



**UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CARTOGRÁFICA**

Taciano José Lins de Medeiros

**PROJEÇÕES DE USO E COBERTURA DA TERRA SOB A
INFLUÊNCIA DO ARCO METROPOLITANO:
TRANSFORMAÇÕES E IMPACTOS NA REGIÃO
METROPOLITANA DO RECIFE, PERNAMBUCO**

Recife

2025

**UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CARTOGRÁFICA**

Taciano José Lins de Medeiros

**PROJEÇÕES DE USO E COBERTURA DA TERRA SOB A
INFLUÊNCIA DO ARCO METROPOLITANO:
TRANSFORMAÇÕES E IMPACTOS NA REGIÃO
METROPOLITANA DO RECIFE, PERNAMBUCO**

Trabalho de Conclusão de Curso, apresentado ao curso de graduação em Engenharia Cartográfica e de Agrimensura da Universidade Federal de Pernambuco como requisito parcial para a obtenção de grau de Bacharel em Engenharia Cartográfica e de Agrimensura.

Orientador: Prof. Dr. Carlos Fabricio Assunção da Silva

Recife

2025

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Medeiros, Taciano José Lins de.

Projeções de uso e cobertura da Terra sob a influência do arco metropolitano: transformações e impactos na região metropolitana do Recife, Pernambuco. / Taciano José Lins de Medeiros. - Recife, 2025.

54 p : il., tab.

Orientador(a): Carlos Fabricio Assunção da Silva

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Engenharia Cartográfica e de Agrimensura - Bacharelado, 2025.

Inclui referências.

1. Infraestruturas rodoviárias. 2. Autômatos celulares. 3. Rede neural artificial. 4. MOLUSCE. 5. Geotecnologias. I. Silva, Carlos Fabricio Assunção da. (Orientação). II. Título.

620 CDD (22.ed.)

Taciano José Lins de Medeiros

**PROJEÇÕES DE USO E COBERTURA DA TERRA SOB A
INFLUÊNCIA DO ARCO METROPOLITANO:
TRANSFORMAÇÕES E IMPACTOS NA REGIÃO
METROPOLITANA DO RECIFE, PERNAMBUCO**

Trabalho de Conclusão de Curso, apresentado ao curso de graduação em Engenharia Cartográfica e de Agrimensura da Universidade Federal de Pernambuco como requisito parcial para a obtenção de grau de Bacharel em Engenharia Cartográfica e de Agrimensura.

Aprovado em: 21 de agosto de 2025

BANCA EXAMINADORA

Prof. Dr. Carlos Fabricio Assunção da Silva - Orientador

Prof. Dra. Maria de Lourdes de Aquino Macedo Gonçalves – UFPE

Prof. Dra. Manuella Anais Rodrigues Fagundes – UFPE

Me. Fernanda Catarina Ribeiro da Luz– UFPE

Dedicatória

Primeiramente à Deus, Senhor de tudo na minha vida. À minha família, com muito afeto, a Therla, minha esposa, e às minhas filhas Lara e Laís, que sempre me apoiaram e incentivaram em todo processo de elaboração deste trabalho. E não posso deixar de agradecer também aos meus pais, Antonia e Reginaldo (in memoriam) pela minha educação.

AGRADECIMENTOS

Agradeço primeiramente a Deus por sua misericórdia infinita em minha vida e me permitir as oportunidades de lutar, e a fé para concluir os objetivos colocados em minha vida.

Aos meus queridos pai (*in memoriam*), mãe, irmão e irmã, pelo amor incondicional.

Às minhas preciosas esposa e filhas, que me dão força e alegria para continuar lutando pelos meus sonhos e terem entendido minha ausência em momentos que se fez necessário por conta de mais essa jornada.

Aos meus bons amigos e demais familiares, por todo apoio.

Aos professores do curso, por todo conhecimento que me foi passado e em especial, ao professor Dr. Carlos Fabricio, obrigado pela orientação e estímulos transmitidos, sempre de forma cordial e cuidadosa.

Ao professor Dr. Erison Barros e ao meu amigo e mestrando da UFPE, Eng. Fernando Lourenço, pela contribuição e disponibilidade ímpar na elaboração deste trabalho.

Agradeço a todas as pessoas e instituições públicas e privadas que colaboraram para o desenvolvimento dessa pesquisa.

A todos minha profunda gratidão.

“A persistência é o caminho do êxito.”

Charles Chaplin

RESUMO

As rodovias são elementos estratégicos de infraestrutura e exercem forte influência no desenvolvimento socioeconômico e territorial das regiões onde são implantadas. No entanto, além dos benefícios esperados, sua presença também provoca transformações ambientais e mudanças significativas nos padrões de uso e cobertura da terra. Dessa forma, este trabalho tem como objetivo projetar cenários de uso e cobertura da terra para os anos de 2020 e 2030 na área de influência direta (*buffer* de 5 km) do Arco Metropolitano, na Região Metropolitana do Recife. A metodologia baseou-se em geotecnologias e modelagem espacial preditiva, utilizando os *softwares* QGIS 3.44.1, ArcGIS 10.5 e os *plugins* MOLUSCE e *Land Change Modeler* (LCM 2.0). Os dados de entrada foram processados em formato *raster*, com padronização de sistema de referência e resolução espacial. A modelagem seguiu abordagens *markovianas* e de autômatos celulares, além da aplicação de redes neurais artificiais, permitindo tanto a quantificação quanto a espacialização das mudanças no uso do solo. Foram utilizadas bases de uso da terra dos anos de 2000 e 2010 como referência para a simulação dos cenários futuros. Os resultados para o ano de 2020 indicaram excelente desempenho do modelo, com precisão geral de 87,14% e índice Kappa geral de 0,81659. A simulação para 2030, ainda que limitada pela ausência dos dados do Censo 2022, obteve índice Kappa de 0,76277, considerado muito bom. A análise revelou tendências de expansão urbana e aumento de áreas florestais, além da diminuição dos mosaicos de usos. A comparação com o mapa original de 2020 do MapBiomias demonstrou alta similaridade espacial com a predição gerada, reforçando a confiabilidade do modelo aplicado. A projeção para 2030 sugere que a futura implantação do Arco poderá intensificar a conversão do solo em zonas de transição urbano-rural. Portanto, o uso de ferramentas de modelagem espacial preditiva permite antecipar cenários de transformação territorial associados à implantação de grandes obras viárias, sendo útil para subsidiar o planejamento urbano e ambiental sustentável.

Palavras-chaves: Infraestruturas rodoviárias. Autômatos celulares. Rede neural artificial. MOLUSCE. Geotecnologias.

ABSTRACT

Highways are strategic infrastructure elements and exert a strong influence on the socioeconomic and territorial development of the regions where they are implemented. However, in addition to the expected benefits, their presence also triggers environmental transformations and significant changes in land use and land cover patterns. Therefore, this study aims to project land use and land cover scenarios for the years 2020 and 2030 within the direct influence area (5 km buffer) of the Arco Metropolitano in the Metropolitan Region of Recife. The methodology was based on geotechnologies and spatial predictive modeling, using the software QGIS 3.44.1, ArcGIS 10.5, and the MOLUSCE and Land Change Modeler (LCM 2.0) plugins. Input data were processed in raster format, with standardized spatial reference system and resolution. The modeling followed Markovian and cellular automata approaches, along with the application of artificial neural networks, allowing both the quantification and spatialization of land use changes. Land use data from the years 2000 and 2010 were used as a reference for simulating future scenarios. The results for the year 2020 indicated excellent model performance, with an overall accuracy of 87.14% and a general Kappa index of 0.81659. The 2030 simulation, although limited by the absence of 2022 Census data, achieved a Kappa index of 0.76277, considered very good. The analysis revealed trends of urban expansion and increase in forest areas, along with a decrease in mosaic land uses. Comparison with the original 2020 MapBiomias map showed high spatial similarity with the predicted map, reinforcing the reliability of the applied model. The projection for 2030 suggests that the future implementation of the Arco may intensify land conversion in peri-urban transition zones. Therefore, the use of spatial predictive modeling tools enables the anticipation of territorial transformation scenarios associated with the implementation of major road infrastructure, proving useful for supporting sustainable urban and environmental planning.

Keywords: Road infrastructures. cellular automata. artificial neural network. MOLUSCE. geotechnologies.

LISTA DE FIGURAS

Figura 1 - Mapa de Localização do Arco Metropolitano	23
Figura 2 - Grade Estatística IBGE - resolução 1 x 1km (região de estudo)	27
Figura 3 - Imagens <i>raster</i> originais do MapBiomas, anos 2000, 2010 e 2020, com resolução de 30×30m e reamostrados para resolução de 1×1 km	28
Figura 4 - <i>Print</i> da tabela de atributos do QGIS com valores de <i>pixels</i> das variáveis ...	30
Figura 5 - Exemplo de <i>raster</i> gerado a partir do <i>grid</i> IBGE – variável quantidade de domicílios	31
Figura 6 - Tela de primeira interface do MOLUSCE - dados de entrada.....	32
Figura 7 - MOLUSCE – avaliação de correlação, método de <i>Pearson</i>	33
Figura 8 - MOLUSCE - estatísticas por classes	34
Figura 9 - MOLUSCE – mapa de alterações.....	34
Figura 10 - MOLUSCE – variações de classe de <i>pixel</i>	35
Figura 11 - MOLUSCE – tela de teste de rede neural.....	36
Figura 12 - Tela com os resultados do índice Kappa e gráfico de aprendizagem relacionados ao modelo de predição a ser gerado	37
Figura 13 - Processo de criação do <i>raster</i> de predição.....	38
Figura 14 - Janela de validação com o <i>raster</i> oficial e análise da certeza (índice Kappa Geral).....	39
Figura 15 - Fluxograma dos processos desenvolvidos para utilização do MOLUSCE .	40
Figura 16 - Interface estatística de classes do MOLUSCE	41
Figura 17 - Curva de aprendizagem rede neural.....	42
Figura 18 - Gráfico de erros da comparação dos mapas de 2020.....	43
Figura 19 - Comparação de <i>rasters</i> de Uso e Cobertura da Terra - Ano de 2020.....	44
Figura 20 - Mapa de Uso e Ocupação da Terra (predição para o ano de 2030).....	46

LISTA DE TABELAS

Tabela 1 - Critérios para interpretação dos valores de Kappa por Landis e Koch (1977).	22
Tabela 2 - Fontes de dados utilizada e principais dados coletados.....	25
Tabela 3 - Critérios de normalização de valores percentuais em valores de <i>pixel</i>	29
Tabela 4 - Dados das variáveis influentes utilizadas no processo (dados normalizados).	29
Tabela 5 - Códigos identificadores das variáveis de entrada no MOLUSCE.....	30
Tabela 6 - Maiores usos verificados na área de interesse (Ano de 2020).....	45

SUMÁRIO

1. INTRODUÇÃO	14
1.1 JUSTIFICATIVA.....	15
1.2 OBJETIVOS	16
<i>1.2.1 Objetivo Geral</i>	<i>16</i>
<i>1.2.2 Objetivos Específicos.....</i>	<i>16</i>
2 EMBASAMENTO TEÓRICO.....	16
2.1 BREVE HISTÓRICO DO PROJETO DO ARCO METROPOLITANO	16
2.2 IMPACTOS AMBIENTAIS GERADOS PELAS INFRAESTRUTURAS DE TRANSPORTES RODOVIÁRIOS.....	17
2.3 MAPEAMENTO DE USO E COBERTURA DA TERRA COMO INSTRUMENTO DE GESTÃO TERRITORIAL	18
2.4 MÉTODOS E MODELOS DE MAPEAMENTO DE USO E COBERTURA DA TERRA.....	19
<i>2.4.1 Comparação de imagens de sensoriamento remoto</i>	<i>19</i>
<i>2.4.2 Modelagem utilizando redes neurais artificiais</i>	<i>20</i>
<i>2.4.3 Matriz de confusão (ou matriz de erro)</i>	<i>21</i>
<i>2.4.4 Medidas e índices derivados da matriz de confusão</i>	<i>22</i>
3 MATERIAIS E MÉTODOS.....	23
3.1 ÁREA DE ESTUDO	23
3.2 MATERIAIS.....	24
3.3 MÉTODOS.....	25
<i>3.3.1 Preparação de dados para utilização no MOLUSCE.....</i>	<i>25</i>
<i>3.3.1.1 Tratamento espacial da grade estatística do IBGE (2010), reajustando o grid para células de 1x1km</i>	<i>26</i>
<i>3.3.1.1 Delimitação do raster de uso e cobertura do solo do MapBiomas</i>	<i>27</i>
<i>3.3.1.2 Pré-processamento das variáveis de influência escolhidas para o MOLUSCE</i>	<i>28</i>
<i>3.3.1.3 Rasterização dos dados processados em grade 1×1 km</i>	<i>30</i>
<i>3.3.2 Ferramenta MOLUSCE.....</i>	<i>31</i>
<i>3.3.2.1 Entrada dos dados tratados</i>	<i>31</i>
<i>3.3.2.2 Análise da correlação entre as variáveis influentes</i>	<i>32</i>
<i>3.3.2.3 Análise do território de mudanças</i>	<i>33</i>
<i>3.3.2.4 Processo de modelagem e aprendizado de máquina.....</i>	<i>35</i>

3.3.2.5 <i>Processo de predição por automação</i>	37
3.3.2.6 <i>Processo de validação</i>	38
4 RESULTADOS E DISCUSSÃO	40
5 CONSIDERAÇÕES FINAIS	48
REFERÊNCIAS	48

1. INTRODUÇÃO

As rodovias desempenham um papel fundamental no desenvolvimento socioeconômico das regiões onde são implantadas (Silva *et al.*, 2023). No entanto, seus impactos vão além dos benefícios diretos, manifestando-se desde a fase de planejamento até a operação da obra. Esses efeitos podem ser positivos ou negativos, influenciando o meio ambiente, o crescimento urbano e a qualidade de vida da população (Silva de Melo, 2022).

Do ponto de vista ambiental, a expansão de novas rodovias tem provocado diversos impactos negativos, como alterações no uso e na cobertura do solo (Kantianis *et al.*, 2025), aumento da poluição atmosférica e sonora (Khan *et al.*, 2018), transformações socioeconômicas nas comunidades afetadas (Sackey, 2023) e redução da biodiversidade em áreas sensíveis (Dhadse *et al.*, 2025). Segundo Alhjouj, Bonoli e Zamorano (2022), a construção de estradas em diferentes regiões do mundo tem contribuído para mudanças ambientais e sociais de grande escala.

A expansão da infraestrutura rodoviária é reconhecida como um dos principais vetores de transformação do uso e cobertura da terra, especialmente em regiões metropolitanas marcadas por crescimento urbano acelerado. Essas mudanças não apenas alteram a configuração física do território, mas também geram impactos ambientais, econômicos e sociais que afetam diretamente a qualidade de vida da população (Amaral *et al.*, 2019).

Diante desses impactos, cresce o uso de ferramentas que auxiliem na compreensão e mitigação dos efeitos causados pela expansão rodoviária, sendo as geotecnologias uma delas. O uso de geotecnologias tem se mostrado uma ferramenta relevante em todas as etapas de grandes obras, permitindo análises detalhadas desde a fase preliminar até a operação (Nyame; Adesanmi, 2024). Tecnologias como o sensoriamento remoto, o geoprocessamento e os sistemas de informação geográfica (SIG) permitem análises detalhadas do território, desde a identificação de áreas com interferência antrópica até o monitoramento de transformações ambientais ao longo do tempo (Leite; Rosa, 2005).

Nesse contexto, a aplicação de geotecnologias torna-se importante em projetos de abertura de novas rodovias, como o Arco Metropolitano da Região Metropolitana do Recife (RMR), cuja complexidade territorial e sensibilidade ambiental exigem análises e planejamento. Projetado para interligar o polo automotivo de Goiana e o complexo portuário de Suape, o empreendimento visa desafogar o volume de tráfego em rodovias estaduais e federais que cortam a região metropolitana, especialmente a BR-101 e a PE-

60. O projeto tem gerado intenso debate devido ao seu traçado atravessar áreas de preservação ambiental do bioma Mata Atlântica (PDUI-RMR, 2024).

Nesse sentido, compreender as possíveis mudanças territoriais decorrentes da implantação da rodovia torna-se importante do ponto de vista ambiental. Dessa forma, o objetivo do estudo é realizar a projeção de cenários de uso e cobertura da terra para os anos de 2020 e 2030 na área de influência direta (*buffer* 5 km), considerando os efeitos da implantação do Arco Metropolitano na RMR. O estudo mostra-se como um instrumento capaz de permitir a compreensão das dinâmicas territoriais na região impactada.

