

AVALIAÇÃO DO ECOSISTEMA PYTHON PARA O DESENVOLVIMENTO DE MODELOS ESPACIALMENTE EXPLÍCITOS

Nerval de Jesus Santos Junior¹, Sérgio Souza Costa²

¹ *Universidade Federal do Maranhão, São Luis - MA, Brasil, nerval.junior@discente.ufma.br.*

² *Universidade Federal do Maranhão, São Luis - MA, Brasil, sergio.souza@ufma.br.*

Resumo: A crescente demanda por ferramentas mais flexíveis na área de Sistemas de Informação Geográfica (SIG) impulsionou o uso de bibliotecas como GeoPandas e PySAL, amplamente utilizadas na análise de dados geoespaciais. No entanto, ainda há uma lacuna na literatura sobre a aplicação dessas ferramentas para a criação de modelos espaciais dinâmicos, que exigem integração eficiente de grandes volumes de dados e simulação computacional, especialmente voltados para mudanças no uso e cobertura da terra (LUCC). Este artigo apresenta uma revisão sistemática do ecossistema Python, avaliando suas ferramentas em comparação com o framework TerraME, do INPE, e identifica requisitos para o desenvolvimento de um framework modular em Python voltado à modelagem espacialmente explícita de LUCC. A proposta visa integrar bibliotecas Python ao paradigma do TerraME, promovendo soluções acessíveis, escaláveis e interoperáveis para simulações dinâmicas, contribuindo para o planejamento territorial sustentável.

Palavras-chave: Sistemas de Informação Geográfica (SIG); Modelos Espaciais Dinâmicos; Análise de Dados Geoespaciais; Ecossistema Python.

EVALUATION OF THE PYTHON ECOSYSTEM FOR THE DEVELOPMENT OF SPATIALLY EXPLICIT MODELS

Nerval de Jesus Santos Junior¹, Sérgio Souza Costa²

¹ Federal University of Maranhão, São Luis - MA, Brasil, nerval.junior@discente.ufma.br.

² Federal University of Maranhão, São Luis - MA, Brasil, sergio.souza@ufma.br.

Summary: The increasing demand for more flexible tools in the field of Geographic Information Systems (GIS) has driven the adoption of libraries such as GeoPandas and PySAL, widely used in geospatial data analysis. However, there remains a gap in the literature regarding the application of these tools for creating dynamic spatial models, which require efficient integration of large data volumes and computational simulation, particularly for Land Use and Land Cover Change (LUCC) studies. This article presents a systematic review of the Python ecosystem, evaluating its tools in comparison with the INPE's TerraME framework, and identifies requirements for developing a modular Python-based framework focused on spatially explicit LUCC modeling. The proposal aims to integrate Python libraries with the TerraME paradigm, fostering accessible, scalable, and interoperable solutions for dynamic simulations, thereby contributing to sustainable territorial planning.

Keywords: Geographic Information Systems (GIS); Dynamic Spatial Models; Geospatial Data Analysis; Python Ecosystem.

INTRODUÇÃO

As mudanças no uso e cobertura da terra (LUCC, do inglês *Land Use and Cover Change*), configuram um dos desafios contemporâneos para a sustentabilidade global, alterando ecossistemas e o clima em escalas que vão do local ao planetário (TURNER et al., 1995). Essas transformações, impulsionadas por interações complexas entre sistemas naturais e sociais, demandam ferramentas computacionais capazes de modelar dinâmicas espaciais e temporais para prever cenários e orientar políticas públicas (PONTIUS et al., 2018; SAJAN et al., 2022). Nesse contexto, o desenvolvimento de modelos espaciais dinâmicos tem se apoiado em diferentes paradigmas de modelagem, como autômatos celulares e modelos baseados em agentes, que oferecem abordagens complementares para representar a complexidade dos sistemas socioambientais. O TerraME (<https://www.terrame.org>), criado pelo Instituto Nacional de Pesquisas Espaciais (INPE), é um framework de código aberto que se destaca nesse contexto por integrar esses paradigmas de forma robusta, permitindo a modelagem acoplada de sistemas ambientais e humanos a partir de dados espaciais gerenciados pela plataforma TerraLib (CARNEIRO et al., 2013).

Apesar da flexibilidade e sofisticação conceitual oferecida pelo TerraME, um fator que pode restringir sua adoção mais ampla é a utilização da linguagem Lua (www.lua.org). Embora eficiente e leve, Lua não é amplamente adotada na comunidade de análise de dados, diferentemente de linguagens como R e Python, que possuem ampla base de usuários e vasto ecossistema de bibliotecas. Essa última, tem evoluído significativamente no campo das análises geoespaciais, com bibliotecas como GeoPandas (<https://geopandas.org>) e PySAL (<https://pysal.org>), oferecendo ferramentas cada vez mais completas para análise e manipulação de dados espaciais. No entanto, seu uso para modelagem dinâmica de mudanças no uso da terra e cobertura vegetal ainda é incipiente. Essa lacuna levanta questões importantes sobre o potencial do Python — com seu crescente ecossistema e popularidade — para suportar aplicações mais avançadas de modelagem espacial dinâmica, tradicionalmente implementadas em ambientes como o TerraME.

