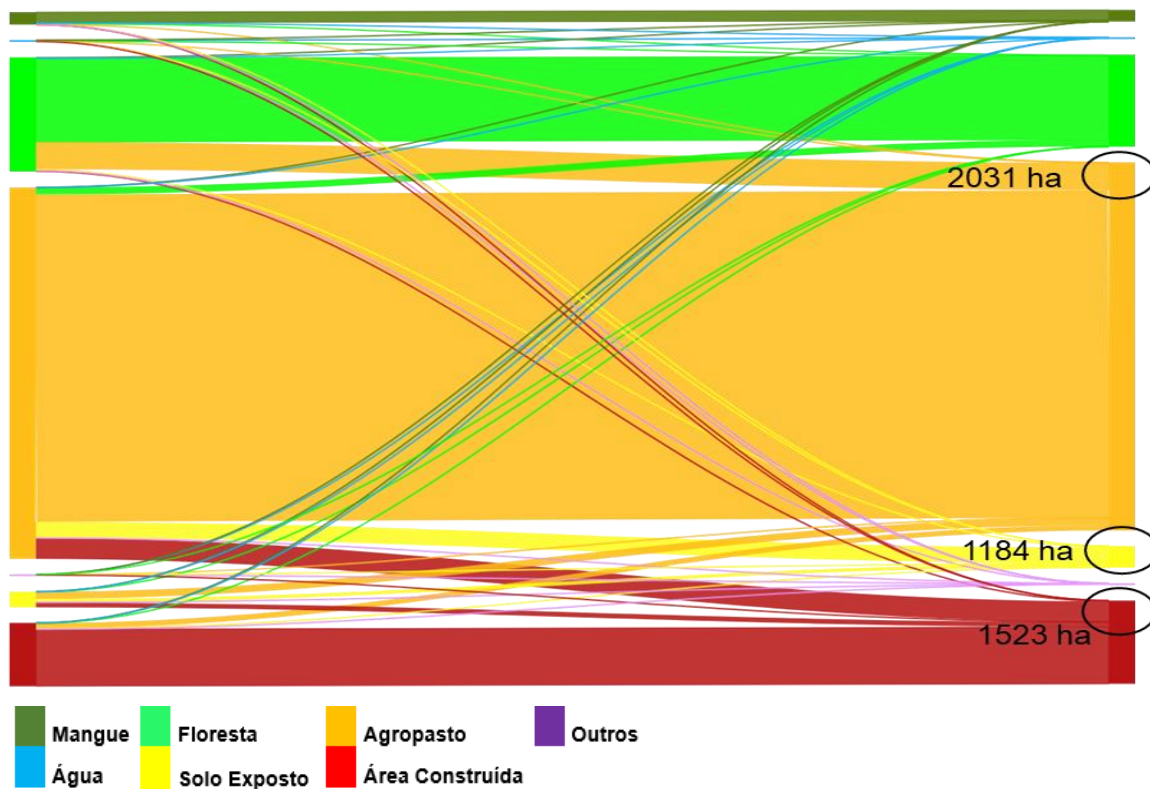


Fonte: Representação feita pelo autor

O segundo período é o que mais retrata as mudanças entre as classes. Há uma considerável diminuição da área da “Floresta” para o “Agropasto”, além de mais

um aumento considerável na “Área Construída” e um outro aumento no “Solo Exposto”. A gráfico 11 apresenta o Sankey do P2 com todas as transições.

Gráfico 11: Diagrama de Sankey apresentado a variação das classes no P2.

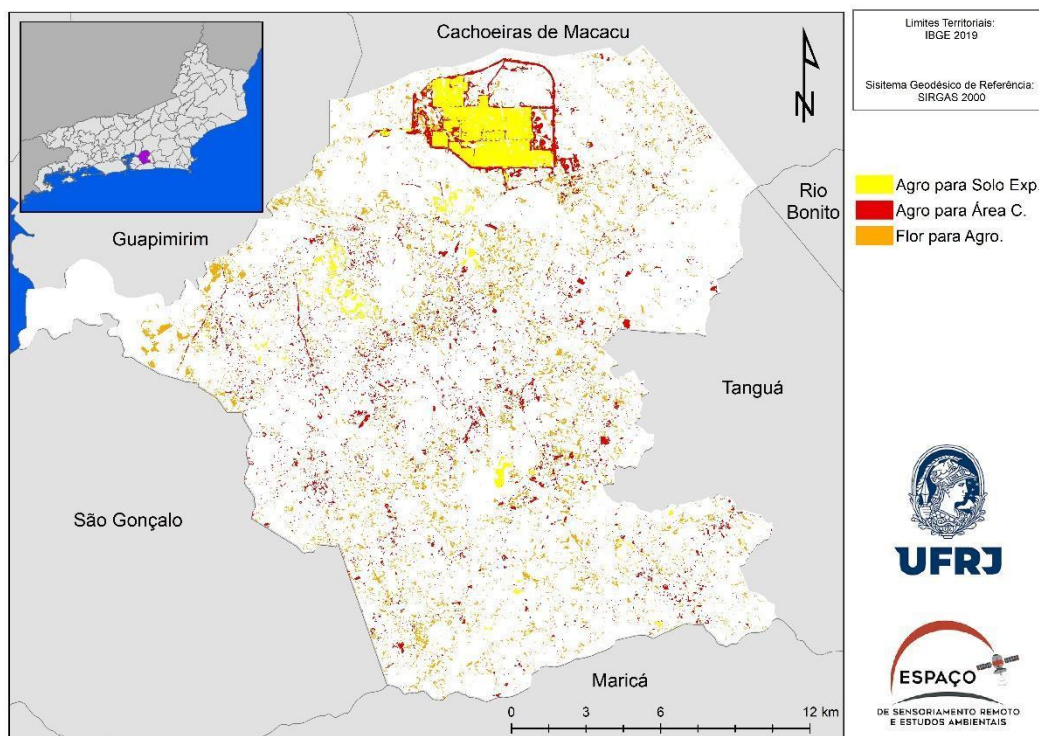


Fonte: Representação feita pelo autor

A “Floresta” perdeu 23,42% da sua área total que tinha em 2007 para o Agropasto nesse período, o que ocasionou uma redução de mais de 2031ha de sua área total. Já o “Agropasto”, apesar de ter ganho 2031 ha de área vindos da classe da “Floresta”, manteve sua área total devido a sua transição para a “Área Construída” e “Solo Exposto”.

O Solo Exposto teve o maior aumento percentual em uma única transição, 73,35% (1184 ha) de sua área total aumentou graças a terraplanagem realizada na área do COMPERJ. Já a “Área Construída” obteve um aumento de 24,43% de sua área total apenas vindo do “Agropasto”. É possível observar na figura 27 que parte desse aumento vem da infraestrutura do COMPERJ, somado a isso a expansão das áreas centrais do município, o aumento da infraestrutura urbana de locais em crescimento próximos a futura estrada do COMPERJ e o surgimento de outras vias.


Figura 27: Localização das principais variações do p2.



Fonte: Representação feita pelo autor

O último período, representado através gráfico 12, consolida algumas mudanças infraestruturais que a cidade esteve sujeita ao longo de todo esse processo, bem como mostra algumas consequências do péssimo desenvolvimento do projeto ao longo dos anos.

Gráfico 12: Diagrama de Sankey apresentado a variação das classes no P3.



