

Mestrado em
**Ciência e Sistemas
de Informação Geográfica**

Especialização em
Ciência e Sistemas de Informação Geográfica

**Modelagem preditiva do
uso e cobertura do solo
com modelo híbrido
AC-RNA:**

Simulação de cenários territoriais no Vale do Jamari, Rondônia.

Cleber Cristian Sebrian da Silva

NOVA Information Management School
Instituto Superior de Estatística e Gestão de Informação
Universidade Nova de Lisboa

Modelagem preditiva do uso e cobertura do solo com modelo híbrido AC-RNA:

Simulação de cenários territoriais no Vale do Jamari, Rondônia.

por

Cleber Cristian Sebrian da Silva

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre em
Ciência e Sistemas de Informação Geográfica, com especialização em Ciência e
Sistemas de Informação Geográfica.

Orientada por:

Dr. Marco Octávio Trindade Painho, NOVA Information Management School

Março, 2026



DECLARAÇÃO DE INTEGRIDADE

Declaro ter realizado o presente trabalho académico com integridade. Confirmando que não recorri à prática de plágio ou de qualquer outra forma de utilização indevida de informação ou de falsificação de resultados durante o processo de elaboração deste trabalho. Declaro ainda que tenho conhecimento das Regras de Conduta e do Código de Honra da NOVA Information Management School.

Lisboa, 17 de março de 2026

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL GENERATIVA

Tarefas	NÃO	SIM	Ferramentas de Inteligência Artificial Generativa
Compreender melhor as questões relacionadas com a investigação		X	Gemini/ChatGPT
Resumir texto de bibliografia / recursos		X	Elicit
Resumo do(s) método(s) utilizado(s)		X	emini/ChatGPT
Tradução de texto			ChatPDF
Verificação gramatical		X	emini/ChatGPT
Parafrasear ou reescrever texto de outras pessoas/recursos			Gemini/ChatGPT
Codificação em R, Python, etc.	X		
Obter ajuda sobre um software		X	Gemini/ChatGPT
Criação e edição de imagens, mapas, vídeos, etc.	X		
Análise de dados		X	Gemini/ChatGPT
Especificar abaixo outras tarefas não mencionadas acima:	X		



DEDICATÓRIA

Dedico este trabalho à minha esposa, pelo amor e companheirismo incondicionais.
Aos meus pais, que sempre foram meu alicerce e guia.
E ao Professor Luís António Piemonte Pereira (*in memoriam*), que despertou em mim a paixão pela Topografia, Cartografia e Geodésia ainda no ensino técnico.



AGRADECIMENTOS

A realização deste trabalho só foi possível graças ao apoio e contributo de diversas pessoas e instituições, às quais expresso a minha profunda gratidão.

Em primeiro lugar, registro o meu agradecimento ao meu orientador, Dr. Marco Octávio Trindade Painho, pela orientação científica, disponibilidade, rigor académico e valiosas contribuições ao longo de todo o desenvolvimento desta dissertação.

Expresso igualmente a minha gratidão à NOVA Information Management School – Instituto Superior de Estatística e Gestão de Informação, da Universidade NOVA de Lisboa, pelo ambiente académico estimulante, pela qualidade da formação oferecida e pelas condições proporcionadas para a realização deste trabalho.

Deixo também um agradecimento especial ao meu local de trabalho, o Ministério Público do Estado de Rondônia (MPRO), em especial ao Núcleo de Análise Técnica (NAT), pelo ambiente profissional e pelas oportunidades concedidas para aplicar os conhecimentos adquiridos ao longo do mestrado, possibilitando a implementação de soluções voltadas à automatização de processos, padronização de trabalhos e organização de fluxos operacionais.

À minha esposa, expresso o meu profundo reconhecimento pelo amor, compreensão, incentivo constante e paciência demonstrados ao longo dos momentos mais exigentes desta jornada académica.

Aos meus pais, manifesto a minha gratidão pelo apoio incondicional, pelos valores transmitidos e por acreditarem sempre no meu percurso pessoal e académico.

Registro ainda o meu agradecimento ao meu colega de mestrado Tiago José Martins, que, nos momentos em que o pensamento de desistir se fazia presente, soube oferecer palavras de otimismo e incentivo. A parceria estabelecida ao longo do curso, por meio da realização de trabalhos conjuntos, foi de grande importância para a aprendizagem, a troca de conhecimentos e o crescimento académico.

Aos colegas do curso, deixo o meu reconhecimento pelo companheirismo, pelas trocas de experiências e pelo apoio mútuo ao longo do mestrado.

Estendo igualmente a minha gratidão a todos os professores que contribuíram para a minha formação académica e científica, bem como às instituições e profissionais que, direta ou indiretamente, colaboraram na disponibilização de dados, informações e apoio técnico essenciais para o desenvolvimento desta investigação.

Por fim, rendo graças a Deus, fonte suprema de sabedoria, força e graça, cuja presença soberana esteve acima de todos os aqui mencionados, sustentando-me nos momentos de dificuldade, guiando as minhas decisões e tornando possível a concretização deste trabalho.



RESUMO

A intensificação da atividade agropecuária na Amazônia Legal tem impulsionado transformações profundas na paisagem, exigindo ferramentas precisas para o monitoramento e o planejamento territorial. Esta dissertação investiga a dinâmica de uso e cobertura do solo no Território Vale do Jamari, em Rondônia, uma região caracterizada por elevada pressão antrópica e rápida conversão florestal. O objetivo principal do estudo foi aplicar e avaliar um modelo híbrido que integra Autômatos Celulares (AC) e Redes Neurais Artificiais (RNA) para simular padrões espaciais de mudança e projetar cenários futuros. A metodologia utilizou séries históricas do projeto MapBiomas para o período de 2014 a 2018 como base para o treinamento de uma Rede Neural do tipo Perceptron Multicamadas (MLP), processada no ambiente do software QGIS através do plugin MOLUSCE. O modelo foi validado simulando o cenário de 2022 e comparando-o com os dados observados, demonstrando elevada concordância estatística e capacidade de capturar a não linearidade dos processos de desmatamento. Com base no modelo calibrado, foram construídos cenários prospectivos para os horizontes de 2030 e 2050, contrastando uma tendência de continuidade histórica (Business as Usual) com cenários de governança que simulam a proteção efetiva de Unidades de Conservação, Terras Indígenas e Áreas de Preservação Permanente. Os resultados indicam que a abordagem híbrida AC-RNA é eficaz para representar a complexidade territorial da região, oferecendo subsídios técnicos robustos e de baixo custo para a formulação de políticas públicas voltadas ao ordenamento territorial e à sustentabilidade ambiental na Amazônia.

Palavras-chave: Modelagem Espacial; Uso e Cobertura do Solo; Vale do Jamari; Redes Neurais Artificiais; Autômatos Celulares; MapBiomas.

Objetivos do Desenvolvimento Sustentável (ODS):





ABSTRACT

ABSTRACT

The intensification of agricultural activity in the Legal Amazon has driven profound landscape transformations, requiring precise tools for monitoring and territorial planning. This dissertation investigates land use and land cover dynamics in the Vale do Jamari Territory, Rondônia, a region characterized by high anthropic pressure and rapid forest conversion. The main objective of the study was to apply and evaluate a hybrid model integrating Cellular Automata (CA) and Artificial Neural Networks (ANN) to simulate spatial change patterns and project future scenarios. The methodology used historical series from the MapBiomas project for the period 2014 to 2018 as the basis for training a Multi-layer Perceptron (MLP) Neural Network, processed within the QGIS software environment using the MOLUSCE plugin. The model was validated by simulating the 2022 scenario and comparing it with observed data, demonstrating high statistical agreement and the ability to capture the non-linearity of deforestation processes. Based on the calibrated model, prospective scenarios were constructed for the 2030 and 2050 horizons, contrasting a historical continuity trend (Business as Usual) with governance scenarios simulating the effective protection of Conservation Units, Indigenous Lands, and Permanent Preservation Areas. The results indicate that the hybrid CA-ANN approach is effective in representing the territorial complexity of the region, offering robust and low-cost technical subsidies for the formulation of public policies aimed at territorial planning and environmental sustainability in the Amazon.

Keywords: Spatial Modeling; Land Use and Land Cover; Vale do Jamari; Artificial Neural Networks; Cellular Automata ; MapBiomas.



ÍNDICE

Declaração de Integridade.....	iii
Dedicatória	iv
Agradecimentos.....	v
Resumo	vi
Abstract	vii
ÍNDICE	viii
Índice de Figuras	x
Índice de Tabelas	xi
Lista de Siglas e Abreviaturas	12
1 Introdução	13
2 Revisão da Literatura	16
2.1 Procedimentos de revisão da literatura.....	16
2.2 Introdução ao Referencial Teórico	16
2.3 Modelagem Preditiva de Uso e Cobertura do Solo	18
2.4 Autômatos Celulares (AC)	20
2.5 Redes Neurais Artificiais (RNA)	21
2.6 O Papel do Sensoriamento Remoto e das Séries Temporais do MapBiomias.....	22
2.7 O Plugin MOLUSCE e o Ambiente QGIS.....	22
2.8 Validação de Modelos e Métricas de Acurácia	23
2.9 Construção de cenários prospectivos e simulação	24
2.10 Ordenamento territorial, instrumentos legais e modelagem espacial do uso da terra	25
2.11 Síntese e Direccionamentos Teóricos da Pesquisa	26
3 Metodologia.....	28
3.1 Caracterização da Área de Estudo	28
3.2 Ambiente Computacional e Softwares	30
3.3 Base de Dados e Variáveis espaciais.....	30
3.3.1 Uso e Cobertura do Solo (Variável Dependente).....	31
3.3.2 Variáveis de Infraestrutura e Acesso	31
3.3.3 Hidrografia	32
3.3.4 Restrições Legais e Fundiárias.....	32
3.3.5 Topografia	33
3.3.6 Limites Administrativos	33
3.4 Procedimentos Metodológicos	34
3.4.1 Preparação e organização dos dados	34



3.4.2	Particionamento espacial para treinamento e validação.....	35
3.4.3	Análise da Dinâmica Temporal e Multicolinearidade	36
3.5	Treinamento e Calibração da Rede Neural Artificial	38
3.6	Validação do Modelo.....	39
3.6.1	Métricas Globais de Concordância	40
3.6.2	Análise de Desempenho por Classe: Matriz de Confusão.....	41
3.6.3	Métricas de Acurácia por Classe	41
3.6.4	F1-Score como Métrica Diagnóstica Complementar	42
3.7	Simulação de Cenários Futuros (2030-2050)	42
3.7.1	Cenário tendencial (BAU).....	43
3.7.2	Construção das máscaras de restrição	43
3.7.3	Geração dos cenários restritos por álgebra de mapas	44
3.7.4	Síntese e Justificativa Metodológica.....	44
4	Resultados e Discussão	45
4.1	Dinâmica espacial do uso e cobertura do solo no período histórico	45
4.2	Desempenho do modelo híbrido AC-RNA na simulação de 2022	46
4.3	Análise de desempenho por classe	49
4.4	Simulação de cenários prospectivos (2030–2050)	50
4.4.1	Cenário 1: Tendencial (<i>Business as Usual</i> – BAU).....	50
4.4.2	Cenário 2: Restrições em Áreas Protegidas (UC e TI)	52
4.4.3	Cenário 3: Restrições Ampliadas (UC, TI, APP e RL)	54
4.5	Análise Comparativa e Dinâmica Temporal dos Cenários (2030–2050)	56
4.5.1	O Horizonte de Curto Prazo (2030	56
4.5.2	O Horizonte de Longo Prazo (2050).....	57
5	Conclusões e Investigação Futura	59
5.1	Síntese dos Resultados e Contribuições	59
5.2	Limitações do Estudo.....	60
5.3	Recomendações para Investigação Futura.....	61
6	Referências Bibliográficas	62



ÍNDICE DE FIGURAS

Figura 1 - Fluxograma da metodologia de modelagem das mudanças de uso e cobertura do solo no Vale do Jamari (RO)	28
Figura 2 - Mapa de Localização, Território Vale do Jamari, Rondônia	29
Figura 3 - Particionamento espacial da área de estudo em conjuntos de treinamento (a) e validação (b)	35
Figura 4 - Mapas de uso e cobertura do solo: a) 2014, b) 2018 e c) 2022	45
Figura 5 - Comparação visual entre o mapa de referência (a) e o mapa simulado (b) para o ano de 2022	47
Figura 6 - Dinâmica espaço-temporal do uso e cobertura do solo no Cenário BAU: (a) 2018; (b) 2030; (c) 2050	51
Figura 7 - Dinâmica espaço-temporal do uso e cobertura do solo no Cenário com Restrições (UC e TI): (a) 2018 (b) 2030; (c) 2050	53



ÍNDICE DE TABELAS

Tabela 1 - Fontes de dados geoespaciais utilizadas na modelagem do uso e cobertura do solo.....	30
Tabela 2 - Reclassificação das classes do MapBiomias (13) em classes agregadas (6) utilizadas no modelo.....	31
Tabela 3 - Matriz de correlação de Pearson entre as variáveis explicativas	37
Tabela 4 - Classificação dos valores de concordância para o índice Kappa.....	41
Tabela 5 - Definição e regras de alocação dos cenários prospectivos (2030-2050..	43
Tabela 6 - Matriz de transição de probabilidade (2014–2018).....	46
Tabela 7 - Matriz de Confusão absoluta comparando o mapa simulado (linhas) com o mapa de referência (colunas), em número de pixels.....	47
Tabela 8 - Métricas globais de validação do modelo.....	48
Tabela 9 - Métricas de desempenho detalhadas por classe de uso e cobertura do solo (2022).....	49
Tabela 10 - Quantificação de áreas e variação percentual no Cenário BAU (2030–2050)	51
Tabela 11 - Quantificação de áreas e variação percentual no Cenário com Restrições (UC e TI) 2030 - 2050.....	53
Tabela 12 - Quantificação de áreas e variação percentual no Cenário com Restrições Ampliadas (UC, TI, APP e RL) 2030-2050	55
Tabela 13 - Comparação dos cenários prospectivos (2030)	56
Tabela 14 - Comparação dos cenários prospectivos (2050)	57



LISTA DE SIGLAS E ABREVIATURAS

AC	Autômatos Celulares
AMD	Advanced Micro Devices
AP	Acurácia do Produtor
APP	Áreas de Preservação Permanente
AU	Acurácia do Usuário
BAU	Business as Usual
CAR	Cadastro Ambiental Rural
DEM	Digital Elevation Model
GDAL	Geospatial Data Abstraction Library
IBGE	Instituto Brasileiro de Geografia e Estatística
INCRA	Instituto Nacional de Colonização e Reforma Agrária
LCM	Land Change Modeler
LULC	Land Use and Land Cover
MDE	Modelo Digital de Elevação
MLP	Multilayer Perceptron
QGIS	Quantum Geographic Information System
RAM	Random Access Memory
RL	Reservas Legal
RNA	Redes Neurais Artificiais
RO	Rondônia
RTX	Ray Tracing eXtension
SEDAM	Secretaria de Estado do Desenvolvimento Ambiental
SIG	Sistemas de Informação Geográfica
SIRGAS 2000	Sistema de Referência Geocêntrico para as Américas (2000)
SRTM	Shuttle Radar Topography Mission
TI	Terras Indígenas
UTM	Universal Transverse Mercator
VRAM	Video Random Access Memory



1 INTRODUÇÃO

As transformações no uso e na cobertura da terra figuram entre os principais vetores de alteração dos sistemas ambientais contemporâneos, especialmente em regiões de fronteira agrícola, onde a dinâmica territorial se caracteriza por elevada velocidade de mudança e forte pressão sobre os ecossistemas naturais (Ramos et al., 2024; Souza et al., 2020). Nesse contexto, a modelagem preditiva baseada em séries temporais de uso e cobertura do solo consolida-se como um instrumento estratégico para a antecipação de cenários futuros, oferecendo subsídios técnicos à formulação de políticas públicas, ao planejamento territorial e às ações de conservação ambiental (Ramos et al., 2024).

A pressão sobre os biomas brasileiros permanece crítica, impulsionada majoritariamente pela expansão de fronteiras produtivas. Segundo o Relatório Anual do Desmatamento no Brasil (MapBiomas, 2024), a atividade agropecuária foi responsável por mais de 97% da área desmatada no Brasil no último ano. Embora tenha havido uma redução nas taxas anuais, o bioma Amazônia registrou, apenas em 2023, a supressão de 454.271 hectares de vegetação nativa (MapBiomas, 2024).

Esse cenário macro reflete-se intensamente em Rondônia. Conforme análise histórica apresentada por Covalleski et al. (2025), o estado experimentou uma redução drástica de sua cobertura florestal original nas últimas décadas: de aproximadamente 203 mil km² em 1985 (85,5% do território), restavam cerca de 133 mil km² em 2020 (56,2%). No mesmo período, as áreas destinadas à agropecuária triplicaram, saltando de 33 mil km² para mais de 103 mil km², consolidando a conversão de florestas em pastagens como o principal vetor de mudança na paisagem rondoniense.

Inserido nesse contexto regional de intensa transformação, o Território Vale do Jamari, composto por nove municípios, destaca-se como uma das áreas mais dinâmicas e sensíveis da fronteira agropecuária. A trajetória de ocupação acelerada dessa região reflete um histórico de intensas pressões antrópicas, impulsionadas pela conversão de áreas florestais para atividades produtivas, resultando em mudanças estruturais na paisagem e em impactos significativos sobre os ecossistemas florestais e os sistemas hidrológicos locais (V. B. V. de Oliveira, 2007; Souza et al., 2020).

A complexidade dessas dinâmicas impõe desafios metodológicos relevantes à análise e à projeção das mudanças no uso da terra. Abordagens tradicionais, como as Cadeias de Markov, embora amplamente utilizadas, apresentam limitações importantes, sobretudo por desconsiderarem explicitamente a dependência espacial e os padrões de vizinhança que condicionam a propagação das mudanças na paisagem (Gharaibeh et al., 2020). Em contrapartida, modelos baseados em Autômatos Celulares (AC) e Redes Neurais Artificiais (RNA) destacam-se pela capacidade de representar interações espaciais locais e relações não lineares entre variáveis ambientais e antrópicas, oferecendo maior aderência à natureza complexa dos sistemas territoriais (Almeida & Gleriani, 2005; Gharaibeh et al., 2020).



