

MAYRA VANNESSA LIZCANO TOLEDO

**ESTUDO DO USO DA TERRA NA BACIA HIDROGRÁFICA DO RIO
SOROCABUÇU, IBIÚNA –SP PARA AVALIAÇÃO DE ÁREAS ELEGÍVEIS EM
PROJETOS MDL**

**Sorocaba
2023**

MAYRA VANNESSA LIZCANO TOLEDO

**ESTUDO DO USO DA TERRA NA BACIA HIDROGRÁFICA DO RIO
SOROCABUÇU, IBIÚNA – SP PARA AVALIAÇÃO DE ÁREAS ELEGÍVEIS
EM PROJETOS MDL**

Dissertação apresentada como requisito para a obtenção do título de Mestre em Ciências Ambientais da Universidade Estadual Paulista "Júlio de Mesquita Filho" na Área de Concentração Diagnóstico, Tratamento e Recuperação Ambiental

Orientador: Prof. Dr. Darllan Collins da Cunha e Silva

Coorientador: Prof. Dr. Roberto Wagner Lourenço

Sorocaba

2023

T649e

Toledo, Mayra Vanessa Lizcano

Estudo do uso da terra na bacia hidrográfica do Rio Sorocabaçu, Ibiúna – SP para avaliação de áreas elegíveis em projetos MDL / Mayra Vanessa Lizcano Toledo. --, Sorocaba, 2023

77 p.

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Instituto de Ciência e Tecnologia, Sorocaba,

Orientador: Darllan Collins da Cunha e Silva

Coorientador: Roberto Wagner Lourenço

1. Geoprocessamento. 2. Mata Atlântica. 3. Modelagem ambiental. 4. Índice de vegetação. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca do Instituto de Ciência e Tecnologia, Sorocaba.

Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: ESTUDO DO USO DA TERRA NA BACIA HIDROGRÁFICA DO RIO SOROCABUÇU, IBIÚNA – SP PARA AVALIAÇÃO DE ÁREAS ELEGÍVEIS EM PROJETOS MDL

AUTORA: MAYRA VANNESSA LIZCANO TOLEDO

ORIENTADOR: DARLLAN COLLINS DA CUNHA E SILVA

Aprovada como parte das exigências para obtenção do Título de Mestra em Ciências Ambientais, área: Diagnóstico, Tratamento e Recuperação Ambiental pela Comissão Examinadora:

Prof. Dr. DARLLAN COLLINS DA CUNHA E SILVA (Participação Virtual)
Departamento de Engenharia Ambiental / Unesp ICT Sorocaba

Darllan Collins
da Cunha e
Silva:223972678
45

Assinado de forma digital por Darllan Collins da Cunha e Silva:22397267845
Dados: 2023.02.23 15:40:38 -03'00'

Prof. Dr. RENAN ANGRIZANI DE OLIVEIRA (Participação Virtual)
Departamento de Engenharia Ambiental / Universidade de Sorocaba (UNISO)



Profª. Drª. VANESSA CEZAR SIMONETTI (Participação Virtual)
Departamento de Engenharia / Universidade de Sorocaba (UNISO)



Sorocaba, 23 de fevereiro de 2023

AGRADECIMENTOS

Ao meu orientador o Dr. Darllan Collins da Cunha e Silva pela sua orientação, incentivo, sugestões, contribuição e apoio ao longo do desenvolvimento deste trabalho.

Aos membros da comissão julgadora, Dra. Vanessa Cezar Simonetti e Dr. Renan Angrizani de Oliveira pelas críticas construtivas que permitiram o aprimoramento do estudo.

Aos docentes do mestrado em ciências ambientais da UNESP Sorocaba pelo conhecimento novo transmitido.

À secretaria de Pós-Graduação pela atenção, boa disposição e gestão em todos os momentos que entrei em contato com eles.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro a esta pesquisa.

Finalmente, à minha família e meus queridos Coquito e Luffy, os quais me deram forças e me apoiaram em todo momento para seguir meus sonhos.

TOLEDO, M. V. L. **Estudo do uso da terra na bacia hidrográfica do Rio Sorocabaçu, Ibiúna – SP para avaliação de áreas elegíveis em projetos MDL.** 2023. Dissertação (Mestrado em Ciências Ambientais), Universidade Estadual Paulista “Júlio de Mesquita Filho”. São Paulo - SP, 2023.

RESUMO

O crescimento da população ao longo dos anos tem levado a um maior consumo dos recursos naturais para garantir uma boa qualidade de vida, entretanto, tem gerado impactos negativos ao ambiente, especialmente nas florestas, as quais fornecem diversos serviços ambientais fundamentais e necessários para garantir a vida no planeta como, por exemplo, a captura de dióxido de carbono que contribui para atenuar os efeitos da mudança climática. Portanto, o reflorestamento permite garantir a sustentabilidade dos serviços ambientais proporcionados pelas florestas, além da qualidade de vida para as gerações futuras. É importante que os projetos destinados a recuperação e expansão daquela cobertura vegetal sejam desenvolvidos em áreas estratégicas que garantam o investimento realizado. Neste sentido, o objetivo deste estudo foi identificar e avaliar áreas com ausência de atividade econômica que apresentassem potencial para o desenvolvimento de projetos que contribuam ao Mecanismo de Desenvolvimento Limpo (MDL). Para o desenvolvimento deste estudo foi selecionada a bacia hidrográfica do Rio Sorocabaçu, a qual se encontra inserida na Área de Proteção Ambiental (APA) de Itupararanga. A metodologia utilizada consistiu na elaboração de mapas temáticos de uso da terra a partir de imagens do satélite Landsat 5 TM e Landsat 8 OLI para os anos 2000 e 2020, respectivamente; onde a classificação das imagens se deram pelo uso de redes neurais artificiais do tipo *Multilayer Perceptron* (MLP), além disso, foi realizado o cálculo e análise temporal do estado da vegetação através do Índice de Vegetação por Diferença Normalizada (NDVI). Finalmente, utilizou-se ferramenta *Land Change Modeler* (LCM) para analisar as mudanças ocorridas no período estudado e calculado o potencial de transição e a identificação e elaboração de um mapa temático das áreas viáveis para o desenvolvimento de projetos que contribuam com o MDL. Foi identificada uma elevada perda de áreas de vegetação natural entre os anos 2000 e 2020, bem como uma expansão das áreas antrópicas, tanto agrícolas quanto não agrícolas; por outra parte, o NDVI calculado mostrou que não há áreas com vegetação saudáveis e que as áreas com maior saúde vegetal estão, principalmente, em áreas com maior declividade. Por fim foi determinado que 1,38% da área de estudo apresenta áreas com alta elegibilidade para implementação de projetos que contribuam com o MDL.

Palavras-chaves: Geoprocessamento. Mata Atlântica. Modelagem ambiental. Índice de vegetação.

TOLEDO, M. V. L. **Study of land use in the Sorocabaçu River watershed, Ibiúna - SP, for evaluation of eligible areas in MDL projects.** 2023. Dissertation (Master in Environmental Sciences), Universidade Estadual Paulista “Júlio de Mesquita Filho”. São Paulo - SP, 2023.

ABSTRACT

The population growth over the years has led to greater consumption of natural resources to ensure a good quality of life. However, this has had negative impacts on the environment, especially in forests, which provide various fundamental environmental services necessary for life on the planet, such as the capture of carbon dioxide, which helps mitigate the effects of climate change. Therefore, reforestation allows for the sustainability of the environmental services provided by forests, as well as the quality of life for future generations. It is important that projects aimed at recovering and expanding forest cover be developed in strategic areas that ensure the investment made. In this sense, the objective of this study was to identify and evaluate areas with no economic activity that presented potential for the development of projects that contribute to the Clean Development Mechanism (CDM). For the development of this study, the Sorocabaçu River watershed was selected, which is located in the Itupararanga Environmental Protection Area (APA). The methodology used consisted of the preparation of thematic maps of land use based on Landsat 5 TM and Landsat 8 OLI satellite images for the years 2000 and 2020, respectively. The classification of the images was carried out using Multilayer Perceptron (MLP) artificial neural networks. In addition, the calculation and temporal analysis of vegetation status was performed using the Normalized Difference Vegetation Index (NDVI). Finally, the Land Change Modeler (LCM) tool was used to analyze the changes that occurred during the study period, calculate the transition potential, and identify and prepare a thematic map of viable areas for the development of projects that contribute to the CDM. A high loss of natural vegetation areas was identified between 2000 and 2020, as well as an expansion of anthropogenic areas, both agricultural and non-agricultural. The calculated NDVI showed that there are no areas with healthy vegetation and that the areas with the healthiest vegetation are mainly in areas with steeper slopes. Finally, it was determined that 1.38% of the study area presents areas with high eligibility for the implementation of projects that contribute to the CDM.

Keywords: Geoprocessing. Atlantic Forest. Environmental modeling. Vegetation Index.

LISTA DE FIGURAS

Figura 1. Emissões de CO ₂ no Brasil no período de 1999 – 2020.....	26
Figura 2. Participação dos setores nas emissões de CO ₂ no Brasil.....	27
Figura 3. Localização da área de estudo.....	30
Figura 4. Esboço metodológico.....	32
Figura 5. Esquema do sistema fuzzy.....	40
Figura 6. Esquema potencial de transição.....	41
Figura 7. Esquema potencial índice de vegetação classificado.....	41
Figura 8. Esquema de elegibilidade das áreas.....	41
Figura 9. Superfície do sistema.....	42
Figura 10. Classificação dos usos da terra para os anos 2000 (A) e 2020 (B).	43
Figura 11. Reclassificação do uso da terra.....	47
Figura 12. Resultado do estado fotossintético da vegetação para a bacia do Rio Sorocabaçu para o ano 2020.	48
Figura 13. Reclassificação NDVI para o ano 2020.....	49
Figura 14. Mudanças de áreas estabilizadas para outras classes.....	51
Figura 15. Persistências das classes no período estudado.....	52
Figura 16. Tendência espacial da mudança do uso da terra.....	53
Figura 17. Variáveis de condução A) Evidence Likelihood B) Distância das principais rodovias C) distância às áreas antrópicas não agrícolas D) distância aos corpos d'água E) Altitude F) Declividade	55
Figura 18. Potencial de transição. A) para Áreas estabilizadas B) para Áreas restritas.....	57
Figura 19. A) PTF normalizado B) PTF reclassificado.....	58
Figura 20. Elegibilidade das áreas.....	59

LISTA DE TABELAS

Tabela 1. Descrição das bandas do satélite Landsat 8.	21
Tabela 2. Informação das imagens de satélite utilizadas	33
Tabela 3. Descrição das classes	34
Tabela 4. Interpretação do índice Kappa	35
Tabela 5. Classificação do NDVI	37
Tabela 6. Potencialidade de consolidação.	39
Tabela 7. Elegibilidade das áreas.....	40
Tabela 8. Regras do sistema.	42
Tabela 9. Mudança da cobertura do solo entre o 2000 e 2020.....	44
Tabela 10. Matriz de confusão da classificação do ano 2000.....	46
Tabela 11. Matriz de confusão da classificação do ano de 2020.....	46
Tabela 12. Mudança temporal para cada classe.....	52
Tabela 13. Teste Cramer 's V.....	56

LISTA DE ABREVIATURAS E SIGLAS

AE	Áreas Estabilizadas
AI	Áreas de Interesse
AR	Áreas Restritas
ANNs	<i>Artificial Neural Networks</i>
APA	Área de Preservação Ambiental
BHRS	Bacia Hidrográfica do Rio Sorocabaçu
BP	<i>Back-Propagation</i>
CDB	Convenção Sobre Diversidade Biológica
CFC	Clorofluorcarbono
CH ₄	Metano
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ErroC	Erro de Comissão
ErroO	Erro de Omissão
GEE	Gases Efeito Estufa
IA	Inteligência Artificial
INPE	Instituto Nacional de Pesquisas Espaciais
IPCC	<i>Intergovernmental Panel on Climate Change</i>
Landsat	<i>Land Remote Sensing Satellite</i>
LCM	<i>Land Change Modeler</i>
MDL	Mecanismo de Desenvolvimento Limpo
MLP	<i>Multilayer Perceptron</i>
NASA	<i>National Aeronautics and Space Administration</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	<i>Near Infrared</i>
NO ₂	Óxido Nitroso
O ₃	Ozônio
OLI	<i>Operational Land Imager</i>
OMM	<i>World Meteorological Organization</i>
PIB	Produto Interno Bruto
PPM	Partes por milhão
PSA	Pagamento por Serviços Ambientais
PTF	Potencial de Transição Final

RCE	Redução Certificada de Emissão
RNA	Redes Neurais Artificiais
SEEG	Sistema de Estimativa de Gases Efeito Estufa
SIG	Sistema de Informação Geográfica
SOM	Self-Organizing Map
TM	Thematic Mapper
UGRHI	Unidade Hidrográfica de Gerenciamento de Recursos Hídricos
UNEP	United Nations Environment Programme
UNESCO	United Nations Educational, Scientific and Cultural Organization
USGS	United States Geological Survey

SUMÁRIO

1. INTRODUÇÃO	12
2. JUSTIFICATIVA	15
3. OBJETIVOS	18
3.1. Geral	18
3.2. Específicos	18
4. REVISÃO BIBLIOGRÁFICA	19
4.1. Instrumentos para análise espacial de dados ambientais	19
4.2. Inteligência artificial aplicada ao processamento de imagens	21
4.3. Relevância das florestas para a sustentabilidade	23
4.4. Mecanismo de desenvolvimento limpo e alternativas para conservação de áreas de vegetação natural	28
5. MATERIAL E MÉTODOS	30
5.1. Área de estudo	30
5.2. Procedimentos Metodológicos	31
5.3. Elaboração dos mapas da classificação de uso da terra para os anos 2000 e 2020	33
5.3.1. Obtenção e processamento da imagem de satélite	33
5.3.2. Classificação das imagens de satélite	33
5.4. Cálculo e classificação do índice da vegetação por diferença normalizada	36
5.5. Modelagem e geração de cenários viáveis	37
5.5.1. Análise temporal das mudanças do uso da terra	37
5.5.2. Obtenção do potencial de transição	37
5.5.3. Sistema Fuzzy para definição das áreas aptas ao MDL	40
6. RESULTADOS E DISCUSSÃO	43
6.1. Construção dos mapas da classificação de uso da terra para os anos 2000 e 2020	43
6.1.1. Avaliação da classificação dos mapas de uso da terra	45
6.2. Classificação do estado fotoquímico da vegetação	47
6.2.1. Índice de Vegetação por Diferença Normalizada	47
6.2.2. Reclassificação do índice de Vegetação por Diferença Normalizada	49
6.3. Modelagem e geração de cenários elegíveis	50
6.3.1. Análise temporal das mudanças.....	50
6.3.2. Modelo do potencial de transição	54
7. CONCLUSÕES	61
REFERÊNCIAS	63

1. INTRODUÇÃO

As florestas são áreas cobertas por formações vegetais, principalmente árvores. Estas constituem 31% da superfície do planeta, no entanto, mais da metade das florestas do mundo encontra-se distribuídas nos seguintes países: Rússia (20%), Brasil (12%), Canadá (9%), Estados Unidos (8%), China (5%) e Austrália (3%) (FAO, 2002; FAO; PNUMA, 2020).

Estas oferecem diversos serviços ambientais que permitem uma melhor qualidade de vida para os organismos vivos, entre estes, cabe destacar a manutenção da biodiversidade, regulação do ciclo da água e a captura de carbono, o qual implica na redução dos gases de efeito estufa e mitigação da mudança climática (MÜLLER *et al.*, 2020; RICHIT *et al.*, 2021).

No entanto, as florestas vêm sendo abruptamente afetadas ao longo dos anos, ocasionando a perda da saúde e vitalidade das árvores; dentre as causas deste fenômeno, podemos destacar as causas naturais, tais como incêndios, pragas, doenças, fenômenos meteorológicos; e causas antrópicas, sendo a expansão agrícola a principal razão do desflorestamento e fragmentação das florestas, além de atividades pecuárias e industriais (FAO;PNUMA, 2020).

A degradação florestal traz ainda diversas consequências, como a redução da capacidade de obtenção de materiais como madeira, forragem e plantas medicinais, além dos benefícios econômicos e a segurança alimentar provenientes das florestas (SANHUEZA; ANTONIESEN, 2014).

Existem diversos estudos focalizados na perda dos serviços ecossistêmicos devido a diversas atividades antropogênicas, como o realizado por Xiang *et al.* (2021) onde é quantificada a diminuição desses serviços em áreas de mineração, principalmente os serviços de regulação como o de retenção de água e o de provisão como produção de grãos, assim como o estudo feito por Bera *et al.* (2022) no qual foram analisados os distúrbios arraigados do desmatamento em florestas entre os anos 2006 e 2020 e verificado que a alta taxa de perda de cobertura florestal ocasionou uma diminuição do serviço ecossistêmico de provisão, principalmente na disponibilidade de plantas medicinais e materiais de construção.

Além disso, é possível citar as consequências sobre bacias hidrográficas, visto que as florestas são essenciais em zonas ripárias para o controle da erosão, que pode contribuir com a sedimentação nos cursos de água, afetando a qualidade da

água e conseqüentemente as atividades de pesca, como também podem desencadear o aumento da perda de água por evapotranspiração; portanto, a perda da cobertura vegetal tem conseqüências sobre o meio ambiente, causando um aumento da temperatura no planeta, o qual afeta a conservação da diversidade biológica para espécies vegetais e animais (FAO, 2000).

O crescimento e desenvolvimento populacional, têm provocado uma alta demanda de recursos naturais o que tem gerado, ao longo dos anos, um incremento nas taxas de desmatamento; no período compreendido entre 1990 e 2020 a perda da superfície vegetal no mundo diminuiu em um total de 178 milhões de hectares; da mesma forma, o Painel Intergovernamental sobre Mudanças Climáticas (IPCC), que conduz avaliações sobre a mudança climática, estimou que a variação climática ocasionada por ações antrópicas desde 2000, é de aproximadamente 0,8 °C à 1,2 °C, representando um aumento de 20%, o que se deve em maior parte ao aumento da concentração de CO₂ no ambiente; para o ano 2015 foi de 400 ppm, enquanto para o mês de junho de 2022 é de 417 ppm (NOAA, 2022; OMM, 2016; FAO; PNUMA, 2020; IPCC, 2020).

Neste sentido, em 1997 foi aprovado o protocolo de Kyoto, um tratado internacional entre os países, com o objetivo de reduzir as emissões de gases efeito estufa mediante políticas e medidas de mitigação, como o comércio internacional de emissões, “aplicação conjunta” que permite aos países do anexo B cumprir com a meta estabelecida através da implementação de projetos em países pertencentes e, finalmente, como último instrumento encontra-se o Mecanismo de Desenvolvimento Limpo (MDL), que consiste em implementar projetos de redução das emissões em países em desenvolvimento (UNFCCC, 1997).

O Brasil é um dos países com maior diversidade biológica no mundo, detentor de mais de 20% do total de espécies do planeta segundo o Ministério do Meio Ambiente (MMA, 2020); adicionalmente, o país encabeça a lista em questão de biodiversidade de mamíferos e peixes de água doce; em relação às florestas do país, estas têm uma capacidade de absorção de carbono de 3,05 Mg C ha⁻¹ ano⁻¹, porém, esta capacidade tem sido afetada pelo desmatamento ao longo dos anos (MELO; TEJERINA, 2007; SILVA *et al.*, 2020; TCN, 2018; UNEP, 2019; UNESCO, 2019).

No período compreendido entre 1985 e 2018, houve uma redução da cobertura vegetal de 12%; no entanto, no ano de 2016 o Brasil assinou o acordo de Paris, comprometendo-se a reduzir suas emissões em 43% até 2025 comparado as

emissões do ano 2005, para isto, foram estabelecidos objetivos de reflorestamento que permitissem cumprir a meta (MELO; TEJERINA, 2007; SILVA *et al.*, 2020; TCN, 2018; UNEP, 2019; UNESCO, 2019).

Portanto, tendo em vista a problemática apresentada no que se refere as mudanças climáticas e a degradação das florestas, o presente estudo tem o objetivo de avaliar o potencial da bacia hidrográfica do Rio Sorocabuçu para a implementação de projetos que contribuam para Mecanismo de Desenvolvimento Limpo através da utilização de ferramentas de geoprocessamento, o que permite a identificação do uso da terra e estado temporal da vegetação, para a identificação das áreas elegíveis para o desenvolvimento de projetos que contribuam aoMDL, a partir o uso de um sistema de inferência fuzzy.

2. JUSTIFICATIVA

As florestas representam um dos mais importantes ecossistemas do mundo, principalmente pela contribuição na captura de dióxido de carbono que influencia no clima e ciclo do carbono, sendo consideradas os principais sumidouros de carbono, sem embargo, esta capacidade tem sido afetada pelo desmatamento; apesar destes ecossistemas serem resilientes, encontram-se também sujeitos a fatores como solo, clima, disponibilidade de nutrientes entre outros, o que limita o crescimento das florestas e os benefícios que proveem (ATTIA *et al.*, 2019).

Por outro lado, o dióxido de carbono (CO₂) é um gás de efeito estufa que se encontra em maior concentração na atmosfera; este permite, em conjunto com outros gases, que a temperatura da terra seja adequada para a existência da vida no planeta, não obstante, as altas porcentagens de perdas em áreas florestais têm sido um dos maiores responsáveis pela diminuição na captura de carbono, contribuindo de forma significativa com o desequilíbrio climático e hidrológico em diversos países; isto tem como principais consequências a perda de biodiversidade e o prejuízo à saúde pública, e, por estes motivos, existe um consenso entre a comunidade científica de que é necessário limitar o aumento da temperatura através da mitigação das emissões de gases efeito estufa (LEFEBVRE *et al.*, 2019).

Diante disto, se faz necessário o desenvolvimento de modelos que possam contribuir com a otimização dos esforços e investimento econômico direcionados aos estudos do potencial de captura e sequestro de carbono por florestas secundárias em bacias hidrográficas; estas são importantes unidades de gestão hídrica com dimensões de difícil mensuração, mas que são de extrema importância no contexto do monitoramento dos fatores que têm influência relevante nas alterações do uso da terra com forte impacto no ciclo climático e hidrológico, em especial no balanço de energia em função da variabilidade no fluxo de carbono (SOARES, 2018).

Sendo assim, tem-se desenvolvido, acordos com o objetivo de promover alternativas que permitam a redução de emissões, entres estes, se destaca o Mecanismo de Desenvolvimento Limpo (MDL), proposto no protocolo de Kyoto em 1997, o qual entrou em vigor no ano 2004 com a principal finalidade de implementar projetos por partados países de primeiro mundo que cumpram com este fim visando o cumprimento da quota de redução de emissões (WEI *et al.*, 2012).

