



Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Mapeamentos Nacionais e Globais da Cobertura e Uso da Terra no Geoparque Mundial da UNESCO Caminhos dos Cânions do Sul: *Conceitos, Metodologias e Tendências.*

Fábio Corrêa Didoné¹, Jairo Valdati², Sidney Geraldo Silveira Velloso³

¹Mestrando em Planejamento Territorial e Desenvolvimento Socioambiental, Universidade do Estado de Santa Catarina (UDESC), Brasil, fcddidone@gmail.com, ORCID: <https://orcid.org/0009-0005-5845-9396>; ² Professor do Departamento de Geografia, Universidade do Estado de Santa Catarina (UDESC), Brasil, jairo.valdati@udesc.br, ORCID: <https://orcid.org/0000-0002-7559-5315>, ³ Tecnologista em Informações Geográficas e Estatísticas em Instituto Brasileiro de Geografia e Estatística (IBGE), Brasil, sidney.velloso@ibge.gov.br, ORCID <https://orcid.org/0000-0001-8936-4027>

Artigo recebido em 07/04/2025 e aceito em 09/12/2025

RESUMO

O mapeamento da cobertura e uso da terra delinea diferentes tipologias e arranjos da atividade humana e do meio ambiente. A forma de mapeamento da cobertura e uso da terra está em constante mudança, partindo dos levantamentos de campo e fotointerpretação de imagens à classificação de imagens de satélite por algoritmos. Este trabalho pretende analisar diferentes mapeamentos, em particular os de abrangência nacional ou global. Objetiva-se, através da exploração dos conceitos relacionados à cobertura e uso da terra e da seleção e análise de mapeamentos, entender as semelhanças e diferenças entre os métodos utilizados. A metodologia constituiu-se de pesquisa bibliográfica e da espacialização de mapeamentos na área do Geoparque Mundial da UNESCO Caminhos dos Cânions do Sul. Os mapeamentos analisados foram o Mapeamento da Vegetação do Brasil, O Monitoramento da Cobertura e Uso da Terra, o MapBiomass, o mapeamento ESA-CCI e o mapeamento ESRI. Os resultados mostraram os conceitos relacionados à cobertura e uso da terra, bem como a tendência do mapeamento de grandes áreas por classificação de imagens por meio de algoritmos em detrimento da fotointerpretação e do levantamento de campo. Os resultados evidenciam as diferenças entre os sistemas de classificação e as metodologias dos mapeamentos. Entretanto, através da harmonização de classes, identificou-se semelhanças na cobertura e uso da terra. Por fim, em virtude da menor exigência de recursos e do avanço tecnológico, notou-se que os mapeamentos recentes se amparam em novos algoritmos, em novas formas de acesso às imagens e novas técnicas de processamento de dados.

Palavras-Chave: Cobertura e Uso da Terra, Meio Ambiente, Geoparque

National and Global Land Cover and Land Use Mapping in UNESCO Global Geopark Caminhos dos Cânions do Sul: *Concepts, Methodologies, and Trends*

ABSTRACT

Land cover and land use (LCLU) maps delineate various typologies and arrangements of human activity and the environment. The methods of LCLU mapping are constantly evolving, ranging from field surveys and photointerpretation to satellite image classification using algorithms. The objective of this study is to analyse different LCLU maps, in particular those with national or global coverage. This study aims to understand the similarities and differences between the methods employed in LCLU maps by exploring concepts related to LCLU and the selection and analysis of the relevant LCLU maps. The methodology consisted of bibliographic analysis and the spatial analysis of LCLU maps for the Caminhos dos Cânions do Sul UNESCO Global Geopark. The LCLU maps analysed were the Vegetation Mapping of Brazil, the Monitoring of Land Cover and Land Use, MapBiomass, ESA-CCI mapping, and ESRI mapping products. The results obtained showed the concepts related to LCLU, as well as the trend of mapping large areas by satellite image classification by algorithms rather than photointerpretation and field surveys. The results highlighted the differences between classification systems and methodologies; however, through class harmonization, similarities were identified in the LULC. Finally, due to the lower resource requirements and continuous technological advancement, it was noted that recent LCLU maps rely on new algorithms, new forms of image access, and new techniques of data processing.

Key words: Land Cover and Land Use, Environment, Geopark

Introdução

O meio ambiente está em constante transformação. Essa transformação, em sua maioria, é causada pela interação do homem com a natureza (Mora *et al.*, 2018). Uma forma de melhorar o entendimento dessa interação e suas consequências é através do estudo da paisagem (Verdum, 2016). O mapeamento da cobertura e uso da terra permite delimitar áreas com características semelhantes, com a finalidade de melhorar a compreensão da forma e da distribuição das interações entre o meio ambiente e o ser humano (Instituto Brasileiro de Geografia e Estatística [IBGE], 2017).

Os dados de cobertura e uso da terra são usados como base em vários programas e estudos. Destaca-se o uso desses dados no monitoramento ambiental (Mashala *et al.*, 2023), nas análises das mudanças climáticas (Burrell *et al.*, 2020), na conservação da biodiversidade (Wu *et al.*, 2021), no planejamento territorial (Capoane & Fushimi, 2023), na prevenção e gerenciamento de desastres naturais (Rahman *et al.*, 2021), na segurança alimentar (Prävälje *et al.*, 2021) e no controle de epidemias (Diuk-Wasser *et al.*, 2021).

Existem várias metodologias para o mapeamento da cobertura e uso da terra. Inicialmente, os mapeamentos eram realizados através de levantamentos de campo e por meio da coleta de dados estatísticos (Loveland, 2016). Entretanto, essas metodologias, apesar de precisas, eram lentas e consumiam muitos recursos.

O avanço da tecnologia fez com que a classificação da cobertura e uso da terra sofresse uma renovação (Vali *et al.*, 2020). O mapeamento por meio da classificação de dados de sensoriamento remoto como imagens de radar, aerofotos e imagens de satélite ganhou espaço à medida que a aquisição desses dados ficou mais acessível (Wang *et al.*, 2023). A interpretação visual das imagens junto com expedições a campo é capaz de produzir mapeamentos de cobertura e uso da terra com ótima acurácia, porém, esses métodos podem ser inviáveis em mapeamentos nacionais ou globais (Loveland, 2016).

Novos insumos e tecnologias surgiram para auxiliar no mapeamento da cobertura e uso da terra. O avanço dessas tecnologias trouxe novos algoritmos de classificação capazes de mapear a cobertura e uso de forma rápida e eficaz. Os mapeamentos gerados por algoritmos ganharam espaço, tornando-se a principal forma de mapeamento atualmente (Rong & Fu, 2023).

Os estudos que buscam realizar o mapeamento da cobertura e uso da terra possuem características próprias como metodologia, resolução temporal, abrangência e objetivos. O conhecimento

dos mapeamentos, das metodologias utilizadas e dos conceitos empregados torna-se importante para o entendimento da cobertura e uso da terra e para a escolha da melhor base de dados (Wang *et al.*, 2023).

Neste artigo, analisou-se os diversos conceitos e a evolução dos métodos de mapeamento na área de cobertura e uso da terra. O objetivo do trabalho é investigar as diferentes formas e metodologias para o mapeamento da cobertura e uso da terra de abrangência nacional ou global. Além disso, busca-se apontar os mapeamentos mais relevantes atualmente por meio da sua espacialização e comparação em uma área de estudo.

Material e métodos

Área de estudo

A Organização das Nações Unidas para Educação, Ciência e Cultura (UNESCO) implantou o programa Geoparques Mundiais da UNESCO em 2015. Esse programa surge como uma iniciativa para preservar áreas com geologia de relevância internacional. Os pilares do programa são a gestão holística do território, a educação, o desenvolvimento sustentável e o manejo de “baixo para cima” (UNESCO, 2015).

A área de estudo deste trabalho é o Geoparque Mundial da UNESCO Caminhos dos Cânions do Sul (GMUCCS). O GMUCCS está localizado no extremo sul do estado de Santa Catarina e no nordeste do estado do Rio Grande do Sul. O GMUCCS abrange sete municípios, sendo eles: Morro Grande, Timbé do Sul, Jacinto Machado e Praia Grande em Santa Catarina, e Cambará do Sul, Mampituba e Torres no Rio Grande do Sul. A Figura 1 mostra a localização da área.

O GMUCCS foi chancelado como Geoparque Mundial da UNESCO em 2022. Ele possui um relevo diverso, sendo constituído por compartimentos de relevo como Serra, Patamares, Planícies e Planaltos (IBGE, 2019). Escolheu-se o GMUCCS como área de estudo, pois a sua diversidade de relevo e a sua relevante geologia permitem analisar os mapeamentos da cobertura e uso da terra em diversas paisagens.

Metodologia

Primeiramente, foram realizadas revisões bibliográficas a fim de identificar os principais conceitos empregados na área de classificação da cobertura e uso da terra, bem como apontar os principais mapeamentos. As informações obtidas foram organizadas e catalogadas, buscando entender o desenvolvimento dessa área do conhecimento.

Posteriormente, os conceitos, as metodologias e os insumos foram estruturados em forma de tópicos e textos. As principais tendências na

área de cobertura e uso da terra foram identificadas com base na análise de trabalhos de revisão sistemática.

Por fim, foram identificados e selecionados mapeamentos relevantes de cobertura e uso da terra. Buscou-se selecionar mapeamentos com abrangência nacional ou global e com diferentes metodologias e insumos. Foram produzidos mapas de cobertura e uso

da terra a partir de cada mapeamento para o GMUCCS e calculadas as porcentagens de área ocupadas por cada classe. Os mapas foram produzidos pela intersecção dos mapeamentos, em vetor ou em *raster*, com o limite territorial do GMUCCS. Concluiu-se com uma proposta de harmonização entre algumas classes, permitindo a comparação entre os mapeamentos.




Figura 1: Localização do Geoparque Mundial da UNESCO Caminhos dos Cânions do Sul.