É neste enquadramento que se insere a presente dissertação, centrada na modelagem preditiva do uso e cobertura do solo no Território Vale do Jamari. O estudo utiliza dados do projeto MapBiomass e variáveis ambientais e antrópicas para calibrar um modelo híbrido AC-RNA com base nas transformações observadas entre 2014 e 2018, validar a sua capacidade de simulação com referência ao ano de 2022 e, a partir dessa base, projetar cenários prospectivos para 2030 e 2050 sob diferentes regimes de governança territorial.

A investigação estrutura-se em torno das seguintes perguntas de investigação:

1. Quais foram os principais padrões de mudança no uso e cobertura do solo no Território Vale do Jamari no período de **2014 a 2018**, utilizado para a calibração do modelo?
2. Em que medida o modelo híbrido baseado em Autômatos Celulares e Redes Neurais Artificiais é capaz de simular, de forma satisfatória, a dinâmica espacial observada, tomando o ano de 2022 como referência de validação?
3. Quais são as tendências de evolução do uso e cobertura do solo no Território Vale do Jamari para 2030 e 2050, considerando um cenário tendencial (*Business as Usual*) e cenários com diferentes níveis de restrição territorial e proteção ambiental?

Metodologicamente, para responder a essas questões, utiliza-se a abordagem disponibilizada pelo plugin MOLUSCE (*Modules for Land Use Change Evaluation*), implementado no ambiente do software livre QGIS (Asia Air Survey & NextGIS, 2025). Essa ferramenta permite a aplicação integrada de algoritmos de modelagem espacial, operacionalizando o treinamento de Redes Neurais Artificiais (Perceptron Multicamadas) para a definição do potencial de transição e a simulação espacial via Autômatos Celulares.

O objetivo principal da pesquisa consiste em calibrar e validar um modelo híbrido de mudança de uso e cobertura do solo para o Território Vale do Jamari, de modo a simular o cenário de 2022 e projetar cenários futuros para 2030 e 2050. Adicionalmente, busca-se identificar os padrões de transformação territorial e os vetores espaciais associados a essas mudanças, como a proximidade de estradas e a infraestrutura, estabelecendo parâmetros metodológicos que viabilizem a projeção de cenários futuros sob diferentes regimes de governança territorial.

Cabe ressaltar que, embora o projeto inicial desta pesquisa previsse a comparação direta entre diferentes algoritmos, incluindo a Regressão Logística, a revisão aprofundada da literatura evidenciou que modelos lineares apresentam limitações significativas para capturar a dinâmica complexa de desmatamento em fronteiras ativas como o Vale do Jamari (Hu & Lo, 2007; Lin et al., 2011). Portanto, optou-se por concentrar o esforço computacional e analítico no refinamento e na validação robusta do Modelo Híbrido (AC-RNA), que se mostra mais adequado à captura de não



linearidades em processos de mudança de uso do solo (Almeida & Gleriani, 2005; Lin et al., 2011).

Dessa forma, a pesquisa insere-se na interface entre geoprocessamento, modelagem espacial e inteligência artificial aplicada, demonstrando a viabilidade do uso de ferramentas acessíveis (*open source*) para a simulação de fenômenos complexos na Amazônia. O estudo contribui tanto para o avanço da compreensão dos mecanismos que moldam a paisagem regional quanto para a validação de instrumentos que podem subsidiar, de forma prática, o planejamento territorial sustentável.

Diante desse contexto, a dissertação estrutura-se em cinco capítulos. Após esta introdução, o Capítulo 2 apresenta a revisão da literatura, discutindo os fundamentos teóricos da modelagem preditiva, o papel dos Autômatos Celulares e das Redes Neurais, e a relevância das séries do MapBiomas. O Capítulo 3 descreve a área de estudo, as bases de dados e os procedimentos metodológicos adotados para a calibração e validação do modelo no QGIS/MOLUSCE. O Capítulo 4 apresenta e discute os resultados obtidos, abrangendo a simulação de 2022, a análise dos vetores de mudança e a projeção de cenários futuros para os anos de 2030 e 2050. Por fim, o Capítulo 5 sintetiza as principais conclusões, limitações e contribuições do estudo, indicando perspectivas para investigações futuras no âmbito da gestão territorial na Amazônia Legal.



2 REVISÃO DA LITERATURA

2.1 PROCEDIMENTOS DE REVISÃO DA LITERATURA

A revisão da literatura baseou-se em uma pesquisa bibliográfica sistemática realizada nas bases de dados Scopus, Google Scholar e Elicit. Foram selecionados artigos publicados entre 2015 e 2025, utilizando as palavras-chave: “land use change Amazon”, “cellular automata”, “neural networks” e “spatial modeling”.

A triagem inicial considerou títulos e resumos, priorizando estudos aplicados à Amazônia Legal, regiões tropicais e modelagens híbridas. Em seguida, foram analisados integralmente os trabalhos com maior relevância metodológica e empírica, garantindo atualidade científica e aderência aos objetivos da pesquisa.

2.2 INTRODUÇÃO AO REFERENCIAL TEÓRICO

O avanço do desmatamento e a intensificação das mudanças no uso e na cobertura do solo na Amazônia impõem desafios crescentes à gestão territorial e à formulação de políticas públicas. No Vale do Jamari, em Rondônia, essas transformações decorrem de uma combinação complexa de fatores socioeconômicos, ambientais e institucionais, que operam em múltiplas escalas espaciais e temporais. Conforme demonstram Ometto et al. (2016), entre 1960 e 2013, o uso e a cobertura da terra na Amazônia passaram por transições marcadas pelo avanço da fronteira agropecuária e pela expansão da infraestrutura, processos diretamente associados à ocupação humana e aos incentivos econômicos promovidos pelo Estado. De forma complementar, Pfaff (1999) evidencia que o aumento da densidade rodoviária e as políticas de desenvolvimento implementadas na década de 1970 foram determinantes na abertura de novas frentes de desmatamento, moldando de maneira duradoura a configuração territorial amazônica.

A pressão sobre os biomas brasileiros permanece crítica, impulsionada majoritariamente pela expansão de fronteiras produtivas. Segundo o Relatório Anual do Desmatamento (RAD 2023), publicado pelo MapBiomas (2024) a atividade agropecuária foi responsável por mais de 97% da área desmatada no Brasil no último ano. Embora tenha havido uma redução nas taxas anuais, o bioma Amazônia registrou, apenas em 2023, a supressão de 454.271 hectares de vegetação nativa.

Esse cenário macro reflete-se intensamente em Rondônia. Conforme análise histórica apresentada por Covaleski et al. (2025) o estado experimentou uma redução drástica de sua cobertura florestal original nas últimas décadas: de aproximadamente 203 mil km² em 1985 (85,5% do território), restavam cerca de 133 mil km² em 2020 (56,2%). No mesmo período, as áreas destinadas à agropecuária triplicaram, saltando de 33 mil km² para mais de 103 mil km², consolidando a conversão de florestas em pastagens como o principal vetor de mudança na paisagem rondoniense.



Essas dinâmicas, contudo, não podem ser interpretadas de forma isolada. É imprescindível considerar as dimensões sociais e econômicas que condicionam o desmatamento em nível local. Pesquisas de Simmons et al. (2016) revelam que a conversão florestal na Amazônia brasileira é majoritariamente conduzida por pequenos produtores e famílias agrícolas, e não apenas por grandes empreendimentos, o que ressalta o caráter social, descentralizado e multifatorial das mudanças no uso do solo. Em escala regional, estudos realizados em Rondônia por Souza et al. (2020) reforçam que as decisões dos produtores rurais são influenciadas por fatores como o tamanho dos lotes, as condições de mercado e a disponibilidade de mão de obra, resultando em impactos ambientais expressivos, como a degradação do solo, a perda de biodiversidade e a alteração dos regimes hidrológicos.

Nas últimas décadas, o papel das políticas públicas e das cadeias produtivas de *commodities* agrícolas tornou-se central nas análises sobre o desmatamento amazônico. Nepstad et al. (2014) demonstram que políticas integradas de comando e controle, quando associadas a mecanismos de rastreabilidade nas cadeias da carne bovina e da soja, reduziram o desmatamento em cerca de 70%, por meio do fortalecimento da legislação ambiental e da ampliação das áreas protegidas. Em análise convergente, Barona et al. (2010) e Picoli et al. (2020) destacam que, embora a expansão da soja frequentemente ocorra sobre áreas já desmatadas, ela contribui indiretamente para o deslocamento da fronteira agrícola e a intensificação do desmatamento em regiões adjacentes, enquanto a pecuária mantém-se como vetor direto predominante dessas transformações. Mais recentemente, Cammelli et al. (2022) discutem os dilemas entre efetividade e equidade em políticas de monitoramento da cadeia da carne, ressaltando que modelos cooperativos de governança tendem a reduzir desigualdades e a fortalecer a legitimidade das ações de fiscalização.

Nesse contexto, compreender e antecipar a dinâmica do uso e da cobertura do solo torna-se essencial para subsidiar estratégias de planejamento, conservação e monitoramento ambiental. De acordo com Maeda et al. (2011), as abordagens baseadas em simulação espaço-temporal, aliadas às técnicas de sensoriamento remoto, têm se mostrado eficazes na representação das transições de uso do solo e na projeção de cenários futuros. Modelos consolidados, como o DINAMICA EGO e o IDRISI *Land Change Modeler* (LCM), vêm sendo amplamente utilizados para analisar padrões de ocupação e estimar probabilidades de transição entre classes de uso e cobertura; entretanto, esses modelos apresentam restrições quanto à capacidade de incorporar processos socioeconômicos não lineares, o que limita sua potência explicativa e preditiva.

Diante dessas limitações, intensifica-se o interesse por abordagens híbridas que integrem métodos de aprendizado de máquina aos modelos tradicionais de Autômatos Celulares (AC). Trabalhos pioneiros, como os de Almeida e Gleriani (2005) e Basse et al. (2014), demonstram que a combinação entre Autômatos Celulares e Redes Neurais Artificiais (RNA) amplia substancialmente a precisão preditiva e a



representatividade espacial das simulações de uso e cobertura do solo. Resultados recentes obtidos por Gharaibeh et al. (2020) reforçam essa tendência, ao mostrarem que a integração entre AC, RNA e Cadeias de Markov atinge índices de acurácia superiores a 90%, superando os modelos convencionais. De forma convergente, Esteves et al. (2024) aplicaram o modelo híbrido AC-RNA a centros urbanos brasileiros, obtendo altos valores de precisão e recall para as classes urbanas e florestais.

Paralelamente, revisões de literatura como a de Aburas et al. (2019) ressaltam que os métodos baseados em aprendizado de máquina permitem capturar interações complexas entre fatores ambientais e antrópicos, proporcionando maior flexibilidade e capacidade de generalização do que os modelos determinísticos tradicionais. Avanços metodológicos mais recentes, representados por Ding et al. (2025) e Anwar e Sakti (2024), ampliam esse campo ao incorporar técnicas de regressão espacial, sensoriamento remoto e análise de big data geográficos em ambientes de Sistemas de Informação Geográfica (SIG), elevando a precisão e a eficiência operacional das modelagens territoriais.

Especificamente na região de estudo desta dissertação, o Território do Vale do Jamari, essas dinâmicas globais da Amazônia manifestam-se com particularidades locais agudas. Segundo o diagnóstico realizado pela Embrapa Rondônia no "Perfil Social e Produtivo do Território" (V. B. V. de Oliveira, 2007), a região caracteriza-se por uma matriz econômica historicamente ligada ao extrativismo de madeira e minérios, que gradualmente cedeu espaço para a pecuária de corte e leite e para a cafeicultura.

Contudo, essa transição produtiva ocorre em uma zona de tensão fundiária. Conforme detalham Novoa Garzon et al. (2022) ao analisarem o 'novo arco de desmatamento', o Vale do Jamari situa-se em uma área de confluência de 'agro-minero-energo estratégias', onde a expansão da infraestrutura viária e a pressão sobre Territórios Indígenas e Unidades de Conservação intensificam a conversão florestal. Essa realidade torna a região um laboratório crítico para a modelagem espacial, pois as mudanças ali não seguem apenas padrões de aptidão agrícola, mas respondem a vetores políticos e de infraestrutura que precisam ser capturados pelas variáveis explicativas do modelo.

2.3 MODELAGEM PREDITIVA DE USO E COBERTURA DO SOLO

A modelagem preditiva de uso e cobertura do solo tem como objetivo simular transformações espaço-temporais, integrando as interações e processos que governam a dinâmica das paisagens, sejam elas urbanas ou rurais. Essa abordagem fundamenta-se na aplicação de dados geográficos, técnicas de análise espacial e ferramentas computacionais avançadas, capazes de representar e projetar cenários complexos de evolução territorial. Conforme revisado por Aburas et al. (2019), a eficácia desses modelos reside na capacidade de lidar com incertezas inerentes aos sistemas físicos e humanos, evoluindo de representações estáticas para dinâmicas.



Nesse contexto, os modelos dinâmicos espaciais, com destaque para aqueles baseados em Autômatos Celulares, assumem especial relevância. Diferentemente de abordagens estáticas, eles combinam uma dimensão temporal explícita com a capacidade de espacializar as transformações, estruturando-se em variáveis de estado, regras de transição e processos de vizinhança que mimetizam o funcionamento dos sistemas territoriais. Embora os fundamentos teóricos tenham sido estabelecidos em trabalhos seminais como os de Almeida e Gleriani (2005), aplicações recentes de Esteves et al. (2024) demonstram que a estrutura dos AC continua sendo a espinha dorsal para simulações de alta resolução espacial.

A literatura classifica esses modelos em duas grandes categorias: empíricos, que extrapolam tendências observadas no passado assumindo a continuidade dos padrões (inércia espacial); e baseados em sistemas, que buscam descrever matematicamente os processos causais subjacentes (Michetti & Zampieri, 2014). Modelos tradicionais não-dinâmicos, muitas vezes teóricos, apresentam limitações significativas por falharem na incorporação de variações temporais contínuas. Representações estáticas mostram-se insuficientes para capturar a natureza estocástica e não-linear de fenômenos como o desmatamento ou a expansão urbana, o que impulsionou o desenvolvimento de novas arquiteturas de modelagem geoespacial na última década (Ding et al., 2025).

Um desafio adicional reside na complexidade inerente ao aumento do número de classes temáticas de uso do solo. A multiplicidade de categorias pode dificultar a calibração dos algoritmos, exigindo, por vezes, a generalização das classes para garantir a convergência e a consistência do modelo.

Diante desses desafios, as abordagens híbridas emergem como a fronteira do conhecimento na área. A integração de Autômatos Celulares com técnicas de Inteligência Artificial, especificamente Redes Neurais Artificiais, proporciona avanços substanciais. Essa sinergia permite a assimilação de dados heterogêneos e a modelagem de regras de transição não lineares, superando a rigidez dos métodos estatísticos clássicos. Estudos comparativos recentes, como os de Gharaibeh et al. (2020) e Anwar e Sakti (2024), validam essa superioridade, indicando que modelos híbridos (AC-RNA) apresentam métricas de acurácia consistentemente superiores aos modelos tradicionais baseados apenas em cadeias de Markov ou regressão logística.

Essa combinação amplia a capacidade de simular a complexidade sistêmica, facilitando a identificação das variáveis espaciais determinantes para as mudanças, como proximidade à infraestrutura viária, redes hidrográficas e declividade. Adicionalmente, o treinamento da rede neural permite ajustar iterativamente os pesos sinápticos entre essas variáveis, refinando a calibração ao aprender padrões não lineares a partir do histórico espacial de transições.

Dessa forma, a modelagem híbrida representa uma superação das limitações dos modelos tradicionais, oferecendo resultados mais aderentes à realidade. Ao permitir



a simulação de cenários futuros com maior confiabilidade estatística e precisão espacial, essas ferramentas tornam-se instrumentos indispensáveis para o ordenamento territorial e para a gestão estratégica da paisagem na Amazônia (Picoli et al., 2020; Souza et al., 2020).

2.4 AUTÔMATOS CELULARES (AC)

A teoria dos Autômatos Celulares (AC) foi concebida originalmente na década de 1940 pelos matemáticos John von Neumann e Stanislaw Ulam, com o objetivo inicial de estudar a lógica da autorreprodução em sistemas mecânicos e biológicos. Wolfram (1984), responsável por popularizar e classificar formalmente esses sistemas, define os Autômatos Celulares como modelos matemáticos idealizados de sistemas complexos, capazes de gerar comportamentos globais elaborados a partir de componentes simples interagindo localmente. Essa capacidade de emergência de padrões complexos a partir de regras básicas consolidou os AC como uma das ferramentas mais potentes para a simulação de dinâmicas espaciais.

Do ponto de vista computacional contemporâneo, conforme definido por Antunes (2021) na documentação da biblioteca *CellPyLib*, os AC são sistemas discretos modelados em uma grade de células, onde cada célula assume um estado finito. A evolução do sistema ocorre em passos de tempo discretos, nos quais o estado de uma célula no tempo $t+1$ é atualizado com base no seu próprio estado no tempo t e nos estados de suas vizinhas, seguindo uma regra de transição fixa e uniforme.

Essa estrutura operacional é ideal para integrar dados de Sensoriamento Remoto e Sistemas de Informações Geográficas (SIG). Al-Ageili et al. (2017) destacam que essa integração permite transformar imagens de satélite classificadas em grades celulares ativas, onde a dinâmica de uso do solo deixa de ser estática. Nesse ambiente, a capacidade dos AC de modelar processos não lineares oferece uma vantagem significativa sobre modelos estatísticos tradicionais, sendo mais eficazes na simulação de mudanças de cobertura da terra que dependem fortemente do contexto local.