1.1 JUSTIFICATIVA

A construção de grandes obras de infraestrutura, como o Arco Metropolitano, está frequentemente associada a impactos significativos sobre o território e a população local. Na Região Metropolitana do Recife (RMR), marcada por elevada densidade populacional e um processo acelerado de urbanização, a implantação de novas vias rodoviárias tende a provocar transformações profundas na dinâmica do uso e cobertura da terra (Guerra, 2021).

Os investimentos em infraestrutura rodoviária geralmente levam ao aumento da atividade econômica. Por exemplo, a duplicação da BR-232 em Pernambuco resultou no crescimento agregado da produção e na geração de empregos nas regiões diretamente afetadas, com a melhoria do acesso viário facilitando o estabelecimento de novos negócios e aumentando o salário dos residentes (Andrade *et al.*, 2015).

Além dos efeitos econômicos, a construção de novas rodovias também está relacionada a questões ambientais e urbanas complexas. Por exemplo, o aumento da emissão de gases nocivos à saúde humana, emitidos por veículos automotores, função de congestionamentos volumosos nos grandes centros urbanos, também impulsiona a redistribuição do tráfego e em consequência a abertura de novas rodovias (Pérez *et al.*, 2021). Esse processo, embora vise melhorar a mobilidade urbana, pode intensificar a expansão desordenada das cidades e gerar impactos significativos sobre o meio ambiente e o planejamento territorial.

Entre os principais fatores que justificam este estudo, destacam-se os impactos ambientais decorrentes da expansão urbana induzida por esse tipo de empreendimento, resultando em desmatamento, redução de áreas verdes e alterações nos ecossistemas locais, comprometendo a biodiversidade e os serviços ecossistêmicos essenciais (Guerra,

2021). Além disso, podem ocorrer alterações diretas no planejamento territorial, com o surgimento de assentamentos precários, o aumento da impermeabilização do solo e a intensificação de problemas como alagamentos e sobrecarga da infraestrutura urbana existente (Maricato, 2011; Rolnik, 2015).

A projeção de cenários de uso e cobertura da terra, permite a adoção de medidas preventivas e a formulação de políticas públicas mais eficazes, torna-se, portanto, uma ferramenta estratégica para subsidiar decisões que promovam um desenvolvimento urbano mais equilibrado e sustentável (Meyer, 2019).

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Projetar cenários de uso e cobertura da terra para os anos de 2020 e 2030 na área de influência direta (*buffer* 5 km), considerando os efeitos da implantação do Arco Metropolitano na Região Metropolitana do Recife, com ênfase em potenciais transformações territoriais e ambientais decorrentes dessa infraestrutura rodoviária.

1.2.2 Objetivos Específicos

- Coletar e organizar dados geoespaciais históricos e atuais sobre uso e cobertura da terra na área de influência direta (*buffer* 5 km) do Arco Metropolitano;
- Mapear as transformações territoriais ocorridas nesta região entre os anos de 2000 e 2010.

2 EMBASAMENTO TEÓRICO

2.1 BREVE HISTÓRICO DO PROJETO DO ARCO METROPOLITANO

A proposta de implantação do Arco Metropolitano da Região Metropolitana do Recife (RMR) está diretamente relacionada à evolução da malha viária estadual. Além disso, busca o afastamento de rodovias dos núcleos urbanos densamente povoados. A BR-101, eixo rodoviário estruturante da região, foi originalmente concebida para contornar os limites urbanos do Recife, funcionando como um corredor de integração entre as capitais do litoral nordestino e as regiões centro-sul do país (DNIT, 2015).

Nesse contexto, é possível estabelecer um paralelo com outras experiências nacionais de infraestrutura viária, como o Rodoanel da cidade de São Paulo. Trata-se de um grande anel viário projetado para aliviar o congestionamento de tráfego de uma metrópole, promovendo o transporte eficiente de mercadorias e pessoas. Ele conecta

várias rodovias, facilitando o acesso às zonas industriais e reduzindo o tempo de viagem, o que é crucial para as atividades econômicas na região (Ichihara *et al.*, 2007).

Com o passar dos anos, o aumento do fluxo de veículos, impulsionado pelo crescimento populacional e pela expansão das atividades econômicas, tornou evidente a necessidade de novas soluções de mobilidade. Por exemplo, a BR-101 passou a concentrar não apenas o transporte de cargas e passageiros, mas também o acesso a pólos industriais e turísticos, o que gerou sobrecarga em trechos urbanos densamente povoados (PDUI-RMR, 2024).

Nesse contexto, o Arco Metropolitano surge como uma alternativa estratégica para redistribuir o tráfego, especialmente de veículos pesados, reduzindo a pressão sobre o chamado Contorno do Recife. Esse trecho da BR-101, com cerca de 30,7 quilômetros de extensão, é responsável por um fluxo diário estimado de 60 mil veículos, dos quais aproximadamente 20% são caminhões. Além disso, abriga importantes linhas de transporte coletivo, que atendem a mais de 120 mil passageiros por dia (Grande Recife, 2024).

A concepção do Arco remonta à década de 1990, sendo considerada uma das principais demandas de infraestrutura viária do estado. O projeto foi dividido em dois segmentos: o Trecho Norte e o Trecho Sul. O primeiro conecta os municípios de Paudalho e Goiana, atravessando áreas de proteção ambiental, como a APA Aldeia-Beberibe, o que tem gerado preocupações quanto aos impactos ecológicos. Já o Trecho Sul, com cerca de 45 quilômetros, liga Paudalho ao Cabo de Santo Agostinho e encontra-se em estágio mais avançado, com processo licitatório em andamento e previsão de execução a partir de 2025 (Jornal do Commercio, 2025).

2.2 IMPACTOS AMBIENTAIS GERADOS PELAS INFRAESTRUTURAS DE TRANSPORTES RODOVIÁRIOS

As infraestruturas de transporte rodoviário, embora fundamentais para a integração territorial e o desenvolvimento econômico, estão entre os empreendimentos que mais geram impactos ambientais diretos e indiretos. A implantação de rodovias exige extensas movimentações de terra e a supressão de vegetação nativa, o que contribui para a fragmentação de *habitats* e a perda de biodiversidade (Lauxen, 2012).

Além disso, a pavimentação e a impermeabilização do solo alteram o regime natural de escoamento das águas pluviais, intensificando processos erosivos e

umentando o risco de enchentes e assoreamento de corpos hídricos (Ferreira *et al.*, 2021).

Coffin (2007) ressalta que essas alterações podem modificar cursos d'água naturais, prejudicando a regeneração de ecossistemas ripários e agravando a degradação ambiental. Estudos apontam que, quando não há planejamento adequado, esses processos podem comprometer a estabilidade da própria estrutura viária e gerar custos elevados de manutenção (Pires; Carmo Júnior, 2018).

Outro impacto recorrente é a ocupação desordenada nas áreas adjacentes às rodovias. A facilidade de acesso proporcionada por essas vias frequentemente atrai empreendimentos e assentamentos informais, resultando em degradação ambiental, pressão sobre os recursos naturais e sobrecarga dos serviços urbanos (Jaeger *et al.*, 2005; Simonetti, 2010).

Do ponto de vista ecológico, as rodovias também funcionam como barreiras físicas à movimentação de espécies, comprometendo a conectividade entre fragmentos de vegetação e dificultando processos naturais como a dispersão de sementes e o fluxo gênico. Esse “efeito barreira” pode gerar consequências ecológicas de longo prazo, especialmente em regiões com alta sensibilidade ambiental (Neri, 2024).

2.3 MAPEAMENTO DE USO E COBERTURA DA TERRA COMO INSTRUMENTO DE GESTÃO TERRITORIAL

O mapeamento de uso e cobertura da terra emerge como uma ferramenta estratégica para subsidiar o planejamento territorial e orientar políticas públicas voltadas à sustentabilidade urbana. Desde a Conferência de Estocolmo, em 1972, a importância do conhecimento sobre o uso da terra tem sido amplamente reconhecida como base para o desenvolvimento de estratégias de gestão ambiental. A partir desse marco, diversos estudos passaram a incorporar metodologias de mapeamento com o objetivo de caracterizar o meio físico e orientar o uso racional dos recursos naturais (Franzoni, 2000).

A Agenda 21, como instrumento de planejamento global, reforça a necessidade de identificar e classificar os recursos do solo, com vistas à sua utilização sustentável. Essa abordagem inclui a delimitação de áreas ambientalmente vulneráveis, suscetíveis a processos erosivos, inundações ou deslizamentos, permitindo a adoção de medidas preventivas e corretivas que minimizem os riscos socioambientais.

No Brasil, o modelo de crescimento urbano tem sido marcado pela ocupação de áreas inadequadas, muitas vezes sem infraestrutura básica ou respaldo legal. Em cidades

como São Paulo, por exemplo, a expansão urbana avançou sobre áreas de proteção de mananciais, revelando a ausência de políticas eficazes de ordenamento territorial (Jacobi, 2000).

Esse padrão de ocupação desordenada gera uma série de consequências ambientais e sociais que comprometem a sustentabilidade urbana. A ocupação desordenada do solo acarreta uma série de impactos negativos, como a perda de biodiversidade, a degradação de corpos hídricos, a impermeabilização excessiva do solo e o comprometimento da qualidade de vida urbana. Tais efeitos são amplamente discutidos por Suertegaray (2000), que destaca a urgência de diagnósticos ambientais baseados em dados espaciais confiáveis para orientar ações de planejamento.

O mapeamento de uso e cobertura da terra permite identificar a compatibilidade entre diferentes formas de ocupação e as características ambientais do território (Santos *et al.*, 2025). Com isso, é possível delimitar áreas que devem ser preservadas, como encostas íngremes, zonas de recarga hídrica ou regiões com fragilidade ecológica (França *et al.*, 2022) bem como reconhecer espaços com potencial para atividades produtivas sustentáveis, como agricultura, turismo ou conservação (The Nature Conservancy, 2023).

Dessa forma, o mapeamento do uso e cobertura da terra não apenas fornece subsídios técnicos para a formulação de políticas públicas, mas também contribui para a construção de uma visão integrada do território, promovendo o equilíbrio entre desenvolvimento e conservação.

2.4 MÉTODOS E MODELOS DE MAPEAMENTO DE USO E COBERTURA DA TERRA

2.4.1 *Comparação de imagens de sensoriamento remoto*

Os dados obtidos por sensores remotos orbitais, a exemplo daqueles disponibilizados através da plataforma MapBiomass, têm se destacado como uma das principais fontes para analisar as transformações espaço-temporal do território, sendo, portanto, essencial para estudos sobre mudanças ambientais em escala local e global (Fearnside, 2001).

A utilização de séries temporais de imagens de satélite permite a avaliação detalhada das taxas de mudança e a identificação de tendências espaciais, contribuindo para diagnósticos mais precisos (Turner II *et al.*, 2007).

A detecção dessas transformações requer a comparação entre mapas temáticos elaborados em diferentes períodos, utilizando técnicas que possibilitem a identificação e

quantificação das alterações ocorridas. Essa abordagem comparativa fornece subsídios técnicos para o ordenamento territorial e a gestão de recursos naturais, ao evidenciar padrões de conversão e persistência das classes de uso da terra (Foley *et al.*, 2005).

Entre os métodos empregados, destaca-se a interpretação visual por especialistas, que, embora considerada uma técnica tradicional, ainda é eficaz em contextos específicos. No entanto, a classificação automática de imagens, com posterior geração de mapas temáticos, tem se consolidado como uma abordagem robusta e replicável, especialmente quando associada a validações em campo e ao uso de plataformas como o MapBiomias (Xavier *et al.*, 2024).

A aplicação prática dessas metodologias exige o controle rigoroso de variáveis como resolução espacial, sazonalidade das imagens e acurácia das classificações. Assim, o aprimoramento contínuo das técnicas de sensoriamento remoto e a integração de dados multiescalares são fundamentais para garantir a confiabilidade dos resultados e apoiar a tomada de decisões no âmbito do planejamento ambiental e territorial (Christofoletti, 1999).

2.4.2 Modelagem utilizando redes neurais artificiais

O cérebro humano tem uma capacidade de processar, analisar e correlacionar informações, ele não apenas analisa os dados do ambiente, mas também os correlaciona com nossas experiências de vida, permitindo-nos resolver problemas de formas únicas. A busca por imitar essa capacidade de processamento, aprendizado e adaptação biológica é o que impulsiona a inteligência artificial moderna (Haykin, 2001).

As redes neurais artificiais são definidas por Haykin (2001) como sendo: um processo maciçamente e paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos: 1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem. 2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

A modelagem preditiva do uso e cobertura da terra constitui uma abordagem essencial para antecipar cenários futuros e subsidiar o planejamento territorial sustentável. Nesse contexto, destaca-se o uso do complemento MOLUSCE (*Modules for Land Use Change Simulations*), integrado ao software QGIS, como uma ferramenta

acessível e robusta para simular transformações espaciais com base em dados históricos e variáveis explicativas (NEXTGIS, 2017).

O MOLUSCE permite a análise de transições entre classes de uso da terra e a projeção de cenários futuros por meio de algoritmos estatísticos e técnicas de aprendizado de máquina. Entre os modelos disponíveis, destacam-se: Redes Neurais Artificiais (ANN), Regressão Logística, Árvores de Decisão, Cadeia de Markov, Pesos de Evidência (WoE) e Autômatos Celulares, frequentemente combinados com o modelo de Markov para maior realismo espacial.

O fluxo metodológico com o MOLUSCE pode ser sintetizado em cinco etapas principais: (1) fornecimento de mapas temáticos de uso e cobertura do solo de dois períodos distintos; (2) cálculo das transições entre classes; (3) seleção de variáveis explicativas (como declividade, distância a vias e centros urbanos); (4) escolha do modelo preditivo; e (5) simulação das mudanças e geração do mapa projetado.

Alguns estudos já demonstraram a eficácia do MOLUSCE na previsão de mudanças espaciais, com resultados satisfatórios em termos de acurácia e aplicabilidade em diferentes contextos geográficos (Rahman, 2017).

2.4.3 Matriz de confusão (ou matriz de erro)

A avaliação da precisão temática em classificações de uso e cobertura da terra é uma etapa fundamental para validar os resultados obtidos por meio de técnicas de sensoriamento remoto. Entre os métodos mais amplamente utilizados para essa finalidade, destaca-se a matriz de confusão, também conhecida como matriz de erro, que fornece uma estrutura analítica para quantificar a acurácia e identificar padrões de erro na classificação (Foody, 2002).

Essa matriz é composta por um arranjo bidimensional, geralmente quadrado, no qual as linhas representam as classes atribuídas pelo classificador e as colunas correspondem às classes reais, verificadas por meio de dados de referência, como levantamentos de campo ou imagens de alta resolução (Congalton, 1991). Os elementos localizados na diagonal principal indicam os acertos da classificação, ou seja, os casos em que a classe atribuída coincide com a classe real. Já os elementos fora da diagonal evidenciam os erros de omissão e comissão, permitindo uma análise detalhada das falhas do modelo.

A partir da matriz de confusão, é possível derivar diversos indicadores estatísticos, como: Exatidão global, Índice Kappa, Precisão do usuário e do produtor.

2.4.4 Medidas e índices derivados da matriz de confusão

A matriz de confusão permite derivar uma série de métricas estatísticas que qualificam a precisão da classificação temática. Entre as mais utilizadas estão: exatidão global, precisão por classe, precisão do produtor, precisão do usuário e o coeficiente Kappa.

A exatidão global é obtida pela razão entre o número total de acertos (soma dos elementos da diagonal principal) e o número total de amostras avaliadas. Essa métrica fornece uma visão geral da performance do classificador, mas não revela a distribuição dos erros entre as classes.

Para uma análise mais detalhada, são utilizadas as precisões por classe, que incluem: Precisão do produtor e Precisão do usuário.

O coeficiente Kappa (K) é uma medida estatística que avalia o grau de concordância entre os dados classificados e os dados de referência, descontando os acertos esperados ao acaso. Embora amplamente utilizado, o coeficiente Kappa não possui um valor mínimo universalmente aceito como satisfatório. No entanto, a literatura propõe faixas interpretativas para os valores de K, conforme verificado na Tabela 1 abaixo.

Tabela 1 - Critérios para interpretação dos valores de Kappa por Landis e Koch (1977).