Além disso, diversos encontros foram realizados para debater as mudanças

climáticas, dentre esses encontram-se os desenvolvidos pela Convenção-Quadro das Nações Unidas sobre Mudança do Clima (UNFCCC); na COP15, foram estabelecidos os objetivos do Acordo de Copenhague, que buscava limitar o aumento da temperatura global a 2°C em relação aos níveis pré-industriais. Na COP18, foram tomadas decisões sobre o segundo período de compromisso do Protocolo de Quioto. A COP21 resultou na assinatura do Acordo de Paris, que busca limitar o aumento da temperatura abaixo de 2°C e reduzir a dependência de combustíveis fósseis. A COP22 focou na implementação do Acordo de Paris. A COP26 teve como principal objetivo avançar na implementação do Acordo de Paris e acelerar a ação climática global (CHECHI, 2019).

Dentre os países signatários do MDL, o Brasil foi um dos países que se comprometeu e aderiu ao acordo, onde para o cumprimento dos objetivos estabelecidos, optou pelo investimento em reflorestamento, porém, a principal problemática apresentada é a escolha de áreas que possuam o potencial para o desenvolvimento deste tipo de projeto e que, com o crescimento das áreas urbanas e expansão agrícola, além de outras atividades, não coloquem em risco o investimento realizado; logo, surge a importância da identificação de áreas que possuam as condições ideais para a implementação de projetos que possam garantir eficiência no manejo de recursos naturais (SILVA *et al.*, 2021).

Com o crescente desenvolvimento da ciência, vem ocorrendo um aumento das ferramentas disponíveis para efetuar estudos do uso da terra, neste sentido, se destaca o sensoriamento remoto, empregado em estudos com diferentes escalas de tempo e espaço, tornando-se uma relevante ferramenta para estudos que consideram as variações de carbono produto da interação floresta-atmosfera (LAUCH *et al.*, 2018).

Por conseguinte, é compreensível o empenho na melhora dos instrumentos utilizados para coleta de informação visando uma maior eficiência através da automatização dos processos, o que conduz ao desenvolvimento de algoritmos, com alto grau de confiabilidade na produção da informação espacial (DUBREUIL *et al.*, 2017; LI *et al.*, 2018; LOURENÇO *et al.*, 2015; REIS *et al.*, 2019; RICHARDSON *et al.*, 2018; SILVA *et al.*, 2019; SOUZA *et al.*, 2019).

Nos últimos anos, tem-se notado um aumento no interesse de abordar áreas da ciência com potencial na resolução de problemas que envolvem o reconhecimento de padrões e a classificação espectral de imagens de satélite; trata-

se das técnicas de Inteligência Artificial (IA), que em linhas gerais consiste em desenvolver paradigmas ou algoritmos que permitam às máquinas realizar tarefas cognitivas como as geralmente desenvolvidas pelos humanos; um sistema IA pode ser estruturado para cumprir três funções fundamentais: representar o conhecimento, operar com o conhecimento armazenado (raciocínio) e ampliar este conhecimento com a experiência (aprendizagem) (HAYKIN, 2009; JARAMILLO; ANTUNES, 2018).

Um desses sistemas é tradicionalmente denominado de Redes Neurais Artificiais (RNAs), intuitivamente, pode-se dizer que uma RNA pode adquirir conhecimento por um processo de aprendizado, e que o conhecimento pode ser armazenado a partir da análise de determinadas características de um objeto, como por exemplo, em uma imagem a partir do reconhecimento de cada pixel de uma classe que represente alguma classe em uma imagem, contida em determinada área geográfica (JARAMILLO; ANTUNES, 2018).

Em relação a acurácia apresentada no uso da inteligência artificial para estudos de modelagem do uso da terra, existem diversos estudos que avaliam o potencial desta ferramenta, a qual tem apresentado resultados favoráveis com alto grau de confiabilidade, como exemplo esta o estudo realizado por Liakos *et al.* (2018), no qual foi realizada uma revisão de diversas pesquisas sobre a aplicabilidade da inteligência artificial na área de ciências exatas e da terra, concluindo que a inteligência artificial representa uma ferramenta eficiente e eficaz para no desenvolvimento deste tipo de estudos; da mesma maneira Inazumi *et al.* (2020) determinaram a eficácia do uso da inteligência artificial na classificação do uso da terra.

Finalmente, é importante mencionar que em relação ao reflorestamento, o esforço encontra-se focalizado na Amazônia, enquanto ao Estado de São Paulo, os estudos encontram-se centrados na expansão agrícola, principalmente na avaliação de áreas para cultivo de cana-de-açúcar, os estudos de reflorestamento no estado são de alta importância já que São Paulo é o principal centro econômico e industrial do país (SARAIVA *et al.*, 2020; SILVA *et al.*, 2021).

3. OBJETIVOS

3.1. Geral

Identificar possíveis áreas com ausência de atividades econômicas presentes na bacia hidrográfica do Rio Sorocabuçu para implementação de práticas que contribuam para o desenvolvimento de projetos que corroboram com o MDL com o auxílio de um sistema de inferência Fuzzy.

3.2. Específicos

- Analisar a variação temporal do uso da terra para os anos 2000 e 2020 através do uso de inteligência artificial.
- Avaliar o estado fotossintético da vegetação para o ano 2020 por meio do índice de vegetação por diferença normalizada (NDVI).
- Calcular o potencial de transição das classes de uso da terra entre os anos 2000 e 2020.
- Identificar possíveis áreas sem atividade econômica com maior potencial para o desenvolvimento de projetos que contribuam ao MDL com o auxílio de um sistema de inferência Fuzzy.

4. REVISÃO BIBLIOGRÁFICA

4.1. Instrumentos para análise espacial de dados ambientais

O Sistema de Informação Geográfica (SIG), faz referência ao uso de ferramentas que permitem a administração e análise de dados, através de softwares com os quais são processadas as informações necessárias à criação de gráficos e mapas que facilitem sua interpretação e permitam a tomada de decisão (FAUSTINO, 2022).

Em relação à obtenção de dados da superfície terrestre, o sensoriamento remoto é um instrumento que permite a planificação de dados ambientais que possibilitam realizar estudos de análises lineares, estatísticos com o manejo de distintas variáveis em grandes superfícies de forma temporal (ÁLVAREZ *et al.*, 2014; NIETO *et al.*, 2011).

Entre as vantagens do sensoriamento remoto destaca-se a possibilidade de trabalhar com áreas de grande superfície e de difícil acesso, obtenção de uma grande quantidade de informação através de uma imagem permitindo a tomada de decisão que vise a prevenção, mitigação de desastres e recuperação de áreas degradadas (ÁLVAREZ *et al.*, 2014; NIETO *et al.*, 2011).

Dentre os produtos com essas características, destaca-se as imagens obtidas pelos satélites da série Landsat, os quais representam uns dos serviços mais longevos e utilizados no sensoriamento remoto; o programa Landsat foi lançado em 1972 pela Administração Nacional da Aeronáutica e Espaço (NASA) em conjunto com o Serviço Geológico dos Estados Unidos (USGS), este consiste na observação da superfície da Terra através de um satélite, permitindo capturar e analisar as mudanças da Terra com média resolução espacial (NASA; USGS, 2013).

As imagens dos satélites Landsat permitem o registro do estado da cobertura da superfície da Terra e, conseqüentemente, o desenvolvimento de diversos estudos como monitoramentos de florestas, espécies invasoras, diversidade biológica, atividade vulcânica, saúde das florestas, atmosfera, geleiras, incêndios, mudanças do uso da Terra, corpos de água, fenologia vegetal, doenças por vetores, crescimento urbano, classificação dos tipos de cobertura urbana, entre outros (VIDA; GALLARDO, 2020).

Para a aquisição das imagens de satélites, deve-se considerar que estas tenham a informação da refletância da superfície terrestre, ou seja, apresentem um baixopercentual de nebulosidade (VIDA; GALLARDO, 2020). Caso contrário, a informações das imagens de satélite podem ser obstruídas pela presença de nuvens, sendo necessário efetuar uma correção radiométrica e atmosférica, o que proporcionará uma melhor qualidade da imagem, além de permitir uma maior facilidade de identificação dos componentes requeridos para o objetivo proposto (AGUILAR *et al.*, 2014).

O satélite Landsat 8, atualmente em operação, conta com onze bandas espectrais, conforme pode ser observado na Tabela 1. É importante mencionar que as bandas 10 e 11 tem uma resolução espacial de 100 m, porém podem ser redimensionadas para 30 m (IGAC, 2013).

Tabela 1. Descrição das bandas do satélite Landsat 8.

	Banda	Descrição	Comprimento de onda (nm)	Resolução
Landsat 8 Operational Land Imager (OLI) and Thermal Infrared Sensor (TIRS)	1	Aerossol costeiro	430 – 450	30
	2	Azul	450 – 510	30
	3	Verde	530 – 590	30
	4	Vermelho	640 – 670	30
	5	Infravermelho	850 – 880	30
	6	SWIR 1	1570 – 1650	30
	7	SWIR 2	2110 – 2290	30
	8	Pancromático	500 – 580	15
	9	Cirrus	1360 – 1380	30
	10	Infravermelho térmico (TIRS 1)	1060 – 1119	10
	11	Infravermelho térmico (TIRS 2)	1150 – 1251	10

Fonte: IGAC, 2013

Uma parte fundamental dos satélites são as bandas que compõem eles, as quais representam a divisão do espectro eletromagnético que contém a radiação captada pelos sensores do satélite, onde estes dados são armazenados como arquivos tipo raster (FAUSTINO, 2022).

Graças à composição das bandas pode-se obter informação que permite

uma melhor análise dos dados, isto consiste em realizar uma combinação de 3 bandas as quais se atribui uma cor primária do RGB (vermelho, verde e azul) como, por exemplo, a combinação das bandas 4, 3, 2 que outorgam a cor natural ou 5, 4, 3 que corresponde às bandas do infravermelho e vermelho, as quais facilitam a identificação da vegetação (NIETO, 2016; RODRIGUEZ; GUTIÉRREZ, 2017). Ao se utilizar a banda do infravermelho, um dos usos mais frequentes desta é para a geração de índices de vegetação, dos quais o que mais se destaca é o Índice de Vegetação por Diferença Normalizada (NDVI) (COSTA *et al.*, 2020).

4.2. Inteligência artificial aplicada ao processamento de imagens

Existem diversas ferramentas para o processamento de imagens de satélite, que proporcionam uma alta quantidade de alternativas para o seu uso, como a classificação temática, que permite a extração de informação através da interpretação dos *pixels* numa área que segue padrões de comportamento semelhantes, com o objetivo de estabelecer classes de interesse numa superfície terrestre (SUAREZ, *et al.*, 2017).

Uma destas é a inteligência artificial, a qual é descrita como um conjunto de algoritmos baseados na lógica, outorgando a capacidade de raciocínio e autoaprendizagem, visando a solução de problemas a partir de informação disponibilizada em bases de dados; existem ainda diversos tipos de inteligência artificial, destacando-se as árvores de decisão, lógica difusa, redes neurais, entre outras (ZHANG; LU, 2021).

As Redes Neurais Artificiais (RNA) são métodos que contribuem com a solução de problemas com um rápido e preciso processamento de informação, estas se encontram conformadas por módulos que recebem e analisam os dados. No funcionamento básico de uma RNA existe uma somatória de cada entrada de dados (geralmente representada como $x_1 x_2 \dots x_n$) o qual é multiplicado pelo peso associado (w_1, w_2, \dots, w_n); se produz uma saída (y) quando o resultado passa por uma função de ativação ($F^{(u_k)}$) para finalmente ser processada na camada seguinte (SANTOS, 2018; HAYKIN, 2009).

É importante mencionar que as redes neurais artificiais tem a capacidade de aprender com exemplos, de tal forma que se pode reduzir a porcentagem de erros nos resultados; em relação à estrutura da rede neural artificial, esta

depende do tipo de situação a ser desenvolvida, quanto maior complexidade do problema e dados a serem processados, maior será o conjunto de variáveis, além do número de camadas necessárias para sua resolução (SILVA *et al.*, 2015; SANTOS, 2018). Dentre as estruturas de redes neurais artificiais, destaca-se as redes neurais de uma camada, multi-camada perceptron (MLP) e de propagação.

Segundo Rios *et al.* (2020), as redes neurais de uma camada representam a organização mais simples das redes neurais, sendo denominada de camada única, pois os dados de entrada se conectam de forma direta à camada de saída, não obstante, a principal desvantagem deste tipo é sua incapacidade de resolução de problemas de duas ou mais variáveis (SANTOS, 2018).

A RNA do tipo MLP é um classificador de várias camadas, se distinguindo por apresentar uma camada de entrada e saída, além de uma ou mais camadas ocultas, todas conectadas entre si, onde cada camada contém nós, e cada nó está interligado por pesos com todos os nós da camada subsequente (HSIEH, 2009; KARUL; SOYUPAK, 2006).

A MLP usa o algoritmo de retro propagação (BP - *back-propagation*) por meio de alguma função não-linear para a transformação das entradas em saídas.

$$x_o = f \left(\sum_{h=1}^H (x_h \times w_{h,o}) \right) \quad (1)$$

Em redes neurais, a função mais comumente utilizada é a sigmoideal não-linear que é aplicada à soma ponderada das entradas antes de ser passada para a próxima camada. Após essa etapa de propagação, as atividades dos nós de saída são comparadas às atividades esperadas, quando um padrão é apresentado à rede, cada nó de saída gera um valor que indica a semelhança entre o padrão de entrada e a classe correspondente, sendo importante mencionar que normalmente, a saída real será diferente do resultado esperado, e essa diferença é conhecida como erro da rede (LORONI, 2007).

A RNA de propagação apresenta um circuito de retroalimentação, esta organização permite ao sistema a capacidade de aprendizagem o qual tem um

grande impacto na eficácia dos resultados; é importante mencionar que o uso de circuitos requer a utilização de unidades de retardo (Z^{-1}) que permitem o deslocamento temporal na dinâmica, fortalecendo a aprendizagem das RNAs (OLIVIERA *et al.*, 2008; RIOS *et al.*, 2020).

No caso de processamento de imagem, os três tipos de RNA que melhor se adaptam a classificação de imagens de satélite são: a RNA do tipo multi-camada; a RNA baseada na teoria de ressonância adaptativa (*Fuzzy ARTMAP*); e a RNA baseada na capacidade auto organizável de diminuir a dimensão de um grupo de dados (SOM - *Self-Organizing Map*), com o auxílio de técnicas de sensoriamento remoto buscando desenvolver uma metodologia automatizada, alternativa aos métodos tradicionais de determinação de estágios de sucessão florestal, com nível de precisão e confiabilidade de forma mais ágil e com menores custos operacionais (ALIABAD, 2022; SUCITHRA; GLADSTON, 2022).

Entre outros tipos de redes neurais encontra-se as Redes Neurais Convolucionais a qual tem sido amplamente utilizada devido a sua eficácia no processo de autoaprendizado de conceitos complexos ou características abstratas com o objetivo de reconhecer padrões e classificar imagens. O funcionamento deste tipo de rede neural consiste na extração de informação através das camadas convolucionais, de ativação, de amostragem, campos receptivos locais e compartilhamento de pesos entre neurônios que permitem aproveitar as características de uma imagem para reduzir a complexidade desta, facilitando a análise e obtenção de informação (SBITKOWSKI *et al.*, 2021).

É importante mencionar que ao longo dos anos o sensoriamento remoto além do uso da inteligência artificial tem permitido a expansão do conhecimento em diversos campos da ciência aportando informação relevante e de alta confiabilidade, contando com diversas funcionalidades que permitem uma melhor tomada de decisões em questão do manejo e gestão dos recursos naturais do planeta (CAMACHO *et al.*, 2015).

4.3. Relevância das florestas para a sustentabilidade

As florestas são de vital importância aos seres vivos e ao planeta, visto que proporcionam diversos serviços ecossistêmicos ou serviços ambientais,

representam a capacidade do ambiente e processos naturais de oferecerem funções e benefícios, de maneira direta ou indireta, os quais refletem no bem-estar e qualidade de vida dos seres vivos no planeta (MONTEIRO *et al.*, 2019). Estes encontram-se divididos em 4 categorias, as quais foram propostas pela Avaliação Ecosistêmica do Milênio (AEM) em 2005 da ONU, descritas adiante:

- Provisão: abastece ao ser humano de bens, recursos e matérias-primas para consumo ou comercialização.
- Regulação: são aqueles processos naturais que influenciam nas condições ambientais sendo responsável da manutenção do equilíbrio do estado do ambiente.
- Suporte: contribuem à existência dos outros serviços, sendo responsáveis de processos que garantem a perenidade da vida no planeta.
- Cultural: representam aqueles benefícios intangíveis que contribuem com o enriquecimento cultural, religioso ou espiritual.

Apesar do valor inestimável dos serviços ecossistêmicos, estes encontram-se sob a pressão de impactos decorrentes do crescimento populacional e desenvolvimento econômico, enquanto nas regiões tropicais está associado, principalmente ao desmatamento e perda de vegetação natural ocasionada pela mudança do uso da terra e expansão da fronteira agrícola (MAGALHÃES, *et al.*, 2021; PEREIRA *et al.*, 2020). Corroborando com esta afirmação, é possível verificar que na mata atlântica encontra-se o 70% da população que é responsável por 80% da economia do país, sendo este bioma o mais ameaçado do Brasil e o qual apresenta um alto nível de perturbações por causa da alta demanda de recursos naturais e, por consequência, à perda de serviços ecossistêmicos (SILVA *et al.*, 2022).

Em relação ao dióxido de carbono (CO₂), este é um gás cuja concentração na atmosfera tem crescido de forma exponencial, principalmente, devido ao aumento da queima de combustíveis fósseis e do desmatamento, o que colabora para o aumento da temperatura no planeta pelo fenômeno denominado de efeito estufa (ANDERSON *et al.*, 2016). Cabe ressaltar, que o efeito estufa é um fenômeno natural, causado pela presença de gases como vapor de água, dióxido de carbono (CO₂), clorofluorcarbono (CFC), óxido nitroso (NO₂), metano (CH₄), ozônio (O₃), entre outros; porém, devido ao

elevado incremento da concentração ao longo dos anos, a temperatura tem aumentado em níveis que representam um risco para a vida, sendo esta problemática também denominada aquecimento global (AĞBULUT *et al.*, 2019; RENDA *et al.*, 2021).

Visto isso, o Painel intergovernamental sobre mudança climática (IPCC) tem proposto que para deter, evitar ou mitigar os riscos a secas, inundações entre outros processos naturais decorrentes do aumento da temperatura; é necessário reduzir as emissões de gases efeito estufa, principalmente do CO₂ antrópico, em até 50% (DAS *et al.*, 2018; DAVRAN, 2018).

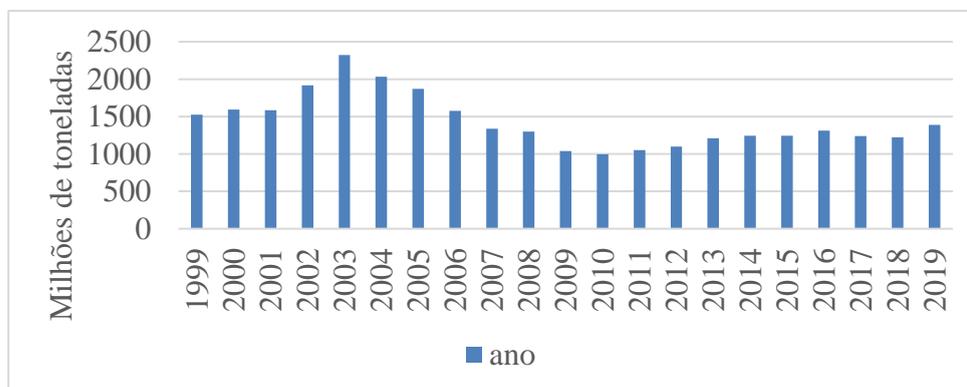
Tem-se demonstrado que devido a capacidade das raízes das árvores para absorver o CO₂ da superfície do solo e devolvê-lo à mesma através do processo de degradação das folhas e incorporar-lhe de novo dentro do ciclo de nutrientes, são considerados como um dos maiores sumidouros de carbono do planeta (DANTAS *et al.*, 2020). É importante mencionar que as florestas são recursos renováveis, porém não quer dizer que sejam infindáveis; visto que o crescimento das árvores é lento e o reflorestamento de uma área degradada requer um manejo de forma apropriada (MORA;ALANÍS, 2016).

A preocupação com o desmatamento e perda da densidade das florestas está nas repercussões no ambiente como perda da qualidade física e química do solo, desestabilização de bacias hidrográficas e alteração do equilíbrio hídrico que pode afetar os fatores climáticos, trazendo outras consequências e, por conseguinte, a deterioração na qualidade de vida para a população e para todos os organismos vivos (MELI, 2003). O Brasil é um país que se destaca pela produção agrícola, entretanto, os benefícios econômicos obtidos a partir destas atividades, também vem refletindo na degradação do ambiente, devido ao desmatamento para a expansão agrícola, diminuindo os serviços ecossistêmicos proporcionados pelas florestas (STEFANES *et al.*, 2018).

Brasil tem sido considerado um dos países com maiores emissões de gases efeito estufa em América Latina, sendo registrados valores que se encontram 30% acima da média global (FRANCHINI *et al.*, 2020). Segundo o Sistema de Estimativa de Emissões de Gases Efeito Estufa (SEEG, 2019), desde o compromisso que o Brasil assumiu com o protocolo de Kyoto, houve uma

redução da emissão de CO₂ como pode ser visto na Figura 1.

Figura 1. Emissões de CO₂ no Brasil no período de 1999 – 2020.

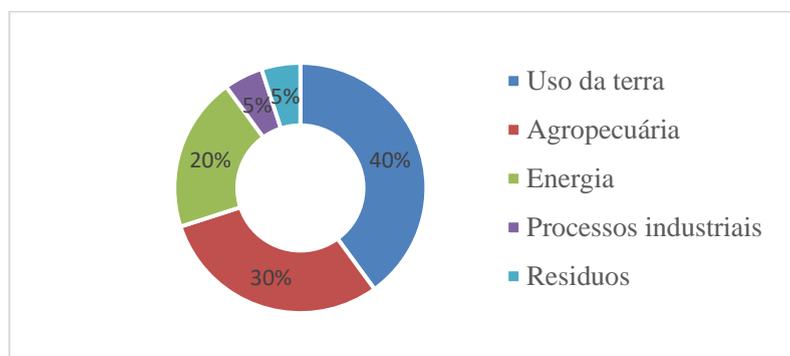


Fonte: SEEG, 2020.

As emissões de dióxido de carbono de 2019 aumentaram em 9,6% em comparação com as apresentadas no ano 2018 (SEEG, 2020), valor esperado devido a política atual de desmantelamento da Secretaria de Mudança do Clima e Florestas do Ministério de Meio Ambiente e o engavetamento dos Planos de Prevenção e Controle do Desmatamento (PPCDAm e PPCerrado) (MMA, 2021).