O motor dessa dinâmica reside no conceito de vizinhança, que materializa a dependência espacial dos fenômenos geográficos. Em estudos recentes de modelagem ambiental, como demonstrado por Hojati e Robertson (2020), a configuração da vizinhança, seja ela de Moore (8 células adjacentes), Von Neumann (4 células) ou geométrica hexagonal, é determinante para a precisão do modelo. A interação entre células vizinhas captura a contiguidade do fenômeno, permitindo que o sistema replique padrões de agregação e dispersão, fundamentais para representar processos de expansão ou retração de manchas de uso do solo.

Dessa forma, a modelagem baseada em AC transcende a mera extrapolação estatística. Ao incorporar a dimensão espacial explícita e as interações de vizinhança validadas tanto pela teoria clássica quanto por implementações computacionais robustas (Antunes, 2021; Hojati & Robertson, 2020), essa metodologia se estabelece



como a estrutura ideal para realizar a alocação espacial das mudanças em modelos híbridos.

2.5 REDES NEURAIS ARTIFICIAIS (RNA)

Enquanto os Autômatos Celulares, abordados anteriormente, são responsáveis pela alocação espacial das mudanças, as Redes Neurais Artificiais (RNA) desempenham papel central na calibração dos modelos híbridos, ao estimar o potencial de transição de cada célula da paisagem. As RNA são modelos computacionais inspirados na arquitetura do sistema nervoso biológico, compostos por unidades interconectadas capazes de aprender relações complexas e generalizar padrões a partir de dados de entrada (Omrani et al., 2017; Silva & Paixão, 2020).

Na modelagem de mudanças de uso e cobertura do solo (LULC), as RNA são utilizadas para mapear a relação não linear entre as transições observadas e as variáveis explicativas (drivers) que condicionam essas alterações. Conforme salientado por Omrani et al. (2017), diferentemente dos métodos estatísticos tradicionais, como a regressão logística, as redes neurais não exigem pressupostos de normalidade e apresentam elevada robustez frente à não linearidade e à colinearidade dos dados espaciais, características típicas de sistemas territoriais complexos.

O algoritmo mais amplamente empregado para essa finalidade, e implementado no complemento MOLUSCE, é o Perceptron Multicamadas (Multilayer Perceptron – MLP), treinado por retropropagação do erro (backpropagation). Essa arquitetura organiza-se em uma camada de entrada, responsável pela receção das variáveis explicativas, uma ou mais camadas ocultas, onde ocorre o processamento não linear, e uma camada de saída, que estima a probabilidade de transição entre classes de uso do solo (Silva & Paixão, 2020)

O processo iterativo de aprendizagem ajusta os pesos sinápticos de modo a minimizar o erro entre os mapas simulados e os observados historicamente, permitindo a geração de superfícies de potencial de transição com elevada aderência espacial. Estudos recentes demonstram que modelos baseados em MLP superam abordagens puramente estocásticas e estatísticas na representação de padrões complexos de mudança do uso da terra (Silva & Paixão, 2020).

As limitações dos métodos tradicionais, como regressão logística e cadeias de Markov isoladas, na captura de relações não lineares e da dependência espacial, impulsionaram o desenvolvimento de abordagens híbridas que integram aprendizado de máquina e modelos dinâmicos espaciais, ampliando substancialmente a capacidade preditiva das simulações territoriais.



2.6 O PAPEL DO SENSORIAMENTO REMOTO E DAS SÉRIES TEMPORAIS DO MAPBIOMAS

A eficácia de qualquer modelo de simulação de mudanças de uso da terra depende intrinsecamente da qualidade e da consistência dos dados de entrada. Conforme apontam Carvalho et al. (2025), as técnicas de sensoriamento remoto integradas a Sistemas de Informação Geográfica (SIG) tornaram-se ferramentas indispensáveis para o monitoramento ambiental, permitindo a detecção precisa de alterações na paisagem e fornecendo a base empírica para projetar cenários futuros.

No contexto brasileiro, a heterogeneidade metodológica entre mapas históricos foi superada pelo projeto MapBiomas, que fornece séries anuais consistentes geradas na plataforma *Google Earth Engine*. Conforme descrito pelo MapBiomas Project (2024), a metodologia utiliza algoritmos de aprendizado de máquina (*Random Forest*) aplicados a imagens Landsat, garantindo uma classificação *pixel a pixel* padronizada para todo o território nacional desde 1985. A aplicabilidade desses dados para a região é validada por Vasconcelos et al. (2024), que destacam a precisão do MapBiomas para quantificar a conversão de florestas no estado do Amazonas, e por Lu et al. (2013), que utilizaram séries temporais para modelar pressões de desmatamento em territórios indígenas na Amazônia.

Além da detecção de mudanças, o sensoriamento remoto é fundamental para a compreensão das causas dessas alterações. Estudos como o de Pfaff (1999) demonstram, através de evidências de satélite e dados socioeconômicos, que o desmatamento na Amazônia é impulsionado por uma interação complexa de fatores. Isso reforça a necessidade de utilizar séries temporais robustas, como as do MapBiomas, não apenas para visualizar o passado, mas para alimentar modelos que correlacionam essas mudanças espaciais com seus vetores econômicos e sociais.

Dessa forma, a utilização do MapBiomas nesta pesquisa atende à premissa de Silva e Paixão (2020) e Pereira Lopes et al. (2024) de que a confiabilidade das simulações está atrelada à acurácia dos dados de entrada. Ao garantir a consistência temporal das classes, minimizam-se erros nas matrizes de transição, permitindo que o modelo híbrido capture as dinâmicas reais do território.

2.7 O PLUGIN MOLUSCE E O AMBIENTE QGIS

A operacionalização de modelos híbridos de mudança de uso da terra, historicamente restrita a softwares proprietários de alto custo, foi significativamente impulsionada pelo desenvolvimento de soluções integradas em ambientes de código aberto. Nesse cenário, o MOLUSCE (*Modules for Land Use Change Evaluation*) consolidou-se como uma ferramenta essencial no ecossistema QGIS. Segundo a documentação técnica da Asia Air Survey e NextGIS (2025), o plugin oferece um fluxo de trabalho unificado e intuitivo, projetado para executar desde a análise de correlação de variáveis até a simulação prospectiva de cenários complexos.



A arquitetura do MOLUSCE organiza-se em quatro etapas sequenciais, conforme detalhado por Saharan e Nehra (2025) em sua aplicação na área urbanizável de Bikaner, Índia: (1) análise estatística das variáveis explicativas (utilizando métodos como Pearson e V de Cramer); (2) cálculo das matrizes de transição de áreas; (3) modelagem do potencial de transição; e (4) simulação futura via Autômatos Celulares. A robustez dessa estrutura é corroborada por Muhammad et al. (2022), que demonstraram a eficácia do plugin no processamento de grandes volumes de dados de sensoriamento remoto (*Big Data*) para modelar dinâmicas espaço-temporais na região de Linyi, China.

A escolha desta ferramenta para a presente pesquisa justifica-se, sobretudo, pela sua implementação transparente de algoritmos de Perceptron Multicamadas (MLP). Enquanto métodos estatísticos tradicionais podem falhar em capturar a não linearidade das mudanças na Amazônia, o MOLUSCE permite, segundo Subiyanto et al. (2019), uma modelagem preditiva superior através de redes neurais artificiais.

Além da capacidade de processamento, o ambiente QGIS proporciona controle total sobre os hiperparâmetros do modelo. Diferente de abordagens "caixa-preta", é possível ajustar a taxa de aprendizado, o momento e as iterações de treinamento, permitindo uma calibração fina para as especificidades do Vale do Jamari. A validação desses modelos é facilitada pelo módulo integrado de estatísticas de concordância (Kappa), garantindo o rigor metodológico exigido em análises espaciais de alta precisão (Asia Air Survey & NextGIS, 2025; Muhammad et al., 2022).

2.8 VALIDAÇÃO DE MODELOS E MÉTRICAS DE ACURÁCIA

A confiabilidade de modelos de mudança de uso do solo depende de uma validação rigorosa que vá além da inspeção visual. Tradicionalmente, o Índice Kappa tem sido a métrica padrão para quantificar a concordância entre mapas simulados e reais Congalton e Green (2009), sendo inclusive o principal indicador de desempenho gerado automaticamente por ferramentas de modelagem consolidadas, como o plugin MOLUSCE. No entanto, a literatura recente Foody (2020) tem criticado o uso exclusivo do Kappa, argumentando que ele pode ser excessivamente otimista em paisagens onde a mudança é pequena em relação à área total (efeito da persistência), mascarando erros importantes.

Nesse contexto, métricas derivadas da matriz de confusão, como a Acurácia do Produtor (relacionada ao erro de omissão) e a Acurácia do Usuário (relacionada ao erro de comissão), tornam-se essenciais para entender onde o modelo erra. Além disso, em aplicações de aprendizado de máquina (*machine learning*), o F1-Score tem ganhado destaque. Segundo Sokolova & Lapalme (2009), o F1-Score é particularmente robusto para avaliar classes desbalanceadas, pois harmoniza a precisão e a sensibilidade do modelo em um único indicador, oferecendo um diagnóstico mais transparente do que as métricas globais convencionais.



2.9 CONSTRUÇÃO DE CENÁRIOS PROSPECTIVOS E SIMULAÇÃO

A modelagem de cenários futuros constitui uma ferramenta estratégica para o planejamento territorial, permitindo antecipar as consequências espaciais de diferentes regimes de governança e tendências socioeconômicas. Conforme destacado por Maeda et al. (2011) a construção de cenários não visa prever o futuro de forma determinística, mas explorar trajetórias plausíveis baseadas em premissas explícitas de políticas públicas e pressões antrópicas, permitindo avaliar o custo da inação e o potencial efeito de instrumentos de controle territorial.

No presente estudo, a estruturação dos cenários prospectivos segue uma abordagem amplamente utilizada na literatura de modelagem espacial para a Amazônia e o Cerrado, baseada na definição de um cenário tendencial (Business as Usual – BAU) e na aplicação de camadas de governança territorial que representam diferentes níveis de efetividade da legislação ambiental (Novoa Garzon et al., 2022; Ramos et al., 2024; Soares-Filho et al., 2005).

O cenário BAU representa a continuidade das dinâmicas recentes de conversão do uso da terra, refletindo o padrão observado no período histórico de calibração do modelo. Este cenário funciona como linha de base e corresponde ao que (Soares-Filho et al., 2005) descrevem como um regime de proteção passiva, no qual a mera existência legal de áreas protegidas não é suficiente para conter a expansão antrópica em regiões de fronteira ativa.

A partir desse cenário-base, são derivados cenários alternativos de governança, nos quais o mesmo padrão de pressão territorial é submetido a diferentes níveis de restrição espacial, permitindo isolar e quantificar o efeito potencial dos instrumentos de proteção ambiental. Essa abordagem é conceitualmente equivalente à utilização de “policy layers” proposta por Picoli et al. (2020), em que o território é filtrado por camadas normativas que condicionam onde a conversão pode ou não ocorrer.

Nesse contexto, além das Unidades de Conservação e Terras Indígenas, o principal instrumento normativo de ordenamento ambiental no espaço rural brasileiro é o Cadastro Ambiental Rural (CAR), instituído pela Lei nº 12.651/2012 (Código Florestal). O CAR constitui um registro georreferenciado dos imóveis rurais, no qual são espacializadas as Áreas de Preservação Permanente (APP), as Reservas Legais (RL) e as áreas consolidadas de uso produtivo, funcionando como uma camada operacional de governança territorial (Castro & Castro, 2022; Soares-Filho et al., 2005).

Assim, a incorporação de APP e RL derivadas do CAR em modelos de simulação espacial permite traduzir o arcabouço jurídico do Código Florestal em restrições territoriais explícitas, possibilitando avaliar como diferentes graus de efetividade da legislação ambiental podem alterar as trajetórias projetadas de mudança do uso da terra no Vale do Jamari.



2.10 ORDENAMENTO TERRITORIAL, INSTRUMENTOS LEGAIS E MODELAGEM ESPACIAL DO USO DA TERRA

O uso e a cobertura da terra em regiões de fronteira agrícola, como a Amazônia e o sudoeste da Amazônia Legal, não são determinados apenas por fatores biofísicos e econômicos, mas também por um conjunto de normas jurídicas e instrumentos de governança que condicionam, em maior ou menor grau, onde a conversão do solo pode ocorrer. Nesse contexto, o ordenamento territorial ambiental no Brasil estrutura-se principalmente por meio do Sistema Nacional de Unidades de Conservação, das Terras Indígenas (TI) e do Código Florestal, que definem zonas legalmente protegidas ou submetidas a regras específicas de uso.

O Código Florestal Brasileiro (Lei nº 12.651/2012) estabelece duas categorias fundamentais de proteção no interior dos imóveis rurais: as Áreas de Preservação Permanente (APP) e as Reservas Legais (RL). As APPs são áreas destinadas à proteção de recursos hídricos, estabilidade geomorfológica e biodiversidade, enquanto as RLs correspondem a uma proporção mínima da propriedade que deve ser mantida com cobertura de vegetação nativa. Ambas constituem restrições legais diretas à conversão do uso do solo, embora sua efetividade dependa do grau de implementação e fiscalização.

A operacionalização espacial dessas obrigações legais é realizada por meio do Cadastro Ambiental Rural (CAR), um registro público eletrônico e georreferenciado no qual todos os imóveis rurais devem declarar os limites da propriedade, as APPs, as RLs e as áreas consolidadas. Dessa forma, o CAR funciona como uma base de dados territorial que traduz o arcabouço jurídico do Código Florestal em informações espaciais, permitindo identificar, mapear e analisar as áreas sujeitas a restrições legais de uso da terra.

Na literatura sobre modelagem de mudança do uso e cobertura do solo, instrumentos legais e áreas protegidas são frequentemente incorporados por meio de camadas de restrição ou exclusão espacial. Essas camadas representam zonas onde determinadas transições são proibidas ou limitadas, como Unidades de Conservação (UC), Terras Indígenas, APPs e outras áreas legalmente protegidas. Modelos amplamente utilizados, como CLUE-S, Dyna-CLUE, DINAMICA EGO e diferentes implementações de autômatos celulares, empregam esse tipo de abordagem para integrar políticas territoriais e normas ambientais às simulações espaciais de longo prazo (Silva & Paixão, 2020; Trentin & Castreghini De Freitas, 2010).

O uso de camadas de restrição permite avaliar não apenas tendências de expansão do uso da terra, mas também o efeito potencial de diferentes regimes de governança sobre essas tendências. Ao comparar um cenário tendencial, no qual as dinâmicas históricas são projetadas sem restrições adicionais, com cenários nos quais áreas legalmente protegidas são explicitamente bloqueadas à conversão, torna-se possível quantificar o papel da legislação ambiental e das áreas protegidas na contenção do avanço da fronteira agrícola (Picoli et al., 2020).



Nesse sentido, Picoli et al (2020) demonstraram que a incorporação de Unidades de Conservação, Terras Indígenas, APPs e Reservas Legais em modelos de simulação espacial não representa apenas uma escolha técnica, mas a tradução cartográfica de instrumentos de política pública e de ordenamento territorial. Essa abordagem permite que cenários prospectivos deixem de ser meras extrapolações estatísticas e passem a refletir diferentes graus de efetividade da governança ambiental, fornecendo subsídios para a avaliação de riscos, conflitos territoriais e impactos ambientais em escalas regionais.

2.11 SÍNTESE E DIRECIONAMENTOS TEÓRICOS DA PESQUISA

A revisão da literatura evidencia que, embora existam vastos estudos sobre o desmatamento na Amazônia, há uma lacuna na aplicação de modelos preditivos que combinem a robustez não-linear das Redes Neurais com a espacialidade dinâmica dos Autômatos Celulares em escalas regionais específicas, como a do Vale do Jamari. Observa-se que abordagens estritamente estocásticas muitas vezes falham em capturar os vetores socioeconômicos complexos, da mesma forma que modelos determinísticos simples não conseguem representar adequadamente a morfologia espacial das mudanças. Esta dissertação propõe enfrentar essa limitação por meio de uma abordagem híbrida (AC-RNA). A premissa teórica central é a de que o padrão de mudança no Vale do Jamari não é aleatório, mas sim o resultado de uma função complexa aprendida pela Rede Neural, a qual é projetada no espaço e no tempo pelas regras de vizinhança dos Autômatos Celulares. Ao integrar dados históricos consistentes do MapBiomas com variáveis explicativas biofísicas e de infraestrutura no ambiente MOLUSCE, a pesquisa não busca apenas prever o futuro passivamente, mas fornecer cenários espacialmente explícitos que sirvam de base para a tomada de decisão e para a mitigação dos vetores de degradação ambiental na região.

Diante do exposto, este referencial teórico orienta diretamente as escolhas metodológicas desta dissertação. Em termos operacionais, a modelagem será conduzida com um arranjo híbrido AC-RNA no ambiente MOLUSCE/QGIS, no qual: as Cadeias de Markov quantificam as probabilidades de transição observadas no período de calibração; a Rede Neural aprende relações não lineares entre os drivers e as transições efetivamente observadas; e o Autômato Celular realiza a alocação espacial das mudanças, incorporando dependência de vizinhança.

A variável dependente será derivada das séries anuais do MapBiomas, permitindo calibrar o modelo com mapas de 2014 para 2018 e validar sua capacidade preditiva ao comparar a simulação de 2022 com o mapa de referência do mesmo ano. Os *drivers* serão representados por variáveis físicas e de acessibilidade (topografia e distâncias a elementos estruturantes), alinhadas à literatura de fronteiras agrícolas amazônicas. A avaliação de desempenho utilizará métricas globais (Acurácia Global e Kappa e suas decomposições) e métricas por classe (Acurácia do Produtor/Usuário e F1-score), de modo a evitar diagnósticos baseados apenas em concordância global.



Por fim, a construção de cenários prospectivos será estruturada a partir de um cenário tendencial (BAU) e de cenários alternativos com camadas de governança (UC/TI, APP e RL), aplicadas como restrições espaciais explícitas. Assim, o Capítulo 3 descreve o fluxo completo de dados, o pré-processamento, o treinamento/validação do MLP e a operacionalização dos cenários, garantindo rastreabilidade e reprodutibilidade das decisões metodológicas.