Resultados e discussão

Cobertura e uso da terra

“Uma das formas de representar e analisar o processo de ocupação do território é espacializar e contabilizar, de forma sistemática e periódica, as alterações ocorridas na cobertura e uso da terra” (IBGE, 2020, p. 24). “O levantamento da cobertura e uso da terra indica a distribuição geográfica da tipologia de uso, identificada por meio de padrões homogêneos da cobertura terrestre” (IBGE, 2013, p. 36). Espera-se que os levantamentos da cobertura e uso da terra forneçam informações do território ao maior número possível de usuários, em várias escalas, de tal forma que possam ser comparadas entre si e periodicamente atualizadas (IBGE, 2017). Os mapeamentos de cobertura e uso da terra podem subsidiar vários estudos, como o “planejamento territorial, passando por avaliação de impactos ambientais, estimativa de emissão e remoção dos

gases do efeito estufa e produção de indicadores relacionados aos objetivos do desenvolvimento sustentável (ODS)” (IBGE, 2020, p. 24).

Os elementos da cobertura e uso da terra são muitas vezes combinados, porém eles são termos conceitualmente diferentes (Giri, 2016). A terra pode ser entendida de várias formas, como um substantivo próprio, representando um planeta do sistema solar; como uma porção da superfície da crosta terrestre; como um substrato natural; como um ativo ambiental; ou, em sentido simbólico, como um lugar de nascimento, que dá identidade a um grupo social (IBGE, 2022a). No mapeamento de cobertura e uso da terra, ela pode ser entendida como um substrato que dá suporte aos diversos usos e coberturas, bem como uma porção da crosta terrestre (Nações Unidas, 2016). A terra pode ser classificada, também, de várias formas, não apenas através de sua cobertura e uso. As outras formas de classificação da terra

incluem, por exemplo, o zoneamento institucional e a posse da terra.

O uso da terra reflete como ela é ocupada e utilizada pelos seres humanos, suas instituições e seus arranjos (Giri, 2016). É possível que uma área tenha diversos usos, como, por exemplo, os corpos d'água, que podem ter uso recreacional, pesqueiro e de abastecimento. Entretanto, nem toda a terra está em uso, pois é necessária uma ação humana de gestão ou de proteção, ou uma ação institucional para definir a finalidade de uso daquela área (Nações Unidas, 2016). Uma área de vegetação natural, por exemplo, tem como uso definido a manutenção e conservação das funções ambientais, apenas se houver um arranjo institucional que a defina dessa forma, como através da criação de uma unidade de conservação ou da averbação da área. Não obstante, inclui-se no mapeamento de uso da terra tanto as áreas em uso como as áreas sem uso. (Nações Unidas, 2016).

A cobertura da terra caracteriza a cobertura física e biológica observada na superfície terrestre, sendo ela a vegetação natural e as superfícies abióticas (Gribb & Czerniak, 2018). A cobertura da terra foca nos tipos de material presentes na área sem, necessariamente, levar em consideração o tipo de uso pelo ser humano.

É possível que o uso seja associado a várias coberturas da terra e vice-versa. Por exemplo, uma área com uso de silvicultura pode ser associada com classes de cobertura de vegetação herbácea, vegetação florestal ou área exposta, de acordo com o seu ciclo de produção. Já áreas de cobertura herbáceas podem estar associadas a usos como agricultura, pastagem ou parques urbanos. A cobertura e uso estão interconectadas e ambas trazem informações importantes. A maioria dos trabalhos realizam um mapeamento híbrido, incluindo a cobertura e o uso da terra na sua classificação (Glimskär & Skånes, 2018).

As vantagens da utilização de dados de cobertura e uso da terra são variadas. Cita-se, aqui, a possibilidade de representação espacial da superfície terrestre, permitindo a identificação das classes de cobertura e uso e dos seus padrões em diferentes escalas (IBGE, 2022a) e a possibilidade do monitoramento ambiental através da análise das mudanças na cobertura e uso da terra (Mashala *et al.*, 2023). Todavia, entre as limitações na utilização dos dados de cobertura e uso da terra, destaca-se a simplificação da superfície terrestre em classes de cobertura e uso que podem não refletir a realidade, acarretando a perda de informações importantes (Jansen, 2018), bem como a possibilidade de erros nos mapeamentos devido a decisões subjetivas e inconsistências metodológicas (Liu *et al.*, 2021).

Princípios e características do mapeamento da cobertura e uso da terra

O IBGE (2013) elenca quatro princípios a serem observados no mapeamento da cobertura e uso da terra, sendo eles: a escala do mapeamento, a natureza da informação básica, a unidade de mapeamento e a nomenclatura das classes.

A escala cartográfica seria a relação entre as distâncias no mapa e as distâncias na superfície que o mapa representa, ou seja, no mundo real (Dabiri & Blaschke, 2019). A sua escolha deve seguir fatores técnicos e científicos. Dependendo da escolha da escala, o mapeamento pode ser capaz de mostrar mais detalhes da cobertura e uso da terra ou ter que recorrer a generalizações (Dabiri & Blaschke, 2019). A melhor escala de representação depende de vários fatores, como o objetivo e uso do mapeamento, a quantidade de recursos disponíveis para o mapeamento, a extensão da área a ser mapeada e o tempo disponível para o mapeamento.

A natureza da informação básica diz respeito aos dados que serão utilizados no mapeamento. Os dados podem ser obtidos através de questionários, pesquisas estatísticas, verificação visual *in loco* ou através de dados de sensoriamento remoto (Loveland, 2016). Os dados de sensoriamento remoto podem ser provenientes de diversos sensores ativos ou passivos, sejam eles de um satélite, de uma constelação de satélites, de aerofotolevantamentos ou provenientes de Veículo Aéreo Não Tripulado (VANT). A escolha da informação básica depende do objetivo do estudo, do tempo disponível para sua realização e dos recursos disponíveis (IBGE, 2013).

A unidade de mapeamento é uma área claramente distinguível das unidades de seu entorno, representando uma significativa porção de terra em uma dada escala (García-Álvarez *et al.*, 2019). Ela está relacionada ao objetivo do mapeamento, à escala de apresentação do mapeamento final e à resolução espacial do sensor, no caso de sensoriamento remoto (IBGE, 2013).

Por último, a nomenclatura das classes são as terminologias utilizadas para a compilação das atividades humanas (Glimskär & Skånes, 2018). “A construção de uma nomenclatura de cobertura e do uso da terra precisa estar de acordo com a diversidade do território a ser mapeado” (IBGE, 2013, p. 42). Ela deve ser compatível com a escala, com o tamanho da menor área a ser mapeada, com a fonte básica de dados e com as necessidades dos vários usuários.

Os mapeamentos de cobertura e uso da terra também possuem características próprias. Essas características são adquiridas de acordo com os princípios seguidos, o material utilizado, a metodologia e o objetivo do mapeamento. Destaca-se a representação espacial, a resolução espacial, a resolução temática, a resolução temporal e a acurácia.

A representação espacial refere-se a como o mapeamento é simbolizado. Usualmente, os

mapeamentos são produzidos digitalmente em formato *raster*, onde cada célula possui a informação de uma classe; ou em polígonos vetoriais, onde cada polígono indica classes de cobertura e uso da terra (Salah, 2017).

A resolução espacial de um mapeamento está associada à produção do mapeamento de cobertura e uso da terra por meio dos insumos provenientes do sensoriamento remoto. Ela é determinada por vários fatores, desde a aquisição até o processamento dos dados para a criação do mapa final. A resolução espacial está associada intrinsecamente à unidade de mapeamento mínima, bem como à escala que se pretende realizar o mapeamento (Dabiri & Blaschke, 2019).

Os mapeamentos de cobertura e uso da terra também possuem uma resolução temática. Essa resolução se relaciona com o nível de detalhamento do sistema de classificação. A resolução temática refere-se à quantidade de classes de cobertura e uso utilizadas no mapeamento (Ahlqvist, 2016).

Observa-se, também, a resolução temporal ou periodicidade do mapeamento. Mapeamentos com cobertura temporal ampla permitem que sejam capturadas as dinâmicas e tendências na cobertura e uso da terra, possibilitando o monitoramento ambiental (Mashala *et al.*, 2023). Os mapeamentos também podem ter uma data ou um intervalo de tempo como referência, dependendo da metodologia utilizada.

Por fim, é essencial conhecer a acurácia do mapeamento, principalmente em mapeamentos derivados de sensoriamento remoto (Olofsson *et al.*, 2014). O mais próximo que a acurácia global do mapeamento chegar a 100%, maior o alinhamento das classes com a verdade terrestre. A acurácia é influenciada pelas classes de cobertura e uso da terra escolhidas e pela unidade de mapeamento (Van Thinh *et al.*, 2019).

Sistemas de classificação da cobertura e uso da terra

A necessidade de categorizar vários aspectos do mundo é uma prática comum e antiga. A classificação seria o ordenamento de objetos em grupos ou em conjuntos com base nas suas relações (Jansen, 2018). Na classificação da cobertura e uso da terra, é necessária a criação de um sistema lógico que defina esses grupos ou classes previamente através de critérios (Ahlqvist, 2016). O sistema de classificação necessita de definições claras e consistentes dos limites entre cada classe, possivelmente baseados em critérios objetivos (Di Gregorio, 2016).

A Organização das Nações Unidas para a Agricultura e Alimentação (FAO) buscou a criação de um sistema de classificação universal da cobertura da terra chamado *Land Cover Classification System*

(LCCS). Esse sistema usa critérios objetivos para classificar a cobertura terrestre, como o aspecto fisionômico. Por exemplo, em áreas com vegetação, o critério a ser classificado é o hábito das plantas, enquanto em áreas sem cobertura vegetal, podem ser usados como critério a presença de água, neve ou de superfícies artificiais (Di Gregorio, 2016).

A criação de um sistema de classificação universal da cobertura e uso da terra é um processo de normatização de “cima para baixo”. Esse processo limita a flexibilidade de classificação, reduzindo a sua versatilidade. A harmonização dos sistemas de classificação da cobertura e uso da terra, por sua vez, busca localizar, esclarecer e minimizar as diferenças entre os sistemas (Herold *et al.*, 2006). Esse processo de “baixo para cima” busca a compatibilização e comparabilidade dos diversos mapeamentos, permitindo que cada mapeamento foque em seus objetivos sem perder a sua interoperabilidade (Nações Unidas, 2016).