Fonte: Representação feita pelo autor

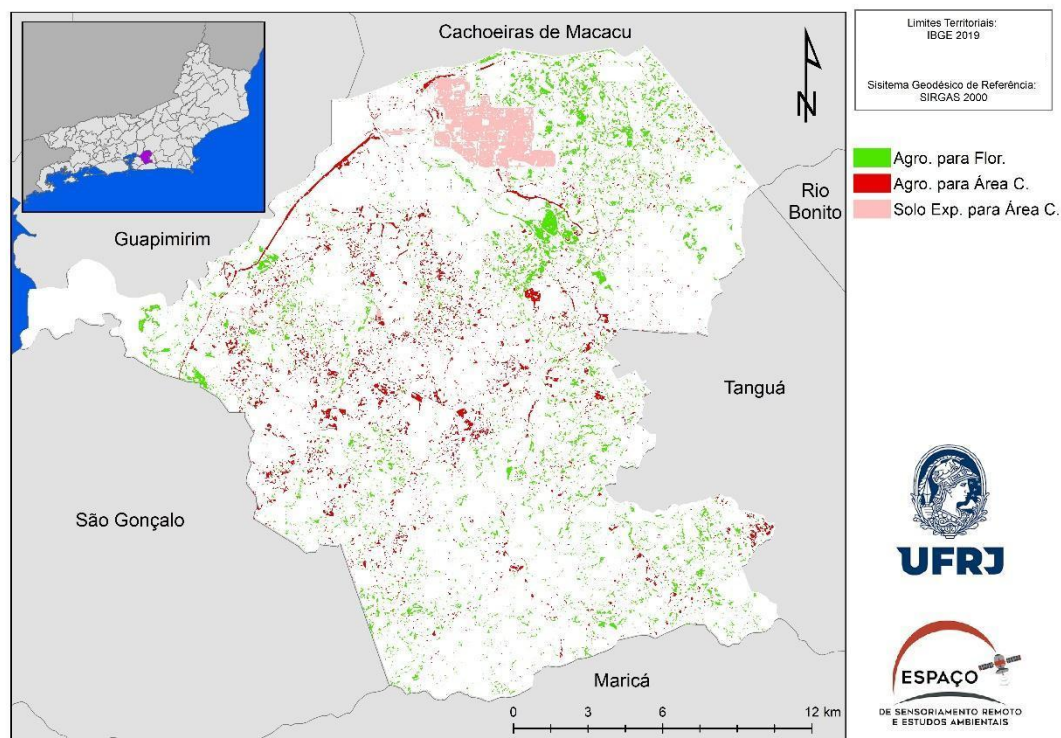
O gráfico 8 já apontava o crescimento da “Floresta” no município, e, por meio do Sankey, é possível identificar e confirmar que o crescimento da “Floresta” acontece majoritariamente sobre a classe “Agropasto”. Esse dado pode indicar o avanço da vegetação sobre áreas que estavam sendo preparadas para outro tipo de uso, bem como algumas políticas de conservação ambiental como já mencionado.

Entre 2011 e 2020 a “Floresta” teve um ganho de 25,17% (1966 ha) vindos apenas da classe do “Agropasto”. Consequentemente, o “Agropasto” perdeu parte de sua representatividade no município, 7,43% de sua área foi transformada em “Floresta”, a classe teve uma redução aproximada de 2054 ha de sua área foi reduzida em comparação ao ano de 2011.

“Área Construída” apresentou um crescimento de 28,37% (1966 ha), 1267 do “Agropasto” e 933 do “Solo Exposto”. Grande parte desse aumento se dá a construção da infraestrutura do COMPERJ e ao surgimento de algumas vias, para a locomoção de pessoas e equipamentos para o COMPERJ. Outra expansão, agora

associada ao aumento vindo do “Agropasto”, acontece novamente nas áreas centrais e agora mais intensamente em bairros próximos as vias que dão acesso ao COMPERJ. A figura 28 mostra a distribuição das principais variações nesse período.




Figura 28: Localização das principais variações do p3.



Fonte: Representação feita pelo autor

A abordagem seguinte da pesquisa buscou identificar o aumento da intensidade da “Área Construída” do município, composta majoritariamente por áreas urbanas. Por meio do recorte da classe “Área Construída” e a seleção de novas amostras (aproximadamente 30 amostras para cada uma das classes em cada um dos quatro anos), foi feita a subdivisão da “Área Construída”, buscando identificar os surgimentos de diferentes focos de expansão urbana ao longo do município, bem como o adensamento das áreas já consolidadas ao longo desse período. Os parâmetros foram os mesmos utilizados nas classificações de cada ano. A figura 29 mostra a divisão da “Área Construída” em “Área Construída Rarefeita”, “Área Construída Média” e “Área Construída Intensa”, as principais áreas onde são encontradas dentro do município e suas características.

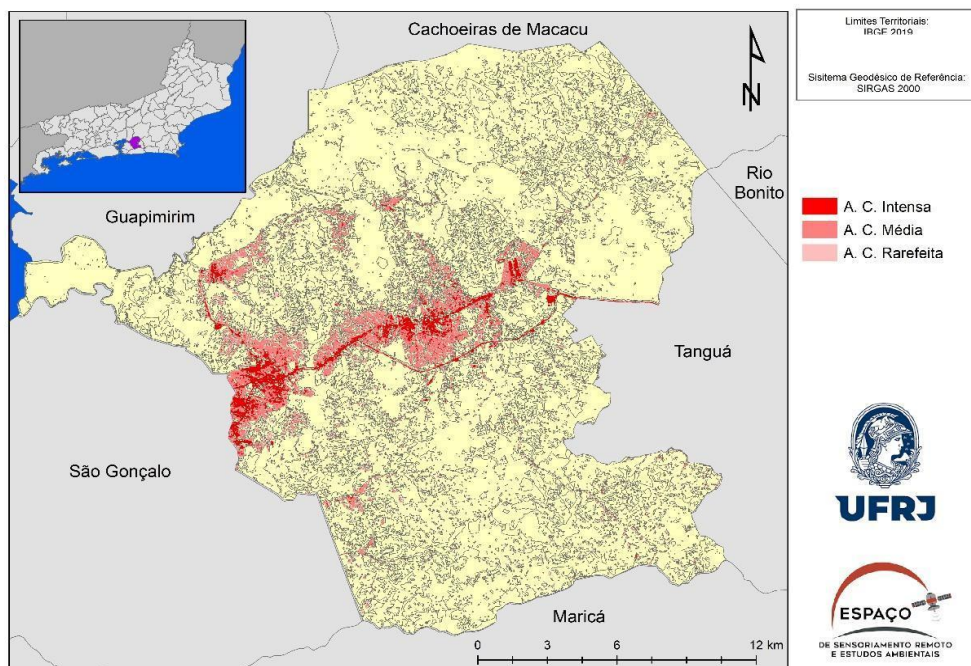
Figura 29: Amostras das intensidades da Área Construída.

<p>1. Área Construída Rarfeita</p>	<p>Poucas construções e espaçadas uma das outras. Grande presença de outras classes.</p>	
<p>2. Área Construída Média</p>	<p>Áreas pouco verticalizadas e com a presença de outras classes.</p>	
<p>3. Área Construída Intensa</p>	<p>Áreas densamente urbanizadas e verticalizadas.</p>	

Fonte: Representação feita pelo autor

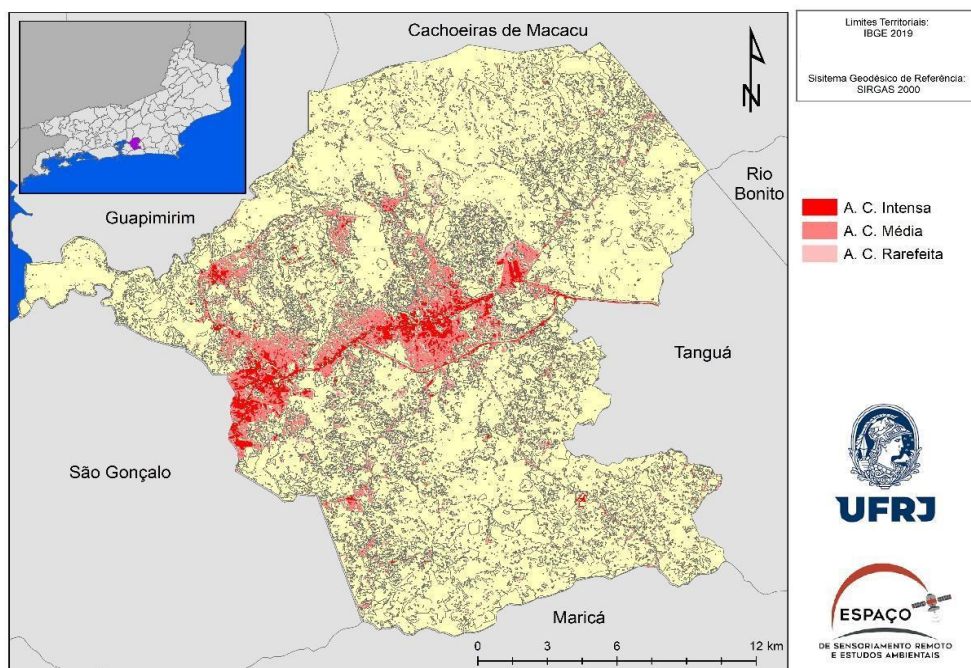
As figuras 30,31, 32 e 33 mostram a distribuição dessas classes ao longo do território municipal nos quatro anos do estudo.