3 METODOLOGIA

Este capítulo descreve os dados utilizados, os procedimentos de pré-processamento e a abordagem de modelagem aplicada para simular as mudanças de uso e cobertura do solo no Vale do Jamari. A Figura 1 apresenta uma visão geral das principais etapas metodológicas adotadas.




Figura 1 - Fluxograma da metodologia de modelagem das mudanças de uso e cobertura do solo no Vale do Jamari (RO)

3.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área de estudo compreende o Território Vale do Jamari, situado na porção norte do estado de Rondônia e inserido no bioma Amazônia. Instituído oficialmente em 2008 como parte de uma estratégia governamental para promover o desenvolvimento territorial focado na agricultura familiar e na melhoria da qualidade de vida local, o território abrange uma área total de 31.749 km² (O. F. de Oliveira et al., 2011), conforme ilustrado na Figura 1.



Administrativamente, a região é composta por nove municípios: Alto Paraíso, Ariquemes, Buritis, Cacaulândia, Campo Novo de Rondônia, Cujubim, Machadinho d'Oeste, Monte Negro e Rio Crespo. Ariquemes atua como o principal polo econômico e demográfico, polarizando os serviços e a logística regional (O. F. de Oliveira et al., 2011).

Do ponto de vista socioeconômico, a matriz produtiva do Vale do Jamari é baseada predominantemente na agropecuária, com destaque para a pecuária de corte e leite, a extração madeireira, a mineração (cassiterita) e a piscicultura, setor em que a região se destaca nacionalmente (V. B. V. de Oliveira, 2007).

Nos últimos anos, o território tem sido palco de uma intensa dinâmica de antropização. O padrão histórico de ocupação, inicialmente marcado pelo desmatamento para formação de pastagens, vem sendo reconfigurado pela expansão da agricultura comercial mecanizada (V. B. V. de Oliveira, 2007). O avanço do cultivo de *commodities* como soja, milho e arroz tem transformado significativamente a paisagem local, acelerando a conversão de áreas florestais remanescentes e pressionando as zonas de transição. Esse cenário de rápidas mudanças no uso e cobertura do solo torna o Vale do Jamari uma área crítica para a aplicação de modelos de simulação espacial (V. B. V. de Oliveira, 2007).




Figura 2 - Mapa de Localização, Território Vale do Jamari, Rondônia



3.2 AMBIENTE COMPUTACIONAL E SOFTWARES

O processamento dos dados, a modelagem espacial e a validação estatística foram realizadas integralmente em uma estação de trabalho de alto desempenho, equipada com processador AMD Ryzen, 32GB de memória RAM e placa gráfica NVIDIA GeForce RTX 4070 Super (12GB VRAM), rodando sobre o sistema operacional Windows 11 Pro. Essa configuração de hardware foi essencial para garantir a eficiência no processamento matricial das bases de dados.

O ambiente de Sistemas de Informação Geográfica (SIG) utilizado foi o software QGIS, na versão 3.40.12 'Bratislava'. A simulação de mudanças de uso do solo foi executada através do complemento MOLUSCE (Modules for Land Use Change Evaluation), versão 5.1.0, desenvolvido pela NextGIS. Este plugin oferece um fluxo de trabalho unificado que abrange desde a análise de correlação de variáveis até o treinamento de Redes Neurais Artificiais e a projeção de cenários futuros.

Para o pós-processamento dos resultados tabulares e o cálculo de métricas de validação complementares (como o F1-Score e as acurácias do produtor e do usuário), utilizou-se o software Microsoft Excel 2021.

3.3 BASE DE DADOS E VARIÁVEIS ESPACIAIS

A construção do banco de dados geoespaciais integrou produtos de sensoriamento remoto e bases vetoriais oficiais, os quais foram previamente harmonizados quanto ao formato, escala e sistema de referência espacial. Todas as camadas foram padronizadas no Sistema de Referência de Coordenadas SIRGAS 2000 / UTM Zona 20S, assegurando a correta sobreposição espacial, consistência geométrica e precisão métrica nas análises subsequentes.

Tabela 1 - Fontes de dados geoespaciais utilizadas na modelagem do uso e cobertura do solo

Dados	Resolução/Escala	Fonte	Formato	Data Aquisição
Uso e cobertura do solo (2014, 2018, 2022)	30 m	MapBiomass Coleção 8	Raster	13/12/2025
Estradas	—	IBGE + Google Earth/Planet	Vetorial	14/12/2025
Áreas urbanas	1:250.000	IBGE	Vetorial	14/12/2025
Hidrografia	1:25.000	SEDAM-RO	Vetorial	14/12/2025
Assentamentos rurais	—	INCRA	Vetorial	14/12/2025
Unidades de Conservação e Terras Indígenas	—	SEDAM-RO	Vetorial	14/12/2025
Modelo Digital de Elevação	30 m	Copernicus DEM	Raster	14/12/2025

Fonte: Elaborado pelo autor (2026)

Os dados utilizados foram organizados em três grandes categorias, descritas detalhadamente nas subseções a seguir.



3.3.1 USO E COBERTURA DO SOLO (VARIÁVEL DEPENDENTE)

Para a análise da dinâmica espaço-temporal do uso e cobertura do solo, foram utilizados os mapas anuais da Coleção 8 do Projeto MapBiomas, que apresentam resolução espacial nativa de 30 metros. Foram selecionados três recortes temporais considerados estratégicos para os objetivos do estudo:

- **Anos de 2014 e 2018:** empregados na etapa de calibração do modelo, incluindo o treinamento da Rede Neural Artificial (RNA) e o cálculo da matriz de transição de probabilidades;
- **Ano de 2022:** utilizado exclusivamente para a etapa de validação estatística, servindo como base de referência para a comparação entre os mapas observados e os mapas simulados pelo modelo.

O mapeamento do MapBiomas disponibiliza uma legenda detalhada composta por 13 classes temáticas para a área de estudo. Com o objetivo de reduzir interferências espectrais, minimizar confusões temáticas entre subclasses com assinaturas semelhantes e aumentar a robustez do processo de modelagem, procedeu-se à reclassificação temática dessas classes. As 13 classes originais foram agregadas em 6 classes finais, utilizadas de forma consistente em todas as etapas da pesquisa (calibração, simulação e validação): Vegetação Nativa, Pastagem, Agricultura, Água, Urbano/Outras e Mineração.

Tabela 2 - Reclassificação das classes do MapBiomas (13) em classes agregadas (6) utilizadas no modelo

Classes Agregadas	Classes MapBiomas agrupadas
Vegetação Nativa	Formação Florestal; Formação Savânica; Floresta Alagável; Campo Alagado e Área Pantanosa; Afloramento Rochoso
Pastagem	Pastagem; Formação Campestre
Agricultura	Soja; Outras Lavouras Temporárias
Água	Rio, Lago e Oceano; Aquicultura
Urbano/Outras	Área Urbanizada; Outras Áreas não Vegetadas
Mineração	Mineração

Fonte: Elaborado pelo autor (2026)

3.3.2 VARIÁVEIS DE INFRAESTRUTURA E ACESSO

- **Estradas:** variável representada pela distância euclidiana à malha viária. A base oficial foi obtida junto ao IBGE; entretanto, visando reduzir incertezas associadas à omissão de vias secundárias, essa base foi refinada por meio da vetorização manual de estradas vicinais e carregadores não representados no mapeamento oficial. Para esse procedimento, utilizaram-se imagens de alta resolução disponíveis na



plataforma Google Earth, bem como mosaicos mensais da constelação Planet.

- **Áreas Urbanizadas:** corresponde à distância euclidiana até os núcleos urbanos consolidados (sedes municipais e distritos), cujos perímetros foram delimitados a partir da base vetorial oficial do IBGE.

3.3.3 HIDROGRAFIA

- **Rios:** variável expressa pela distância euclidiana aos cursos d'água da rede de drenagem. A base vetorial foi obtida junto à Secretaria de Estado do Desenvolvimento Ambiental de Rondônia (SEDAM-RO), elaborada na escala de 1:25.000, o que confere elevado nível de detalhamento e maior confiabilidade à representação da hidrografia regional. Essa variável contínua considera todos os canais de drenagem, incluindo cursos de menor ordem, sendo empregada como fator explicativo da dinâmica espacial de conversão do uso e cobertura do solo.
- **Água:** camada binária que representa os corpos d'água permanentes, composta por rios de maior porte, reservatórios de usinas hidrelétricas e áreas destinadas à aquicultura, incluindo empreendimentos abastecidos por sistemas de bombeamento. Diferentemente da variável Distância de Rios, esta camada não atua como variável explicativa contínua, mas como uma restrição espacial explícita, cujo objetivo é impedir a ocorrência de transições indevidas entre a classe Água e as demais classes de uso e cobertura do solo durante a simulação.

A adoção da camada Água como variável binária visa assegurar a coerência física e funcional do modelo, evitando a conversão artificial de corpos hídricos em classes terrestres, um efeito frequentemente observado em simulações de mudança de uso do solo quando tais áreas não são explicitamente bloqueadas. Dessa forma, garante-se que, ao longo do processo de simulação, os corpos d'água possam permanecer estáveis ou ser ampliados, quando permitido pelas regras do modelo, mas não sejam convertidos para usos incompatíveis.

3.3.4 RESTRIÇÕES LEGAIS E FUNDIÁRIAS

- **Unidades de Conservação e Terras Indígenas (UCs e TI):** distância até áreas legalmente protegidas, incluindo Unidades de Conservação de proteção integral e uso sustentável, bem como Terras Indígenas homologadas. Os limites vetoriais dessas áreas foram obtidos no banco de dados oficial da SEDAM-RO.
- **Assentamentos:** distância até projetos de assentamento rural, reconhecidos como áreas historicamente associadas à dinâmica de conversão do uso da terra. Os perímetros dos assentamentos foram obtidos junto ao acervo fundiário do Instituto Nacional de Colonização e Reforma Agrária (INCRA).



Ressalta-se que, embora o Cadastro Ambiental Rural (CAR) e suas componentes de Áreas de Preservação Permanente (APP) e Reserva Legal (RL) desempenhem papel central na governança territorial, conforme discutido na Seção 2.10, optou-se por utilizá-los exclusivamente na etapa de simulação de cenários (Seção 3.7), atuando como camadas de restrição espacial, e não como variáveis explicativas da dinâmica pretérita. Tal decisão metodológica fundamenta-se na heterogeneidade temporal dos registros do CAR ao longo do período de calibração (2014–2018), a qual poderia introduzir incertezas e ruídos indesejáveis no treinamento da Rede Neural Artificial.

3.3.5 TOPOGRAFIA

As variáveis topográficas e morfométricas foram derivadas do Modelo Digital de Elevação (MDE) global Copernicus DEM GLO-30, com resolução espacial de 30 metros. A escolha desse produto, em detrimento de modelos amplamente utilizados como o SRTM (Shuttle Radar Topography Mission), justifica-se por sua maior atualidade, melhor consistência espacial e maior acurácia vertical.

Em regiões amazônicas, modelos derivados de missões de radar mais antigas tendem a superestimar a elevação do terreno devido à interação do sinal nas bandas C e X com o dossel florestal. Considerando que a área de estudo passou por intenso processo de desmatamento nas últimas décadas, o uso de um MDE mais recente contribui para reduzir erros altimétricos em áreas convertidas para pastagem ou agricultura, representando de forma mais fidedigna a morfologia atual da superfície terrestre. Reconhece-se, contudo, que o Copernicus DEM não corresponde a um modelo de terreno puro, podendo ainda refletir influência residual da cobertura vegetal, o que constitui uma limitação inerente às variáveis topográficas derivadas.

A partir do MDE, foram obtidas as seguintes variáveis:

- **Altimetria (DEM):** representa a elevação do terreno em relação ao nível médio do mar;
- **Declividade:** variável derivada diretamente do MDE, fundamental para a avaliação da aptidão agrícola, distinguindo áreas mecanizáveis de terrenos com relevo mais acidentado. O processamento foi realizado no software QGIS, utilizando o algoritmo *Slope* da biblioteca GDAL, com os valores expressos em porcentagem (%).

3.3.6 LIMITES ADMINISTRATIVOS

- **Limite do Vale do Jamari:** camada vetorial correspondente à delimitação oficial do território, utilizada como máscara de recorte (*clip*) para todas as camadas do projeto. Essa geometria foi gerada a partir da agregação espacial (*dissolve*) dos polígonos municipais que compõem o território, obtidos a partir da base oficial de limites municipais do IBGE



3.4 PROCEDIMENTOS METODOLÓGICOS

A abordagem metodológica adotada baseia-se na integração de técnicas de sensoriamento remoto e modelagem estocástica de mudanças de uso da terra. O fluxo de trabalho foi estruturado em quatro etapas sequenciais: pré-processamento e harmonização dos dados; análise da dinâmica temporal e multicolinearidade; treinamento da rede neural e configuração do modelo; validação e calibração do modelo.

3.4.1 PREPARAÇÃO E ORGANIZAÇÃO DOS DADOS

Os mapas de uso e cobertura do solo referentes aos anos de 2014, 2018 e 2022, bem como os fatores de influência de natureza físico-ambiental e antrópica, foram previamente harmonizados quanto à resolução espacial, sistema de referência cartográfica e extensão geográfica, assegurando a compatibilidade entre os diferentes conjuntos de dados utilizados no estudo.

Para viabilizar a álgebra de mapas e o processamento matricial no complemento MOLUSCE, foi realizada uma padronização rigorosa de todas as camadas espaciais. O mapa de uso e cobertura do solo do ano de 2014, proveniente do projeto MapBiomass, foi adotado como camada de referência. Esse mapa foi submetido a recorte espacial a partir da delimitação vetorial do Território do Vale do Jamari, sendo utilizado como base para a definição da extensão geográfica, do alinhamento da grade e do sistema de coordenadas de todo o projeto.

O pré-processamento das variáveis explicativas seguiu um fluxo padronizado. Inicialmente, os dados originalmente em formato vetorial foram convertidos para o formato raster, utilizando o mapa de 2014 como gabarito, de modo a garantir que os pixels resultantes apresentassem dimensões, alinhamento e resolução idênticos à base de referência.

Especificamente para a camada *Água*, que representa os corpos d'água permanentes (rios de maior porte, reservatórios, áreas de aquicultura), a base vetorial obtida foi rasterizada e convertida em uma camada binária. Nesta camada, os pixels correspondentes a corpos d'água foram atribuídos com um valor 1 e as áreas terrestres ou sem água com outro valor 0. Este processo garantiu que a camada *Água* pudesse ser utilizada posteriormente como uma restrição espacial explícita, bloqueando a ocorrência de transições de classes de uso e cobertura do solo em áreas hídricas durante a simulação.

Na sequência, sobre as camadas previamente rasterizadas, foi aplicado o algoritmo de proximidade *Distância Raster* disponível no software QGIS, gerando mapas contínuos de distância euclidiana. Esses mapas representam o afastamento de cada pixel em relação ao elemento de interesse mais próximo, sendo amplamente utilizados como variáveis explicativas em modelos de mudança de uso e cobertura do solo.



Por fim, assegurou-se que todas as camadas resultantes, tanto as variáveis dependentes quanto as independentes, apresentassem o mesmo Sistema de Referência de Coordenadas (SIRGAS 2000 / UTM Zona 20S) e resolução espacial de 30 metros, garantindo o alinhamento pixel a pixel requerido para o treinamento da rede neural artificial.

3.4.2 PARTICIONAMENTO ESPACIAL PARA TREINAMENTO E VALIDAÇÃO

Com o objetivo de reduzir os efeitos da autocorrelação espacial e garantir a independência entre as etapas de calibração e avaliação do modelo, foi adotada uma estratégia de particionamento espacial da área de estudo. Para tal, a área total foi subdividida por meio de uma grade regular, cujas células foram selecionadas aleatoriamente, destinando-se 70% da área ao conjunto de treinamento e 30% ao conjunto de validação espacial independente.

As máscaras espaciais resultantes desse procedimento foram aplicadas de forma consistente aos mapas de uso e cobertura do solo dos anos de 2014, 2018 e 2022, bem como a todos os fatores de influência, originando conjuntos de dados espacialmente independentes para treinamento e validação do modelo.

A representação cartográfica do particionamento espacial permite verificar visualmente a distribuição aleatória das células destinadas ao treinamento e à validação, reduzindo potenciais vieses associados à autocorrelação espacial. A Figura 3 ilustra a divisão da área de estudo em células de treinamento e validação, evidenciando a independência espacial entre os dois conjuntos de dados utilizados no modelo.




Figura 3 - Particionamento espacial da área de estudo em conjuntos de treinamento (a) e validação (b)



O mapa (a) representa as células selecionadas para o treinamento do modelo (70% da área), enquanto o mapa (b) corresponde às células destinadas à validação espacial independente (30% da área).

3.4.3 ANÁLISE DA DINÂMICA TEMPORAL E MULTICOLINEARIDADE

Para compreender os padrões de mudança no uso e cobertura do solo, procedeu-se ao cálculo da Matriz de Transição entre os anos de 2014 e 2018. Esse procedimento permitiu quantificar as áreas que permaneceram em sua classe original, representadas pela diagonal principal da matriz, bem como aquelas que migraram para outras categorias ao longo do período analisado, fornecendo subsídios para a modelagem das transições espaciais.

Previamente à etapa de modelagem preditiva, avaliou-se a relação de dependência entre as variáveis explicativas, com o objetivo de identificar possíveis redundâncias associadas à multicolinearidade. Embora redes neurais artificiais apresentem maior tolerância à correlação entre variáveis quando comparadas a modelos lineares tradicionais, a presença de fatores altamente correlacionados pode influenciar a estabilidade dos pesos aprendidos e dificultar a interpretação dos resultados.

Considerando que todas as variáveis preditoras utilizadas são de natureza numérica contínua, como mapas de distância euclidiana e dados topográficos, foi aplicado o Coeficiente de Correlação de Pearson (r), expresso pela Equação (X):

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}}$$

onde x e y representam os valores de pixel correspondentes a dois rasters distintos. A análise da matriz de correlação foi realizada com o auxílio do plugin MOLUSCE, permitindo identificar pares de variáveis com elevado grau de associação linear.