Nesse sentido, a FAO criou a *Land Cover Meta Language* (LCML). A LCML é uma metalinguagem que busca descrever as várias classes de cobertura através de classificadores (Di Gregorio, 2016). A LCML permite que os sistemas nacionais e regionais de cobertura da terra existentes permaneçam em uso, permitindo que os seus dados sejam integrados com outros sistemas em nível mundial de acordo com um padrão de classificação de cobertura da terra (Nações Unidas, 2016). O LCCS e o LCML são padrões aprovados internacionalmente pela *International Organization for Standardization* (ISO) desde 2012. As normas ISO19144-1 e ISO19144-2 correspondem, respectivamente, a cada um deles (Di Gregorio, 2016). A norma do LCML foi atualizada em 2023, refletindo as demandas crescentes na área de classificação da cobertura e uso da terra.

O IBGE (2013) também criou um sistema de classificação, denominado sistema de classificação da cobertura e uso da terra (SCUT). O SCUT é um sistema multinível, visando atender mapeamentos de escalas de 1:250.000 até 1:100.000 (IBGE, 2013). Três níveis estão presentes no SCUT: o primeiro nível indica as principais categorias de cobertura terrestre no planeta; o segundo nível traduz a cobertura e o uso em uma escala regional; e o terceiro nível explicita o uso propriamente dito (IBGE, 2013).

Por fim, as Nações Unidas (2016) basearam-se no LCCS e utilizaram o LCML para criar o seu próprio sistema de classificação, buscando a realização das Contas da Terra. Esse sistema contém 14 classes de cobertura e uso da terra. O sistema de classificação pode e deve ser modificado de acordo com as necessidades e características de cada país, porém, sempre seguindo os padrões internacionais,

visando manter a sua interoperabilidade (Nações Unidas, 2016).

Mapeamento da cobertura e uso da terra

O mapeamento da cobertura e uso da terra é feito com base no sistema de classificação escolhido e nas fontes básicas de informação. Essa classificação pode ser feita a partir de vários métodos e técnicas. Por exemplo, pesquisas em mapeamentos antigos; pesquisas em dados administrativos e estatísticos; levantamento de campo; fotointerpretação de imagens; classificação de imagens através de algoritmos; ou através da combinação entre os diferentes métodos relatados. (Loveland, 2016).

A pesquisa em mapeamentos antigos e em dados estatísticos depende da qualidade dos dados de base, da sua periodicidade e da sua consistência. Essa metodologia demanda recursos e conhecimento dos dados analisados. O mapeamento de uso e cobertura da terra utilizando os dados numéricos do censo agropecuário de 2006 do IBGE (IBGE, 2018a) é um exemplo dessa forma de mapeamento de abrangência nacional feito através do uso de dados estatísticos.

A fotointerpretação de imagens e o levantamento de campo conseguem fornecer um mapeamento com ótimos resultados (IBGE, 2013). Entretanto, esses métodos necessitam de uma mão de obra especializada na identificação das diferentes classes de cobertura e uso da terra (IBGE, 2022b). Esse tipo de mapeamento pode se tornar inviável em grandes áreas, pois é um processo meticuloso e longo. O mapeamento da vegetação (IBGE, 2023); o mapeamento de cobertura e uso da terra estadual (IBGE, 2013); e o monitoramento da cobertura e uso da terra (IBGE, 2022b) utilizam a fotointerpretação associada com levantamentos de campo em diferentes graus. Contudo, nota-se que esse tipo de metodologia se torna, cada vez mais, impraticável devido à necessidade elevada de recursos materiais e de intérpretes especializados, bem como pela popularização de outras formas de mapeamento.

Algoritmos para classificação da cobertura e uso da terra

A utilização de algoritmos de classificação de imagens modificou a área do mapeamento de cobertura e uso da terra. O avanço da tecnologia facilitou a manipulação de um grande volume de dados e popularizou o uso de algoritmos de classificação através de *softwares* livres (Veiga *et al.*, 2020). Existe uma tendência crescente na produção de mapas de cobertura e uso da terra através da classificação de imagens de satélite por algoritmos (Wang *et al.*, 2023). Por isso, primeiramente, é importante entender algumas características desses algoritmos.

Os algoritmos de classificação podem ser divididos em algoritmos de classificação supervisionada e classificação não-supervisionada (Sheykhmousa *et al.*, 2020). A classificação não-supervisionada agrupa dados semelhantes em ‘clusters’ ou grupos (Lv & Wang, 2020). Ela utiliza apenas os dados inerentes da imagem, ou seja, os píxeis de cada banda espectral. A classificação não-supervisionada não necessita de amostras das classes para treinamento. É uma forma de classificação mais flexível, porém pode ser menos precisa (Phiri & Morgenroth, 2017). Dentre os algoritmos de classificação não-supervisionada cita-se o *K-means clustering*, *K-nearest neighbors*, *Iterative Self-Organizing Data Analysis*, entre outros (Salah, 2017).

Os algoritmos de classificação supervisionada necessitam de amostras de treinamento (Guo *et al.*, 2017). As amostras de treinamento são dados com classes de cobertura e uso da terra que os algoritmos utilizam para aprender as características de cada classe (Salah, 2017). Por necessitarem de amostras, são mais trabalhosos e menos flexíveis, porém podem ter uma melhor acurácia que os algoritmos não-supervisionados (Phiri & Morgenroth, 2017).

Os algoritmos de aprendizado de máquina são algoritmos de classificação supervisionada (Rong & Fu, 2023). O objetivo desses algoritmos é criar modelos que classifiquem um dado de entrada em uma classe de cobertura e uso da terra (Lv & Wang, 2020). Os dados de entrada geralmente são dados das bandas espectrais das imagens, porém outros dados podem ser utilizados, como dados geológicos, geomorfológicos, econômicos, entre outros. Entre os algoritmos de classificação supervisionada destacam-se o *Random Forest* (RF), o *Extreme Gradient Boosting* (XgBoost), a *Convolutional Neural Network* (CNN) e o *Support Vector Machine* (SVM) (Camara *et al.*, 2025).

O mapeamento da cobertura e uso da terra pela classificação de imagens de sensoriamento remoto por meio de algoritmos é a principal forma de mapeamento atualmente (Wang *et al.* 2023). Como exemplos de mapeamentos que utilizam este método para classificação, destaca-se, com abrangência nacional, o mapeamento do MapBiomas (MapBiomas Project, 2024) e, com abrangência global, destacam-se os mapeamentos da ESA-CCI (Harper *et al.*, 2023) e da ESRI (Karra *et al.*, 2021). O uso de algoritmos de classificação permite que mapeamentos possam ser lançados com abrangência global e com resolução temporal anual ou, até mesmo, em tempo real, como o caso do *Dynamic World* (Brown *et al.*, 2022).

Percebe-se que a classificação de imagens por algoritmos domina o mapeamento da cobertura e uso da terra de grandes áreas (Liu *et al.*, 2021). A

seguir, alguns conceitos relacionados a essa forma de mapeamento são explorados, bem como novos métodos e tendências que estão emergindo na área.

Mapeamento pixel-a-pixel e orientado ao objeto

O mapeamento da cobertura e uso da terra por algoritmos de classificação pode variar de acordo com duas técnicas: a classificação pixel-a-pixel e a classificação orientada ao objeto ou *object-based image analysis* (OBIA) (Duro *et al.*, 2012).

A classificação pixel-a-pixel classifica os dados de cada pixel individualmente, enquanto a OBIA analisa um conjunto de pixels, agrupando-os em segmentos de pixels semelhantes e classificando os segmentos gerados (Phiri & Morgenroth, 2017). A principal desvantagem da classificação pixel-a-pixel é que, dada a heterogeneidade dos pixels, existe a presença de pixels isolados classificados diferentemente do seu entorno, gerando um efeito conhecido como *Salt and Pepper* (Ozturk & Colkesen, 2024). A OBIA também possui desvantagens, como a possibilidade de uma segmentação exagerada ou insuficiente e a necessidade de maior poder computacional (Salah, 2017). A OBIA geralmente produz uma classificação de cobertura e uso da terra de maior acurácia que a classificação pixel-a-pixel (Myint *et al.*, 2011). Possivelmente, essa maior acurácia é causada pela inclusão de dados adicionais como textura, formato e relação com os dados adjacentes (Salah, 2017).

Uma forma de incluir os dados dos pixels vizinhos na classificação pixel-a-pixel é realizar operações que criem bandas auxiliares contendo dados da vizinhança. Essas bandas reúnem as informações dos pixels vizinhos mediante uma janela de análise baseada em um pixel central (Camara *et al.*, 2025). As funções de agregação podem ser média, valor máximo, valor mínimo, desvio padrão, entropia, entre outras. A OBIA é recomendada na classificação de imagens de alta resolução, enquanto a classificação pixel-a-pixel é mais indicada para a classificação de imagens de baixa ou média resolução (Salah, 2017).

Analysis-ready data e cubo de dados

As imagens de satélites são a fonte de dados mais completa sobre o meio ambiente (Camara *et al.*, 2025). Elas cobrem uma grande área da superfície da terra e permitem o estudo regional e global ao longo do tempo (Mashala *et al.*, 2023). *Petabytes* de dados de imagens de satélite estão disponíveis de maneira gratuita para o estudo do meio ambiente, no entanto, o desafio é acessá-los e analisá-los (Simões *et al.*, 2021).

A computação em nuvem tenta resolver esse problema através do armazenamento e processamento desses dados em servidores na internet (nuvem) (Liu

et al., 2021). *Data cube*, ou cubo de dados, é uma estrutura de dados em nuvem que armazena informações de diferentes sensores de observação da terra, de maneira regular e sistemática (Simões *et al.*, 2021).