Figura 30: Área Construída em 2005.



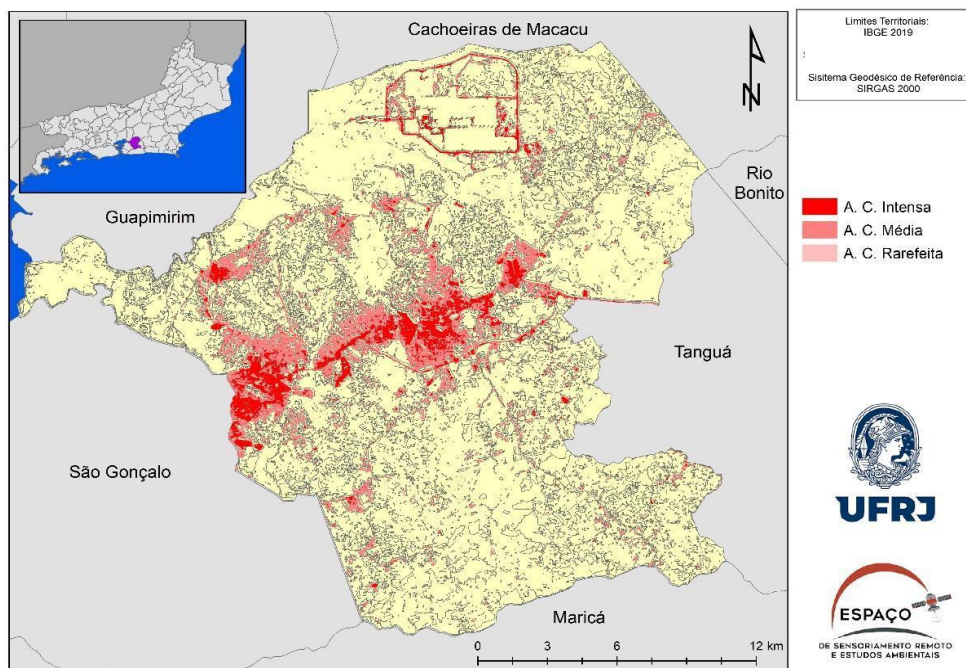
Fonte: Representação feita pelo autor

Figura 31: Área Construída em 2007



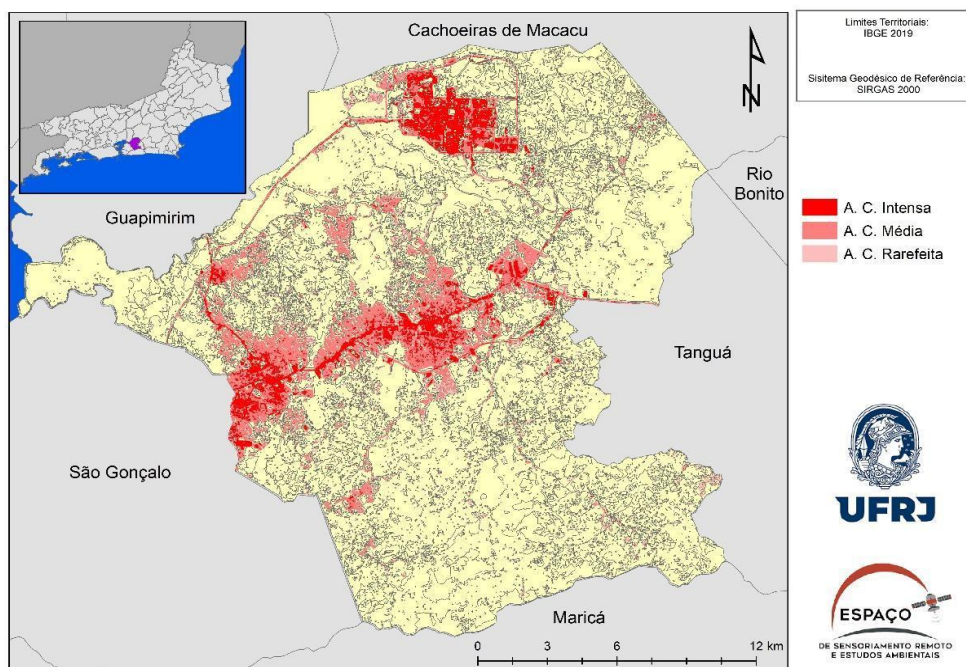
Fonte: Representação feita pelo autor

Figura 32: Área Construída em 2011



Fonte: Representação feita pelo autor

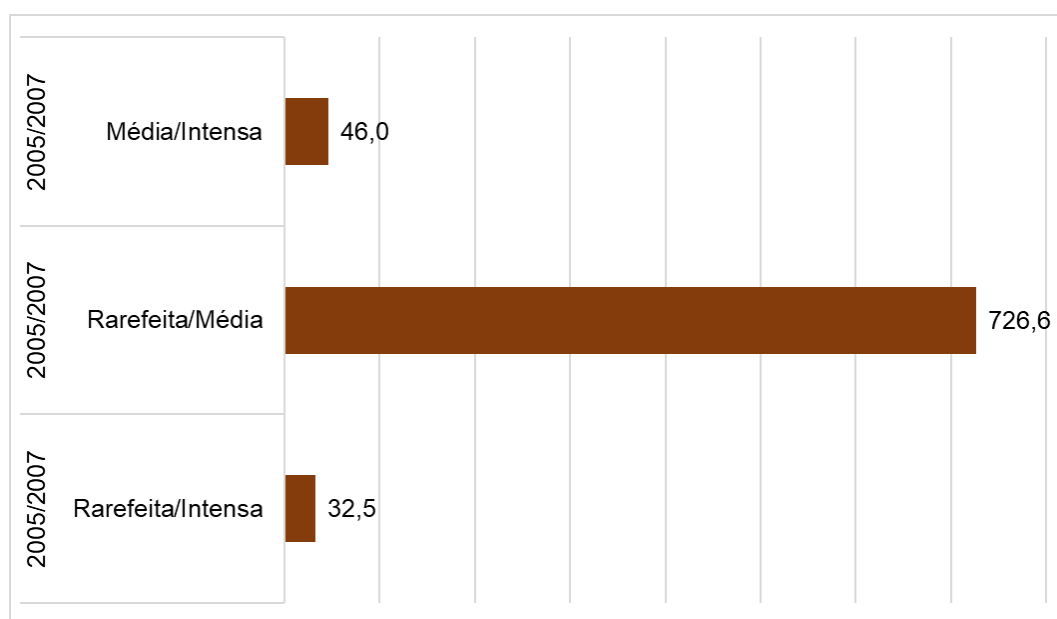
Figura 33: Área Construída em 2020.



Fonte: Representação feita pelo autor

A classe da “Área Construída” foi uma das que mais sofreu influência da especulação imobiliária e do fluxo de pessoas e capital destinados a atender a demanda do COMPERJ. O gráfico 13, quantificam em hectares a intensificação da Área Construída ao longo do primeiro período (2005 – 2007).