Índice Kappa	Desempenho
< 0	Péssimo
$0 < K \leq 0,2$	Ruim
$0,2 < K \leq 0,4$	Razoável
$0,4 < K \leq 0,6$	Bom
$0,6 < K \leq 0,8$	Muito Bom
$0,8 < K \leq 1,0$	Excelente

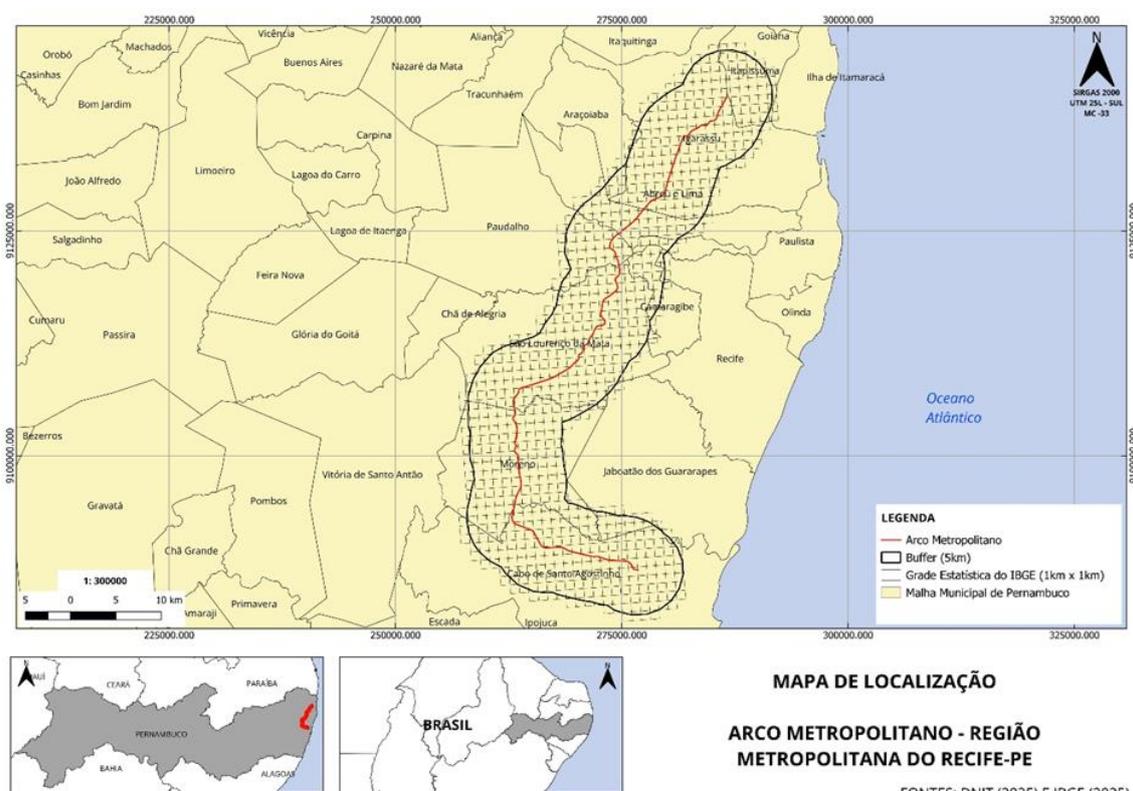
Adaptado: Landis e Koch (1977).

3 MATERIAIS E MÉTODOS

3.1 ÁREA DE ESTUDO

A área de estudo está compreendida entre as coordenadas 257.000 m e 292.000 m no eixo E, e entre 9.080.000 m e 9.146.000 m no eixo N, conforme o Sistema Geográfico de Referência SIRGAS 2000, utilizando a Projeção Universal Transversa de Mercator (UTM), Fuso 25 Sul, com Meridiano Central a 39° W.Gr. Essa delimitação corresponde ao traçado proposto para o Arco Metropolitano, um corredor rodoviário planejado para contornar a mesorregião Região Metropolitana do Recife.

Figura 1 - Mapa de Localização do Arco Metropolitano



Fonte: O autor (2025)

O Arco Metropolitano está inserido na região da Zona da Mata de Pernambuco, atravessando diretamente os municípios de Igarassu, Abreu e Lima, Paudalho, São Lourenço da Mata, Moreno e Cabo de Santo Agostinho. A área de influência direta (AID) foi definida por um *buffer* de 5 km ao redor do traçado, abrangendo também áreas limítrofes de outros municípios, incluindo a cidade do Recife.

De acordo com a Agência Pernambucana de Águas e Climas - APAC, a região apresenta clima quente e úmido, com precipitação média anual entre 1.000 e 2.000mm.

O regime pluviométrico é caracterizado por duas estações distintas: a estiagem (setembro a fevereiro) e o período chuvoso (março a agosto), sendo que cerca de 45% da precipitação anual ocorre nos meses de maio, junho e julho (APAC, 2025).

O relevo da região é resultado de processos erosivos e deposicionais, com destaque para duas unidades geomorfológicas principais: morfologias onduladas e várzeas e terraços aluviais (Alheiros, 1988).

A rede hidrográfica da área de influência é composta por importantes rios, como o Jaboatão, Várzea do Una, Duas Unas, Multibara e Capibaribe. Esses corpos hídricos são historicamente utilizados para abastecimento humano, irrigação, dessedentação animal e atividades industriais (Silva, 2018).

Além disso, a presença de nascentes e cacimbas evidencia a importância da preservação dos recursos hídricos subterrâneos, especialmente em áreas rurais onde o acesso à água potável depende dessas fontes (Silva, 2018).

3.2 MATERIAIS

Foram utilizados dados de uso e cobertura da terra referentes aos anos de 2000, 2010 e 2020, obtidos por meio da Coleção 9 do projeto MapBiomas, que disponibiliza séries temporais de dados ambientais em formato *GeoTIFF*, com abrangência nacional. Os arquivos foram posteriormente processados e recortados para delimitar a área de estudo.

Os dados referentes ao traçado do Arco Metropolitano foram obtidos por meio do portal do Departamento Nacional de Infraestrutura de Transportes (DNIT, 2024), no formato *shapefile*.

Foram incorporados dados vetoriais da malha territorial, setores censitários e grade estatística, disponibilizados pelo Instituto Brasileiro de Geografia e Estatística (IBGE), anos de 2000 e 2010, com o objetivo de subsidiar análises espaciais e demográficas.

Informações sobre governança fundiária foram extraídas do portal do Instituto Nacional de Colonização e Reforma Agrária (INCRA), enquanto os dados socioeconômicos, demográficos e de desenvolvimento humano foram obtidos junto à Agência Estadual de Planejamento e Pesquisas de Pernambuco (CONDEPE/FIDEM), contemplando os mesmos recortes temporais (2000, 2010 e 2020).

Os *softwares* empregados foram o QGIS Desktop 3.44.1, com o complemento MOLUSCE; e o ArcGIS Desktop 10.5 com o complemento *Land Change Modeler*

(LCM) 2.0. As extensões LCM e MOLUSCE requerem que os arquivos de entrada estejam no formato *raster (GeoTIFF)*, com o mesmo sistema de referência, projeção e resolução espacial. Todos os dados tabulados foram compilados com o auxílio do *software Microsoft Office Excel*.

Na tabela 2 é apresentado um resumo das fontes de dados utilizadas na elaboração deste trabalho.

Tabela 2 - Fontes de dados utilizada e principais dados coletados

FONTE DE DADOS	DESCRIÇÃO	TIPO
DNIT	Traçado do Arco Metropolitano da cidade do Recife	<i>Shapefile</i>
MAPBIOMAS	Mapas de usos e cobertura da terra	Imagens <i>GeoTIFF</i>
IBGE	Malha territorial Pernambuco	<i>Shapefile</i>
	Dados censitários Pernambuco	Planilha
	Grade estatística	<i>Shapefile</i>
INCRA	Governança fundiária	Planilha
CODEPE/FIDEM	Socioeconômicos e desenvolvimento humano	Planilha

Fonte: O autor (2025)

3.3 MÉTODOS

3.3.1 Preparação de dados para utilização no MOLUSCE

A metodologia adotada neste estudo visa à detecção e análise das mudanças no uso e cobertura da terra na área de influência do Arco Metropolitano do Recife, com base em dados geoespaciais e modelagem preditiva. Para garantir a compatibilidade, os dados foram previamente preparados em três etapas principais: preparação dos dados, carregamento dos dados e geração da matriz de transição.

Conforme o relatório de impacto ambiental (EIA-RIMA) elaborado para o empreendimento (CPRH, 2020), a área de influência indireta (AII) foi definida como de 10km em torno do eixo do arco e a área de influência direta (AID) como uma faixa de 1km. Em função da resolução do *pixel* deste estudo ser de 1km x 1km, a opção de utilizar o *buffer* de 1km (AID) para esse trabalho se mostrou ineficaz, pois teríamos somente a configuração de 01 *pixel* para cada lado do eixo da rodovia, impossibilitando análises de mudanças de uso e cobertura da Terra por aspectos de não termos *pixels* vizinhos que contribuíssem nesse aspecto de análise. Optou-se pela utilização de *buffer* de 5km, onde essa faixa se encontra entre as áreas de AII e AID determinada para o empreendimento e possibilita aumento significativo no número de *pixels* a serem considerados nas análises de vizinhança do *pixel* central.

A modelagem com o LCM permite não apenas quantificar as mudanças, mas também espacializá-las, identificando áreas com maior propensão à conversão de uso. A abordagem utilizada segue os princípios descritos por Paegelow e Camacho Olmedo (2005).

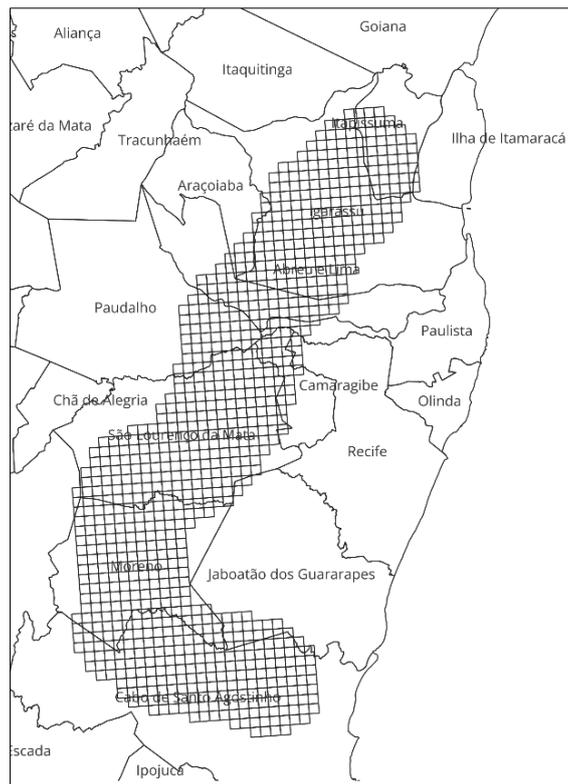
O *plugin* MOLUSCE permite a geração de matrizes de transição, também utilizando uma abordagem *Markoviana*. Um processo estocástico (aleatório) revela a propriedade *markoviana*, se os estados anteriores do processo são irrelevantes para a predição dos próximos estados, desde que o estado atual seja conhecido (Mishra; Rai, 2016).

3.3.1.1 Tratamento espacial da grade estatística do IBGE (2010), reajustando o grid para células de 1x1km

A geração da grade estatística por parte do IBGE foi iniciada em 2007 e se consolidou com a disponibilização dos dados do Censo de 2010. A disponibilização de dados através de grades estatísticas visam, principalmente, atender a demanda de se ter dados em unidades geográficas pequenas e estáveis ao longo do tempo, facilitando a comparação dos dados nestas unidades específicas (IBGE, 2016).

Em regiões de áreas urbanas, pode-se encontrar para algumas regiões as grades estatísticas com resoluções de até 250x250m. mas em áreas rurais esta resolução mínima é em grande parte das localidades de 1x1km. Como forma de padronizar a malha de análise, em função da área de estudo e para atender as premissas de *input* do MOLUSCE, optou-se por utilizar a malha de 1x1km como visto na figura 2.

Figura 2 - Grade estatística IBGE - resolução 1 x 1km (região de estudo)



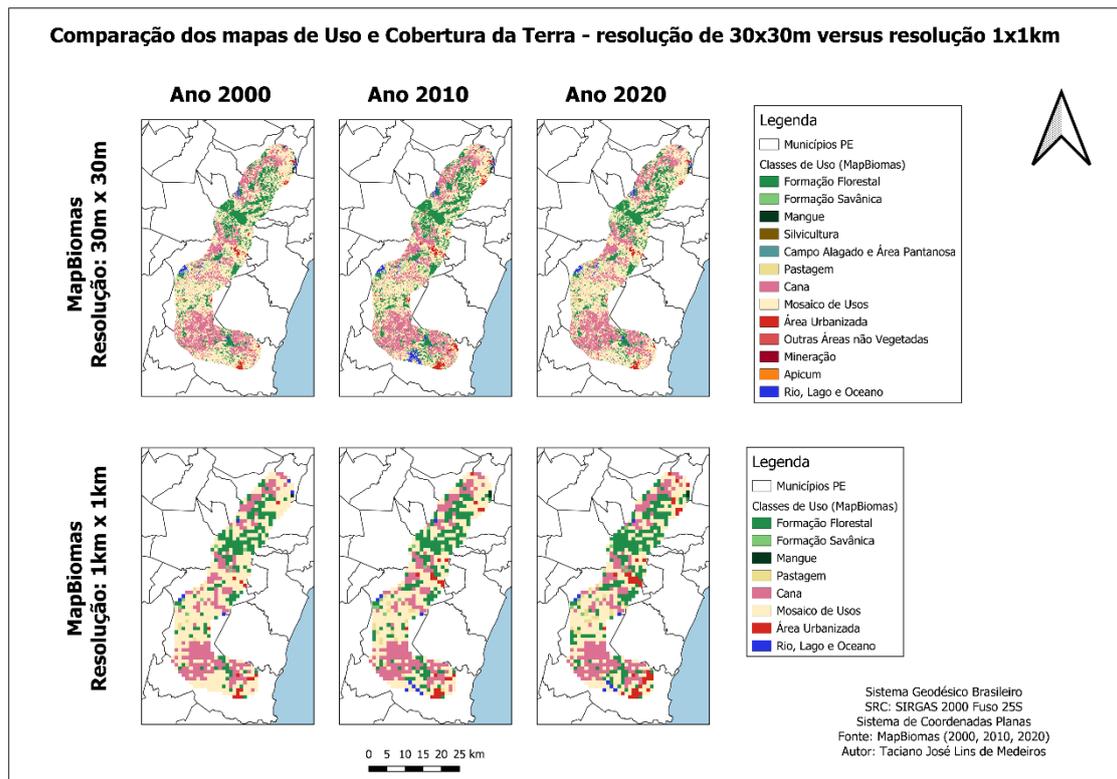
Fonte: O autor (2025)

3.3.1.1 Delimitação do raster de uso e cobertura do solo do MapBiomias

Para a análise de mudanças de uso e cobertura do solo, foram utilizados os *rasters* da coleção do MapBiomias referentes aos anos de 2000, 2010 e 2020 (resolução original de 30x30m). Inicialmente, os dados foram recortados para delimitar a área de estudo. Em seguida, realizou-se uma reamostragem espacial por agregação, convertendo a resolução dos *rasters* de 30x30 metros para 1x1 quilômetro, visando compatibilizar a escala de análise e reduzir a complexidade computacional.

As imagens originais (30x30m) e as reamostradas (1x1 km) dos três anos analisados são apresentadas na figura 3. Esses produtos processados serviram como dados de entrada para o módulo MOLUSCE, permitindo a modelagem de transições e projeções temporais.

Figura 3 - Imagens *raster* originais do MapBiomias, anos 2000, 2010 e 2020, com resolução de 30×30m e reamostrados para resolução de 1×1 km



Fonte: O autor (2025)

3.3.1.2 Pré-processamento das variáveis de influência escolhidas para o MOLUSCE

O tratamento das variáveis selecionadas para o estudo consistiu em quatro etapas principais de preparação dos dados, visando sua adequação como *inputs* para o MOLUSCE: na primeira etapa, realizou-se a associação espacial (*join*) entre dados tabulares em formato *Excel* (contendo indicadores socioeconômicos, demográficos ou ambientais) e o *shapefile* de setores censitários, garantindo o georreferenciamento das informações.

Na segunda etapa, aplicou-se um processo de desagregação espacial utilizando a ferramenta *Tabulation Area* do ArcGIS. Este método redistribuiu os valores dos setores censitários para uma grade regular de 1×1 km do IBGE, com base na proporção de sobreposição de áreas entre as unidades censitárias e os *pixels* da grade.