As imagens e dados armazenados em um cubo de dados são, preferencialmente, *Analysis-ready data* (ARD). Imagens ARD são imagens prontas para uso, sem necessidade de pré-processamento ou transformação. O acesso a imagens ARD simplifica o estudo do meio ambiente através de imagens de satélite, pois permite o acesso a imagens consistentes, de alta qualidade e de diferentes sensores em um mesmo lugar (Song, 2023). As imagens ARD estão presentes em vários projetos na internet, como *Amazon Web Service*, *Brazil Data Cube*, *Digital Earth Africa*, *Swiss Data Cube* e *Microsoft's Planetary Computer* (Simões *et al.*, 2021).

Entre esses projetos, destaca-se o *Brazil Data Cube* (BDC). Ele é um projeto de 2019 desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE). O BDC tem como um dos objetivos criar um cubo de dados multidimensionais de imagens ARD de média resolução de vários sensores, cobrindo todo o território brasileiro (Simões *et al.*, 2021). O projeto BDC também busca gerar informações de cobertura e uso da terra através do uso de cubos de dados e algoritmos de classificação (Camara *et al.*, 2025).

A disponibilização dos dados de imagens de satélite em nuvem, os cubos de dados e a geração de imagens de satélite ARD permitem uma análise mais completa (Song, 2023). O acesso às várias imagens pré-processadas de múltiplos anos permite que uma vasta série temporal de imagens seja examinada. As séries temporais são uma coleção de imagens de satélite em um determinado intervalo de tempo para um mesmo local (Simões *et al.*, 2021). Nelas, cada pixel contém informações sobre as bandas presentes ao longo do intervalo selecionado. Antes, a necessidade de armazenar uma grande quantidade de dados dificultava a análise de séries temporais. A computação em nuvem facilitou o acesso integral aos dados, diminuindo o armazenamento e o processamento necessário. A análise de uma série temporal permite que toda a informação captada pelos sensores seja utilizada pelo algoritmo de classificação, gerando produtos mais robustos (Giuliani, 2024).

Algoritmos de classificação de séries temporais

Os algoritmos de classificação da cobertura e uso da terra transformam dados em classes de cobertura e uso (Abdi, 2020). Entre os algoritmos mais utilizados para a classificação de séries temporais de imagens destacam-se RF, SVM, XgBoost e algoritmos de redes neurais como CNN (Camara *et al.*, 2025).

No que se diz respeito às séries temporais, os algoritmos analisam os dados de duas formas. A primeira não considera a estrutura da série temporal, tratando cada dado como único e independente dos outros. O RF, o SVM e o XgBoost são exemplos desses tipos de algoritmos (Camara *et al.*, 2025). A segunda forma analisa, também, a relação temporal entre os valores. Esses algoritmos são projetados especialmente para a análise de séries temporais, sendo a ordem dos valores na série relevante. Um exemplo desses algoritmos é a *Temporal Convolutional Neural Network* (TempCNN) (Pelletier *et al.*, 2019).

O *Random Forest* (RF) é um algoritmo que usa métodos combinados para a classificação de dados, sendo descrito pela primeira vez em 2001 (Breiman, 2001). O algoritmo cria várias árvores de decisão, onde cada árvore é treinada com uma parcela da amostra de treinamento disponibilizada pelo usuário. O algoritmo computa a classe que cada árvore de decisão previu para determinado píxel. Como são criadas diversas árvores, a classe com maior número de predições é selecionada e alocada àquele píxel (Sheykhoumousa *et al.*, 2020). O RF é um algoritmo robusto e que consegue lidar bem com vários tipos de dados de entrada (Arpitha *et al.*, 2023). É um dos algoritmos mais usados na classificação de imagens de satélite atualmente e deve ser incluído nas avaliações dos possíveis modelos de classificação de cobertura e uso da terra de qualquer mapeamento (Camara *et al.*, 2025).

O *Support Vector Machine* (SVM) foi apresentado, pela primeira vez, no final da década de 70. Ele é usado em uma variedade de classificações, especialmente na classificação de imagens. O SVM busca identificar um limite entre as classes, traçando um hiperplano para separar os dados em um número predeterminado de classes (Mountrakis *et al.*, 2011). O SVM é menos estável e menos robusto em relação a ruídos nos dados do que o algoritmo RF (Camara *et al.*, 2025).

O *Extreme Gradient Boosting* (XGboost) é um algoritmo de *machine learning* apresentado pela primeira vez em 2016 (Chen & Guestrin, 2016). O XgBoost é da família de algoritmos de árvores de decisão, assim como o RF. O XgBoost constrói uma árvore de decisão por vez, onde cada árvore ajuda a corrigir os erros das árvores anteriores. Cada árvore é adicionada, sequencialmente, até que não seja possível fazer mais nenhum aperfeiçoamento (Camara *et al.*, 2025). Os primeiros estudos utilizando o algoritmo XgBoost para a classificação do uso e cobertura da terra foram realizados em 2018. Notou-se que o XgBoost teve uma performance melhor que os outros algoritmos na classificação de imagens de alta resolução em cidades africanas (Georganos *et al.*, 2018). Logo, gradativamente,

outros trabalhos surgiram demonstrando a viabilidade do uso do algoritmo XgBoost nessa tarefa, bem como o seu desempenho igual ou superior a outros algoritmos tradicionais como o RF e SVM (Xie *et al.*, 2024).

As redes neurais modificaram a classificação de imagens de satélite por algoritmos. Elas são capazes de lidar com estruturas de dados complexas e com ruídos nos dados de maneira eficiente (Fan *et al.*, 2023). As redes neurais consistem em uma rede de camadas, onde cada camada possui uma série de unidades de processamento chamadas de neurônios. Cada neurônio é conectado por pesos com os neurônios vizinhos e com outras camadas (Salah, 2017). Existem várias arquiteturas de redes neurais, destacando-se a TempCNN. Ela é uma implementação da arquitetura de uma rede neural a uma série temporal, visando a classificação dos dados de entrada em classes, como as de cobertura e uso da terra (Pelletier *et al.*, 2019). A TempCNN usa uma janela móvel que simplifica a série temporal, gerando, à medida que a janela avança, outras séries temporais. Dessa maneira, o algoritmo consegue capturar as características da série temporal que permanecem estáveis ao longo da simplificação (Camara *et al.*, 2025). Cada camada da rede neural identifica padrões nas séries temporais de maneira diferente, permitindo que todas as suas características sejam captadas pelo algoritmo. Por causa de sua característica multiescalar, a TempCNN consegue capturar padrões temporais complexos, resultando em uma classificação muito precisa (Sun *et al.*, 2025). É importante ressaltar que a CNN se destaca como o modelo de rede neural mais utilizado no mapeamento da cobertura e uso da terra na última década (Rong & Fu, 2023). A TempCNN é um modelo confiável, sendo o algoritmo estado da arte na classificação de séries temporais, entretanto, ela demanda um considerável tempo de treinamento quando comparado aos algoritmos RF, XgBoost e SVM (Camara *et al.*, 2025).

O fator mais importante para a escolha do algoritmo de classificação é a qualidade dos dados de treinamento (Maxwell *et al.*, 2018). A qualidade da classificação depende das amostras de treinamento e de qual modelo melhor se adapta a essas amostras (Camara *et al.*, 2025). Deve-se levar em conta o tempo necessário da classificação, bem como o objetivo do trabalho (Maxwell *et al.*, 2018). Empiricamente, na classificação de séries temporais, RF, XgBoost e TempCNN apresentam a melhor performance (Camara *et al.*, 2025).

Exemplos de mapeamentos de cobertura e uso da terra no GMUCCS

Foram analisados os principais mapeamentos de cobertura e uso da terra de abrangência nacional

ou global e suas características. O GMUCCS serviu de área de estudo, visando demonstrar as semelhanças e diferenças de cada mapeamento. Os mapeamentos analisados são o Mapeamento da Vegetação (IBGE, 2023), o Monitoramento de Cobertura e Uso da Terra (Monitoramento) (IBGE, 2022b), o MapBiomias (MapBiomias Project, 2024), o ESA-CCI (Harper *et*

al., 2023) e o ESRI (Karra *et al.*, 2021). Esses mapeamentos usam diversas formas de classificação da cobertura e uso da terra, que serão discutidas ao longo do texto. A Tabela 1 traz as características de cada mapeamento.

Tabela 1: Características dos mapeamentos selecionados.

	Mapeamento da Vegetação	Monitoramento	ESA-CCI	MapBiomias	ESRI
Representação Espacial	Vetorial	Vetorial	Raster	Raster	Raster
Resolução Espacial	1:250 000	1 km ²	300 m ²	30 m ²	10 m ²
Resolução Temática	80 Classes	12 classes	22 classes	29 classes	8 classes
Resolução Temporal	Sem informação	Bienal* 2000-2020	Anualmente 1992-2020	Anualmente 1985-2023	Anualmente 2017-2023
Acurácia	Sem informação	Sem informação	75,38%	89,27%	85,00%

Fonte: Os Autores (2025) * Do ano 2010 a 2020.

O mapeamento da vegetação do Brasil pelo IBGE (Mapeamento da Vegetação) teve início no projeto Levantamento Radargramétrico da Amazônia (RADAM) (IBGE, 2012). O projeto surgiu a partir da decisão do governo brasileiro de incluir a Amazônia no processo desenvolvimentista. Para isso, era imperativo o conhecimento cartográfico da região e o levantamento dos seus recursos naturais (IBGE, 2018a). O RADAM foi criado na década de 1970 com atribuição de levantar as potencialidades naturais da Amazônia brasileira (IBGE, 2018a). Foram utilizados radares de vista lateral aerotransportados, com ajuda de equipes multidisciplinares, para realizar o mapeamento (IBGE, 2018a). Com o sucesso inicial, em 1975, foi criado o RADAMBRASIL. Esse projeto buscou realizar, no restante do território brasileiro, o mesmo mapeamento feito na Amazônia (IBGE, 2018a). O RADAMBRASIL representou um dos mais significativos esforços para se adquirir informações sobre a geologia, vegetação, solos, geomorfologia, uso da terra e cartografia do Brasil (IBGE, 2018a). Dentre os recursos naturais mapeados, a vegetação destacava-se por representar a cobertura da terra. Em 1992, o primeiro manual de mapeamento da vegetação foi lançado (IBGE, 1992). Ele explicava a metodologia usada para a classificação da cobertura da terra pelo RADAMBRASIL. O mapa foi lançado na escala 1:1.000.000 possuindo polígonos com legendas compostas, onde cada parte da legenda correspondia a uma cobertura vegetal ou a um uso da terra (IBGE, 1992). Os dados utilizados foram provenientes do RADAMBRASIL, bem como das várias expedições a campo (IBGE, 1992).