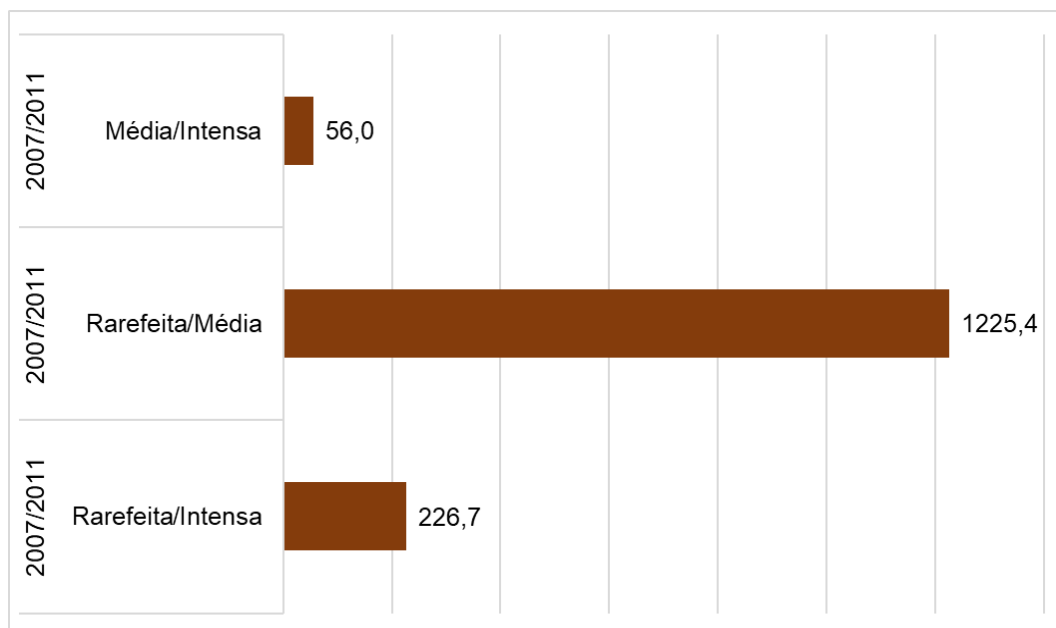
Gráfico 13: Variação da intensidade da Área Construída entre 2005 e 2007 em hectares.



Fonte: Representação feita pelo autor

O crescimento de 726,6 ha de “Área Construída Rarefaita” para “Área Construída Média” é o grande destaque desse período, que marca uma expansão inicial, fruto do anúncio do COMPERJ. O mesmo crescimento pode ser observado no segundo período (gráfico 14), no qual a “Área Construída Rarefaita” para “Área Construída Média” foi de 1225,4 ha.

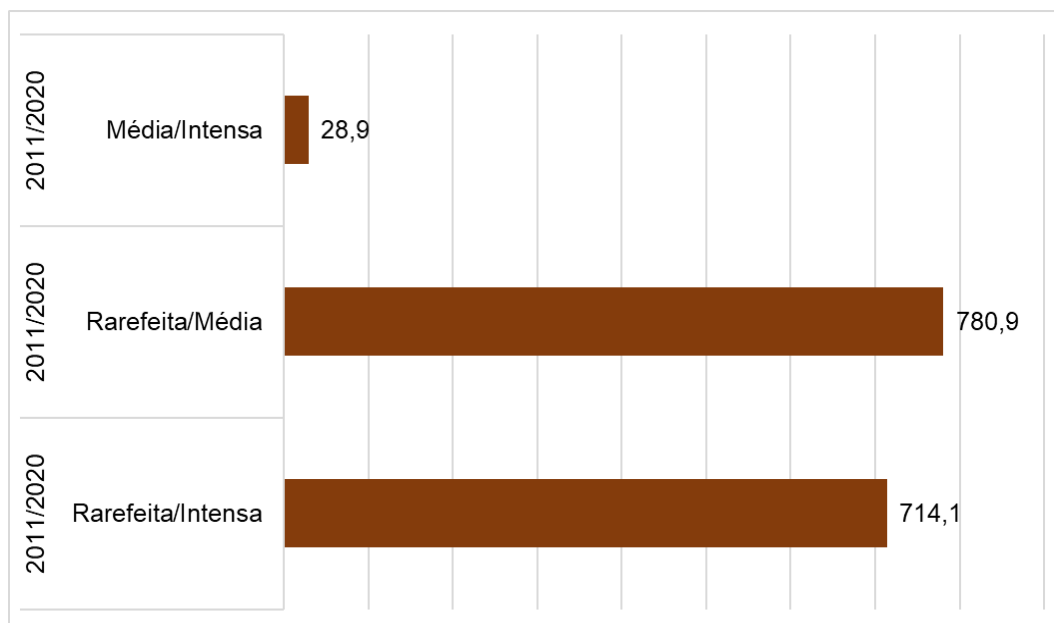
Gráfico 14: Variação da intensidade da Área Construída entre 2007 e 2011 em hectares.



Fonte: Representação feita pelo autor

O último período, por sua vez, continua a evidenciar o crescimento da “Área Construída Rarefeita” para “Área Construída Média”, 780,9 ha. No entanto, nesse que é o período mais extenso, parte da “Área Construída Intensa” teve uma expansão de 7.141ha, vindo da “Área Construída Rarefeita”. Essas informações podem ser observadas no gráfico 15.

Gráfico 15: Variação da intensidade da Área Construída entre 2011 e 2020 em hectares.



Fonte: Representação feita pelo autor

6.4. Conclusão

O objetivo deste capítulo foi desenvolver um algoritmo de classificação para Itaboraí, utilizando o algoritmo *RandomForest* e a plataforma *Google Earth Engine*. Para isso, foram utilizadas imagens de sensoriamento remoto pré-processadas dos anos de 2005, 2007, 2011 e 2020. A seleção dos parâmetros de classificação em conjunto com as amostras de treinamento foi eficiente nos testes de classificação e na construção dos modelos de aprendizado de máquina.

As avaliações, análises estatísticas, desempenho do algoritmo e exatidão temática revelaram que os modelos com 2000 árvores de decisão alcançaram altas taxas de acerto e estabilidade. Os testes de validação pós edição mostraram que as correções necessárias para aprimorar os mapeamentos foram inferiores a 10% da área total mapeada.

Os processamentos e testes realizados neste capítulo foram ágeis e acessíveis. A coleta de amostras exige do analista estudos prévios sobre a área de estudo e do fenômeno em questão. É importante ressaltar que, como é um método de aprendizado de máquina, alguns objetos exigirão avaliações e reajustes constantes nos modelos, o que afetará diretamente a amostragem.

Os resultados destacam o desempenho do processamento em nuvem e do uso de bibliotecas de código aberto, como o algoritmo *RandomForest*. O acesso gratuito à plataforma, a velocidade de processamento, a não necessidade de softwares ou hardwares específicos, a baixa demanda de armazenamento e a possibilidade de compartilhamento online dos resultados são contribuições importantes para a disseminação de informação.

Foram observadas variações significativas nas classes de Cobertura e Uso da Terra em Itaboraí. A classe de “Agropasto” permaneceu predominante, mas perdeu parte de sua área para a classe de “Área Construída” e variou em relação à “Floresta”. A “Área Construída” teve um aumento constante ao longo dos anos, apresentando um aumento significativo na intensidade da classe no município.

Embora os resultados possam requerer edições e pequenos ajustes, o algoritmo atingiu níveis de acurácia satisfatórios. A disponibilização do algoritmo para que pesquisadores possam aplicar em outras regiões, contribuirá com avanço do conhecimento e para a produção de mapeamentos cada vez mais precisos e completos.

7. CONSIDERAÇÕES FINAIS

As análises e resultados evidenciam que Itaboraí passou por um período significativo de transformações e mudanças. Atualmente, o município enfrenta incertezas em seu futuro. A injeção de investimentos ao longo dos últimos anos resultou em um aumento significativo na ocupação das áreas centrais da cidade por empreendimentos comerciais. Por sua vez, as áreas adjacentes se tornaram locais de habitação para pessoas que migraram em busca de oportunidades geradas por esses investimentos.