A Figura 2 apresenta a relação entre as emissões de dióxido de carbono por setores econômicos, é possível visualizar que o uso da terra é o principal setor emissor de CO₂ representando um total de 40% das emissões do país, outro setor que representa uma contribuição importante é o setor agropecuário que emite 20% das emissões do país associadas ao crescimento de setor agropecuário, principalmente o rebanho bovino (SEEG, 2020).

Figura 2. Participação dos setores nas emissões de CO₂ no Brasil.



Fonte: SEEG, 2020

Ainda, o Brasil propôs como objetivo nacional para o ano de 2020, na Convenção Sobre Diversidade Biológica (CDB), a restauração de ao menos 15% dos ecossistemas que se encontram degradados; para isto foi desenvolvida uma estratégia que permitia a redução do custo para alcançar a meta que consistiu na identificação de pequenos agricultores para a aplicação de incentivos de projetos que promovam o reflorestamento; além do anterior mencionado, o país conta com taxas de circulação aos bens e serviços, que distribuem o dinheiro dos impostos estatais aos municípios, considerando os indicadores ambientais, o que pode fomentar atividades de reflorestamento em áreas rurais (SOARES *et al.*, 2020).

O Brasil tem ainda vários projetos para a recuperação da cobertura vegetal, onde cabe destacar que a maior parte dos projetos de reflorestamento acontecem na Amazônia, já que é a maior floresta do mundo, além de representar um sumidouro de grande parte do carbono da atmosfera; como exemplo, podemos citar o projeto desenvolvido pela união da Conservação Internacional (CI) uma ONG dos Estados Unidos e a empresa SC Johnson, que tem como principal objetivo a mitigação da mudança climática através do plantio de 70.000 hectares na Amazônia brasileira até o ano 2023 (OLIVEIRA, 2017).

Por outro lado, o estado São Paulo é caracterizado por sua intensa atividade industrial e agrícola, principalmente de laranja e açúcar, sendo o maior produtor de açúcar do país; onde além do alto benefício econômico, esta atividade também reflete em um maior uso do solo, com uma superfície semeada de quase 6 milhões de hectares que corresponde a 52,7% da produção nacional (COUTO *et al.*, 2019).

Segundo Ronquim e Fonseca (2018), no estado do São Paulo, o principal foco da expansão agrícola está direcionado ao cultivo de cana-de-açúcar, o qual teve uma expansão de 2,4 milhões de hectares entre os anos 2000 e 2016 influenciando positivamente o Produto Interno Bruto - PIB do estado, sendo utilizada como estratégia de fortalecimento econômico dos agricultores, no entanto, tornando vulneráveis as áreas próximas à essas cultivos (FREITAS; ALVES, 2016; NAGIB; CAMPOS, 2020; SILVA *et al.*, 2021).

4.4. Mecanismo de desenvolvimento limpo e alternativas para conservação de áreas de vegetação natural

O protocolo de Kyoto, o qual foi assinado no ano 1997, representa o primeiro compromisso internacional adquirido que visou o controle e redução de gases efeito estufa, principalmente o CO₂, em países industrializados como Austrália, Canadá, Estados Unidos, Japão e Nova Zelândia, entre outros; através de diferentes diretrizes, propostas e ferramentas implementadas de maneira autônoma que conduzam a um desenvolvimento sustentável e por conseguinte a mitigação da mudança climática.

Em adição também foram criados os créditos de carbono ou também denominados Redução Certificada de Emissão (RCE), os quais são obtidos a partir da redução das emissões de GEE, sendo importante mencionar que as porcentagens de redução das metas são estabelecidas por cada país e os créditos de carbono estimulam uma maior ação para a diminuição das emissões.

Entre as alternativas que permitem a obtenção de créditos de carbono encontra-se o desenvolvimento de projetos que pertençam ao mecanismo de desenvolvimento limpo (MDL), este surgiu como uma ferramenta que permite aos países cumprirem as metas estabelecidas para compensar as emissões de GEE emitidas através da implementação de projetos que permitam a redução desses gases.

Uma alternativa proposta para a recuperação de áreas degradadas e suprimento da necessidade energética da população, é a implementação de políticas energéticas que permitam reduzir a dependência aos combustíveis fósseis como o petróleo, carvão e gás natural (AĞBULUT *et al.*, 2019). Adicionalmente, foi proposta a economia verde, que consiste em gerar benefícios na proteção do meio ambiente, sociedade e crescimento econômico; sendo o seu objetivo conseguir um desenvolvimento econômico que permita o bem-estar humano e mitigação das principais problemáticas ambientais atuais através de uma boa governança e políticas devidamente estabelecidas (SILVA *et al.*, 2021).

No Brasil, o MDL tem fomentado um modelo de desenvolvimento em parceria com países industrializados (COSTA-JÚNIOR *et al.*, 2013). Ainda,

segundo os autores, foram analisados 75 projetos executados no país, sendo identificado que um 21% dos projetos desenvolvidos correspondem a práticas que já eram executadas no país antes do MDL.

O objetivo de Bonn, o qual foi um acordo de Paris e a Política Nacional de Recuperação de Vegetação que consistiu no compromisso de mais de 60 países para a restauração de 350 milhões de hectares até o ano 2030, o Brasil tem o compromisso de, entre os anos de 2020 e 2030, implementar projetos que visem a restauração de 12 milhões de hectares de áreas que se encontram degradadas, além de reduzir a taxa de emissões de gases efeito estufa; no entanto, este compromisso é considerado ambicioso e um grande desafio, devido a uma inadequada inversão de recursos econômicos necessários, falta de investimentos, assistência técnica limitada e governança enfocada na obtenção de benefícios econômicos através do uso de áreas florestais como matéria prima (CROUZEILLES *et al.*, 2019).

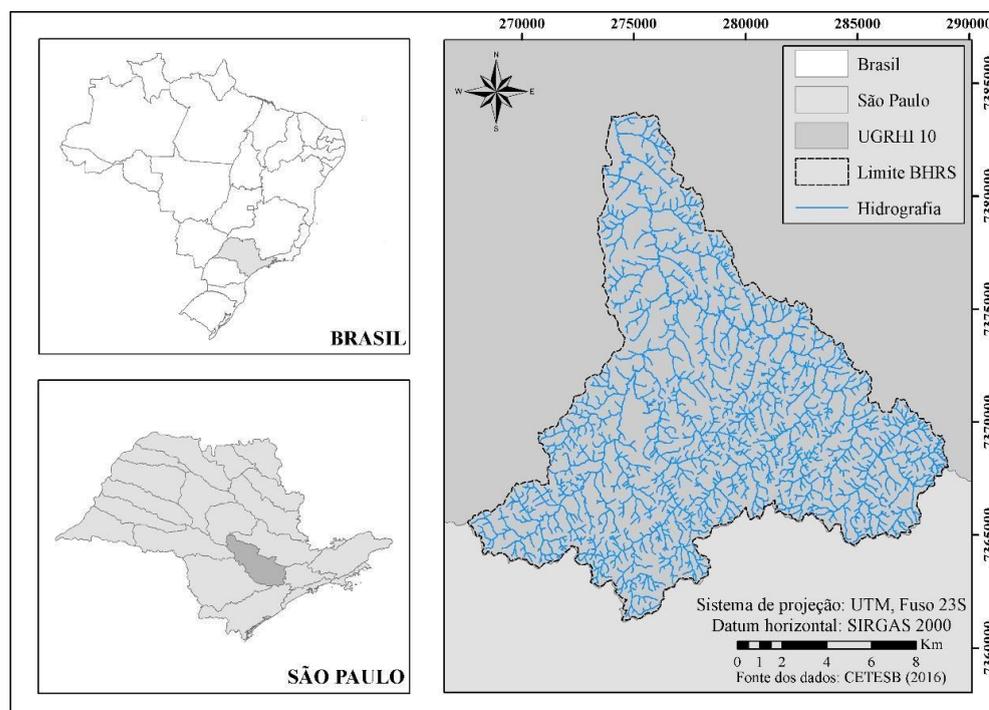
Nesse sentido, uma das alternativas para a conservação das florestas no Brasil é a implementação do programa de Pagamento por Serviços Ambientais (PSA); este, outorga um incentivo econômico para propriedades privadas que designem áreas para conservação, esta estratégia é altamente comum para promover a conservação do ambiente, enquanto o impacto para a conservação é relativamente baixo sendo vulneráveis a dependência aos PSA para manter estes níveis de conservação (RUGGIERO *et al.*, 2019).

5. MATERIAL E MÉTODOS

5.1. Área de estudo

O estudo foi desenvolvido na Bacia Hidrográfica do Rio Sorocabuçu (BHRS) (Figura 3), a qual encontra-se completamente inserida na Área de Preservação Ambiental (APA) de Itupararanga que é uma unidade de conservação dos recursos naturais criada pela Lei Estadual nº 10.100 de 1998, na qual encontra-se o reservatório de Itupararanga construído em 1912 com objetivo de abastecer os municípios de Ibiuna, Sorocaba, Mairinque e Votorantim, além gerar de energia elétrica, sendo formado pelo Rio Sorocabuçu, Rio Sorocamirim e Rio Una (GOMES *et al.*, 2020; MORAES *et al.*, 2014).

Figura 3. Localização da área de estudo.



Fonte: Autoria própria

A área da bacia hidrográfica é de 202,67 km², o que equivale a 19% do território do município de Ibiúna que tem 79.479 habitantes, onde sua economia encontra-se baseada em atividades agrícolas, indústrias processadoras de madeira e produção hortifrutigranjeiros (IBGE, 2020; MAIA; LOURENÇO, 2020; VASQUES, *et al.*, 2021).

Em relação as suas características climáticas, a zona encontra-se caracterizada por um clima temperado de montanha, com inverno seco (CWB) segundo a classificação climática de Köppen-Geiger; apresenta uma precipitação média anual de 1330 mm e sua temperatura varia entre 14,2 °C a 21,3 °C com umidade relativa de 84%; os solos predominantes na região são o latossolo vermelho amarelo – orto e podzolizado com cascalho (MAIA; LOURENÇO, 2020; VASQUES *et al.*, 2021).

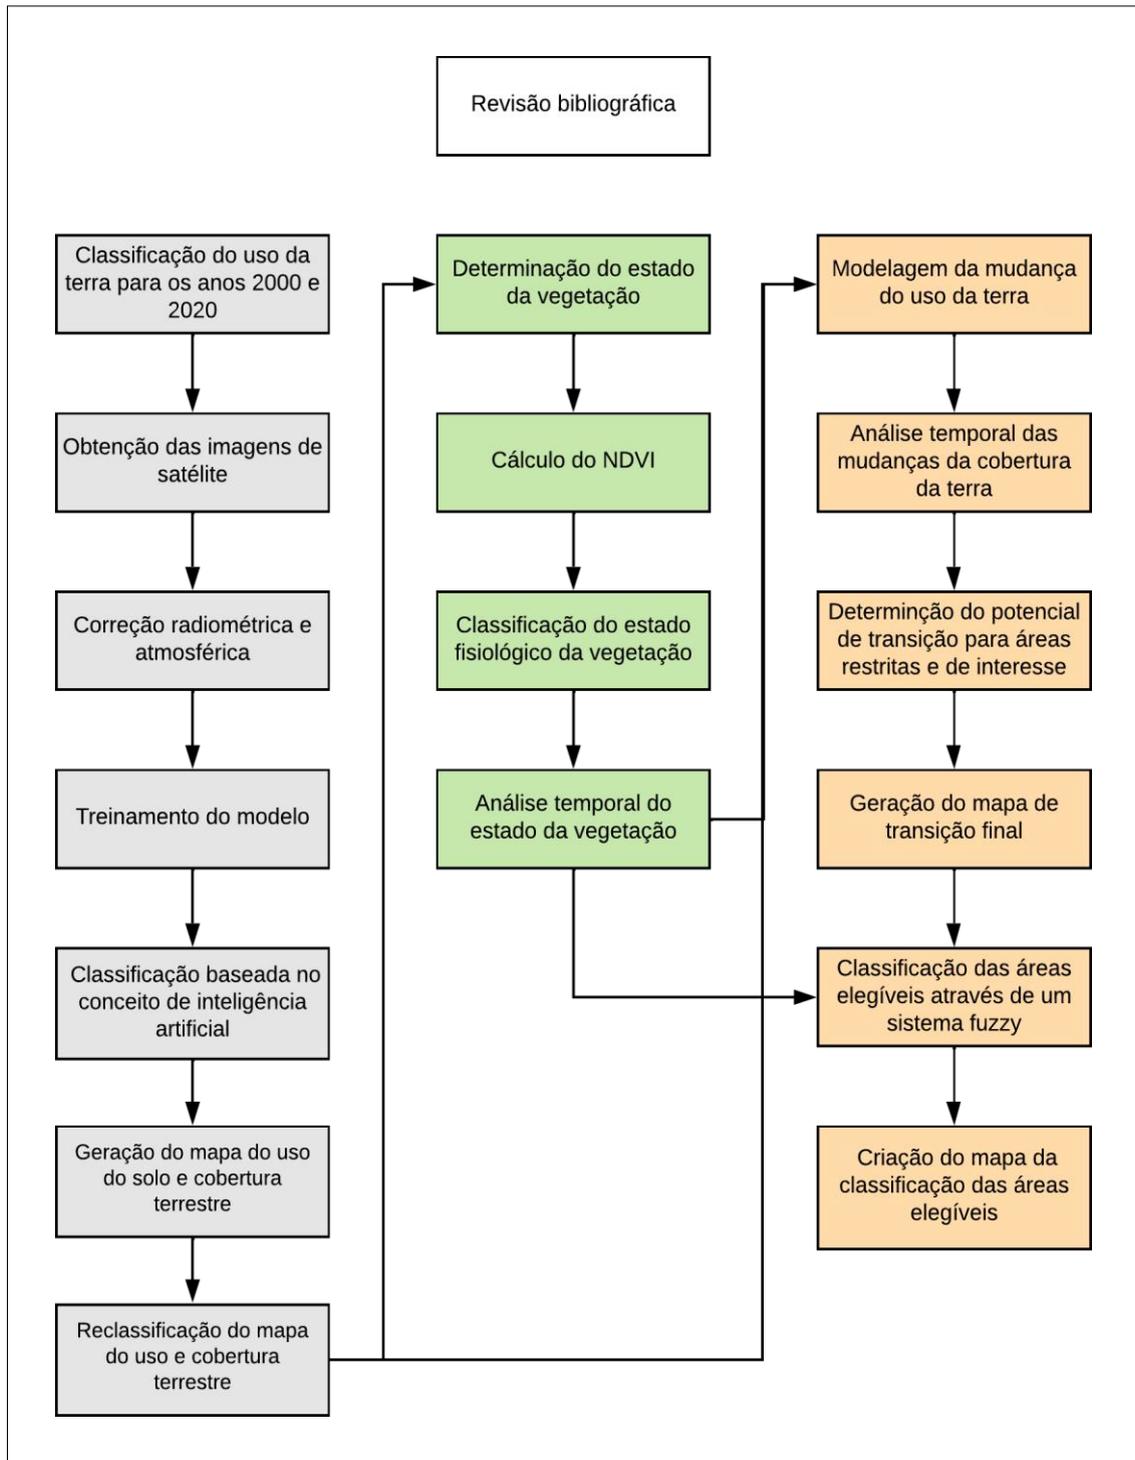
No que se refere a cobertura vegetal, a área de estudo encontra-se situada no bioma da Mata Atlântica o qual compreende o 20% do sistema costeiro do país, encontra-se caracterizada por cadeias de montanhas, platôs, vales e planícies além de um conjunto florestal ombrófilas (associada ao clima quente úmido) e estacionais; adicionalmente, neste tipo de bioma, devido aos altos índices de umidade relativa e luz, predominam diversas famílias vegetais tais como: *Myrtaceae*, *Caesalpinaceae*, *Fabaceae*, *Mimosaceae*, *Rutaceae*, *Lauraceae*, *Meliaceae*, *Apocinaceae* e *Arecaceae* (ANDREOTI, 2012; IBGE, 2019).

5.2. Procedimentos Metodológicos

A primeira revisão bibliográfica realizada abordou temas de grande importância para o desenvolvimento da pesquisa considerando o período entre 1997 e 2022. No qual, foram discutidos conceitos fundamentais relacionados à caracterização da área de estudo, bem como o papel das florestas no contexto geral e sua relevância como captadoras de carbono.

Também foram analisados os objetivos estabelecidos pelo Brasil para a conservação das florestas, bem como o Mecanismo de Desenvolvimento Limpo (MDL) e as convenções nos anos posteriores relacionadas ao tema e, finalmente, os fundamentos para o geoprocessamento, análise e modelagem dos dados. A Figura 4 apresenta o fluxograma desenvolvido para identificação das áreas aptas para implantação de projetos de MDL.

Figura 4. Fluxograma metodológico.



Fonte: Autoria própria.

5.3. Elaboração dos mapas da classificação de uso da terra para os anos 2000 e 2020

5.3.1. Obtenção e processamento da imagem de satélite

As imagens espaciais foram obtidas junto ao catálogo disponibilizado pela Divisão de Geração de Imagens do Serviço Geológico dos Estados Unidos (USGS), para os satélites Landsat 5 com sensor TM e Landsat 8 com sensor OLI, ambos com resolução espacial de 30 m; as informações mais detalhadas das imagens utilizadas encontram-se na Tabela 2.

Tabela 2. Informação das imagens de satélite utilizadas

Ano	Dia e mês	Órbita/ponto
2000	25/06	219/76
2000	25/06	219/77
2020	31/05	219/76

Fonte: autoria própria

Após obter as imagens de satélite correspondentes, foi feita uma correção radiométrica com o objetivo de tratar os valores dos pixels e obter os valores de intensidade homogênea. Isso foi feito para corrigir as perturbações atmosféricas, corrigindo-se os efeitos de dispersão e absorção da atmosfera.

5.3.2. Classificação das imagens de satélite

Foi utilizado, nesta etapa, as bandas do azul, verde, vermelho e infravermelho próximo, médio, termal e distante, respectivamente, as bandas 1, 2, 3, 4, 5, 6 e 7; do Landsat 5 para o mapeamento do uso da terra do ano de 2000; para o mapeamento do uso da terra do ano de 2020 foram utilizadas as bandas do azul, verde, vermelho e infravermelho próximo, médio e distante, respectivamente, as bandas 2, 3, 4, 5, 6 e 7 do Landsat 8.

Como método de classificação foi utilizado o algoritmo de classificação baseado no conceito de inteligência artificial (*Artificial Intelligence* – ou simplesmente *AI*) por meio de Redes Neurais Artificiais (*Artificial Neural Networks* – *ANNs*); A combinação de Redes Neurais

Artificiais (RNA) e sensoriamento remoto é uma opção relevante para obter informações precisas e confiáveis, além de possibilitar fazer ajustes de forma mais automatizada. (IZADKHAH, 2022).

No presente estudo foi utilizado RNA MLP – *Multi-layer Perceptron* presente no software TerrSet onde as classes do uso da terra utilizadas foram estabelecidas tomando como base a classificação definida no Manual Técnico do Uso da Terra do IBGE nível I, conforme pode ser visto na Tabela 3 (MENESES; ALMEIDA, 2012; DEFIGE *et al.*, 2018).

Tabela 3. Descrição das classes

Número	Cobertura da terra	Descrição
1	Água	Encontra-se caracterizado pela presença de águas continentais e costeiras.
2	Áreas de vegetação natural	Representa as áreas florestais ecampestres.
3	Áreas antrópicas agrícolas	Equivale aquelas áreas de culturas temporais, permanentes, pastagens e silvicultura.
4	Áreas antrópicas não agrícolas	Nesta classe encontram-se as áreas urbanizadas, além de áreas de mineração.
5	Outras áreas	Representa aquelas áreas que se encontram desprovidas de vegetação

Fonte: (IBGE, 2013)

Para classificação do uso da terra através de redes neurais artificiais *Multilayer Perceptron* (MLP) foram utilizadas sete camadas de neurônios, com uma amostra mínima de 1000 pixels, onde seis delas encontravam-se ocultas; o número de interações foi de 10.000 para o treinamento do sistema; além disso, foi necessário acrescentar amostras das classes estabelecidas para o uso da terra, para isto realizou-se diversas composições de bandas visando ter uma melhor identificação das classes, facilitando a amostragem e por consequência tendo uma maior precisão na classificação.

A qualidade dos resultados da classificação das saídas geradas pela

RNA na classificação do uso da terra para os anos selecionados foi avaliada quantitativamente através da geração de uma matriz de confusão, também chamada matriz de erro, a qual consiste em uma tabela cujo número de linhas e colunas depende das classes avaliadas, esta permite uma melhor apreciação do desempenho da classificação através do registro da classificação de cada pixel, onde a classificação errada de um pixel pode ser categorizada como erro de comissão (ErroC) ou erro de omissão (ErroO) (JARAMILLO; ANTUNES, 2018).

Em relação aos tipos de erros mencionados anteriormente, o ErroC representa aqueles dados que foram catalogados a uma classe à que não pertencem, enquanto o ErroO representa aqueles valores que foram omitidos pelo algoritmo (VERMA *et al.*, 2020). A partir da matriz de confusão, foi calculado o índice Kappa (k), o qual permite conhecer a exatidão global da classificação e apresenta seis classes de precisão (Tabela 4) definidas por Landis e Koch (1997). Essas métricas permitem avaliar melhor a classificação final da área de estudo sob a hipótese de igualdade entre dois coeficientes de exatidão advindos de classificações diferentes ($k_1 = k_2$).

Tabela 4. Interpretação do índice Kappa

Valor de Kappa	Concordância
<0	Péssima
0 – 0,2	Ruim
0,2 – 0,4	Razoável
0,4 – 0,6	Boa
0,6 – 0,8	Muito boa
1	Excelente

Fonte: (Landis e Koch, 1997).

Uma vez gerados os mapas da classificação do uso da terra, fez-se uma reclassificação das classes em 3 novas classes em função de suas

características para identificar áreas aptas e com necessidade de recuperação da vegetação para torná-las aptas ao MDL e, conseqüentemente, recuperar áreas degradadas. As mencionadas classes são descritas a continuação.

Áreas restritas: São aquelas áreas que por suas características possuem um baixo potencial para o desenvolvimento de projetos que contribuam ao desenvolvimento limpo, estando caracterizadas pela presença de centros urbanos e atividades de mineração, sendo as classes áreas antrópicas não agrícolas e água como parte desta classe.

Áreas de interesse: Equivalem as áreas que necessitam ser recuperadas para contribuírem com a captura de carbono e se tornarem aptas ao MDL, portanto, são classes de áreas antrópicas agrícolas e outras áreas.

Áreas estabilizadas: Representa as áreas que possuem uma alta densidade florestal e já contribuem para a captura de carbono e, portanto, estão aptas ao MDL sem a necessidade de recuperação destas, sendo representada pelas áreas de vegetação natural.