O critério de avaliação seguiu a literatura estatística clássica, segundo a qual coeficientes de correlação elevados, próximos de 1 ou -1, indicam potencial redundância entre variáveis. De acordo com Dormann et al. (2013), valores superiores a 0,7 podem ser considerados críticos em estudos ambientais, justificando a exclusão ou substituição de uma das variáveis.

Conforme apresentado na Tabela 2, todas as correlações observadas entre os fatores de influência permaneceram abaixo desse limiar. O maior coeficiente registrado foi de 0,541 entre as variáveis 'Assentamentos' e 'UCs e TI', valor que não caracteriza multicolinearidade severa. Dessa forma, optou-se pela manutenção de todas as variáveis explicativas no treinamento da rede neural artificial.



Tabela 3 - Matriz de correlação de Pearson entre as variáveis explicativas

	Água	Assentamentos	Declividade	DEM (Altitudes)	Estradas	Rios	UCs e TI	Área Urbanizadas
Água	--	0,021	-0,020	-0,076	-0,003	-0,060	0,001	-0,022
Assentamentos		--	0,078	-0,001	0,205	0,055	0,541	0,077
Declividade			--	0,377	-0,010	0,017	0,154	-0,006
DEM (Altitudes)				--	0,140	0,113	0,280	-0,007
Estradas					--	-0,025	-0,090	0,265
Rios						--	0,011	-0,017
UCs e TI							--	0,008
Área Urbanizadas								--

Fonte: Elaborado pelo autor com base nos dados do processamento (2026)

Para a variável 'Água', embora de natureza binária, o coeficiente de correlação de Pearson foi calculado para avaliar sua associação linear com as demais variáveis contínuas, sendo interpretado como um coeficiente de correlação ponto-bisserial.

Além da verificação da colinearidade entre as variáveis explicativas, esta etapa metodológica resultou na geração da Matriz de Probabilidades de Transição. Essa matriz constitui a base empírica da modelagem estocástica, na qual cada elemento expressa a probabilidade de um pixel pertencente a uma determinada classe de uso e cobertura do solo no ano inicial (2014) permanecer na mesma categoria ou transitar para outra classe no ano final (2018).

O cálculo das probabilidades de transição baseou-se na sobreposição espacial dos mapas de uso e cobertura do solo reclassificados, permitindo quantificar tanto a estabilidade de cada classe quanto as direções preferenciais de conversão entre as seis classes adotadas no estudo. A matriz resultante, de dimensão 6 × 6, foi utilizada como base empírica nas etapas subsequentes de treinamento do modelo e de simulação das mudanças de uso e cobertura do solo.

Concomitantemente ao cálculo das probabilidades de transição, foi gerado o Mapa de Alterações de Uso do Solo, produto cartográfico que espacializa as transições ocorridas entre 2014 e 2018, atribuindo identificadores únicos para cada tipo de mudança observada no território. A geração desse mapa constitui uma etapa mandatória no fluxo de processamento do plugin MOLUSCE, uma vez que é a partir dele que o algoritmo extrai as amostras espaciais necessárias para o treinamento da rede neural artificial.

Esse procedimento permite ao modelo associar as mudanças efetivamente observadas no período de calibração às condições locais representadas pelas variáveis explicativas, estabelecendo a relação entre os padrões espaciais de conversão e os fatores de influência considerados.



3.5 TREINAMENTO E CALIBRAÇÃO DA REDE NEURAL ARTIFICIAL

A modelagem do potencial de transição foi realizada por meio de Redes Neurais Artificiais (RNA), utilizando o algoritmo Multi-layer Perceptron (MLP), implementado no complemento MOLUSCE do software QGIS. O treinamento da rede foi conduzido exclusivamente sobre o subconjunto espacial destinado ao treinamento, correspondente a 70% da área de estudo, conforme o particionamento espacial descrito na Seção 3.4.1.1, assegurando a independência espacial entre as etapas de calibração e validação do modelo.

A extração das amostras espaciais foi realizada por meio de amostragem estratificada, onde os 20.000 pixels foram selecionados de forma a garantir a representação proporcional de todas as classes de uso e cobertura do solo e de cada um dos tipos de transição observados entre 2014 e 2018. Essa estratégia, ao evitar a sub-representação de classes e transições menos frequentes, permitiu que a rede neural aprendesse de forma mais equilibrada, reduzindo vieses associados ao desbalanceamento amostral.

A configuração da topologia da rede neural seguiu uma abordagem empírica, fundamentada na literatura especializada sobre modelagem espacial de mudanças de uso da terra. A arquitetura adotada buscou capturar a natureza não linear e multiescalar das transições, comuns em paisagens fortemente antropizadas. A influência do contexto espacial foi incorporada por meio da definição de uma vizinhança com raio de 1 pixel, equivalente a uma janela móvel de 3×3 células, correspondendo a uma vizinhança de Moore expandida. Essa configuração permite considerar não apenas o entorno imediato, mas também padrões espaciais de maior alcance, sendo recomendada para processos difusos e cumulativos, como a expansão agropecuária e a conversão progressiva da cobertura vegetal ((Hojati & Robertson, 2020; Muhammad et al., 2022)

A definição dos hiperparâmetros da Rede Neural Artificial seguiu um processo iterativo de ajuste empírico, conduzido a partir dos parâmetros disponíveis no complemento MOLUSCE, incluindo taxa de aprendizado, número máximo de iterações e parâmetro de momento. Embora o ambiente não disponha de rotinas automáticas de otimização ou de análise formal de sensibilidade global, diferentes combinações desses parâmetros foram testadas de forma sistemática durante a fase de calibração, avaliando-se seu impacto sobre o erro global, o índice Kappa interno e a estabilidade espacial dos padrões simulados. A configuração final adotada correspondeu àquela que apresentou o melhor compromisso entre desempenho estatístico e coerência espacial das transições simuladas.

O processo de aprendizagem foi conduzido com uma taxa de aprendizagem (learning rate) de 0,001 e um número máximo de 1.500 iterações. A escolha por uma taxa de aprendizado conservadora visou garantir a estabilidade do processo iterativo e favorecer a convergência gradual do erro global, reduzindo o risco de oscilações abruptas e de aprisionamento em mínimos locais, em consonância com as



recomendações da documentação técnica do MOLUSCE (Asia Air Survey & NextGIS, 2025)

O treinamento foi limitado a um número máximo de 1.500 iterações. Durante esse processo, o erro global e o índice Kappa de validação interna fornecidos pelo algoritmo foram monitorados, oferecendo uma perspectiva contínua sobre o desempenho da rede. Ao final do processo de calibração, o modelo apresentou um índice Kappa interno de aproximadamente 0,81, indicando capacidade robusta de ajuste aos padrões de transição observados no período de calibração (2014–2018). Ressalta-se que esse valor reflete exclusivamente o desempenho interno do modelo durante o treinamento, não devendo ser interpretado como medida definitiva de capacidade preditiva.

A avaliação da capacidade de generalização espacial do modelo foi realizada posteriormente por meio de validação espacial independente, utilizando o subconjunto de 30% da área de estudo reservado para teste, conforme descrito na Seção 3.4.1.1. Essa abordagem permite estimar de forma mais realista o desempenho preditivo do modelo, reduzindo os efeitos da autocorrelação espacial frequentemente associados a validações internas.

Embora a Regressão Logística seja amplamente utilizada como método de referência em estudos de mudança de uso e cobertura do solo (Hu & Lo, 2007), optou-se por não implementá-la neste trabalho. A escolha exclusiva pelo uso de Redes Neurais Artificiais fundamenta-se em sua reconhecida capacidade de capturar relações não lineares e interações complexas entre variáveis explicativas, superando as limitações dos modelos lineares tradicionais em paisagens heterogêneas e fragmentadas, conforme discutido na revisão de literatura (Esteves et al., 2024; Gharaibeh et al., 2020)

3.6 VALIDAÇÃO DO MODELO

A validação do modelo foi concebida com o objetivo de avaliar sua capacidade de generalização espacial e temporal. O modelo de potencial de transição foi treinado a partir das transições observadas no período de 2014 a 2018, utilizando 70% da área de estudo, incluindo os respectivos drivers espaciais associados. Esse modelo calibrado foi posteriormente aplicado a um subconjunto espacial independente, correspondente aos 30% restantes da área, previamente reservado para teste. Para essa etapa, os drivers espaciais referentes exclusivamente à área de teste foram utilizados conforme o mesmo particionamento adotado no treinamento.

A partir dessa configuração, o modelo foi empregado para simular as mudanças de uso e cobertura do solo no intervalo de 2018 a 2022, restritas à área de teste. O procedimento de validação consistiu na comparação entre o mapa simulado de uso e cobertura do solo para o ano de 2022 e o mapa de referência observado do projeto MapBiomass para o mesmo ano, considerando exclusivamente a área de teste.



Seguindo abordagens hierárquicas amplamente empregadas na literatura de modelagem espacial, a avaliação foi estruturada em três níveis complementares: métricas globais de concordância, métricas por classe derivadas da matriz de confusão e índices compostos de desempenho.

3.6.1 MÉTRICAS GLOBAIS DE CONCORDÂNCIA

A validação do modelo de simulação de mudanças de uso e cobertura do solo foi realizada com base nas métricas globais de concordância disponibilizadas pelo módulo de validação do plugin MOLUSCE, amplamente empregado em estudos de modelagem espacial baseados em Cadeias de Markov e Autômatos Celulares (Muhammad et al., 2022). A avaliação do desempenho do modelo seguiu os princípios clássicos de análise de acurácia temática em sensoriamento remoto, fundamentados na comparação entre mapas simulados e observados por meio de matrizes de erro e índices derivados (Congalton & Green, 2009).

Foram utilizados os seguintes indicadores:

- **Acurácia Global (Overall Accuracy):** representa a proporção total de pixels corretamente classificados em relação ao total de pixels avaliados, sendo uma medida sintética da concordância geral entre os mapas.
- **Índice Kappa (Kappa Coefficient):** quantifica o grau de concordância entre os mapas simulado e observado, descontando a concordância esperada ao acaso. Embora reconhecidamente sujeito a limitações, especialmente em contextos de desbalanceamento entre classes, o índice Kappa foi utilizado de forma complementar às demais métricas, conforme prática recorrente na literatura de validação de modelos de mudança de uso da terra.

De forma adicional, o índice Kappa foi decomposto em três componentes, conforme disponibilizado pelo MOLUSCE:

- **Kappa geral (Overall):** expressa a concordância global ajustada pelo acaso;
- **Kappa de histograma (Histogram):** avalia a concordância entre as quantidades simuladas e observadas de cada classe;
- **Kappa de localização (Location):** mensura a concordância espacial associada à correta alocação das classes no território.

Esses indicadores forneceram uma visão sintética do desempenho global do modelo na simulação das mudanças de uso e cobertura do solo.



Para a interpretação qualitativa dos resultados obtidos na validação, adotou-se a escala de classificação proposta por Landis & Koch (1977). Conforme demonstrado na Tabela 4, os valores do coeficiente Kappa são categorizados em seis níveis de concordância.

Tabela 4 - Classificação dos valores de concordância para o índice Kappa

Intervalo de Kappa (κ)	Força de Concordância (<i>Strength of Agreement</i>)
< 0,00	Pobre (<i>Poor</i>)
0,00 – 0,20	Leve (<i>Slight</i>)
0,21 – 0,40	Considerável (<i>Fair</i>)
0,41 – 0,60	Moderada (<i>Moderate</i>)
0,61 – 0,80	Substancial (<i>Substantial</i>)
0,81 – 1,00	Quase Perfeita (<i>Almost Perfect</i>)

Fonte: Adaptado de Landis e Koch (1977, p. 165)

3.6.2 ANÁLISE DE DESEMPENHO POR CLASSE: MATRIZ DE CONFUSÃO

Considerando que métricas globais podem ocultar o desempenho do modelo em classes com menor representatividade espacial, foi realizada uma avaliação detalhada em nível de classe. Para isso, foi gerada uma matriz de confusão ($n \times n$, onde n representa o número de classes de uso e cobertura do solo), comparando pixel a pixel o mapa simulado para 2022 com o mapa de referência do MapBiomass 2022.

Em função das limitações do plugin MOLUSCE para exportação desagregada da matriz de confusão, este procedimento foi realizado por meio do algoritmo *r.kappa*, do provedor GRASS GIS, executado em ambiente QGIS.

3.6.3 MÉTRICAS DE ACURÁCIA POR CLASSE

A partir da matriz de confusão, foram calculadas métricas de desempenho específicas para cada classe de uso e cobertura do solo, seguindo os protocolos estabelecidos por (Congalton & Green, 2009). Foram utilizadas as seguintes métricas:

- **Acurácia do Usuário (AU_i):** relacionada ao erro de comissão, indica a confiabilidade do mapa simulado para uma determinada classe. É definida como a razão entre o número de pixels corretamente classificados na classe (x_{ii}) e o total de pixels classificados nessa classe pelo modelo (x_{i+}), conforme a equação:

$$AU_i = \left(\frac{x_{ii}}{x_{i+}} \right) \times 100$$

- **Acurácia do Produtor (AP_i):** relacionada ao erro de omissão, expressa a capacidade do modelo em identificar corretamente os pixels de uma



determinada classe presentes no mapa de referência. É definida como a razão entre o número de pixels corretamente classificados (x_{ii}) e o total de pixels dessa classe no mapa de referência (x_{+i}), conforme a equação:

$$AP_i = \left(\frac{x_{ii}}{x_{+i}} \right) \times 100$$

3.6.4 F1-SCORE COMO MÉTRICA DIAGNÓSTICA COMPLEMENTAR

Como etapa complementar da validação, foi adotado o F1-Score como métrica de síntese do desempenho por classe. Conforme discutido por Sokolova e Lapalme (2009), o F1-Score é particularmente adequado para avaliações em contextos de classes desbalanceadas, pois corresponde à média harmônica entre a precisão e a revocação, representadas, respectivamente, pela Acurácia do Usuário e pela Acurácia do Produtor.

O F1-Score foi calculado para cada classe k conforme a equação:

$$F1_k = 2 \times \frac{AU_k \times AP_k}{AU_k + AP_k} \times 100$$

onde AU_k representa a Acurácia do Usuário e AP_k a Acurácia do Produtor da classe k , expressas em percentual.

O conjunto de procedimentos descritos assegura uma validação estruturada, multiescalar e metodologicamente consistente do modelo de simulação de mudanças de uso e cobertura do solo, fornecendo subsídios quantitativos para as etapas subsequentes de análise e projeção de cenários.

3.7 SIMULAÇÃO DE CENÁRIOS FUTUROS (2030-2050)

A simulação de cenários prospectivos foi estruturada como um exercício de integração entre um modelo tendencial de mudança do uso da terra e camadas espaciais de governança territorial. Inicialmente, o modelo híbrido AC–RNA foi utilizado para gerar um cenário *Business as Usual* (BAU), projetando a continuidade das dinâmicas históricas de conversão observadas no período de calibração. A partir desse cenário-base, foram derivados cenários alternativos mediante a aplicação de camadas de restrição espacial, correspondentes a Unidades de Conservação e Terras Indígenas (UC_TI), Áreas de Preservação Permanente (APP) e Reservas Legais (RL), permitindo avaliar como diferentes níveis de efetividade da legislação ambiental poderiam alterar as trajetórias futuras de uso e cobertura do solo no Vale do Jamari.



Tabela 5 - Definição e regras de alocação dos cenários prospectivos (2030-2050)

Cenário	Descrição / objetivo	Regras de restrição espacial (máscaras)
Tendencial (BAU)	Projeta a continuidade das tendências históricas (2014–2022) sem novas intervenções.	Sem restrições adicionais.
Restrição (Proteção Institucional)	Simula o cumprimento da legislação ambiental vigente em áreas protegidas.	Bloqueio de desmatamento em Unidades de Conservação (UC) e Terras Indígenas (TI).
Restrição (Proteção Institucional + Código Florestal)	Cenário conservacionista que amplia a proteção para áreas vulneráveis.	Bloqueio de desmatamento em UC, TI, Áreas de Preservação Permanente (APP) e Reservas Legais (RL).

Fonte: Elaborado pelo autor (2026)

3.7.1 CENÁRIO TENDENCIAL (BAU)

O cenário *Business as Usual* (BAU) foi gerado diretamente no ambiente do plugin MOLUSCE para os horizontes de 2030 e 2050, mantendo-se constantes os parâmetros de transição e a matriz de probabilidade calibrada no período histórico. Este cenário pressupõe a manutenção das tendências recentes de antropização, sem a imposição de novas barreiras espaciais além daquelas já assimiladas pelo modelo durante o treinamento.

3.7.2 CONSTRUÇÃO DAS MÁSCARAS DE RESTRIÇÃO

Para a construção dos cenários alternativos, foram elaboradas máscaras binárias a partir da rasterização dos vetores oficiais, padronizados para o mesmo sistema de referência, resolução espacial (30 m) e grade de pixels dos modelos BAU. A lógica binária adotada para a álgebra de mapas foi:

- **Valor 1:** Área restrita (presença de impedimento legal à conversão).
- **Valor 0:** Área livre (sujeita à dinâmica simulada pelo modelo).

Foram definidas duas máscaras de restrição cumulativa:

- **Máscara R1 (Proteção Institucional):** Considera as restrições de Unidades de Conservação, Terras Indígenas.
- **Máscara R2 (Proteção Institucional + Código Florestal):** Incorpora as exigências de Reserva Legal e Áreas de Preservação Permanente, somando-as às restrições já existentes.

As expressões lógicas utilizadas na Calculadora Raster do QGIS para a geração das máscaras, considerando as camadas de entrada "UC_TI", "APP" e "RL" (onde pixel 1 indica presença da feição), foram:

- **Máscara R1 (UC_TI)**

$$("UC_TI@1" = 1) > 0$$

(Resultado: 1 se for área protegida, 0 se for livre)



- **Máscara R2 (UC_TI + APP + RL)**

$$((\text{"UC_TI@1"} = 1) + (\text{"APP@1"} = 1) + (\text{"RL@1"} = 1)) > 0$$

(Resultado: 1 se for área protegida/RL, 0 se for livre)

3.7.3 GERAÇÃO DOS CENÁRIOS RESTRITOS POR ÁLGEBRA DE MAPAS

Os cenários alternativos foram obtidos pela combinação condicional entre os mapas simulados (BAU) e as máscaras de restrição (R1 e R2). A premissa metodológica adotada foi o congelamento das áreas restritas: assume-se que, nos locais onde a máscara possui valor 1, a conversão de uso do solo é impedida, mantendo-se a classe original observada no ano base (LULC_2018). Nas áreas livres (valor 0), aceita-se a predição do modelo (BAU).