Na terceira etapa, os dados desagregados foram normalizados em ambiente *Excel* por meio do cálculo da diferença percentual entre os valores de 2000 e 2010 para cada *pixel*. Essa normalização temporal permitiu classificar os *pixels* em intervalos específicos (variações de 20 em 20%), transformando as variáveis brutas em indicadores de mudança

comparáveis e adequados para alimentar o algoritmo do MOLUSCE. A normalização dos percentuais em valores de *pixel* seguiu os critérios apresentados na Tabela 3.

Tabela 3 - Critérios de normalização de valores percentuais em valores de *pixel*

Valor percentual	Valor de <i>Pixel</i>
Nenhum Dado	0
Menor que -100	1
Maior/igual a -100 e menor que -80	2
Maior/igual a -80 e menor que -60	3
Maior/igual a -60 e menor que -40	4
Maior/igual a -40 e menor que -20	5
Maior/igual a -20 e menor que 0	6
Igual a 0	7
Maior que 0 e menor/igual a 20	8
Maior que 20 e menor/igual a 40	9
Maior que 40 e menor/igual a 60	10
Maior que 60 e menor/igual a 80	11
Maior que 80 e menor que 100	12
Maior/igual a 100	13

Fonte: O autor (2025)

Um compilado das variáveis utilizadas neste trabalho está apresentado na Tabela 4, onde consta a descrição da variável e sua equação de cálculo, caso necessário.

Tabela 4 - Dados das variáveis influentes utilizadas no processo (dados normalizados)

Variáveis utilizadas no estudo extraídas diretamente da base de dados (IBGE: 2000 e 2010)				
Variável	Censo 2000		Censo 2010	
	Tabela	ID	Tabela	ID
Domicílios Particulares Permanentes (DPPs)	Domicílio_PE	V0003	Domicilio01_PE	V002
Total Rendimento Nominal Mensal Dos Responsáveis (Em Reais)	Responsavel1_PE	V0623	ResponsavelRenda_PE	V022
Variáveis utilizadas no estudo calculadas a partir da base de dados (IBGE: 2000 e 2010)				
Variável	Censo 2000 (Cálculo)		Censo 2010 (Cálculo)	ID
Percentual de DPPs Precários	(Dom_V0014/Dom_V0003) *100		(Dom1_V011/Dom1_V002) *100	V1
Percentual Pessoas Alfabetizadas	(Instr1_V2248/Morad_V0239) *100		(Pes1_V001/Bas_V002) *100	P_ALFA P
Variáveis auxiliares utilizadas nos cálculos (IBGE 2000 e 2010)				
Variável	Censo 2000		Censo 2000	
	Tabela	ID	Tabela	ID
DPPs em outra condição de ocupação (não são próprios, nem alugados, nem cedidos).	Domicílio_PE	V0014	Domicilio01_PE	V011
Pessoas alfabetizadas com 5 ou mais anos de idade	Instrucao1_PE	V2248	Pessoa1_PE	V001
Moradores em domicílios particulares permanentes ou população residente em domicílios particulares permanentes	Morador_PE	V0239	Básico_PE	V002

Fonte: O autor (2025)

Adicionalmente na Tabela 5, constam os códigos que utilizamos para identificar essas variáveis no *plugin* MOLUSCE.

Tabela 5 - Códigos identificadores das variáveis de entrada no MOLUSCE

Variável	Código no MOLUSCE
Domicílios Particulares Permanentes	pDom
Total Rendimento Nominal Mensal Dos Responsáveis	pResp
Percentual de DPPs Precários	pV01
Percentual Pessoas Alfabetizadas	pAlfap

Fonte: O autor (2025)

Por fim, na quarta etapa, foi realizado o *Join* novamente das categorias de *pixels* ao *grid* do IBGE, utilizando o código de 1x1km como base.

3.3.1.3 Rasterização dos dados processados em grade 1×1 km

As variáveis foram convertidas para o formato *raster* utilizando como base a grade regular de 1×1 km do IBGE. Os dados tabulares resultantes da etapa anterior foram associados à malha vetorial do *grid*, atribuindo-se a cada célula os respectivos valores processados, como pode ser verificado na figura 4, com destaque para o objeto (*pixel*) 50 com valor de pDom = 5 (indicando que houve uma diminuição percentual na faixa entre 20 e 40%, comparando os anos de 2010 e 2000).

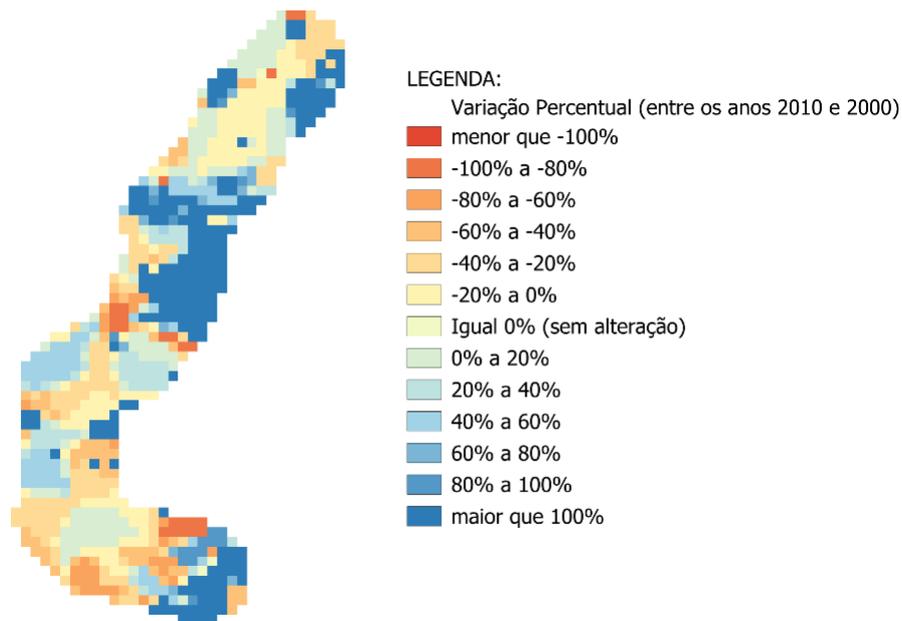
Figura 4 - *Print* da tabela de atributos do QGIS com valores de *pixels* das variáveis

OBJECTID	nome_1KM	Shape_Leng	Shape_Area	pxDom	pxResp	pxPes	pxV01	pxalfap
50	1KME7041N10...	4001,68499727...	1000672,49219...	5	10	5	1	1
59	1KME7042N10...	4001,65935356...	1000659,41003...	5	10	5	1	1
60	1KME7042N10...	4001,66053875...	1000660,27549...	5	10	5	1	1
68	1KME7043N10...	4001,63352557...	1000646,23711...	6	11	5	1	1
69	1KME7043N10...	4001,63481752...	1000647,15541...	5	10	5	1	1
70	1KME7043N10...	4001,63620190...	1000648,12182...	5	10	5	1	1
77	1KME7044N10...	4001,60856041...	1000633,49467...	9	13	9	1	1
78	1KME7044N10...	4001,60966667...	1000634,31923...	6	13	6	1	1
79	1KME7044N10...	4001,61086574...	1000635,19053...	13	13	13	1	1
80	1KME7044N10...	4001,61225025...	1000636,15541...	5	10	5	1	1
86	1KME7045N10...	4001,58299712...	1000620,45473...	9	13	9	1	1
87	1KME7045N10...	4001,58439541...	1000621,42584...	9	13	9	1	1
88	1KME7045N10...	4001,58550212...	1000622,25011...	8	13	8	1	1
89	1KME7045N10...	4001,58668606...	1000623,11407...	5	10	5	1	1
90	1KME7045N10...	4001,58780765...	1000623,94665...	5	10	5	1	1
96	1KME7046N10...	4001,55921783...	1000608,57710...	9	13	9	1	1

Fonte: O autor (2025)

Por meio do QGIS, a camada *shapefile* foi convertida em *raster*, mantendo a resolução espacial de 1×1 km e preservando os valores das variáveis em cada *pixel*. O *raster* resultante, como exemplificado na figura 5, variável quantidade de domicílios, representa a entrada final padronizada para o MOLUSCE, integrando todas as variáveis processadas em um formato espacialmente adequado para a modelagem de mudanças de uso e cobertura da Terra.

Figura 5 - Exemplo de *raster* gerado a partir do *grid* IBGE – variável quantidade de domicílios



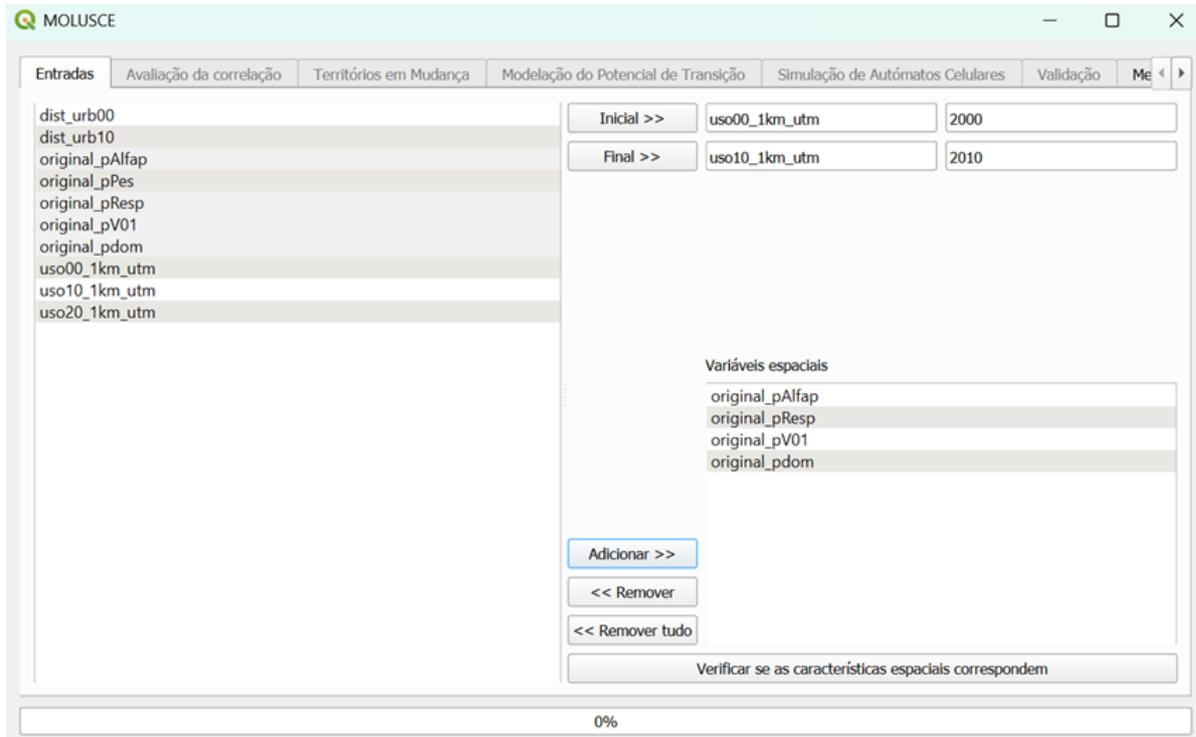
Fonte: O autor (2025)

3.3.2 Ferramenta MOLUSCE

3.3.2.1 Entrada dos dados tratados

A primeira interface do *plugin* MOLUSCE é composta pela aba “*Entradas*”, responsável pela adição dos mapas de uso e cobertura da terra, pelos campos “*Inicial*” e “*Final*” e das “*variáveis de espaciais*”, sendo importante ressaltar que todos os arquivos utilizados devem ser do tipo *raster*, possuírem as mesmas dimensões espaciais, o mesmo tamanho de *pixel* e a mesma projeção, verificando tais critérios por meio do botão “*verificar se as características espaciais correspondem*”, como pode ser observado na figura 6.

Figura 6 - Tela de primeira interface do MOLUSCE - dados de entrada

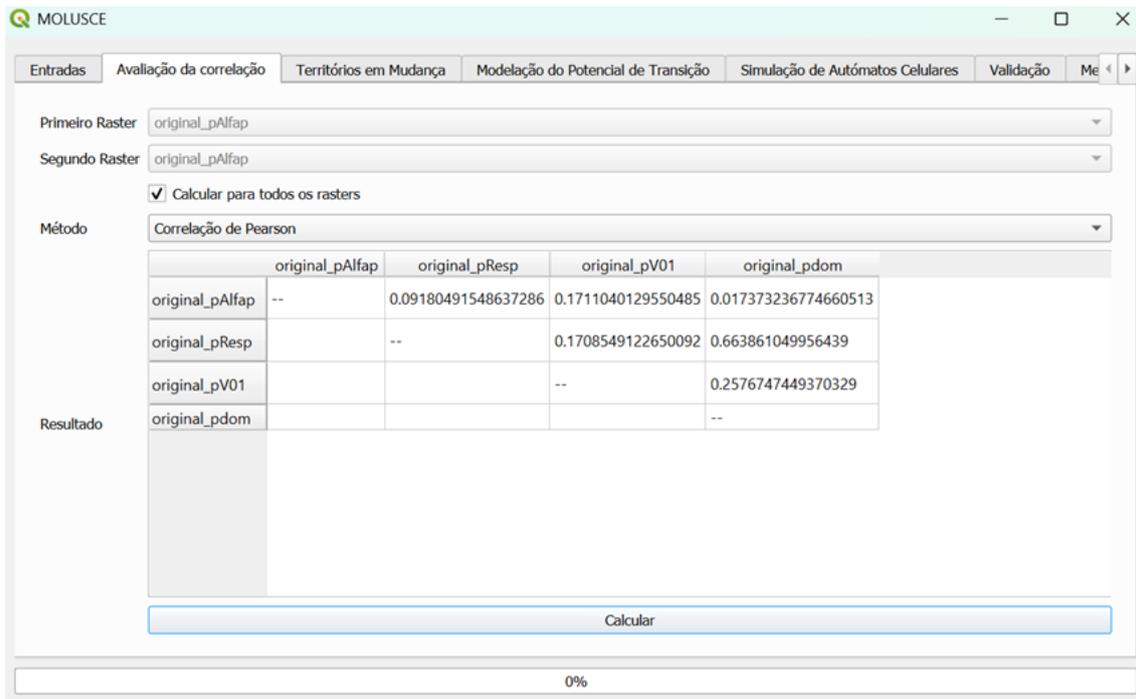


Fonte: O autor (2025)

3.3.2.2 Análise da correlação entre as variáveis influentes

Na segunda interface, representada na figura 7, que corresponde à “avaliação de correlação”, é possível realizar técnicas de análise de correlação entre as variáveis, podendo ser feitas por meio de apenas 2 arquivos *rasters* ou analisando todos eles de forma conjunta. As opções de técnicas disponíveis são a Correlação de *Pearson*, o Coeficiente de *Cramer* e a Incerteza de informação conjunta, sendo que os dois últimos podem ser utilizados apenas para dados categóricos. Foi utilizada a correlação de *Pearson* considerando o tipo de dados utilizados (quantitativo). O coeficiente de *Pearson* é definido por Figueiredo Filho e Silva Júnior (2009) como “uma medida de associação linear entre variáveis”, onde a linearidade ocorre devido ao padrão de relacionamento entre duas variáveis serem representados por uma linha reta, onde um acréscimo ou um desconto de uma unidade representada na variável X acarreta o mesmo impacto na variável Y.