A partir de 1997, com o convênio realizado entre o IBGE e o Sistema de Vigilância da Amazônia (SIVAM), foi iniciado o projeto de Mapeamento dos Recursos Naturais (MRN) (IBGE, 2019). Esse

projeto visava “mapear em uma escala de 1:250.000 os temas de geologia, geomorfologia, pedologia e vegetação” (IBGE, 2019, p. 12). Em 2012, foi lançada a 2ª edição do manual de mapeamento da vegetação (IBGE, 2012). Ele foi lançado para atualizar e adequar a metodologia de mapeamento da vegetação à escala 1:250.000 utilizada pelo MRN.

Foram utilizadas imagens de satélite da série *Landsat*, mapeamentos de vegetação anteriores e expedições a campo para realizar o levantamento da vegetação (IBGE, 2019). A legenda do mapeamento foi aprimorada, sendo incluídas outras fitofisionomias presentes na vegetação brasileira. Entretanto, os polígonos de mapeamento ainda possuíam legendas compostas devido à escala do mapeamento e à necessidade de generalização de algumas áreas.

Hoje, a metodologia de classificação da vegetação e os mapeamentos realizados pelo IBGE servem como base para diversos estudos de vegetação no Brasil. As legendas de uso da terra presentes no mapeamento da vegetação, infelizmente, não tem uma data precisa, sendo, assim, pouco utilizadas nos estudos de uso da terra.

A metodologia utilizada pelo mapeamento da vegetação do IBGE envolve o levantamento de campo por meio de especialistas, bem como a fotointerpretação de imagens de satélite. Há uma previsão de melhoramento contínuo do mapeamento, porém sem a especificação de data ou aprimoramento da legenda (IBGE, 2023). Os dados são disponibilizados em vetores e não há informação sobre a acurácia do mapeamento. A escala do mapeamento é de 1:250.000, não possuindo resolução espacial devido a sua metodologia. A Figura 2 mostra o Mapeamento da Vegetação para o GMUCCS. A Figura 3 mostra a porcentagem ocupada pelas classes

dominantes do Mapeamento da Vegetação no GMUCCS.

O Monitoramento da Cobertura e Uso da Terra do Brasil (Monitoramento) utiliza mapeamentos já realizados pelo IBGE, como o mapeamento de vegetação e a base cartográfica; séries temporais do Índice de Vegetação por Diferença Normalizada (NDVI) do sensor MODIS; imagens de satélites, como do *Landsat-8* e *Sentinel-2*; estatísticas coletadas pelas pesquisas do IBGE, como a pesquisa agropecuária municipal (PAM) e a pesquisa de extração vegetal e silvicultura (PEVS); e viagens a campo para realizar o mapeamento de cobertura e uso da terra (IBGE, 2022b). O

Monitoramento faz uso da grade estatística de 1 km². Sua utilização tem como objetivo promover uma estrutura fixa de referência para integrar e harmonizar informações geoespaciais, como dados de pesquisas e mapeamentos (IBGE, 2017). Cada célula é uma unidade espacial básica e única, que não está sujeita a modificações nos seus limites ao longo dos anos. Através da interação dessas informações, facilitada pelo uso da grade estatística, é possível, de uma forma rápida e eficiente, gerar dados geoespaciais variados, combinando diversas fontes de dados (IBGE, 2022a).

As diferentes informações, então, são analisadas por intérpretes que, através da fotointerpretação das imagens de satélite, classificam cada uma das células da grade em uma das 12 classes do projeto (IBGE 2017). O sistema de classificação é adaptado à realidade brasileira, porém segue os padrões internacionais, relacionando-se com as classes do LCCS. Hoje, o Monitoramento é utilizado nas contas ambientais das Nações Unidas e em estudos do IBGE como, por exemplo, as Contas da Terra (IBGE, 2022a) e as Contas de Ecossistemas (IBGE, 2020).

O Monitoramento necessita de uma equipe especializada para realizar a fotointerpretação das imagens (IBGE, 2022b). A periodicidade do mapeamento é de dois anos, com exceção do período de 2000 a 2010. A unidade mínima mapeável é a célula da grade estatística de 1 km², sendo essa também a sua resolução espacial. Enquanto a grade estatística possibilita uma contabilidade das mudanças mais eficiente, ela generaliza a informação, diminuindo o uso do Monitoramento em outros

estudos. Os arquivos são disponibilizados em formato vetorial e não há informações publicadas sobre a sua acurácia. A Figura 4 mostra o mapeamento do Monitoramento para o GMUCCS no ano de 2020. A Figura 5 mostra a porcentagem ocupada pelas classes do Monitoramento no GMUCCS.

O mapeamento de cobertura e uso da terra da ESA-CCI (ESA-CCI) é um mapeamento realizado a partir de imagens de diferentes satélites e sensores (Harper *et al.*, 2023). O mapeamento é realizado pela Agência Espacial Europeia (ESA) e pela organização não-governamental (ONG) *Climate Change Initiative* (CCI). Primeiro, são classificadas as imagens do sensor MERIS através de algoritmos de classificação não-supervisionada. Após a primeira etapa, o resultado da classificação não-supervisionada é usado como amostras de treinamento para uma classificação supervisionada das demais imagens de satélite (ESA, 2017). O mapeamento utiliza séries temporais de imagens do sensor AVHRR para os anos de 1992 a 1999, séries temporais de imagens do sensor MERIS para os anos de 2003 a 2012, séries temporais de imagens do satélite SPOT para os anos de 1999 a 2013, séries temporais de imagens do satélite PROBA para os anos de 2014 a 2015 e séries temporais de imagens do satélite *Sentinel-2* para os anos de 2016 a 2020 (ESA, 2017).

O mapa de cobertura e uso da terra da ESA-CCI usa o LCCS para definir as classes de cobertura e uso da terra. O uso do LCCS permite a compatibilidade do mapeamento com outros mapeamentos e produtos de cobertura e uso (ESA, 2017). O sistema de classificação é hierárquico, o que permite a inclusão de novas classes à medida que o detalhamento aumenta (ESA, 2017). No nível 1, há 22 classes, sendo esse nível determinado como global, estando presente em todas as áreas de mapeamento. O nível 2 é determinado como regional e possui detalhamento de algumas classes do nível 1, porém não está presente em todas as áreas no mapeamento. O mapa tem resolução espacial de 300 metros e resolução temporal de um ano. Estão mapeados todos os anos entre 1992 e 2020 (Harper *et al.*, 2023).




Figura 2: Mapa de Cobertura e Uso da Terra do Mapeamento da Vegetação do GMUCCS




Figura 3: Proporção da área ocupada pelas classes do GMUCCS. Áreas com 0,1% ou menos não foram rotuladas. Fonte de Dados: IBGE (2023)




Figura 4: Mapa de Cobertura e Uso da Terra do Monitoramento do GMUCCS no ano de 2020.




Figura 5: Proporção da área ocupada pelas classes do GMUCCS. Áreas com 0,1% ou menos não foram rotuladas. Fonte de Dados: IBGE (2022b)




Figura 6: Mapa de Cobertura e Uso da Terra do ESA-CCI do GMUCCS no ano de 2020.




Figura 7: Proporção da área ocupada pelas classes do GMUCCS. Áreas com 0,1% ou menos não foram rotuladas. Fonte de Dados: Harper *et al.* (2023)

Por fim, esse mapeamento serve de base para vários estudos. Ele é indicado pelas Nações Unidas para o cálculo dos índices ODS caso o país não possua um mapeamento de cobertura e uso da terra próprio (Sims *et al.*, 2021). Cita-se, como exemplos, o cálculo do índice ODS 15.3.1 (índice de proporção de Terras Degradadas) (Sims *et al.*, 2021); e o índice ODS 15.4.2 (índice de cobertura verde em áreas de montanhas) (FAO, 2024).

O mapeamento da ESA-CCI usa a metodologia de classificação de imagens de satélite através de algoritmos de classificação não supervisionada e classificação supervisionada de séries temporais por meio de redes neurais (ESA, 2017). A resolução espacial do mapeamento é de 300 metros e possui periodicidade anual. A acurácia global do mapeamento é de 75,38% para o ano de 2015 (ESA, 2017). A Figura 6 mostra o mapeamento da ESA-CCI para o GMUCCS no ano de 2020. A Figura 7 mostra a porcentagem ocupada pelas classes do ESA-CCI no GMUCCS.

O MapBiomas é uma iniciativa da ONG Observatório do Clima (MapBiomas Project, 2024). A iniciativa foi formada em 2015 e é composta por ONGs, universidades e companhias privadas. O MapBiomas visa produzir mapas de cobertura e uso da terra do Brasil e de diferentes áreas do mundo. Até o ano de 2025, a iniciativa já produziu 9 coleções de mapas de cobertura e uso da terra do Brasil.

Os mapas produzidos pelo MapBiomas utilizam a série de satélites *Landsat* e os seus diferentes sensores (Souza *et al.*, 2020). O MapBiomas já produziu mapas do ano de 1985 a 2023 para o Brasil (Mapbiomas Project, 2024). Os dados são obtidos a partir de cubos de dados e processados através de computação em nuvem utilizando o *Google Earth Engine* (Souza *et al.*, 2020). É utilizado o algoritmo de classificação supervisionada RF no mapeamento, porém outros algoritmos, como CNN, também são utilizados para a classificação de algumas classes como aquicultura, mineração, irrigação, arroz, *citrus* e plantação de dendê (Mapbiomas Project, 2024). Várias amostras de treinamento são coletadas para a classificação, sendo escolhidas sempre amostras onde não houve mudança na cobertura e uso nos anos anteriores (Mapbiomas Project, 2024).