É possível observar que parte do que ocorreu em Itaboraí tem paralelos em outras cidades do estado do Rio de Janeiro, também influenciadas pela indústria do petróleo, e que enfrentaram sérios impactos sociais e ambientais. Esses impactos podem ser atribuídos, em parte, à falta de planejamento e despreocupação do governo em relação às questões que envolvem a população e o meio ambiente. Essa situação destaca a importância de um planejamento cuidadoso e de medidas sustentáveis para lidar com o desenvolvimento econômico e industrial em áreas sensíveis.

A evolução das técnicas de Aprendizado de Máquina, combinadas com o Processamento em Nuvem, disponível gratuitamente em plataformas de análises espaciais, proporcionou a capacidade de manipular grandes conjuntos de dados e processar imagens com custos reduzidos. O desenvolvimento dessas tecnologias aplicadas ao tratamento de dados de Sensoriamento Remoto aumentou significativamente a eficiência na produção de mapeamentos de Cobertura e Uso da Terra. Além disso, tornou-se cada vez mais viável realizar análises comparativas e estudos que envolvem múltiplos sensores e periodicidades. Essa abordagem está revolucionando a forma como compreendemos e monitoramos as mudanças na superfície terrestre.

O *Google Earth Engine* surgiu como uma plataforma que oferece uma abordagem flexível, rápida e automatizada para a análise das mudanças na Cobertura e Uso da Terra. Por meio do GEE, é possível testar quais algoritmos e sensores são mais adequados para representar as mudanças na Cobertura e Uso da Terra de forma mais precisa.

A primeira etapa envolveu a análise dos produtos gerados pelo MapBiomias, utilizando a classificação produzida pelo SEA/UFRJ. Os resultados obtidos sinalizam que o Mapa de Cobertura e Uso da Terra do Projeto MapBiomias, com um kappa de aproximadamente 60% quando comparado com o mapeamento realizado pelo SEA/INEA, não elimina a necessidade de se desenvolver uma classificação específica para Itaboraí. Apesar dessa constatação, é importante ressaltar que a iniciativa MapBiomias oferece um valioso conjunto de dados e serve como um ponto de referência crucial para análises espaciais. Além disso, ela instiga discussões importantes sobre a diversidade de usos e coberturas da terra presentes no Brasil, ao fornecer um extenso registro temporal e uma detalhada classificação temática.

Através das classificações realizadas, foi possível constatar que classe “Agropasto” permanece como a predominante no município. No entanto, esta classe sofreu variações determinantes que contribuíram para o aumento da representatividade de outras classes. Um exemplo disso é a classe “Floresta”, que experimentou as maiores variações em relação ao “Agropasto”. Durante o início do processo de implementação do COMPERJ, a classe “Floresta” perdeu parte de sua extensão, porém, ao longo dos anos a classe foi recuperando parte de sua representatividade em áreas de “Agropasto”.

A classe “Área Construída” apresentou o maior aumento em sua área total, e esse crescimento ocorreu de maneira progressiva. Grande parte dessa expansão teve origem na conversão de áreas de “Agropasto” e “Solo Exposto” em “Áreas Construídas”. O aumento da “Área Construída” é notável em áreas centrais, próximas à Avenida 22 de Maio, e em locais próximos às vias de acesso ao COMPERJ. O crescimento vertical e horizontal do município ocorreu principalmente nos bairros dos distritos de Itaboraí, Manilha e Itambi.

Os resultados obtidos nas classificações destacaram a eficácia da plataforma GEE em conjunto com o algoritmo *RandomForest*. A capacidade de compartilhar *scripts*, a baixa dependência de *softwares* secundários e o acesso gratuito tornam essa plataforma uma excelente ferramenta para disseminar as tendências e avanços no campo dos estudos geoespaciais.

Os objetivos estabelecidos para este trabalho foram plenamente alcançados, e os mapeamentos de Cobertura e Uso da Terra forneceram dados essenciais para identificar os principais usos do município de Itaboraí, bem como as mudanças significativas que ocorreram nessas classes ao longo dos últimos anos. A pesquisa

apresentou abordagens automatizadas e acessíveis, que têm o potencial de servir como base para futuras pesquisas relacionadas à Cobertura e Uso da Terra nos municípios do Leste Metropolitano. Além disso, essas informações podem ser valiosas para os órgãos de planejamento urbano e ambiental do município de Itaboraí.

REFERÊNCIAS

BIENESTEIN, R. et al. Urbanização nos municípios de São Gonçalo e Itaboraí: Impactos partir de um grande projeto regional. In: MODERNIZAÇÃO FRACASSADA: Dossiê COMPERJ. Rio de Janeiro: Editora: Consequência, 2018. p. 200.

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>>.

ARAUJO, E. C. RUFINO. W. B; A especialização do espaço na escala metropolitana–CONLESTE: Utopia ou uma forma de blindagem aos impactos do COMPERJ. III Encontro da Associação Nacional de Pesquisa e Pós-graduação em Arquitetura e Urbanismo, 12p (2014).

AUGUSTO, R. C. A Cartografia De Paisagens e a Perspectiva Geossistêmica Como Subsídios Ao Planejamento Ambiental. Revista Tamoios, v. 12, n. 1, p. 144–153, 2016.

BARANAUSKAS, J.A. Extração Automática de Conhecimento por Múltiplos Indutores. Tese apresentada ao Instituto de Ciências Matemáticas e de Computação - ICMC-USP. USP – São Carlos. São Paulo. 2001.

BAUMANN, P. ET AL. Big Data Analytics for Earth Sciences: The EarthServer Approach. International Journal of Digital Earth. 2015.

BERTRAND, Georges. Paisagem e geografia física global: esboço metodológico. Caderno de Ciências da Terra, n. 13, p. 1-27, 1971.

BLASCHKE, T.; GLASSER, C. & LANG, S. Processamento de Imagens num ambiente integrado SIG/Sensoriamento Remoto – Tendências e Conseqüências. In:Sensoriamento Remoto e SIG: novos sistemas sensores: métodos inovadores. (T.Blaschke & H. Kux, orgs.). São Paulo: Oficina de Textos, pp. 11-18. 2005.

BONAMIGO, A. F. C.B; OLIVEIRA, J. C; FIGUEIREDO, G. K. D. A; LAMPARELLI, R. A. C; CAMPBELL, E. E; SOARES, J. R; MONTEIRO, L. A; VIANNA, M. S; SHEEHAN, J. J; LYND, L. R. PLICAÇÃO DE FILTRO EM SÉRIES TEMPORAIS DE IMAGENS MODIS NA ANÁLISE DE MANEJOS DE PASTAGENS. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, 14 a 17 de Abril de 2019.

BREIMAN, L..Random forests. Machine learning Journal, 45(1), p. 5–32. 2001.

BROCKWELL, Peter J.; DAVIS, Richard A. (Ed.). Introduction to time series and forecasting. New York, NY: Springer New York, 2002.

CABRAL, C. Itaboraí e suas histórias. 2010.