5.4. Cálculo e classificação do índice da vegetação por diferença normalizada

Para o cálculo do NDVI, foram utilizadas as bandas espectrais 4 e 5 que correspondem ao vermelho (V) e infravermelho próximo (NIR) do satélite Landsat 8 para o ano 2020 com a exceção dos meses que apresentaram uma elevada cobertura de nuvens impedindo seu uso para o cálculo, sendo necessário o uso dos dados do ano 2019 ou 2021; este procedimento foi realizado através do software ArcGIS. Assim, o NDVI foi calculado conforme a Equação (2):

$$NDVI = \frac{NIR - V}{NIR + V} \quad (2)$$

Com o objetivo de ter um valor representativo do NDVI foi seguida a metodologia proposta por Pauleto *et al.* (2019), a qual utiliza a média do NDVI ao longo de um ano. Devido à alta cobertura de nuvens, a metodologia adotada foi modificada utilizando imagens de satélite dos anos 2019 e 2021 para os meses de fevereiro, novembro e dezembro.

Uma vez obtidos os valores do NDVI, os quais encontram-se no intervalo de -1 a 1, estes foram classificados conforme pode ser visto na

Tabela 5 e denominados de NDVIclass. Ressalta-se que os valores negativos correspondem as áreas que não apresentam cobertura vegetal, enquanto os valores positivos indicam vegetação fotossinteticamente ativa. A classificação foi adaptada de Menezes *et al.* (2019) e acrescentado o potencial para aplicação do MDL para cada classe apresentada.

Tabela 5. Classificação do NDVI.

Classes de cobertura vegetal	Intervalo	Potencial
Sem cobertura	<0	Baixo potencial
Vegetação não saudável	>0 – 0,33	Médio potencial
Vegetação pouco saudável	>0,33 – 0,66	Alto potencial
Vegetação saudável	> 0,66	Altíssimo potencial

Fonte: Adaptado de MENEZES *et al.* (2019).

5.5. Modelagem e geração de cenários viáveis

5.5.1. Análise temporal das mudanças do uso da terra

O estudo das mudanças do uso da terra foi realizado por meio da Modelagem da Mudança do Uso da Terra (*Land Change Modeler - LCM*); o LCM é uma aplicação orientada para a análise de mudanças da terra e a criação de planos e cenários viáveis para o futuro; foi gerado um mapa da transição das classes de áreas restritas e de interesse, analisando os ganhos e perda de área de cada classe no período de estudo; também foi gerado um mapa de persistências de cada classe onde foram identificadas aquelas áreas que permaneceram com o mesmo uso da terra durante o intervalo de tempo selecionado; em adição, foram gerados diversos mapas da tendência espacial da mudança do uso da terra, calculada no polinômio de 3ª ordem já que permite uma melhor identificação das mudanças espaciais referentes a atividades antrópicas, além de permitir conferir o direcionamento das mudanças ocorridas entre o período analisado (2000 e 2020).

5.5.2. Obtenção do potencial de transição

No LCM, a análise e a previsão das mudanças foram organizadas em

torno de uma série de submodelos de transição avaliados empiricamente; o potencial de transição foi calculado através do método MLP *Neural Network* (redes neurais) com sete camadas de neurônios e 10.000 interações entre as variáveis acrescentadas, uma vez finalizado o processo executado, foram obtidos os mapas do potencial de transição; para a construção da estrutura do submodelo de transição foi necessária a adição de variáveis de condução subjacentes, melhorando a significância da predição da dinâmica do processo de mudança histórica, enquanto para a modelagem foram utilizadas a altitude e declividade (variáveis estáticas, isto é não se alteram com o tempo).

Além disso, utilizou-se a variável *Evidence Likelihood* entre as classificações do uso da terra dos anos 2000 e 2020, a qual transforma tais classificações em valores numéricos para que correspondam aos tipos de dados usados na modelagem, esta foi calculada empiricamente através do módulo “mapa de mudanças” no TerrSet.

Adicionalmente, em relação às variáveis de condução utilizadas, diversas investigações identificaram que o uso das variáveis potenciadoras tem uma elevada significância estatística na predição da dinâmica florestal; portanto, é importante mencionar que existem diversas variáveis que podem ser utilizadas para melhorar o rendimento e exatidão dos potenciais de transição, não obstante, as utilizadas na presente pesquisa foram aquelas recomendadas pelo Laboratório Clark, além de outras cuja significância foi elevada na criação e cálculo de precisão do submodelo; neste sentido, o estudo realizado por Wang *et al.* (2020) argumenta como as variáveis naturais (elevação e inclinação) têm uma influência elevada para o aumento na precisão do submodelo.

Um dos dados que foram acrescentados foi a análise da distância às rodovias e centros urbanos, estas variáveis foram calculadas com a ferramenta “*Euclidean distance*” no ArcGIS, para isso, utilizou-se as rodovias de primeiro e segundo níveis e a classificação do uso da terra para o ano 2020, no qual foram extraídos os centros urbanos; é importante mencionar que estas variáveis são dinâmicas e que os dados utilizados para o cálculo foram levantados pelo Departamento de Estrada de Rodagem (DER) do Estado de São Paulo, sendo obtidos a partir do site datageo (Disponível

em: <https://datageo.ambiente.sp.gov.br/>)

Devido a evidência do incremento da precisão para a geração dos mapas de potencial de transição em outras pesquisas, foi acrescentada a variável distância aos corpos d'água, a qual foi calculada a partir da utilização da classificação do uso da terra determinado para o ano 2020, já que é recomendado o cálculo da variável a partir dos dados mais atualizados disponíveis, esta variável dependente foi determinada através do método “*Euclidean distance*” no ArcGIS, da mesma maneira que as variáveis mencionadas anteriormente (HAN *et al.*, 2015; ISLAM *et al.*, 2018).

Deve-se mencionar que as variáveis potenciadoras foram avaliadas através do teste Cramer's V no TerrSet, visando identificar a força da relação das mesmas para o submodelo de transição, este calcula a associação entre as variáveis de estudo com um intervalo de 0 a 1, onde valores próximos de 1 representam uma melhor significância estatística para o modelo. Neste sentido, é importante mencionar que as variáveis com valores menores que 0,1 não representam uma influência considerável nas mudanças do uso da terra, assim, é importante esclarecer que um valor alto para o mencionado teste não garante que a modelagem apresente um alto nível de desempenho, no entanto, um valor baixo permite analisar o grau de conveniência em relação a incluir uma variável ou não no submodelo (ISLAM *et al.*, 2018; RONALD EASTMAN, 2006; SANKARRAO *et al.*, 2021).

Como resultado foram obtidos mapas do potencial de transição da classe de áreas de interesse (AI) para áreas restritas (AR) e áreas estabilizadas (AE), os mapas apresentam um intervalo de 0 a 1, o que permitiu identificar o direcionamento das mudanças; a partir daí, foi gerado um mapa do potencial de transição final (PTF) através do uso do AR e AE, onde para o mapa mencionado foi utilizada a Equação (3).

$$PTF = AE - AR \quad (3)$$

Os valores do PTF encontram-se no intervalo de -1 a 1, os quais foram normalizados para os seus valores para variarem entre 0 e 1; para isso, foi utilizado o método de normalização estatística o qual permite realizar a normalização a partir da seguinte Equação (4).

$$x = \frac{x - \min(x)}{\max(x) - \min(x)}; \quad (4)$$

z é o valor normalizado;

x é o valor no conjunto de dados;

Min (x) é o valor mínimo no conjunto de dados; Max (x) é o valor máximo no conjunto de dados.

Uma vez normalizado os dados, o mapa de PTF foi denominado de mapa do potencial de transição final normalizado (PTFn) e reclassificado conforme a Tabela 6 em cinco classes de iguais valores de amplitude, indicando o potencial das áreas para transformação em zonas apropriadas/aptas a aplicação do MDL, visando a consolidação destes territórios em áreas com cobertura vegetal de grande porte (florestas).

Tabela 6. Potencialidade de consolidação.

Classe	Intervalo
Altíssimo potencial de consolidação	0,8 a 1
Alto potencial de consolidação	0,6 a 0,8
Médio potencial de consolidação	0,4 a 0,6
Baixo potencial de consolidação	0,2 a 0,4
Baixíssimo potencial de consolidação	0 a 0,2

Fonte: Autoria própria

5.5.3. Sistema Fuzzy para definição das áreas aptas ao MDL

A identificação das áreas viáveis foi realizada através de um sistema Fuzzy onde as variáveis linguísticas de entrada utilizadas foram a classificação do NDVI e PTFn, enquanto a variável de saída foi a elegibilidade das áreas, as quais encontram-se classificadas dentro de uma escala de 0 a 1 (Tabela 7), separadas em classes com potencial para recuperação da vegetação, consequentemente aptas para ser desenvolvidos projetos de MDL.

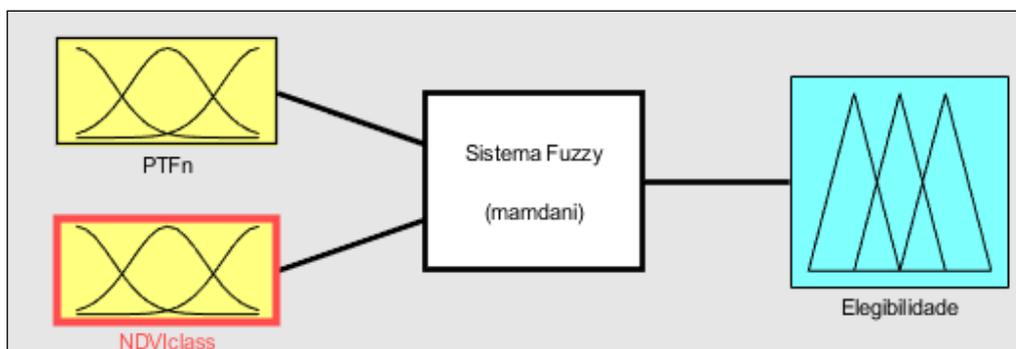
Tabela 7. Elegibilidade das áreas.

classe	Intervalo
Baixo potencial	0 – 0,50
Potencial médio	0,50 – 0,75
Alto potencial	0,75 - 1

Fonte: Autoria própria

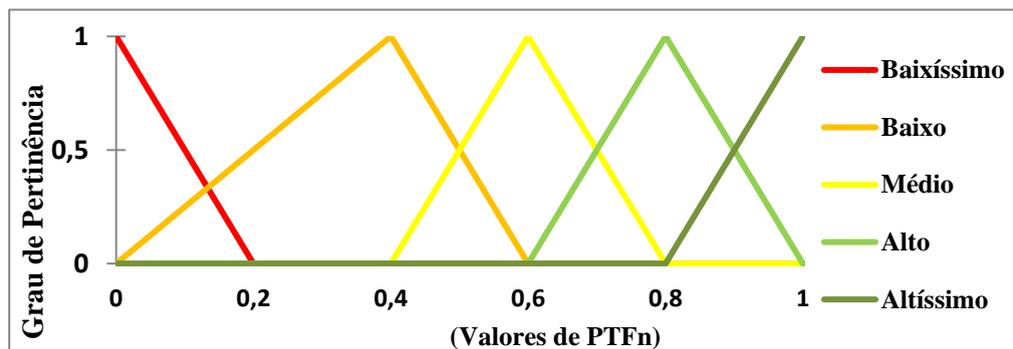
Para o sistema fuzzy elaborado (Figura 5) utilizou-se o sistema de inferência de Mamdani (1976), cujas variáveis de entrada foram o potencial de transição para as áreas de interesse e a classificação do NDVI, enquanto a variável de saída representa o grau de elegibilidade das áreas para MDL; todas as variáveis apresentam funções do tipo triangular com intervalo de 0 a 1, conforme as figuras 6 a 8.

Figura 5. Esquema do sistema fuzzy.



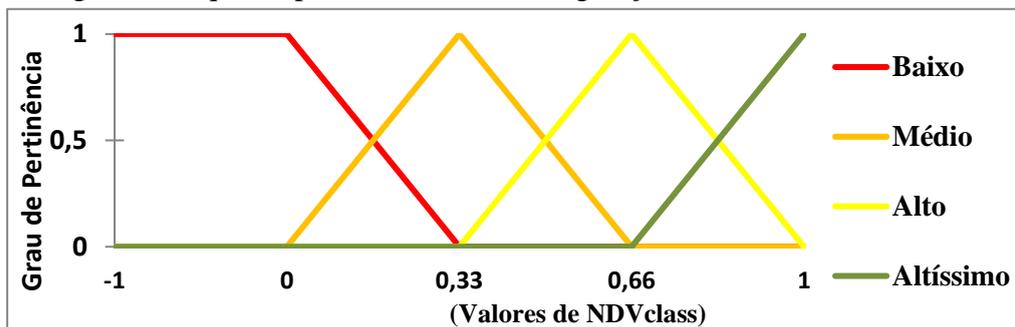
Fonte: Autoria própria

Figura 6. Esquema potencial de transição.



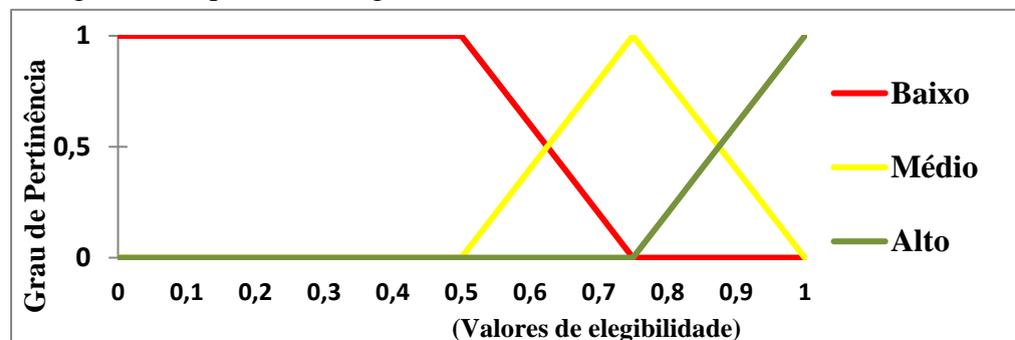
Fonte: Autoria própria

Figura 7. Esquema potencial índice de vegetação classificado.



Fonte: Autoria própria

Figura 8. Esquema de elegibilidade das áreas.



Fonte: Autoria própria

As regras do sistema desenvolvido encontram-se baseadas no sistema *If A Then B* (se A então B), onde o total das regras (Tabela 8) foi determinado pela quantidade de classes de cada variável, além disso, foi feita uma superfície (Figura 9) onde é possível visualizar o comportamento de cada sistema de acordo com as variáveis de entrada.

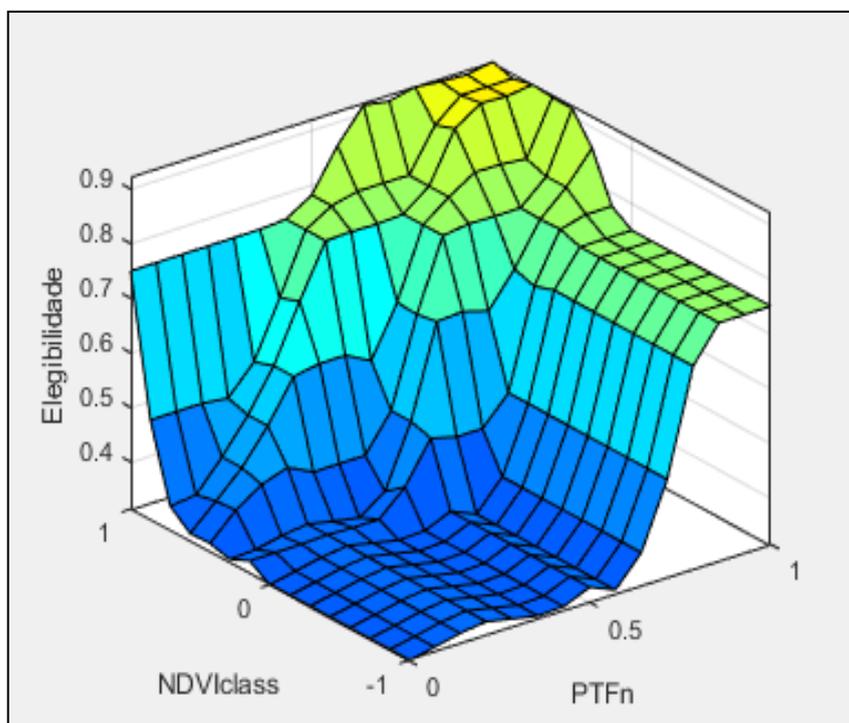
Tabela 8. Regras do sistema.

Potencialidade de consolidação	NDVI	Elegibilidade
Altíssimo	Baixo	Médio
	Médio	Alto
	Alto	Alto
	Altíssimo	Alto
Alto	Baixo	Médio
	Médio	Médio
	Alto	Alto
	Altíssimo	Alto
Médio	Baixo	Baixo
	Médio	Médio
	Alto	Médio

Potencialidade de consolidação	NDVI	Elegibilidade
	Altíssimo	Alto
Baixo	Baixo	Baixo
	Médio	Baixo
	Alto	Médio
	Altíssimo	Médio
Baixíssimo	Baixo	Baixo
	Médio	Baixo
	Alto	Baixo
	Altíssimo	Médio

Na Figura 9 é visualizado a representação do comportamento do sistema, no qual a variação da elegibilidade das áreas depende da relação direta entre os valores apresentados pelo NDVI e o PTF.

Figura 9. Superfície do sistema.



Fonte: Autoria própria

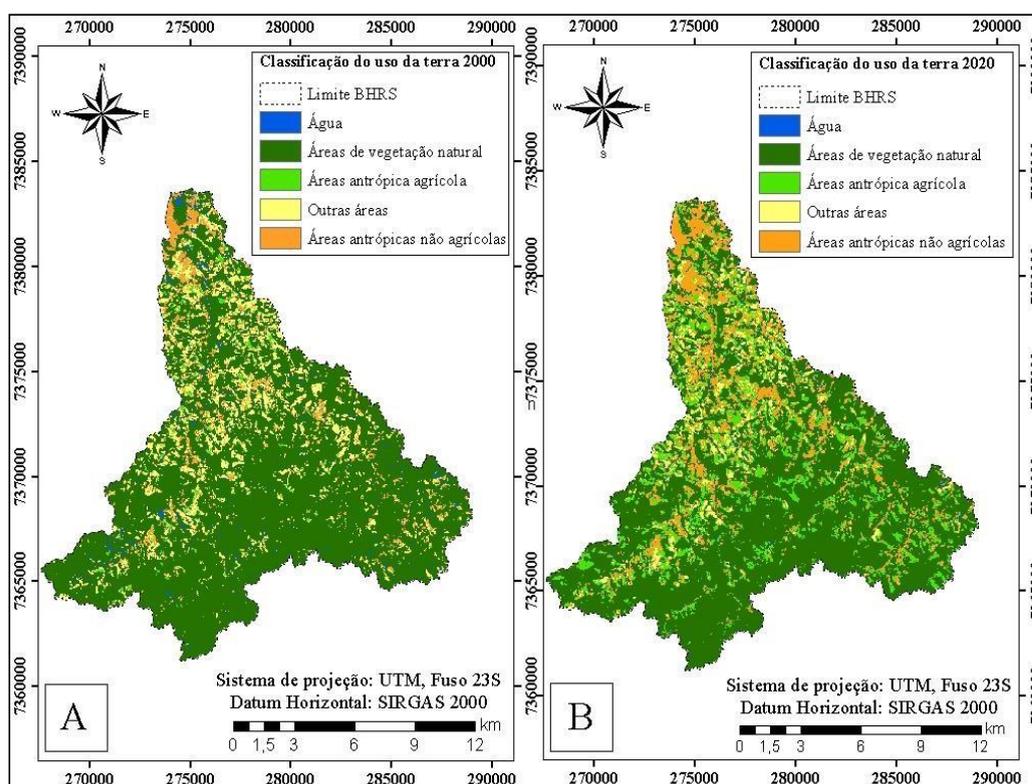
Finalmente, para a defuzificação dos dados, foi utilizado o método do centroide, o qual encontra-se baseado na soma dos centros para gerar um valor *crisp* e criar um mapa das áreas com potencial de elegibilidade à aplicabilidade de MDL através do software ArcGIS.

6. RESULTADOS E DISCUSSÃO

6.1. Construção dos mapas da classificação de uso da terra para os anos 2000 e 2020

A classificação do uso da terra contou com uma taxa de aprendizagem do algoritmo medida para os anos 2000 e 2020 de respectivamente, 99,38% e 99,91%, com uma taxa de precisão de 99,26% para o ano 2000 e 99,89% para o 2020; os mapas do uso da terra para os anos 2000 e 2020 estão apresentados na Figura 10.

Figura 10. Classificação dos usos da terra para os anos 2000 (A) e 2020 (B).



Fonte: Autoria própria

Na classificação, visualiza-se a mudança do uso da terra através dos anos 2000 e 2020, sendo possível a identificação da expansão de áreas antrópicas não agrícolas, que apresentou uma expansão de 15,7 km² (7,74%) da área de estudo.

No caso das áreas de vegetação natural, estas tiveram um aumento para o ano 2020 com relação ao ano de 2000 de aproximadamente 4%, por outro lado, a área correspondente as áreas antrópicas agrícolas e outras áreas apresentaram um recuo correspondente a 13,1%.

Tabela 9. Mudança da cobertura do solo entre o 2000 e 2020.

Classe	2000		2020	
	Área (km ²)	%	Área (km ²)	%
Água	4,08	2,00	2,34	1,15
Área de vegetação natural	155,4	76,69	130,46	64,38
Áreas antrópicas agrícolas	3,92	1,93	29,58	14,59
Áreas antrópicas não agrícolas	12,76	6,30	28,46	14,04
Outras áreas	26,52	13,08	11,83	5,84

Fonte: Autoria própria

Na pesquisa desenvolvida por Simonetti *et al.* (2019) determinou-se que para o ano 2017 houve uma expansão significativa na classe outras áreas para a APA de Itupararanga, além de sugerir que devido à rápida antropização, aumentou-se os riscos e degradação das florestas na APA de Itupararanga.

Não obstante, na classificação do uso da terra feita por Maia e Lourenço para o ano 2018 na bacia hidrográfica do Rio Sorocabaçu foi identificada uma perda de 2,5% das áreas de vegetação natural em relação ao ano 2008, a partir deste resultado foi concluído que devido à alta declividade que apresentam as áreas com cobertura de vegetação natural, as atividades antrópicas que correspondem à agropecuária têm uma maior dificuldade para seu estabelecimento, por outra parte, identificou-se que áreas antrópicas não agrícolas tiveram o maior expansão percentual (40%), enquanto que foram às áreas antrópicas agrícolas as que tiveram o maior ganho em área (4,22 km²) (MAIA; LOURENÇO, 2020).