A coleção 9 do mapeamento de cobertura e uso da terra do MapBiomas foi lançada em 2024. Essa coleção possui 29 classes de cobertura e uso da terra. As classes mapeadas buscam a compatibilização com o LCCS, com os mapeamentos do IBGE e com o inventário nacional dos gases do efeito estufa (Mapbiomas Project, 2024). O mapeamento possui resolução espacial de 30 metros, periodicidade de um

ano e abrange todo o território brasileiro (Souza *et al.*, 2020).

Hoje, os mapas de cobertura e uso da terra produzidos pela iniciativa MapBiomas são utilizados nas mais diversas aplicações e estudos. Algumas das aplicações dos mapas são o monitoramento de desastres naturais, o planejamento regional, a modelagem da propagação de doenças infecciosas, a identificação de processos de desertificação, o monitoramento da expansão da agricultura, entre outras (MapBiomas Project, 2024). A acurácia global do mapeamento do MapBiomas coleção 9 do ano de 2022 é 89,84%. A Figura 8 mostra o mapeamento do MapBiomas para o GMUCCS no ano de 2023. A Figura 9 mostra a porcentagem ocupada pelas classes do MapBiomas no GMUCCS.

O mapeamento da cobertura e uso da terra da ESRI (ESRI) foi lançado em 2021 (Karra *et al.*, 2021). Atualmente, foi mapeada a cobertura e uso da terra global do ano de 2017 ao ano de 2023. O mapeamento é uma parceria das empresas ESRI e *Impact Observatory*. Ele usa como insumo uma série temporal anual das bandas Azul, Verde, Vermelho, Infravermelho-próximo e as bandas de infravermelho de ondas curtas 1 e 2 do satélite *Sentinel-2* (Karra *et al.*, 2021). A classificação é realizada através da computação em nuvem usando um cubo de dados no *Microsoft's Planetary Computer*. Mais de 5 bilhões de amostras, coletadas manualmente, foram utilizadas para treinar um algoritmo de classificação de rede neural. O algoritmo utilizado é a CNN, através da arquitetura U-Net (Karra *et al.*, 2021). Foram processadas, em média, 96 imagens por cena do *Sentinel-2*, totalizando 2 *petabytes* de dados processados. Oito classes de cobertura e uso da terra foram classificadas no mapeamento (Karra *et al.*, 2021). O mapeamento tem resolução espacial de 10 metros e resolução temporal de um ano.

O mapeamento de cobertura e uso da terra da ESRI é, atualmente, o estado da arte nos mapeamentos globais. Ele utiliza classificação supervisionada através de redes neurais para gerar um mapeamento com acurácia global de 85% (Impact Observatory, 2022). O mapeamento utiliza uma gigantesca amostra de treinamento, o que aumenta a consistência da sua classificação em todos os biomas terrestres.

O mapeamento está disponível *online* e pode ser usado como insumo de auxílio aos gestores no planejamento territorial, na gestão dos recursos naturais e na proteção ao meio ambiente (Impact Observatory, 2022). A Figura 10 mostra o mapeamento da ESRI para o GMUCCS no ano de 2023. A Figura 11 mostra a porcentagem ocupada pelas classes da ESRI no GMUCCS.




Figura 8: Mapa de Cobertura e Uso da Terra do MapBiomass do GMUCCS no ano de 2023.




Figura 9: Proporção da área ocupada pelas classes do GMUCCS. Áreas com 0,1% ou menos não foram rotuladas. Fonte de Dados: MapBiomassProject (2024).




Figura 10: Mapa de Cobertura e Uso da Terra do ESRI do GMUCCS no ano de 2023.




Figura 11: Proporção da área ocupada pelas classes do GMUCCS. Áreas com 0,1% ou menos não foram rotuladas. Fonte de Dados: Karra *et al.*(2021).

Tabela 2: Proposta de harmonização das classes Cobertura Florestal, Cobertura Campestre e Uso agrícola dos mapeamentos analisados e sua porcentagem de ocupação no GMUCCS.

Mapeamentos		Cobertura Florestal	Cobertura Campestre	Uso Agrícola
Mapeamento da Vegetação	Classes	Vegetação Secundária + Reflorestamento	Estepe Gramíneo-Lenhosa + Pecuária	Agricultura
	Total	52,60%	25,50%	12,80%
Monitoramento	Classes	Vegetação Florestal + Silvicultura	Vegetação Campestre + Pastagem com Manejo	Área Agrícola
	Total	52,80%	19,87%	10,30%
ESA-CCI	Classes	Vegetação Florestal	Vegetação Campestre + Mosaico de Vegetação Campestre	Área Agrícola + Área Agrícola Irrigada + Mosaico Área Agrícola e Vegetação
	Total	58,90%	14,40%	10,41%
MapBiomias	Classes	Formação Florestal + Silvicultura	Formação Campestre + Pastagem	Lavoura Temporária
	Total	55,00%	23,70%	9,90%
ESRI	Classes	Cobertura Florestal	Vegetação Campestre	Área agrícola
	Total	59,40%	23,30%	14,30%

Fonte: Os Autores (2025)

Semelhanças e diferenças na cobertura e uso da terra no GMUCCS

Nota-se que os mapeamentos analisados são de diferentes anos e apresentam diferenças de acurácia e metodologia entre eles. Entretanto, apesar dessas ressalvas, é possível analisar alguns pontos de concordância e discrepância entre os mapeamentos.

Percebe-se, de modo geral, que há uma concordância na distribuição espacial entre as principais classes. As áreas de vegetação campestre estão localizadas no Planalto, a oeste do GMUCCS. A vegetação florestal está localizada na Serra e Patamares, no centro do GMUCCS. Já as áreas de uso agrícola predominam na planície, a leste do GMUCCS.

Cada mapeamento possui suas próprias características e sistemas de classificação, portanto, é necessária a harmonização das classes para realizar uma possível comparação entre elas. A Tabela 2 mostra uma proposta de harmonização das classes de cobertura florestal, cobertura campestre e uso agrícola.

A cobertura florestal pode abrigar tanto as formações florestais quanto as áreas de uso para silvicultura. Os mapeamentos da ESRI e ESA-CCI incluem as áreas de silvicultura na cobertura florestal, enquanto os mapeamentos restantes separam as duas classes. Assim, levando em consideração as áreas de vegetação florestal e de silvicultura em todos os mapeamentos, a área de cobertura florestal varia entre 52,6% e 59,4% no GMUCCS.

Existem também discrepâncias em relação à definição da classe de cobertura campestre. Por exemplo, o Monitoramento divide as classes de vegetação campestre e de pastagem com manejo e o ESA-CCI une essas classes, além de adicionar a classe de mosaico de vegetação campestre. Já o ESRI agrupa todas as classes mencionadas na classe vegetação campestre. Portanto, quando considerado as classes harmonizadas, a área de cobertura campestre varia entre 14,4% e 23,3% no GMUCCS.

A classe de uso agrícola também possui definições diferentes em cada mapeamento. O Monitoramento, a ESA-CCI e o MapBiomias utilizam classes de mosaico. Essas classes podem abrigar tanto áreas agrícolas, quanto pastagens ou vegetação

natural. Além disso, a ESA-CCI diferencia os mosaicos por predomínio, sendo que a classe com maior área no polígono do mapeamento aparece em primeiro na nomenclatura. Portanto, quando contabilizado apenas as classes agrícolas puras ou onde predomina a área agrícola no mosaico, o uso agrícola varia entre 9,9% e 14,3% no GMUCCS.

Como visto, os mapeamentos possuem sistemas de classificação, resoluções e metodologias diferentes, sendo a sua comparabilidade difícil. Ainda assim, é possível identificar, através da harmonização das classes, algumas informações em concordância. Nota-se que as diferentes formas de mapeamento disponibilizam dados úteis para cada usuário. A principal diferença está nos recursos despendidos nos mapeamentos e a consequente viabilidade e continuação dos projetos ao longo dos anos. Enquanto os mapeamentos que utilizam algoritmos de classificação conseguem lançar anualmente novos dados de cobertura e uso da terra, mapeamentos que fazem levantamentos de campo e interpretação visual de imagens, demoram a atualizar os dados ou são descontinuados.

Conclusão

Conclui-se que a área de mapeamento de cobertura e uso da terra evoluiu significativamente. O mapeamento da cobertura e uso da terra permite entender a paisagem e como o ser humano interage com ela, bem como fornece dados para diversos estudos, como os indicadores ODS.

As novas metodologias de mapeamento de grandes áreas, mais acessíveis e abrangentes, substituíram formas de mapeamento mais especializadas, porém lentas ou com menor resolução. A disponibilização de imagens ARD em cubos de dados e a computação em nuvem permitiu que mais dados e informações fossem analisados de maneira rápida e eficiente. O uso de séries temporais e algoritmos de classificação tende a aumentar à medida que a tecnologia se estabelece.

Por fim, destaca-se os mapeamentos que utilizam algoritmos de classificação, possuem periodicidade anual, abrangência nacional ou global e uma alta acurácia. Esses mapeamentos conseguem produzir dados confiáveis com relativamente menos recursos.

Espera-se que este trabalho ajude a elucidar a trajetória dos mapeamentos de cobertura e uso da terra, melhore a compreensão dessa área de estudo e contribua na seleção de métodos e bases de dados para estudos posteriores na cobertura e uso da terra.

Agradecimentos

Os autores agradecem a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Programa de Pós-Graduação em Planejamento Territorial e Desenvolvimento Socioambiental (PPGPLAN) da Universidade do Estado de Santa Catarina (UDESC) pelo apoio na pesquisa, bem como o Instituto Brasileiro de Geografia e Estatística (IBGE) pelo apoio por meio de concessão de afastamento para realização de Pós-Graduação.