- CÂMARA, G. et al. Introdução à ciência da geoinformação. INPE-SP, p. 345, 2001.
- 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.
- CASARIL, C. C; FRESCA, T. M. Verticalização urbana brasileira: histórico, pesquisadores e abordagens. *Revista Faz Ciência*. V. 9 n. 10 Jul/Dez 2007, pp. 169-190.
- COSTA, Evelyn de Castro Porto. Mapeamento do Uso e Cobertura da Terra nas unidades de conservação do Litoral Leste Fluminense– RJ. 2017. Monografia (Licenciatura em Geografia) – Faculdade de Formação de Professores, Universidade do Estado do Rio de Janeiro, 2017.
- COSTA, M. C. Plano de ação de emergência integrador: uma proposta com base no COMPERJ/CONLESTE. Tese (doutorado) – Universidade do Estado do Rio de Janeiro, 2013, 149f.
- 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.
- DE OLIVEIRA, Jeorge Luis Martins; DE CERQUEIRA NETO, Sebastião Pinheiro Gonçalves; DA SILVA, João Batista Lopes. Avaliação das mudanças no uso e ocupação do solo do Município de Eunápolis-BA através da análise da eficiência dos índices espectrais de NDVI, NDBI e Built-Up. *Brazilian Journal of Development*, v. 7, n. 9, p. 87529-87544, 2021.
- 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
- Duarte, V., Shimabukuro, Y. E., Rudorff, B. F. T., Moreira, M. A., & Sbruzzi, R. S. (2004). Mapeamento da vegetação do estado de São Paulo, por meio do uso do sensoriamento remoto e geoprocessamento. São José dos Campos: INPE.
- EMBRAPA: PE / PV / PVA. Disponível em: <<https://www.embrapa.br/agencia-de-informacao-tecnologica/tematicas/bioma-cerrado/solo/tipos-de-solo/pe-/pv-/pva>> Acesso em: 25 de set. 2022
- FIGUEIREDO, Divino. Conceitos básicos de sensoriamento remoto. São Paulo, 2005.
- FILHO, J. C. G. O ARCO RODOVIÁRIO METROPOLITANO COMO ELEMENTO DE REESTRUTURAÇÃO DO ESPAÇO FLUMINENSE. UFRRJ: *Revista Continentes*, v. 2, n. 2, p. 147–163, 2013.

FIRJAN. Avaliação dos Impactos Logísticos e Socioeconômicos da Implantação do Arco Metropolitano do Rio de Janeiro. p.89, 2008.

FITZ, P. R. Geoprocessamento sem complicação. São Paulo: Oficina de Textos, 160 p. 2008.

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

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.

GIANNOTTI, M. Laboratórios didáticos de Geoprocessamento Google Earth Engine: aquisição de imagens de satélite. Poli-Usp: LabGeo, pág. 1 – 21, 2019.

Google Earth Engine: Planetary - scale Geospatial Analysis for everyone. Remote Sensing of Environment. V. 202. P.18-27. 2017.

GORELICK, N., HANCHER, M., DIXON, M., ILYUSCHENKO, S., THAU, D., MOORE, R. Google Earth Engine: Planetary - scale Geospatial Analysis for everyone. Remote Sensing of Environment. V. 202. P.18-27. 2017.

HOLLOWAY, J; MENGERSEN, K. Statistical Machine Learning Methods and Remote Sensing for Sustainable Development Goals: A Review. School of Mathematical Sciences. 2018.

IBGE. Instituto Brasileiro de Geografia e Estatística. Censo Demográfico 2010. Disponível em: <https://censo2010.ibge.gov.br/>. Acesso em Outubro de 2020.

IBGE. Instituto Brasileiro de Geografia e Estatística. Manual Técnico de Uso da Terra. Manuais Técnicos em Geociências. no 7, 3º edição. Rio de Janeiro. 2013.

IBGE: CIDADES. Disponível em: <<https://cidades.ibge.gov.br/>> Acesso em: 18 de set. de 2019.

LACERDA, Eduardo Ribeiro; VICENS, Raúl Sánchez. ALGORITMO PARA COMPOSIÇÃO DE SÉRIES TEMPORAIS LANDSAT PARA DETECÇÃO DE MUDANÇAS EM COBERTURAS AGRÍCOLAS. Anais do XIX simpósio brasileiro de sensoriamento remoto, pág. 2682 – 2685, 2019

LANG, S.; BLASCHKE, T. Análise da paisagem com SIG. São Paulo: Oficina de Textos, 2009.

LI, M., IM, J., BEIER, C. Machine learning approaches for forest classification and change analysis using multi-temporal Landsat TM images over Huntington Wildlife Forest. GIScience & Remote Sensing. Vol. 50, No. 4, p. 361–384. 2013.

LI, S., DRAGICEVIC, S., CASTRO, F.A., SESTER, M., WINTER, S., COLTEKIN, A., PETIT, C., JIANG, B., HAWORTH, J., STEIN, A., CHENG, T. Geospatial big data

handling theory and methods: A 164 review and research challenges. *SPRS Journal of Photogrammetry and Remote Sensing*. 115, p. 119–133. 2015.

LIAW, A., WIENER, M. Classification and regression by randomForest. *R News*, 2(3), pp.18-22. 2002.

LIMA, E. M. B. Caracterização geoambiental de áreas antropizadas no Município de Itaboraí - Rio de Janeiro /Edla Maria Bezerra Lima... [et al.]. _ Rio de Janeiro: Embrapa Solos, 2000.

LIU, Yanli; WANG, Yourong; ZHANG, Jian. New machine learning algorithm: Random forest. In: *Information Computing and Applications: Third International Conference, ICICA 2012, Chengde, China, September 14-16, 2012. Proceedings 3*. Springer Berlin Heidelberg, 2012. p. 246-252.

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.

MapBiomias. Disponível em: < <https://mapbiomas.org/>> Acesso em: 18 de set. de 2023.

MapBiomias: ESTIMATIVAS DA ACURÁCIA DO MAPEAMENTO DA COBERTURA DA TERRA PELO PROJETO MAPBIOMAS. Disponível em: <<https://brasil.mapbiomas.org/analise-de-acuracia/>> Acesso em: 18 de ago. de 2023.

MASEK, Jeffrey G. et al. A Landsat surface reflectance dataset for North America, 1990-2000. *IEEE Geoscience and Remote sensing letters*, v. 3, n. 1, p. 68-72, 2006.

MAXWELL, A.E., WARNER, T.A., FANG, F. Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing*. Volume 39, Issue 9. 2018.

MENESES, P. R.; ALMEIDA, T. DE. Introdução ao processamento de imagem de sensoriamento remoto. Brasília: Cnpq/Unb, p. 266, 2012.

MENEZES, P. M. L., NETO, A. L. C. Escala: estudo de conceitos e aplicações. UFRJ. 1999.

MENEZES, P.M.L. A interface Cartografia-Geoecologia nos estudos diagnósticos e prognósticos da paisagem: um modelo de avaliação de procedimentos analíticointegrativos. Tese de Doutorado, Programa de Pós-Graduação em Geografia, Depto. de Geografia, IGEO/UFRJ, 208 f., 2000.

MOISES, Y. DOS S. O COMPERJ: MODELO DE DESENVOLVIMENTO HEGEMÔNICO E CONTRADIÇÕES NO ESPAÇO LOCAL (ITABORAÍ, RIO DE JANEIRO) THE COMPERJ : MODEL OF HEGEMONIC MODERNIZATION AND CONTRADICTIONS IN LOCAL AREA (ITABORAÍ , RIO DE JANEIRO). UFPR: *Revista Geografar*, v. 5, n. 1, p. 24, 2010.

MOYSES, Y.dos S. Desenvolvimento Sustentável?.Modernização fracassada: Dossiê COMPERJ. Rio de Janeiro: Consequência/FAPERJ, 2018. Pp. 151-188

NASCIMENTO, E; MATIAS, L. F. EXPANSÃO URBANA E DESIGUALDADE SOCIOESPACIAL:UMA ANÁLISE DA CIDADE DE PONTA GROSSA (PR)RAÉ GA23 (2011), p. 65-97.

NOVO, E. M. L. DE M.; PONZONI, F. J. INTRODUÇÃO AO SENSORIAMENTO REMOTO.São José dos Campos: [s.n.], p. 68, 2001. review and research challenges. SPRS Journal of Photogrammetry and Remote Sensing. 115, p. 119–133. 2015.

NUNES JÚNIOR, E. et al. O USO DO SOFTWARE VICON/SAGA/UFRJ NO GERENCIAMENTO DE INFORMAÇÕES GEOMORFOLÓGICAS DO PARQUE PALEONTOLÓGICO DE SÃO JOSÉ DE ITABORAÍ E SEU ENTORNO. In: SIMPÓSIO NACIONAL DE GEOMORFOLOGIA E À REGIONAL CONFERENCE ON GEOMORPHOLOGY. 2006.