A pesquisa adotou uma abordagem exploratória e qualitativa para avaliar o ecossistema Python no desenvolvimento de modelos espaciais dinâmicos voltados à modelagem LUCC. A metodologia foi estruturada em quatro etapas principais: revisão sistemática, identificação de requisitos com base no TerraME, desenvolvimento da arquitetura do framework e validação por

meio de um estudo de caso. Este trabalho apresenta apenas a revisão sistemática, conduzida como uma análise sistemática.


FUNDAMENTAÇÃO

Modelagem de Mudanças no Uso e Cobertura da Terra

A modelagem LUCC, um campo interdisciplinar, explora interações entre sistemas humanos e naturais, impactando sustentabilidade, biodiversidade e clima global, baseando-se em três componentes: Demanda (quantifica mudanças), Potencial (avalia suscetibilidade) e Alocação (distribui mudanças espacialmente) (VERBURG et al., 2006). Impulsionadas por fatores como crescimento populacional, expansão agrícola, urbanização e políticas econômicas, essas mudanças exigem modelos espaciais dinâmicos que representam a superfície terrestre como grades celulares, evoluindo sob regras biofísicas e socioeconômicas para simular cenários e apoiar políticas públicas (PONTIUS et al., 2018; SAJAN et al., 2022). Comumente top-down, essa abordagem é usada em modelos como CLUE, Dinamica EGO e GEOMOD, mas plataformas proprietárias podem limitar acessibilidade e escalabilidade (VERBURG; OVERMARS, 2007; PONTIUS et al., 2018). As principais teorias subjacentes incluem:

1. **Teoria de Autômatos Celulares (AC):** Representa a superfície terrestre como uma grade de células que evoluem sob regras locais, capturando dinâmicas espaciais como a propagação de mudanças no uso da terra (RIMAL et al., 2018; SAJAN et al., 2022). A abordagem AC modela processos espaciais como desmatamento ou urbanização, onde padrões emergem de interações locais (Figura 1) (GOODCHILD; LONGLEY, 2021);

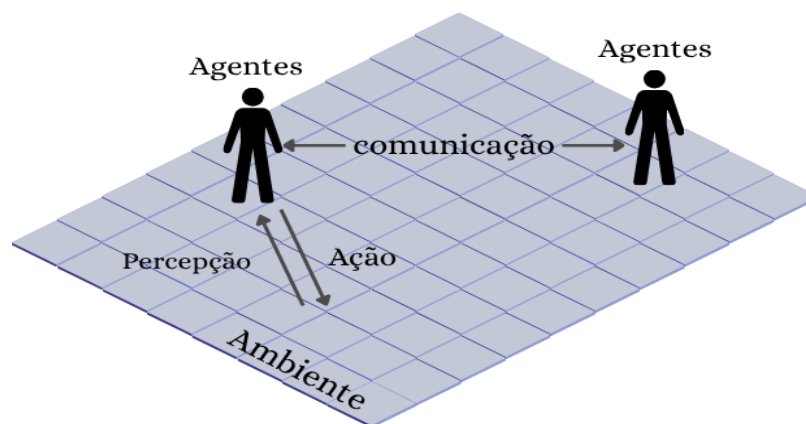
Figura 1. modelo de Automatos Celulares.



2. **Teoria de Modelos Baseados em Agentes (ABM):** Simula o comportamento de agentes individuais (e.g., agricultores, planejadores urbanos) que tomam decisões com base em regras predefinidas ou aprendizado adaptativo (TARIQ, A.; MUMTAZ,

2023; XU; ZHANG, 2016). ABMs são particularmente eficazes para capturar heterogeneidade comportamental e feedbacks em sistemas socioecológicos, como a conversão de florestas em áreas agrícolas (Figura 2);

Figura 2. modelo de agentes com sistema, agentes e ambiente.



Essas representações incorporam conceitos como coordenadas para localização, vizinhanças (como Moore ou von Neumann) para interações espaciais e atributos múltiplos associados a cada unidade espacial. A modelagem LUCC fundamenta-se em teorias complementares, como a Teoria de Autômatos Celulares, que representa a evolução de células sob regras locais, a Teoria de Sistemas, que captura interações entre componentes humanos e ambientais, e a Teoria de Agentes, que simula comportamentos individuais de atores como agricultores ou planejadores urbanos (SAJAN et al., 2022; CARNEIRO et al., 2013).

3. **Teoria de Sistemas Dinâmicos:** Modela as interações entre componentes do sistema (e.g., população, economia, meio ambiente) por meio de equações diferenciais ou relações causais (QIANG, Y.; LAM, 2015). Embora não seja espacialmente explícita, essa teoria é útil para quantificar a demanda por mudanças no uso da terra em escalas regionais ou globais, complementando abordagens espaciais;
4. **Teoria de Sistemas:** Integra os componentes humanos e ambientais em um sistema acoplado, modelando feedbacks e interdependências (CARNEIRO et al., 2013). Essa abordagem é essencial para representar a natureza complexa das mudanças LUCC, onde fatores biofísicos (e.g., solo, clima) e socioeconômicos (e.g., políticas, mercados) interagem dinamicamente.

