

Gabriela dos Santos Luchetti Vieira

**ESTIMATIVA DO POTENCIAL DE GERAÇÃO DE CRÉDITO DE CARBONO
ATRAVÉS DA REDUÇÃO DE EMISSÕES DE CARBONO POR MEIO DE
DESMATAMENTO EVITADO E DEGRADAÇÃO FLORESTAL UTILIZANDO
REDES NEURAIS ARTIFICIAIS**

Sorocaba
2026

PROGRAMA DE PÓS-GRADUAÇÃO em

*ciências
ambientais*

Gabriela dos Santos Luchetti Vieira

**ESTIMATIVA DO POTENCIAL DE GERAÇÃO DE CRÉDITO DE CARBONO
ATRAVÉS DA REDUÇÃO DE EMISSÕES DE CARBONO POR MEIO DE
DESMATAMENTO EVITADO E DEGRADAÇÃO FLORESTAL UTILIZANDO
REDES NEURAIAS ARTIFICIAIS**

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

Orientador: Prof. Dr. Roberto Wagner
Lourenço

Sorocaba

2026

V658e

Vieira, Gabriela dos Santos Luchetti

Estimativa do potencial de geração de crédito de carbono através da redução de emissões de carbono por meio de desmatamento evitado e degradação florestal utilizando Redes Neurais Artificiais / Gabriela dos Santos Luchetti Vieira. -- Sorocaba, 2026

77 p. : tabs., fotos, mapas

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

Orientador: Roberto Wagner Lourenço

1. Mudanças climáticas. 2. Créditos de carbono. 3. Aprendizagem profunda (Aprendizado do computador). 4. Redes neurais (Computação). 5. Sensoriamento remoto. I. Título.


CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Estimativa do potencial de geração de crédito de carbono através da redução de emissões de carbono por meio de desmatamento evitado e degradação florestal utilizando Redes Neurais Artificiais

AUTORA: GABRIELA DOS SANTOS LUCHETTI VIEIRA

ORIENTADOR: ROBERTO WAGNER LOURENÇO

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. ROBERTO WAGNER LOURENÇO (Participação Virtual)
Departamento de Engenharia Ambiental / UNESP / Câmpus de Sorocaba - ICTS

Documento assinado digitalmente



WILLIAM DANTAS VICHETE
Data: 11/02/2026 10:45:24-0300
Verifique em <https://validar.jb.gov.br>

Prof. Dr. WILLIAM DANTAS VICHETE (Participação Virtual)
Departamento de Engenharia Ambiental / UNESP / Câmpus de Sorocaba - ICTS

Documento assinado digitalmente



VALQUIRIA MIWA HANAI YOSHIDA
Data: 11/02/2026 10:40:01-0300
Verifique em <https://validar.it.gov.br>

Profa. Dra. VALQUIRIA MIWA HANAI YOSHIDA (Participação Virtual)
Departamento de Biomateriais e Nanotecnologia / Universidade de Sorocaba - UNISO

Sorocaba, 11 de fevereiro de 2026.

Com todo o meu amor, respeito e profunda admiração, dedico esta dissertação e todo o meu conhecimento à minha mãe, Cecília, e ao meu pai, Agnaldo.

AGRADECIMENTOS

Agradeço a Deus por me guiar até aqui. Aos meus pais por todo o amor, apoio e confiança incondicionais, que sustentaram minha trajetória. Sou eternamente grata por terem investido, sem hesitação, todos os recursos ao seu alcance para que eu pudesse ter a liberdade de escolher o meu caminho, deixando uma herança imaterial de valor incomparável: meu conhecimento, minha ética e meus valores.

Aos meus irmãos, pelo carinho, incentivos, e o companheirismo na vida, por nunca me deixarem sentir sozinha. Ao meu sobrinho e sobrinha, que trouxeram a luz e alegria de criança para minha vida, e me mostraram uma nova forma de amar e viver. Ao meu companheiro, por me reconfortar nos momentos difíceis, pelo apoio e incentivo constante. A todos meus amigos e familiares muito obrigada.

Ao Prof. Dr. Roberto Wagner Lourenço (China), que, além de orientador de longa data, tornou-se meu mentor e colega de trabalho. Sou muito grata por todos os ensinamentos, conselhos, oportunidades e pela confiança. Meu profundo agradecimento e respeito.

À Prof. Valquíria Miwa Hanai Yoshida e ao Prof. William Dantas Vichete que compuseram a banca examinadora, por compartilhar seu conhecimento, pelas leituras atentas, contribuições valiosas e pelas sugestões que enriqueceram este trabalho.

Ao Laboratório de Geoprocessamento e Modelagem Matemática Ambiental (LABGEMM), do qual tive o prazer de fazer parte juntamente com todos os colegas, agradeço pela convivência diária, pelas trocas de conhecimento e pelo apoio técnico.

À Universidade Estadual Paulista (UNESP), bem como a todos os docentes, pelo compromisso com a formação gratuita e de qualidade no ensino, na pesquisa e na extensão. Em especial, ao Prof. Dr. Fábio Navarro Manfredini, com quem tive a oportunidade de acompanhar o estágio de docência, pelos valiosos conselhos, conversas e discussões acerca da legislação ambiental no Brasil. A todos os funcionários terceirizados e técnicos administrativos, pelo suporte institucional, pela infraestrutura disponibilizada, bem como pela manutenção e segurança realizadas.

A todos que fizeram parte da minha trajetória e que me apoiaram até aqui, muito obrigada!

“Nós ainda estamos aqui pelas florestas brasileiras, pelos direitos das mulheres e pela democracia.”

(Fernanda Torres, discurso no Ato pela Democracia, Rio de Janeiro, 2025)

RESUMO

Desde o início do século XXI o mundo testemunha diversos eventos decorrentes da crise climática, o histórico das iniciativas globais para lidar com questões ambientais e mudanças climáticas inicia na Conferência das Nações Unidas em 1992 e se estende até a atualidade. O Protocolo de Kyoto e o Acordo de Paris destacam a importância da cooperação internacional para enfrentar esses desafios, como, a crise climática e serviços ecossistêmicos, enfatizando a urgência de adotar medidas de mitigação a nível global. A precificação do carbono impulsiona a transição para uma economia verde global, incentivando o crescimento da indústria de baixo carbono. Assim surge o Mercado Voluntário de Carbono (MVC), uma ferramenta que promove a padronização e eficiência nas transações de créditos de carbono. Neste sentido, esse trabalho tem como objetivo pesquisar o potencial de geração de créditos de carbono através da redução de emissões de carbono por meio de desmatamento evitado e degradação florestal (REDD+), utilizando técnicas de sensoriamento remoto e aprendizado de máquinas. Utilizou-se a metodologia do Programa de Padrão de Carbono Verificado (VCS), para basear os critérios de elegibilidade de áreas de REDD+ em regiões densamente habitadas. Para obtenção dos resultados foi empregado métodos de sensoriamento remoto para análise da cobertura vegetal e mapeamento do uso da terra, bem como métodos de aprendizado de máquina (machine learning) através da implementação de Redes Neurais Artificiais (RNA), do tipo Perceptron Multicamadas (MLP) para classificação e predição de áreas elegíveis. Os resultados apresentados, mostram que o modelo foi eficiente para simulação do uso da terra futuro, com uma acurácia global de 58,46% e índice Kappa de 0,90 na comparação entre o cenário simulado e o cenário real de 2023, o que caracteriza concordância excelente. O modelo identificou cerca de 101,96 ha de áreas sob pressão de desmatamento. A análise das variáveis explicativas indicou que a proximidade aos centros urbanos e à malha viária exerceu a maior influência sobre a dinâmica de desmatamento, evidenciando que a expansão urbana e a infraestrutura viária constituem os principais fatores associados à conversão florestal observada, fornecendo subsídios quantitativos relevantes para a avaliação do potencial de mitigação de emissões associadas ao desmatamento evitado e à degradação florestal (REDD+). Por fim, conclui-se que os resultados podem ser utilizados como base para o desenvolvimento sustentável futuro, e que a metodologia proposta possa contribuir para o estudo de novas áreas que possam contribuir no futuro como potenciais a geração de créditos de carbono, oferecendo a gestão pública e empresarial um mecanismo de análise voltada ao mercado voluntário de carbono, em áreas densamente habitadas e consolidadas.

Palavras-chave: REDD+, Mudanças climáticas, MultiLayer-Perceptron, sensoriamento remoto, Deep learning.

ABSTRACT

Since the beginning of the 21st century, the world has witnessed several events resulting from the climate crisis. The history of global initiatives to address environmental issues and climate change began with the United Nations Conference in 1992 and continues to the present day. The Kyoto Protocol and the Paris Agreement highlight the importance of international cooperation in addressing challenges such as the climate crisis and the preservation of ecosystem services, emphasizing the urgency of adopting mitigation measures at a global scale. Carbon pricing drives the transition toward a global green economy by encouraging the growth of the low-carbon industry. In this context, the Voluntary Carbon Market (VCM) emerges as a tool that promotes standardization and efficiency in carbon credit transactions. Accordingly, this study aims to investigate the potential for carbon credit generation through the reduction of carbon emissions resulting from avoided deforestation and forest degradation (REDD+), using remote sensing and machine learning techniques. The methodology of the Verified Carbon Standard (VCS) Program is applied to define eligibility criteria for REDD+ areas in densely populated regions. To obtain the results, remote sensing methods were employed for vegetation cover analysis and land use mapping, as well as machine learning approaches through the implementation of Artificial Neural Networks (ANN), specifically Multilayer Perceptron (MLP) models, for the classification and prediction of eligible areas. The results demonstrate that the model was efficient in simulating future land use, with an overall accuracy of 58.46% and presenting a Kappa index of 0.90 when comparing the simulated scenario with the observed scenario for 2023, which indicates excellent agreement. The model identified approximately 101.96 ha of areas under deforestation pressure. The analysis of explanatory variables indicated that proximity to urban centers and the road network exerted the greatest influence on deforestation dynamics, evidencing that urban expansion and transportation infrastructure are the main factors associated with the observed forest conversion. These findings provide relevant quantitative support for assessing the potential for emission mitigation associated with avoided deforestation and forest degradation (REDD+). Finally, it is concluded that the results can be used as a basis for future sustainable development and that the proposed methodology may contribute to the investigation of new areas with potential for carbon credit generation. Moreover, it offers public authorities and private enterprises an analytical framework tailored to the voluntary carbon market, particularly in densely populated and consolidated regions.

Keywords: REDD+, Climate change, MultiLayer-Perceptron, remote sensing, Deep learning.

LISTA DE FIGURAS

Figura 1 – Mapa de localização da RMS.....	27
Figura 2 – Fluxograma geral da metodologia proposta.....	29
Figura 3 – Escala relativa para comparação pareada da importância entre critérios.....	34
Figura 4 – Mapa de uso da terra da RMS de 2003; 2013 e 2023.	45
Figura 5 – Variáveis utilizadas no modelo de mudança e previsão do uso da terra.	47
Figura 6 – Mapa real e previsão do uso da terra de 2023	49
Figura 7 – Mapa de previsão do uso da terra em 2053.....	51
Figura 8 – Distribuição percentual da área por classe de uso da terra em todos os anos analisados	52
Figura 9 – Mapa de ganhos, perdas e persistências da classe Floresta no período de 2023 a 2053 na RMS.....	55
Figura 10 – Mapa de mudanças de uso da terra (2023-2053) considerando as classes Floresta e Agropecuária.....	56
Figura 11 – Tendência espacial de mudança do uso da terra (2023-2053)	58
Figura 12 – Mapa das Áreas sob pressão de desmatamento e protegidas	59

LISTA DE QUADROS

Quadro 1 – Relação de banco de dados e informações utilizadas.	28
Quadro 2 – Reclassificação das classes de uso da terra do MapBiomass	30
Quadro 3 – Classificação do relevo conforme declividade em %	32
Quadro 4 – Valores de RI por número de critérios.....	35
Quadro 5 – Relação de áreas protegidas dentro do território da RMS	38

LISTA DE TABELAS

Tabela 1 – Classificação da taxa de perda de solo da RUSLE	33
Tabela 2 – Valor do fator de erodibilidade do solo referente a cada tipo de solo.	36
Tabela 3 – Parâmetros definidos para a arquitetura da RNA MLP.	41
Tabela 4 – Classificação do índice Kappa.	42
Tabela 5 – Parâmetros utilizados no modelo para o cálculo do estoque de carbono	43
Tabela 6 – Matriz de confusão com número de pixels do cenário do uso da terra real e previsto de 2023	50
Tabela 7 – Área referente as classes do uso da terra para todos os anos apresentados	52
Tabela 8 – Acurácia individual e ordem de influência das variáveis utilizadas no modelo	53
Tabela 9 – Resultados da estimativa das emissões antropogênicas atribuídas a áreas elegíveis a projeto REDD+.....	62

LISTA DE ABREVIATURAS E SIGLAS

AB	<i>Above-ground Biomass</i> (traduzido para a língua portuguesa como biomassa acima do solo)
AFOLU	<i>Agriculture, Forestry, and Other Land Use</i> (traduzido para a língua portuguesa como Agricultura, Silvicultura e Outros Usos da Terra)
AHP	<i>Analytic Hierarchy Process</i> (traduzido para a língua portuguesa como Análise Hierárquica de Processos)
APA	Área de Proteção Ambiental
BB	<i>Below-ground Biomass</i> (traduzido para a língua portuguesa como biomassa abaixo do solo)
COP	Conferência das Partes
ENREDD+	Estratégia Nacional para REDD+
ESG	<i>Environmental, Social and Governance</i> (traduzido para a língua portuguesa como Ambiental, Social e Governança)
FAO	<i>Food and Agriculture Organization</i> (traduzido para a língua portuguesa como Organização das Nações Unidas de Alimentação e a Agricultura)
Flona	Floresta Nacional de Ipanema
GEE	Gases de Efeito Estufa
ICMBio	Instituto Chico Mendes de Conservação da Biodiversidade
IBGE	Instituto Brasileiro de Geografia e Estatística
IDEA-SP	Infraestrutura de Dados Espaciais Ambientais do Estado de São Paulo
IPCC	<i>Intergovernmental Panel on Climate Change</i> (traduzido para a língua portuguesa como Painel Intergovernamental sobre Mudança do Clima)
IPA	Instituto de Pesquisas Ambientais
LCM	<i>Land Change Modeler</i> (traduzido para a língua portuguesa Modelador de Mudanças de Uso da Terra)
MDE	Modelo Digital de Elevação
MDL	Mecanismo de Desenvolvimento Limpo
MEV	Modelo de Economia Verde
MMP	Macrometrópole Paulista
MRC	Mercado Regulado de Carbono
MRV	<i>Monitoring, Reporting and Verification</i> (traduzido para a língua portuguesa Monitoramento, Relato e Verificação)
MVC	Mercado Voluntário de Carbono

NIR	<i>Near Infrared band</i> (traduzido para a língua portuguesa como banda do infravermelho próximo)
NDVI	<i>Normalized Difference Vegetation Index</i> (traduzido para a língua portuguesa como Índice de Vegetação por Diferença Normalizada)
ODS	Objetivos de Desenvolvimento Sustentável
ONU	Organização das Nações Unidas
PDI	Processamento Digital de Imagens
PIB	Produto Interno Bruto
PNAP	Plano Estratégico Nacional de Áreas Protegidas
PNMA	Política Nacional do Meio Ambiente
R	<i>Red band</i> (traduzido para a língua portuguesa como banda do vermelho)
REDD+	Redução das Emissões por Desmatamento e Degradação florestal evitado
RNA	Redes Neurais Artificiais
RUSLE	<i>Revised Universal Soil Loss Equation</i> (traduzido para a língua portuguesa como Equação Universal de Perda de Solo Revisada)
RNA SOM	Rede Neural Artificial Mapas auto-organizáveis
RNA-MLP	Rede Neural Artificial Perceptron Multicamadas
RMS	Região Metropolitana de Sorocaba
RPPN	Reservas Particulares do Patrimônio Natural
SAVI	<i>Soil Adjusted Vegetation Index</i> (traduzido para a língua portuguesa como Índice de Vegetação Ajustado ao Solo)
SEADE	Sistema Estadual de Análise de Dados
SBCE	Sistema Brasileiro de Comércio de Emissões de Gases de Efeito Estufa
SIG	Sistema de Informação Geográfica
SNUC	Sistema Nacional de Unidades de Conservação da Natureza
SOC	<i>Soil Organic Carbon</i> (traduzido para a língua portuguesa como Carbono Orgânico no Solo)
TIN	<i>Triangular Irregular Network</i> (traduzido para a língua portuguesa como Rede Triangular Irregular)
UC	Unidades de Conservação
UNFCCC	Nações Unidas sobre Mudança do Clima
USGS	<i>United States Geological Survey</i> (traduzido para a língua portuguesa como Serviço Geológico dos Estados Unidos)
VCS	<i>Verified Carbon Standard</i> (traduzido para a língua portuguesa como Padrão de Carbono Verificado)

Sumário

1	INTRODUÇÃO	16
2	REVISÃO DE LITERATURA.....	17
2.1	MUDANÇAS CLIMÁTICAS.....	17
2.2	CRÉDITOS E MERCADO DE CARBONO.....	19
2.3	PROJETOS DE REDUÇÃO DE EMISSÕES POR DESMATAMENTO E DEGRADAÇÃO FLORESTAL (REDD+)	22
2.4	APRENDIZADO DE MÁQUINAS (MACHINE LEARNING)	24
3	OBJETIVO	26
3.1	OBJETIVO GERAL	26
3.2	OBJETIVOS ESPECÍFICOS.....	26
4	METODOLOGIA.....	27
4.1	ÁREA DE ESTUDO	27
4.2	SISTEMATIZAÇÃO DOS DADOS E FLUXOGRAMA METODOLÓGICO.....	28
4.3	MAPEAMENTO DO USO DA TERRA	29
4.4	PROCESSAMENTO ESPACIAL VARIÁVEIS AMBIENTAIS	31
4.4.1	<i>Modelo Digital de Elevação</i>	<i>31</i>
4.4.2	<i>Mapas das Declividades</i>	<i>31</i>
4.4.3	<i>Mapas de proximidade</i>	<i>32</i>
4.4.4	<i>Equação universal de perda de solo revisada</i>	<i>33</i>
4.5	ÁREAS PROTEGIDAS	37
4.6	REDD+	40
4.6.1	<i>Previsão das mudanças do uso da terra</i>	<i>41</i>
4.6.2	<i>Áreas sob pressão de desmatamento</i>	<i>42</i>
4.6.3	<i>Estimativa de estoque de carbono</i>	<i>42</i>
5	RESULTADOS E DISCUSSÃO	45
5.1	MAPA DE USO DA TERRA.....	45
5.2	MAPEAMENTO DAS VARIÁVEIS DO MODELO PREDITIVO	46
5.3	MODELAGEM REDD+.....	48
5.3.1	<i>Mapeamento preditivo do uso da terra.....</i>	<i>48</i>
5.3.2	<i>Análises de mudança do uso da terra.....</i>	<i>54</i>
5.3.3	<i>Áreas sob pressão de desmatamento</i>	<i>58</i>
5.3.4	<i>Estoque de carbono estimado.....</i>	<i>60</i>
6	CONCLUSÕES.....	65
	REFERÊNCIAS	67

1 INTRODUÇÃO

As mudanças climáticas globais e as atividades humanas relacionadas ao uso da terra estão afetando a cobertura vegetal nativa, a biodiversidade e os serviços ecossistêmicos. Esses impactos adversos têm consequências significativas para a segurança alimentar, na saúde pública, resiliência das cidades e na conservação dos ecossistemas. Neste contexto, as emissões atmosféricas assumem relevância e importância significativas desde o início do século XXI (Song et al., 2018; Pecl et al., 2017).