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.

OLIVEIRA, S. S. T. Explorando Paralelismo em Big Data no Processamento de Séries Temporais de Imagens de Sensoriamento RemotoTese (Doutorado) - Universidade Federal de Goiás, Instituto de Informática (INF), Programa de Pós-Graduação em Ciência da Computação em rede (UFG/UFMS), Goiânia, 2019.

PEREIRAA, P. R. M., DE OLIVEIRA, M. M. N., BOLFE, E. L., MACARRINGUE, L. S. (2023). COMPARAÇÃO DA CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA EM IMAGENS LANDSAT-8 E SENTINEL-2 NO CERRADO MARANHENSE. Geo UERJ, (42), 66306.

Petrobrás: Polo GásLub Itaboraí: Disponível em: < <https://petrobras.com.br/quem-somos/polo-gaslub-itaborai>> Acesso em: 13 de jun. 2023

Plano-Diretor-de-Desenvolvimento-Integrado-do-Municipio-de-Itaborai Disponível em: <[https://www.itaborai.rj.gov.br/wp-content/uploads/2019/11/01-Plano-Diretor-de-Desenvolvimento-Integrado-do-Municipio-de-Itaborai-\(com-anexos\).pdf](https://www.itaborai.rj.gov.br/wp-content/uploads/2019/11/01-Plano-Diretor-de-Desenvolvimento-Integrado-do-Municipio-de-Itaborai-(com-anexos).pdf)> Acesso em: 04/02/2022

PROJETO MAPBIOMAS. Coleção 4.0 da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil. Disponível em: <https://mapbiomas.org/download>. Acesso em 1 dez. 2019.

REIS, Cláudio Henrique; SÉRGIO, Mauro; ARGENTO, Fernandes. Caracterização espacial do Uso da Terra em áreas de manguezais utilizando diferentes sistemas orbitais–Um caso aplicado aos manguezais da APA–Guapimirim-RJ. Rio de Janeiro, v. 148, 2007.

RIMA. COMPERJ. p. 153, 2007.

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

ROBERTO, D.M. DIAGNÓSTICO DA HIDROGRAFIA ESTAÇÃO ECOLÓGICA DA GUANABARA E REGIÃO. Maio 2009.

SALANDIA, L. V. A implantação do COMPERJ e os desafios da gestão. MODERNIZAÇÃO FRACASSADA: Dossiê COMPERJ. Rio de Janeiro: Consequência, 2018. p. 200.

SEA / INEA. Projeto de Mapeamento da Cobertura da Terra e de Detecção de Mudanças na Cobertura Florestal do Estado do Rio de Janeiro. Fundação COPPETEC - Laboratório Espaço de Sensoriamento Remoto e Estudos Ambientais. Rio de Janeiro. 2018.

SHIRATSUCHI, Luciano Shozo et al. Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. Bernardi, ACC; Naime, JM; Resende, AV; Bassoi, LH, p. 58-73, 2014.

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.

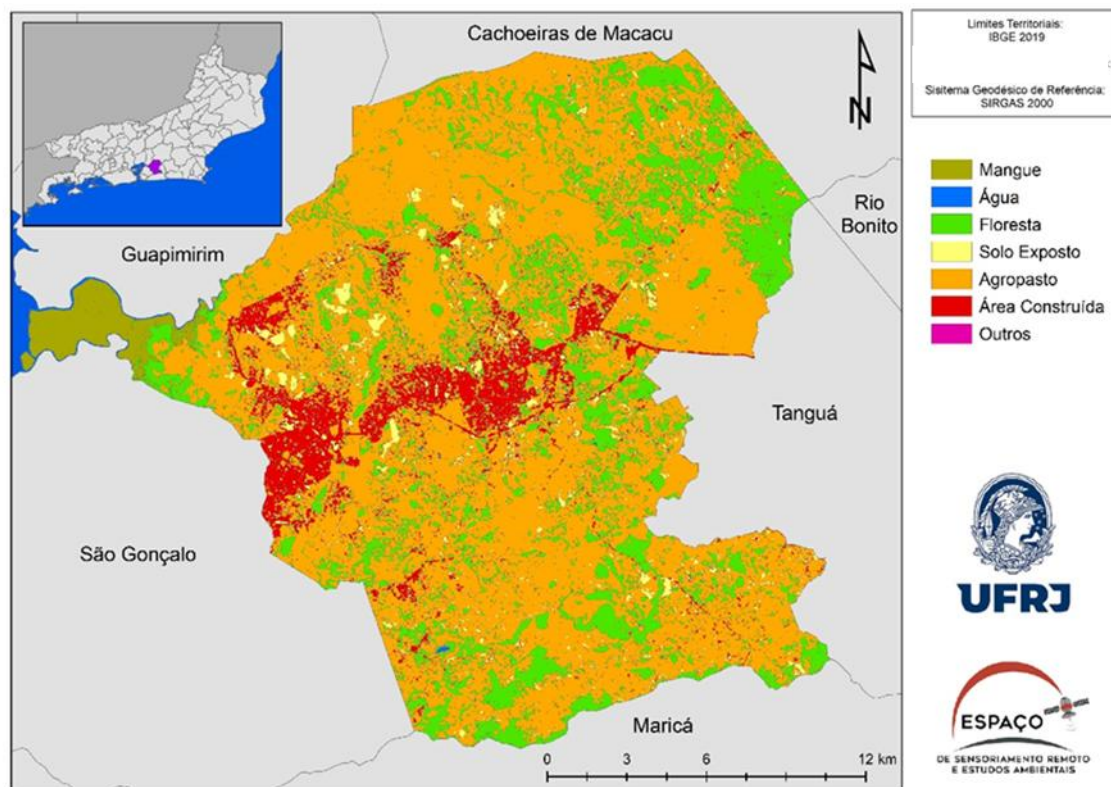
SILVA, T. M. da; CALDEIRA, C. R. T.; CALDEIRA, M. C. O.; BALIEIRO, C. P. P.; FERREIRA, M. E. Classificação de uso e cobertura da terra e o monitoramento de áreas em restauração florestal por RPAS. Revista Cerrados, [S. l.], v. 19, n. 01, p. 84–112, 2021.

TINOCO, V: ARCO METROPOLITANO DO RIO DE JANEIRO. Revista Continentes (UFRRJ), ano 8, n. 14, 2019 (ISSN 2317-8825), 2019: 94-117.