Modelos híbridos que combinam abordagens discretas — como autômatos celulares (AC) e modelos baseados em agentes (ABM) — com componentes contínuos têm se mostrado eficazes para representar dinâmicas espaciais complexas. O uso de Matrizes de Proximidade Generalizadas (GPM) permite modelar espaços anisotrópicos, capturando tanto transições críticas quanto mudanças graduais no uso e cobertura da terra (CARNEIRO et al., 2013).

Nesse contexto, o TerraME destaca-se por integrar múltiplos paradigmas de modelagem (AC, ABM e simulação de eventos discretos) em um ambiente unificado. Baseado na biblioteca geoespacial TerraLib, o TerraME oferece suporte a simulações multiescalares e multiespaciais por meio de estruturas como CellularSpace (grades espaciais) e Neighborhood (relações de vizinhança).

Embora ferramentas como Swarm, Repast e NetLogo ofereçam suporte à modelagem dinâmica baseada em agentes, elas geralmente não possuem integração nativa com dados geoespaciais — um diferencial importante do TerraME para aplicações em sistemas socioambientais acoplados.

Nesse contexto, o Dinamica EGO, desenvolvido pelo Centro de Sensoriamento Remoto da UFMG, destaca-se como uma plataforma especializada em modelagem de LUCC. Diferentemente de ferramentas multiparadigma como o TerraME, o Dinamica EGO é projetado para simulações baseadas em AC, utilizando uma interface de programação visual por blocos que facilita a construção de modelos espaciais dinâmicos. Essa abordagem, embora menos flexível em termos de paradigmas de modelagem, é robusta para simular processos como desmatamento e expansão urbana (VARNIER; WEBER, 2025), que utilizam o método de pesos de evidência para prever supressão de vegetação em biomas brasileiros.

Representações Espaciais

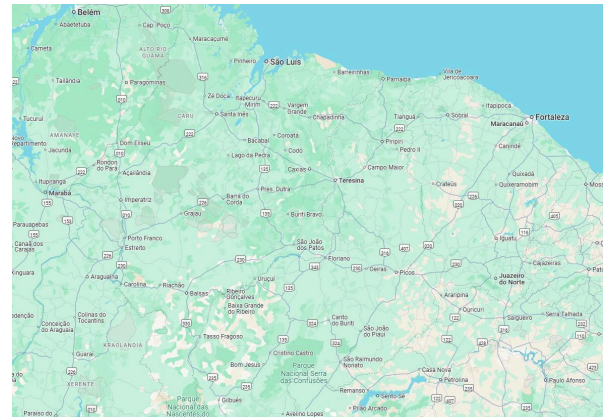
Modelos espaciais explícitos representam a superfície terrestre por meio de geo-campos (matrizes com valores categóricos e numéricos) ou geo-objetos (entidades vetoriais como pontos, linhas e polígonos) (GOODCHILD; LONGLEY, 2021). Geo-campos, implementados como rasters, dividem o espaço em células regulares que armazenam atributos, como em imagens de satélite (Figura 3a). Geo-objetos, associados a vetores, representam feições geométricas com atributos, como em mapas geopolíticos (Figura 3b). Essas representações incorporam conceitos como coordenadas para localização, vizinhanças para interações espaciais e atributos múltiplos por unidade espacial, refletindo a complexidade das mudanças no uso da terra (BEZERRA et al., 2022).

Figura 3. Exemplo de uma imagem de satélite representando um geo-campo.



(a) Exemplo de uma imagem de satélite.

Fonte Google Earth, 2025.




(b) Exemplo de um mapa geopolítico

Fonte Google Maps, 2025.

A estrutura pixelizada, ilustrada na Figura 4, destaca a organização de *geo-campos* em células regulares que são implementados por meio de matrizes, enquanto os tipos geométricos primitivos (pontos, linhas, polígonos) usados em *geo-objetos* que são associadas a estruturas de dados vetoriais.

Figura 4. Imagem mostrando pixels como elementos estruturais.




Ecosistema Python

O ecossistema Python promove colaboração científica e reprodutibilidade. A integração de bibliotecas como GeoPandas, Rasterstats, Pysal e Salabim com paradigmas de modelagem do TerraME, pode contribuir para a modelagem de LUCC.