Referências

- Abdi, A. M. (2020). Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. *GIScience & Remote Sensing*, 57(1), 1–20. <https://doi.org/10.1080/15481603.2019.165044>
- Ahlqvist, O. (2016). Semantic Issues in Land-Cover Analysis Representation, Analysis, and Visualization. Em C. P. Giri (Org.), *Remote Sensing of Land Use and Land Cover: Principles and Applications*. CRC Press. <https://doi.org/10.1201/b11964>
- Arpitha, M., Ahmed, S. A., & Harishnaika, N. (2023). Land use and land cover classification using machine learning algorithms in google earth engine. *Earth Science Informatics*, 16(4), 3057–3073. Scopus. <https://doi.org/10.1007/s12145-023-01073-w>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. Scopus. <https://doi.org/10.1023/A:1010933404324>
- Brown, C. F., Brumby, S. P., Guzder-Williams, B., Birch, T., Hyde, S. B., Mazzariello, J., Czerwinski, W., Pasquarella, V. J., Haertel, R., Ilyushchenko, S., Schwehr, K., Weisse, M., Stolle, F., Hanson, C., Guinan, O., Moore, R., & Tait, A. M. (2022). Dynamic World, Near real-time global 10 m land use land cover mapping. *Nature*, 9(1), 251. <https://doi.org/10.1038/s41597-022-01307-4>
- Burrell, A. L., Evans, J. P., & De Kauwe, M. G. (2020). Anthropogenic climate change has driven over 5 million km² of drylands towards desertification. *Nature Communications*, 11(1). Scopus. <https://doi.org/10.1038/s41467-020-17710-7>
- Camara, G., Simoes, R., Souza, F., Menino, F., Pelletier, C., Andrade, P. R., Ferreira, K., & Queiroz, G. (2025). *sits: Satellite Image Time Series Analysis on Earth Observation Data Cubes*. National Institute for Space Research (INPE). <https://e-sensing.github.io/sitsbook/machine-learning-for-data-cubes.html>
- Capoane, V., & Fushimi, M. (2023). Alterações antropogeomorfológicas na bacia hidrográfica Córrego Lajeado, Campo Grande—MS. *GEOUSP*,

- 27, e. <https://doi.org/10.11606/issn.2179-0892.geousp.2023.196393>
- Chen, T., & Guestrin, C. (2016). *XGBoost: A scalable tree boosting system*. 13-17-August-2016, 785–794. Scopus. <https://doi.org/10.1145/2939672.2939785>
- Congalton, R. G., & Green, K. (2019). *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices, Third Edition* (3° ed.). CRC Press. <https://doi.org/10.1201/9780429052729>
- Dabiri, Z., & Blaschke, T. (2019). Scale matters: A survey of the concepts of scale used in spatial disciplines. *European Journal of Remote Sensing*, 52(1), 419–435. Scopus. <https://doi.org/10.1080/22797254.2019.1626291>
- Di Gregorio, A. (2016). *Land Cover Classification System—Classification*. <https://openknowledge.fao.org/server/api/core/bitstreams/bb3fe826-5869-49c1-9b3f-87a160de8403/content>
- Diuk-Wasser, M. A., Vanacker, M. C., & Fernandez, M. P. (2021). Impact of Land Use Changes and Habitat Fragmentation on the Eco-epidemiology of Tick-Borne Diseases. *Journal of Medical Entomology*, 58(4), 1546–1564. Scopus. <https://doi.org/10.1093/jme/tjaa209>
- Duro, D. C., Franklin, S. E., & Dubé, M. G. (2012). A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote Sensing of Environment*, 118, 259–272. <https://doi.org/10.1016/j.rse.2011.11.020>
- ESA. Agência Espacial Européia, (2017). *Land Cover CCI: PRODUCT USER GUIDE*. https://maps.elie.ucl.ac.be/CCI/viewer/download/ESACCI-LC-Ph2-PUGv2_2.0.pdf
- Fan, X., Chen, L., Xu, X., Yan, C., Fan, J., & Li, X. (2023). Land Cover Classification of Remote Sensing Images Based on Hierarchical Convolutional Recurrent Neural Network. *Forests*, 14(9), Artigo 9. <https://doi.org/10.3390/f14091881>
- FAO. Organização das Nações Unidas para a Agricultura e Alimentação, (2016). *Map Accuracy Assessment and Area Estimation: A practical Guide*. Roma.
- FAO. Organização das Nações Unidas para Alimento e Agricultura, (2024). *SDG 15.4.2 Computation Tools Documentation*. Roma. <https://mgci-docs.readthedocs.io/en/latest/>
- García-Álvarez, D., Olmedo, M. T. C., & Paegelow, M. (2019). Sensitivity of a common Land Use Cover Change (LUCC) model to the Minimum Mapping Unit (MMU) and Minimum Mapping Width (MMW) of input maps. *Computers, Environment and Urban Systems*, 78. Scopus. <https://doi.org/10.1016/j.compenvurbsys.2019.101389>
- Georganos, S., Grippa, T., Vanhuysse, S., Lennert, M., Shimoni, M., & Wolff, E. (2018). Very High Resolution Object-Based Land Use-Land Cover Urban Classification Using Extreme Gradient Boosting. *IEEE Geoscience and Remote Sensing Letters*, 15(4), 607–611. Scopus. <https://doi.org/10.1109/LGRS.2018.2803259>
- Giri, C. P. (2016). Brief Overview of Remote Sensing of Land Cover. Em C. P. Giri (Org.), *Remote Sensing of Land Use and Land Cover: Principles and Applications*. CRC Press. <https://doi.org/10.1201/b11964>
- Giuliani, G. (2024). Time-first approach for land cover mapping using big Earth observation data time-series in a data cube – a case study from the Lake Geneva region (Switzerland). *Big Earth Data*, 8(3), 435–466. <https://doi.org/10.1080/20964471.2024.2323241>
- Glimskär, A., & Skånes, H. (2018). Land Type Categories as a Complement to Land Use and Land Cover Attributes in Landscape Mapping and Monitoring. Em O. Ahlqvist, D. Varanka, S. Fritz, & K. Janowicz (Org.), *Land Use and Land Cover Semantics: Principles, Best Practices, and Prospects*. CRC Press. <https://doi.org/10.1201/9781351228596>
- Gribb, W. J., & Czerniak, R. J. (2018). Land Use/Land Cover Classification Systems and Their Relationship to Land Planning. Em O. Ahlqvist, D. Varanka, S. Fritz, & K. Janowicz (Org.), *Land Use and Land Cover Semantics: Principles, Best Practices, and Prospects*. CRC Press. <https://doi.org/10.1201/978135122859>
- Guo, M., Li, J., Sheng, C., Xu, J., & Wu, L. (2017). A review of wetland remote sensing. *Sensors (Switzerland)*, 17(4). Scopus. <https://doi.org/10.3390/s17040777>
- Harper, K., Lamarche, C., Hartley, A., Peylin, P., Otle, C., Bastrikov, V., San Martin, R., Bohnenstengel, S., Kirches, G., Boettcher, M., Shevchuk, R., Brockmann, C., & Defourny, P. (2023). A 29-year time series of annual 300 m resolution plant-functional-type maps for climate models. *Earth System Science Data*, 15, 1465–1499. <https://doi.org/10.5194/essd-15-1465-2023>
- Herold, M., Woodcock, C. E., Gregorio, A. di, Mayaux, P., Belward, A. S., Latham, J., & Schmullius, C. C. (2006). A joint initiative for harmonization and validation of land cover datasets. *IEEE Transactions on Geoscience and Remote Sensing*, 44(7), 1719–1727. <https://doi.org/10.1109/TGRS.2006.871219>
- IBGE. Instituto Brasileiro de Geografia e Estatística, (1992). *Manual técnico da vegetação brasileira* (1° ed.). Rio de Janeiro.

- <https://biblioteca.ibge.gov.br/pt/biblioteca-catalogo?view=detalhes&id=223267>
- IBGE. Instituto Brasileiro de Geografia e Estatística, (2012). *Manual técnico da vegetação brasileira* (2º ed.). Rio de Janeiro. <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=263011>
- IBGE. Instituto Brasileiro de Geografia e Estatística, (2013). *Manual técnico de uso da terra* (3ª edição). Rio de Janeiro. <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=281615>
- IBGE. Instituto Brasileiro de Geografia e Estatística, (2017). *MONITORAMENTO DA COBERTURA E USO DA TERRA DO BRASIL 2000 – 2010 – 2012 – 2014: EM GRADE TERRITORIAL ESTATÍSTICA*. Rio de Janeiro. <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101469>
- IBGE. Instituto Brasileiro de Geografia e Estatística, (2018a). *Desbravar, conhecer, mapear: Memórias do Projeto Radam/RadamBrasil*. Rio de Janeiro. <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101614>
- IBGE. Instituto Brasileiro de Geografia e Estatística, (2018b). *MAPEAMENTO DE USO E COBERTURA DA TERRA UTILIZANDO OS DADOS NUMERICOS DO CENSO AGROPECUARIO 2006*. Rio de Janeiro
- IBGE. Instituto Brasileiro de Geografia e Estatística, (2019). *Macrocaracterização dos Recursos Naturais do Brasil: Províncias estruturais, compartimentos de relevo, tipos de solos e regiões fitoecológicas*. Rio de Janeiro. <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101648>
- IBGE. Instituto Brasileiro de Geografia e Estatística, (2020). *Contas de ecossistemas: O uso da terra nos biomas brasileiros: 2000- 2018*. Rio de Janeiro. <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101754>
- IBGE. Instituto Brasileiro de Geografia e Estatística, (2022a). *Contas econômicas ambientais da terra: Contabilidade Física, Brasil, 2000/2020*. Rio de Janeiro. <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101965>
- IBGE. Instituto Brasileiro de Geografia e Estatística, (2022b). *Monitoramento da Cobertura e Uso da Terra do Brasil: 2018/2020*. Rio de Janeiro. <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101966>
- IBGE. Instituto Brasileiro de Geografia e Estatística, (2023). *Banco de Dados e Informações Ambientais (BDiA): Mapeamento de Recursos Naturais (MRN) Escala 1:250 000*. Rio de Janeiro. <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2102042>
- Impact Observatory. (2022). *Methodology & Accuracy Summary*. <https://www.impactobservatory.com/static/c033eb846160f6a0a35c63a64ef45e52/lulc-methodology-accuracy.pdf>
- Jansen, L. J. M. (2018). Parameterized Approaches to the Categorization of Land Use and Land Cover. Em O. Ahlqvist, D. Varanka, S. Fritz, & K. Janowicz (Org.), *Land Use and Land Cover Semantics: Principles, Best Practices, and Prospects*. CRC Press. <https://doi.org/10.1201/9781351228596>
- Karra, K., Kontgis, C., Statman-Weil, Z., Mazzariello, J. C., Mathis, M., & Brumby, S. P. (2021). Global land use / land cover with Sentinel 2 and deep learning. *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 4704–4707. <https://doi.org/10.1109/IGARSS47720.2021.9553499>
- Liu, L., Zhang, X., Gao, Y., Chen, X., Shuai, X., & Mi, J. (2021). Finer-Resolution Mapping of Global Land Cover: Recent Developments, Consistency Analysis, and Prospects. *Journal of Remote Sensing (United States)*, 2021. Scopus. <https://doi.org/10.34133/2021/528969>
- Loveland, T. R. (2016). History of LandCover Mapping. Em C. P. Giri (Org.), *Remote Sensing of Land Use and Land Cover: Principles and Applications*. CRC Press. <https://doi.org/10.1201/b11964>
- Lv, W., & Wang, X. (2020). Overview of Hyperspectral Image Classification. *Journal of Sensors*, 2020. Scopus. <https://doi.org/10.1155/2020/4817234>
- MapBiomas Project. (2024). *Collection 9 of the Annual Land Cover and Land Use Maps of Brazil (1985-2023)* [Conjunto de dados]. MapBiomas Data. <https://doi.org/10.58053/MAPBIOMAS/XXUKA>
- Mapbiomas Project. (2024). *MapBiomas General “Handbook”: Algorithm Theoretical Basis Document (ATBD): Collection 9*. <https://brasil.mapbiomas.org/wp-content/uploads/sites/4/2024/08/ATBD-Collection-9-v2.docx.pdf>
- Mashala, M. J., Dube, T., Mudereri, B. T., Ayisi, K. K., & Ramudzuli, M. R. (2023). A Systematic Review on Advancements in Remote Sensing for Assessing and Monitoring Land Use and Land Cover Changes Impacts on Surface Water Resources in Semi-Arid Tropical Environments.