Em 2015, em um apelo global, a Organização das Nações Unidas (ONU) estabeleceu os Objetivos de Desenvolvimento Sustentável (ODS) para 2030. Dentre os 17 objetivos tem-se os *ODS* 13, “Ação contra a mudança global do clima”, o qual possui urgência na adoção de medidas contra as mudanças climáticas e seus impactos adversos (UN, 2015).

As florestas desempenham papel central na dinâmica do carbono atmosférico, atuando simultaneamente como potenciais fontes de emissão e como importantes sumidouros. Ontl et al. (2020) e Tooichi (2018) destacam que a degradação florestal pode liberar grandes quantidades de CO₂ para a atmosfera, enquanto ecossistemas íntegros são capazes de sequestrar esse carbono e armazená-lo sob a forma de biomassa, contribuindo para a regulação climática global.

Na última década a produção científica a respeito de créditos de carbono cresceu, onde o Brasil está entre os quatro países que lideram a produção de conhecimento científico sobre o tema, detendo 65,79% de todas as publicações. Os resultados mostraram que tanto as organizações públicas quanto as privadas estão reunindo forças para conduzir mais estudos, onde as universidades se mostraram mais dedicadas a isto. Mesmo assim, ainda é possível observar espaços e lacunas, bem como uma carência na cooperação para o enfrentamento dos desafios associados a mudanças climáticas (Dias et al., 2023).

Dada a importância do tema, bem como as diversas questões ainda a serem estudadas e pesquisadas, foi realizada uma pesquisa visando contribuir com a Redução de Emissões por Desmatamento e Degradação Florestal (REDD+) identificando áreas com potencial de geração de créditos de carbono, contribuindo com a conservação, manejo sustentável e aumento dos estoques de carbono, que possam servir de ferramentas para incentivar financeiramente entidade públicas e privadas a protegerem suas florestas, com recompensas baseadas em resultados verificáveis de conservação de carbono e ganhos socioambientais, além de contribuir significativa com a mitigação dos impactos das mudanças climáticas, em com ênfase em regiões densamente povoadas.

2 REVISÃO DE LITERATURA

2.1 Mudanças climáticas

As questões ambientais começaram a ser reconhecidas globalmente na década de 80, quando a ONU publicou oficialmente o conceito de desenvolvimento sustentável por meio do Relatório “nosso futuro comum” pela Comissão de Brundtland, onde o conceito foi definido como o desenvolvimento que concilia as necessidades atuais sem comprometer a capacidade das futuras gerações de atender suas próprias necessidades (UN, 1987).

A Segunda Conferência das Nações Unidas sobre Desenvolvimento e Meio Ambiente, conhecida como ECO-Rio 92 ou Rio 92. Esta conferência reuniu 178 nações e teve como resultado a institucionalização da Convenção-Quadro das Nações Unidas para as Mudanças Climáticas (UNFCCC, na sigla em inglês para *United Nations Framework Convention for Climate Change*), reconhecendo que os avanços nas soluções só seriam possíveis por meio do compromisso e esforços conjuntos entre os países (Okereke; Coventry, 2016; Souza; Corazza, 2017).

A pauta ambiental sobre mudanças climáticas ganhou visibilidade pela primeira vez no âmbito global em 1997 por meio do Protocolo de Kyoto, em que reúne os países industrializados e estabelece a redução das emissões de Gases de Efeito Estufa (GEE) por meio de metas acordadas individualmente, onde as políticas e medidas de mitigação sejam reportadas periodicamente (UNFCCC, 1997). A construção de acordos, como este, implica na elaboração de princípios, normas e procedimentos para a tomada de decisões, os quais refletem nas expectativas dos países envolvidos na negociação. Estas construções são moldadas por tensões políticas, geopolíticas e fatores vinculados as tradições culturais e ideológicas (Haggard; Simmons, 1987).

O Protocolo de Kyoto adota inicialmente uma abordagem que responsabiliza os países historicamente responsáveis pelas emissões acumuladas, impondo-lhes um fardo maior com base na justificativa de garantir uma distribuição justa das responsabilidades de mitigação. Dessa forma, reconhecendo que estes países têm uma parcela significativa na responsabilidade pelos altos níveis de emissões de GEE na atmosfera. De forma geral, embora as mudanças climáticas sejam de natureza global, a contribuição dos países não é uniforme, isto por que o acordo é fundamento a partir do princípio de "responsabilidades comuns, porém diferenciadas, e capacidades respectivas" (Souza; Corazza, 2017; UNFCCC, 1997).

Em 2015, a importância da adoção de medidas e políticas para o combate às mudanças climáticas foi reforçado na Conferência das Partes (COP) 21 pelo Acordo de Paris, com o objetivo de fortalecer a gravidade dos impactos adversos e reforçar a capacidade de adaptação dos países de lidar com as consequências das mudanças climáticas. Este novo acordo adota uma abordagem bottom-up para as negociações, ou seja, ocorre uma análise mais específica para o cenário mais amplo (Afionis, 2019; Okereke; Coventry, 2016; Rubial, 2016).

Com consequências já determinadas, como as que afetam a floresta amazônica, por exemplo, o combate as mudanças climáticas, vai ao encontro de proteger as florestas, que desempenham serviço de relevante importância à regulação do clima global. Quando se trata da floresta amazônica, região abriga a maior proporção de terras indígenas do Brasil, sua importância se relativa mais ainda com às mudanças climáticas, e é essencial para o bem-estar e a economia e para a proteção dessas comunidades.

Assim, buscar medidas que busquem a proteção e a preservação de locais frágeis, se torna urgente, e adotar medidas para mitigar os impactos climáticos e estabelecer áreas protegidas como refúgios climáticos para manter a biodiversidade são ações de responsabilidade tanto do setor público como privado (Arruda et al., 2024).

Quando a questão é emissões de gases de efeito estufa (GEE), pode-se citar dois importantes mecanismos para lidar com as questões de métodos de mitigação de emissões de GEE: o Mecanismo de Desenvolvimento Limpo (MDL) e o Modelo de Economia Verde (MEV). O MDL permite que os países atinjam suas metas de redução de emissões ao implementar projetos que reduzem a emissão dos GEE, gerando créditos de carbono. Por outro lado, o MEV visa alcançar o desenvolvimento econômico enquanto protege o meio ambiente e promove o bem-estar humano, por meio de políticas e governança eficazes para mitigar, entre outras coisas as emissões de GEE (Silva et al., 2021).

No Brasil, o MDL impulsiona um modelo de desenvolvimento em colaboração com países industrializados, permitindo que países em desenvolvimento obtenham créditos de carbono a partir da implementação de projetos que reduzem as emissões, este produto é conhecido como créditos de carbono, o qual pode ser comercializado gerando ganhos econômicos para estes países. Em contrapartida, os créditos de carbono auxiliam os países industrializados a cumprirem parte das metas acordadas no Protocolo de Kyoto e atualizadas no Acordo de Paris (Patel et al., 2020).

2.2 Créditos e Mercado de Carbono

No âmbito do mercado de carbono, um crédito corresponde à remoção ou à não emissão de uma tonelada de CO₂ equivalente, formalizada por meio de um certificado digital, conforme definido pela Endeavor (2022). Esse mercado opera com dois tipos principais de ativos: permissões de emissão negociadas dentro de sistemas regulados com limites máximos de emissão (*cap and trade*) e reduções de emissões provenientes de projetos, entre eles os de reflorestamento e conservação (IPAM, 2024). Ambos os mecanismos contribuem para a precificação do carbono, ferramenta essencial para que países avancem no cumprimento de suas metas de mitigação de gases de efeito estufa, consideradas fundamentais para limitar o aquecimento global, como reforçado pelo Painel Intergovernamental sobre Mudanças Climáticas (IPCC) (2023).

Crédito de carbono é um mecanismo ambiental que representa a quantificação da redução, remoção ou emissão evitada de GEE. Esse sistema está diretamente relacionado aos sumidouros ou sequestro de carbono realizado por ecossistemas naturais, como florestas, que armazenam carbono em sua biomassa e solo, contribuindo para a regulação do clima e mitigação das mudanças climáticas. A preservação e o manejo sustentável dessas áreas, são fundamentais para manter e aumentar esses estoques de carbono, gerando benefícios ambientais e econômicos expressos em valores monetários que refletem o custo de uma tonelada de carbono equivalente (Schinato, 2019).

A viabilidade econômica de projetos de créditos de carbono tem sido demonstrada em estudos de caso. Rodriguez (2015), ao analisar iniciativas de reflorestamento ecológico em Áreas de Preservação Permanente no município de São Luiz do Paraitinga (SP), estimou que a venda de créditos de carbono poderia gerar uma receita acumulada de US\$ 2.725.255,2 ao longo de 20 anos. De maneira semelhante, (Barbosa et al., 2021) verificou que o reflorestamento de toda a área elegível analisada poderia resultar, em um ciclo de seis anos e sem considerar taxas de juros, em montantes entre US\$ 62.701.663,8 e US\$ 156.754.159,5.

Os valores obtidos a partir de projetos de créditos de carbono, representam potencial relevante na captura adicional de carbono e para a geração de renda, alcançando patamares significativo no Produto Interno Bruto (PIB) anual dos municípios (Barbosa et al., 2021).

Nesse contexto, Castro (2017) argumenta que, devido às extensas áreas elegíveis existentes em todo território brasileiro e às condições ambientais e clima favoráveis, os projetos florestais no âmbito do MDL configuram uma das modalidades de flexibilização mais promissoras para o Brasil. Além de prestarem serviços ecossistêmicos essenciais, tais

projetos possibilitam a geração de renda por meio da comercialização de créditos de carbono e a valorização da cultura local.

A precificação do carbono é um instrumento econômico fundamental para estimular a transição para uma economia de baixo carbono, ao atribuir um custo às emissões de GEE. Essa abordagem influencia decisões de produção, consumo e investimento, promovendo setores mais sustentáveis.

Existem duas modalidades destas transações à nível global. O Mercado Regulado de Carbono (MRC), estabelecido por lei e limitado a regiões e setores específicos, movidos por metas obrigatórias de redução das emissões acordadas entre as nações. E por outro lado, o Mercado Voluntário de Carbono (MVC), permite que organizações privadas, públicas e indivíduos possam reduzir sua pegada de carbono de forma voluntária, sem limitações de fronteiras ou setores.

No Brasil, o mercado regulado de carbono avançou de maneira gradual, impulsionado tanto pelos compromissos internacionais de mitigação quanto pela necessidade de criar instrumentos econômicos capazes de orientar a transição para uma economia de baixo carbono. Somente em 2024 foi homologada a Lei nº 15.042/2024, que institui o Sistema Brasileiro de Comércio de Emissões de Gases de Efeito Estufa (SBCE). Essa legislação se aplica a todas as atividades, fontes e instalações situadas no território nacional que emitam ou tenham potencial de emitir GEE, sob responsabilidade de pessoas físicas ou jurídicas (BRASIL, 2024).

A norma estrutura instrumentos, define obrigações e cria mecanismos de monitoramento, reporte e verificação voltados à redução das emissões nacionais, baseando-se em limites máximos (caps) e no comércio de permissões negociáveis (trades). Na prática, setores enquadrados terão a obrigação de monitorar suas emissões e comprovar, anualmente, a posse de permissões equivalentes ao volume efetivamente emitido. O limite total de emissões é definido pelo governo federal, sendo reduzido de forma progressiva para induzir estratégias contínuas de mitigação (BRASIL, 2024).

A legislação também estabelece importantes critérios de Monitoramento, Relato e Verificação (MRV) aplicáveis às entidades responsáveis pelas metodologias de certificação de créditos de carbono. Isso significa que certificadoras e programas de certificação devem seguir padrões rigorosos de MRV, garantindo transparência, rastreabilidade e integridade ambiental na geração dos créditos. Dessa forma, o SBCE se alinha às principais tendências internacionais do mercado de carbono, reforçando a credibilidade dos ativos e a harmonização das práticas nacionais com os mecanismos globalmente adotados.

Antes do sancionamento da referida Lei, o mercado voluntário já era praticado por meio das plataformas de negociação especializadas no MVC, permitindo que os participantes identifiquem produtos confiáveis, operados com preços determinados, promovendo a padronização e uniformidade das transações. Isso não apenas torna o mercado mais transparente, mas também mais líquido, facilitando a avaliação e negociação de créditos de carbono de maneira eficiente (Valente; Vargas; Kingston, 2023).

Neste sentido, uma das referências no mercado de carbono global é a VERRA, uma organização sem fins lucrativos que opera padrões nos mercados ambientais e sociais. Atualmente a organização conta com o gerenciamento do principal programa de mercado voluntários de carbono do mundo, o Programa de Padrão de Carbono Verificado (VCS, na sigla em inglês de *Program Verified Carbon Standard*).

A organização também está à frente de outros programas que estabelecem padrões mundiais para ações climáticas e desenvolvimento sustentável, desempenhando um papel importante para os povos indígenas e comunidades locais. Todos eles envolvem uma série de requisitos que contam com parâmetros para a redução do desmatamento, melhoria das práticas agrícolas, redução dos resíduos plásticos, verificação de resultados de forma confiável e transparente, e promover a colaboração entre governos, empresas e sociedade civil a fim de institucionalizar as normas e metodologias (VERRA, 2022).

A equipe do Programa VCS da VERRA estabelece diversas metodologias robustas, especialmente no setor de Agricultura, Silvicultura e Outros Usos da Terra (AFOLU, sigla em inglês de Agriculture, Forestry, and Other Land Use), as quais permitem o registro confiável de créditos de carbono, promovendo as reduções e remoções de emissões proveniente de uma grande variedade de atividades (VERRA, 2022)

De acordo com o Relatório Anual da VERRA (2022), em novembro de 2022 foi emitido o bilionésimo crédito de carbono sob o Programa VCS, ou seja, 1 bilhão de toneladas de CO₂ retirados na atmosfera. O equivalente a mais de 220 milhões de veículos movidos a gasolina dirigindo por um ano.

Até o final de 2022 foram 3.134 projetos implementados pelo Programa VCS, onde apenas 13% estão localizados na América Latina, mais de 1,04 bilhão de créditos de carbono foram emitidos e mais de 550 milhões de créditos de carbono foram retirados. As estatísticas mostram o importante papel que o mercado voluntário de carbono desempenha na redução das emissões globais e no combate às mudanças climáticas.

2.3 Projetos de Redução de Emissões por Desmatamento e Degradação Florestal (REDD+)

O REDD é uma iniciativa das Nações Unidas desenvolvida para criar valor monetário para o carbono armazenado nas florestas, incentivando, assim, a redução do desmatamento e da degradação florestal. O programa evoluiu para o REDD+, que abrange ainda atividades voltadas ao manejo florestal sustentável englobando a comunidade em prol da conservação.

De forma geral, os projetos REDD+ constituem uma iniciativa global para combater as mudanças climáticas por meio da valorização do carbono florestal que representa emissões evitadas (Avtar et al., 2022).