Para manipulação de dados vetoriais, destaca-se a **GeoPandas** que é uma extensão do Pandas para manipulação de dados vetoriais, suportando operações geométricas (e.g., interseção,

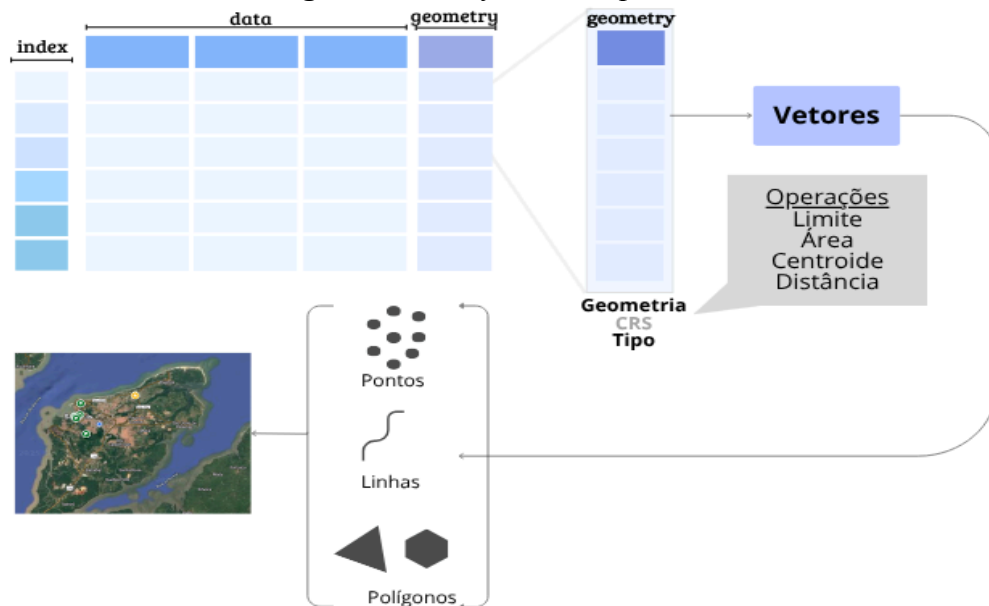
união, buffer) e formatos como shapefiles (.shp) e GeoJSON e bancos de dados espaciais como PostGIS, integrado ao PostgreSQL (USP, 2023). Utiliza bibliotecas como Shapely (análise geométrica), Fiona (leitura/escrita de arquivos) e Pyproj (transformações de coordenadas) (JORDAHL et al., 2021). A integração do GeoPandas com ambientes interativos, como Jupyter Notebooks, e frameworks como CLUMPY e OpenLDM, reforça sua acessibilidade para modelagem geoespacial (HAEDRICH et al., 2023; MAZY; LONGARETTI, 2022; JHA et al., 2022). A estrutura de dados *GeoDataFrame* integra colunas geométricas (*GeoSeries*) com dados tabulares, permitindo análises espaciais avançadas (Figura 5);

Figura 5. Estrutura de um *GeoDataFrame* e *GeoSeries* no *GeoPandas*.



GeoPandas, utilizando o *GeoDataFrame* (extensão do *pandas.DataFrame*), integra dados tabulares a geometrias espaciais via *GeoSeries*. Cada *GeoSeries* inclui um atributo de Sistema de Referência de Coordenadas (CRS), permitindo flexibilidade em projeções (Figura 6).

Figura 6. Dataframe *Geopandas*.



Em um *GeoDataFrame*, apenas uma coluna de geometria é considerada ativa, e todas as operações geométricas são realizadas sobre ela, acessível pelo atributo *geometry*. Essa organização permite associar informações tabulares a entidades geográficas em cada linha. Internamente, o *GeoPandas* utiliza outras bibliotecas para facilitar o manuseio das geometrias:

- **Shapely**: Com o Shapely, é possível realizar operações geométricas como união, interseção e diferença entre objetos geográficos;
- **Fiona**: Responsável por ler e escrever arquivos de formato geoespacial, como Shapefiles, GeoJSON e outros formatos de dados geoespaciais;
- **Pyproj**: Usada para manipular projeções e transformações de coordenadas, o que é fundamental para realizar análises geoespaciais precisas.

A biblioteca também facilita a visualização de dados geoespaciais, sendo possível gerar mapas diretamente a partir de um GeoDataFrame utilizando o Matplotlib ou outras bibliotecas de visualização. A biblioteca também suporta geocodificação, convertendo endereços em coordenadas geográficas (JORDAHL et al., 2021; ROJAS et al., 2023).

Para manipulação de dados raster, diversas bibliotecas complementam o GeoPandas. A Rasterio é especializada no processamento de imagens de satélite, suportando formatos como GeoTIFF e oferecendo funcionalidades para leitura, escrita e transformações de dados raster (LANG et al., 2021). Outras bibliotecas importantes incluem GDAL, que fornece ferramentas robustas para manipulação de dados raster e vetoriais, e Xarray, que facilita o trabalho com dados raster multidimensionais, como séries temporais de imagens de satélite.

A Rasterstats é utilizada para calcular estatísticas zonais, combinando dados raster com geometrias vetoriais. Por exemplo, permite extrair valores médios ou máximos de um raster dentro de polígonos definidos por um GeoDataFrame, sendo essencial para análises de LUCC (LANG et al., 2021).