Em comparação com estudos feitos em outras áreas, como a bacia do Rio Una, a qual encontra-se estabelecida na mesma UGRHI e APA, foi identificado que a área apresenta um elevado desenvolvimento com fins econômicos e expansão agrícola (SALES *et al.*, 2017). Padovanni *et al.* (2018) identificaram uma expansão de atividades agrícolas para a área de estudo ao longo dos anos 2004, 2008 e 2012 o qual implica em uma elevada interferência antrópica.

Analisando a mudança da cobertura da terra em outros tipos de

biomas no Brasil como o cerrado foi identificado que o desmatamento da vegetação nativa entre o período de 1984 e 2007 na bacia hidrográfica do rio Uruçuí-Preto alcançou uma porcentagem de 13,48% representando entre o 20% e 50% de perda para algumas sub-bacias, o qual permite identificar a substituição do uso da terra para fins de expansão agrícola, principalmente cultivo de soja, enquanto para 2019 foi identificada uma tendência negativa para o estado fotossintético da vegetação ocasionado pela expansão de atividades agrícolas (BARBOSA *et al.*, 2019; SANTANA *et al.*, 2020).

Desde a década de 80, tem-se registrado abruptas mudanças no uso da terra no Brasil, onde as florestas têm estado sob intensas perturbações antrópicas, dentre as quais as destaca-se a extração de recursos naturais, entretanto tem-se desenvolvido diversas alternativas visando a diminuição do desmatamento, ocasionado principalmente pela extensão da atividade agrícola; apesar das medidas empregadas para a redução do desflorestamento, a perda da vegetação natural segue sendo um dos maiores problemas do país; portanto, existe uma forte necessidade de aumentar os esforços que permitam a elaboração de estratégias que sejam eficientes e eficazes para a conservação deste recurso natural (FREITAS, *et al.*, 2022; GARRETT, *et al.*, 2022; RIBEIRO, *et al.*, 2021).

Dentre os esforços para a conservação da cobertura vegetal encontra-se o sensoriamento remoto, que tem sido utilizado em diversas investigações visando analisar a informação espaço-temporal que permita aumentar o conhecimento sobre os recursos naturais presentes em uma área, a mudanças destes em determinado período, a variabilidade da ação antrópica, dados que proporcionem informação estratégica para o estabelecimento de ações de alta eficiência e eficácia (REIS *et al.*, 2012; SALES *et al.*, 2022).

Em alguns estudos, como os realizado por de Azevedo *et al.* (2022) e Silva *et al.* (2021), foi possível a identificação da relação do aumento da eficiência em atividades agrícolas e a diminuição do desmatamento, concluindo que a perda da vegetação natural foi reduzida, não obstante, existem áreas nas quais a mencionada redução não foi tão eficiente como em outras, pelo que é recomendado expandir os esforços para uma conservação das áreas de vegetação através da criação de estratégias e medidas que contribuam com o desenvolvimento sustentável do país.

6.1.1. Avaliação da classificação dos mapas de uso da terra

Para a avaliação das classificações foram efetuadas matrizes de confusão, além do cálculo do índice *Kappa*, os quais permitiram determinar a categorização da classificação e o desempenho da aprendizagem do modelo, os quais podem ser observados na Tabela 10 e Tabela 11.

Tabela 10. Matriz de confusão da classificação do ano 2000.

	1	2	3	4	5	6	Total	ErroC
1	70	0	0	0	0	0	70	0
2	0	3390	0	0	0	0	3390	0
3	0	0	108	0	0	0	108	0
4	2	0	0	146	5	0	153	0,046
5	1	0	0	6	355	0	362	0,019
6	0	0	0	0	0	241	241	0
Total	73	0	0	152	360	241	4324	
ErroO	0,041	0	0	0,039	0,0139	2		0,003

Fonte: Autoria própria

Nota:1: Água; 2: Áreas de vegetação natural; 3: Áreas antrópicas agrícolas; 4: Outras áreas; 5: Áreas antrópicas não agrícolas.

Tabela 11. Matriz de confusão da classificação do ano de 2020.

	1	2	3	4	5	6	Total	ErroC
1	93	0	0	0	0	0	93	0
2	0	3589	1	0	0	0	3590	0
3	0	0	248	0	2	0	250	0,003
4	0	0	0	186	0	0	186	0,008
5	0	0	0	0	660	0	660	0
6	0	0	0	0	0	105	105	0
Total	93	3589	249	186	662	105	4884	
ErroO	0	0	0,004	0	0,003	0		0,0001

Fonte: Autoria própria

Nota:1: Água; 2: Áreas de vegetação natural; 3: Áreas antrópicas agrícolas; 4: Outras áreas; 5: Áreas antrópicas não agrícolas.

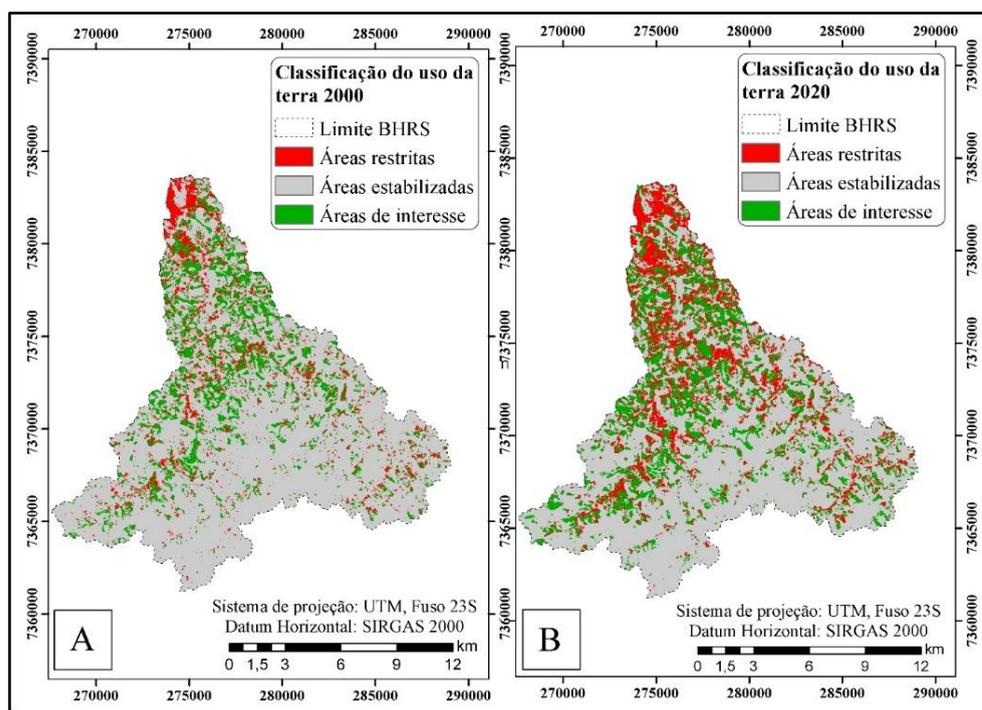
Ao efetuar a matriz de confusão da classificação do ano 2000, pode-se observar, na Tabela 10, que as classes que apresentam maiores erro de Omissão (ErroO) são as classes de água, áreas antrópicas não agrícolas e outras áreas, enquanto o erro de comissão (ErroC) são apresentados somente pelas classes de áreas antrópicas não agrícolas e outras áreas; o erro global teve um valor de 0,003 enquanto o índice Kappa da classificação do uso da terra teve um valor de 0,99 encontrando-se classificado como excelente.

No caso da matriz de confusão (Tabela 11) para a classificação do uso da terra do ano 2020 são apresentados erros de omissão para as classes de

áreas antrópicas agrícolas e áreas antrópicas não agrícolas, enquanto são as classes de áreas antrópicas agrícolas e outras áreas as que apresentaram erros de comissão; no entanto, tais erros apresentam valores menores do que 0,001; de maneira semelhante, o erro global apresentou um valor embaixo 0,001 e o índice Kappa teve um valor de 0,99 o que categoriza como excelente.

Na Figura 11 é possível verificar a reclassificação do uso da terra para os anos de 2000 e 2020, evidenciando o aumento de área para as classes restritas e áreas de interesse ao longo do período de estudo selecionado; no caso das áreas restritas houve uma expansão de 13,96 km², o que representa 6,89% da área de estudo, enquanto as áreas de interesse apresentaram uma expansão de 5,42% (10,98 km²); também é possível identificar que as áreas de interesse se encontram próximas as áreas restritas, além da sua proximidade com o curso principal do Rio Sorocabuçu o qual é um padrão comum para o desenvolvimento de atividades antrópicas.

Figura 11. Reclassificação do uso da terra.



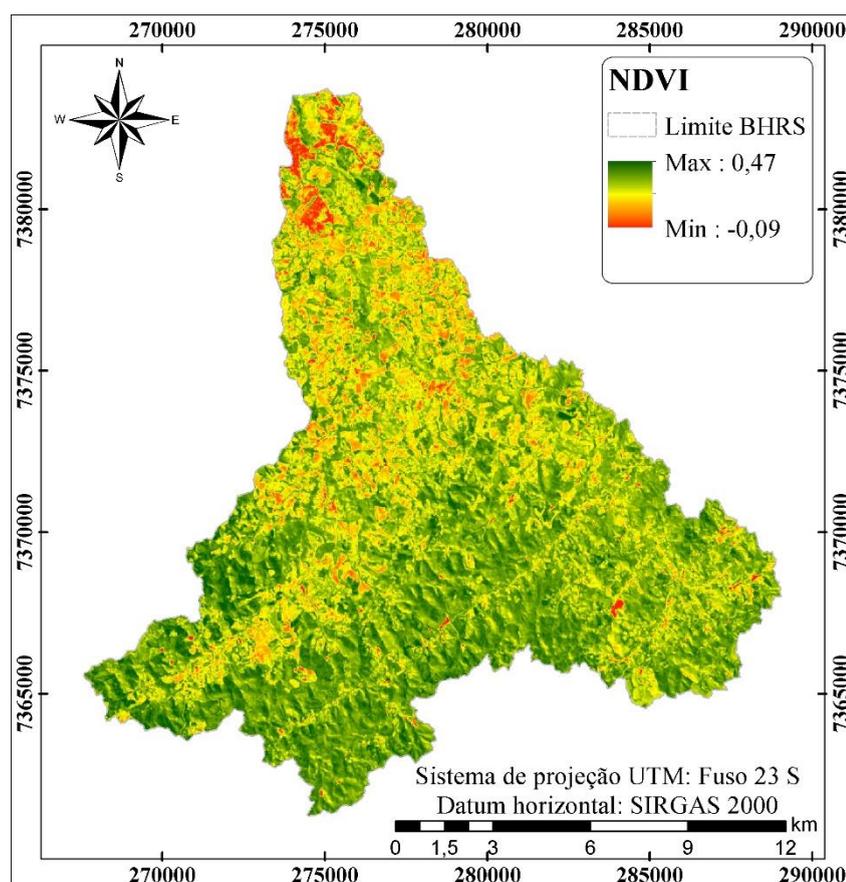
Fonte: Autoria própria

6.2. Classificação do estado fotoquímico da vegetação

6.2.1. Índice de Vegetação por Diferença Normalizada

A Figura 12 apresenta o estado da vegetação através do cálculo do NDVI para o ano 2020 para a bacia hidrográfica do Rio Sorocabuçu; em áreas caracterizadas por uma alta fragilidade ambiental como a bacia hidrográfica do Rio Sorocabuçu (SIMONETTI *et al.*, 2019). O estado fotossintético da vegetação depende do comportamento de resposta às perturbações ou resiliência que a área apresenta; na área de estudo, foi identificado um acelerado desenvolvimento de centros urbanos e como consequência de áreas destinadas para atividades antrópicas, principalmente agricultura (SILVA *et al.*, 2021).

Figura 12. Resultado do estado fotossintético da vegetação para a bacia do Rio Sorocabuçu para o ano 2020.



Fonte: Autoria própria

É importante esclarecer que os valores que encontram-se abaixo de zero representam aquelas áreas onde não existe vegetação como os corpos d'água e os assentamentos urbanos, no caso dos valores que representam o estado fotossintético da vegetação. No estudo realizado por Simonetti *et al.* (2019) foi identificado que a região sul da bacia do alto Sorocaba, inserida na

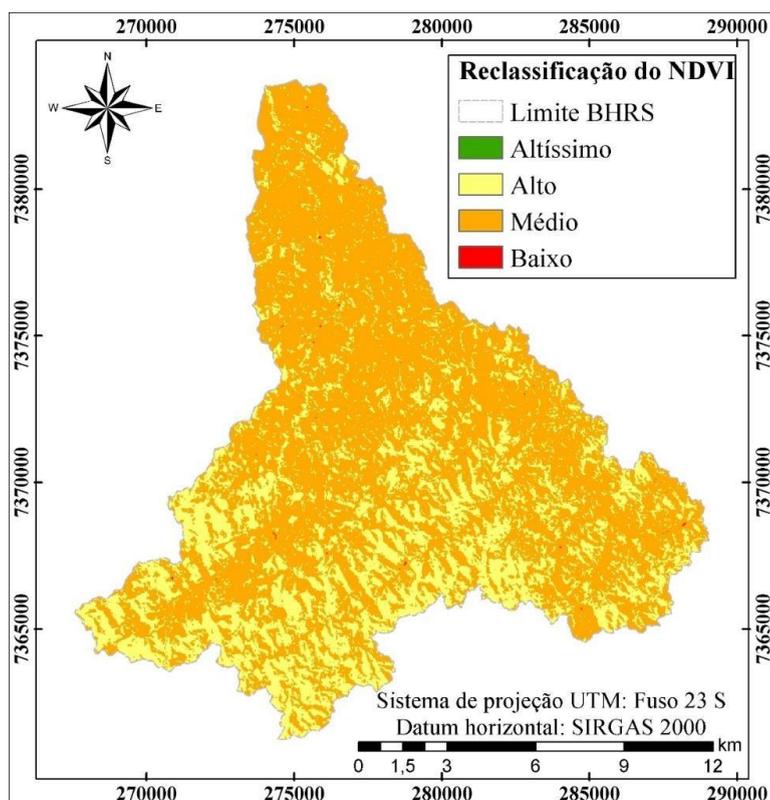
APA de Itupararanga, a qual representa a área de estudo, encontra-se classificada como “Muito Forte” para a fragilidade ambiental, a qual, encontra-se vinculado ao comportamento do ecossistema; tal informação é de grande relevância na tomada de decisões para a execução de políticas de gestão, tendo em consideração que as perturbações antrópicas têm um maior impacto negativo nas áreas fragilizadas inibindo sua resiliência.

Por outro lado, no estudo desenvolvido por Chino *et al.* (2010) foi identificado que o NDVI do ano 2006 para o estado do São Paulo teve um valor de 0,59 que, segundo a classificação proposta por Menezes *et al.* (2019), encontra-se categorizado como vegetação pouco saudável, no qual os autores sugeriram que pode estar associado à ação antrópica, principalmente a extensão de atividades agrícolas como o cultivo de cana-de-açúcar.

6.2.2. Reclassificação do índice de Vegetação por Diferença Normalizada

A Figura 13 apresenta a classificação dos valores de NDVI em classes de potencial para aplicação do MDL.

Figura 13. Reclassificação NDVI para o ano 2020.



Fonte: Autoria própria

Em relação aos resultados da reclassificação do potencial de NDVI, os quais podem ser observados na Figura 13, não é possível identificar áreas classificadas como de altíssimo potencial, enquanto as classes de alto potencial representam 81,37 km², já as classes com médiopotencial abrangem 121,13 km², sendo predominantes na área de estudo, além de representarem principalmente à área de interesse.

O bioma de Mata Atlântica é destacado por ter uma fragilidade elevada como produto de suas características ambientais, alguns autores descrevem como as qualidades de uma região podem influenciar no comportamento fotossintético da vegetação, já que, em áreas com maior declividade, as quais têm uma menor intervenção antrópica, apresentam valores maiores que representam um melhor estado fotossintético, sendo este padrão evidenciado na bacia hidrográfica do Rio Sorocabaçu (SILVA *et al.*, 2021; MARCHETTI *et al.*, 2016).

Barbosa *et al.* (2006) realizaram um estudo da variabilidade do estado da vegetação no período compreendido entre os anos 1982 e 2001 para a região nordeste do Brasil, que corresponde a nove estados, os resultados obtidos permitem identificar uma variação no vigor da vegetação ao longo do período selecionado para o qual descrevem que as mudanças no estado da vegetação, considerando variações abruptas causadas por fenômenos naturais como *La Niña* e *El Niño*, influenciam de maneira direta na dinâmica da mesma.

Além disso, os referidos autores citam ao final da pesquisa uma diminuição no vigor da vegetação ao longo dos 20 anos, o qual está associado ao crescimento populacional e desenvolvimento de atividades agrícolas e industriais; é importante mencionar que, embora o protocolo de Kyoto tenha sido proposto no ano de 1997, este não entrou em vigor até o ano de 2005, portanto, corrobora com os resultados encontrados para decréscimo do estado fotossintético da vegetação.

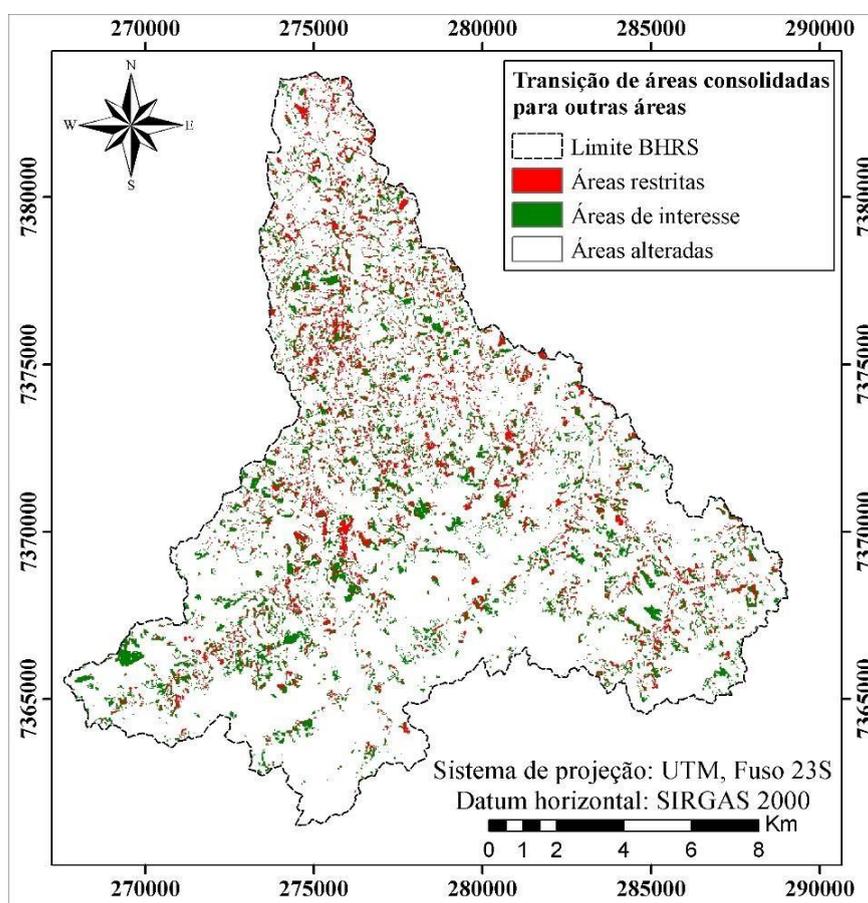
6.3. Modelagem e geração de cenários elegíveis

6.3.1. Análise temporal das mudanças

Em relação à modelagem e geração de cenários viáveis, foram

utilizadas as reclassificações do uso da terra dos anos 2000 e 2020 para gerar um mapa de mudanças do uso da terra (Figura 14); neste mapa é possível observar a transformação das áreas estabilizadas para outras classes, onde a expansão que as mesmas tiveram foram semelhantes, apresentando um aumento de 13,06 km² para áreas restritas e de 17,98 km² para áreas de interesse.

Figura 14. Mudanças de áreas estabilizadas para outras classes.



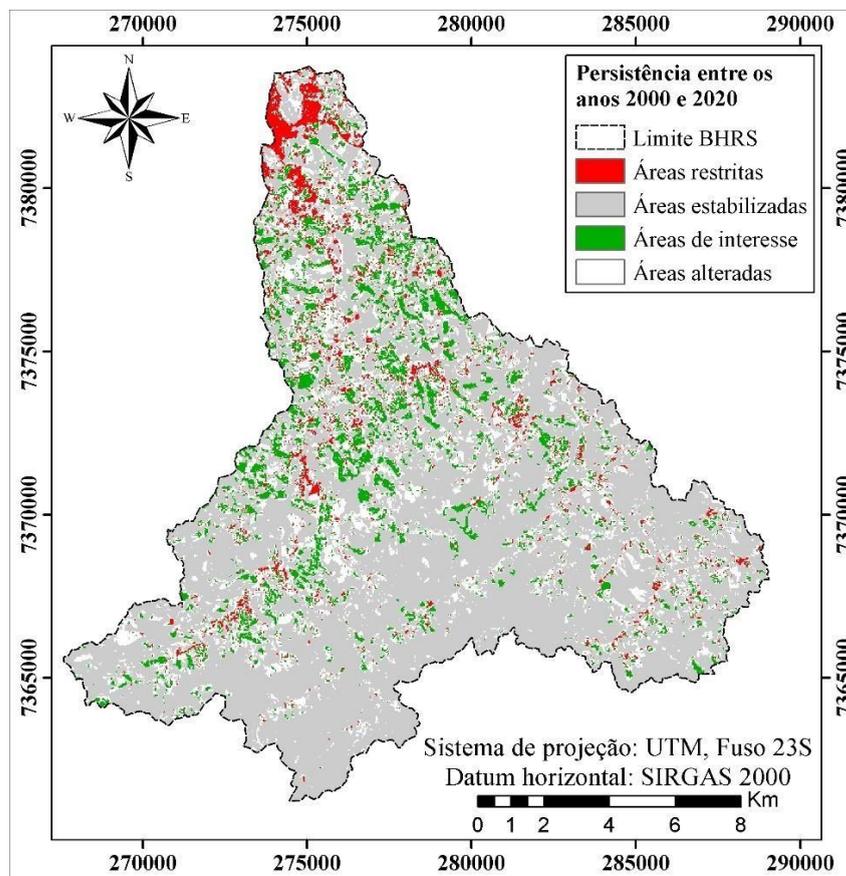
Fonte: A autoria própria

Por outro lado, na Figura 15 constam as persistências para cada classificação do uso da terra entre os anos 2000 e 2020, onde é possível perceber que, embora as áreas estáveis tenham mudado muito para outras categorias, também foram as que mais mantiveram, especialmente em regiões com alta declividade, as quais estão distantes de áreas restritas.