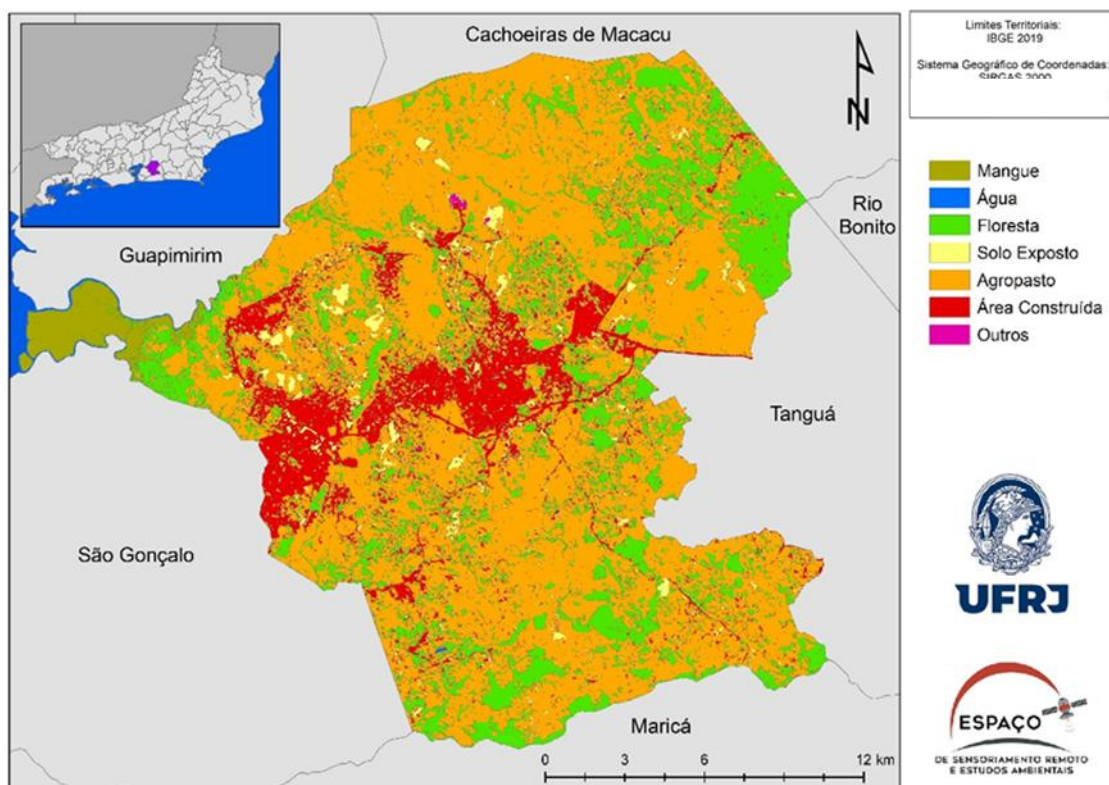
VIEIRA, M. C; BORGES, M. M. S, VIRGINIO, J. S. Perspectivas sobre a dinâmica industrial produtiva no Leste Metropolitano do Rio de Janeiro. XX ENANPUR 2023 – BELÉM 23 A 26 DE MAIO, 2023.

Anexo - Mapas de Uso e Cobertura da Terra dos anos de 2006, 2007, 2011 e 2020 (Sentinel-2 e Landsat-8). (Capítulo 2)

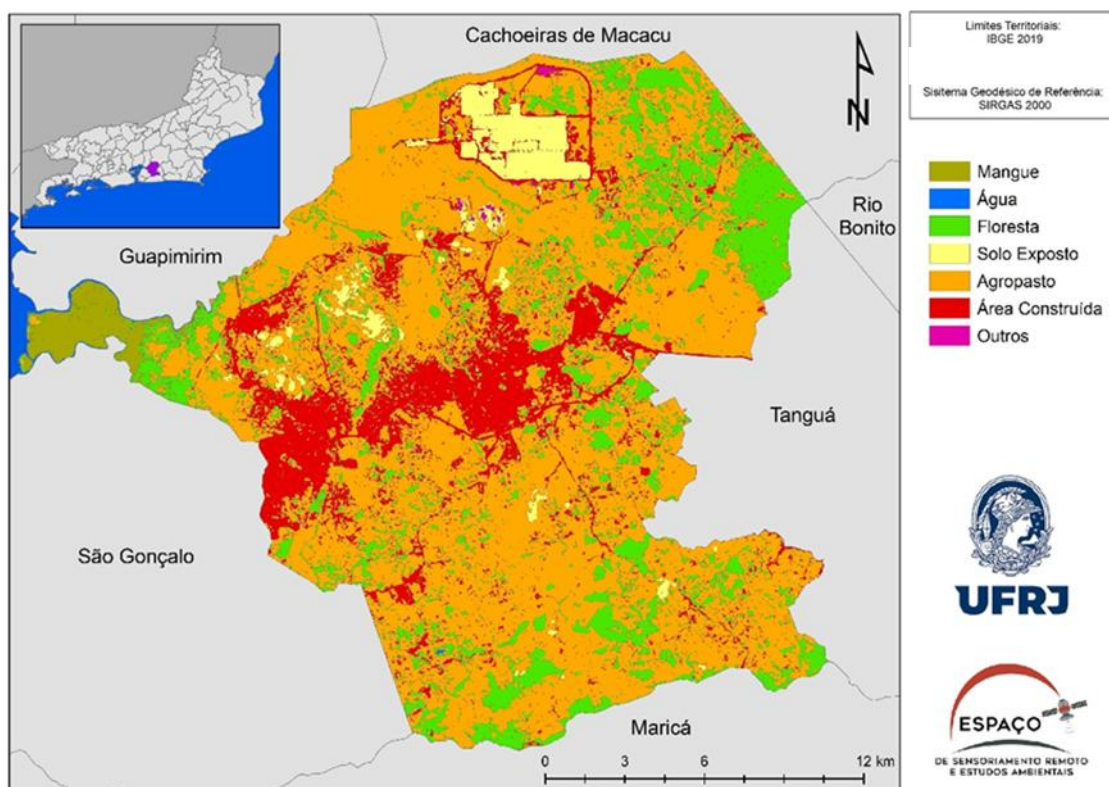
Mapa de Cobertura e Uso da Terra de 2005



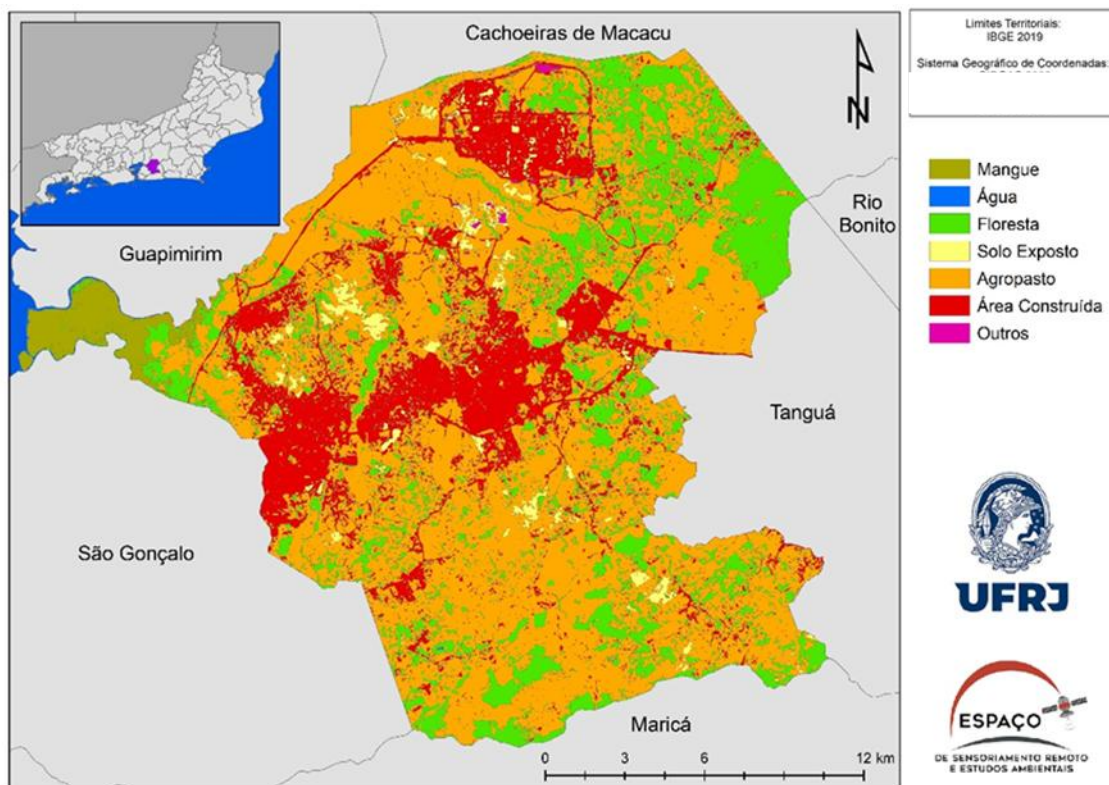
Mapa de Cobertura e Uso da Terra de 2007



Mapa de Cobertura e Uso da Terra de 2011



Mapa de Cobertura e Uso da Terra de 2020



Mapa de Cobertura e Uso da Terra de 2020 com a progressão da floresta e da Área Construída.