Para análise de dados espaciais, a biblioteca PySAL é voltada para análises estatísticas espaciais, destacando-se pelos recursos de análise de vizinhança e regressão espacial. Esses recursos permitem identificar padrões de autocorrelação espacial e modelar relações espaciais em dados de LUCC, como a influência de variáveis socioeconômicas ou ambientais em mudanças de uso do solo (HUANG et al., 2021). A PySAL também suporta a construção de matrizes de vizinhança, fundamentais para análises de dependência espacial.

Para modelagem de processos dinâmicos em LUCC, a biblioteca Salabim suporta simulações de eventos discretos, permitindo representar mudanças temporais no uso do solo, como desmatamento ou urbanização (LANG et al., 2021). Embora menos comum em SIG, sua integração com outras bibliotecas Python amplia sua utilidade em cenários complexos. A Tabela 1 sintetiza as principais bibliotecas utilizadas, destacando suas funcionalidades e aplicações.

Tabela 1. Funcionalidades das Bibliotecas Python Identificadas.

Biblioteca	Funcionalidade Principal	Aplicação em LUCC	Dependências	Limitações
GeoPandas	Manipulação de dados vetoriais	Análise de padrões espaciais	Shapely, Fiona, Pyproj	Sem suporte nativo a simulações dinâmicas
PySAL	Análise estatística espacial	Identificação de autocorrelação	NumPy, SciPy	Foco em análises estáticas
Rasterio	Manipulação de dados raster	Processamento de imagens de satélite	GDAL	Requer integração para simulações
Salabim	Simulação de eventos discretos	Modelagem de processos dinâmicos	-	Não otimizado para dados espaciais
Rasterstats	Simulação de Estatísticas zonais em raster	Cálculos estatísticos em zonas vetoriais	Rasterio, NumPy	Foco em análises estáticas

Na Tabela 2 são comparados os formatos raster e vetorial, destacando suas características:

Tabela 2. Comparação entre formatos raster e vetorial.

Formato	Estrutura	Características	Formatos
Vetorial	Pontos, linhas, polígonos	Objetos geométricos, escaláveis	.svg, .shp
Raster	Pixels (grade fixa)	Resolução definida, ideal para imagens	.tif, geotiff

Os formatos .jpg e .png, embora comuns em visualização, não são amplamente utilizados em SIG devido à falta de suporte nativo para metadados geoespaciais, sendo substituídos por formatos como GeoTIFF, que preservam informações de georreferenciamento.

MATERIAL E MÉTODOS

A revisão sistemática buscou identificar bibliotecas Python aplicáveis à modelagem espacial dinâmica e avaliar sua compatibilidade com os paradigmas do TerraME. As bases de dados Scopus, Web of Science e IEEE Xplore foram consultadas, utilizando termos em inglês e português, como “dynamic spatial modeling”, “land use and cover change”, “Python”, “GeoPandas”, e “TerraME” termos definidos com base nas questões de pesquisa (QP1–QP3). A busca utilizou combinações de palavras-chave com operadores booleanos (AND, OR). A string de busca principal foi:

(("Land Use Change" OR "Land Cover Change" OR "Environmental Modeling" OR "Spatial Simulation" OR "Geospatial Modeling") AND ("Cellular Automata" OR "Land Change Models" OR "GIS-Based Modeling" OR "Geospatial Simulation" OR "Spatial Analysis") AND ("Python" OR "GeoPandas" OR "PySAL" OR "Rasterio" OR "Salabim" OR "TerraME"))

Os critérios de inclusão e exclusão foram definidos para garantir a relevância dos estudos (Tabela 2). Foram incluídos artigos que: (IC1) abordassem modelagem espacial dinâmica e explícita; (IC2) utilizassem Python ou Lua; (IC3) fossem aplicados a diferentes escalas espaciais; (IC4) fossem publicados entre 2020 e 2025, em inglês ou português; e (IC5) detalhasse a implementação computacional. Foram excluídos estudos que: (EC1) não envolvessem modelagem baseada em dados espaciais; (EC2) não descrevessem a implementação dos modelos; (EC3) fossem literatura cinza ou não revisados por pares; (EC4) estivessem em outros idiomas; ou (EC5) utilizassem linguagens distintas de Python ou Lua.

Tabela 3. Critérios de Seleção dos Estudos.

Critérios de Inclusão	Descrição (Inclusão)	Critérios de Exclusão	Descrição (Exclusão)
IC1	Modelagem espacial, dinâmica e explícita	EC1	Não baseado em dados espaciais
IC2	Uso de Python ou Lua	EC2	Não detalha a implementação
IC3	Aplicação em diferentes escalas espaciais	EC3	Literatura cinza ou não revisada por pares
IC4	Publicado entre 2020-2025 em inglês/português	EC4	Outros idiomas sem tradução
IC5	Detalhamento da implementação computacional	EC5	Uso de outras linguagens

Processo de Seleção

O processo foi estruturado em quatro fases: (1) definição da estratégia de busca; (2) seleção dos estudos; (3) extração de dados; e (4) síntese qualitativa. A seleção foi conduzida por dois revisores independentes, com discordâncias resolvidas por consenso. A extração de dados utilizou um formulário padronizado, registrando bibliotecas Python, paradigmas de modelagem (e.g., autômatos celulares, ABM), tipos de dados espaciais (vetoriais/raster), integração com SIG, escalabilidade computacional e aplicabilidade a LUCC.