As mudanças ocorridas no período de estudo analisado são percebidas em áreas com menor declividade, onde alguns estudos descrevem este comportamento como um padrão, já que tais características são

apresentadas em áreas que têm uma maior facilidade para o estabelecimento de cultivos (SANKARRAO *et al.*, 2021).

Figura 15. Persistências das classes no período estudado.



Fonte: Autoria própria

Em relação à mudança para cada classe (Tabela 12), as áreas estabilizadas apresentaram uma maior perda de extensão, que representa o 15,32% da área de estudo, no caso das áreas restritas, estas tiveram um ganho de 10,53% de área e uma perda de 3,65%; finalmente, as áreas de interesse apresentaram uma perda de 5,53% e um ganho de extensão de 10,94%.

Tabela 12. Mudança temporal para cada classe.

Classe	Ganho (km ²)	Perda (km ²)
Áreas Estabilizadas	6,09	31,04
Áreas Restritas	21,35	7,39
Áreas de Interesse	22,18	11,2

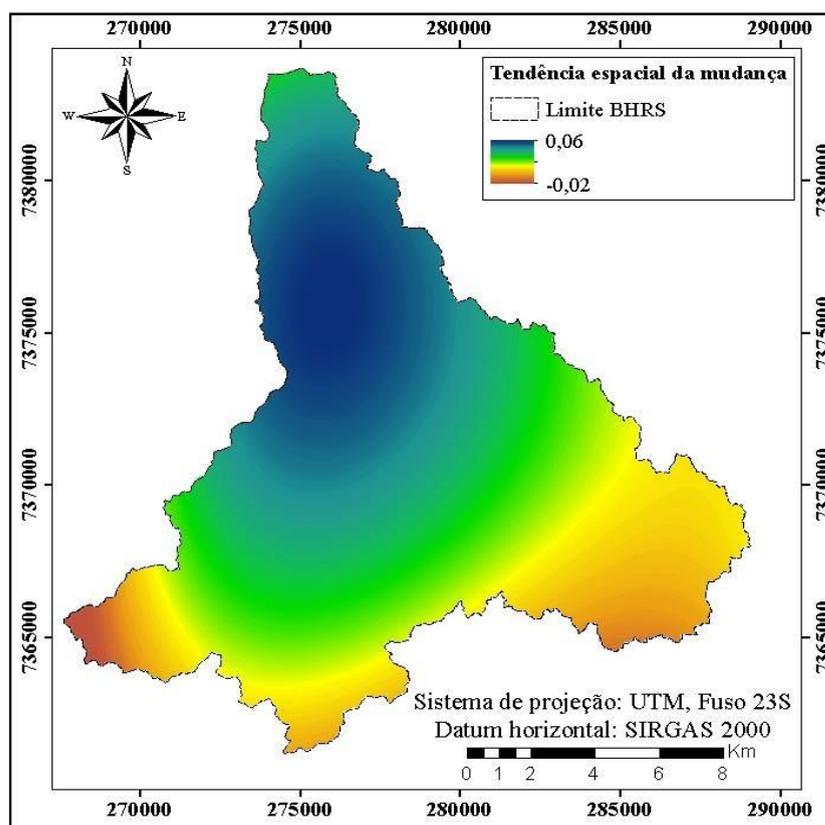
Fonte: Autoria própria

Finalmente, é importante mencionar que o módulo LCM tem sido amplamente utilizado em diversas investigações, sendo considerado uma ferramenta das mais utilizadas para avaliar e gerar cenários no futuro, é amplamente utilizado em pesquisas desenvolvidas nos continentes da Ásia e Europa, como exemplo o estudo feito por Sankarrao *et al.* (2021), o qual efetua uma comparação entre a classificação do uso da terra para o ano 2020, com a predição realizada para o mesmo ano através de quatro métodos distintos, conferindo, a partir dos resultados obtidos, que o modelo baseado no autoaprendizado apresentou a maior precisão com respeito aos outros utilizados como a cadeia de Markov do tipo MLP e regressão logística.

O LCM também é classificado como de alta confiabilidade, devido ao seu elevado nível de precisão avaliado através de índices como o Kappa, entre outros; finalmente, os modelos de redes neurais são considerados uma alternativa com um alto potencial para a predição do uso do solo (GARCÍA-ÁLVAREZ, 2022; GOMES *et al.*, 2021; SANKARRAO *et al.*, 2021; WANG *et al.*, 2021).

Em relação à tendência espacial da mudança do uso da terra, a Figura 16 permite observar as mudanças acontecidas no período de estudo, sendo visualizada uma maior tendênciana região noroeste da Bacia Hidrográfica do Rio Sorocabuçu, este comportamento pode ser influenciado pela presença de áreas antrópicas não agrícolas, além da localização da principal rodovia que se encontra localizada nessa área e a declividade (SANKARRAO *et al.*, 2021).

Figura 16. Tendência espacial da mudança do uso da terra.



Fonte: Autoria própria.

No estudo realizado por Oliviera-Andreoli *et al.* (2021) nota-se a importância das análises da dinâmica do uso da terra a relevância dessas informações para uma eficiente tomada de decisão e estabelecimento de medidas que permita uma melhora na gestão e conservação dos recursos naturais.

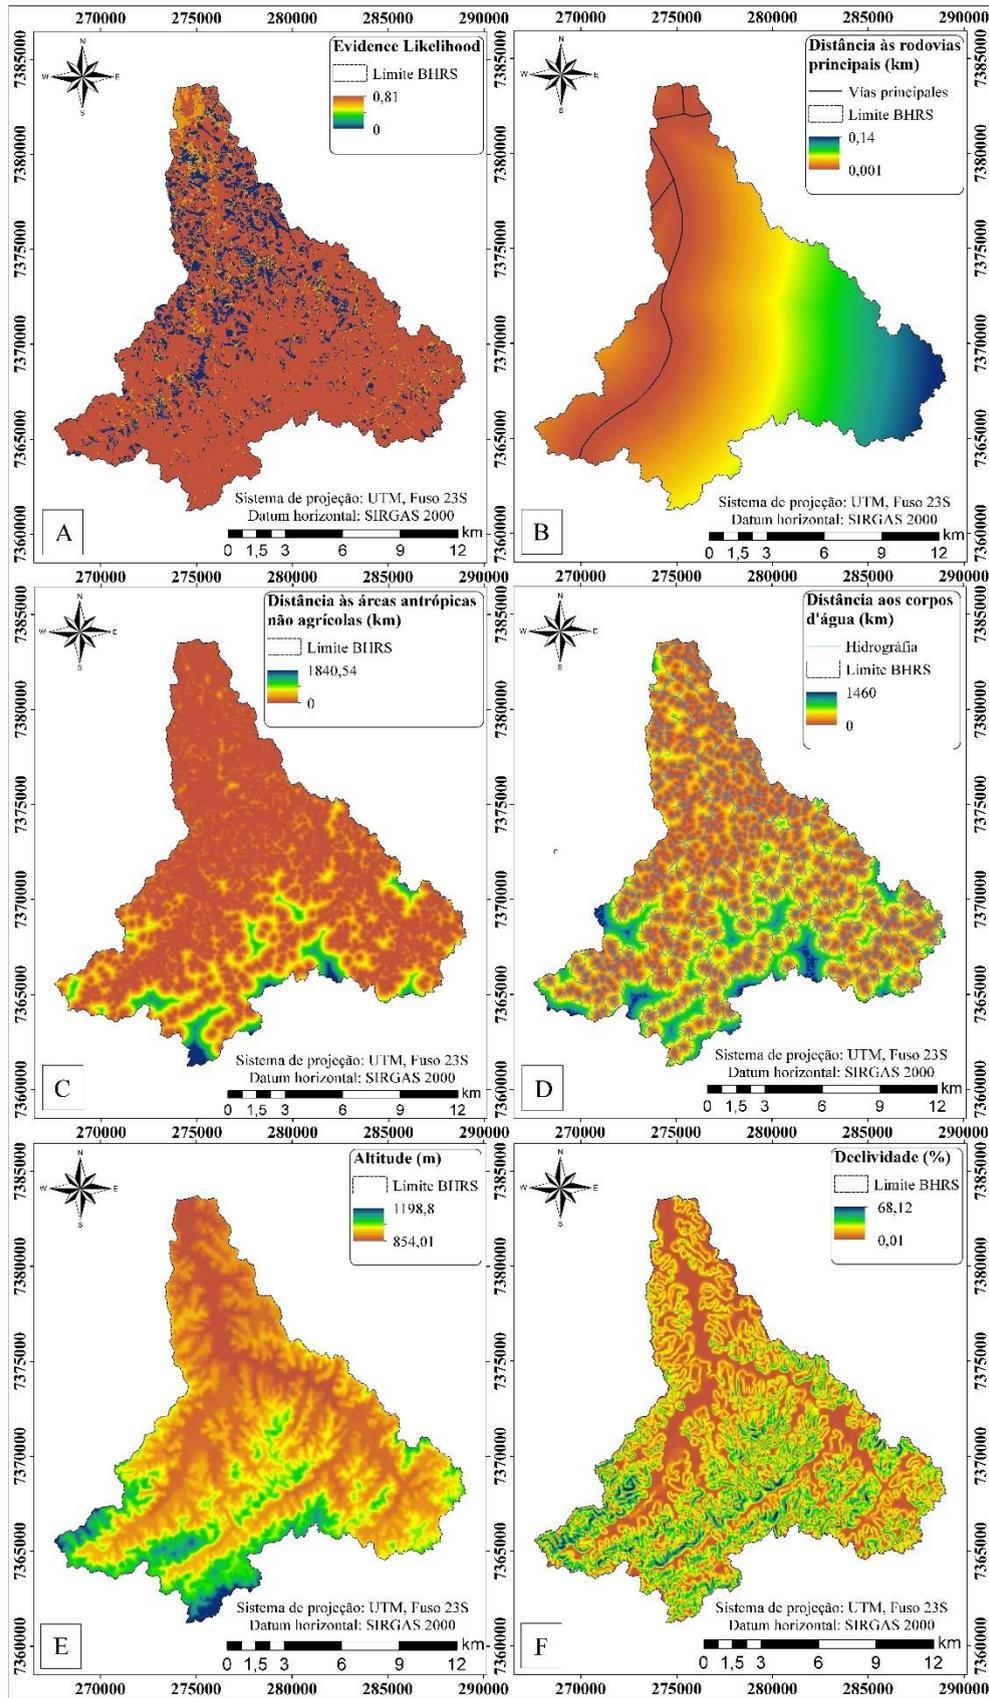
6.3.2. Modelo do potencial de transição

A Figura 17A apresenta a variável *Evidence Likelihood* que representa a frequência relativa onde aconteceram as transições das diferentes classes do uso da terra entre os anos 2000 e 2020, onde o aumento do valor representa a probabilidade de encontrar o uso da terra no pixel, caso fosse uma área de transição, sendo possível evidenciar que os valores maiores são principalmente os apresentados nas áreas de vegetação natural.

Por outro lado, também é possível evidenciar outras variáveis potenciadoras utilizadas para a construção do submodelo de transição obtidas e calculadas a partir do Modelo Digital de Elevação (MDE) do Estado de São

Paulo obtido através do site da Secretaria de Meio Ambiente.

Figura 17. Variáveis de condução A) *Evidence Likelihood* B) Distância às principais rodovias C) distância às áreas antrópicas não agrícolas D) distância aos corpos d'água E) Altitude F) Declividade.



Fonte: Autoria própria

Para a altitude (Figura 17E) e declividade (Figura 17F) é possível evidenciar que as áreas de maior valor pertencem à classe correspondente à área de vegetação natural; no caso das áreas antrópicas não agrícolas (Figura 17C), é visualizado que a menor distância se encontra em áreas com menor declividade e altitude, próxima à rodovia principal (Figura 17B), o qual é um padrão de desenvolvimento da população; da mesma maneira aos corpos d'água (Figura 17D) apresenta uma distância menor as áreas antrópicas não agrícolas, sendo um comportamento esperado já que ao longo dos anos o estabelecimento dos centros urbanos foi desenvolvido nas proximidades de corpos d'água para ter uma maior acessibilidade à este recurso (SANKARRAO *et al.*, 2021).

Na Tabela 13 é possível visualizar os resultados do teste de Cramer's V para cada variável, tanto para os valores obtidos de maneira geral quanto para cada tipo de cobertura da terra.

Tabela 13. Teste Cramer 's V.

F o n t e	Uso da terra	Variáveis de condução					Distância aos corpos d'água
		Evidência de semelhança	Altitude	Declividade	Distância às rodovias	Distância às áreas urbanas	
: Áreas Restritas a Áreas Estabilizadas o Áreas de r Interesse i Geral a	Áreas Restritas	0	0	0	0	0	0
	Áreas Estabilizadas	0,39	0,31	0,22	0,21	0,96	0,28
	Áreas de Interesse	0,59	0,36	0,24	0,25	0,65	0,31
	Geral	0,37	0,23	0,16	0,16	0,60	0,21

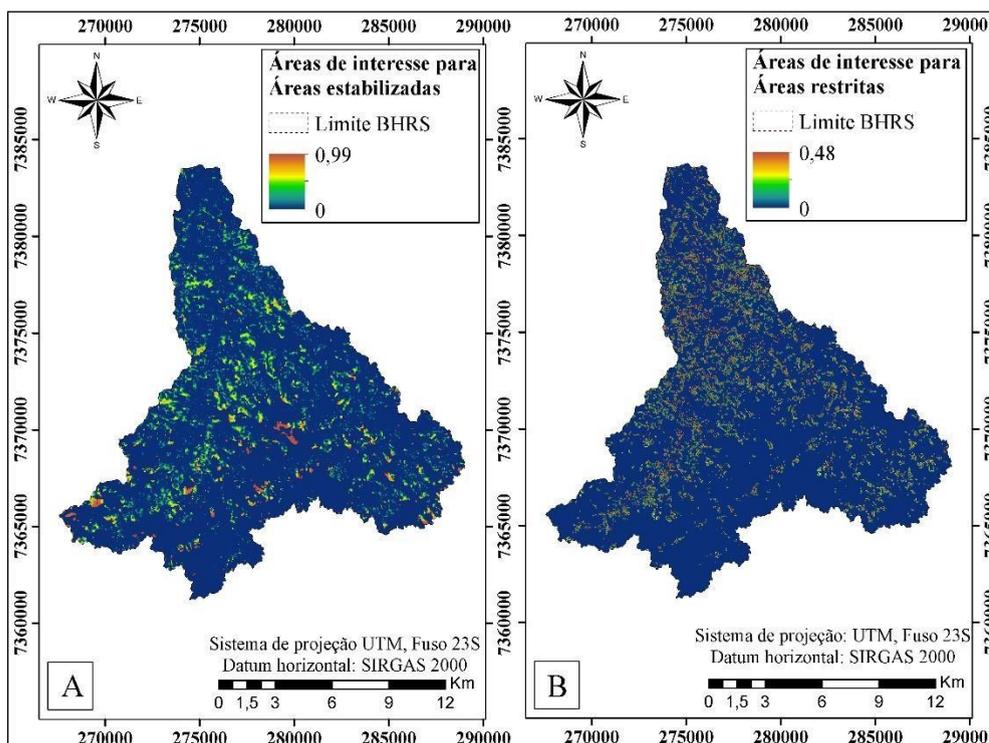
Fonte: autoria própria

Os valores mais significativos, de maneira geral, foram apresentados pelas variáveis de distância às áreas urbanas e evidência de semelhança, com 0,60 e 0,37, respectivamente, enquanto os valores mais baixos pertencem às variáveis de declividade (0,16) e distância às rodovias (0,16).

Em relação aos mapas do potencial de transição, estes apresentaram uma taxa de precisão de 84,25%, sendo recomendado o valor mínimo de 80% para os resultados modelados (SANKARRAO *et al.*, 2021). A Figura 18A mostra o potencial de transição de áreas de interesse para áreas estabilizadas, onde é possível observar que o maior potencial é apresentado em áreas

afastadas de maior concentração nos centros urbanos, por outro lado, é apresentado um menor potencial de transição para áreas restritas (0,48), cuja extensão encontra-se principalmente em áreas com menor declividade.

Figura 18. Potencial de transição. A) para Áreas estabilizadas B) para Áreas restritas.



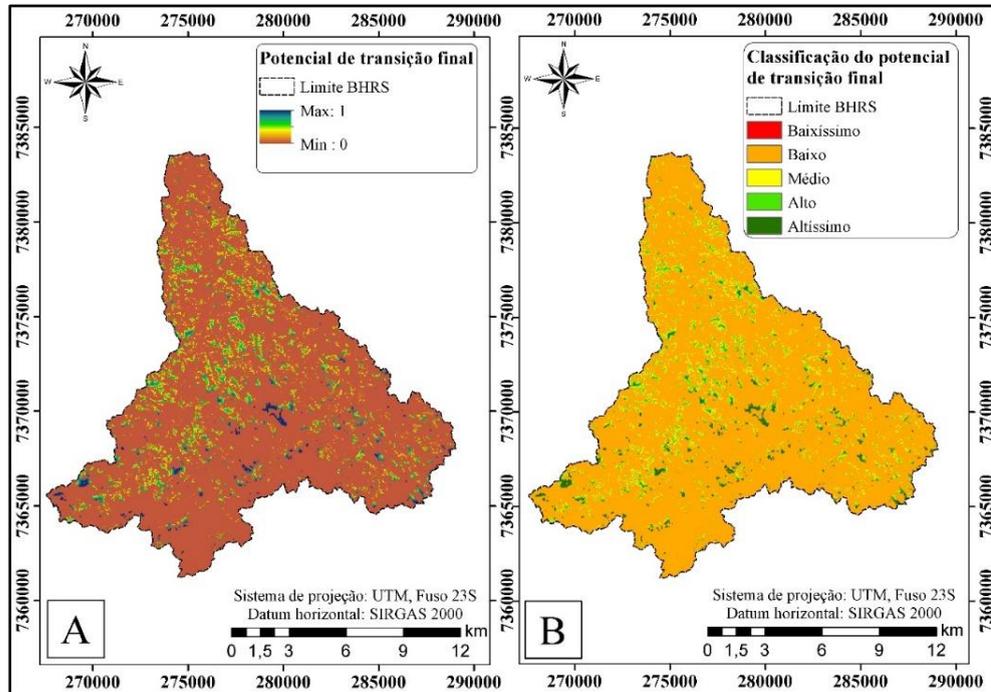
Fonte: Autoria própria

O estudo realizado Milhomem *et al.* (2022) no bioma do cerrado, o qual visava avaliar os impactos gerados devido às mudanças no uso da terra no período compreendido entre os anos 1986 - 2016, além de gerar cenários futuros, também determinou que entre as principais causas das mudanças abruptas no uso da terra encontram-se as atividades agropecuárias, representando o principal setor do país; tais atividades podem ser mais invasivas com o passar dos anos devido ao aumento da demanda de recursos naturais caso não sejam adotadas técnicas de baixo carbono e sustentáveis, podendo ter um aumento de até um 49% com respeito à uso da terra entre o 2033 e 2100 (RODRIGUES *et al.*, 2020).

Na Figura 19 é apresentado o potencial de transição final, sendo possível observar que o potencial categorizado como baixo predomina na área de estudo, não obstante, existem áreas com potencial altíssimo as quais

representam 2,21% do total da área de estudo.

Figura 19. A) PTF normalizado B) PTF reclassificado.



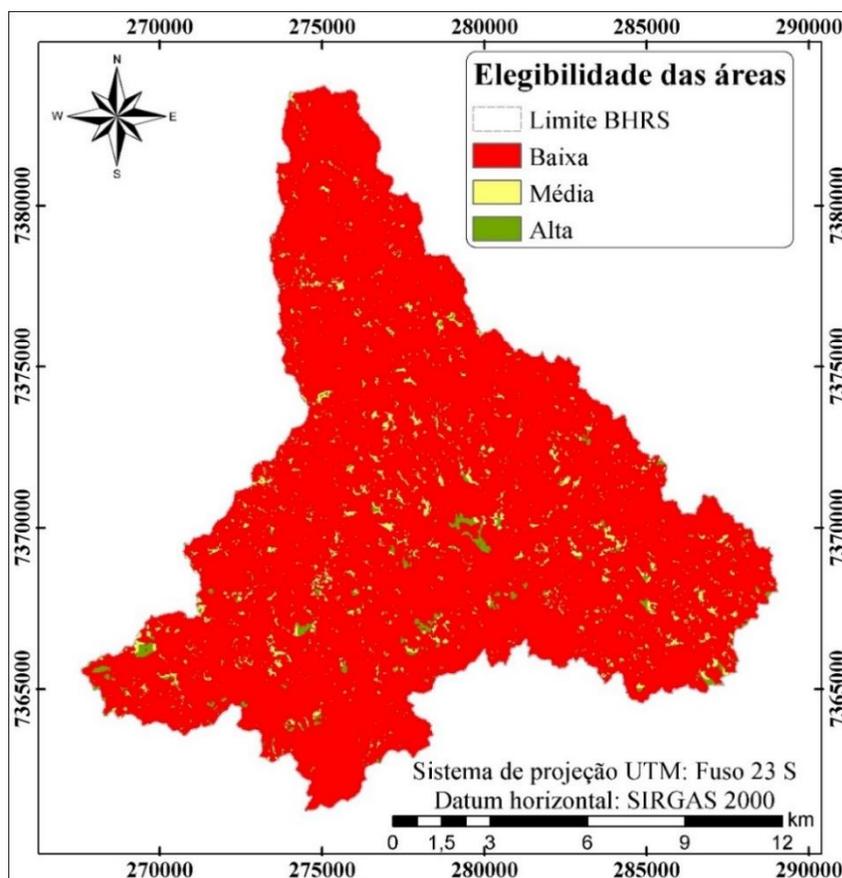
Fonte: Autoria própria

No estudo feito por Díaz-Pacheco e Hewitt (2013), foi identificada a utilidade dos modelos de simulação baseados no uso de inteligência artificial, além da geração de mapas do potencial do uso da terra, no qual é possível a identificação de padrões do comportamento, nesse caso o potencial de uma área para modificar-se por outro uso da terra no futuro.

A Figura 20 apresenta os valores obtidos através do sistema fuzzy, os quais representam a elegibilidade das áreas na bacia hidrográfica do Rio Sorocabaçu que apresentam potencial para o desenvolvimento de projetos de MDL e, consequentemente, a identificação de áreas com uma alta capacidade de captura de CO₂.

Foi identificado que a área de estudo se encontra principalmente com uma baixa elegibilidade (192,67 km²) para a implementação de projetos que contribuam com o mecanismo de desenvolvimento limpo, enquanto a área de estudo apresentou uma porcentagem de elegibilidade média e alta, respectivamente, de 3,55% (7,19 km²) e 1,38% (2,81 km²).

Figura 20. Elegibilidade das áreas.