A Estratégia Nacional para REDD+ (ENREDD+), formalizada no Brasil em 2015, representa um marco nas ações voltadas à redução das emissões de GEE provenientes do desmatamento e da degradação florestal. O objetivo geral é contribuir para a mitigação das mudanças climáticas por meio da eliminação do desmatamento ilegal, da conservação e recuperação dos ecossistemas florestais e do desenvolvimento de uma economia florestal sustentável de baixo carbono, gerando benefícios econômicos, sociais e ambientais (MMA, 2016).

A ENREDD+ é usada como referência para avaliar o alinhamento das iniciativas de REDD+ com os objetivos nacionais, os projetos de fundo público (como os do Fundo Amazônia) demonstram um alinhamento mais forte com a ENREDD+, enquanto os projetos de mercado voluntário (fundo privado) falham em se alinhar aos objetivos da estratégia devido à baixa diversidade de proponentes (Maciel 2020). Não houve uma atualização das metas e planos do ENREDD+, mas continua formalmente ativa como a estratégia nacional (MMA, 2025).

O desafio citado por Maciel (2020) ainda se mostra real, onde a governança existe no papel, mas sua eficácia prática depende criticamente de vontade política, financiamento consistente e priorização constante na agenda governamental.

A empresa VERRA possui uma metodologia específica VM0006, a qual define os procedimentos para a contabilização de carbono em projetos REDD+ implementados em escala de paisagem. A linha de base adotada segue os critérios definidos a partir de uma abordagem de paisagem, alinhada a tendências de desmatamento em escala mais ampla. Esse critério influencia a estimativa de créditos de carbono mais conservadoras das reduções de emissões por desmatamento evitado. O propósito central dos projetos baseados nessa metodologia é a redução de emissões oriundas do desmatamento e da degradação florestal.

Embora abrangente, apresenta diversas limitações e condições específicas que devem ser observadas (Terra Carbon; Silvestrum Climate Associates, 2023).

O cálculo baseia-se na diferença entre as mudanças monitoradas nos estoques de carbono das áreas de projeto e as mudanças projetadas no cenário de linha de base, podendo também incorporando emissões provenientes de vazamentos e outras fontes. As taxas de referência de desmatamento e degradação são determinadas a partir de análises de sensoriamento remoto, utilizando períodos históricos de referência.

Entre as principais estratégias voltadas à redução do desmatamento e da degradação florestal não planejados, destacam-se o fortalecimento da governança fundiária e florestal, por meio de acordos legais que asseguram a posse da terra e os direitos de carbono, reduzindo conflitos de autoridade, exploração ilegal e conversão irregular de florestas (Terra Carbon; Silvestrum Climate Associates, 2023).

De forma geral, a metodologia busca integrar conservação florestal, manejo sustentável e engajamento comunitário, fornecendo as bases para que projetos REDD+ alcancem reduções e remoções de emissões mensuráveis, robustas e socialmente inclusivas.

Os projetos REDD+ enfrentam desafios que envolvem a distribuição justa de benefícios, a viabilidade financeira e a consolidação dos mecanismos de mercado de carbono. A efetividade dos pagamentos depende da forma como são distribuídos, sendo insuficientes, em muitos casos, para garantir a atratividade econômica, o que exige a combinação com subsídios (Ren et al., 2020). Além disso, limitações tecnológicas e regulatórias restringem o funcionamento do mercado de carbono, que ainda se encontra em estágio inicial e carece de sistemas robustos de avaliação, contemplando monitoramento, relato e verificação (Lin et al., 2024).

A estimativa precisa da biomassa florestal do solo é fundamental para o gerenciamento eficaz das florestas e para a mitigação das mudanças climáticas. Isso é particularmente importante para apoiar os processos de REDD+, que representam a redução das emissões do desmatamento e da degradação florestal, a promoção do manejo florestal sustentável e a conservação e o aumento dos estoques de carbono florestal (Chen et al., 2018).

A implementação do REDD+ no Brasil enfrenta o desafio de integrar a abordagem nacional centralizada com diversas iniciativas subnacionais, garantindo um monitoramento robusto e transparente e eficaz (Gomes et al., 2016).

2.4 Aprendizado de máquinas (machine learning)

As Redes Neurais Artificiais (RNA) integram o campo de *Deep Learning*, uma subárea do *Machine Learning* caracterizada pela utilização de modelos com múltiplas camadas hierárquicas capazes de extrair padrões complexos a partir de grandes volumes de dados. O *Deep Learning* baseia-se na ideia de que estruturas computacionais profundas conseguem aprender representações progressivamente mais abstratas dos dados, permitindo através da identificação de padrões, automatizar tarefas como classificação, previsão e simulação de dados (Caudill, 1987; Hecht-Nielsen, 1987; Hinton et al., 2006).

Inspiradas no funcionamento das redes neurais biológicas, as RNAs são modelos compostos por unidades interconectadas (nodos ou “neurônios artificiais”) que simulam o processamento e a transmissão de sinais observado no sistema nervoso. Seu objetivo é reconhecer padrões, realizar inferências e aprender diretamente a partir dos dados de entrada, ajustando iterativamente seus parâmetros internos para melhorar o desempenho preditivo. Esse tipo de arquitetura tem se mostrado especialmente eficiente em problemas não lineares e de alta complexidade (Cheshmberah et al., 2020; Hinton et al., 2006).

Existem três tipos de RNA que se destacam no processamento digital de imagens, devido a eficiência na classificação de imagens de satélite (Toledo, 2023). A RNA Fuzzy ARTMAP que é baseada na teoria de ressonância adaptativa; a RNA SOM (*Self-Organizing Map*), capaz de mapear padrões complexos e otimizar a dimensionalidade; e a RNA Perceptron Multicamadas (*Multilayer Perceptron*). Combinadas ao Sensoriamento Remoto, as arquiteturas têm sido aplicadas no desenvolvimento de metodologias automatizadas que se apresentam como alternativas mais ágeis, precisas e economicamente viáveis aos métodos tradicionais (Tang et al., 2022; Toledo, 2023).

As redes profundas e densamente conectadas, especialmente os modelos com múltiplas camadas ocultas, apresentam elevada capacidade de representação, permitindo modelar relações complexas contidas nos dados. Embora o processo de treinamento e inferência seja mais desafiador, esses modelos demonstram desempenho superior em tarefas de reconhecimento de padrões e modelagem generativa (Hinton et al., 2006b; Bengio et al., 2013; Goodfellow et al., 2016; Mohd Noor; Ige, 2025).

A MLP é um tipo de rede neural artificial amplamente utilizada em tarefas de aprendizado supervisionado, como classificação e regressão (Cheshmberah et al., 2020). Sua estrutura é composta por múltiplas camadas de neurônios: camada de entrada, uma ou mais camadas ocultas e camada de saída. Cada neurônio está conectado aos neurônios da camada

seguinte, permitindo que a rede aprenda representações complexas por meio do ajuste dos pesos das conexões durante o treinamento (Lorini et al., 2007).

Os neurônios artificiais são utilizados na aplicação das funções de ativação não lineares, permitindo modelar relações complexas e não lineares entre os dados. O treinamento da MLP é realizado por meio do algoritmo de retropropagação, que ajusta os pesos das conexões para minimizar o erro entre as previsões e os valores reais. Entre suas vantagens estão a capacidade de generalização e a flexibilidade para lidar com diferentes tipos de problemas, incluindo estudos ambientais (Hecht-Nielsen, 1987; Hinton; Osindero; Teh, 2006a; Lorini et al., 2007).

Destacando-se por sua alta capacidade de modelar relações não lineares entre variáveis, a MLP torna-se útil em aplicações de previsão, classificação e simulação. Em estudos ambientais, demonstra excelente desempenho na modelagem de dados complexos, incluindo estimativas de sequestro de carbono (Tang et al., 2022), apesar da necessidade de grandes volumes de dados para o treinamento dos dados.

Desta forma, a MLP se mostra uma ferramenta poderosa e versátil no campo da inteligência artificial e do aprendizado de máquina aplicado a modelagem matemática de dados ambientais (Cheshmberah et al., 2020).

3 OBJETIVO

3.1 Objetivo Geral

Desenvolver um estudo baseado em conceitos de projetos REDD+ visando identificar áreas elegíveis para o potencial de geração de créditos de carbono através da integração de ferramentas de geoprocessamento e aprendizado de máquinas.

3.2 Objetivos específicos

Para que seja possível alcançar o objetivo geral, foram desenvolvidas as seguintes etapas de pesquisa:


- a. Realização de uma revisão de literatura estruturada, planejada e crítica, que permitiu mapear o estado da arte de um tema;
- b. Levantamento, sistematização e organização de bancos de dados brutos secundários que foram estruturadas e analisadas de acordo com o rigor metodológico e os objetivos da pesquisa;
- c. Realização do processamento digital de imagens (PDI) para mapear o uso e cobertura da terra, bem como a dinâmica espacial e temporal utilizando uma série de etapas técnicas, desde a aquisição de dados até a análise estatística de mudanças ao longo do tempo;
- d. Desenvolvimento de uma RNA MLP para simulação de cenários futuros de uso e cobertura da terra integrando técnicas de geoprocessamento em Sistemas de Informações Geográficas (SIG) com aprendizado de máquina para modelar as transições ao longo do período estudado;
- e. Identificação de áreas elegíveis para projetos de desmatamento evitado (REDD+) a partir do mapeamento de áreas de alto risco de desmatamento futuro em áreas florestais conservadas, com vistas a geração de créditos adicionais (que não aconteceriam sem a intervenção);
- f. Estimar o estoque de carbono das áreas mapeadas para projetos de REDD+ através da quantificação da biomassa florestal para definir uma linha de base (C-Baseline) e monitorar a redução de emissões ao longo do tempo (C-REDD) de acordo com as diretrizes do IPCC.

4 METODOLOGIA

4.1 Área de estudo

O presente estudo foi realizado na Região Metropolitana de Sorocaba (RMS) (Figura 1), localizada na região centro-oeste do Estado de São Paulo englobando 27 municípios.

Figura 1 – Mapa de localização da RMS



Fonte: Autoria própria.

A RMS possui influência econômica e revela importância no abastecimento de recursos provenientes de atividade industriais e agrícolas, principalmente para Macrometrópole Paulista (MMP) (EMPLASA, 2014). As atividades econômicas da RMS se apresentam de forma diversificada, predominando nos setores metalúrgico, têxtil e do agrícola. A infraestrutura na região é abundante, incluindo fornecimento de água, gás natural e energia elétrica. É possível observar uma crescente oferta de mão de obra qualificada, devido à presença de importantes instituições de ensino e centros de formação profissional, como Unesp, Ufscar, Uniso, Facens, Fatecs e Etecs. A localização estratégica com fácil acesso a São Paulo e Campinas por rodovias bem estruturadas atraiu grandes empresas de diversos segmentos e seus fornecedores (EMPLASA, 2017).

Segundo a classificação climática Köppen-Geiger, a região possui um clima Cwb, caracterizado por ser de clima temperado de montanha, com verão chuvoso e inverno seco. Já a vegetação primária é composta por uma floresta ombrófila densa, em uma zona de transição entre Mata Atlântica e Cerrado (Oliveira et al., 2016; Salles et al., 2008).

De acordo com o Cadastro Nacional de Unidades de Conservação do Ministério do Meio Ambiente, a RMS abriga diversas Unidades de Conservação (UC), definido pela Lei n.º 9.985/2000 que também institui o Sistema Nacional de Unidades de Conservação da Natureza (SNUC). Mantendo, ainda, 157.252,2 hectares de seu território, o equivalente a 13,54% do total, protegido por unidades de conservação pertencentes à União, Estado ou Municípios. Tendo como as mais relevantes a área de Proteção Ambiental da Represa de Itupararanga; os Parques Estaduais Carlos Botelho e Jurupará; a Flona e o Parque Municipal Corredores da Biodiversidade (EMPLASA, 2014, 2017).

4.2 Sistematização dos dados e fluxograma metodológico

A cartografia de base foi elaborada a partir da integração de dados digitais provenientes do catálogo da Infraestrutura de Dados Espaciais Ambientais do Estado de São Paulo (IDEA-SP) (DataGEO, 2022), bem como imagens de satélite de domínio público disponibilizadas pela United States Geological Survey (USGS) e outros bancos de dados.

Utilizou-se SIG para manipulação e modelagem dos dados. As atividades de processamento, análise espacial e elaboração dos produtos cartográficos foram realizadas com o apoio de diferentes ferramentas computacionais, entre as quais se destacam os softwares ArcGIS 10.6, QGIS 3.36.2, Google Earth Pro e TerrSet. O Quadro 1 apresenta uma síntese dos bancos de dados e informações utilizados no desenvolvimento deste trabalho.


Quadro 1 – Relação de banco de dados e informações utilizadas.

Descrição	Fonte
Uso da terra	Landsat 5 e 8 (USGS)
Declividade e MDE	Pontos contados e curvas de nível (DATAGEO)
Centros Urbanos	Recortes Metropolitanos e Aglomerações Urbanas (IBGE)
Malha viária	Malha municipal (IBGE)
Hidrografia	Base Hidrográfica (ANA)
Unidades de conservação	Unidades de conservação (DATAGEO e ICMBio)
Rede elétrica de transmissão	Agência Nacional de Energia Elétrica (Aneel)

Fonte: Autoria própria.

Após a sistematização dos dados e o pré-tratamento das variáveis, procedeu-se com a construção, validação e execução do modelo, conforme o fluxograma apresentado na Figura 2.

Figura 2 – Fluxograma geral da metodologia proposta



Fonte: Autoria própria

4.3 Mapeamento do Uso da terra

O Mapa de uso da terra foi obtido a partir do projeto MapBiomias - Coleção 9, em que foi utilizada as imagens de satélite do Landsat 5, 8 e 9 para a construção de mosaicos para todo o território nacional. A partir dos mosaicos de imagens, foi produzido mapas de classes de cobertura e uso da terra, usando o classificador automático chamado "random forest classifier (Classificador de Floresta Aleatória)". O Random Forest é um algoritmo de aprendizado de máquina supervisionado que cria múltiplas árvores de decisão durante o treinamento e combina suas previsões por votação para definir a classe final (Souza et al., 2020). Além disso, são aplicados filtros para melhorar a consistência dos dados, reclassificando pixels com base na vizinhança (MapBiomias Project, 2023a).

Utiliza uma técnica de amostragem aleatória de dados (*bagging*) por seleção aleatória de recursos para treinar cada árvore de forma independente, garantindo baixa correlação entre elas. Para cada novo dado, cada árvore da "floresta" dá um voto de classificação, e a

classe com a maioria dos votos é escolhida, e a classe de uso da terra com a maioria dos votos é escolhida, garantindo maior precisão, minimizando a falta de dados, a lida com os outliers e alta dimensionalidade.

Com base no reconhecimento geográfico da área de estudo, o qual se apresenta com grande diversidade de categorias de uso da terra, e dado o objetivo de buscar áreas elegíveis para o REDD+, as classes de uso da terra foram agrupadas da seguinte maneira (Quadro 2).

Quadro 2 – Reclassificação das classes de uso da terra do MapBiomias

id	Classe	id MapBiomias	Classe MapBiomias
1	Floresta	3	Formação florestal
		4	Formação Savana
		5	Mangue
		9	Plantação florestal
		12	Formação Herbácea
		29	Afloramento rochoso
2	Agropecuária	15	Pastagem
		20	Cana-de-açúcar
		21	Mosaico de agricultura e pastagem
		39	Grãos de soja
		41	Mosaico de culturas
		46	Café
		47	Citrus
		48	Outras culturas perenes
3	Urbana	24	Infraestrutura urbana
		25	Outra área não vegetada
		30	Mineração
4	Corpos hídricos	33	Rio, lago e oceano
		31	Aquicultura

Fonte: Autoria própria.

Para a categorização das classes de uso da terra foi utilizada a ferramenta “*Reclassify Table (Spatial Analyst)*” do ArcGIS/ArcMap (Esri, 2023).

4.4 Processamento Espacial Variáveis Ambientais

4.4.1 Modelo Digital de Elevação

O Modelo Digital de Elevação (MDE) é uma representação numérica da superfície terrestre baseada na variação altimétrica do terreno. Neste trabalho, sua construção foi fundamental para a obtenção de variáveis topográficas, como a altimetria e declividade, que subsidiam a análise espacial da área de estudo.

O MDE foi gerado a partir do modelo matemático do tipo Rede Triangular Irregular (*Triangular Irregular Network* – TIN), método que permite a modelagem da superfície com alta precisão. Essa abordagem se baseia na triangulação de Delaunay, utilizando curvas de nível e pontos cotados como insumos primários para a interpolação da superfície.

Por meio dessa triangulação, a geometria do relevo é representada por um conjunto de faces triangulares conectadas, refletindo as características da topografia e da rede de drenagem da região analisada. Essa técnica é amplamente reconhecida por sua capacidade de capturar as complexidades do terreno (Aggidis; Benzon, 2013; Câmara et al., 1996; Li; Zhu; Gold, 2004).

4.4.2 Mapas das Declividades

O mapa de declividade foi gerado com base no MDE, o qual reflete as variações altimétricas da superfície terrestre. A declividade, é calculada como a razão entre o desnível do terreno e a distância horizontal correspondente, pode ser expressa tanto em graus quanto em porcentagem, sendo esta última a convenção adotada (Valeriano; Albuquerque, 2010). Neste trabalho optou-se pela representação em classes percentuais, conforme a padronização estabelecida pela Embrapa (2018), por se tratar da forma mais convencional e amplamente utilizada em análises ambientais. O Quadro 3 apresenta as classes de declividades utilizadas.