Figura 7 - MOLUSCE – avaliação de correlação, método de *Pearson*

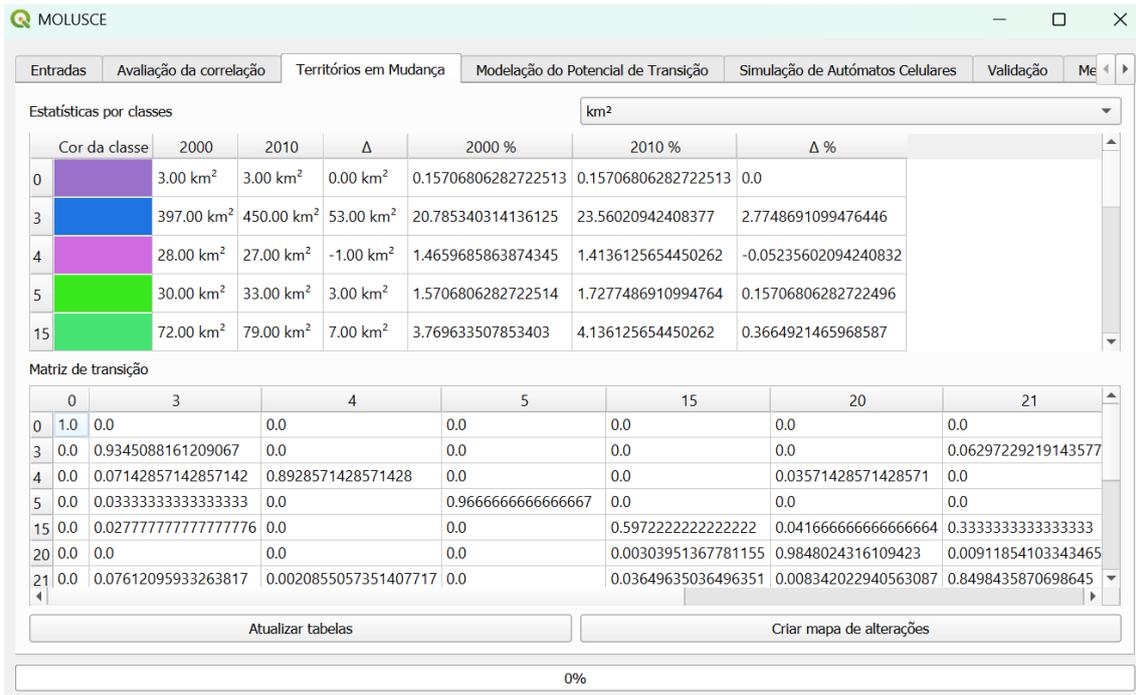


Fonte: O Autor (2025)

3.3.2.3 Análise do território de mudanças

A terceira interface do MOLUSCE é composta pela aba “*território de mudança*”. Nesse espaço é possível analisar e comparar mapeamentos de uso e cobertura da terra de anos diferentes. No campo “*estatísticas por classes*” é gerado uma tabela com a área ocupada por cada classe no mapeamento de uso e cobertura da terra inicial e no final, enquanto no campo “*matriz de transição*” é obtida uma matriz de transição entre as classes de usos e cobertura da terra, que se resume na proporção de *pixels* modificados de uma classe para outra, como demonstrado na figura 8.

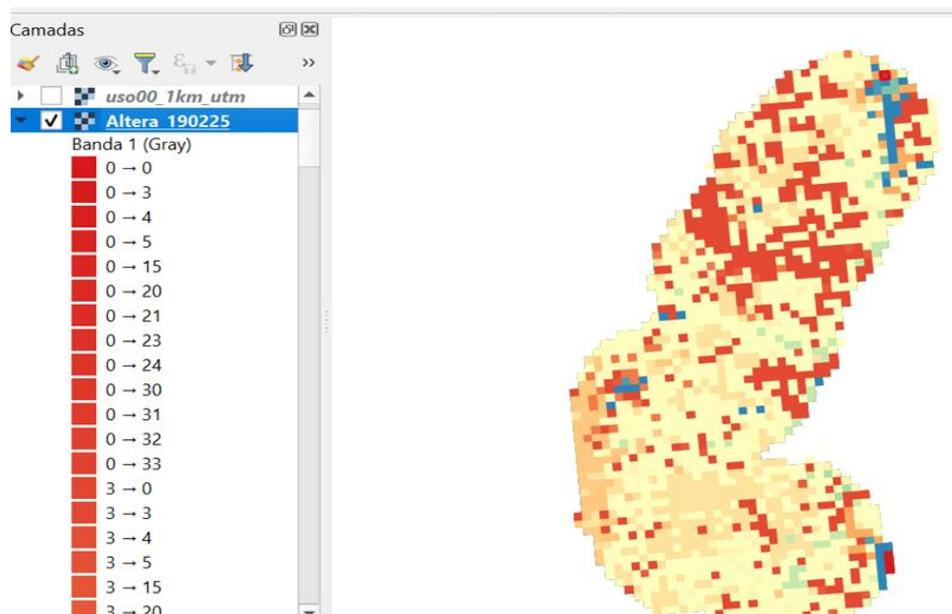
Figura 8 - MOLUSCE - estatísticas por classes



Fonte: O autor (2025)

No campo “criar mapa de alterações” é gerado um mapa indicando espacialmente os locais de alteração de um uso e cobertura da terra para outro. Além da matriz de transição, também é gerado um *raster* com a classificação de todas as transições de usos possíveis (ocorridas ou não) na região, como exemplificado na figura 9.

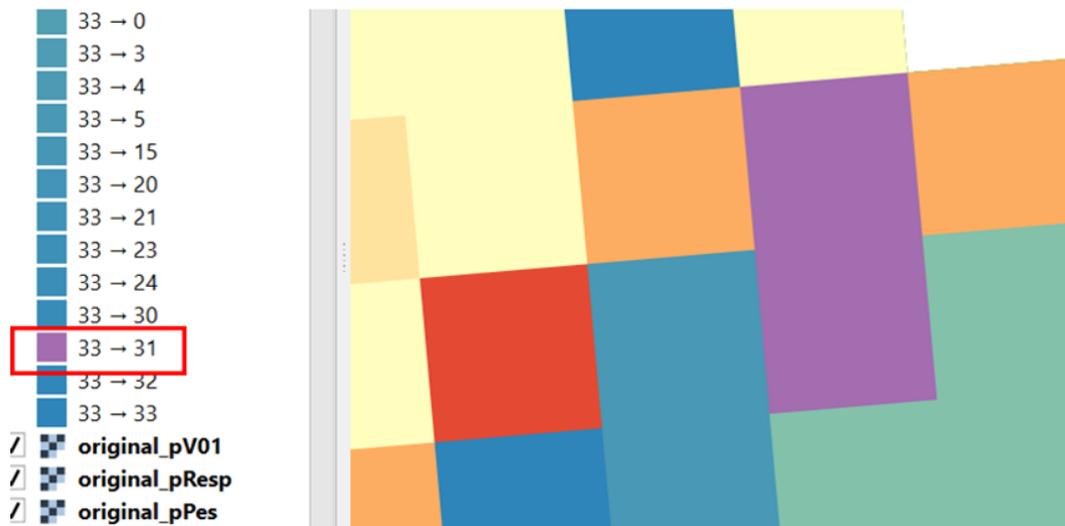
Figura 9 - MOLUSCE – mapa de alterações



Fonte: O autor (2025)

A título de exemplo, segue *print* da região aproximada onde a classificação indica que a transição do uso “Rio, lago e oceano” (*pixel* 33) em 2000 para o uso “Aquicultura” (*pixel* 31) em 2010, figura 10.

Figura 10 - MOLUSCE – variações de classe de *pixel*



Fonte: O autor (2025)

3.3.2.4 Processo de modelagem e aprendizado de máquina

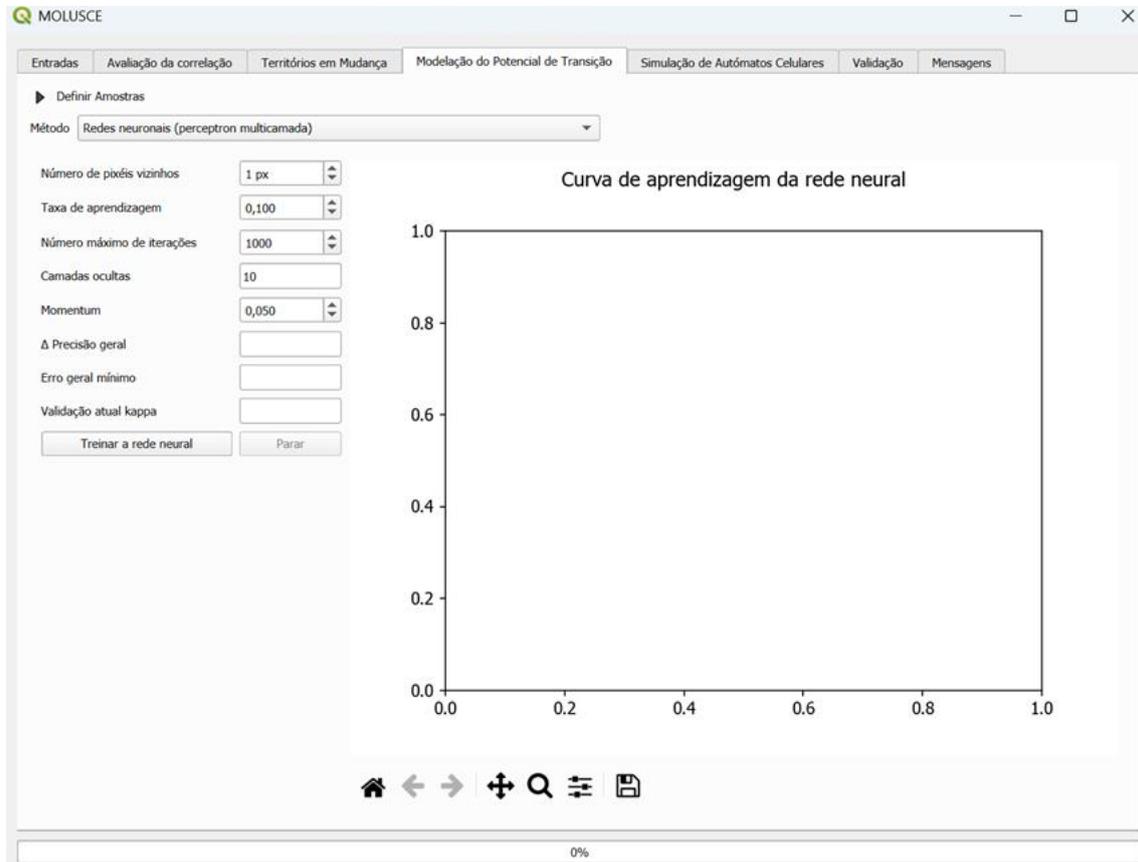
Na quarta interface do MOLUSCE, observa-se a “*modelação do potencial de transição*”, ambiente destinado à elaboração do potencial de transição do uso e cobertura da terra, ou seja, são obtidos valores relativos à probabilidade ou potencial de mudança de uma classe de uso e cobertura da terra para outra, representados quantitativamente com valores que variam de 0, representando um baixo potencial de transição, a 100, classificados como um alto potencial de transição.

É disponibilizado pelo MOLUSCE os métodos de modelagem de uma Rede Neural Artificial do tipo percepção por multicamadas, Regressão Logística (LR), Avaliação Multicritério (MCE) e Pesos de Evidência (WoE), sendo possível ainda a escolha dos valores dos parâmetros adaptáveis de cada modelo, como pode ser visto na figura 11, com o exemplo da Rede Neural Artificial, método utilizado no presente estudo.

Os parâmetros utilizados foram: *i*) Número de *pixel* vizinho: indica o raio de análise da máquina com relação às alterações de categorias. O raio de 1 *pixel* foi escolhido com o intuito da máquina verifica apenas o tipo de categoria que está diretamente ligado ao *pixel* central (vizinho direto); *ii*) Demais parâmetros mantivemos o padrão do

MOLUSCE.; *iii*) Depois proceder com o início dos testes da rede neural; *iv*) Extrair os resultados e utilizar em análises necessárias – Índice Kappa; *v*) Gerar o *raster* de predição do processo.

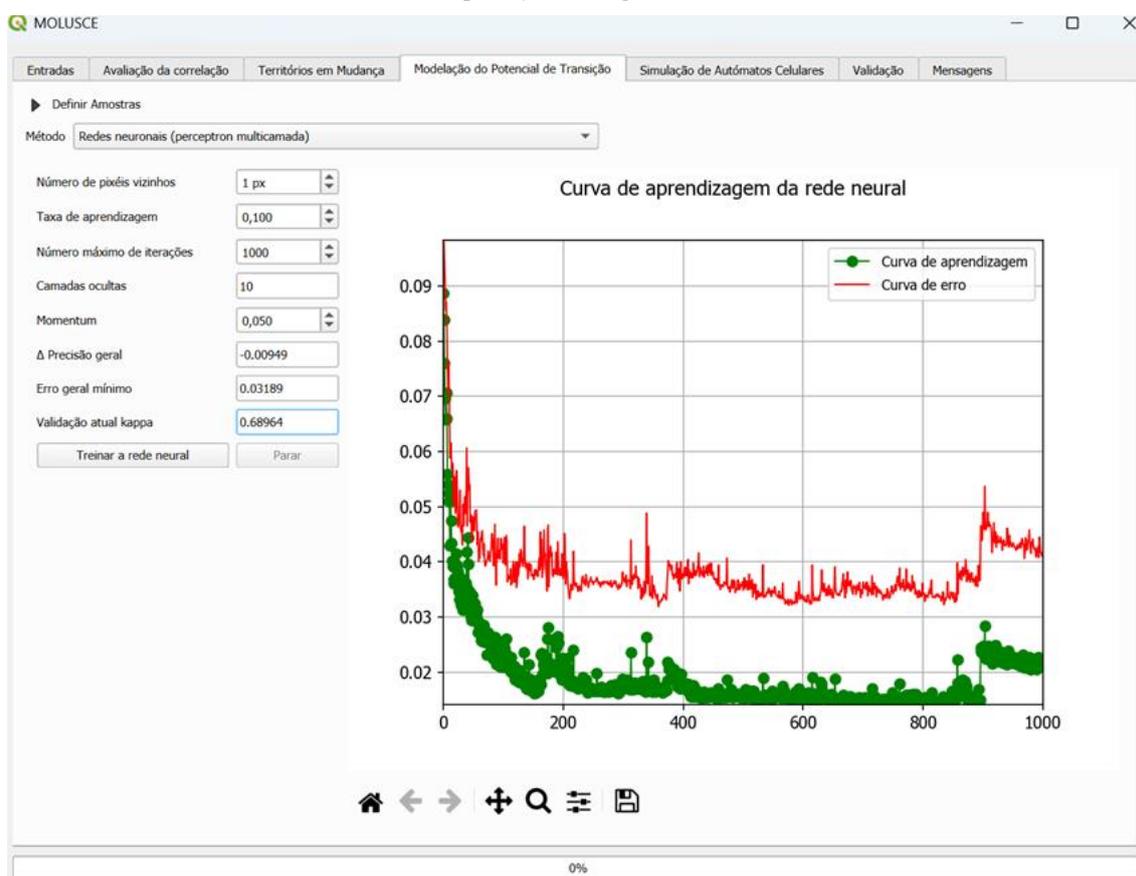
Figura 11 - MOLUSCE – tela de teste de rede neural



Fonte: O autor (2025)

Abaixo na figura 12, podemos verificar um exemplo de dados de saída do MOLUSCE, que apresenta a curva de aprendizagem da rede neural e os resultados de precisão geral, erro geral mínimo e validação atual Kappa, após o treinamento da rede neural efetivado.

Figura 12 - Tela com os resultados do índice Kappa e gráfico de aprendizagem relacionados ao modelo de predição a ser gerado



Fonte: O autor (2025)

3.3.2.5 Processo de predição por automação

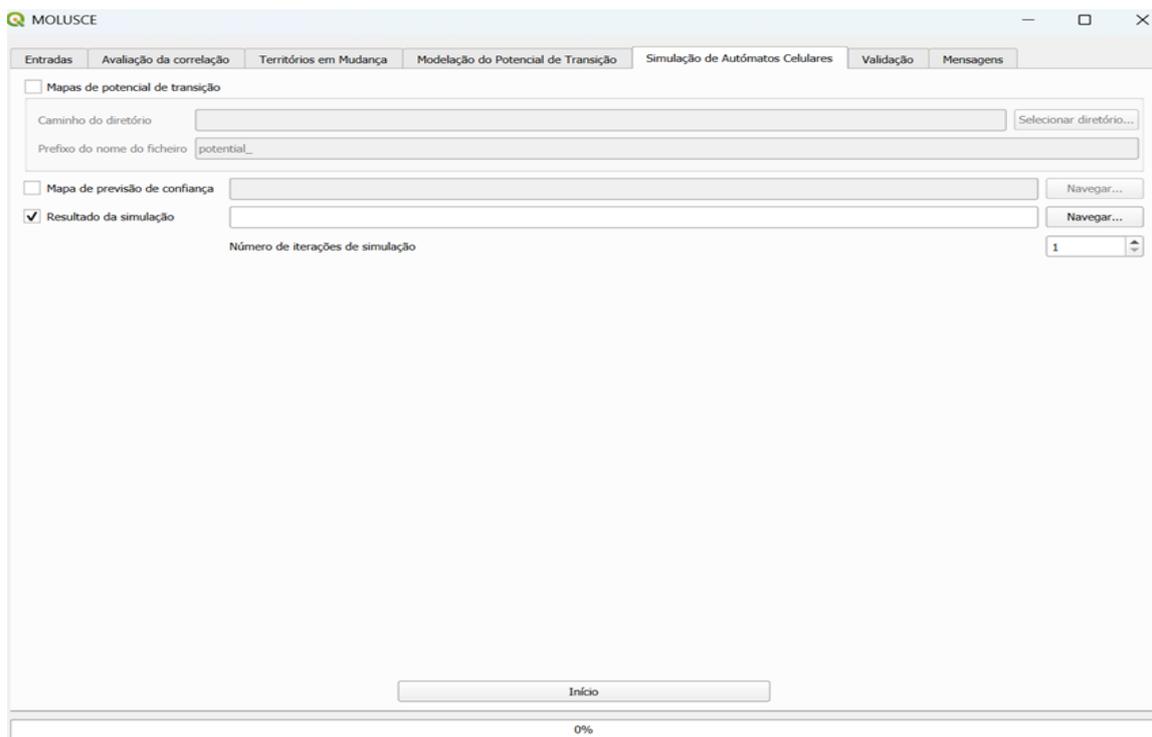
A quinta interface do MOLUSCE, representando a área “*simulação de autômatos celulares*”, utilizado para gerar o mapa projetado de uso e cobertura da terra. No campo “*mapas de potencial de transição*” é escolhido a pasta onde serão salvos os arquivos correspondentes ao potencial de transição gerado na interface anterior, o campo “*resultado da simulação*” produz o mapa de uso e cobertura da terra simulado, se baseando em um modelo autômato celular¹ na abordagem Monte Carlo².