As operações foram executadas através das seguintes expressões na Calculadora Raster:

- **Cenário 1 – Proteção Institucional (Máscara R1)**

Para 2030: $(\text{"R1@1"} = 1) * \text{"LULC_2018@1"} + (\text{"R1@1"} \neq 1) * \text{"BAU_2030@1"}$

Para 2050: $(\text{"R1@1"} = 1) * \text{"LULC_2018@1"} + (\text{"R1@1"} \neq 1) * \text{"BAU_2050@1"}$

- **Cenário 2 – Proteção Institucional + Código Florestal (Máscara R2)**

Para 2030: $(\text{"R2@1"} = 1) * \text{"LULC_2018@1"} + (\text{"R1@1"} \neq 1) * \text{"BAU_2030@1"}$

Para 2050: $(\text{"R2@1"} = 1) * \text{"LULC_2018@1"} + (\text{"R1@1"} \neq 1) * \text{"BAU_2050@1"}$

3.7.4 SÍNTESE E JUSTIFICATIVA METODOLÓGICA

A estratégia resultou em três conjuntos de projeções para análise comparativa:

- **Cenário 0 (BAU):** Tendência histórica sem filtros adicionais.
- **Cenário 1 (R1):** Cenário de conservação focado em áreas públicas.
- **Cenário 2 (R2):** Cenário de plena implementação do Código Florestal (inclusão da Reserva Legal e Áreas de Preservação Permanentes).

Essa abordagem operacionaliza, em ambiente SIG, o conceito de camadas de governança territorial discutido por Soares-Filho et al. (2005) e Galford et al. (2015). Ao filtrar o cenário tendencial com máscaras de proteção, torna-se possível quantificar o estoque de conservação garantido pelo cumprimento da legislação. Reconhece-se, contudo, que este método atua como um filtro espacial estático e não simula o efeito de vazamento, onde a pressão de desmatamento evitada em uma área protegida poderia ser redistribuída dinamicamente para zonas adjacentes. Apesar dessa limitação, o método oferece uma métrica robusta para diferenciar o impacto territorial de diferentes regimes de gestão ambiental.



4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta e discute os resultados obtidos a partir da aplicação do modelo híbrido Autômatos Celulares – Redes Neurais Artificiais (AC-RNA) para a simulação das mudanças de uso e cobertura do solo no Território Vale do Jamari, Rondônia. Inicialmente, são analisados os padrões espaciais e quantitativos das transições observadas no período de calibração e validação do modelo. Em seguida, avalia-se o desempenho preditivo por meio de métricas globais e por classe, culminando na discussão dos cenários prospectivos simulados para o período de 2030 a 2050.

4.1 DINÂMICA ESPACIAL DO USO E COBERTURA DO SOLO NO PERÍODO HISTÓRICO

A análise da dinâmica espaço-temporal do uso e cobertura do solo no Vale do Jamari é apresentada na Figura 4, que ilustra a evolução da paisagem nos anos de 2014 (a), 2018 (b) e 2022 (c). A comparação visual evidencia a persistência da conversão de vegetação nativa em áreas antrópicas, com destaque para a consolidação da classe Pastagem (representada em amarelo) como a matriz dominante na porção antropizada, e a expansão pontual, porém crescente, da Agricultura (em rosa).

Os mapas demonstram um padrão de fragmentação florestal contínuo, onde as áreas de Vegetação Nativa (em verde) perdem conectividade, especialmente nas bordas de fragmentos maiores e ao longo dos eixos viários, refletindo a pressão histórica de ocupação da região.




Figura 4 - Mapas de uso e cobertura do solo: a) 2014, b) 2018 e c) 2022

A quantificação dessas mudanças é detalhada na matriz de transição do período de calibração (2014–2018), apresentada na Tabela 5. Os dados indicam que a maior



parte das alterações de uso ocorreu sobre a vegetação original, confirmando a continuidade do padrão de desmatamento para fins agropecuários.

Tabela 6 - Matriz de transição de probabilidade (2014–2018)

CLASSES	Vegetação Nativa	Pastagem	Agricultura	Água	Urbano e Outras	Mineração
Vegetação Nativa	0,867905	0,126585	0,002648	0,002578	0,000058	0,000227
Pastagem	0,015542	0,966412	0,016235	0,001552	0,000097	0,000162
Agricultura	0,004605	0,029135	0,961219	0,003834	0,001138	0,000068
Água	0,034934	0,016548	0,000566	0,934516	0,000163	0,013274
Urbano e Outras	0,000271	0,000197	0,000025	0,000222	0,999285	0,000000
Mineração	0,001432	0,001358	0,000110	0,037281	0,000202	0,959617

Fonte: Elaborado pelo autor (2026), a partir do software QGIS (Plugin MOLUSCE).

Observa-se que a Pastagem atuou como a principal classe receptora das transições. A probabilidade de conversão de Vegetação Nativa para Pastagem foi de 12,66% no período analisado, ratificando seu papel estrutural na organização do território. Esse resultado está em consonância com estudos recentes conduzidos na região amazônica, nos quais a pecuária extensiva é identificada como o principal vetor direto da conversão florestal, conforme destacado Vasconcelos et al. (2024) e V. C. da S. S. De Oliveira et al. (2024).

Por sua vez, a classe Agricultura apresentou um crescimento mais localizado, ocorrendo predominantemente sobre áreas previamente convertidas em Pastagem, com uma probabilidade de transição de 1,62%. Essas mudanças concentraram-se, sobretudo, em áreas próximas à infraestrutura viária e a núcleos urbanos consolidados, indicando um padrão de intensificação do uso do solo agrícola sobre áreas já antropizadas. Tal comportamento reforça os achados apresentados pelos autores supracitados, que apontam a conversão indireta da vegetação nativa, mediada pela expansão da pastagem, como uma característica recorrente da dinâmica recente de uso da terra na Amazônia.

Do ponto de vista espacial, as transições ocorreram de forma agregada, formando manchas contínuas de expansão ao longo das rodovias principais e vicinais. Esse padrão, visível na progressão dos mapas da Figura 4, reforça a hipótese de que a dinâmica de uso da terra no Vale do Jamari não é aleatória, mas fortemente condicionada pela proximidade a elementos estruturantes do território, como estradas e cidades.

4.2 DESEMPENHO DO MODELO HÍBRIDO AC-RNA NA SIMULAÇÃO DE 2022

A validação do modelo foi realizada por meio da comparação entre o mapa simulado para o ano de 2022 e o mapa de referência do MapBiomass (Coleção 8) para o mesmo período, utilizando a porção espacialmente independente destinada à validação. A



análise visual, apresentada na Figura 5, demonstra uma elevada concordância espacial entre os mapas, com o modelo conseguindo reproduzir satisfatoriamente o padrão de fragmentação da paisagem e a distribuição das classes predominantes.




Figura 5 - Comparação visual entre o mapa de referência (a) e o mapa simulado (b) para o ano de 2022

A matriz de confusão absoluta (Tabela 6) detalha as concordâncias e discrepâncias entre a simulação e a referência. Observa-se uma predominância de valores elevados ao longo da diagonal principal, o que indica forte correspondência entre as classes simuladas e as observadas.

Tabela 7 - Matriz de Confusão absoluta comparando o mapa simulado (linhas) com o mapa de referência (colunas), em número de pixels

		Mapa de Referência						Mapa Simulado
		Vegetação Nativa	Pastagem	Agricultura	Água	Urbano e Outras	Mineração	
	Vegetação Nativa	2.739.687	635.428	7.840	1.904	30	1.292	
	Pastagem	576.252	4.782.690	79.685	1.314	804	1.549	
	Agricultura	2.618	28.948	120.374	77	586	26	
	Água	4.274	4.276	250	51.096	0	236	
	Urbano e Outras	331	235	146	6	42.505	3	
	Mineração	2.450	2.467	63	1.457	159	31.390	
Total		3.325.612	5.454.044	208.358	55.854	44.084	34.496	

Fonte: Elaborado pelo autor (2026).

A análise da matriz revela que a maior parte dos erros se concentra na distinção entre Vegetação Nativa e Pastagem. O modelo classificou como Vegetação Nativa cerca de 635 mil pixels que eram, na realidade, Pastagem (erro de comissão para floresta), enquanto simulou como Pastagem cerca de 576 mil pixels



de Vegetação (erro de omissão de floresta). Tais discrepâncias são esperadas em áreas de transição e borda, mas não comprometem a tendência geral de expansão agropecuária capturada pela simulação.

Para avaliar a qualidade global do modelo, foram calculadas métricas estatísticas de concordância, apresentadas na Tabela 7.

Tabela 8 - Métricas globais de validação do modelo

Métrica	Valor
Acurácia Global	87,36%
Kappa Geral	0,75
Kappa de Histograma	0,98
Kappa de Localização	0,76

Fonte: Elaborado pelo autor (2026), a partir do software QGIS (Plugin MOLUSCE)

Os resultados corroboram a eficácia da calibração realizada. A Acurácia Global de 87,36% reflete uma elevada capacidade geral do modelo em reproduzir o uso e a cobertura da terra observados. O Kappa Geral (0,75) posiciona-se na faixa de concordância considerada *substancial* (0,61–0,80), segundo a escala proposta por Landis & Koch (1977) indicando que o desempenho do modelo é significativamente superior ao esperado ao acaso.

Destaca-se o elevado valor do Kappa de Histograma (0,98), próximo de 1, o que evidencia que o modelo capturou com excelência a demanda quantitativa das mudanças, isto é, a área total convertida entre as classes. Por sua vez, o Kappa de Localização (0,76), embora ligeiramente inferior ao componente de quantidade, indica que o modelo foi capaz de espacializar corretamente a maior parte das novas áreas de desmatamento e expansão agropecuária, em consonância com as variáveis explicativas incorporadas à Rede Neural Artificial.

Resultados semelhantes são reportados por Silva & Paixão (2020) em estudos de modelagem do uso e ocupação do solo, nos quais os autores obtiveram elevados níveis de concordância global, expressos por valores de Kappa Geral, Kappa de Histograma e Kappa de Localização superiores a 0,90. De forma complementar, Muhammad et al. (2022), ao utilizarem o plugin MOLUSCE e uma metodologia semelhante à adotada neste trabalho, reportaram valores de Kappa Geral superiores a 0,50, evidenciando desempenho satisfatório do modelo em contextos espaciais distintos.

A convergência entre esses resultados e aqueles observados neste estudo reforça a robustez do modelo híbrido AC–RNA e a consistência da estratégia de calibração adotada, bem como sua adequação para a simulação da dinâmica de uso e cobertura do solo em áreas de elevada complexidade espacial.



4.3 ANÁLISE DE DESEMPENHO POR CLASSE

A análise detalhada por classe permite identificar padrões específicos de erros de omissão e comissão que as métricas globais não revelam. A Tabela 9 apresenta a consolidação das métricas de Acurácia do Produtor, Acurácia do Usuário e F1-Score para a simulação do ano de 2022.

Tabela 9 - Métricas de desempenho detalhadas por classe de uso e cobertura do solo (2022)

Classe de Uso	Acurácia do Produtor %	Acurácia do Usuário %	F1-Score
Vegetação Nativa	82,40	91,87	0,869
Pastagem	87,69	93,69	0,906
Agricultura	57,77	87,31	0,695
Água	91,48	89,03	0,902
Urbano/Outras	96,42	98,50	0,975
Mineração	90,99	91,40	0,912

Fonte: Elaborado pelo autor (2026).

As classes Urbano/Outras e Mineração apresentaram os melhores desempenhos conjuntos, com F1-Score superior a 0,90, indicando elevada precisão e capacidade de detecção. Esse desempenho pode ser atribuído ao fato de essas classes possuírem padrões espaciais bem definidos, além de apresentarem forte dependência da localização prévia, especialmente no caso da mineração, o que favorece sua correta representação pelo modelo.

A classe Vegetação Nativa demonstrou alta confiabilidade na classificação, evidenciada pela Acurácia do Usuário de 91,87%, indicando que as áreas simuladas como floresta raramente correspondem a falsos positivos. No entanto, a Acurácia do Produtor de 82,40% sugere uma leve subestimação da área total vegetada, indicando que o modelo adotou um comportamento mais conservador na manutenção da cobertura florestal, sobretudo em áreas de transição com pastagem.

A classe Pastagem, que atua como a classe matricial predominante da paisagem, apresentou excelente desempenho, com F1-Score de 0,906, refletindo elevados índices tanto de detecção quanto de precisão. Esse resultado reforça a capacidade do modelo em capturar adequadamente a dinâmica da principal classe receptora das transições de uso da terra na área de estudo.

O principal desafio do modelo concentrou-se na classe Agricultura, que apresentou o menor F1-Score (0,695). A discrepância entre a alta Acurácia do Usuário (87,31%) e a baixa Acurácia do Produtor (57,77%) revela um padrão típico de erro de omissão, no qual o modelo é preciso ao identificar áreas agrícolas, mas falha em capturar toda a sua extensão real, frequentemente confundindo-as com áreas de pastagem. Esse comportamento é esperado em regiões de fronteira agrícola dinâmica, onde a



conversão de Pastagem para Agricultura ocorre de forma acelerada e compartilha características espectrais e espaciais semelhantes.

Resultados comparáveis são reportados por Esteves et al. (2024), que, ao empregar modelos baseados em autômatos celulares integrados a redes neurais artificiais, obtiveram valores de F1-Score de 0,74 para silvicultura, 0,54 para agricultura e 0,64 para corpos d'água. A proximidade desses valores com os obtidos neste estudo, especialmente para a classe Agricultura, reforça que as limitações observadas estão associadas à complexidade intrínseca da dinâmica agrícola em paisagens altamente antropizadas, e não a falhas estruturais do modelo adotado.

4.4 SIMULAÇÃO DE CENÁRIOS PROSPECTIVOS (2030–2050)

A modelagem de cenários prospectivos constitui uma etapa fundamental para o planejamento territorial, permitindo antecipar tendências e avaliar o impacto de diferentes políticas de gestão sobre a paisagem. Nesta seção, são apresentados cenários distintos simulados para os horizontes temporais de 2030 e 2050, utilizando o ano de 2018 como linha de base.

As simulações foram realizadas através do plugin MOLUSCE (QGIS), baseando-se nas variáveis explicativas validadas anteriormente. Os cenários foram desenhados para representar diferentes graus de restrição legal e proteção ambiental, variando desde a manutenção das tendências históricas até a aplicação rigorosa da legislação ambiental vigente.

4.4.1 CENÁRIO 1: TENDENCIAL (BUSINESS AS USUAL – BAU)

A Figura 6 apresenta a espacialização do Cenário Tendencial (Business as Usual – BAU), que projeta a continuidade das tendências históricas de mudança de uso e cobertura do solo, sem a inserção de novas políticas restritivas além das já existentes na dinâmica atual.




Figura 6 - Dinâmica espaço-temporal do uso e cobertura do solo no Cenário BAU:
(a) 2018; (b) 2030; (c) 2050

Visualmente, a comparação entre o cenário base (2018) e as projeções (2030 e 2050) evidencia uma reorganização da paisagem, marcada pela redução da Vegetação Nativa e pela ampliação de usos antrópicos, em especial a Agricultura. A análise quantitativa (Tabela 10), calculada a partir dos quantitativos dos rasters, confirma essa tendência.

Tabela 10 - Quantificação de áreas e variação percentual no Cenário BAU (2030–2050)

Classe	Área 2018 (ha)	Área 2030 (ha)	Variação 2018-2030 (%)	Área 2050 (ha)	Variação 2018-2050 (%)
Vegetação Nativa	1.410.374	1.206.338	-14,47	1.165.312	-17,38
Pastagem	1.682.554	1.797.915	6,86	1.691.758	0,55
Agricultura	42.725	128.981	201,89	272.508	537,82
Água	22.054	22.114	0,27	22.105	0,23
Urbano e Outras	7.675	8.142	6,09	8.755	14,08
Mineração	8.303	10.192	22,76	13.246	59,53
TOTAL	3.173.684	3.173.684	-	3.173.684	-

Fonte: Elaborado pelo autor (2026)

Entre 2018 e 2030, a Vegetação Nativa reduz de 1.410.374 ha para 1.206.338 ha, correspondendo a -14,47%. Em 2050, a classe atinge 1.165.312 ha, acumulando -17,38% em relação a 2018. A Pastagem apresenta crescimento até 2030, passando de 1.682.554 ha para 1.797.915 ha (+6,86%), mas no horizonte de 2050 recua para 1.691.758 ha, resultando em variação praticamente estável no período completo (+0,55%), o que sugere conversão de áreas de pasto para outros usos na segunda etapa da projeção, principalmente para Agricultura.



A Agricultura é a classe com maior incremento proporcional: evolui de 42.725 ha (2018) para 128.981 ha em 2030 (+201,89%) e alcança 272.508 ha em 2050 (+537,82%), indicando intensificação expressiva e expansão territorial ao longo do período. A classe Água mantém estabilidade, com variações mínimas: 22.054 ha (2018), 22.114 ha (2030; +0,27%) e 22.105 ha (2050; +0,23%). Urbano e Outras cresce de 7.675 ha para 8.142 ha em 2030 (+6,09%) e atinge 8.755 ha em 2050 (+14,08%). Por fim, a Mineração aumenta continuamente: de 8.303 ha (2018) para 10.192 ha em 2030 (+22,76%) e 13.246 ha em 2050 (+59,53%).

Assim, o cenário BAU projeta, até 2050, uma paisagem mais antropizada, com redução contínua da Vegetação Nativa (de 1.410.374 ha para 1.165.312 ha; -17,38%), forte expansão da Agricultura (de 42.725 ha para 272.508 ha; +537,82%) e crescimento de Mineração e Urbano (Mineração: +59,53%; Urbano e Outras: +14,08%), enquanto a Pastagem cresce até 2030 (+6,86%) e perde parte desse avanço até 2050 (+0,55%), compatível com conversão de áreas de pasto para agricultura na segunda metade do período.