Quadro 3 – Classificação do relevo conforme declividade em %

Classe	Declividade (%)	Descrição
Plano	0 - 3	Superfície de topografia esbatida ou horizontal, onde os desnivelamentos são muito pequenos
Suave ondulado	3 - 8	Superfície de topografia pouco movimentada, constituída por conjunto de colinas e/ou outeiros, apresentando declives suaves
Ondulado	8 - 20	Superfície de topografia pouco movimentada, constituída por conjunto de colinas e/ou outeiros, apresentando declives moderados
Forte ondulado	20 - 45	Superfície de topografia movimentada, formada por outeiros e/ou morros e raramente colinas, com declives fortes
Montanhoso	45 - 75	Superfície de topografia vigorosa, com predomínio de formas acidentadas, usualmente constituídas por morros, montanhas, maciços montanhosos e alinhamentos montanhosos, apresentando desnivelamentos relativamente grandes e declives fortes e muito fortes
Escarpado	>75	Áreas com predomínio de formas abruptas, compreendendo superfícies muito íngremes e escarpamentos.

Fonte: Adaptado EMBRAPA (2018).

4.4.3 Mapas de proximidade

A construção dos mapas de proximidade baseou-se na aplicação da distância euclidiana, um conceito amplamente utilizado em análises espaciais e ecológicas como medida de dissimilaridade entre elementos (Gauch, 1982). Essa medida é empregada para quantificar a menor distância linear entre cada entidade de um mapa e os elementos geográficos de interesse — centros urbanos, hidrografia, malha viária e UCs. O resultado é uma representação espacial contínua que permite identificar zonas de influência e acessibilidade em torno dessas feições, fundamentais para a análise da pressão antrópica sobre os remanescentes florestais.

No contexto deste estudo, os elementos geográficos de interesse selecionados para a análise de proximidade corresponderam àqueles que influenciam diretamente os processos de acesso, ocupação e pressão sobre os remanescentes florestais da região (Khoi e Murayama, 2010). Do ponto de vista antrópico, foi utilizada a malha viária e os centros urbanos, buscando verificar qual o impacto que as distâncias das áreas com maior densidade demográfica e as vias de acesso podem causar na conservação dos fragmentos florestais.

No que se refere aos aspectos bióticos, foi utilizada a hidrografia, com base na premissa de que o acesso à água é elemento essencial tanto para o desenvolvimento urbano e rural quanto para a conservação ecológica. A presença de corpos hídricos pode exercer papel duplo: como fator de atração para ocupações humanas e, simultaneamente, como suporte à manutenção de ecossistemas florestais.

Para elaboração dos mapas de proximidade foi utilizada a função *Proximity (distance raster)* do software QGIS 3.36.2 (QGIS Development Team, 2026).

4.4.4 Equação universal de perda de solo revisada

A Equação Universal de Perda de Solo Revisada (RUSLE) é considerado um produto que relaciona quatro fatores: erosividade da chuva, erodibilidade do solo, topográfico, e de cobertura e manejo do solo (Alves et al., 2022; Lazzari et al., 2015). Sendo utilizada para estimar a perda média anual de solo, o qual seguirá a classificação adotada *pela Food and Agriculture Organization (FAO) (1981)*, conforme Tabela 1.

Tabela 1 – Classificação da taxa de perda de solo da RUSLE

Classe	Taxa de perda de solo (tha-1ano-1)
Baixa	< 10
Moderada	10 -50
Alta	50 - 200
Muito Alta	> 200

Fonte: Adaptado FAO (1981).

A RUSLE é calculada a partir da Equação 1, utilizando pesos definidos utilizando a Análise Hierárquica de Processos (AHP). Considerada uma abordagem amplamente reconhecida e utilizada em processos de tomada de decisão complexos, que envolvem múltiplos critérios e alternativas. (Arya e Singh, 2021; Falowo e Ojo, 2023; Nyimbili et al., 2018; Tudes e Yigiter, 2010; Yilmaz, 2022).

$$A = R \times K \times LS \times C \times P \quad (1)$$

Sendo:

A: perda de solo por unidade de área no tempo;

R: fator de erosividade da chuva;

K: fator de erodibilidade do solo;

LS: fator topográfico que relaciona a declividade e comprimento de rampa;


C: fator de manejo e uso do solo;

P: fator de práticas de ações de conservação do solo.

A combinação dos aspectos subjetivos e objetivos desta abordagem, possibilita que os tomadores de decisão avaliem a consistência dos critérios principais e subcritérios de acordo com sua relevância, considerando diferentes parâmetros (Taromideh et al., 2022).

Descrita por Saaty (1977), essa metodologia consiste na comparação e atribuição relativa da importância entre dois elementos, gerando uma matriz de comparação pareada. Para a atribuição de importância a cada variável, adotou-se a escala absoluta de Saaty (1977), que abrange a intensidade de 1 a 9, conforme descrito na Figura 3. Esse procedimento permite o cálculo dos pesos para cada critério e subcritérios, refletindo sua importância relativa.

Figura 3 – Escala relativa para comparação pareada da importância entre critérios



Fonte: Saaty (1977).

Ainda, a consistência das atribuições de pesos é avaliada por meio do cálculo do Índice de Consistência (CI) (Equação 2), a Matriz Aleatória (RI) (Quadro 4) e a Razão de Consistência (CR) (Equação 3). A atribuição dos pesos é considerada aceitável quando a CR for inferior a 0,1 (Saaty, 1977).

$$CI = \frac{\lambda_{max} - n}{n - 1} \quad (2)$$

Sendo:

CI: índice de consistência;

λ_{max} : autovalor máximo;

n: número de critérios.

Quadro 4 – Valores de RI por número de critérios

n	1	2	3	4	5	6	7	8	9	10	11
RI	0	0	0,58	0,9	1,12	1,24	1,32	1,41	1,45	1,49	1,51

Fonte: Saaty (1977).

$$CR = \frac{CI}{RI} \quad (3)$$

Sendo:

CR: Razão de consistência;

CI: Índice de consistência;

RI: Matriz Random-Like.

Utilizou-se o software Excel para construção da matriz de comparação pareada, enquanto a execução da AHP foi efetuada por meio da ferramenta “Map Algebra” e “Weighted Overlay” do software ArcGIS.

Os fatores utilizados para o cálculo da RUSLE foram adotados de acordo com a seguinte metodologia:

O fator de erosividade da chuva (R) é fundamental para o uso sustentável do solo, este expressa o potencial da chuva em desencadear erosões no solo. O cálculo do fator R é complexo e lento, sendo obtido a partir de dados pluviométricos (Bertoni e Lombardi, 2017). Por isso, optou-se por utilizar o mapa de Erosividade da Chuva do Estado de São Paulo produzido pelo Instituto de Pesquisas Ambientais – IPA (2022) e disponibilizado pelo DataGEO, onde os índices de erosividade foram calculados a partir de dados pluviométricos e espacializados por meio de interpolações pelo processo de krigagem ordinária em procedimento padrão da análise geoestatística (DataGEO, 2022).

O fator de erodibilidade do solo (K), por meio das características específicas dos tipos de solo, expressa a suscetibilidade natural à agentes erosivos. Este fator assume um papel importante do planejamento e uso do solo (Arraes et al., 2010; Silva et al., 2010).

Visto isso utilizou-se o Mapa Pedológico do Estado de São Paulo com a escala de 1:25000, produzido por Rossi (2017) e disponibilizado pelo DataGEO, para definir o solo da área de estudo. Para a definição do fator K utilizou-se a média dos valores definidos pelos autores Lombardi Neto e Bertoni (1997) e Fiorio (2019), conforme Tabela 2.

Tabela 2 – Valor do fato de erodibilidade do solo referente a cada tipo de solo.

Tipo de solo	Fator K
Cambissolo Háplicos (CX)	0,0504
Latossolo Vermelho (LV)	0,0170
Argissolo Vermelho-Amarelo (PVA)	0,0655

Fonte: Adaptado de (Fiorio, 2019; Lombardi Neto; Bertoni, 1975)

O fator topográfico (LS) foi utilizado a função “*r.watershed*” do QGIS 3.36.2. Essa função é baseada na modelagem do fluxo dos corpos hídricos, e por isso, utilizou-se o MDE como referência de entrada (GRASS, 2022). Considerando a declividade (S) e o comprimento de encostas (L) os principais influenciadores na perda de solo, tem-se que o fator LS reflete o impacto da topografia no desencadeamento de processos erosivos (Panditharathne et al., 2019).

O fator de uso e manejo (CP), foi estimado por meio do Soil Adjusted Vegetation Index (SAVI), considerando que o solo não exerce tanta influência na vegetação quando comparado aos outros índices vegetativos (Huete, 1988).

O SAVI, foi obtido a partir das mesmas imagens do satélite Landsat adquiridas para o Uso da terra. Esse índice é utilizado para corrigir o *Normalized Difference Vegetation Index* (NDVI) para a influência do brilho do solo onde a cobertura vegetal é baixa. O SAVI é calculado a partir da Equação 4, sendo a razão entre os valores das bandas espectrais do vermelho (R) e infravermelho próximo (NIR), neste trabalho foi adotado um fator de correção de brilho do solo (L) igual a 0,5 para acomodar a maioria dos tipos de cobertura da terra, ou seja, com áreas de cobertura vegetal em nível intermediário (USGS, 2024; Dermachi et al., 2011).

$$SAVI = \frac{(1+L)(\rho_{iv}-\rho_v)}{(\rho_{iv}+\rho_v+L)} \quad (4)$$

Sendo:

SAVI: *Soil Adjusted Vegetation Index*;

ρ_{iv} : banda do infravermelho próximo;

ρ_v : banda do vermelho;

L: fator de ajuste do índice SAVI, sendo 0,5

Por meio da Equação 5, foi realizado a normalização linear do SAVI para aproximação do Fator CP, resultando no SAVI_{esc}, que varie de 0 a 1. Isto ocorre, pois, a escala dos valores não segue a mesma proporcionalidade, tendo em vista que o SAVI varia de -1 a 1.

$$SAVI_{esc} = 0,3335 \times SAVI + 0,4998 \quad (5)$$

Sendo:

SAVI_{esc}: refere-se ao valor normalizado do SAVI;

SAVI: refere-se ao valor do SAVI.

Para obtenção do fator CP é necessário combinar os fatores C e P em um único plano de informação (Bertoni e Lombardi, 2017; Stein et al., 1987; Bahadur, 2009), por isso, após o escalonamento criou-se um PI com atribuição de valores entre 0 (urbana, descoberta e água) e 1 (vegetação e agrícola) para cada classe. Com o auxílio da ferramenta “Map Álgebra” do ArcGIS 10.6 foi realizada a multiplicação entre o SAVI_{esc} e o PI, obtendo-se o produto do fator CP.

4.5 Áreas protegidas

A determinação das áreas protegidas, neste estudo, partiu da premissa de considerar os territórios que possuem algum grau de proteção ambiental por meio de instrumentos legais, seja integral ou parcial. Essas áreas englobam diversas categorias, como UC, Áreas de Proteção Ambiental (APA), Reservas Particulares do Patrimônio Natural (RPPN), estações ecológicas, parques naturais, terras indígenas e quilombolas. As áreas protegidas podem ser instituídas nas esferas federal, estadual ou municipal, desde que cumpram os critérios técnicos e legais para sua criação e reconhecimento oficial.

As áreas protegidas desempenham um papel crucial não apenas na RMS, mas em todo o território nacional, contribuindo para a contenção da expansão urbana, a preservação dos remanescentes florestais e a proteção da Mata Atlântica. Sua presença é estratégica para a manutenção da integridade ecológica regional, especialmente diante da intensa pressão antrópica sobre os ecossistemas nativos (Junior et al., 2020).

Para este estudo, foi realizada a compilação de todas as áreas protegidas reconhecidas oficialmente na RMS, com base em legislações vigentes nos âmbitos federal, estadual e municipal. As informações foram organizadas conforme apresentadas no Quadro 5.

Quadro 5 – Relação de áreas protegidas dentro do território da RMS

(Continua)

Tipo de área protegida	Descrição	Domínio	Legislação	Área (ha)
Unidade de conservação de proteção integral	Parque Estadual Carlos Botelho	Estadual	Decreto Estadual nº 19.499, de 10 de setembro de 1982	8200,85
	Parque Estadual do Jurupará	Estadual	Decreto Estadual n.º 35.703/35.704, de 22 de setembro de 1992	26221,18
	Parque Natural Municipal Corredores de Biodiversidade	Municipal	Decreto Municipal nº 19.424, de 17 de agosto de 2011	68,71
	Parque Natural Municipal de Brigadeiro Tobias	Municipal	Decreto Municipal nº 21.618, de 7 de janeiro de 2015	11,86
	Estação Ecológica Mário Covas	Municipal	Lei Municipal nº 11.234, de 10 de dezembro de 2015.	52,67
	Estação Ecológica Municipal do Pirajibu	Municipal	Decreto Municipal nº 22.023, de 28 de outubro de 2015	46,79
Unidade de conservação de uso sustentável	Floresta Natural Federal de Ipanema	Federal	Decreto Federal nº 530, de 20 de maio de 1992	5389,99
	Reserva Particular do Patrimônio Natural - Cruz preta	Privado	Portaria nº 29 de 22/02/2012	157,31
	Reserva Particular do Patrimônio Natural - Trápaga	Privado	Resolução nº Resolução SMA Nº 10 de 31/01/2018	70,28
	APA Cabreúva	Estadual	Lei Estadual nº 12.289, 2 de março de 2015	7796,31
	APA Itupararanga	Estadual	Lei Estadual nº 11.579, de 2 de dezembro de 2003	82297,98

Fonte: Autoria própria.

Quadro 5 – Relação de áreas protegidas dentro do território da RMS
(Conclusão)

Tipo de área protegida	Descrição	Domínio	Legislação	Área (ha)
Unidade de conservação de uso sustentável	APA Serra do Mar	Estadual	Decreto Estadual nº 22.717, de 21 de setembro de 1984	56364,54
	APA Tietê	Estadual	Decreto Estadual nº 20.959, de 8 de junho de 1983	45899,44
	APA Pedregulho	Municipal	Lei ordinária nº 1610 de 13/12/2013	7355,36
	APA do Engenho d'água	Municipal	Lei nº 4.170, de 25 de outubro de 2004	3507,46
	APA Avecuia	Municipal	Lei nº 5.064, de 12 de junho de 2012	13238,19
Outras áreas protegidas	Reserva Indígena Federal Tekoa Gwyrá Pepo - Guaraní Mbya	Federal	Parecer Técnico n. 01/CGID/2016	330,30
	Estação Experimental Estadual de Itupapetiniga	Estadual	Decreto Estadual nº 34.082/1958	6787,97
	Estação Ecológica Municipal Bráulio Guedes da Silva	Municipal	Lei ordinária nº 11471 de 06/01/2017	9,38

Fonte: Autoria própria.

A partir dessas bases, foi estruturado uma camada de representação contendo todas as áreas protegidas, o qual foi utilizado para compor o cálculo da estimativa de carbono (CO₂) evitado no modelo de REDD+, considerando a proteção legal como fator limitante ao avanço do desmatamento.

4.6 REDD+

Para que um projeto do tipo do REDD+ seja elegível a geração de créditos de carbono, deve-se respeitar os critérios estabelecidos pela metodologia VM 0006 (VERRA VCS), a qual é dividida em critérios para a elegibilidade de terras e de projetos (Terra Carbon, 2017). Neste trabalho, não foi abordado a análise dos critérios e pré-requisitos para a implementação do projeto, uma vez que essa etapa envolve aspectos altamente específicos e dependentes do contexto local.

A definição do perfil das atividades a serem desenvolvidas nas áreas elegíveis para a concretização de um projeto REDD+ varia conforme o escopo do projeto, as fontes de financiamento, as partes interessadas envolvidas, a participação de comunidades locais e outras condicionantes socioeconômicas e institucionais. Assim, tais elementos extrapolam os objetivos e a abordagem metodológica adotados neste estudo, que se concentram na identificação e na análise espacial das áreas com potencial para projetos REDD+.

Visto isso, o principal critério para elegibilidade de terras é que na ausência da implementação do projeto REDD+, haveria o desmatamento e degradação. Também deve qualificar-se como “floresta internacionalmente aceita” pela UNFCCC ou FAO, as que possuem no mínimo 10 anos antes da data de início do projeto e ter no mínimo 0,5 hectares. Além disso, os fatores de desmatamento e degradação florestal devem se enquadrar em tipos conversão florestal específicas (Terra Carbon, 2017). Neste trabalho foi utilizado como referência a conversão de terras florestais em terras agrícolas, assentamento ou em infraestrutura urbana.

Para o desenvolvimento desta etapa foi utilizado a ferramenta “REDD project” do *software* TerrSet (ClarkLabs, 2025), que tem como objetivo calcular a redução estimada das emissões de GEE proveniente da implementação de um projeto RED (Eastman, 2024).

Foram utilizados como série histórica os anos de 2003, 2013 e 2023 para previsão das mudanças do uso da terra para 2053, bem como para identificar áreas suscetíveis ao desmatamento com o potencial de implementação de projetos REDD+ e calcular a redução líquida estimada de CO₂. A seleção do ano de 2023 fundamentou-se por representar o período mais recente com disponibilidade de imagens compatíveis com a metodologia adotada. O período de 2003 e 2013 foi definido como o de imagens históricas de referência para determinar o padrão de variabilidade com intervalos regulares de dez anos. O ano de 2023 foi escolhido para representar a consistência temporal e comparabilidade entre os períodos analisados anteriores. O ano de 2053 foi estabelecido como horizonte de projeção

após 2023 por corresponder a um intervalo de 30 ano, alinhando-se à duração média considerada para projetos REDD+.