¹ Os Autômatos celulares (*Cellular Automata - CA*) foram criados por John von Neumann e Stanislaw Ulam no final da década de 1940, com o intuito de elaborar estudos capazes de analisar sistemas complexos e sistemas com capacidade de autorreprodução (VON NEUMANN, 1966). Conforme abordado por Castro (2008), eles são sistemas físicos compostos por componentes discretos com interações locais, correspondendo a sistemas evolutivos que a partir de uma configuração inicial, cada elemento do sistema evolui de acordo com o seu estado atual, com o estado de seus vizinhos e por meio de um conjunto de regras que são iguais para todos esses elementos.

² O Método de Monte Carlo é uma técnica de amostragem artificial empregada para operar numericamente sistemas complexos que tenham componentes aleatórios (...) são realizadas diversas simulações onde, em cada uma delas, são gerados valores aleatórios para o conjunto de variáveis de entrada e parâmetros do modelo que estão sujeitos à incerteza. Tais valores aleatórios gerados seguem distribuições de probabilidade específicas que devem ser identificadas ou estimadas previamente. O conjunto de resultados produzidos ao longo de todas as simulações poderão ser analisados estatisticamente e fornecer resultados em termos de probabilidade (Costa e Azevedo, 1996)

A escolha do tempo de prospecção realizado no modelo é feita no campo “*número de iterações da simulação*”, ao assinalar o valor 1 no campo, o modelo realizará uma prospecção correspondendo ao mesmo período entre o mapa inicial e o final, ou seja, inserindo um mapa inicial do ano 2000 e um mapa final do ano de 2010, seria gerado um mapa futuro para o ano de 2020. Se inserido o valor 2 nesse campo, o mapa projetado seria referente ao ano de 2030, levando em consideração o exemplo do presente estudo e mostrado na figura 13.

Figura 13 - Processo de criação do *raster* de predição



Fonte: O autor (2025)

3.3.2.6 Processo de validação

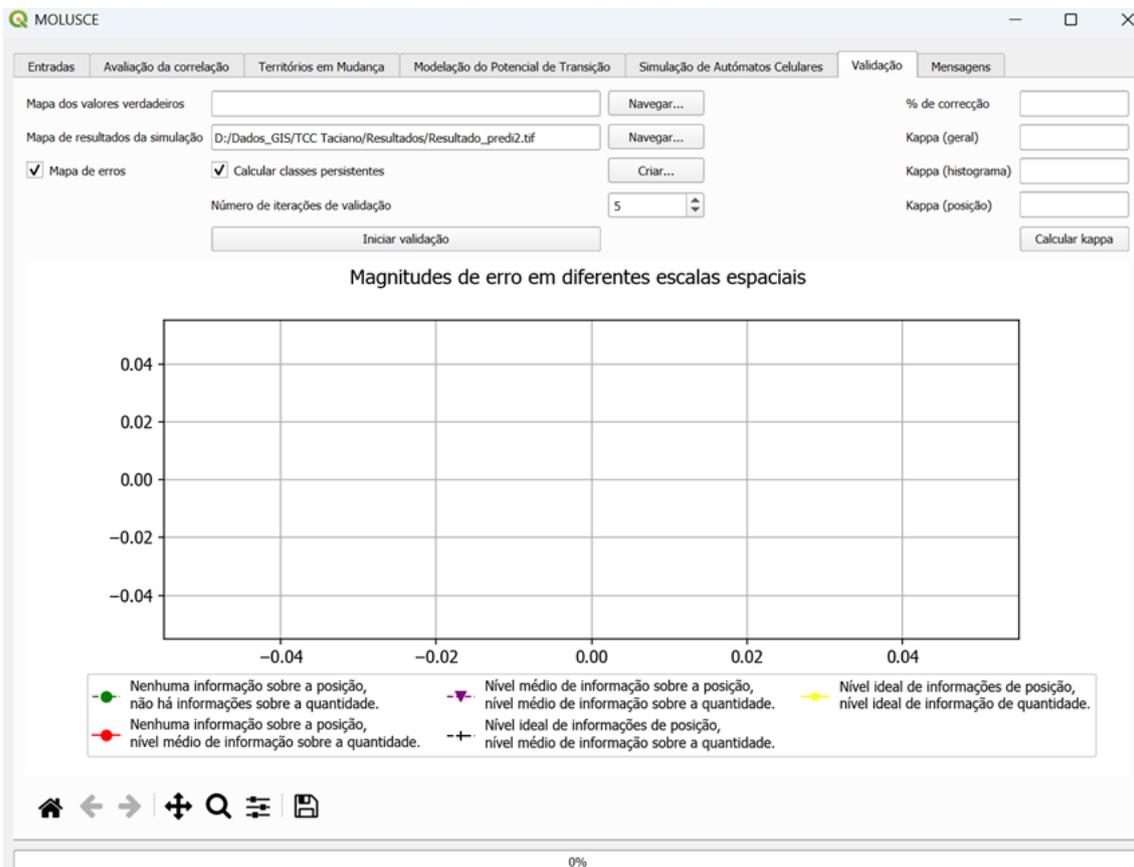
A aba “*validação*” é a etapa do processo que realiza a comparação entre o modelo de predição com o *raster* oficial da região (MapBiomass 2020), sendo a última interface funcional do MOLUSCE, é destinada para a avaliação da acurácia do mapeamento gerado, feito por meio do índice Kappa.

No campo “*mapa dos valores verdadeiros*” e “*mapa de resultados da simulação*” são inseridos mapas de uso e cobertura da terra de um mesmo ano, o primeiro correspondendo a um mapeamento de uso e cobertura da terra do próprio ano de interesse, e o segundo oriundo da simulação dos dois períodos anteriores do utilizado como referência, ou seja, se o mapa de referência for proveniente do ano de 2020, o mapa

simulado tem que ser fruto da projeção de um modelo composto pelos anos de 2000 e 2010.

O programa possibilita a realização de uma comparação em 3 vias, se habilitado pelo usuário o campo “*mapa de erros*”, utilizando além do mapa de referência e o mapa simulado de uso e cobertura da terra, o mapa de uso e ocupação da terra inicial e final. Após a análise pelo programa das divergências apresentadas entre o mapa de referência e o mapa simulado, é obtido a porcentagem de acerto (% de correção), Kappa (geral), Kappa (histograma) e Kappa (posição), abaixo segue a figura 14 com a demonstração desta aba do programa.

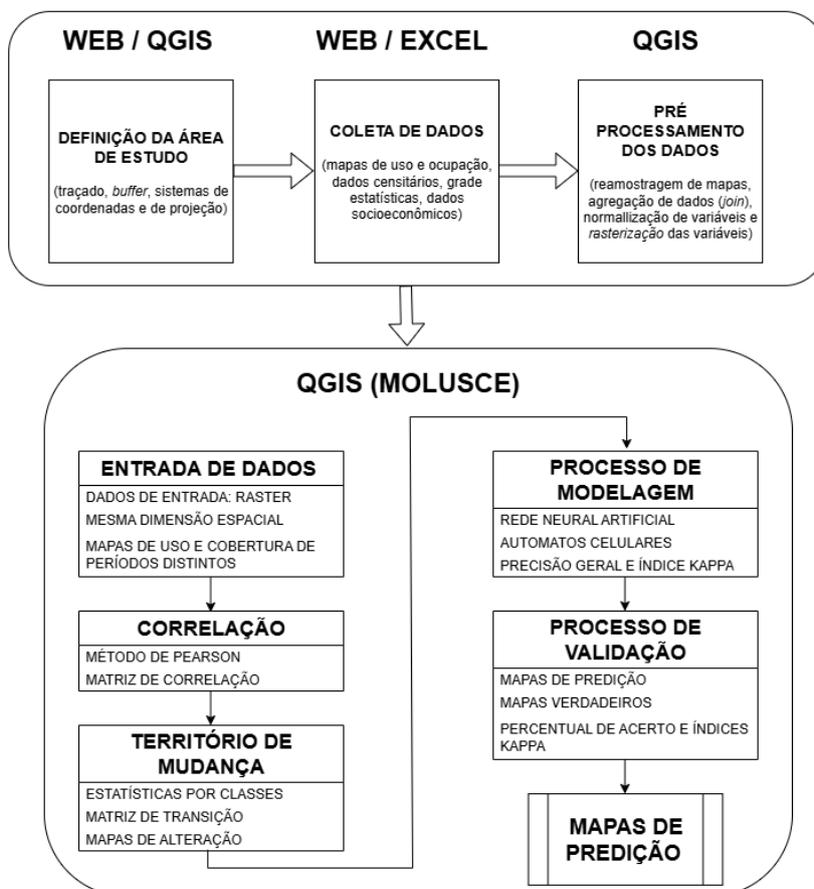
Figura 14 - Janela de validação com o *raster* oficial e análise da certeza (índice Kappa Geral)



Fonte: O autor (2025)

No fluxograma abaixo (Figura 15) é apresentado o passo a passo dos processos desenvolvidos no *plugin* MOLUSCE.

Figura 15 - Fluxograma dos processos desenvolvidos para utilização do MOLUSCE



Fonte: O autor (2025)

4 RESULTADOS E DISCUSSÃO

A análise realizada por meio da interface *Estatística de Classes* do MOLUSCE revelou os primeiros resultados sobre as dinâmicas de uso e cobertura da terra na região do Arco Metropolitano.

Os resultados da Figura 16 apresenta, em quilômetros quadrados, a área ocupada por cada classe de uso e cobertura da terra no início e no fim da simulação, anos 2000 e 2010, respectivamente. Além disso, indica a variação positiva ou negativa ocorrida ao longo do período analisado, bem como a porcentagem que cada classe representa em relação à área total da região do Arco Metropolitano.

Figura 16 - interface estatística de classes do MOLUSCE

Estatísticas por classes							km ²
Cor da classe	2000	2010	Δ	2000 %	2010 %	Δ %	
0	3.00 km ²	3.00 km ²	0.00 km ²	0.15706806282722513	0.15706806282722513	0.0	
3	397.00 km ²	450.00 km ²	53.00 km ²	20.785340314136125	23.56020942408377	2.7748691099476446	
4	28.00 km ²	27.00 km ²	-1.00 km ²	1.4659685863874345	1.4136125654450262	-0.05235602094240832	
5	30.00 km ²	33.00 km ²	3.00 km ²	1.5706806282722514	1.7277486910994764	0.15706806282722496	
15	72.00 km ²	79.00 km ²	7.00 km ²	3.769633507853403	4.136125654450262	0.3664921465968587	
20	329.00 km ²	336.00 km ²	7.00 km ²	17.225130890052355	17.591623036649214	0.36649214659685825	
21	959.00 km ²	868.00 km ²	-91.00 km ²	50.20942408376963	45.44502617801047	-4.764397905759161	
23	2.00 km ²	2.00 km ²	0.00 km ²	0.10471204188481675	0.10471204188481675	0.0	
24	37.00 km ²	58.00 km ²	21.00 km ²	1.9371727748691099	3.0366492146596857	1.0994764397905759	
30	3.00 km ²	3.00 km ²	0.00 km ²	0.15706806282722513	0.15706806282722513	0.0	
31	4.00 km ²	7.00 km ²	3.00 km ²	0.2094240837696335	0.36649214659685864	0.15706806282722513	
32	1.00 km ²	1.00 km ²	0.00 km ²	0.05235602094240838	0.05235602094240838	0.0	
33	45.00 km ²	43.00 km ²	-2.00 km ²	2.356020942408377	2.25130890052356	-0.10471204188481709	

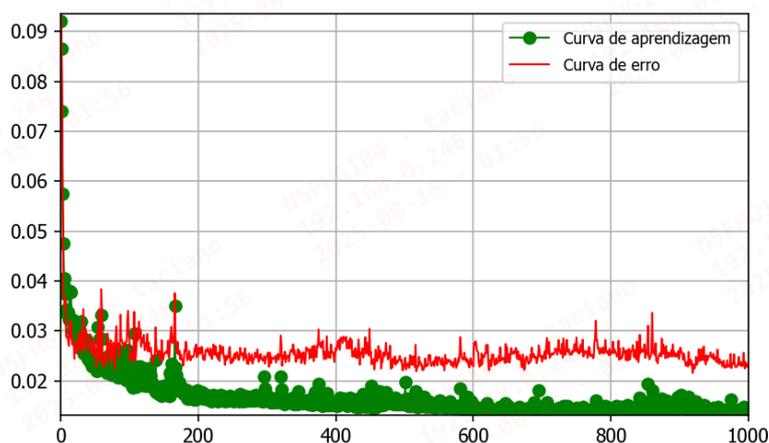
Fonte: O autor (2025)

É possível verificar a partir da Figura 16 para o período considerado de 10 anos, entre os anos 2000 e 2010, que houve o maior aumento na classe de cobertura de formação florestal com 53 km², seguido da classe de uso de área urbanizada com 21km². Já a classe mosaico de usos foi a que mais reduziu no período, com menos 91 km² de ocupação, embora continue predominante na região. De acordo com Haldar *et al.* (2024), a expansão urbana e a reorganização do uso da terra possuem tendências comuns em áreas periurbanas e de transição. Bairwa *et al.* (2025) destacam que mudanças no uso da terra podem ser previstas mesmo antes da implantação de grandes infraestruturas, como corredores viários. Li *et al.* (2024) observaram que o aumento de cobertura florestal pode refletir processos de regeneração ou mudanças na dinâmica de ocupação. Já Hurtt *et al.* (2020) enfatizam a importância de harmonizar dados históricos e futuros de uso da terra para compreender os impactos ambientais de longo prazo. Esses achados reforçam a importância de analisar as dinâmicas territoriais anteriores à construção de empreendimentos como o Arco Metropolitano, contribuindo para um planejamento mais sustentável.

A Figura 17 apresenta a curva de aprendizagem da rede neural utilizada no complemento MOLUSCE durante a execução da tarefa. Observa-se que, nas primeiras

300 iterações, o processo de aprendizado apresenta certa instabilidade, com variações mais acentuadas na curva (linha verde). A partir desse ponto, o modelo começa a se ajustar, e as oscilações tornam-se mais suaves. Já a curva de erro (linha vermelha) inicia em um patamar superior a 0,03, mas posteriormente se estabiliza em torno de 0,025, indicando uma melhora na performance da rede ao longo das iterações.

Figura 17 - Curva de aprendizagem rede neural



Fonte: O autor (2025)

Verificou-se, ainda, que o processo de aprendizado de máquina apresentou um erro mínimo geral de 0,02160 e um índice Kappa associado de 0,81128, o que indica um desempenho excelente. De acordo com os critérios de interpretação propostos por Landis e Koch (1977), valores de Kappa entre 0,81 e 1,00 são considerados excelentes, reforçando a qualidade do modelo gerado.

Foram analisados os resultados relativos ao modelo potencial de transição por rede neural e à simulação elaborada por autômatos celulares. Para validação e comparação, utilizou-se o mapa de uso e cobertura da terra do ano de 2020 como referência, confrontando-o com os resultados da simulação do período de 2000–2010. Os resultados obtidos foram considerados excelentes: foi alcançada uma precisão geral de 87,14%, representando a porcentagem de correspondência entre os mapas. Além disso, foram obtidos os seguintes índices Kappa: Kappa (geral) de 0,81659, Kappa (histograma) de 0,92417 e Kappa (posição) de 0,88359.