Fonte: Autoria própria

Segundo Nogueira (2018) o potencial do MDL é de elevada importância para o país considerando a relevância das florestas para mitigação da mudança climática através da remoção de CO₂. No entanto, para sua implementação como política pública, este enfrenta dois desafios, o primeiro relacionado à criação de alternativas que permitam o cumprimento dos critérios de adicionalidade dos benefícios obtidos por meio de práticas sustentáveis; e o segundo a identificação da permanência de florestas para garantir a remoção de CO₂, considerando que as atividades MDL estão limitadas ao florestamento e reflorestamento.

No estudo realizado por Barbosa *et al.* (2021) foi avaliado o potencial de sequestro de CO₂ de áreas elegíveis para implementação de projetos MDL na bacia hidrográfica do rio Pardo localizada no estado de Minas Gerais através da simulação de diversos cenários de florestamento e reflorestamento, onde foi identificado que para florestamento de 20 anos há um sequestro de 10,22 milhões de mg de CO₂, enquanto para o reflorestamento de seis anos o

sequestro de carbono foi de 12 milhões de mg de CO₂.

Em questão do desenvolvimento de projeto MDL, o Brasil localiza-se no terceiro lugar em número de projetos, sendo que foi desenvolvido na cidade de Rio de Janeiro no Aterro Novagerrar, o primeiro projeto MDL registrado no mundo; seguido por China e Índia. Entretanto, a contribuição ainda é insuficiente para alcançar a meta de redução de 43% estabelecida para o ano 2030 em relação as emissões emitidas para o ano de 2005, no qual o mercado é incipiente à implementação de novos projetos e, também, para a questão da redução de emissões de GEE (MARTINS, 2010; TORRES *et al.*, 2016).

Segundo Gil (1999) dentre os principais problemas relacionados à implementação de projetos MDL é a falta de conhecimento já que respostas mitigadoras na implementação de medidas carecem de levantamento bibliográfico na área.

Mesmo que o Brasil, ao ser um país em desenvolvimento não tenha a obrigação de reduzir as emissões de gases efeito estufa, a geração e implementação de projetos MDL tem como benefícios o investimento e a venda de créditos de carbono para o cumprimento das suas metas, além da viabilização do desenvolvimento sustentável do país (SATIO, 2006). Além disso, Lima (2019) descreve que para uma economia de baixo carbono no país é necessária uma redução de emissões já que o Brasil tem uma média de 1 t CO₂ por milhão de PIB, sendo necessário um valor, em média, de 0,05 t CO₂ por milhão de PIB para o cumprimento da meta.

Segundo Benites-Lazaro *et al.* (2018) a implementação de projetos MDL não só contribui com a redução de emissões dos gases efeito estufa, como também com o desenvolvimento sustentável do país já que aprimora a sustentabilidade social através da geração de empregos, capacitação social, além de assistência às comunidades em atividades sociais.

Por fim, é importante mencionar que o Brasil é um dos pilares fundamentais para o mecanismo de desenvolvimento limpo mundial, uma vez que o mesmo foi criado a partir de uma proposta feita pelo país em 1997, além de ser um dos primeiros países a estabelecer bases para a implementação de projetos, mantendo-se nas primeiras posições com relação a quantidade de projetos MDL desenvolvidos (MUDROVITSCH *et al.*, 2018).

7. CONCLUSÕES

No presente estudo foram obtidos resultados satisfatórios para a validação da classificação do uso da terra, sendo categorizada com um nível de concordância excelente o qual permite conhecer o grau de confiabilidade dos dados apresentados bem como do potencial de transição. Além do exposto, ressalta-se que o uso da inteligência artificial, ao comparar com o mapeamento tradicional, possui a vantagem de permitir que a classificação do uso do solo apresente maior eficácia.

Através da classificação do uso da terra efetuada na bacia hidrografia do Rio Sorocabaçu foi possível identificar uma expansão de áreas antrópicas não agrícolas e um aumento nas áreas de vegetação natural para o ano de 2020 em comparação ao ano de 2000. Além disso, outros estudos apresentados apontam uma perda da vegetação natural, em áreas de proteção ambiental próximas da área de estudo, principalmente devido à expansão da atividade agrícola.

Com base nos resultados obtidos pelo cálculo do Índice de Vegetação por Diferença Normalizada, é possível concluir que a vegetação nas áreas estudadas apresenta baixo nível de saudabilidade. Além disso, observou-se que a vegetação com maior atividade fotossintética se encontra principalmente em áreas com maior declividade, o que pode ser explicado pela presença de áreas de proteção ambiental que possuem mecanismos de proteção viabilizando a manutenção desses maciços florestais. No entanto, esses mecanismos não são altamente eficazes para garantir que o estado fotossintético da vegetação esteja numa categoria mais saudável.

É importante ressaltar que os resultados obtidos a partir das análises e modelagens realizadas neste estudo podem ser utilizados como importantes ferramentas para auxiliar na gestão ambiental e no planejamento de políticas públicas que visam a conservação da biodiversidade e o enfrentamento das mudanças climáticas.

Nesse sentido, torna-se necessário investir em pesquisas que visem aprimorar os projetos de MDL e a produção de material bibliográfico científico que dê suporte às decisões políticas e à implementação de projetos ambientais efetivos. A implementação de medidas eficazes de proteção ambiental e de mitigação das mudanças climáticas é crucial para garantir um futuro sustentável para as próximas gerações.

A identificação de áreas elegíveis para reflorestamento representa um papel

fundamental no combate às mudanças climáticas e na promoção do desenvolvimento sustentável, contribuindo diretamente com os ODS da Organização das Nações Unidas (ONU), como a ação contra a mudança global do clima.

Por fim, para futuros projetos é recomendado o cálculo do orçamento que permita a identificação do custo/benefício no que se refere à identificação de áreas elegíveis para a implementação de projetos MDL em relação à extensão da área, além da determinação do CO₂ que seria capturado a partir das medidas projetadas.

REFERÊNCIAS

- AĞBULUT, Ü.; CEYLAN, İ.; GÜREL, A. E.; ERGÜN, A., 2019. The history of greenhouse gas emissions and relation with the nuclear energy policy for Turkey. **International Journal of Ambient Energy**, v. 3, n. 2, 2019, DOI 10.1080/01430750.2018.1563818.
- AGUILAR, H.; MORA, R.; VARGAS, C. Metodología para la corrección atmosférica de imágenes aster, rapideye, spot 2 y landsat 8 con el módulo flaash del software ENVI. **Revista geográfica de América central**, v. 2, n. 53, p. 39 – 59, 2014, DOI 10.15359/rgac.2-53.2.
- ALIABAD, F.; ZARE, M.; SOLGI, R.; SHOJAEI, S.; Comparison of neural network methods(fuzzy ARTMAP, Kohonen and Perceptron) and maximum likelihood efficiency in preparation of land use map. **GeoJournal**, Ago. 2022, DOI 10.1007/s10708-022-10744-y.
- ÁLVAREZ, X.; VALERO, E.; PICOS, J. O. L. Estudio de la cubierta vegetal del monte forgoselo mediante imágenes de Landsat TM 5 (Galicia, NW España). **DYNA**, Medellín, v. 82,n. 190, p. 173 – 181, mar./abr. 2014, DOI 10.15446/dyna.v82n190.43725.
- ANDERSON, T.; HAWKINS, E.; JONES, P. CO₂, the greenhouse effect and global warming:from the pioneering work of Arrhenius and Calendar to today's Earth System Models. **Endeavour**, v. 40, n. 3, p. 178-187, Set 2016, DOI 10.1016/j.endeavour.2016.07.002
- ANDREOTI, C. **Avaliação da eficiência de um sistema agroflorestal na recuperação de um solo degradado por pastoreio. São Paulo**, 2012, 131 p. Dissertação (Mestrado em Geografia física), Universidade de São Paulo, São Paulo, 2012.
- ATTIA, A.; NOUVELLON, Y.; CUADRA, S.; CABRAL, O.; LACLAU, J.; GUILLEMOT, J.;CAMPOE, O.; STAPE, J.; GALDOS, M.; LAMPARELLI, R.; MAIRE, G. Modeling carbon and water balance of Eucalyptus plantations at regional scale: Effect of climate, soil and genotypes. **Forest Ecology and Management**, v. 449, Out 2019, DOI 10.1016/j.foreco.2019.117460.
- AZEVEDO, W. C.; RODRIGUES, M.; CORREIA, D. Does agricultural efficiency contribute to slowdown of deforestation in the Brazilian Legal Amazon?. **Journal for Nature Conservation**, v. 65, fev. 2022, DOI 10.1016/j.jnc.2021.126092.
- BARBOSA, G.; SANTOS, M.; LIMA, V.; VICENTE, M.; MARTINS, T. Avaliação de áreas elegíveis à implantação de projetos de MDL florestais na bacia de Rio Pardo, em Minas Gerais. **Pesquisas Agrárias e Ambientais**, v. 9 n. 1, jan./fev. 2021, DOI:10.31413/nativa.v9i1.11173
- BARBOSA, K.; BATISTA, J.; ROCHA, S.; SANTOS, K.; SANTOS, G.; RATKE, R. Mudança no uso do solo na bacia hidrográfica do rio Uruçuí-Preto, Piauí. **Brazilian Journal of Development**, v. 5, n. 11, p. 25490 – 25511, Nov 2019, DOI

10.34117/bjdv5n11-211.

BENITES-LAZARO, L.; MELLO-THÉRY, N.; SIMÕES, A.; GNACCARINI, I. Governança e desenvolvimento sustentável: a participação dos stakeholders locais nos projetos de mecanismo de desenvolvimento limpo no Brasil. **Revista Colombiana de Geografia**. v. 27, n. 2, p. 227 – 241, 2018, DOI: 10.15446/rcdg. v27n2.66336.

BERA, D.; CHATTERJEE, N.; GOSH, S.; DINDA, S.; BERA, S.; MANDAL, M.; Assessment of forest cover loss and impacts on ecosystem services: Coupling of remote sensing data and people's perception in the dry deciduous forest of West Bengal, India. **Journal of Cleaner Production**, v. 356, Jul 2022, DOI 10.1016/j.jclepro.2022.131763.

CETESB. Enquadramento dos Corpos Hídricos – Mapas Temáticos. Disponível em: <https://cetesb.sp.gov.br/aguas-interiores/enquadramento-dos-corpos-hidricos-mapas-tematicos/>, 2016

CHECHI, L. A. **Dos acordos globais às ações locais sobre mudanças climáticas: tradução e implementação do plano e programa ABC**. 2019. Tese de Doutorado (Desenvolvimento Rural)

CHINO, D. Y. T; ROMANI, L. A. S.; TRAINA, A. J. M. Construindo séries temporais de imagens de satélite para sumarização de dados climáticos e monitoramento de safras agrícolas. **Revista Eletrônica de Iniciação Científica - REIC**, v. 10, p. 1-16, 2010.

COSTA JÚNIOR, A.; Pasini, K.; Andrade, C. Clean Development Mechanism in Brazil: an instrument for technology transfer and the promotion of cleaner technologies?. **Journal of Cleaner Production**. v. 46, p. 67 – 73, 2013, DOI 10.1016/j.jclepro.2012.09.044

COSTA, L.; NUNES, L.; AMPATZIDIS, Y. A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms. **Computers and Electronics in Agriculture**, v. 172, Maio 2020, DOI 10.1016/j.compag.2020.105334.

COUTO, A.; CONCEIÇÃO, F.; FERNANDES, A.; SPATTI, E.; LUPINACI, C.; MORUZZI, R. Land use changes associated with the expansion of sugar cane crops and their influences on soil removal in a tropical watershed in São Paulo State (Brazil). **CATENA**, v. 172, p. 313 – 323, Jan. 2019, DOI 10.1016/j.catena.2018.09.001.

CROUZEILLES, R.; SANTIAMI, E.; ROSA, M.; PLUGIESE, L.; BRANCALION, P.; RODRIGUES, R.; METZGER, J.; CALMON, M.; SCARAMUZZA, C.; MATSUMOTO, M.; PADOVEZI, A.; BENINI, R.; CHAVES, R.; METZKER, T.; FERNANDES, R.; SCARANO, F.; SCHMITT, J.; LUI, G.; CHRIST, P.; VIEIRA, R.; SENTA, M.; MALAGUTI, G.; STRASSBURG, B.; PINTO, S. There is hope for the achieving ambitious Atlantic Forest restoration commitments. **Perspectives in ecology and conservation**. v. 17, p. 80 – 83, 2019

CUYA, O. **Variación del índice de vegetación de diferencia normalizada (NDVI) en relación con la gradiente altitudinal en las lomas de Atocongo (Lima**

- Perú), 2016, 276 p., Dissertação (Mestrado em Ecología e Gestão ambiental), Universidad Ricardo Palma, Lima, 2016.
- DANTAS, D.; CASTRO, M.; RODRIGUES, L.; CALEGARIO, M.; MANDARANO, S. Above and belowground carbon stock in a tropical forest in Brazil. **Acta Scientiarum**, v. 43, 2020, DOI 10.4025/actasciagron.v43i1.48276.
- DAS, R., DAS, S.; BHATTACHARJEE, H. CO₂ Sequestration Using Algal Biomass and its Application as Bio Energy. **Encyclopedia of Renewable and Sustainable Materials**. 2018.
- DAVRAN, T. CO₂ Capturing Materials. **Comprehensive Energy Systems**, v. 2, 2018, p. 881 – 912, DOI 10.1016/B978-0-12-809597-3.00255-8.
- DEFIGE, A.; ZABEL, F.; MAUSER, W. Assessing land use and land cover changes and agricultural farmland expansions in Gambella Region, Ethiopia, using Landsat 5 and Sentinel 2a multispectral data. **Heliyon**, v. 4, n. 11, Nov 2018, DOI 10.1016/j.heliyon.2018.e00919.
- DÍAZ-PACHECO, J.; HEWITT, R. Modelado de câmbios de usos de suelo urbano a través de redes neuronales artificiales: Comparando dos aplicaciones de software. **Geofocus**. 2013.
- DUBREUIL, V.; FANTE, K.; PLANCHON, O.; SANT'ANNA, J. Les types de climats annuels au Brésil: une application de la classification de Köppen de 1961 à 2015. **EchoGéo**, v. 41, n. 41, Set. 2017, DOI 10.4000/echogeo.15017.
- FAO, **Bosques, seguridad alimentaria y medios de vida sostenibles**. 2000, Disponível em: <https://www.fao.org/3/x7273s/x7273s01.htm>
- FAO, **Los árboles fuera del bosque, hacia una mejor consideración**. 2002, Disponível em: <https://www.fao.org/3/y2328s/y2328s00.htm#toc>.
- FAO; PNUMA, **El estado de los bosques del mundo 2020. Los bosques, la biodiversidad y las personas**. 2020, Disponível em: [fao.org/3/ca8642es/CA8642ES.pdf](https://www.fao.org/3/ca8642es/CA8642ES.pdf)
- FAUSTINO, A. **Sistemas de Informação Geográfica em contexto municipal: o caso da elaboração do REOT da Câmara Municipal de Leiria**. 2022. Tese de Doutorado.
- FRANCHINI, M.; EVANGELISTA, A. C.; VIOLA, E.; De Lula a Bolsonaro: una década de degradación de la gobernanza climática em Brasil. **Análisis político**, n. 99, p. 81 – 100, Maio/Ago 2020.
- FREITAS, M.; SANTOS, A.; SILVA, É.; PIANCENTINI, L.; NASSER, V.; RAMOS, M. The role of environmental legislation and land use patterns on riparian deforestation dynamics in an Amazonian agricultural frontier (MT, Brazil). **Land Use Policy**, v. 118, Jul 2022, DOI 10.1016/j.landusepol.2022.106132.
- FREITAS, R.; ALVES, M.; Expansão agrícola no Brasil e a participação da soja: 20 anos. **RESR**, v. 54, n. 3 p. 497 – 516, Jul/Set 2016, DOI 10.1590/1234-56781806-

94790540306.

GARCÍA-ÁLVAREZ, D. Comparing the structural uncertainty and uncertainty management in four common Land Use Cover Change (LUCC) model software packages. **Environmental Modelling & Software**, p. 105411, 2022.

GARRETT, R.; GRABS, J.; CAMMELLI, F.; GOLLNOW, F.; LEVY, S. Should payments for environmental services be used to implement zero-deforestation supply chain policies? The case of soy in Brazilian cerrado. **World Development**, v. 152, abril 2022, DOI 10.1016/j.worlddev.2022.105814.

GIL, A.C. Métodos e técnicas de pesquisa social. 5 ed. São Paulo: **Atlas**, 1999. p. 206

GOMES, E.; INÁCIO, M.; BOGDZEVIČ, K.; KALINAUSKAS, M.; KARNAUSKAITE, D.; PEREIRA, P. Future land-use changes and its impacts on terrestrial ecosystem. **Science of the Total Environment**, v. 781, Ago. 2021, DOI 10.1016/j.scitotenv.2021.146716.

GOMES, T.; SOUZA, K.; RANI-BORGUES, B.; BIAMONT-ROJAS, E.; MARTINS, M. Análise espacial de matéria orgânica do reservatório de Itupararanga (SP, Brasil). **Anais do Encontro Nacional de Pós-Graduação – IX ENPG** v. 4, 2020, Disponível em: periodicos.unisantabr/index.php/ENPG/article/view/2578/1867.

GURFINKEL, S. Projetos de redução de emissões de gases de efeito estufa: desempenho e custos de transação. **Revista de Administração**, v. 48, n. 2, p. 310 – 326, 2013, DOI: 10.5700/rausp1090.

HAN, H.; YANG, C.; SONG, J. Scenario Simulation and the Prediction of Land Use and Land Cover Change in Beijing, China. **Sustainability**, v 7, n. 4, p. 4260 – 4279, 2015, DOI 10.3390/su7044260.

HAYKIN, S. **Neural Networks and Learning Machines**. 2009, Third ed: Pearson Education. Inc.

HSIEH, W. **Machine Learning Methods in the Environmental Sciences**: Cambridge University Press, 2009.

IBGE, Instituto Brasileiro de Geografia e Estatística. **Biomass e sistema costeiro - marinho do Brasil**. Rio de Janeiro, 2019

IBGE, Instituto Brasileiro de Geografia e Estatística. **IBGE cidades**. 2020, Disponível em: <http://www.cidades.ibge.gov.br/v4/brasil/sp/ibiuna/panorama>

IBGE. - Instituto Brasileiro de Geografia e Estatística **Manual Técnico de Uso da Terra**. 2013

IGAC, I. G. A. C., 2013. **Descripción y corrección de productos Landsat 8 LDCM**. Bogotá, Colombia, 2013, Disponível em: .un-

spider.org/sites/default/files/LDCM-L8.R1.pdf

INAZUMI, S.; INTUI, S.; JOTISANKASA, A.; CHAIPRAKAIKEOW, S.; KOJIMA, K. Artificial intelligence system for supporting soil classification. **Results in Engineering**, v. 8, Dez 2022, DOI 10.1016/j.rineng.2020.100188

IPCC, **Climate change and land**, 2020, Disponível em: ipcc.ch/site/assets/uploads/2019/11/SRCCL-Full-Report-Compiled-191128.pdf.

ISLAM, K.; RAHMAN, M. F.; JASHIMUDDIN, M. Modeling land use change using CellularAutomata and Artificial Neural Network: The case of Chunati Wildlife Sanctuary, Bangladesh. **Ecological Indicators**, v 88, p. 439 – 453, Maio 2018, DOI 10.1016/j.ecolind.2018.01.047.

IZADKHAH, H. Basic structure of neural networks, **Deep Learning in Bioinformatics**, 2022, cap. 4, p. 67 – 93, DOI 10.1016/B978-0-12-823822-6.00011-1.

JARAMILLO, L.; ANTUNES, A. Detecção de cambios en la cobertura vegetal mediante interpretación de imágenes Landsat por redes neuronales artificiales (RNA). Caso de estudio: Región Amazónica Ecuatoriana. **Revista de Teledetección**, v. 51, n. 33, p. 33 – 46, 2018, DOI10.4995/raet.2018.8995.

KARUL, C.; SOYUPAK, S., 2006. A comparison between neural network based and multiple regression models for Chlorophyll-a estimation. In Recknagel: **Ecological Informatics**, p 309 – 323, 2006, DOI 10.1007/3-540-28426-5_15.

LANDIS, J.; KOCH, G. The measurement of observer agreement for categorical data, **Biometrics**, v. 33, n. 1, p 159 – 174, Mar. 1977.

LAUCH, A.; BASTIAN, O.; KLOTZ, S.; LEITÃO, P.; JUNG, A.; ROCCHINI, D.; SCHAEPMAN, M.; SKIDMORE, A.; TISCHENDORF, L.; KNAPP, S. Understanding and assessing vegetation health by in situ species and remote-sensing approaches. **Methods in ecology and evolution**, v. 9, n. 8, p. 1799 – 1809, Ago. 2018, DOI 10.1111/2041-210X.13025.

LEFEBVRE, D.; GOGLIO, P.; WILLIAMS, A.; MANNING, D.; DE AZEVEDO, A.; BERGMANN, M.; MEERSMANS, J.; SMITH, P. Assessing the potential of soil carbonation and enhanced weathering through Life Cycle Assessment: A case study for Sao Paulo State, Brazil. **Journal of Cleaner Production**, v. 233, p. 468 – 481, Out. 2019, DOI10.1016/j.jclepro.2019.06.099.

LI, C.; WEI, Y.; CAO, S.; GUO, X.; YU, X.; CHANG, C. Estimating apple tree canopy chlorophyll content based on Sentinel-2A remote sensing imaging. **Scientific reports**, v. 8, p. 1 – 10, 2018, DOI 10.1038/s41598-018-21963-0.

LIAKOS, K.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine Learning in agriculture: A Review. **Sensors**, v 18, n. 8, 2018, DOI 10.3390/s18082674.

LIMA, R. Cenário do mercado regulado de MDL no nordeste do Brasil. Dissertação

(Mestrado em Ciências Econômicas), Serra Talhada, 2019.

LORONI, M. L. **Abordagem hierárquica e multiescalar para análises de distribuição geográfica da biodiversidade: sistemas quaternários costeiros da mata atlântica como estudo de caso.** 2007

LOURENÇO, R.; SILVA, D.; MARTINS, A.; SALES, J.; ROVEDA, S.; ROVEDA, J. Use of fuzzy systems in the elaboration of an anthropic pressure indicator to evaluate the remaining forest fragments. **Environmental Earth Sciences**, v. 74, n. 3, p. 2481 – 2488, Ago. 2015, DOI10.1007/s12665-015-4253-6.

MAGALHÃES, K.; SOUZA, K.; LIMA, M.; ALMEIDA, C.; ROSA, J.; OLIVEIRA, M. Oil spill+ COVID-19: A disastrous year for Brazilian seagrass conservation, **Science of the Total Environment**, Vol. 764, p. 142872, 2021 doi:10.1016/j.scitotenv.2020.142872.