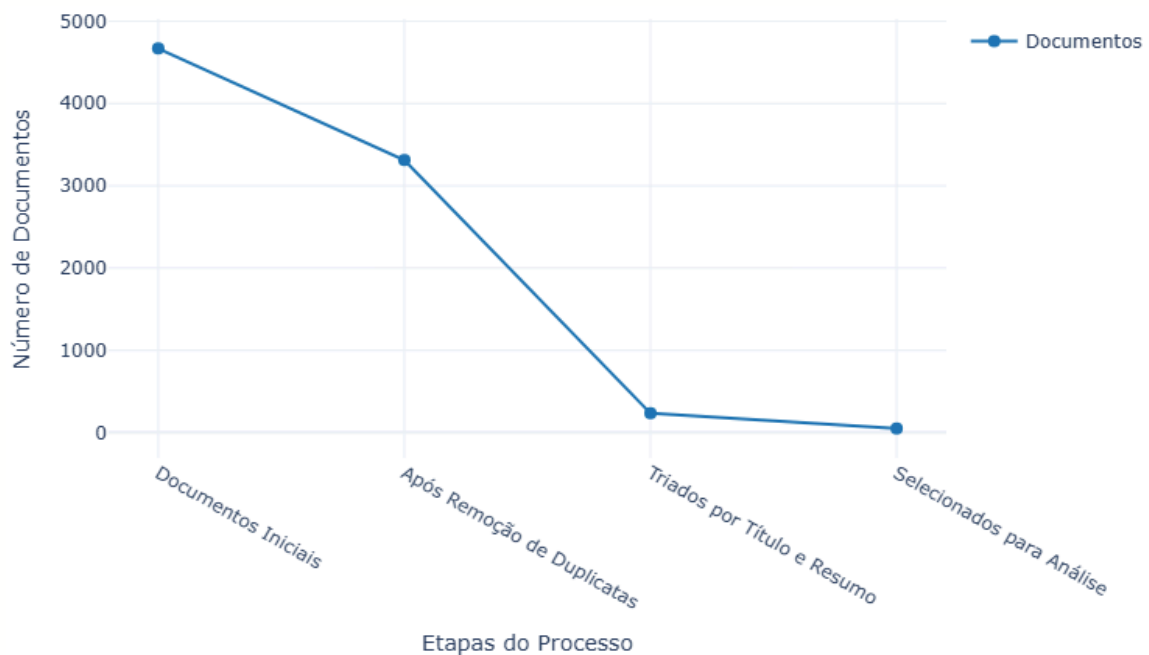
A seguir, apresentamos as Questões de Pesquisa (QPs) e suas justificativas:

- **(QP1)** Quais são os tipos de dados e fontes utilizadas para modelagem espacial dinâmica com o TerraME? *Justificativa:* Essa questão busca identificar os principais insumos utilizados para alimentar modelos desenvolvidos com o TerraME, incluindo dados geoespaciais e fontes de informação;
- **(QP2)** Como é estruturado o fluxo de trabalho da modelagem ambiental utilizando o TerraME? *Justificativa:* Essa questão permite entender como os diferentes módulos e funcionalidades do TerraME são utilizados para a construção de modelos espaciais dinâmicos;
- **(QP3)** Quais são as aplicações e impactos das simulações realizadas com o TerraME? *Justificativa:* Visa analisar estudos de caso que utilizem o TerraME e seu impacto em processos de decisão ambiental e territorial.

RESULTADOS E DISCUSSÃO

A busca inicial retornou 4668 documentos. Após a remoção de duplicatas (n=1356), 3312 artigos foram triados por título e resumo. Destes, 232 foram avaliados em texto completo, resultando em 50 estudos selecionados para análise (Figura 7). O processo de seleção foi conduzido por dois revisores independentes, com discordâncias resolvidas por consenso. A extração foi realizada por um revisor e validada por um segundo revisor.

Figura 7. Processo de Filtragem de Documentos.