4.4.2 CENÁRIO 2: RESTRIÇÕES EM ÁREAS PROTEGIDAS (UC E TI)

A Figura 7 ilustra a distribuição espacial das classes de uso e cobertura do solo simuladas para 2030, 2040 e 2050 no Cenário 2. Ao comparar com o cenário tendencial (BAU), observa-se que as restrições em Unidades de Conservação e Terras Indígenas oferecem uma proteção localizada, porém com impacto limitado na dinâmica regional global.

A Vegetação Nativa projeta-se em 1.176.182 ha para 2050 (-16,60%), o que representa uma mitigação da perda de vegetação nativa adicional de apenas cerca de 11.000 hectares (menos de 1 ponto percentual) em relação ao cenário sem restrições. A expansão da Agricultura permanece intensa (+531,09% em 2050, contra 537,82% no BAU), indicando que a atividade produtiva tende a contornar as áreas protegidas, mantendo elevada a pressão de conversão sobre as demais áreas de vegetação disponível.




Figura 7 - Dinâmica espaço-temporal do uso e cobertura do solo no Cenário com Restrições (UC e TI): (a) 2018 (b) 2030; (c) 2050

Ao observar a evolução do uso do solo entre 2018 e as simulações futuras (2030 e 2050), nota-se uma paisagem onde a pressão antrópica é contida nas bordas dessas áreas protegidas. Percebe-se a manutenção de manchas significativas de vegetação que, no cenário tendencial (BAU), seriam suprimidas, indicando que as restrições atuam como um fator de proteção eficaz contra o avanço desordenado do desmatamento.

A análise quantitativa, detalhada na Tabela 11, confirma essa tendência de conservação relativa quando comparada ao cenário sem restrições.

Tabela 11 - Quantificação de áreas e variação percentual no Cenário com Restrições (UC e TI) 2030 - 2050

Classe	Área 2018 (ha)	Área 2030 (ha)	Variação 2018-2030 (%)	Área 2050 (ha)	Variação 2018-2050 (%)
Vegetação Nativa	1.410.374	1.215.552	-13,81	1.176.182	-16,60
Pastagem	1.682.554	1.789.664	6,37	1.683.862	0,08
Agricultura	42.725	128.068	199,75	269.629	531,09
Água	22.054	22.106	0,23	22.100	0,21
Urbano e Outras	7.675	8.127	5,89	8.733	13,79
Mineração	8.303	10.167	22,45	13.179	58,73
TOTAL	3.173.684	3.173.684	-	3.173.684	-

Fonte: Elaborado pelo autor (2026)

A classe Vegetação Nativa apresenta uma redução de 1.410.374 ha (2018) para 1.215.552 ha em 2030 (-13,81%), atingindo 1.176.182 ha em 2050 (-16,60%). Embora ainda haja perda, ela é amortecida pelas salvaguardas legais. A Pastagem cresce na primeira fase, passando de 1.682.554 ha para 1.789.664



ha em 2030 (+6,37%), mas recua ligeiramente no horizonte de 2050 para 1.683.862 ha, resultando em uma variação acumulada praticamente nula (+0,08%), sugerindo que a expansão agropecuária encontra limites físicos e passa a ocorrer via conversão de áreas já abertas.

A Agricultura, contudo, mantém um crescimento vigoroso: salta de 42.725 ha (2018) para 128.068 ha em 2030 (+199,75%) e alcança 269.629 ha em 2050 (+531,09%). As classes Água e Urbano e Outras mostram estabilidade ou crescimento moderado (Água: +0,21%; Urbano: +13,79% até 2050), enquanto a Mineração mantém sua tendência de alta, crescendo 22,45% até 2030 e acumulando 58,73% até 2050 (chegando a 13.179 ha).

Dessa forma, o Cenário com Restrições desenha um futuro em que o desenvolvimento agrícola coexiste com a conservação. A matriz produtiva continua a se expandir, mas o "freio" legal impede a fragmentação excessiva em zonas críticas, garantindo a manutenção de maiores blocos de vegetação nativa essenciais para a biodiversidade regional.

4.4.3 CENÁRIO 3: RESTRIÇÕES AMPLIADAS (UC, TI, APP E RL)

A Figura 8 apresenta a espacialização do terceiro cenário simulado, que representa a aplicação mais rigorosa da legislação ambiental. Além das restrições em Unidades de Conservação (UC) e Terras Indígenas (TI), este cenário incorpora a proteção das Áreas de Preservação Permanente (APP) e a exigência de manutenção da Reserva Legal (RL).




Figura 8 - Dinâmica espaço-temporal do uso e cobertura do solo no Cenário com Restrições Ampliadas (UC, TI, APP e RL): (a) 2018; (b) 2030 (c) 2050.

A leitura espacial dos mapas, partindo de 2018 rumo aos horizontes de 2030 e 2050, evidencia uma malha de proteção ambiental mais densa e conectada. Observa-se a formação de corredores ecológicos ao longo da rede de drenagem, restringindo



significativamente as áreas disponíveis para a conversão produtiva indiscriminada e protegendo cursos d'água e fragmentos florestais estratégicos.

A análise quantitativa, apresentada na Tabela 12, demonstra que este cenário é o que oferece a maior conservação de ecossistemas naturais entre os simulados.

Tabela 12 - Quantificação de áreas e variação percentual no Cenário com Restrições Ampliadas (UC, TI, APP e RL) 2030-2050

Classe	Área 2018 (ha)	Área 2030 (ha)	Variação 2018-2030 (%)	Área 2050 (ha)	Variação 2018-2050 (%)
Vegetação Nativa	1.410.374	1.323.274	-6,18	1.306.447	-7,37
Pastagem	1.682.554	1.693.579	0,66	1.586.623	-5,70
Agricultura	42.725	117.279	174,50	238.593	458,45
Água	22.054	22.094	0,18	22.087	0,15
Urbano e Outras	7.675	7.888	2,78	8.261	7,63
Mineração	8.303	9.570	15,27	11.673	40,59
TOTAL	3.173.684	3.173.684	-	3.173.684	-

Fonte: Elaborado pelo autor (2026)

A Vegetação Nativa, partindo de 1.410.374 ha (2018), reduz para 1.323.274 ha em 2030 (-6,18%) e finaliza o período em 1.306.447 ha em 2050 (-7,37%). Comparativamente, esta perda acumulada de 7,37% é substancialmente menor do que a projetada no cenário BAU (-17,38%) e no cenário apenas com UC/TI (-16,60%), indicando que a inclusão de APP e RL é determinante para evitar o desmatamento em larga escala.

A Pastagem exhibe um comportamento distinto: mantém-se praticamente estável até 2030, passando de 1.682.554 ha para 1.693.579 ha (+0,66%), mas sofre retração importante até 2050, caindo para 1.586.623 ha (-5,70% no acumulado). Isso sugere que, diante da impossibilidade de desmatar novas áreas protegidas (RL e APP), a expansão agrícola passa a ocorrer sobre áreas de pastagem antigas.

A Agricultura confirma seu papel como vetor de expansão, crescendo de 42.725 ha (2018) para 117.279 ha em 2030 (+174,50%) e atingindo 238.593 ha em 2050 (+458,45%). Embora o crescimento percentual seja expressivo, a área absoluta final é menor do que nos cenários anteriores, refletindo o respeito às limitações ambientais.

As demais classes apresentam ajustes menores ou crescimento específico: Água permanece estável (+0,15% até 2050); Urbano e Outras cresce de forma moderada (+2,78% em 2030 e +7,63% em 2050); e a Mineração mantém



tendência de alta, subindo de 8.303 ha para 9.570 ha em 2030 (+15,27%) e alcançando 11.673 ha em 2050 (+40,59%).

Em síntese, o Cenário 3 demonstra que a implementação plena do Código Florestal não impede o desenvolvimento econômico, a agricultura mais que quintuplica e a mineração cresce 40%, mas altera fundamentalmente a dinâmica da paisagem. O modelo promove uma matriz produtiva menos fragmentada e ambientalmente mais funcional, garantindo a permanência de mais de 1,3 milhão de hectares de vegetação nativa.

4.5 ANÁLISE COMPARATIVA E DINÂMICA TEMPORAL DOS CENÁRIOS (2030–2050)

A integração dos resultados nos horizontes de curto (2030) e longo prazo (2050) permite compreender não apenas a magnitude das mudanças, mas a velocidade com que as políticas de ordenamento territorial, ou a ausência delas, impactam a paisagem da região.

4.5.1 O HORIZONTE DE CURTO PRAZO (2030)

A Tabela 13 apresenta o comparativo entre os cenários após a primeira década de simulação. Os dados revelam que a trajetória de degradação no cenário tendencial é acelerada, exigindo medidas de contenção imediatas.

Tabela 13 - Comparação dos cenários prospectivos (2030)

Classe	Base 2018	Cenário 01 BAU	Cenário 02 UC/TI	Cenário 03 UC+TI+APP+RL
Vegetação Nativa	1.410.374	1.206.338 (-14,47%)	1.215.552 (-13,81%)	1.323.274 (-6,18%)
Pastagem	1.682.554	1.797.916 (6,86%)	1.789.664 (6,37%)	1.693.579 (0,66%)
Agricultura	42.725	128.982 (201,89%)	128.068 (199,75%)	117.279 (174,50%)
Água	22.054	22.114 (0,27%)	22.106 (0,23%)	22.094 (0,18%)
Urbano e Outras	7.675	8.142 (6,09%)	8.127 (5,89%)	7.888 (2,78%)
Mineração	8.303	10.192 (22,76%)	10.167 (22,45%)	9.570 (15,27%)
TOTAL	3.173.684	3.173.684	3.173.684	3.173.684

Fonte: Elaborado pelo autor (2026)

A análise para 2030 aponta divergências críticas logo nos primeiros anos:

- **Velocidade do Desmatamento:** No cenário BAU, projeta-se uma perda de 14,47% da vegetação nativa já em 2030. Isso indica que a maior parte do passivo ambiental acumulado até 2050 ocorre na primeira década.



- **A "Freada" do Cenário 3:** A implementação das restrições (APP e Reserva Legal) atua como um freio instantâneo. Em 2030, o Cenário 3 consegue limitar a perda de vegetação a -6,18%. Em termos absolutos, a diferença entre o BAU (1.206.338 ha) e o Cenário 3 (1.323.274 ha) representa 116.936 hectares de vegetação salvos em apenas 12 anos.
- **Contenção da Pastagem:** Enquanto no BAU a pastagem avança quase 7% sobre a vegetação nativa, no Cenário 3 esse avanço é travado (+0,66%), sinalizando o início de uma reorganização produtiva.

4.5.2 O HORIZONTE DE LONGO PRAZO (2050)

Ao estender a projeção para 2050 (Tabela 14), as diferenças estruturais entre os cenários tornam-se definitivas, expondo a limitação das políticas de proteção isoladas e a eficácia da proteção em rede.

Tabela 14 - Comparação dos cenários prospectivos (2050)

Classe	Base 2018	Cenário 01 BAU	Cenário 02 UC/TI	Cenário 03 UC+TI+APP+RL
Vegetação Nativa	1.410.374	1.165.312 (-17,38%)	1.176.182 (-16,60%)	1.306.447 (-7,37%)
Pastagem	1.682.554	1.691.758 (0,55%)	1.683.862 (0,08%)	1.586.623 (-5,70%)
Agricultura	42.725	272.508 (537,82%)	269.629 (531,09%)	238.593 (458,45%)
Água	22.054	22.105 (0,23%)	22.100 (0,21%)	22.087 (0,15%)
Urbano e Outras	7.675	8.755 (14,08%)	8.733 (13,79%)	8.261 (7,63%)
Mineração	8.303	13.246 (+59,53%)	13.179 (+58,73%)	11.673 (+40,59%)
TOTAL	3.173.684	3.173.684	3.173.684	3.173.684

Fonte: Elaborado pelo autor (2026)

A comparação final em 2050 evidencia três dinâmicas centrais para a discussão política e ambiental:

- **A Insuficiência das Áreas Protegidas Isoladas (Cenário 2):** A proteção restrita a Unidades de Conservação e Terras Indígenas (Cenário 2) mostrou-se ineficaz para alterar a matriz regional. A diferença de vegetação preservada em relação ao BAU é marginal (11.000 hectares a mais). Nessa situação a pressão do desmatamento apenas contorna os limites das áreas protegidas, mantendo a perda regional de vegetação em patamares críticos (-16,60%).
- **A Eficácia do Código Florestal (Cenário 3):** O Cenário 3 consolida-se como a única alternativa sustentável. A perda acumulada de vegetação nativa estaciona em -7,37%, menos da metade do desmatamento observado no cenário tendencial (-17,38%). Isso preserva, em números



absolutos, 141.135 hectares de ecossistemas nativos em comparação ao BAU, garantindo a conectividade da paisagem através das APPs.

- **A Conciliação entre Conservação e Produção:** O dado mais revelador do estudo reside na dinâmica entre Agricultura e Pastagem no Cenário 3: Pastagem é o único cenário onde a área de pastagem diminui (-5,70% ou -95.931 ha em relação a 2018); e Agricultura, mesmo com as restrições ambientais, a agricultura cresce expressivos 458,45%.

Isso comprova que a conservação ambiental no Cenário 3 não inviabiliza o desenvolvimento econômico. Pelo contrário, ela induz a intensificação do uso da terra: a agricultura deixa de avançar sobre a floresta (desmatamento) e passa a ocupar áreas de pastagens degradadas ou subutilizadas. O Cenário 3, portanto, substitui a expansão horizontal predatória por uma ocupação territorial mais eficiente.



5 CONCLUSÕES E INVESTIGAÇÃO FUTURA

A presente pesquisa investigou a dinâmica espaço-temporal do uso e cobertura do solo no Território Vale do Jamari, em Rondônia, por meio da aplicação de técnicas de modelagem espacial baseadas em Redes Neurais Artificiais e Autômatos Celulares. Ao integrar as séries históricas do projeto MapBiomias à plataforma QGIS, com apoio do plugin MOLUSCE, o estudo demonstrou a viabilidade técnica e a relevância estratégica do uso de geotecnologias livres para a compreensão de processos complexos de transformação da paisagem amazônica. A validação do modelo, realizada por meio da comparação entre o cenário simulado para 2022 e os dados observados, confirmou a adequação da abordagem híbrida AC-RNA para representar a dinâmica territorial da região.

De modo geral, os resultados permitiram responder às perguntas de investigação formuladas na introdução. Em primeiro lugar, foi possível identificar os principais padrões de mudança no uso e cobertura do solo no período de 2014 a 2018, utilizado para a calibração do modelo. Em segundo lugar, verificou-se que o modelo híbrido foi capaz de simular, de forma satisfatória, a dinâmica espacial observada, tomando 2022 como referência de validação. Por fim, as projeções para 2030 e 2050 evidenciaram trajetórias distintas conforme o cenário considerado, reforçando a importância da governança territorial e da efetividade das políticas ambientais na definição dos futuros possíveis para o Vale do Jamari.

5.1 SÍNTESE DOS RESULTADOS E CONTRIBUIÇÕES

No que se refere à primeira pergunta de investigação, os resultados mostraram que, entre 2014 e 2018, o Território Vale do Jamari apresentou um padrão consistente de transformação da paisagem, marcado principalmente pela conversão de áreas florestais em usos antrópicos. Destacou-se, nesse processo, a expansão de áreas agropastoris, com avanço sobre zonas de maior acessibilidade e proximidade da infraestrutura viária. Esse comportamento confirma que a dinâmica de mudança no território não ocorre de forma aleatória, mas responde a condicionantes espaciais claramente associados à ocupação histórica, à presença de estradas e à consolidação de áreas produtivas.

Em relação à segunda pergunta, verificou-se que o treinamento da Rede Neural Artificial do tipo Perceptron Multicamadas, com base nos dados do intervalo de 2014 a 2018, foi capaz de captar as não linearidades características da fronteira agrícola amazônica, identificando de forma satisfatória as áreas mais suscetíveis à conversão. A comparação entre o cenário simulado para 2022 e os dados observados indicou boa correspondência espacial, evidenciando a eficácia do modelo híbrido AC-RNA para representar a realidade territorial do Vale do Jamari. A análise dos vetores de mudança reforçou que a acessibilidade permanece como um dos principais determinantes da alteração da paisagem regional.



Quanto à terceira pergunta de investigação, as projeções para 2030 e 2050 apontaram para duas trajetórias contrastantes. No cenário tendencial (Business as Usual), observou-se a continuidade da expansão dos usos antrópicos e o avanço da pressão sobre os remanescentes florestais, indicando a persistência das dinâmicas verificadas no período de calibração. Esse cenário sugere o agravamento da fragmentação da cobertura florestal, com potenciais impactos sobre a conectividade ecológica e os recursos hídricos. Em contrapartida, os cenários que simulam maior efetividade na aplicação das restrições territoriais e das normas ambientais demonstraram redução relativa da expansão sobre áreas sensíveis, evidenciando que a governança territorial constitui variável decisiva para a sustentabilidade regional no longo prazo.

A principal contribuição desta dissertação reside, portanto, na validação de uma abordagem metodológica de baixo custo, base open source e alta replicabilidade, capaz de apoiar a análise de mudanças no uso e cobertura do solo em regiões de elevada complexidade socioambiental. Além de contribuir para a compreensão dos mecanismos que moldam a paisagem do Vale do Jamari, o estudo oferece subsídios técnicos que podem ser incorporados por gestores públicos e instituições de planejamento na formulação de estratégias territorialmente mais sustentáveis.