4.6.1 Previsão das mudanças do uso da terra

Realizou-se a identificação das áreas com base na previsibilidade de conversão florestal, por meio da análise da mudança no uso da terra. Para isso, foi utilizado um método de aprendizado de máquina (machine learning) através da implementação da RNA do tipo MLP para prever as áreas sob pressão de desmatamento até o ano de 2053, segundo Khoi e Murayama (2010) e Sankarrao et al. (2021).

Seguindo os critérios estabelecidos, foi empregada a ferramenta Modelador de Mudança da Terra (*Land Change Modeler* - LCM), disponível no *software* TerrSet (ClarkLabs, 2025), para analisar as mudanças no uso da terra no período de 2023 a 2053.

Inicialmente, o módulo LCM foi executado utilizando 2003 como ano inicial e 2013 como ano final, com o objetivo de gerar uma simulação do uso da terra para o ano de 2023, permitindo posteriormente a validação do desempenho do modelo.

Para a construção do modelo, foram utilizadas as nove variáveis previamente descritas, e a arquitetura da RNA foi definida de acordo com os seguintes parâmetros (Tabela 3)

Tabela 3 – Parâmetros definidos para a arquitetura da RNA MLP.

Parâmetro	Valor
Neurônios da camada de entrada	9
Neurônios da camada oculta	10
Neurônios da camada de saída	4
Amostras solicitadas por classe	2500
Sigmoide constante	1
Fator de impulso	0.7

Fonte: Autoria própria.

Após o treinamento da rede, a previsão obtida para 2023 foi então validada por meio da comparação com o mapa real de uso da terra, elaborado para 2023. Essa etapa foi realizada por meio da matriz de confusão, cujo cálculo de acurácia é apresentado na forma do Índice de Kappa, um coeficiente de concordância que verifica a qualidade do mapeamento (Cohen,

1960). O índice Kappa varia de 0 a 1 e segue a classificação definida por (Landis; Koch, 1977), descrita na Tabela 4.

Tabela 4 – Classificação do índice Kappa.

Concordância	Índice Kappa
Péssima	< 0
Ruim	$0,0 - 0,19$
Razoável	$0,2 - 0,39$
Boa	$0,4 - 0,59$
Muito Boa	$0,6 - 0,79$
Excelente	$0,8 - 1,00$

Fonte: Landis e Koch (1977).

Tendo validado o modelo, procedeu-se à simulação do uso da terra para o ano de 2053 considerando o padrão descrito na rede neural do intervalo de 2003 a 2023, seguindo exatamente a mesma arquitetura e variáveis.

4.6.2 Áreas sob pressão de desmatamento

Para a identificação das áreas suscetíveis ao desmatamento evitado foi realizada a sobreposição do mapa real de uso da terra do ano de 2023 sobre o mapa simulado para 2053, utilizando as ferramentas de álgebra de mapas. Foram consideradas elegíveis áreas com extensão mínima de 0.5 hectares (critério previamente estabelecido pelas diretrizes da VERRA), ou seja, territórios que caso não haja a implementação de medidas de conservação sofreram desmatamento. As áreas identificadas foram consideradas aptas a integrar, em etapas subsequentes do projeto, os procedimentos de quantificação de emissões evitadas e de avaliação da possibilidade de geração de créditos de carbono, condicionados ao atendimento integral dos critérios técnicos e legais definidos pelos padrões metodológicos.

4.6.3 Estimativa de estoque de carbono

Com as áreas suscetíveis ao desmatamento evitado previamente identificadas, foi utilizado a ferramenta “REDD Project” do LCM para estimar o estoque de CO presente nas formações florestais. Essa estimativa tem como base a premissa de que a vegetação, ao ser mantida em pé, continua a estocar carbono em sua biomassa acima e abaixo do solo.

Dessa maneira, calculou-se as emissões de carbono associadas à perda de biomassa florestal (estoques de carbono). Considerando a efetividade líquida do projeto, levando em conta a taxa de sucesso da iniciativa REDD+ e o fator de perda, isto é, o percentual de desmatamento que pode ocorrer em outras áreas como consequência indireta da proteção da área principal (Eastman, 2024)

O modelo considera parâmetros, como Carbono Orgânico no Solo (SOC), Biomassa acima (AB) e abaixo (BB) do solo, que resultam em uma quantificação potencial de CO que seria emitido caso ocorresse a conversão do uso da terra. Para estes parâmetros foram utilizados valores de referência encontrados na literatura para a área de estudo considerando bioma, clima e classe de uso da terra (Tabela 5).

Tabela 5 – Parâmetros utilizados no modelo para o cálculo do estoque de carbono

	AB (tC/ha)	BB (%)	SOC (tC/ha)
Classe			
Floresta	200	25	70
Agropecuária	50	15	40
Urbana	0	0	0
Água	0	0	0

Fonte: (IPCC, 2006, 2019; MapBiomass Project, 2023; Sacramento, 2020)

Ao final, por meio da Equação 6, obteve-se a redução líquida das emissões de carbono ao longo da vida útil do projeto estimada para os próximos 30 anos (Eastman, 2024).

$$C_{REDD} = C_{Baseline} - C_{Actual} - C_{Leakage} \quad (6)$$

Sendo:

C_{REDD} : Redução líquida de GEE antropogênicos

$C_{Baseline}$: emissões esperadas sem o projeto;

C_{Actual} : emissões reais durante o projeto;

$C_{Leakage}$: emissões deslocadas para fora da área.

No contexto de projetos REDD+, o parâmetro $C_{Baseline}$ representa as emissões de GEE que ocorreriam na área do projeto na ausência da atividade REDD+, ou seja, em um cenário onde as áreas permaneçam do jeito que estão sem a implementação de nenhum

projeto REDD+. Esse valor é estimado a partir da projeção do desmatamento ou da degradação florestal futura, baseada em transições históricas de uso e cobertura da terra simuladas pelo LCM, combinadas com fatores de emissão e estoques de carbono associados às classes mapeadas. Já o *C-Actual* corresponde às emissões efetivamente observadas dentro da área do projeto durante o período de monitoramento, considerando o uso e a cobertura da terra reais após a implementação das ações REDD+.

O parâmetro *C-Leakage* refere-se às emissões indiretas de carbono que ocorrem fora da área do projeto como consequência das atividades REDD+, como o deslocamento do desmatamento para áreas adjacentes ou regiões não incluídas no projeto. Essas emissões devem ser quantificadas para evitar a superestimação dos benefícios climáticos. Por fim, o C-REDD, sendo o principal resultado pois representa a redução líquida das emissões antropogênicas atribuível ao projeto REDD+, sendo calculado a partir da diferença entre o cenário de referência (*C-Baseline*) e as emissões observadas (*C-Actual*), descontadas as emissões por vazamento (*C-Leakage*), expressando de forma integrada o benefício climático efetivo do projeto. Essa quantificação (C_{REDD}) serve de base para o cálculo dos créditos de carbono, fundamentando-se no princípio de que, ao evitar o desmatamento, o carbono permanecerá estocado na vegetação.


É necessário estimar o impacto potencial do projeto ao longo de sua vida útil, por meio de tendências históricas na mudança de cobertura da terra. São definidos dois cenários futuros de desmatamento: um em que a terra do projeto proposto é preservada, e outro em que as tendências passadas de mudança da terra continuam sem impedimentos. A diferença nos estoques de carbono entre esses dois cenários, chamada de adicionalidade, é usada como medida da compensação de carbono resultante da implementação do projeto REDD+ proposto (Clark Labs, 2024).

5 RESULTADOS E DISCUSSÃO

5.1 Mapa de Uso da terra

A Figura 4 apresenta o Mapa de uso da terra dos anos de 2003, 2013 e 2023, onde é possível observar que a grande maioria é destinada a atividades agropecuárias, e que houve um aumento nos centros urbanos. Além disso, a maior parte da classe Floresta está concentrada na região sul da RMS devido a presença de grandes e importantes áreas de preservação.

Figura 4 – Mapa de uso da terra da RMS de 2003; 2013 e 2023.



Fonte: Autoria própria.

A atividade agropecuária, ainda que menos expressiva na RMS em comparação ao panorama nacional, apresenta relevância regional. Sua participação supera em 37,5% a média do estado de São Paulo e é superior às regiões de Campinas e Vale do Paraíba, mesmo estas apresentando forte presença do cultivo de café e outras atividades agrícolas. A produção na RMS é voltada majoritariamente para hortaliças, sendo responsável por aproximadamente 20% do abastecimento estadual e por 22% do valor bruto da produção. Apesar da presença de grandes empresas rurais e propriedades agrícolas de médio porte, predomina a agricultura familiar, o que limita a formalização do mercado de trabalho e reforça a necessidade de investimentos voltados à modernização tecnológica e ao fortalecimento econômico do setor (Ribeiro et al., 2018).

A classe "Floresta" constitui o segundo maior uso da terra na RMS, concentrando-se principalmente no sul do território, área ocupada por importantes unidades de conservação de proteção integral. Destacam-se a APA Serra do Mar e os Parques Estaduais Carlos Botelho e Jurupará. A APA Serra do Mar abriga alguns dos remanescentes mais preservados da Mata Atlântica no Centro-Sul do país. Já o Parque Estadual Carlos Botelho tem como

objetivo a proteção da fauna, da flora e de atributos naturais, com ênfase em atividades científicas, educativas e recreativas. O Parque Estadual do Jurupará, por sua vez, situado em uma antiga reserva extrativista, configura-se como corredor ecológico estratégico, assegurando a integridade da bacia hidrográfica do Alto Juquiá e promovendo ações voltadas à conservação e à educação ambiental (Junior et al., 2020; Ribeiro et al., 2018).

As áreas urbanizadas da RMS expandiram-se de forma contínua ao longo das décadas, com núcleos de adensamento localizados principalmente nas regiões norte, centro-oeste e nordeste. Os municípios de Sorocaba e Votorantim concentram a maior mancha urbana, enquanto municípios como Salto, Itu e Itapetininga apresentam centros urbanos de menor extensão, mas com crescente influência no uso da terra.


De acordo com os dados do Sistema Estadual de Análise de Dados (SEADE) (2023), em 2022 a população da RMS atingiu cerca de 2.174.525 habitantes, em uma área territorial de 11.611,48 km² com densidade demográfica de 189 hab./ km², tendo um crescimento anual de 1,26% no período de 2010 a 2022. Em 2020 a população rural da RMS foi 203.342 habitantes enquanto a população urbana era 1.875.465 habitantes, tendo um grau de urbanização geral de 90,2% e 692.585 domicílios particulares ocupados.

5.2 Mapeamento das Variáveis do Modelo preditivo

Ao total foram utilizadas nove variáveis no modelo de mudança e previsão do uso da terra, conforme ilustrado na Figura 5. As mesmas variáveis foram aplicadas de forma padronizada em todos os modelos elaborados, permitindo a comparação entre os resultados das simulações.

Quanto menor o valor da distância euclidiana entre dois objetos, maior a semelhança entre eles em termos de parâmetros quantitativos. Essa lógica fundamenta a aplicação do método na análise de proximidade, pois distâncias menores indicam maior interação ou influência entre os elementos, tornando a variável espacialmente significativa para modelagens ambientais e conversão florestal (Borges; Silva; Castro, 2007; Brower; Zar, 1977).

Figura 5 – Variáveis utilizadas no modelo de mudança e previsão do uso da terra.



Fonte: Autoria própria.

A declividade é uma variável geográfica de elevada relevância na modelagem ambiental, pois influencia diretamente a dinâmica de uso da terra. Em geral, áreas com maior inclinação apresentam menor propensão à conversão para atividades antrópicas, como agricultura e urbanização, devido às limitações físicas impostas pelo relevo. Além disso, a declividade pode influenciar o comportamento do vento e, consequentemente, afetar a propagação de focos de queimada, aumentando o risco de degradação em determinadas regiões (SOUSA, 2021). Por essas razões, sua inclusão como variável preditora em modelos de pressão de desmatamento contribui para a delimitação de áreas prioritárias para conservação e manejo sustentável.

As UCs, por sua vez, foram incorporadas à análise com base no princípio de que essas áreas, por serem protegidas por instrumentos legais, deveriam apresentar menor influência antrópica direta. Esses mecanismos legais funcionam como uma barreira administrativa para a expansão do desmatamento e da exploração econômica predatória. As UC são divididas em categorias de acordo com as suas características específicas, todas com o intuito de proteger e preservar a fauna e flora nativa, através da proteção integral ou proteção com uso sustentável.

Por outro lado, as APAs de Itupararanga, Tietê-Jumirim e Cabreúva, embora relevantes para a preservação da vegetação nativa da RMS, enfrentam maior vulnerabilidade ambiental. Essa condição se relaciona à natureza jurídica dessas unidades, classificadas como de uso sustentável, o que as torna mais suscetíveis à ocupação irregular e à intensificação das atividades humanas. O Plano Municipal de Conservação e Recuperação da Mata Atlântica de Ibiúna (SEMA, 2018) destaca que a APA de Itupararanga sofre pressões crescentes provocadas pela expansão de loteamentos e pelo uso agrícola em áreas de alta fragilidade ambiental. Essa APA é classificada como área de impacto "Muito Forte", com remanescentes florestais expostos a impactos significativos que comprometem sua resiliência (Junior et al., 2020).

Embora exista um plano de manejo, sua aplicação prática pelos municípios ainda é deficiente, prejudicando a efetividade da gestão e a sustentabilidade ecológica local (SOUSA, 2021). O avanço de outras classes de uso da terra associado ao processo acelerado de antropização, intensificou os riscos de degradação ambiental, sobretudo a partir de 2017 (Simonetti; Silva; Rosa, 2019).

Na porção leste da RMS, destaca-se a Floresta Nacional de Ipanema, sob gestão do Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio). Trata-se de um dos maiores fragmentos contínuos de vegetação nativa da Mata Atlântica inseridos em um contexto fortemente antropizado, cercado por áreas urbanas e agrícolas. A unidade tem como missão a conservação e a recuperação da vegetação nativa, além de promover atividades de pesquisa e educação ambiental (ICMBio, 2024).


5.3 Modelagem REDD+

5.3.1 Mapeamento preditivo do uso da terra

A partir da metodologia proposta, obteve-se, primeiramente, a previsão do uso da terra para o ano de 2023, gerada com base na análise das mudanças ocorridas entre 2003 e

2013, utilizando as variáveis definidas neste estudo. Essa previsão foi posteriormente comparada ao cenário real de uso da terra em 2023, obtido por meio do mapeamento descrito no item 4.4. A Figura 6 apresenta, lado a lado, os mapas do uso da terra real e previsto para o ano de 2023.

Figura 6 – Mapa real e previsão do uso da terra de 2023



Fonte: Autoria própria

Vale ressaltar que o modelo RNA MLP foi previamente submetido a um processo de calibração, realizado de forma integrada à etapa de treinamento supervisionado. Somente após essa etapa foram conduzidos os procedimentos de validação do modelo. Conforme Haykin (2009) e Bishop (1995), em redes MLP o treinamento consiste exatamente no ajuste iterativo dos pesos sinápticos, ou seja, na calibração do modelo a partir de sua arquitetura. No presente estudo, essa etapa foi realizada utilizando as amostras de transição derivadas dos mapas de uso da terra, o que permitiu à rede aprender as relações entre as variáveis e as mudanças ocorridas. Dessa forma, não se fez necessária uma fase de calibração independente, pois o próprio algoritmo redefiniu automaticamente os parâmetros da arquitetura durante o treinamento, uma prática consolidada em modelagens ambientais com MLP (Eastman, 2016; Silva et al., 2020).

Após o treinamento e calibração, conduziu-se a validação, por meio da matriz de confusão e do índice Kappa, cujo objetivo foi avaliar a capacidade do modelo já calibrado de reproduzir as transições observadas no período analisado.

A validação foi utilizada como indicador do desempenho do modelo, que apresentou resultados considerados satisfatórios. Visualmente é possível observar que a previsão foi menos abrangente do que o cenário real, especialmente em relação às pequenas áreas florestais, que não foram bem representadas no mapa previsto. Nota-se a ausência de

pequenos fragmentos florestais, indicando que a classe floresta foi subestimada, enquanto a classe agrícola aparenta ter sido superestimada. Por outro lado, as classes urbanas e corpos hídricos apresentam grande similaridade entre os dois cenários.

Para avaliar de forma mais precisa a correspondência entre os dados previstos e os dados reais, foi gerada a matriz de confusão da comparação pixel a pixel, apresentada na Tabela 6.

Tabela 6 – Matriz de confusão com número de pixels do cenário do uso da terra real e previsto de 2023

Real/Previsto	Floresta	Agropecuária	Urbana	Corpos Hídricos
Floresta	5.222.416	70.819	2.029	787
Agropecuária	0	8.287.757	0	0
Urbana	0	0	680.751	0
Corpos Hídricos	0	0	0	126.889

Fonte: Autoria própria.

A matriz de confusão tem como objetivo demonstrar a relação entre os acertos e os erros da classificação. Neste caso, ela indica quantos pixels de cada classe do cenário real de 2023 foram classificados como pertencentes a outras classes no cenário previsto para o mesmo ano, conforme o modelo gerado pelo LCM. Os acertos são representados pelos valores localizados na diagonal principal da matriz, pois indicam que o pixel foi corretamente classificado. Em contrapartida, os erros de classificação são representados pelos valores fora da diagonal, evidenciando confusões entre as classes.