- Remote Sensing*, 15(16). Scopus. <https://doi.org/10.3390/rs15163926>
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784–2817. Scopus. <https://doi.org/10.1080/01431161.2018.1433343>
- Mora, C., Spirandelli, D., Franklin, E. C., Lynham, J., Kantar, M. B., Miles, W., Smith, C. Z., Freel, K., Moy, J., Louis, L. V., Barba, E. W., Bettinger, K., Frazier, A. G., Colburn IX, J. F., Hanasaki, N., Hawkins, E., Hirabayashi, Y., Knorr, W., Little, C. M., ... Hunter, C. L. (2018). Broad threat to humanity from cumulative climate hazards intensified by greenhouse gas emissions. *Nature Climate Change*, 8(12), 1062–1071. Scopus. <https://doi.org/10.1038/s41558-018-0315-6>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247–259. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S., & Weng, Q. (2011). Per-pixel vs. Object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, 115(5), 1145–1161. Scopus. <https://doi.org/10.1016/j.rse.2010.12.017>
- Nações Unidas. (2016). *Sistema de Contas Econômicas Ambientais*. Comissão Econômica para a América Latina e o Caribe (CEPAL).
- Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., & Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, 42–57. Scopus. <https://doi.org/10.1016/j.rse.2014.02.015>
- Ozturk, M. Y., & Colkesen, I. (2024). A novel hybrid methodology integrating pixel- and object-based techniques for mapping land use and land cover from high-resolution satellite data. *International Journal of Remote Sensing*, 45(16), 5640–5678. <https://doi.org/10.1080/01431161.2024.2379515>
- Pelletier, C., Webb, G. I., & Petitjean, F. (2019). Temporal Convolutional Neural Network for the Classification of Satellite Image Time Series. *Remote Sensing*, 11(5), Artigo 5. <https://doi.org/10.3390/rs11050523>
- Phiri, D., & Morgenroth, J. (2017). Developments in Landsat land cover classification methods: A review. *Remote Sensing*, 9(9). Scopus. <https://doi.org/10.3390/rs9090967>
- Prăvălie, R., Patriche, C., Borrelli, P., Panagos, P., Roșca, B., Dumitrașcu, M., Nita, I.-A., Săvulescu, I., Birsan, M.-V., & Bandoc, G. (2021). Arable lands under the pressure of multiple land degradation processes. A global perspective. *Environmental Research*, 194. Scopus. <https://doi.org/10.1016/j.envres.2020.110697>
- Rahman, M., Ningsheng, C., Mahmud, G. I., Islam, M. M., Pourghasemi, H. R., Ahmad, H., Habumugisha, J. M., Washakh, R. M. A., Alam, M., Liu, E., Han, Z., Ni, H., Shufeng, T., & Dewan, A. (2021). Flooding and its relationship with land cover change, population growth, and road density. *Geoscience Frontiers*, 12(6). Scopus. <https://doi.org/10.1016/j.gsf.2021.101224>
- Rong, C., & Fu, W. (2023). A Comprehensive Review of Land Use and Land Cover Change Based on Knowledge Graph and Bibliometric Analyses. *Land*, 12(8), 1573. <https://doi.org/10.3390/land12081573>
- Salah, M. (2017). *A survey of modern classification techniques in remote sensing for improved image classification*. 11(1).
- Sheykhou, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308–6325. Scopus. <https://doi.org/10.1109/JSTARS.2020.3026724>
- Simões, R., Camara, G., Queiroz, G., Souza, F., Andrade, P., Santos, L., Carvalho, A., & Ferreira, K. (2021). Satellite Image Time Series Analysis for Big Earth Observation Data. *Remote Sensing*, 13(13), 2428. <https://doi.org/10.3390/rs13132428>
- Sims, N. C., Newnham, G. J., England, J. R., Cox, S. J. D., Roxburgh, S. H., Viscarra Rossel, R. A., Fritz, S., & Wheeler, I. (2021). *Good practice guidance. SDG indicator 15.3.1, Proportion of land that is degraded over total land area. Version 2.0*. (2.0). UNCCD. <https://www.unccd.int/resources/manuals-and-guides/good-practice-guidance-sdg-indicator-1531-proportion-land-degraded>
- Song, X.-P. (2023). The future of global land change monitoring. *International Journal of Digital Earth*, 16(1), 2279–2300. Scopus. <https://doi.org/10.1080/17538947.2023.2224586>
- Souza, C. M., Z. Shimbo, J., Rosa, M. R., Parente, L. L., A. Alencar, A., Rudorff, B. F. T., Hasenack, H., Matsumoto, M., G. Ferreira, L., Souza-Filho, P. W. M., de Oliveira, S. W., Rocha, W. F., Fonseca, A. V., Marques, C. B., Diniz, C. G., Costa, D., Monteiro, D., Rosa, E. R., Vélez-Martin, E., ... Azevedo, T. (2020). Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. *Remote Sensing*, 12(17), Artigo 17. <https://doi.org/10.3390/rs12172735>

- Sun, X., Wang, M., Wang, J., Li, G., & Hou, X. (2025). Deep learning classification of winter wheat from Sentinel optical-radar image time series in smallholder farming areas. *Advances in Space Research*, 75(3), 2683–2695. Scopus. <https://doi.org/10.1016/j.asr.2024.11.038>
- UNESCO. Organização das Nações Unidas para Educação, Ciência e Cultura, (2015). *STATUTES OF THE INTERNATIONAL GEOSCIENCE AND GEOPARKS PROGRAMME*. Paris. <https://unesdoc.unesco.org/ark:/48223/pf0000260675?posInSet=3&queryId=18a01105-ae82-4fb2-9824-08747d2c9257>
- Vali, A., Comai, S., & Matteucci, M. (2020). Deep learning for land use and land cover classification based on hyperspectral and multispectral earth observation data: A review. *Remote Sensing*, 12(15). Scopus. <https://doi.org/10.3390/RS12152495>
- Van Thinh, T., Duong, P. C., Nasahara, K. N., & Tadono, T. (2019). How does land use/land cover map's accuracy depend on number of classification classes? *Scientific Online Letters on the Atmosphere*, 15, 28–31. Scopus. <https://doi.org/10.2151/SOLA.2019-006>
- Veiga, A. J. P., Matta, J. M. B. da, Veiga, D. A. M., & Bomfim, C. S. S. (2020). Análise do uso e cobertura da terra em Itapetinga no estado da Bahia, Brasil, com uso de Sensoriamento Remoto e SIG / Analysis of the use and land cover in Itapetinga in the state of Bahia, Brazil, using Remote Sensing and GIS. *Brazilian Journal of Development*, 6(9), 73928–73947. <https://doi.org/10.34117/bjdv6n9-741>
- Verdum, R. (2016). As Múltiplas Abordagens para o Estudo da Paisagem The Multiples Approaches For The Landscape Study. *Espaço Aberto*, 6, 131–150.
- Wang, Y., Sun, Y., Cao, X., Wang, Y., Zhang, W., & Cheng, X. (2023). A review of regional and Global scale Land Use/Land Cover (LULC) mapping products generated from satellite remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 206, 311–334. <https://doi.org/10.1016/j.isprsjprs.2023.11.014>
- Wu, L., Sun, C., & Fan, F. (2021). Estimating the characteristic spatiotemporal variation in habitat quality using the invest model—A case study from guangdong–hong kong–macao greater bay area. *Remote Sensing*, 13(5), 1–24. Scopus. <https://doi.org/10.3390/rs13051008>
- Xie, G., Bai, X., Peng, Y., Li, Y., Zhang, C., Liu, Y., Liang, J., Fang, L., Chen, J., Men, J., Wang, X., Wang, G., Wang, Q., & Ren, S. (2024). Aquaculture Ponds Identification Based on Multi-Feature Combination Strategy and Machine Learning from Landsat-5/8 in a Typical Inland Lake of China. *Remote Sensing*, 16(12). Scopus. <https://doi.org/10.3390/rs16122168>