MAIA, L.; LOURENÇO, R. Impactos das mudanças no uso e cobertura da terra sobre a variabilidade do albedo na bacia hidrográfica do rio Sorocabaçu (Ibiúna - SP). **Revista Brasileira de climatologia**, v. 27, n. 16, p. 443 – 462, 2020, DOI 10.5380/abclima.v27i0.72761.

MAMDANI, E.; ASSILIAN, S. An experiment in linguistic synthesis with a fuzzy logic controller. **International Journal of Man-Machine Studies**, v. 7, n.1, p. 1–13, Jan. 1975, DOI10.1016/S0020-7373(75)80002-2.

MARCHETTI, Z.; MINOTTI, P.; RAMONELL, C.; SCHIVO, F.; KANDUS, P. NDVI patterns as indicator of morphodynamic activity in the middle Paraná River floodplain. **Geomorphology**, v. 253, p. 146 – 158, Jan. 2016, DOI 10.1016/j.geomorph.2015.10.003.

MARTINS, F. O desenvolvimento sustentável e os projetos MDL no Brasil. **Revista Brasileira de Direito Constitucional – RBDC**, n. 16, Jul/Dez 2010.

MELI, P. Restauración ecológica de bosques tropicales. Veinte años de investigación académica. **Asociación Interciencia**, v. 28, n. 10, p. 581 – 589, Out. 2003.

MELO, T.; TEJERINA, F. D. M. C. Diversidade biológica da comunidade de peixes no baixo rio das Mortes, Mato Grosso, Brasil. **Revista Brasileira de Zoologia**, v. 24, n. 3, p. 657 – 665, Set. 2007, DOI 10.1590/S0101-81752007000300017.

MENESES, P.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**, abril 2012.

MENEZES, A.; CABRAL, J.; LINHARES, M. A aplicação do índice de vegetação por diferença normalizada (NDVI) para análise da degradação ambiental da área de influência direta do açude castanhão. **Revista casa de geografia de sobral**, v. 21, n. 2, p. 674 – 685, 2019.

MILHOMEM, D.; ALVARADO, S.; MARQUES, M.; RIBEIRO, M.; **Alterações do uso e cobertura da terra entre os anos de 1986 e 2018: estudo de caso da bacia**

do rio Lajeado no cerrado Maranhense. v. 1. p. 34 – 51, 2022, doi 10.37885/220909951.

MMA, **Ministério de Meio Ambiente**, Os planos de prevenção e controle do desmatamento em âmbito federal, 2021, Disponível em: combateadodesmatamento.mma.gov.br/

MMA, **Ministério do meio ambiente**. 2020 Disponível em: <https://www.gov.br/mma/pt-br/assuntos/biodiversidade>

MONTEIRO, I.; OLIVIERA, P.; GUEDES, D.; COSTA, D. Serviços ecossistêmicos de provisão prestados pelo entorno da Estação Ecológica do Seridó (Serra Negra do Norte-RN/NE, Brasil). **Revista GeoUECE**, v. 8, n. 14, p. 316-336, 2019.

MORA, C.; ALANÍS, E. Resiliencia de bosques de pino – encino en América: Una visión global del estado actual. **Revista forestal Mesoamericana**, v. 13, n. 33, p. 1 – 2, Jul/Dez 2016, DOI 10.18845/rfmk.v13i33.2571.

MORAES, F.; CONCEIÇÃO, F.; SARDINHA, D.; MOSCHINI, V.; POMPÊO, M. Avaliação da qualidade da água no reservatório de Itupararanga, bacia do alto Sorocaba (SP). **Geociências**, v. 33, n. 1, p. 26 – 38, Abril 2014.

MUDROVITSCH, S.; BUSCH, S.; ROJAS, M. **O MECANISMO DE DESENVOLVIMENTO LIMPO NO BRASIL**, 2018, Disponível em: <https://repositorio.ipea.gov.br/bitstream/11058/9474/1/O%20Mecanismo.pdf>

MÜLLER, A.; OLSCHESKI, R.; UNTERBERGER, C.; KNOKE, T. The valuation of forest ecosystem services as a tool for management planning – A choice experiment. **Journal of Environmental Management**, v. 271, Out 2020, DOI 10.1016/j.jenvman.2020.111008.

NAGIB, G.; CAMPOS, A. Urban agriculture in the city of São Paulo: New spatial transformations and ongoing challenges to guarantee the production and consumption of healthy food. **Global Food Security**, v. 26, Set. 2020, DOI 10.1016/j.gfs.2020.100378.

NASA E USGS, 2013. **Landsat data continuity mission (LDCM)**. 2013, Disponível em: nasa.gov/pdf/723395main_LDCMpresskit2013-final.pdf

NIETO, A. Tecnologías de la información geográfica en el análisis espacial: Aplicaciones en los sectores público, **empresarial y universitario**, 2016.

NIETO, A.; GARCÍA, C.; FERNÁNDEZ, A. Estudio de casos para detección y análisis de fenómenos naturales con imágenes de seviri, modis y Landsat 5 TM: Emisiones volcánicas, ciclogénesis explosivas y grandes incendios forestales. **Revista internacional de ciência e tecnologia da informação geográfica**, n. 11, p. 375 – 408, 2011.

NOAA, Global Monitoring Laboratory Earth System Research Laboratory, **Trends in atmospheric carbon dioxide**, 2022 Disponível em: gml.noaa.gov/ccgg/trends/global.html

NOGUEIRA, F. **O MDL florestal no Brasil : fundamentos, legado e elementos para ofuturo**. 2018. p.131 – 178 .

OLIVEIRA, J. En la Amazonía brasileña se hará el mayor proyecto de reforestación de la historia. **Anadolu Agency**. 2017.

OLIVIERA F.; PALHARES, R.; YAKOVLEVITCH, P. Análise de estabilidade assintótica e exponencial em redes neurais artificiais sujeitas a retardo no tempo e a incertezas do tipo politópicas. **Revista Controle & Automação**. v. 18, n. 2, Abril/Jun 2008, DOI 10.1590/S0103-17592008000200001.

OLIVIERA-ANDREOLI, E.; PRADO, M.; DA SILVA, A.; FLORIANO, A.; WILMER, C.; MOSCHINI, L.; MELANDA, E.; APARECIDA, E.; DI LOLLO, J.; LORANDI, R. Multi-temporal analysis of land use land cover interference in environmental fragility in a Mesozoic basin, southeastern Brazil. **Groundwater for Sustainable Development**, v. 12, Fev. 2021, DOI10.1016/j.gsd.2020.100536.

OMM, **Organización Meteorológica Mundial**. 2016, Disponível em: public.wmo.int/es/media/comunicados-de-prensa/el-promedio-mundial-de-co2-alcanza-las-400-partes-por-mill%C3%B3n-en-2016.

PADOVANNI, N.; REIS, E.; SOUZA, J.; MATIAS, M.; LOURENÇO, R. Análise Espacial da Temperatura e Albedo de Superfície na Bacia Hidrográfica do rio Una – Ibiúna/São Paulo, a partir de imagens MODIS. **Revista Brasileira de Geografia Física**, v. 11, n. 5, p. 1832-1845, 2018, DOI 10.26848/rbgf.v11.5.p1832-1845.

PAULETO, H.; HOFF, R.; COSTACURTA, L.; PORTELLA, M.; ALBERTI, R. Investigação do ciclo de pomares de macieira pelo NDVI de imagens Sentinel-2 na região dos campos de cima da serra, Rio Grande do Sul, Brasil, **XIX Simpósio Brasileiro de Sensoriamento Remoto**, 2019

PEREIRA, M.; BRITO, G.; DE OLIVEIRA, G.; PEREIRA, R.; BARBOSA, O.; GOMES, P.; TEODORO, P. Growth of native forest species in a mixed stand in the Brazilian Savanna. **Forest Ecology and Management**, v. 462, Abril 2020, DOI 10.1016/j.foreco.2020.118011.

REIS, A., MEIRELES, A. & CUNHA-LIGNON, M., 2019. Natural Regeneration of the Mangrove Vegetation on Abandoned Salt Ponds in Ceará, in the Semi-Arid Region of Northeastern Brazil. **Diversity**, v. 11, n. 27, p. 5 – 12, 2019, DOI 10.3390/d11020027.

REIS, A.; DIAS, M.; ACERBI, F.; DE MELLO, J.; REZENDE, L.; TEIXEIRA, S. Land use and occupation analysis of Permanent Preservation Areas in Lavras County, MG. **Ciência e Agrotecnologia**, v. 36, n. 3, p. 300 – 308, 2012, DOI 10.1590/S1413-70542012000300005.

RENDA, P.; MERGULHAO, C.; STOFFES, J.; REIS, C. Simulação do Efeito Estufa, da intensificação do Efeito Estufa pela presença de CO₂ e do impacto da mudança da cobertura da Terra na temperatura média do meio utilizando o Arduino. **Revista Brasileira de Ensino de Física**, v. 43, 2021, DOI 10.1590/1806-9126-RBEF-2020-0355.

RIBEIRO, M. T.; PIONTEKOWSKI, V.; BUSCARDO, E.; PEDLOWSKI, M.; EYJI, E.; TRONDOLI, E. Effects of settlement designs on deforestation and fragmentation in the Brazilian Amazon. **Land Use Policy**, v. 109, Out. 2021, DOI 10.1016/j.landusepol.2021.105710.

RICHARDSON, A.; HUFKENS, K.; MILLIMAN, T.; FROLKING, S. Intercomparison of phenological transition dates derived from the PhenoCam Dataset V1.0 and MODIS satellite remote sensing. **Scientific reports**, v. 8, p. 1 – 12, 2018, DOI 10.1038/s41598-018-23804-6.

RICHIT, L.; RICHIT, J.; BONATTO, C.; DA SILVA, R.; GRZYBOWSKI, J. Forest recovery prognostics in conservation units of the Atlantic rainforest. **Ecological Informatics**, v. 61, Mar. 2021, DOI 10.1016/j.ecoinf.2020.101199.

RIOS, J.; ALANIS, A.; ARANA, N.; LOPEZ, C. **Neural networks modeling and control**, 2020, DOI 10.1016/C2018-0-01454-1.

RODRIGUES, E.; GUIMARÃES, C.; MARQUES, R.; BACANI, V.; POTT, A. Future scenarios based on a CA-Markov land use and land cover simulation model for a tropical humid basin in the Cerrado/Atlantic forest ecotone of Brazil. **Land Use Policy**. v. 101, 2021, DOI 10.1016/j.landusepol.2020.105141

RODRIGUEZ, M.; GUTIÉRREZ, S. Metodología para la elaboración de mapas de superficie de cultivos priorizados, a través de análisis geoespacial multicriterio, 2017, Disponível em: docplayer.es/92058192-Guia-institucional-metodologia-para-la-elaboracion-de-mapas-de-superficie-de-cultivos-priorizados-a-traves-de-analisis-geoespacial-multicriterio.html.

RONALD EASTMAN, J. **IDRISI Andes: Guide to GIS and Image Processing**. Worcester, MA: IDRISI Production, 2006, Disponível em: https://gis.fns.uniba.sk/vyuka/DTM_ako_sucast_GIS/Kriging/1/Andes_Manual.pdf

RONALD EASTMAN, J. **IDRISI Andes: Tutorial**. Worcester, MA: IDRISI Production, 2006, Disponível em: gis.fns.uniba.sk/vyuka/DTM_ako_sucast_GIS/Kriging/1/Andes_Tutorial.pdf

RONQUIM, C.; FONSECA, M. Avanço das áreas de cana-de-açúcar e alterações em áreas de agropecuária no interior paulista. **EMBRAPA, Empresa Brasileira de Pesquisa Agropecuária**. 2018. Disponível em: infoteca.cnptia.embrapa.br/infoteca/handle/doc/1094694.

RUGGIERO, P.; METZGER, J.; REVERBERI, L.; NICHOLS, E. Payment for ecosystem services programs in the Brazilian Atlantic Forest: Effective but not enough. **Land Use Policy**, v. 82, p. 283 – 291, Mar. 2019, DOI 10.1016/j.landusepol.2018.11.054.

SALES, V.; STROBL, E.; ELLIOTT, R. Cloud cover and its impact on Brazil's deforestation satellite monitoring program: Evidence from the Cerrado biome of the Brazilian Legal Amazon. **Applied Geography**, v. 140, Mar. 2022, DOI 10.1016/j.apgeog.2022.102651.

SANHUEZA, J.; ANTONIENESSEN, M.; **REDD+ en América latina. Estado actual de las estrategias de reducción de emisiones por deforestación y degradación florestal.** 2014. Disponível em <https://repositorio.cepal.org/handle/11362/36810>

SANKARRAO, L.; KUMAR, D.; RATHINSAMY, M. Predicting land-use change: Intercomparison of different hybrid machine learning models. **Environmental Modelling and Software**, v. 145, Nov. 2021, DOI 10.1016/j.envsoft.2021.105207.

SANTANA, R.; DELGADO, R.; SCHIAVETTI, A. The past, present and future of vegetation in the Central Atlantic Forest Corridor, Brazil. **Remote Sensing Applications: Society and Environment**, v. 20, Nov. 2020, DOI 10.1016/j.rsase.2020.100357.

SANTOS, R. **Uso de redes neurais artificiais como alternativa para estimativa volumétrica na floresta estadual do Amapá, Dissertação** (Mestrado em Ciências Florestais), Universidade Federal Rural da Amazônia, Belém, 2018.

SARAIVA, M.; DIAS, M.; CUNHA, D.; PEGORINI, L.; OYAMA, A.; FERREIRA, G. Forest regeneration in the Brazilian Amazon: Public policies and economic conditions. **Journal of Cleaner Production**, v. 269, Out. 2020, DOI 10.1016/j.jclepro.2020.122424.

SATIO, N.; Tratamento contábil dos projetos de mecanismo de desenvolvimento limpo – MDL Brasil: Um estudo exploratório, Dissertação (Ciências contábeis), Centro universitário ÁlvaresPenteado – UNIFECAP, São Paulo, 2006.

SBITKOWSKI, W.; BATISTELLA, D.; CRISIGIOVANI, E. Aprendizado de máquina aplicado em imagens de satélite para classificação de telhados. **Brazilian Journal of Development**. v. 7, n. 7, p.72558-72576, Jul 2021, DOI: 10.34117/bjdv7n7-437.

SEEG, 2020. **Sistema de estimativa de emissões de gases efeito estufa**, 2020, Disponível em: plataforma.seeg.eco.br/total_emission.

SEEG, **Análise das emissões brasileiras de gases efeito estufa e suas implicações para as metas de clima do Brasil 1970 – 2019**, 2019.

SILVA GARCIA, Paulo; SILVA GARCIA, Carlos. Análise de fragmentos florestais por métrica de paisagem na microrregião de redenção no Sudeste do Pará–Brasil. **Revista Brasileira de Sensoriamento Remoto**, v. 3, n. 2, 2022.

SILVA, C.; HEINRICH, V.; FREIRE, A.; BROGGIO, I.; ROSAN, T.; DOBLAS, J.; ANDERSON, L.; ROUSSEAU, G.; SHIMABUKURO, Y.; SILVA, C.; HOUSE, J.; ARAGÃO, L. Benchmark maps of 33 years of secondary forest age for Brazil. **Scientific data**, v. 7, n. 269, 2020, DOI 10.1038/s41597-020-00600-4.

SILVA, C.; MEDEIROS, G.; SARAGOSA, F.; EVANGELISTA, J.; BRITO, R.; LIMA, M.; OLIVEIRA, J.; TEODORO, P.; CARVALHO, R. Remote sensing for updating the boundaries between the Brazilian Cerrado-Amazonia biomes. **Environmental Science & Policy**, v. 101, p. 383 – 392, Nov 2019, DOI

10.1016/j.envsci.2019.04.006.

SILVA, C.; NANNI, M.; CEZAR, E.; CARVALHO, A.; ROMAGNOLI, F.; CAPRISTO, G.; SILVA, A.; BERTI, R. Rede neural artificial (Perceptrón) aliada a índices de vegetação na estimativa de áreas com plantas de soja. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, v. 17, 2015.

SILVA, G.; BERG, E.; CALIJURI, M.; SANTOS, V.; FERREIRA, J.; CARMO, S. Aptitude of areas planned for sugarcane cultivation expansion in the state of São Paulo, Brazil: a study based on climate change effects. **Agriculture, Ecosystems and Environment**, v.305, Jan. 2021, DOI 0.1016/j.agee.2020.107164.

SILVA, R.; SANTOS, A.; BATISTA, J.; FIEDLER, N.; JUVANHOL, R.; BARBOSA, K.; FIGUEIRA, E. Vegetation trends in a protected area of the Brazilian Atlantic Forest. **Ecological Engineering**, v. 162, Abril 2021, DOI 10.1016/j.ecoleng.2021.106180.

SIMONETTI, V.; SILVA, D.; ROSA, A. Proposta metodológica para identificação de riscos associados ao relevo e antropização em áreas marginais aos recursos hídricos. **Scientia plena**, v. 15, n. 2, 2019, DOI 10.14808/sci.plena.2019.025301.

SOARES, G. J. Influência da rochagem no desenvolvimento de sistemas agroflorestais e na captura de dióxido de carbono atmosférico. 2018.

SOARES, S.; BIFANO, I.; TOLEDO, V.; LEÃO, B.; VILLANOVA, P.; BOAVENTURA, E.; BLENDIA, L.; GONÇALVES, L.; MOREIRA, C. Ecological ICMS enables forest restoration in Brazil. **Land Use Policy**, v. 91, Fev 2020, DOI 10.1016/j.landusepol.2019.104381.

SOUZA, J.; SALES, J.; NASCIMENTO, E.; ROVEDA, J.; ROVEDA, S., LOURENÇO, R. Valuation methodology of laminar erosion potential using fuzzy inference systems in a Brazilian savanna. **Environmental monitoring and assessment**, v. 191, n. 624, p. 1 – 15, 2019, DOI 10.1007/s10661-019-7789-1.

STEFANES, M.; OLIVEIRA, F.; LOURIVAL, R.; MELO, I., RENAUD, P.; OCHOA, J. Property size drives differences in forest code compliance in the Brazilian Cerrado. **Land Use Policy**, v. 75, p. 43 – 49, Jun 2018, DOI 10.1016/j.landusepol.2018.03.022.

SUAREZ, A.; JIMÉNEZ, A.; CASTRO, M.; CRUZ, R. Clasificación y mapeo automático de coberturas del suelo en imágenes satelitales utilizando Redes Neuronales Convolucionales. **Colombia Supplement**, v. 21, n. 1, Dez. 2017, DOI 10.22579/20112629.432.

SUCITHRA, B.; GLADSTON, A. Deep Learning Model for Enhanced Crop Identification From Landsat 8 Images. **International Journal of Information Retrieval Research (IJIRR)**, v. 12, n. 1, p. 1-24, 2022, DOI 10.4018/IJIRR.298648.

TCN, **The Nature Conservancy**. 2018, Disponível em: [nature.org/es-us/que-hacemos/nuestras-prioridades/hacer-frente-al-cambio-climatico/captura-de-carbon](https://www.nature.org/es-us/que-hacemos/nuestras-prioridades/hacer-frente-al-cambio-climatico/captura-de-carbon).

TORRES, C.; FERMAM, R.; SBRAGIA, I. Projetos de MDL no Brasil: Oportunidade de mercado para empresas e para novas entidades operacionais designadas. **Ambiente & Sociedade**.v. 19, n. 3, p. 199 – 214, Jul/Set 2016.

UNEP, **Programa de las naciones unidas para el medio ambiente**. 2019 Disponível em: unep.org/es/noticias-y-reportajes/reportajes/la-biodiversidad-de-brasil-recibe-apoyo-en-linea.

UNESCO, **Organização das nações unidas para a educação, a ciência e a cultura**. 2019, Disponível em: pt.unesco.org/fieldoffice/brasil/expertise/biodiversity-brazil

UNFCCC, **Convención marco de las naciones unidas sobre el cambio climático**. 1997, Disponível em: unfccc.int/es/kyoto_protocol

VASQUES, E.; SILVA, A.; ALMEIDA, E.; GOMES, G.; FOLONI, M. Queima De Resíduos Domiciliares A Céu Aberto Em Lageadinho, Ibiúna/SP: Causas, Consequências, Propostas DeMelhoria. **Multidisciplinar Núcleo do Conhecimento**, v. 3, n. 4, p. 22-44, 2021.

VERMA, P.; RAGHUBANSHI, A.; SRIVASTAVA, P.; RAGHUBANSHI, A. Appraisal of kappa-based metrics and disagreement indices of accuracy assessment for parametric and nonparametric techniques used in LULC classification and change detection. **Modeling EarthSystems and Environment**, v. 6, n. 2, p. 1045-1059, 2020.

VIDA, J.; GALLARDO, J. P. C. Potencial del acervo de imágenes Landsat disponible en Google Earth Engine para el estudio del territorio mexicano. **Investigaciones geográficas**, n. 101, 2020, DOI 10.14350/rig.59821.

WANG, Q.; GUAN, Q.; LIN, J.; LUO, H.; TAN, Z.; MA, Y.; 2021. Simulating land use/land cover change in an arid region with the coupling models. **Ecological Indicators**, v. 122, Mar. 2021, DOI 10.1016/j.ecolind.2020.107231.

WANG, R.; MURAYAMA, Y.; MORIMOTO, T.. Scenario simulation studies of urbandevelopment using remote sensing and GIS. **Remote Sensing Applications: Society and Environment**, v. 22, p. 100474, 2021.

WEI, T.; YANG S.; MOORE, J.; SHI, P.; CUI, X.; DUAN, Q.; XU, B.; DAI, Y.; YUAN, W.; WEI, X.; YANG, Z.; WEN, T.; TENG, F.; GAO, Y.; CHOU, J.; YAN, X.; WEI, Z.; GOU, Y.; JIANG, Y.; GAO, X.; WANG, K.; ZHENG, X.; REN, F.; LV, S.; YU, Y.; LIU, B.; LUO, Y.; LI, W.; JI, D.; FENG, J.; WU, Q.; CHENG, H.; HE, J.; FU, C.; YE, D.; XU, G.; DONG, W. Developed and developing world responsibilities for historical climate change and CO₂ mitigation. **Proceedings of the national academy of sciences of united states of america**, v.109, n. 32, p. 12911 – 12915, 2012, DOI 10.1073/pnas.1203282109.

XIANG, H.; WANG, Z.; MAO, D.; ZHANG, J.; ZHAO, D.; ZENG, Y.; WU, B. Surface mining caused multiple ecosystem service losses in China. **Journal of Environmental Management**. v. 290, Jul. 2021, DOI 10.1016/j.jenvman.2021.112618.

ZHANG, C., LU, Y. Study on artificial intelligence: The state of the art and future prospects. **Journal of Industrial Information Integration**. v. 23, Set. 2021, DOI 10.1016/j.jii.2021.100224.