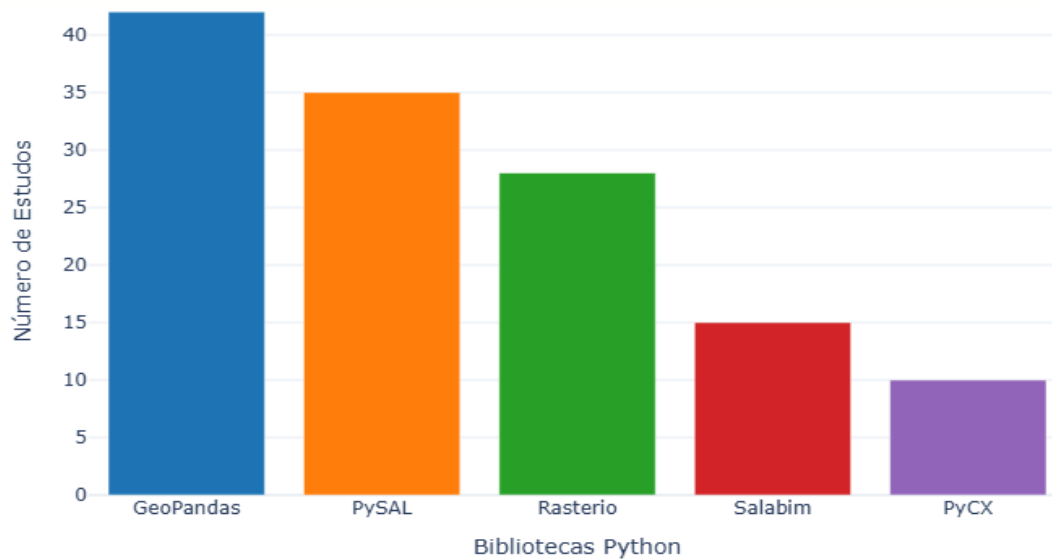
A Tabela 4 compara o Terrame com as ferramentas do ecossistema python.

Tabela 4. Comparação entre TerraME e Ecossistema Python.

Aspecto	TerraME	Ecossistema python
Estrutura Espacial	CellularSpace (grade fixa)	GeoDataFrame (vetorial, flexível)
Tipos de Dados	Vetoriais (shapefiles, bancos)	Vetoriais + raster (Rasterio)
Vizinhança	Moore, von Neumann, GPM	PySAL (Queen, Rook, Kernel)
Simulação Dinâmica	Nativo (Event, Timer)	Salabim, PyCX
Integração SIG	TerraLib	GeoPandas, GDAL
Visualização	Map, Chart (exportação para GIS)	Matplotlib, Folium, Streamlit

Os dados foram extraídos dos 50 estudos selecionados, que registrou: (1) bibliotecas Python utilizadas, com destaque para GeoPandas (n=42), PySAL (n=35), Rasterio (n=28), Salabim (n=15) e PyCX (n=10) (Figura 8), e frameworks como CLUMPY e OpenLDM, (2) paradigmas de modelagem (autômatos celulares, ABM), (3) tipos de dados espaciais (vetoriais/raster), (4) integração com SIG, (5) escalabilidade computacional, e (6) aplicabilidade a LUCC (JORDAHL et al., 2021; HUANG et al., 2021; MAZY; LONGARETTI, 2022; JHA et al., 2022).

Figura 8. Uso de Bibliotecas Python nos Estudos.



CONCLUSÃO

Neste trabalho foi realizada uma análise avaliação do ecossistema python para modelagem espacialmente explícita de LUCC, tomando como base requisitos do TerraME. A revisão sistemática e a análise comparativa demonstraram que bibliotecas como GeoPandas, PySAL, Rasterio e Salabim oferecem flexibilidade, escalabilidade e acessibilidade, tornando uma alternativa promissora para simulações dinâmicas de uso e cobertura da terra. Os próximos passos incluem a

implementação completa do framework e sua validação com estudos de caso reais, visando contribuir para o planejamento territorial sustentável e a tomada de decisões informadas.

AGRADECIMENTOS

Os autores agradecem às agências de fomento **FAPEMA** e **CNPq** pelo apoio financeiro, por meio das bolsas de **Iniciação Científica (PIBIC)** e **Iniciação Tecnológica (PIBITI)** concedidas no decorrer deste trabalho.

REFERÊNCIAS

- [1] BEZERRA, F. G. S.; SOUSA, L. F.; MEDEIROS, L. F.; ANDRADE, M. J.; SILVA, R. M. New land-use change scenarios for Brazil: refining global SSPs with a regional spatially-explicit allocation model. *PLOS ONE*, v. 17, n. 4, p. 1–17, abr. 2022. Disponível em: <https://doi.org/10.1371/journal.pone.0256052>. Acesso em: 2 jun. 2025.
- [2] CÂMARA, G.; SOUZA, R. C. M.; FREITAS, U. M.; GARRIDO, J. TerraLib: An open source GIS library for large-scale environmental and socio-economic applications. In: *Open Source Approaches in Spatial Data Handling*. Springer, 2008. p. 247-270.
- [3] VARNIER, M.; WEBER, E. J. Evaluating the accuracy of land-use change models for predicting vegetation loss across brazilian biomes. *Land*, v. 14, n. 3, 2025. ISSN 2073-445X. Disponível em: <<https://www.mdpi.com/2073-445X/14/3/560>>.
- [4] GARCIA, D. A.; COSTA, S. S.; MOREIRA, E. G. Publicação de dados conectados para modelos de uso e cobertura da terra. *Revista Geonorte*, v. 10, p. 77-94, 2019.
- [5] PONTIUS, R. G. et al. Lessons and challenges in land change modeling derived from synthesis of cross-case comparisons. In: *Trends in spatial analysis and modelling*. [S.l.]: Springer, 2018. p. 143–164.
- [6] XU, X.; DU, Z.; ZHANG, H. Integrating the system dynamic and cellular automata models to predict land use and land cover change. *International Journal of Applied Earth Observation and Geoinformation*, v. 52, p. 568–579, 2016.
- [7] TURNER, B. et al. *Land-Use and Land-Cover Change: science/research plan*. 1995.