Observa-se que as classes 2, 3 e 4 apresentaram bom desempenho preditivo, enquanto a classe Floresta concentrou a maior parte das classificações incorretas. Ainda assim, o percentual de erro foi relativamente baixo: aproximadamente 1,39% dos pixels originalmente classificados como floresta foram atribuídos a outras classes, sendo 1,34% classificados como agropecuária, 0,04% como área urbana e 0,01% como corpos hídricos.

Nesse sentido, a matriz de confusão indica que os erros de classificação foram reduzidos e concentrados principalmente na classe floresta, resultando em uma leve subestimação da ocorrência dessa classe. Apesar disso, o nível de erro observado não compromete o desempenho do modelo, permitindo sua validação para os objetivos do estudo. Esse resultado é coerente com a abordagem adotada, uma vez que a análise está voltada justamente à dinâmica das áreas florestais, tornando a representação dessa classe mais sensível ao modelo.

O Índice Kappa obtido a partir da matriz de confusão foi igual a 0,90, indicando um nível alto de concordância entre o cenário previsto e o cenário real. Esse valor demonstra que o modelo apresentou desempenho muito satisfatório na classificação e previsão do uso da terra para 2023, com elevada concordância e baixa influência da aleatoriedade nos acertos.

Contudo, este valor deve ser interpretado com cautela, uma vez que representa o desempenho global do modelo, influenciado principalmente por áreas que não sofreram alterações. Portanto, embora demonstre um modelo com alta capacidade de previsão geral (uso da terra), ele não reflete necessariamente a acurácia nas transições críticas para os objetivos do REDD+, isto é, a mudança de floresta para não floresta.

Após a validação do modelo, iniciou-se uma nova análise das mudanças ocorridas entre 2003 e 2023 com as mesmas variáveis no intuito de realizar a previsão de 2053, conforme apresentado na Figura 7.



Fonte: Autoria própria.

Para uma análise mais precisa em termos quantitativos, a Tabela 7 e a Figura 8 apresenta a porcentagem de área ocupada por cada classe de uso da terra em relação à área


total da RMS, considerando todos os anos analisados neste estudo, tanto reais quanto previstos.

Tabela 7 – Área referente as classes do uso da terra para todos os anos apresentados

Classe	Área (%)				
	2003 (real)	2013 (real)	2023 (real)	2023 (previsto)	2053 (previsto)
Floresta	33,06	36,75	38,84	35,22	35,75
Agropecuária	62,20	57,64	54,77	59,12	57,86
Urbana	3,80	4,74	5,50	4,78	5,50
Corpos hídricos	0,95	0,88	0,89	0,89	0,89

Fonte: Autoria própria.

Figura 8 – Distribuição percentual da área por classe de uso da terra em todos os anos analisados



Fonte: Autoria própria.

Observa-se um crescimento constante da classe urbana, coerente com o aumento populacional na RMS. Segundo o Censo 2022 do Instituto Brasileiro de Geografia e Estatística (IBGE), a população de Sorocaba cresceu 23,3% entre 2010 e 2022, passando de 586.625 para 723.682 habitantes. Esse crescimento influenciou diretamente a expansão urbana mapeada no período. Já a classe “corpos hídricos” manteve-se estável em termos percentuais, uma vez que alterações em recursos hídricos costumam ser pouco expressivas dentro da análise em porcentagem, apresentando apenas leves variações em valores absolutos, uma vez que a intervenções em grandes corpos hídricos não são comuns.

A Tabela 8 apresenta as estatísticas de treinamento referentes às variáveis utilizadas, evidenciando a acurácia individual de cada variável e sua respectiva ordem de influência no

modelo de transição. Esses dados permitem compreender quais fatores possuem maior capacidade explicativa na dinâmica na mudança do uso da terra.

Tabela 8 – Acurácia individual e ordem de influência das variáveis utilizadas no modelo

Modelo	Acurácia (%)	Ordem de influência
Todas as variáveis	58.46	N/A
Centros urbanos	41.50	2
Malha viária	24.80	1 (mais influente)
Rede elétrica de transmissão	56.93	6
MDE	56.44	4
Declividade	57.05	7
Hidrografia	50.39	3
UC – Proteção integral	58.51	9 (menos influente)
UC – Uso sustentável	56.62	5
RUSLE	58.36	8

Fonte: Autoria própria

Dentre as variáveis analisadas, o modelo indicou que a mais influente na transição entre floresta e não floresta foi a variável “malha viária” e “centros urbanos”, evidenciando que o acesso por meio de rua e rodovias e a própria presença de centros urbanos exerce maior influência sobre o desmatamento. Esse resultado é coerente com a dinâmica de expansão urbana e rural, que tende a se concentrar em torno de áreas urbanizadas, onde há disponibilidade de infraestrutura e serviços essenciais ao desenvolvimento socioeconômico. Por outro lado, as unidades de conservação de proteção integral apresentaram a menor influência, o que reforça seu papel na contenção do desmatamento, atuando como barreiras à pressão antrópica nas áreas sob sua abrangência.

O principal instrumento normativo que rege a criação e a gestão das Unidades de Conservação é a Lei nº 9.985/2000, que institui o SNUC. Essa lei estabelece as categorias de UCs, seus objetivos, regimes de uso e os critérios para sua implantação e manejo. Adicionalmente, a Lei nº 6.902/1981 foi responsável por instituir as Estações Ecológicas e as APAs como instrumentos de conservação. A proteção ambiental também é respaldada pela Lei nº 6.938/1981, que institui a Política Nacional do Meio Ambiente (PNMA), e pelo Decreto nº 5.758/2006, que estabelece o Plano Estratégico Nacional de Áreas Protegidas (PNAP), o qual orienta a consolidação e a ampliação do sistema de áreas protegidas no país.

Mesmo as variáveis que apresentaram menor influência no modelo, devem ser mantidas na análise, pois representam aspectos físicos e administrativos relevantes do

território. Essas variáveis expressam características importantes da dinâmica territorial da região e, portanto, sua exclusão poderia comprometer a compreensão mais ampla dos fatores que condicionam ou não as mudanças no uso da terra.

Além disso, as variáveis menos influentes no modelo não implicam na menor importância analítica. Enquanto as variáveis mais influentes indicam os fatores que contribuem diretamente para a conversão ou conservação florestal, as variáveis menos influentes podem revelar elementos que não interferem significativamente nesse processo ou que atuam de forma indireta na sua estabilidade.


Dessa forma, sua presença no modelo contribui para uma interpretação mais completa do sistema analisado, permitindo identificar características territoriais que podem estar associadas à manutenção da cobertura florestal ou à ausência de pressões significativas de conversão das florestas.

5.3.2 Análises de mudança do uso da terra

Com a previsão do uso da terra para o ano de 2053, foram realizadas as análises de mudança referentes ao período de 2023 (ano inicial) a 2053 (ano final). Essa comparação permitiu evidenciar as transições de uso da terra ao longo do período analisado, com ênfase nas conversões da classe “floresta” para outras classes (“agropecuária”, “urbana” e “corpos hídricos”), sendo essas indicativas de perda de cobertura florestal. Para isso, foram gerados três produtos principais: mapa de ganhos e perdas, mapa de mudança, e mapa de tendências espaciais.

A análise da persistência, ou seja, áreas de vegetação que permaneceram inalteradas ao longo do período, é tão relevante quanto a análise de ganhos e perdas. Por esse motivo, o mapa apresentado na Figura 9 reúne essas três dimensões da dinâmica florestal da RMS, permitindo uma compreensão integrada dos processos de conservação, conversão e recuperação da classe Floresta.

Figura 9 – Mapa de ganhos, perdas e persistências da classe Floresta no período de 2023 a 2053 na RMS



Fonte: Autoria própria

A persistência da classe Floresta que corresponde a quase 92% da área total originalmente classificada, está fortemente associada à presença de unidades de conservação e outras áreas legalmente protegidas. A maior concentração dessas áreas conservadas, no período analisado (2023–2053), localiza-se no extremo sul da RMS, onde o modelo prevê elevada estabilidade da vegetação nativa e onde está localizada grandes unidades de conservação. Tal padrão decorre de diversos fatores, como ausência de grandes cidades e declividade, que dificultam a ocupação para atividades econômicas e expansão urbana, mas, sobretudo, da existência de instrumentos legais, como as unidades de conservação, que garantem a proteção dessas áreas.

Outro exemplo claro da eficácia de conservação por meio da proteção legal é observado na Floresta Nacional de Ipanema (Flona), que, apesar de estar cercada por intensa pressão antrópica, mantém alta taxa de persistência com poucas perdas, provavelmente devido à dificuldade da expansão urbana.


Por outro lado, na porção oeste da RMS, embora existam extensas áreas de persistência florestal, observa-se uma dinâmica de perdas mais consistente. Esse padrão pode

ser associado a dois fatores principais: a presença de relevo com declividade favorável à agricultura e outras atividades econômicas, e a ausência de unidades de conservação de relevância. A única área protegida identificada nessa região é a Estação Experimental, cuja presença isolada não indica ser suficiente para conter a pressão antrópica e, consequentemente, a perda de cobertura vegetal.

Apesar de representar cerca de 8% da área florestal original, a perda observada nesta região corresponde a mais de 36 mil hectares, valor expressivo do ponto de vista territorial e ambiental. Já os ganhos florestais foram mínimos, equivalendo a apenas 0,04% da área florestal e aproximadamente 0,01% da área total da RMS.

Complementarmente, a Figura 10 apresenta o mapa de mudanças do uso da terra entre 2023 e 2053 na RMS. Devido à grande extensão da área analisada, torna-se difícil identificar visualmente todas as classes de mudança, com exceção da conversão de Floresta para Agrícola, que representa uma porção significativa do território. Embora a conversão de áreas Agrícolas para Florestais também seja relevante, sua representação espacial é muito reduzida devido a pequena área, o que dificulta sua visualização na escala adotada. As demais transições são consideradas insignificantes, pois ocorrem em poucos pixels, dispersos em áreas isoladas do mapa.

Figura 10 – Mapa de mudanças de uso da terra (2023-2053) considerando as classes Floresta e Agropecuária.




Fonte: Autoria própria

Observa-se a predominância da conversão de áreas de floresta para agropecuária, representada pelas manchas vermelhas distribuídas principalmente ao longo da faixa central da RMS, no sentido leste-oeste, com maior concentração na porção oeste. As classes localizadas nas extremidades sul e norte permanecem conservadas, sem alterações significativas. Essa transição apresenta-se de forma fragmentada e dispersa, indicando um processo de substituição florestal localizado. A concentração das mudanças em regiões específicas aponta zonas de maior pressão antrópica, que podem orientar ações estratégicas voltadas à conservação e à mitigação do desmatamento, especialmente em contextos de projetos REDD+.

Em paisagens fortemente modificadas pela ação antrópica, os padrões de mudança no uso da terra tendem a ser complexos, o que dificulta sua interpretação direta. Pensando nisso, realizou-se a análise de tendências espaciais, que gera uma superfície de tendência polinomial de melhor ajuste ao padrão observado. As superfícies de tendência são empregadas, principalmente, para identificar padrões espaciais amplos dentro de um conjunto de dados, e não com a finalidade de gerar um modelo preditivo direto para uso em outras análises. Elas oferecem uma representação geral da direção e magnitude das mudanças, evidenciando zonas com maior ou menor tendência de conversão (Eastman, 2024).

A Figura 11 apresenta a tendência espacial das mudanças no uso da terra. Entre os anos de 2003 e 2023 observa-se uma tendência mais acentuada de conversão florestal na porção leste da RMS, destacada na cor vermelha. Essa região concentra uma maior perda de cobertura vegetal, especialmente nos municípios de Alumínio, Mairinque e São Roque, onde também se encontra parte da Área de Proteção Ambiental APA de Itupararanga. Já entre os anos 2023 e 2053 há uma intensificação da tendência de conversão florestal, principalmente na parcela oeste da RMS. Essa expansão é mais abrangente nos municípios de Itapetininga, Sarapuí e Alambari, indicando uma possível intensificação do processo de desmatamento futuro nessa porção do território, atrelado a isso nota-se que nesta região existe apenas uma área protegida, sendo a Estação experimental de Itupatininga.

Figura 11 – Tendência espacial de mudança do uso da terra (2023-2053)



Fonte: Autoria própria


Um padrão comum entre os dois cenários é o comportamento semelhante nas extremidades norte e sul da RMS, que apresentam baixa tendência de conversão florestal, embora mais acentuada no período de 2003 a 2023. Essa estabilidade se deve, principalmente, à presença de áreas legalmente protegidas, como a APA da Serra do Mar, o Parque Estadual Carlos Botelho, a Terra Indígena Tekoa Gwyrá Pepo e a APA Jurupará. Outro fator relevante é a baixa densidade de centros urbanos nessas regiões, justamente em razão da presença de extensas áreas protegidas fundamentais para conservação ambiental.

Além disso, nota-se a identificação de padrões espaciais mais sutis e variações com maior fidelidade, aprimorando a interpretação das áreas de maior vulnerabilidade à conversão florestal.

5.3.3 Áreas sob pressão de desmatamento

Foi identificado o equivalente a 101,96 ha de áreas sob pressão de desmatamento, correspondentes àquelas nas quais se observou a conversão da classe Floresta na previsão de 2053, desde que com extensão superior a 0,5 ha. A Figura 12 apresenta as áreas identificadas, juntamente com as áreas protegidas existentes na RMS.

Figura 12 – Mapa das Áreas sob pressão de desmatamento e protegidas



Fonte: Autoria própria.

As áreas em vermelho foram consideradas elegíveis para a inserção em projetos REDD+, por representarem unidades espaciais com potencial real de prevenção de emissões de carbono decorrentes da supressão florestal. A elegibilidade implica, ainda, na possibilidade de geração de créditos de carbono, desde que os critérios técnicos e legais dos padrões metodológicos sejam integralmente atendidos em etapas subsequentes do projeto.

O município de Itapetininga, foi o que apresentou maior extensão de áreas elegíveis, incluindo um setor que abrange a Estação Experimental Estadual de Itapetininga, unidade criada pelo Decreto Estadual nº 34.082/1958. Embora se trate de uma área legalmente protegida, a presença de áreas elegíveis indica a necessidade de atenção especial, onde podem ocorrer conflitos de uso da terra e pressões antrópicas indiretas. As estações experimentais desempenham papel relevante na conservação de remanescentes florestais e na pesquisa científica aplicada, o que reforça a importância de integrar instrumentos de monitoramento e gestão territorial para garantir a efetividade de sua proteção.

Outros municípios apresentam áreas com potencial para a geração de créditos de carbono, destacando-se Alambari, Sarapuá, Salto de Pirapora, Piedade, Pilar do Sul, São Miguel Arcanjo, Votorantim, Ibiúna, Alumínio e Mairinque. Nos casos de Ibiúna, Alumínio

e Mairinque, as áreas identificadas encontram-se inseridas na APA de Itupararanga. Ambas as UC são classificadas como de uso sustentável, o que permite a ocupação urbana, o desenvolvimento de atividades agrícolas e a realização de outras atividades antrópicas, desde que compatíveis com os objetivos de conservação e caracterizadas como de baixo impacto ambiental.

É necessária cautela na interpretação dos resultados, uma vez a maioria das áreas protegidas não foram consideradas elegíveis justamente por já estarem formalmente protegidas e delimitadas. O objetivo do modelo é identificar áreas sob pressão de desmatamento, e, considerando a existência de políticas públicas consolidadas, especialmente no caso das UC de proteção integral, entende-se que essas áreas são amparadas por mecanismos legais, políticos e administrativos de proteção.

Outro ponto a ser levantado é a respeito de áreas que já não possuem cobertura vegetal, ou seja, áreas previamente desmatadas. Como é o caso de algumas UC de uso sustentável que possuem atividades agrícolas ou ocupação urbana. Nesses casos, o modelo não as classifica como áreas sob pressão, pois parte do pressuposto de que o desmatamento já ocorreu e, portanto, não pode mais ser evitado. Embora essas áreas possam ser elegíveis para geração de créditos de carbono em outras modalidades, como projetos de restauração ou reflorestamento, elas não se enquadram nos critérios de projetos REDD+, que se baseiam na redução de emissões por desmatamento evitado. Assim, áreas que são formalmente protegidas, mas que não apresentam cobertura vegetal, não são identificadas pelo modelo como áreas sob pressão de desmatamento.

5.3.4 Estoque de carbono estimado

Para toda as áreas sob pressão de desmatamento identificadas, foram realizados os cálculos estimados para o estoque de carbono e quantidade de emissões evitadas durante todo o período de monitoramento hipotético do projeto (2023-2053). A Tabela 9 apresenta os resultados da modelagem das áreas potenciais para a implementação de projetos REDD+.

Observa-se que a redução das emissões de GEE devido ao projeto REDD+ nas áreas sob pressão de desmatamento da RMS seria de -810.055,625 tCO₂, em uma área total de 101,96 ha, correspondente a 7.944,83 tCO₂/ha no intervalo de 30 anos. Ao longo do período de monitoramento do projeto, a média anual de redução de emissões de carbono seria de aproximadamente 264,82 tCO₂/ha/ano.