5.2 LIMITAÇÕES DO ESTUDO

Apesar dos resultados satisfatórios, é necessário reconhecer as limitações inerentes ao processo de modelagem desenvolvido nesta dissertação. Uma limitação operacional refere-se à própria arquitetura do plugin MOLUSCE, que não dispõe de funcionalidade nativa para a incorporação de variáveis de restrição absoluta durante a etapa de simulação. Essa característica exigiu o uso complementar de álgebra de mapas para inserir as camadas de restrição territorial, procedimento metodológico necessário para assegurar o respeito às condicionantes legais nos cenários prospectivos. Contudo, essa abordagem assume contenção absoluta do desmatamento nas áreas protegidas e não contempla explicitamente o possível efeito de vazamento (leakage), isto é, o deslocamento da pressão de conversão para áreas adjacentes não protegidas.

Outra limitação diz respeito à resolução espacial e espectral dos dados utilizados. Embora a resolução de 30 metros do MapBiomass seja adequada para análises regionais, observou-se dificuldade na distinção entre áreas de pastagem degradada e agricultura em estágio inicial, em razão de semelhanças fenológicas e texturais entre essas classes. Essa sobreposição espectral pode afetar o desempenho do modelo em determinadas transições e introduzir incertezas na representação de parte da dinâmica recente do território.

Também se destaca como limitação o tratamento estático de determinadas variáveis explicativas. A infraestrutura viária, por exemplo, foi considerada fixa ao longo da modelagem, sem incorporar a abertura dinâmica de novas estradas, em especial vias não oficiais, que frequentemente atuam como vetores de expansão da fronteira



agropecuária. Esse aspecto pode levar à subestimação da pressão antrópica em áreas de ocupação mais recente.

Por fim, o modelo baseou-se predominantemente em padrões espaciais pretéritos e em variáveis territorialmente observáveis, sem incorporar de forma direta fatores externos não espacializados, como oscilações nos preços de commodities, mudanças institucionais abruptas ou alterações nas políticas públicas. Tais fatores podem acelerar ou conter o desmatamento independentemente das condições físicas e locais, o que significa que os cenários produzidos devem ser interpretados como representações condicionadas pelas premissas adotadas, e não como previsões determinísticas.

5.3 RECOMENDAÇÕES PARA INVESTIGAÇÃO FUTURA

Com vistas ao aprimoramento das ferramentas de análise e gestão territorial aplicadas à Amazônia, recomenda-se que investigações futuras avancem na integração entre modelagem espacial e variáveis socioeconômicas, permitindo a construção de cenários sensíveis a incentivos de mercado, flutuações econômicas e mudanças institucionais. A incorporação de redes viárias dinâmicas também se mostra promissora, sobretudo para representar de forma mais realista os mecanismos de retroalimentação entre abertura de estradas e expansão do uso antrópico da terra.

Sugere-se, igualmente, o aprofundamento de estudos voltados ao aprimoramento da classificação do uso e cobertura do solo, com ênfase na distinção espectral entre pastagens e áreas agrícolas. Nesse sentido, a aplicação de técnicas mais avançadas de Inteligência Artificial e Machine Learning, como Random Forest e arquiteturas de Deep Learning, poderá contribuir para elevar a acurácia dos potenciais de transição e refinar a representação das classes de uso. Esse avanço pode, inclusive, permitir o desdobramento da classe agrícola em subclasses mais específicas, distinguindo, por exemplo, culturas anuais e perenes, o que ampliaria a capacidade analítica da modelagem em contextos produtivos complexos.

Também seria relevante testar a abordagem proposta em outras áreas da Amazônia Legal, a fim de avaliar sua robustez em diferentes contextos territoriais e ampliar sua replicabilidade. Estudos comparativos entre regiões poderiam contribuir para identificar padrões comuns e especificidades locais, fortalecendo o uso da modelagem preditiva como ferramenta de apoio ao planejamento regional.

Em síntese, esta dissertação reforça que o futuro do Vale do Jamari não constitui uma trajetória fixa, mas resulta de decisões territoriais tomadas no presente. Nesse contexto, a modelagem espacial preditiva oferece uma base técnica relevante para orientar escolhas entre caminhos de expansão produtiva e estratégias de conservação ambiental, contribuindo para um planejamento territorial mais informado, preventivo e sustentável.



6 REFERÊNCIAS BIBLIOGRÁFICAS

- Aburas, M. M., Ahamad, M. S. S., & Omar, N. Q. (2019). Spatio-temporal simulation and prediction of land-use change using conventional and machine learning models: a review. *Environmental Monitoring and Assessment*, 191(4), 205. <https://doi.org/10.1007/s10661-019-7330-6>
- Al-Ageili, M., Mouhoub, M., & Piwowar, J. (2017). Remote sensing, GIS and cellular automata for urban growth simulation. *Computer and Information Science*, 10(4), 38. <https://doi.org/10.5539/cis.v10n4p38>
- Almeida, C. M. de, & Gleriani, J. M. (2005). Cellular automata and neural networks as a modelling framework for the simulation of urban land use change. *Anais do XII Simpósio Brasileiro de Sensoriamento Remoto*, 3697–3705.
- Antunes, L. M. (2021). CellPyLib: A Python library for working with Cellular Automata. *Journal of Open Source Software*, 6(67), 3608. <https://doi.org/10.21105/joss.03608>
- Asia Air Survey, & NextGIS. (2025). MOLUSCE: Módulos para Avaliação de Mudanças no Uso da Terra [Software de computador]. NextGIS.
- Barona, E., Ramankutty, N., Hyman, G., & Coomes, O. T. (2010). The role of pasture and soybean in deforestation of the Brazilian Amazon. *Environmental Research Letters*, 5(2). <https://doi.org/10.1088/1748-9326/5/2/024002>
- Basse, R. M., Omrani, H., Charif, O., Gerber, P., & Bódis, K. (2014). Land use changes modelling using advanced methods: Cellular automata and artificial neural networks. The spatial and explicit representation of land cover dynamics at the cross-border region scale. *Applied Geography*, 53, 160–171. <https://doi.org/10.1016/j.apgeog.2014.06.016>
- Cammelli, F., Levy, S. A., Grabs, J., Valentim, J. F., & Garrett, R. D. (2022). Effectiveness-equity tradeoffs in enforcing exclusionary supply chain policies: Lessons from the Amazonian cattle sector. *Journal of Cleaner Production*, 332. <https://doi.org/10.1016/j.jclepro.2021.130031>
- Carvalho, A. C. P., Carvalho, A. P. P., Gomes, T. M., & Rossi, F. (2025). Spatiotemporal analysis of land use and land cover using remote sensing. *Engenharia Agrícola*, 45(spe1). <https://doi.org/10.1590/1809-4430-eng.agric.v45nespe120240180/2025>



- Castro, E. M. R., & Castro, C. P. (2022). Desmatamento na Amazônia, desregulação socioambiental e financeirização do mercado de terras e de commodities. *Novos Cadernos NAEA*, 25, 11–36.
- Congalton, R. G., & Green, K. (2009). Assessing the accuracy of remotely sensed data: principles and practices. CRC Press/Taylor & Francis.
- Covaleski, J. P., Almeida, D. H. de, Lima, F. C. de, Conto, V. de, Lopes, L. de S., & Lemes, S. P. da S. (2025). Métricas da paisagem no Vale do Jamari: tendências e desafios na produção científica. *Contribuciones a las Ciencias Sociales*, 18(3), 01–20. <https://doi.org/10.55905/revconv.18n.3-201>
- De Oliveira, V. C. da S. S., Costa, A. G., Baptista, A. C., & Machado, T. de A. (2024). Dynamic modeling applied for the assessment of areas with agricultural activities in the Matopiba region/Brazil. *Contribuciones a las Ciencias Sociales*, 17(2), e4288. <https://doi.org/10.55905/revconv.17n.2-088>
- Ding, L., Cai, P., Huang, W., Zhang, H., Ding, F., Zhao, W., Tang, D., & Wang, Z. (2025). GIS analysis model integration and service composition prospects. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 48(G-2025), 899–904. <https://doi.org/10.5194/isprs-archives-XLVIII-G-2025-899-2025>
- Dormann, C. F., Elith, J., Bacher, S., Buchmann, C., Carl, G., Carré, G., Marquéz, J. R. G., Gruber, B., Lafourcade, B., Leitão, P. J., Münkemüller, T., McClean, C., Osborne, P. E., Reineking, B., Schröder, B., Skidmore, A. K., Zurell, D., & Lautenbach, S. (2013). Collinearity: a review of methods to deal with it and a simulation study evaluating their performance. *Ecography*, 36(1), 27–46. <https://doi.org/10.1111/j.1600-0587.2012.07348.x>
- Esteves, R. J. Z., Velastegui-Montoya, A., Scalfani Pujatti, M. A., Silvestre, L. J., & Pereira, M. de A. (2024). Land use and land cover change analysis in Brazilian urban centres: an approach using cellular automata and neural networks. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 48(3), 155–161. <https://doi.org/10.5194/isprs-archives-XLVIII-3-2024-155-2024>
- Foody, G. M. (2020). Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. *Remote Sensing of Environment*, 239, 111630. <https://doi.org/10.1016/j.rse.2019.111630>



- Galford, G. L., Soares-Filho, B. S., Sonter, L. J., & Laporte, N. (2015). Will passive protection save Congo forests? *PLOS ONE*, 10(6), e0128473. <https://doi.org/10.1371/journal.pone.0128473>
- Gharaibeh, A., Shaamala, A., Obeidat, R., & Al-Kofahi, S. (2020). Improving land-use change modeling by integrating ANN with Cellular Automata-Markov Chain model. *Heliyon*, 6(9). <https://doi.org/10.1016/j.heliyon.2020.e05092>
- Hojati, M., & Robertson, C. (2020). Integrating cellular automata and discrete global grid systems: a case study into wildfire modelling. *AGILE: GIScience Series*, 1, 1–23. <https://doi.org/10.5194/agile-giss-1-6-2020>
- Hu, Z., & Lo, C. P. (2007). Modeling urban growth in Atlanta using logistic regression. *Computers, Environment and Urban Systems*, 31(6), 667–688. <https://doi.org/10.1016/j.compenvurbsys.2006.11.001>
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159. <https://doi.org/10.2307/2529310>
- Lin, Y.-P., Chu, H.-J., Wu, C.-F., & Verburg, P. H. (2011). Predictive ability of logistic regression, auto-logistic regression and neural network models in empirical land-use change modeling – a case study. *International Journal of Geographical Information Science*, 25(1), 65–87. <https://doi.org/10.1080/13658811003752332>
- Lu, D., Li, G., Moran, E., & Hetrick, S. (2013). Spatiotemporal analysis of land-use and land-cover change in the Brazilian Amazon. *International Journal of Remote Sensing*, 34(16), 5953–5978. <https://doi.org/10.1080/01431161.2013.802825>
- Maeda, E. E., de Almeida, C. M., de Carvalho Ximenes A., A., Formaggio, A. R., Shimabukuro, Y. E., & Pellikka, P. (2011). Dynamic modeling of forest conversion: Simulation of past and future scenarios of rural activities expansion in the fringes of the Xingu National Park, Brazilian Amazon. *International Journal of Applied Earth Observation and Geoinformation*, 13(3), 435–446. <https://doi.org/10.1016/j.jag.2010.09.008>
- MapBiomass. (2024). Relatório Anual do Desmatamento no Brasil 2023 (RAD2023). <http://alerta.mapbiomas.org>
- MapBiomass Project. (2024). Algorithm Theoretical Basis Document (ATBD) - Collection 9: Land Use and Land Cover Classification in Brazil.



- Michetti, M., & Zampieri, M. (2014). Climate-human-land interactions: A review of major modelling approaches. *Land*, 3(3), 793–833. <https://doi.org/10.3390/land3030793>
- Muhammad, R., Zhang, W., Abbas, Z., Guo, F., & Gwiazdzinski, L. (2022). Spatiotemporal change analysis and prediction of future land use and land cover changes using QGIS MOLUSCE plugin and remote sensing big data: A case study of Linyi, China. *Land*, 11(3), 419. <https://doi.org/10.3390/land11030419>
- Nepstad, D., McGrath, D., Stickler, C., Alencar, A., Azevedo, A., Swette, B., Bezerra, T., DiGiano, M., Shimada, J., Seroa da Motta, R., Armijo, E., Castello, L., Brando, P., Hansen, M. C., McGrath-Horn, M., Carvalho, O., & Hess, L. (2014). Slowing Amazon deforestation through public policy and interventions in beef and soy supply chains. *Science*, 344(6188), 1118–1123. <https://doi.org/10.1126/science.1248525>
- Novoa Garzon, L. F., da Silva, D. S., & Ribeiro, M. S. (2022). Dismantling of indigenous territories and conservation units in the new arc of deforestation in Rondônia/Brazil and Beni/Bolívia (2018-2020). *Desenvolvimento e Meio Ambiente*, 60, 116–142. <https://doi.org/10.5380/dma.v60i0.80233>
- Oliveira, O. F. de, Costa, G. B. da, Campos, H. Á., & Silva, J. B. da. (2011). A implementação do Plano Territorial de Desenvolvimento Rural Sustentável e do Programa Territórios da Cidadania no estado de Rondônia. *Revista Grifos*, 20, 81–102.
- Oliveira, V. B. V. de. (2007). Perfil social e produtivo do Território Vale do Jamari-Rondônia (1ª ed.). Embrapa Rondônia.
- Ometto, J. P., Sousa-Neto, E. R., & Tejada, G. (2016). Land Use, Land Cover and Land Use Change in the Brazilian Amazon (1960–2013). In *Interactions Between Biosphere, Atmosphere, and Human Land Use in the Amazon Basin: An Introduction* (pp. 369–383). Springer. https://doi.org/10.1007/978-3-662-49902-3_15
- Omrani, H., Tayyebi, A., & Pijanowski, B. (2017). Integrating the multi-label land-use concept and cellular automata with the artificial neural network-based Land Transformation Model: an integrated ML-CA-LTM modeling framework. *GIScience and Remote Sensing*, 54(3), 283–304. <https://doi.org/10.1080/15481603.2016.1265706>
- Pereira Lopes, I. A., Aires de Macedo, M. L., Nobrega Torres, É., Ramos de Sousa, R., & Anjos Correia, A. (2024). Análise espaço-temporal do uso e cobertura do




solo em área semiárida da Paraíba. *Revista de Geociências do Nordeste*, 10(1), 14–23. <https://doi.org/10.21680/2447-3359.2024v10n1ID33459>

- Pfaff, A. S. P. (1999). What drives deforestation in the Brazilian Amazon? Evidence from satellite and socioeconomic data. *Journal of Environmental Economics and Management*, 37(1). <http://www.idealibrary.comonIDEkL3>
- Picoli, M. C. A., Rorato, A., Leitão, P., Camara, G., Maciel, A., Hostert, P., & Sanches, I. D. A. (2020). Impacts of public and private sector policies on soybean and pasture expansion in Mato Grosso-Brazil from 2001 to 2017. *Land*, 9(1). <https://doi.org/10.3390/land9010020>
- Ramos, A. W. P., Azevedo, Ú. R. de, & Galvanin, E. A. dos S. (2024). Modelagem preditiva de desmatamento na Bacia do Alto Paraguai no estado de Mato Grosso, Brasil. *Caminhos de Geografia*, 25(101), 112–130. <https://doi.org/10.14393/RCG2510171664>
- Rehan Anwar, M., & Dwi Sakti, L. (2024). Integrating artificial intelligence and environmental science for sustainable urban planning. *IAIC Transactions on Sustainable Digital Innovation (ITSDI)*, 5(2), 179.
- Saharan, D. D., & Nehra, D. S. (2025). Geospatial assessment and prediction of land use changes in Bikaner urbanizable area: A QGIS-based approach using MOLUSCE plugin. *International Journal of Environmental Sciences*, 130–142. <https://doi.org/10.64252/zkxzq680>
- Silva, L. P. e, & Paixão, A. N. da. (2020). Modelagem e análise temporal da dinâmica do uso e ocupação do solo na Bacia do Rio Cuiá-PB. *InterEspaço: Revista de Geografia e Interdisciplinaridade*, 5(17), 11617. <https://doi.org/10.18764/2446-6549.2019.11617>
- Simmons, C., Walker, R., Perz, S., Arima, E., Aldrich, S., & Caldas, M. (2016). Spatial patterns of frontier settlement: Balancing conservation and development. *Journal of Latin American Geography*, 15(1), 33–58. <https://doi.org/10.1353/lag.2016.0011>
- Soares-Filho, B. S., Nepstad, D. C., Curran, L., Cerqueira, G. C., Garcia, R. A., Ramos, C. A., Voll, E., McDonald, A., Lefebvre, P., Schlesinger, P., & McGrath, D. (2005). Cenários de desmatamento para a Amazônia. *Estudos Avançados*, 19(54), 137–152. <https://doi.org/10.1590/S0103-40142005000200008>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>



- Souza, F. G. de, Moura, V., Brito, M. V. A. de, Krause, E. F., Oliveira, F. E. F., Souza, R. dos A. de, Tavares, B. L., & Filho, E. G. de B. (2020). Mapeamento do uso e cobertura do solo em mesorregiões do estado de Rondônia. *Research, Society and Development*, 9(8). <https://doi.org/10.33448/rsd-v9i8.5522>
- Subiyanto, S., Sukmono, A., Bashit, N., & Amarrohman, F. J. (2019). The use of a MLP neural network for analysis and modeling of land use changes with variations variable of physical and economic social. *IOP Conference Series: Earth and Environmental Science*, 389(1), 012029. <https://doi.org/10.1088/1755-1315/389/1/012029>
- Trentin, G., & Castreghini de Freitas, M. I. (2010). Modelagem da dinâmica espacial urbana: modelo de autômato celular na simulação de cenários para o município de Americana-SP. *Revista Brasileira de Cartografia*, 01.
- Vasconcelos, B. R. de, Vieira Lima, M. T., & Conceição Paranhos Filho, A. (2024). Detecção de mudanças no uso e ocupação do solo no estado do Amazonas baseada nas classificações do Projeto MapBiomass. *Geofronter*, 10. <https://doi.org/10.61389/geofronter.v10.7773>
- Wolfram, S. (1984). Universality and complexity in cellular automata. *Physica D: Nonlinear Phenomena*, 10(1–2), 1–35. [https://doi.org/10.1016/0167-2789\(84\)90245-8](https://doi.org/10.1016/0167-2789(84)90245-8)



Data with Purpose.