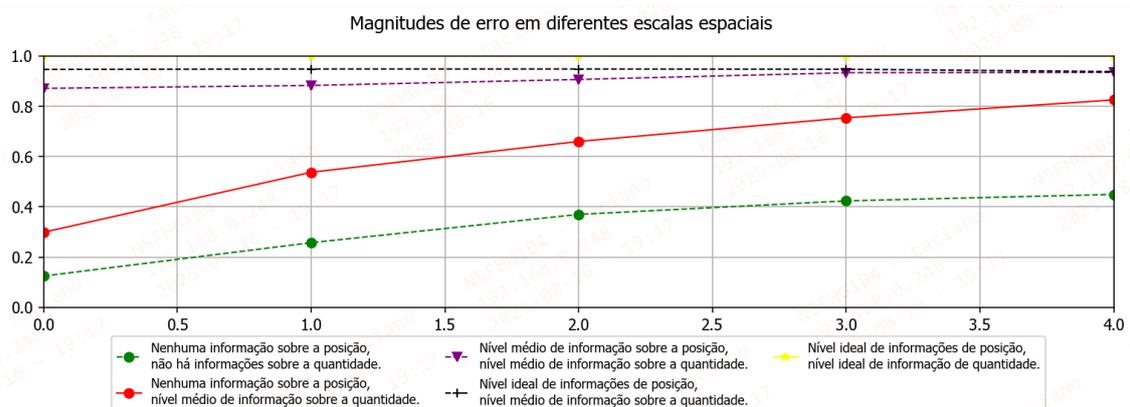
Os índices de precisão geral (87,14%) e Kappa (>0,81) obtidos indicam excelente desempenho do modelo, o que está alinhado com avanços recentes no uso de redes neurais e autômatos celulares para simulações espaciais aplicadas ao transporte. Por exemplo,

Feng *et al.* (2021) demonstram que a construção da rodovia Wujing, na China, provocou alterações significativas na cobertura vegetal e na temperatura da superfície, com impactos mensuráveis até 1000 metros de distância, reforçando a importância de modelos espaciais para prever tais efeitos.

Outro exemplo é o estudo de Aldileemi *et al.* (2023), que aplicaram o modelo CA-Markov para simular mudanças de uso e cobertura da terra em áreas urbanas da Líbia, alcançando índices Kappa superiores a 0,77, o que valida a eficácia da abordagem em cenários de expansão urbana induzida por infraestrutura de transporte rodoviário, como é o caso do Arco Metropolitano. Adicionalmente, Verma *et al.* (2020) destacaram que redes neurais aplicadas à classificação de uso da terra apresentam os maiores coeficientes de Kappa, sendo particularmente úteis para detectar mudanças associadas ao aumento da densidade viária e urbanização.

A Figura 18 compara o mapa simulado com o mapa de referência de 2020, mostrando uma hierarquia clara nos resultados do gráfico de erros. As curvas que representam as maiores divergências entre os mapas (as piores correspondências) têm os valores mais baixos, indicando menor qualidade de informação no *pixel*. A curva verde, com as piores incongruências, tem os menores valores. Em seguida, a curva vermelha representa as segundas piores divergências e também tem valores baixos, a curva roxa que representa médias divergências garante um nível mínimo de certeza de 85% e as próximas duas curvas, preta e amarela, têm uma probabilidade de certeza quase que total para todo nível de escala.

Figura 18 - Gráfico de erros da comparação dos mapas de 2020



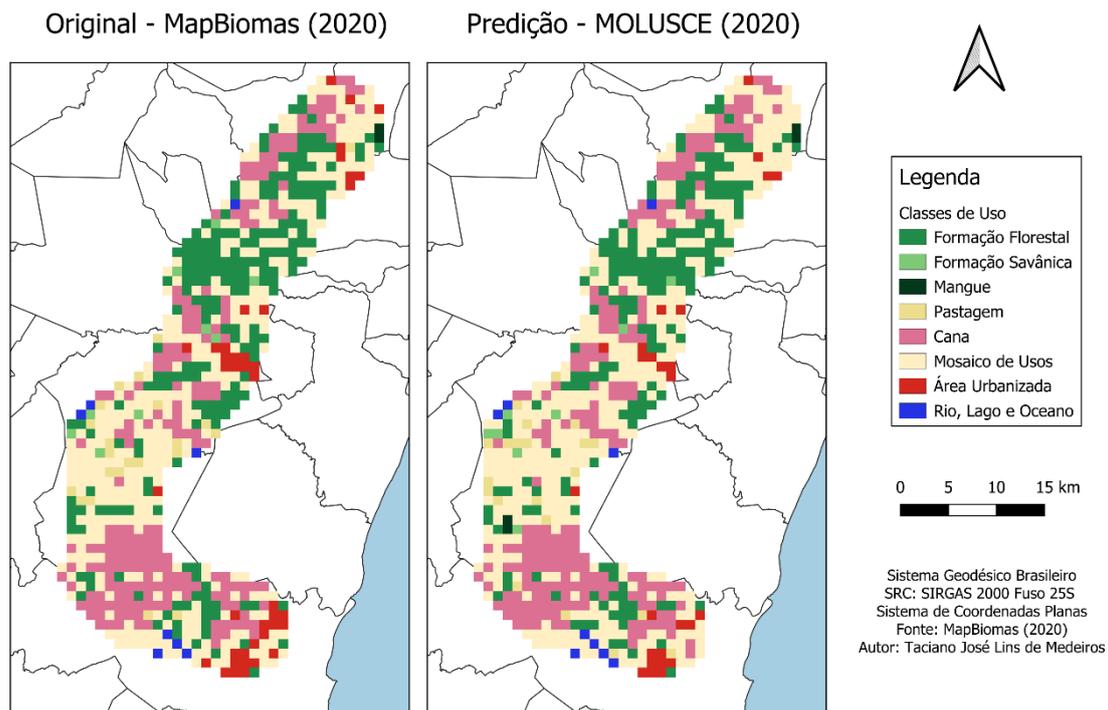
Fonte: O autor (2025)

A Figura 19 apresenta os dois *rasters* de uso e ocupação da terra para o ano de 2020: à esquerda, o mapa original do MapBiomass; à direita, o mapa gerado pelo

MOLUSCE. Para a região ao Norte da RMR (municípios de Igarassu, Itapissuma e Abreu e Lima) podemos destacar que o Mapa de Predição estimou uma diminuição dos usos de Formação Florestal e Área Urbanizada, mas o que foi verificado foi um aumento do Mosaico de Usos na mesma proporção que a diminuição prevista. Para a região mais ao centro, conhecido como o contorno do Recife e envolvendo os municípios de São Lourenço da Mata, Camaragibe e Paudalho, a previsão foi semelhante ao que foi comentado para o Setor Norte, e essa diminuição prevista da área de Floresta se concentrava mais próximo ao município de Paudalho, região onde está localizada a área de preservação ambiental APA-Aldeia/Beberibe. Ao Sul da RMR (municípios de Moreno, Jaboatão e Cabo de Santo Agostinho) a previsibilidade foi bem assertiva, ocorrendo basicamente alternância dos usos de Mosaico de Usos e Área Urbanizada.

Figura 19 - Comparação de *rasters* de Uso e Cobertura da Terra - Ano de 2020

Comparação dos mapas de Uso e Cobertura da Terra - Buffer do Arco Metropolitano



Fonte: O autor (2025)

A comparação entre o mapa original do MapBiomias e a predição gerada pelo MOLUSCE para o ano de 2020 demonstrou uma considerável similaridade espacial. Isso indica que o modelo conseguiu simular de forma consistente os padrões de uso e cobertura da terra observados. As áreas de maior conversão de uso, especialmente em regiões com predominância de solo antropizado, foram bem representadas pela simulação, embora

diferenças pontuais em zonas de transição revelem limitações do modelo em capturar certas dinâmicas locais.

O resultado da simulação é corroborado por estudos recentes que avaliam a acurácia de modelos de mudança de uso da terra em contextos de infraestrutura viária. Por exemplo, o estudo Gündüz (2025) revela que o uso de MOLUSCE aliado a algoritmos de aprendizado de máquina permite simulações confiáveis em áreas urbanas em crescimento, com destaque para zonas de transição, onde os erros tendem a se concentrar.

Além disso, foi resumido na Tabela 3 os usos mais significativos e recorrentes para o ano de 2020 na área de estudo. Observa-se total semelhança quanto aos usos mais significativos nos dois mapas observados e na relevância desses usos para o total do espaço amostral, sendo de 85% para o mapa original e de 95% para o mapa de predição.

Tabela 6 - Maiores usos verificados na área de interesse (Ano de 2020)

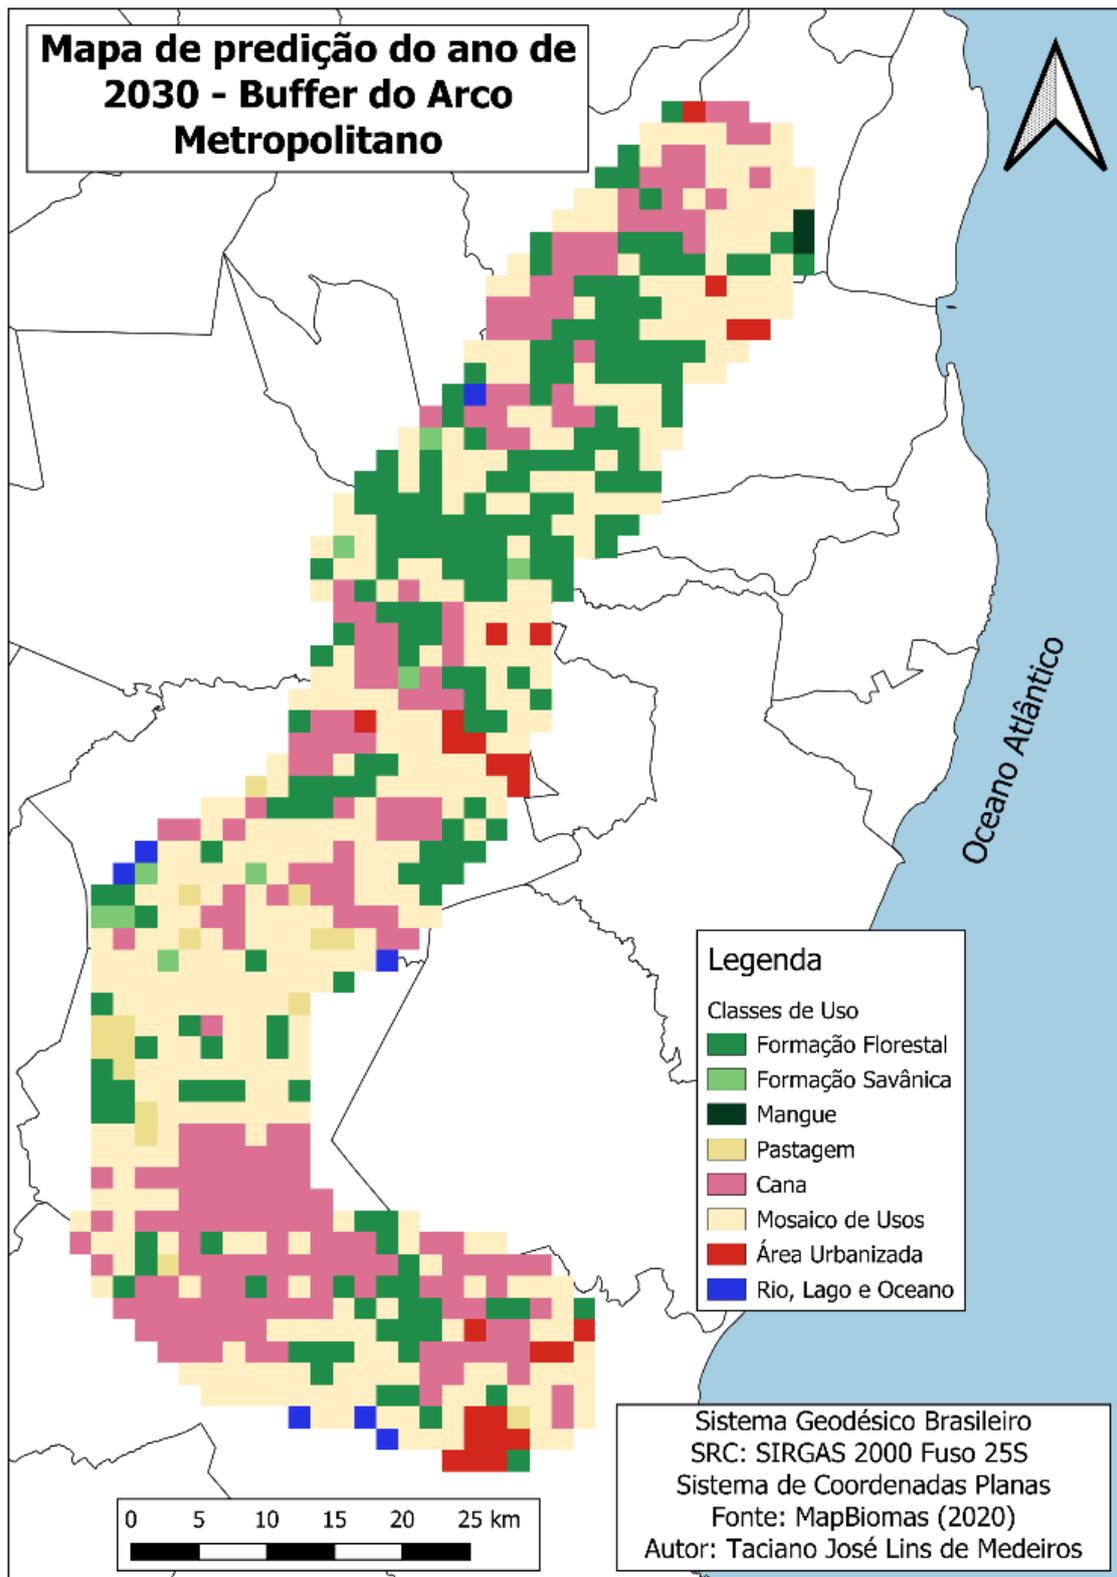
Classe de Uso	Original	Simulado
	% Área Total	% Área Total
Mosaicos de Usos	45%	50%
Formação Florestal	24%	26%
Cana de Açúcar	17%	19%

Fonte: O autor (2025)

Destaca-se ainda que, o mapa de predição do MOLUSCE apresentou áreas de cerca de 10% maiores quando comparadas com as áreas originais do MapBiomas, sendo sugestivo de impacto das variáveis influentes (socioambientais) nesta majoração.

Por fim, a Figura 20 apresenta o Mapa de projeção para área de entorno do Arco Metropolitano para o ano de 2030, elaborado através do *plugin* MOLUSCE.

Figura 20 - Mapa de Uso e Ocupação da Terra (predição para o ano de 2030)



Fonte: O autor (2025)

Ressalta-se que, para a elaboração do mapa de uso e cobertura da terra da área de influência (*buffer* de 5 km) do Arco Metropolitano para o ano de 2030, seriam necessários

os dados dos mapas temáticos de influência dos anos de 2010 e 2020, a fim de permitir a projeção para 2030. No entanto, os dados temáticos dos setores censitários de 2020 foram comprometidos devido à não realização do Censo pelo IBGE naquele ano, em decorrência da pandemia da COVID-19. Até a data presente, os dados do Censo de 2022 ainda não foram disponibilizados em sua totalidade.

Em termos de aprendizado de máquina, a simulação realizada apresentou um valor de índice Kappa de 0,76277, classificando o desempenho como muito bom, embora ligeiramente inferior ao obtido para o ano de 2020.

A abordagem adotada no estudo é respaldada por estudos recentes que demonstram a eficácia de modelos baseados em autômatos celulares e redes neurais artificiais para simulações de longo prazo. Por exemplo, Girsang *et al.* (2025) aplicaram o MOLUSCE em uma área na Indonésia, no qual, destacou a capacidade do modelo em representar tendências de expansão agrícola e urbana mesmo com dados limitados. Já Livadiotis *et al.* (2024) demonstraram que o modelo CA-Markov, mesmo com lacunas temporais nos dados, conseguiu prever padrões de urbanização e irrigação na Grécia Central. Esses estudos reforçam a validade da metodologia adotada no estudo, mesmo em contextos de dados incompletos, e destacam a importância da calibração adequada e da escolha criteriosa das variáveis influentes.