Vale ressaltar que a efetividade do projeto foi estimada a partir da combinação entre a taxa de sucesso das ações implementadas e a taxa de vazamento associada a cada intervalo de reporte, resultando em um fator de ajuste aplicado às emissões projetadas na C-Baseline. Essa abordagem reflete o amadurecimento progressivo do projeto ao longo do tempo, na prática indica que a eficiência do projeto aumentará conforme as medidas implementadas ganharem efetividade com o passar dos anos. Tal abordagem está alinhada à lógica de projetos REDD+, nos quais as reduções de emissões correspondem às emissões evitadas em relação a um cenário de referência.

Tabela 9 – Resultados da estimativa das emissões antropogênicas atribuídas a áreas elegíveis a projeto REDD+

(Continua)

Ano do projeto		C-Baseline		C-Actual		C-Leakage		C-REDD	
Nº	Ano	Anual (tCO ₂ e)	Acumulado (tCO ₂ e)	Anual (tCO ₂ e)	Acumulado (tCO ₂ e)	Anual (tCO ₂ e)	Acumulado (tCO ₂ e)	Anual (tCO ₂ e)	Acumulado (tCO ₂ e)
1	2024	-21.236,36	-21.236,36	-9.556,36	-9.556,36	-4.247,27	-4.247,27	-7.432,72	-7.432,72
2	2025	-21.236,36	-42.472,71	-9.556,36	-19.112,72	-4.247,27	-8.494,54	-7.432,72	-14.865,45
3	2026	-21.236,36	-63.709,07	-9.556,36	-28.669,08	-4.247,27	-12.741,81	-7.432,72	-22.298,17
4	2027	-21.236,36	-84.945,43	-9.556,36	-38.225,45	-4.247,27	-16.989,09	-7.432,72	-29.730,90
5	2028	-21.236,36	-106.181,79	-9.556,36	-47.781,80	-4.247,27	-21.236,36	-7.432,72	-37.163,63
6	2029	-28.849,55	-135.031,34	-11.539,82	-59.321,63	-5.769,91	-27.006,27	-11.539,82	-48.703,45
7	2030	-28.849,55	-163.880,88	-11.539,82	-70.861,45	-5.769,91	-32.776,18	-11.539,82	-60.243,25
8	2031	-28.849,55	-192.730,42	-11.539,82	-82.401,27	-5.769,91	-38.546,09	-11.539,82	-71.783,07
9	2032	-28.849,55	-221.579,97	-11.539,82	-93.941,09	-5.769,91	-44.316,00	-11.539,82	-83.322,89
10	2033	-28.849,55	-250.429,50	-11.539,82	-105.480,91	-5.769,91	-50.085,91	-11.539,82	-94.862,69
11	2034	-36.876,25	-287.305,75	-11.062,87	-116.543,78	-5.531,44	-55.617,34	-20.281,94	-115.144,63
12	2035	-36.876,25	-324.182,00	-11.062,87	-127.606,66	-5.531,44	-61.148,78	-20.281,94	-135.426,56
13	2036	-36.876,25	-361.058,25	-11.062,87	-138.669,53	-5.531,44	-66.680,22	-20.281,94	-155.708,50
14	2037	-36.876,25	-397.934,47	-11.062,87	-149.732,41	-5.531,44	-72.211,66	-20.281,94	-175.990,41
15	2038	-36.876,25	-434.810,72	-11.062,87	-160.795,28	-5.531,44	-77.743,09	-20.281,94	-196.272,34
16	2039	-41.903,83	-476.714,53	-10.475,96	-171.271,23	-6.285,57	-84.028,67	-25.142,30	-221.414,63
17	2040	-41.903,83	-518.618,34	-10.475,96	-181.747,19	-6.285,57	-90.314,25	-25.142,30	-246.556,91
18	2041	-41.903,83	-560.522,13	-10.475,96	-192.223,14	-6.285,57	-96.599,83	-25.142,30	-271.699,16
19	2042	-41.903,83	-602.426,00	-10.475,96	-202.699,09	-6.285,57	-102.885,41	-25.142,30	-296.841,50
20	2043	-41.903,83	-644.329,75	-10.475,96	-213.175,05	-6.285,57	-109.170,98	-25.142,30	-321.983,72
21	2044	-57.373,11	-701.702,94	-11.474,62	-224.649,67	-5.737,31	-114.908,30	-40.161,18	-362.144,97

Fonte: Autoria própria.

Tabela 9 – Resultados da estimativa das emissões antropogênicas atribuídas a áreas elegíveis a projeto REDD+
(Conclusão)

Ano do projeto		C-Baseline		C-Actual		C-Leakage		C-REDD	
Nº	Ano	Anual (tCO ₂ e)	Acumulado (tCO ₂ e)	Anual (tCO ₂ e)	Acumulado (tCO ₂ e)	Anual (tCO ₂ e)	Acumulado (tCO ₂ e)	Anual (tCO ₂ e)	Acumulado (tCO ₂ e)
22	2045	-57.373,11	-759.076,00	-11.474,62	-236.124,30	-5.737,31	-120.645,61	-40.161,18	-402.306,09
23	2046	-57.373,11	-816.449,13	-11.474,62	-247.598,92	-5.737,31	-126.382,92	-40,161.18	-442.467,28
24	2047	-57.373,11	-873.822,25	-11.474,62	-259.073,55	-5.737,31	-132.120,23	-40.161,18	-482.628,47
25	2048	-57.373,11	-931.195,31	-11.474,62	-270.548,16	-5.737,31	-137.857,55	-40.161,18	-522.789,63
26	2049	-67.592,08	-998.787,38	-6.759,21	-277.307,38	-3.379,60	-141.237,16	-57.453,27	-580.242,88
27	2050	-67.592,08	-1.066.379,38	-6.759,21	-284.066,59	-3.379,60	-144.616,77	-57.453,27	-637.696,00
28	2051	-67.592,08	-1.133.971,38	-6.759,21	-290.825,81	-3.379,60	-147.996,38	-57.453,27	-695.149,19
29	2052	-67.592,08	-1.201.563,50	-6.759,21	-297.585,03	-3.379,60	-151.375,98	-57.453,27	-752.602,50
30	2053	-67.592,08	-1.269.155,50	-6.759,21	-304.344,25	-3.379,60	-154.755,59	-57.453,27	-810.055,63

Fonte: Autoria própria.

Por fim, destaca-se que um dos principais desafios dessa metodologia está na definição prévia do escopo do estudo, bem como na seleção adequada das variáveis e no seu correto pré-processamento. Etapas que exigem sólido embasamento no conhecimento técnico, social e territorial da área de estudo, uma vez que a escolha das variáveis influencia diretamente a capacidade explicativa e preditiva do modelo. Além disso, os valores de referência utilizados para o cálculo da estimativa do estoque de carbono devem estar compatíveis com as características específicas da região analisada, como bioma, tipo de formação florestal e características do solo.

Nesse contexto, entende-se que o estudo apresentado é reprodutível e escalonável, podendo ser aplicado tanto na mesma área de estudo quanto em outras regiões metropolitanas, municípios, bacias hidrográficas ou diferentes recortes territoriais. A estrutura metodológica descrita fornece base para o desenvolvimento de estudos semelhantes, contudo, a seleção das variáveis deve sempre considerar as características socioambientais da área analisada. Além das variáveis mais recorrentes, como declividade, relevo e hidrografia, outras podem ser incorporadas conforme os objetivos do estudo, como unidades de conservação, redes de transmissão de energia, malha viária, RUSLE e centros urbanos.

A arquitetura da RNA também deve ser ajustada, especialmente no que se refere ao número de neurônios de entrada e à quantidade de amostras solicitadas por classe. Esses parâmetros precisam estar alinhados tanto com o número de variáveis incluídas no modelo quanto com a dimensão da área de estudo, de modo a garantir coerência entre a estrutura do modelo e a complexidade do sistema analisado.

Dessa forma, os resultados obtidos evidenciam o potencial da abordagem proposta para a identificação de áreas elegíveis à geração de créditos de carbono no contexto de projetos de REDD+. A integração entre técnicas de geoprocessamento e RNA mostrou-se adequada para analisar a dinâmica espacial do uso da terra e apoiar a identificação de áreas com potencial para iniciativas de conservação florestal por meio de soluções baseadas na natureza.

6 CONCLUSÕES

Conforme os resultados obtidos na pesquisa pode-se afirmar que o modelo preditivo demonstrou desempenho bastante próximo ao que pode vir a ser a realidade futura com relação ao estudo do desmatamento evitado, dada a consistência estatística apresentada no mapeamento preditivo do uso da terra para o ano de 2053. Porém, certas condições não são totalmente capturadas pelo modelo de transição da classe Floresta para Não Floresta, que são de interesse para projetos REDD+, sendo que as limitações da variabilidade espacial comprometem de alguma forma o poder preditivo do modelo, visto que tais previsões estão associadas à quantidade e dinâmica das variáveis selecionadas para poder descrever o padrão de ocupação da superfície, já que estão submetidas às condições econômicas e sociais da área de estudo. Essas variáveis são de difíceis captura e por assim ser, comprometem de alguma maneira a identificação precisa das áreas de conversão.

Apesar disso, zonas de pressão antrópica que o modelo permitiu identificar, são as mais significativas para reger o processo nas quais o desmatamento tende a se concentrar. Nessas áreas, os resultados do modelo podem ser utilizados não somente para a implementação de projetos REDD+, mas também na orientação de políticas públicas, ações de monitoramento e investimento do setor privado em estratégias de conservação, mesmo que em escala regional.

Ressalta-se ainda que a exclusão de áreas menores que 0,5 hectare, embora metodologicamente coerente para evitar ruído estatístico e cumprir critérios para implementação de projetos REDD, pode subestimar a fragmentação do desmatamento. A aglomeração dessas áreas pequenas, quando espacialmente próximas, poderia representar um impacto ambiental relevante e, portanto, deve ser considerada em futuras análises.

Os resultados obtidos neste estudo, assim como aqueles que poderão ser gerados por pesquisas futuras que adotem a mesma abordagem, apresentam aplicabilidade tanto no setor público quanto no setor privado, configurando-se como instrumentos de interesse coletivo. Diante da urgência imposta pelas mudanças climáticas e pela necessidade de redução das emissões de GEE na atmosfera, observa-se uma mobilização crescente no Brasil para concentrar esforços em políticas públicas e ações concretas voltadas à mitigação desses impactos.

Nesse contexto, os resultados deste trabalho podem subsidiar a tomada de decisão por parte de gestores públicos, contribuindo para a formulação e o aprimoramento de políticas públicas, bem como para a delimitação de áreas prioritárias para a criação de novas

unidades de conservação e para a manutenção e fortalecimento das áreas protegidas já existentes.

No âmbito do setor privado, os resultados podem ser utilizados como suporte técnico para o cumprimento de metas de redução de emissões de carbono, para ações de compensação ambiental e para a implementação de projetos alinhados a práticas de ESG (*Environmental, Social and Governance*). Além disso, tais informações podem fundamentar iniciativas de participação voluntária no mercado de carbono, ampliando o engajamento do setor produtivo em estratégias de carbono neutro. Colaborando com mitigação climática e valorização dos serviços ecossistêmicos, em consonância com as tendências nacionais e internacionais.

A precificação do carbono constitui um instrumento central de política econômica para promover a transição rumo a uma economia verde em escala global. Ao atribuir um custo às emissões de GEE, esse mecanismo influencia os padrões de decisão relacionados à produção, ao consumo e aos investimentos, estimulando a adoção de tecnologias mais limpas e o fortalecimento da indústria de baixo carbono.

Dessa forma, o projeto REDD+ se configura como uma estratégia de valorização dos serviços ecossistêmicos prestados pela floresta em pé, ao mesmo tempo em que contribui para a mitigação das mudanças climáticas. Os resultados obtidos reforçam a importância de incorporar aspectos territoriais e socioeconômicos na modelagem, além de aprimorar os critérios de definição de áreas prioritárias para conservação, com foco especial nas regiões sob maior risco de conversão florestal. Para fins de elegibilidade e mensuração de créditos de carbono, é essencial interpretar os dados de maneira crítica e contextualizada, reconhecendo as limitações do modelo, mas também suas potencialidades como ferramenta de apoio à gestão ambiental para o setor público e privado.

REFERÊNCIAS

- AFIONIS, Stavros. The European Union in International Climate Change Negotiations. Illustrated ed. London: Routledge, 2019.
- AGGIDIS, G. A.; BENZON, D. S. Operational optimisation of a tidal barrage across the Mersey estuary using 0-D modelling. *Ocean Engineering*, v. 66, p. 69–81, jul. 2013.
- ALVES, W. S. et al. Mapeamento do potencial de erosão laminar em área de cerrado utilizando RUSLE e SIG. *Revista Brasileira de Geomorfologia*, v. 23, n. 4, p. 812–826, 2022.
- ARRUDA, Daniel M. et al. Vegetações amazônicas e terras indígenas ameaçadas pelas próximas mudanças climáticas: Previsão de impacto nos biomas brasileiros. *Austral Ecology*, v. 49, n. 1, jan. 2024.
- ARRAES, C. L. et al. Impacto das mudanças de uso do solo sobre a fragilidade ambiental da bacia hidrográfica do Ribeirão das Anhumas, Amparo (SP). *Engenharia Agrícola*, v. 30, n. 3, p. 404–414, 2010.
- ARYA, S.; SINGH, R. Applications of Analytical Hierarchy Process in remote sensing and GIS: a review. *Spatial Information Research*, v. 29, n. 6, p. 755–768, 2021.
- AVTAR, Ram et al. Land Use Change and Prediction for Valuating Carbon Sequestration in Viti Levu Island, Fiji. *Land*, v. 11, n. 8, ago. 2022.
- BAHADUR, K. C. K. Improving Landsat and IRS image classification: evaluation of unsupervised and supervised classification through band ratios and DEM in a mountainous landscape in Nepal. *Remote Sensing*, v. 1, n. 4, p. 1257–1272, 2009.
- BARBOSA, Gesiane Simara et al. Avaliação de áreas elegíveis à implantação de projetos de MDL florestais na Bacia do Rio Pardo, em Minas Gerais. *Nativa*, v. 9, n. 1, p. 115–122, fev. 2021.
- BENGIO, Yoshua; COURVILLE, Aaron; VINCENT, Pascal. Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 35, n. 8, p. 1798–1828, 2013.

- BERTONI, J.; LOMBARDI NETO, F. Conservação do solo. 9. ed. São Paulo: Ícone, 2017.
- BISHOP, Christopher M. Neural Networks for Pattern Recognition. Oxford: Oxford University Press, 1995.
- BORGES, Raphael De Oliveira; SILVA, Rosane Amaral Alves Da; CASTRO, Selma Simões De. Utilização da classificação por distância euclidiana no mapeamento dos focos de arenização no setor sul da alta bacia do Rio Araguaia. Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, p. 3777–3784, abr. 2007.
- BRASIL. Lei nº 15.042, de 11 de dezembro de 2024. Institui o Sistema Brasileiro de Comércio de Emissões de Gases de Efeito Estufa (SBCE). Diário Oficial da União, Brasília, DF, 12 dez. 2024.
- BROWER, J. E.; ZAR, J. H. Field & Laboratory Methods for General Ecology. Dubuque: Wm. C. Brown Publishers, 1977.
- CÂMARA, Gilberto et al. SPRING: Integrating remote sensing and GIS by object-oriented data modelling. Computers & Graphics, v. 20, n. 3, p. 395–403, maio 1996.
- CASTRO, A. F. Potencial de geração de créditos de carbono de fragmentos florestais da Mata Atlântica em áreas de preservação permanente no Estado de São Paulo. 2017. Dissertação (Mestrado) – Universidade Estadual Paulista, Sorocaba, 2017.
- CAUDILL, M. Neural networks primer, part I. AI Expert, v. 2, p. 46–52, 1987.
- CHEN, Lin et al. Estimation of forest above-ground biomass by geographically weighted regression and machine learning with Sentinel imagery. Forests, v. 9, n. 10, set. 2018.
- CHESHMBERAH, F. et al. Comparison of RBF and MLP neural network performance and regression analysis to estimate carbon sequestration. International Journal of Environmental Science and Technology, v. 17, n. 9, p. 3891–3900, set. 2020.
- CLARK LABS. TerrSet 2020 Geospatial Monitoring and Modeling Software. Disponível em: <<https://clarklabs.org/terrset/>>. Acesso em: 12 set. 2024.
- CLARKLABS. TerrSet Geospatial Monitoring and Modeling System. Clark University, 2025. Disponível em: <<https://clarklabs.org>>. Acesso em: 26 jan. 2026.