Por fim, é importante destacar que, não é possível ainda, realizar a simulação de comparação entre os mapas original (MapBiomass) e previsto (MOLUSCE) para o ano de 2030 em função de não ter disponível dados de mapas originais de 2030. Em termos de exercício e função necessária para dar continuidade à elaboração do mapa de previsão de 2030, foi realizada a comparação dos mapas de previsão de 2030 e 2020 e na análise visual qualitativa dos mapas produzidos verificamos uma similaridade entre os dois cenários temporais, e chegou-se aos seguintes resultados quantitativos: precisão geral de 93,25%, Kappa (geral) de 0,90311; Kappa (histograma) de 0,97446 e o Kappa (posição) de 0,92678. Tais valores são considerados excelentes, embora esperados, tendo em vista que os dados de entrada utilizados foram idênticos e a linha de tendência apresentou variação mínima. Nesse contexto, as variáveis influentes demonstraram comportamento predominantemente linear.

5 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo projetar cenários de uso e cobertura da terra para os anos de 2020 e 2030, considerando os efeitos da futura implantação do Arco Metropolitano na Região Metropolitana do Recife, com foco nas possíveis transformações territoriais e ambientais decorrentes dessa nova infraestrutura rodoviária. A partir da aplicação do *plugin* MOLUSCE, aliado a técnicas de redes neurais e autômatos celulares, foi possível simular e analisar dinâmicas espaciais das mudanças mesmo em um contexto em que o Arco ainda não foi construído.

A simulação para o ano de 2030 indicou padrões de expansão urbana e reconfiguração de usos do solo que apontam para uma tendência de intensificação das pressões antrópicas na área de influência direta (*buffer* 5 km) do futuro corredor viário. Embora o modelo tenha demonstrado um bom desempenho, os resultados devem ser interpretados com cautela, uma vez que a ausência de dados censitários atualizados e de um cenário real de operação do Arco Metropolitano impôs limitações à robustez do cenário prospectivo. Ainda assim, os resultados obtidos oferecem uma importante base exploratória para antecipar áreas prioritárias de monitoramento, planejamento urbano e preservação ambiental.

Para trabalhos futuros, recomenda-se realizar novamente a predição e a elaboração do mapa de uso e cobertura da terra para o ano de 2030, com a inserção das variáveis influentes referentes ao ano de 2020, provenientes do Censo Demográfico de 2022. Recomenda-se, ainda, a incorporação de variáveis diretamente relacionadas à acessibilidade viária e aos fluxos de transporte, além da utilização de dados socioeconômicos mais recentes. A contínua atualização dos dados e o aperfeiçoamento dos algoritmos de simulação devem garantir maior precisão e utilidade aos modelos, especialmente em contextos urbanos sujeitos a rápidas transformações territoriais.

REFERÊNCIAS

- AMARAL, S. et al. Expansão urbana e impactos ambientais: uma análise da Região Metropolitana do Recife. **Revista Brasileira de Geografia**, v. 70, n. 2, p. 215–230, 2019.
- ANDRADE, M. O. de, MAIA, M. L. A., e NETO, O. L. Impactos de investimentos em infraestruturas rodoviárias sobre o desenvolvimento regional no Brasil - possibilidades e limitações. **Revista Transportes**, v. 23(3), p 90–99. (2015).

APAC – **Agência Pernambucana de Águas e Clima**. Portal Institucional. Disponível em: <https://www.apac.pe.gov.br/clima/boletim>. Acesso em: 2025.

ALHEIROS, M. M. et al. Sistemas deposicionais na Formação Barreiras no Nordeste Oriental. **Anais do Congresso Brasileiro de Geologia**, 35., Belém, 1988, p. 753-760.

ALHJOUJ, Ahmad; BONOLI, Alessandra; ZAMORANO, Montserrat. A critical perspective and inclusive analysis of sustainable road infrastructure literature. **Applied Sciences**, v. 12, n. 24, p. 12996, 2022.

ALDILEEMI, H. *et al.* Geospatial Monitoring and Prediction of land Use/Land Cover (LULC) Dynamics Based on the CA-Markov Simulation Model in Ajdabiya, Libya. **International Journal of Geoinformatics**, v. 19, n. 12, p. 15-29, 2023.

BAIRWA, Brijmohan et al. Predicting changes in land use and land cover using remote sensing and land change modeler. **Frontiers in Environmental Science**, v. 13, p. 1540140, 2025.

BANDEIRA, J. M.; FLORIANO, C. F. Planejamento de transportes e meio ambiente. In: SILVA DE MELO, T. (Org.). *Infraestrutura e sustentabilidade*. Recife: Editora Universitária, 2022.

BIANCHINI, R.; OLIVEIRA, M. Geotecnologias aplicadas ao planejamento urbano. In: SILVA DE MELO, T. (Org.). *Infraestrutura e sustentabilidade*. Recife: Editora Universitária, 2022.

BRASIL; IBGE. *Grade Estatística*. Rio de Janeiro: IBGE, 2016.

CHRISTOFOLETTI, A. *Modelagem de sistemas ambientais*. São Paulo: Blucher, 1999.

CODEPE/FIDEM. Agência Estadual de Planejamento e Pesquisas de Pernambuco. Portal Institucional. Disponível em: <http://www.condepefidem.pe.gov.br/web/condepe-fidem>. Acesso em: 2025.

COFFIN, A. W. From Roadkill to Road Ecology: A Review of the Ecological Effects of Roads. **Journal of Transport Geography**, v. 15, n. 5, p. 396–406, 2007.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, p. 35–46, 1991.

CONGALTON, R. G.; GREEN, K. *Accuracy assessment of remote sensing-derived change detection*. Boca Raton: CRC Press, 1999.

COSTA, L. G. T. A.; AZEVEDO, M. C. L. *Análise fundamentalista*. Rio de Janeiro: FGV/EPGE, 1996.

CPRH – Agência Estadual de Meio Ambiente. Portal Institucional. Disponível em: <http://www.cprh.pe.gov.br>. Acesso em: 2025.

DHADSE, Sharda et al. Biodiversity loss due to road widening and a new highway. **Sustainability and Biodiversity Conservation**, v. 4, n. 2, p. 38-52, 2025.

DNIT – Departamento Nacional de Infraestrutura de Transportes. Estudo de Impacto Ambiental do Arco Metropolitano do Recife. Brasília: DNIT, 2024.

DNIT – Departamento Nacional de Infraestrutura de Transportes. Plano Nacional de Logística e Transportes. Brasília: DNIT, 2015.

DUTRA, R. D. C. et al. Caderno - Indicadores de vulnerabilidade global - proposta metodológica para estudos e mapeamentos de risco em área de encostas Percebendo Riscos, Reduzindo Perdas. Santa Catarina, 2010. p. 400-408.

ESRI. ArcGIS Desktop: Release 10.5. Redlands, CA: Environmental Systems Research Institute, 2017.

FEARNSIDE, P. M. Environmental impacts of Brazil's Tucuruí Dam: Unlearned lessons for hydroelectric development in Amazonia. **Environmental Management**, v. 27, p. 377–396, 2001.

FENG, Shuailong et al. Quantification of the environmental impacts of highway construction using remote sensing approach. **Remote Sensing**, v. 13, n. 7, p. 1340, 2021.

FERREIRA, C. *et al.* Rainfall-runoff-erosion processes in urban areas. **Elsevier**, 2021.

FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r). **Revista Política Hoje**, v. 18, n. 1, p. 115-146, 2009.

FRANÇA, Luciano Cavalcante de Jesus et al. Environmental fragility zoning using GIS and AHP modeling: Perspectives for the conservation of natural ecosystems in Brazil. **Conservation**, v. 2, n. 2, p. 349-366, 2022.

FOLEY, J. A. et al. Global consequences of land use. *Science*, v. 309, p. 570–574, 2005.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v. 80, p. 185–201, 2002.

FRANZONI, L. P. Planejamento ambiental urbano: uma abordagem integrada. São Paulo: Contexto, 2000.

GIRSANG, S. S. B. et al. Dynamics prediction of land use changes using cellular automata and artificial neural network modeling. **Global Journal of Environmental Science and Management**, v. 11, n. 2, p. 427-442, 2025.

GUERRA, A. J. T. Impactos ambientais urbanos. 2. ed. Rio de Janeiro: Bertrand Brasil, 2021.

GÜNDÜZ, Halil İbrahim. Land-use land-cover dynamics and future projections using GEE, ML, and QGIS-MOLUSCE: A case study in Manisa. **Sustainability**, v. 17, n. 4, p. 1363, 2025.

HAIR, J. F. et al. Análise Multivariada de Dados. Porto Alegre: Bookman, 2009.

HALDAR, Subrata et al. Peri-urban dynamics: assessing expansion patterns and influencing factors. **Ecological Processes**, v. 13, n. 1, p. 58, 2024.

HAYKIN, S. Redes neurais: princípios e prática. 2. ed. Porto Alegre: Bookman Editora, 2001.

HURTT, George C. et al. Harmonization of global land-use change and management for the period 850–2100 (LUH2) for CMIP6. **Geoscientific Model Development Discussions**, v. 2020, p. 1-65, 2020.

IBGE. Bases e Referenciais. IBGE - Instituto Brasileiro de Geografia e Estatística, 2019. Disponível em: <https://mapas.ibge.gov.br/bases-e-referenciais/bases-cartograficas/malhas-digitais>. Acesso em: 2025.

ICHIHARA, S. M., GUILHOTO, J. J. M., e GUILHOTO, J. J. M. O Impacto do crescimento econômico sobre as rodovias de São Paulo: Uma aplicação do modelo de insumo-produto combinado com o geoprocessamento. **Social Science Research Network**. (2008). <https://doi.org/10.2139/SSRN.1862188>

INCRA – Instituto Nacional de Colonização e Reforma Agrária. Portal institucional. Disponível em: <https://www.gov.br/incra/pt-br>. Acesso em: 2024.

JACOBI, P. R. Políticas públicas e gestão ambiental urbana: desafios à governança democrática. *Revista Estudos Avançados*, v. 14, n. 40, p. 135–152, 2000.

JAEGER, J. A. G. et al. Landscape fragmentation in Europe. Luxembourg: European Environment Agency, 2005.

JORNAL DO COMERCIO. Arco Metropolitano: projeto avança com licitação do trecho sul. Recife, 2025.

KHAN, Jibrán et al. Road traffic air and noise pollution exposure assessment—A review of tools and techniques. **Science of The Total Environment**, v. 634, p. 661-676, 2018.

KANTIANIS, Dimitrios; POLYZOS, Serafeim; KRABOKOUKIS, Thomas. Land Use Changes, Environmental Impact and Socio-Economic Effects of Road Infrastructure Mega Projects: The Combined Case of the Rio–Antirio Bridge and the Ionian Road in Greece. **Land**, v. 14, n. 3, p. 486, 2025.

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

LAUXEN, F. P. Avaliação de impactos ambientais em empreendimentos lineares: uma abordagem integrada. **Revista Brasileira de Geografia Física**, v. 5, n. 3, p. 497–512, 2012.

LEITE, L. L.; ROSA, R. Planejamento ambiental e geotecnologias. São Paulo: Oficina de Textos, 2005.

LI, Lidong et al. Global land use change and its impact on greenhouse gas emissions. **Global Change Biology**, v. 30, n. 12, p. e17604, 2024.

LIVADIOTIS, Evangelos *et al.* Evaluating the Land Use/Land Cover Change with a Future Prediction Using Remote Sensing and GIS in the Elassona-Tsaritsani Basin of Thessaly (Central Greece). In: **Euro-Mediterranean Conference for Environmental Integration**. Cham: Springer Nature Switzerland, 2022. 709-713.

MAPBIOMAS. Coleção 9 – Série histórica de uso e cobertura da terra no Brasil. Disponível em: <https://brasil.mapbiomas.org/>. Acesso em: 2024.

MARICATO, E. O impasse da política urbana no Brasil. **Petrópolis: Vozes**, 2011.

MEYER, V. Planejamento urbano e sustentabilidade: desafios contemporâneos. **Revista de Estudos Urbanos**, v. 12, n. 1, p. 33–48, 2019.

MISHRA, Varun Narayan; RAI, Praveen Kumar. Prediction of land use changes based on land change modeler (LCM) using remote sensing: A case study of Muzaffarpur (Bihar), India. **Journal of the Geographical Institute Jovan Cvijic, SASA**, v. 64, n. 1, p. 111-127, 2014.

NYAME, Michael; ADESANMI, Bukola M. Innovative Geotechnical Solutions for Sustainable Infrastructure Development. **Journal of Scientific Research and Reports**, v. 30, n. 9, p. 719-727, 2024.

NERI, A. M. Infraestruturas verdes e conectividade ecológica: desafios para a conservação em áreas urbanizadas. **Revista Brasileira de Ecologia**, v. 23, n. 1, p. 88–102, 2024.

NEXTGIS. MOLUSCE 3.x - Quick Help. NEXTGIS - Opensource Geospatial Solutions, 2017. Disponível em: <http://nextgis.com/blog/molusce/>. Acesso em: 2024.

NEXTGIS. MOLUSCE Plugin Documentation. Disponível em: <https://nextgis.com>. Acesso em: 2024.

PAEGELOW, M.; CAMACHO OLMEDO, M. Possibilities and limits of prospective GIS land cover modeling – an example for the Sierra de Gador (Almeria, Spain). **Landscape and Urban Planning**, v. 79, p. 130–144, 2005.

PDUI-RMR – Plano de Desenvolvimento Urbano Integrado da Região Metropolitana do Recife. Governo do Estado de Pernambuco, 2024.

PÉREZ, S. M. *et al.* Contaminación ambiental producida por el tránsito vehicular y sus efectos en la salud humana: revisión de literatura. v. 16, p. 20-30, 2021. Disponível: <https://doi.org/10.26620/UNIMINUTO.INVENTUM.16.30.2021.20-30>

PIRES, A. P.; CARMO JÚNIOR, J. R. Impactos ambientais de rodovias: diagnóstico e medidas mitigadoras. **Revista Engenharia Ambiental**, v. 15, n. 2, p. 45–56, 2018.

QGIS. QGIS Geographic Information System. Open Source Geospatial Foundation Project. Disponível em: <https://qgis.org>. Acesso em: 2024.

RAHMAN, M. T. U. *et al.* Temporal dynamics of land use/land cover change and its prediction using CA-ANN model for southwestern coastal Bangladesh. **Environmental Monitoring and Assessment**, v. 189, n. 11, p. 1-18, out. 2017.

ROLNIK, R. Guerra dos lugares: A colonização da terra e da moradia na era das finanças. São Paulo: Boitempo Editorial, 2015.

SACKEY, Lyndon NA *et al.* Road construction and its socio-economic and health impact: a case study of Atonsu lake road. **Discover environment**, v. 1, n. 1, p. 6, 2023.

SANTOS, Priscilla Azevedo dos *et al.* Land Use and Land Cover Products for Agricultural Mapping Applications in Brazil: Challenges and Limitations. **Remote Sensing**, v. 17, n. 13, p. 2324, 2025.

SILVA, C. T. Caracterização da Bacia do Capibaribe e análise do uso da água nos principais municípios do Polo de Confecções de Pernambuco. Dissertação (Mestrado). Recife: UFPE, 2018.

SILVA, Carlos Fabricio Assunção *et al.* Road network and deforestation of indigenous lands in the Brazilian Amazon. **Transportation Research Part D: Transport and Environment**, v. 119, p. 103735, 2023.

SIMONETTI, J. A. Avaliação ambiental estratégica em projetos de infraestrutura. **Revista de Planejamento e Políticas Públicas**, v. 34, p. 77–94, 2010.

SUERTEGARAY, D. M. A. Urbanização e meio ambiente: desafios para a sustentabilidade. Porto Alegre: UFRGS, 2000.

The Nature Conservancy. A New Roadmap for Conservation: How mapping technology is helping achieve sustainability in Mexico's forests. 2023. Disponível em:

<https://www.nature.org/en-us/what-we-do/our-insights/perspectives/a-new-roadmap-for-conservation/>. Acesso em: 15 ago. 2025.

TURNER II, B. L. et al. The emergence of land change science for global environmental change and sustainability. **Proceedings of the National Academy of Sciences**, v. 104, p. 20666–20671, 2007.

VERMA, Primit et al. Appraisal of kappa-based metrics and disagreement indices of accuracy assessment for parametric and nonparametric techniques used in LULC classification and change detection. **Modeling Earth Systems and Environment**, v. 6, n. 2, p. 1045-1059, 2020.

VON NEUMANN, J. *Theory of Self-Reproducing Automata*. Illinois: University of Illinois Press, 1966.

XAVIER, L. et al. Aplicações do MapBiomas na análise de uso e cobertura da terra no Brasil. **Revista Brasileira de Geografia Física**, v. 17, n. 2, p. 450–472, 2024.