- COHEN, Jacob. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, v. 20, n. 1, p. 37–46, abr. 1960.
- DATAGEO. Infraestrutura de Dados Espaciais Ambientais do Estado de São Paulo – IDEA-SP. 2022. Disponível em: <<https://datageo.ambiente.sp.gov.br/>>. Acesso em: 26 jan. 2026.
- DERMACHI, C. G. et al. Relação entre dados de sensoriamento remoto e perda de solo por erosão hídrica. *Engenharia Agrícola*, v. 31, n. 3, p. 504–514, 2011.
- DIAS, Françoan de Oliveira et al. Análise bibliométrica da produção científica sobre créditos de carbono (2012–2021). *Revista de Gestão Social e Ambiental*, v. 17, n. 1, p. e03101, fev. 2023.
- EASTMAN, J. Ronald. TerrSet Tutorial. Massachusetts: Clark University, 2024.
- EASTMAN, J. Ronald. TerrSet: Earth Trends Modeler. Massachusetts: Clark University, 2016.
- EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. Sistema Brasileiro de Classificação de Solos. 5. ed. rev. ampl. Brasília: Embrapa, 2018.
- EMPLASA. Plano de Ação da Macrometrópole Paulista, 2013–2040. São Paulo: EMLASA, 2014.
- EMPLASA. Plano de Desenvolvimento Urbano Integrado: Panorama Geral. Sorocaba: EMLASA, 2017.
- ENDEAVOR BRASIL. Crédito de carbono: o que é, como funciona e por que importa. São Paulo: Endeavor Brasil, 2022. Disponível em: <<https://endeavor.org.br/estrategia-e-gestao/credito-de-carbono/>>. Acesso em: 26 jan. 2026.
- ESRI. ArcGIS Desktop. Environmental Systems Research Institute, 2023. Disponível em: <<https://www.esri.com>>. Acesso em: 26 jan. 2026.
- FALOWO, O. O.; OJO, O. I. GIS-based multi-criteria decision analysis for land suitability evaluation of small hydropower development. *Applied Energy*, v. 351, p. 121869, 2023.

- FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS – FAO. A Framework for Land Evaluation. Rome: FAO, 1976. (FAO Soils Bulletin, 32).
- FIORIO, P. R. Erodibilidade dos solos no Estado de São Paulo — revisão e atualização dos valores de K. *Revista Brasileira de Ciência do Solo*, v. 43, e0190035, 2019.
- GAUCH, H. G. *Multivariate Analysis in Community Ecology*. Cambridge: Cambridge University Press, 1982.
- GOMES, M. et al. Integrating national and subnational policies for REDD+ in Brazil: challenges and opportunities. *Forests*, v. 7, n. 12, p. 297, 2016.
- GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. *Deep Learning*. Cambridge: MIT Press, 2016.
- GRASS DEVELOPMENT TEAM. *Geographic Resources Analysis Support System (GRASS GIS) Software, Version 8.2*. Open Source Geospatial Foundation, 2022. Disponível em: <<https://grass.osgeo.org>>. Acesso em: 26 jan. 2026.
- HAGGARD, Stephan; SIMMONS, Beth A. Theories of international regimes. *International Organization*, v. 41, n. 3, p. 491–517, maio 1987.
- HAYKIN, Simon S. *Neural Networks and Learning Machines*. 3. ed. Upper Saddle River: Pearson Prentice Hall, 2009.
- HECHT-NIELSEN, R. Kolmogorov's mapping neural network existence theorem. In: *FIRST IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 1987. Proceedings...* [S.l.]: IEEE, 1987. v. III, p. 11–14.
- HINTON, Geoffrey E.; OSINDERO, Simon; TEH, Yee-Whye. A fast learning algorithm for deep belief nets. *Neural Computation*, v. 18, n. 7, p. 1527–1554, jul. 2006.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, v. 25, n. 3, p. 295–309, nov. 1988.
- INSTITUTO BRASILEIRO DE MEIO AMBIENTE E DOS RECURSOS NATURAIS RENOVÁVEIS – ICMBIO. *Floresta Nacional de Ipanema*. 2024. Disponível em:

<<https://www.icmbio.gov.br/flonaipanema/floresta-nacional-de-ipanema.html>>.

Acesso em: 12 set. 2024.

INSTITUTO DE PESQUISAS AMBIENTAIS – IPA. Mapa de erosividade da chuva do Estado de São Paulo. São Paulo: IPA/SMA, 2022. Disponível em: <<https://datageo.ambiente.sp.gov.br/>>. Acesso em: 26 jan. 2026.

INSTITUTO DE PESQUISA AMBIENTAL DA AMAZÔNIA – IPAM. Mercado de carbono: oportunidades e desafios para o Brasil. Belém: IPAM, 2024. Disponível em: <<https://ipam.org.br>>. Acesso em: 26 jan. 2026.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. 2006 IPCC Guidelines for National Greenhouse Gas Inventories. Volume 4: Agriculture, Forestry and Other Land Use. Hayama: IGES, 2006.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. 2019 Refinement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories. Geneva: IPCC, 2019.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Geneva: IPCC, 2023.

JUNIOR, Vidal Dias da Mota et al. Proteção da biodiversidade, legislação e políticas públicas na região metropolitana de Sorocaba–SP, Brasil, entre 2010 e 2019. Trayectorias Humanas Trascontinentales, n. 7, maio 2020.

KHOI, Duong Dang; MURAYAMA, Yuji. Forecasting areas vulnerable to forest conversion in the Tam Dao National Park region, Vietnam. Remote Sensing, v. 2, n. 5, p. 1249–1272, maio 2010.

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

LAZZARI, M. R. et al. Aplicação da RUSLE na estimativa da perda de solo em propriedades rurais do município de Curitiba (SC). Geociências, v. 34, n. 3, p. 459–471, 2015.

- LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. *Nature*, v. 521, p. 436–444, 2015.
- LI, Zhilin; ZHU, Christopher; GOLD, Chris. *Digital Terrain Modeling: Principles and Methodology*. Boca Raton: CRC Press, 2004.
- LIN, B. et al. Challenges and opportunities of voluntary carbon markets in meeting net-zero targets. *Nature Climate Change*, v. 14, p. 120–128, 2024.
- LOMBARDI NETO, F.; BERTONI, J. *Erodibilidade de solos do Estado de São Paulo*. Campinas: Instituto Agrônômico, 1975. (Boletim Técnico, 27.
- LORINI, Maria Lucia et al. Abordagem espacialmente explícita, hierárquica e multiescalar para análises de distribuição e persistência de espécies, populações e habitats em paisagens heterogêneas. In: CONGRESSO BRASILEIRO DE ECOLOGIA, 7., 2007, Caxambu. *Anais...* [S.l.: s.n.], 2007.
- MACIEL, M. N. REDD+ projects in Brazil: alignment between voluntary carbon market initiatives and the national REDD+ strategy. *Forest Policy and Economics*, v. 113, p. 102116, 2020.
- MAPBIOMAS PROJECT. Annual mapping of land use and land cover of Brazil. Algorithm theoretical basis document. MapBiomass Data, 2023. Disponível em: <<https://data.mapbiomas.org/dataset.xhtml?persistentId=doi:10.58053/MapBiomass/3KXXVV>>. Acesso em: 23 jun. 2025.
- MINISTÉRIO DO MEIO AMBIENTE – MMA. *Estratégia Nacional para REDD+ do Brasil: Resumo Executivo*. Brasília: MMA, 2016. Disponível em: <<https://www.gov.br/mma/pt-br/composicao/smc/departamento-de-instrumentos-de-mercado-e-redd/redd/assuntos/a-estrategia-nacional-para-redd-do-brasil>>. Acesso em: 20 jan. 2026.
- MINISTÉRIO DO MEIO AMBIENTE – MMA. *Gestão da ENREDD+*. 2025. Disponível em: <<https://www.gov.br/mma/pt-br/composicao/smc/departamento-de-instrumentos-de-mercado-e-redd/redd/salvuardas-de-redd/destaques/gestao-da-enredd>>. Acesso em: 20 jan. 2026.

- MOHD NOOR, Mohd Halim; IGE, Ayokunle Olalekan. A survey on state-of-the-art deep learning applications and challenges. *Engineering Applications of Artificial Intelligence*, v. 159, p. 111225, nov. 2025.
- NYIMBILI, P. H.; ERDEN, T.; KARAMAN, H. Integration of GIS, AHP and TOPSIS for earthquake hazard analysis. *Natural Hazards*, v. 92, n. 3, p. 1523–1546, 2018.
- OKEREKE, Chukwumerije; COVENTRY, Philip. Climate justice and the international regime: before, during, and after Paris. *WIREs Climate Change*, v. 7, n. 6, p. 834–851, nov. 2016.
- OLIVEIRA, Renan Angrizani de et al. Proposição de corredor ecológico entre duas unidades de conservação na Região Metropolitana de Sorocaba. *Revista do Departamento de Geografia da USP*, v. 32, p. 61, dez. 2016.
- ONTL, T. A. et al. Forest management for carbon sequestration and climate adaptation. *Journal of Forestry*, v. 118, n. 3, p. 264–278, 2020.
- PANDITHARATHNE, D. L. et al. Application of revised universal soil loss equation (RUSLE) model and GIS to estimate soil erosion in "Kalu Ganga" river basin, Sri Lanka. *Applied and Environmental Soil Science*, v. 2019, 2019.
- PATEL, Dhiren et al. Carbon credits on blockchain. In: *IEEE INTERNATIONAL CONFERENCE ON BLOCKCHAIN*, 2020. Proceedings... IEEE, fev. 2020.
- PECL, Gretta T. et al. Biodiversity redistribution under climate change: impacts on ecosystems and human well-being. *Science*, v. 355, n. 6332, p. eaai9214, 2017.
- QGIS DEVELOPMENT TEAM. QGIS Geographic Information System. Open Source Geospatial Foundation, 2026. Disponível em: <<https://qgis.org/download/>>. Acesso em: 26 jan. 2026.
- REN, Yisheng et al. Residents' willingness to pay for ecosystem services and its influencing factors: A study of the Xin'an River basin. *Journal of Cleaner Production*, v. 268, p. 122301, set. 2020.
- RIBEIRO, Francisco Carlos et al. Indicadores comparados da produção agrícola da Região Metropolitana de Sorocaba: emprego, renda e capital humano. In: *ECONOMIA*

- BRASILEIRA EM DEBATE: Subsídios ao Desenvolvimento. São Paulo: Editora Blucher, 2018. p. 33–46.
- RODRIGUEZ, L. C. E. Valoração econômica do potencial de sequestro de carbono em projetos de reflorestamento ecológico de áreas de preservação permanente no município de São Luiz do Paraitinga, SP. 2015. Dissertação (Mestrado) – Universidade de São Paulo, Piracicaba, 2015.
- ROSSI, Márcio. Mapa Pedológico do Estado de São Paulo: Revisado e Ampliado. São Paulo: Instituto Florestal, 2017. 1 mapa color., 118 × 89 cm, escala 1:250.000.
- RUBIAL, María del Pilar Bueno. El Acuerdo de París: ¿una nueva idea sobre la arquitectura climática internacional? *Relaciones Internacionales*, n. 33, out. 2016.
- SACRAMENTO, Bruna Henrique. Proposta metodológica de conectividade florestal e análise de gases de efeito estufa em bacias hidrográficas. 2020. Tese (Doutorado em Ciências Ambientais) – Instituto de Ciência e Tecnologia, Universidade Estadual Paulista, Sorocaba, 2020.
- SALLES, M. H. D. et al. Avaliação simplificada de impactos ambientais na bacia do Alto Sorocaba (SP). *REA – Revista de Estudos Ambientais*, v. 10, p. 6–20, jan. 2008.
- SANKARRAO, Landa; GHOSE, Dillip Kumar; RATHINSAMY, Maheswaran. Predicting land-use change: Intercomparison of different hybrid machine learning models. *Environmental Modelling & Software*, v. 145, p. 105207, nov. 2021.
- SAATY, Thomas L. A scaling method for priorities in hierarchical structures. *Journal of Mathematical Psychology*, v. 15, n. 3, p. 234–281, 1977.
- SCHINATO, Franco. Sequestro de carbono. *DRd – Desenvolvimento Regional em Debate*, v. 9, p. 347–365, maio 2019.
- SEADE. SEADE População. Disponível em: <<https://populacao.seade.gov.br/>>. Acesso em: 26 maio 2024.
- SECRETARIA DO MEIO AMBIENTE DO ESTADO DE SÃO PAULO – SEMA. Plano Municipal de Conservação e Recuperação da Mata Atlântica de Ibiúna. São Paulo: SEMA, 2018.

- SILVA, Greicelene Jesus et al. Aptitude of areas planned for sugarcane cultivation expansion in the state of São Paulo, Brazil: a study based on climate change effects. *Agriculture, Ecosystems & Environment*, v. 305, p. 107164, jan. 2021.
- SILVA, J. F. et al. Predicting land use and land cover change in Brazil using machine learning. *Ecological Modelling*, v. 430, p. 109134, 2020.
- SILVA, R. M. et al. Estimativa de perda de solos por erosão hídrica utilizando técnicas de geoprocessamento no Distrito Federal. *Espaço e Geografia*, v. 13, n. 2, p. 225–247, 2010.
- SIMONETTI, Vanessa Cezar; SILVA, Darllan Collins da Cunha e; ROSA, André Henrique. Análise da influência das atividades antrópicas sobre a qualidade da água da APA Itupararanga (SP), Brasil. *Geosul*, v. 34, n. 72, p. 01–27, jul. 2019.
- SONG, X. P. et al. Global land change from 1982 to 2016. *Nature*, v. 560, n. 7720, p. 639–643, 2018.
- SOUSA, Jocy Ana Paixão de. Elaboração de um índice de vulnerabilidade ambiental dos fragmentos florestais da Mata Atlântica. 2021. Tese (Doutorado em Ciências Ambientais) – Instituto de Ciência e Tecnologia, Universidade Estadual Paulista, Sorocaba, 2021.
- SOUZA, Carlos M. et al. Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and Earth Engine. *Remote Sensing*, v. 12, n. 17, p. 2735, ago. 2020.
- SOUZA, Maria Cristina Oliveira; CORAZZA, Rosana Icassatti. Do Protocolo de Kyoto ao Acordo de Paris: uma análise das mudanças no regime climático global a partir do estudo da evolução de perfis de emissões de gases de efeito estufa. *Desenvolvimento e Meio Ambiente*, v. 42, dez. 2017.
- STEIN, D. P. et al. Avaliação da degradação dos solos da Bacia do Rio Peixe-Paranapanema. In: SIMPÓSIO NACIONAL DE CONTROLE DE EROSÃO, 4., 1987, Marília. Anais... [S.l.: s.n.], 1987.

- TANG, Zhi et al. Estimation of national forest aboveground biomass from multi-source remotely sensed dataset with machine learning algorithms in China. *Remote Sensing*, v. 14, n. 21, p. 5487, out. 2022.
- TAROMIDEH, F. et al. Urban flood-risk assessment: integration of decision-making and machine learning. *Frontiers in Earth Science*, v. 10, 2022.
- TERRA CARBON. VCS Methodology VM0006: Methodology for Carbon Accounting for Mosaic and Landscape-scale REDD Projects. Washington: Verra, 2017. Disponível em: <<https://verra.org/wp-content/uploads/imported/methodologies/VM0006-REDD-Mosaic-Methodology-v2.2.pdf>>. Acesso em: 9 maio 2024.
- TERRA CARBON; SILVESTRUM CLIMATE ASSOCIATES. VCS Methodology VM0048: Afforestation, Reforestation and Revegetation. Washington: Verra, 2023. Disponível em: <https://verra.org/wp-content/uploads/2023/09/VM0047_ARR_v1.0-1.pdf>. Acesso em: 9 maio 2024.
- TOOCHI, E. C. Carbon sequestration: how much can forestry sequester CO₂? *Forestry Research and Engineering: International Journal*, v. 2, n. 3, p. 148–150, 2018.
- TOLEDO, Mayra Vannessa Lizcano. Estudo do uso da terra na Bacia Hidrográfica do Rio Sorocabaçu, Ibiúna–SP, para avaliação de áreas elegíveis em projetos MDL. 2023. Tese (Doutorado em Ciências Ambientais) – Instituto de Ciência e Tecnologia, Universidade Estadual Paulista, Sorocaba, 2023.
- TUDES, S.; YIGITER, N. D. Preparation of land use planning model using GIS based on AHP: case study Adana-Turkey. *Scientific Research and Essays*, v. 5, n. 19, p. 3001–3011, 2010.
- UNITED NATIONS – UN. The 17 Goals: Sustainable Development Goals. 2015. Disponível em: <<https://sdgs.un.org/goals>>. Acesso em: 20 jan. 2026.
- UNITED NATIONS – UN. Our Common Future. Oxford: Oxford University Press, 1987. (Relatório Brundtland, Comissão Mundial sobre Meio Ambiente e Desenvolvimento).

UNITED NATIONS FRAMEWORK CONVENTION ON CLIMATE CHANGE – UNFCCC. Kyoto Protocol to the United Nations Framework Convention on Climate Change. [S.l.: s.n.], 1997. Disponível em: <<https://unfccc.int/documents/2409>>. Acesso em: 9 maio 2024.

UNITED STATES GEOLOGICAL SURVEY – USGS. Landsat Collection 2 Science Product Guide. Reston: USGS, 2024. Disponível em: <<https://www.usgs.gov/landsat-missions>>. Acesso em: 26 jan. 2026.

VALENTE, Fernanda; VARGAS, Daniel; KINGSTON, Lilian. Avanços no Mercado Voluntário de Carbono: Bolsas Digitais, Tokenização e Padronização. São Paulo: [s.n.], 2023.

VALERIANO, Márcio de Morisson; ALBUQUERQUE, Paulo Cesar Gurgel de. TOPODATA: Processamento dos Dados SRTM. São José dos Campos: INPE, 2010. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m19@80/2010/05.10.18.42>>.

VERRA. Annual Report 2022. [S.l.]: Verra, 2022. Disponível em: <<https://verra.org/wp-content/uploads/2023/11/2022-Verra-Annual-Report.pdf>>. Acesso em: 9 maio 2024.

YILMAZ, I. Landslide susceptibility mapping using frequency ratio, logistic regression, artificial neural networks and their comparison: a case study from Kat landslides (Tokat, Turkey). Computers & Geosciences, v. 35, n. 6, p. 1125–1138, 2009.