- [8] VERBURG, P. H. et al. Land use change modelling: current practice and research priorities. *GeoJournal*, v. 61, n. 4, p. 309-324, 2006.
- [9] AGUIAR, A. P. D. et al. Modeling the spatial and temporal heterogeneity of deforestation-driven carbon emissions: the INPE-EM framework applied to the Brazilian Amazon. *Global Change Biology*, v. 18, n. 11, p. 3346–3366, 2012.
- [10] AGUIAR, A. P. D. et al. Land use change emission scenarios: anticipating a forest transition process in the Brazilian Amazon. *Global Change Biology*, v. 22, n. 5, p. 1821–1840, 2016.
- [11] VERBURG, P. H.; OVERMARS, K. P. Dynamic simulation of land-use change trajectories with the CLUE-s model. In: *Modelling land-use change: Progress and applications*. [S. l.]: Springer, 2007. p. 321–337.
- [12] GOODCHILD, M. F.; LONGLEY, P. A. Geographic information science. In: *Handbook of Regional Science*. [S. l.]: Springer, 2021. p. 1597–1614.
- [13] HAEDRICH, C. et al. Integrating GRASS GIS and Jupyter Notebooks to facilitate advanced geospatial modeling education. *Transactions in GIS*, v. 27, n. 3, p. 686–702, 2023. Disponível em: <https://doi.org/10.1111/tgis.13031>. Acesso em: 2 jun. 2025.
- [14] HARUMI-ITO, M.; FONSECA FILHO, H.; CONTI, L. A. Uso do software livre QGIS (Quantum GIS) para ensino de Geoprocessamento em nível superior. *Revista do Centro de Artes e Letras*, p. 127–148, 2017. Disponível em: <https://www.revistasipgh.org/index.php/rcar/article/view/345>. Acesso em: 2 jun. 2025.
- [15] HUANG, Q. et al. Exploring Residential Heterogeneity through Multiscalar Lens: A Case Study of Hangzhou, China. *Complexity*, v. 2021, p. 1–12, 2021. Disponível em: <https://doi.org/10.1155/2021/3798183>. Acesso em: 2 jun. 2025.
- [16] JHA, A. K. et al. OpenLDM: Open-Source Land-Use and Land-Cover Dynamics Modeling Platform. *Journal of the Indian Society of Remote Sensing*, v. 50, n. 6, p. 1071–1086, 2022. Disponível em: <https://doi.org/10.1007/s12524-022-01516-9>. Acesso em: 2 jun. 2025.
- [17] JORDAHL, K. et al. *geopandas/geopandas: v0.5.0*. Zenodo, 2021. Disponível em: <https://doi.org/10.5281/zenodo.3946767>. Acesso em: 2 jun. 2025.

- [18] LANG, S. et al. Modeling production scheduling problems as reinforcement learning environments based on discrete-event simulation and openai gym. *IFAC-PapersOnLine*, v. 54, n. 1, p. 793–798, 2021.
- [19] MAZY, F.-R.; LONGARETTI, P.-Y. Towards a generic theoretical framework for pattern-based LUCC modeling: An accurate and powerful calibration–estimation method based on kernel density estimation. *Environmental Modelling and Software*, v. 158, p. 105551, 2022. Disponível em: <https://doi.org/10.1016/j.envsoft.2022.105551>. Acesso em: 2 jun. 2025.
- [20] QIANG, Y.; LAM, N. S. N. Modeling land use and land cover changes in a vulnerable coastal region using artificial neural networks and cellular automata. *Environmental Monitoring and Assessment*, v. 187, p. 1–16, 2015.
- [21] RIMAL, B. et al. Land use/land cover dynamics and modeling of urban land expansion by the integration of cellular automata and markov chain. *ISPRS International Journal of Geo-Information*, v. 7, n. 4, p. 154, 2018.
- [22] ROJAS, C. et al. Using Geopandas for locating virtual stations in a free-floating bike sharing system. *Heliyon*, v. 9, n. 1, 2023.
- [23] SAJAN, B. et al. Cellular automata-based artificial neural network model for assessing past, present, and future land use/land cover dynamics. *Agronomy*, v. 12, n. 11, p. 2772, 2022.
- [24] TARIQ, A.; MUMTAZ, F. A series of spatio-temporal analyses and predicting modeling of land use and land cover changes using an integrated Markov chain and cellular automata models. *Environmental Science and Pollution Research*, v. 30, n. 16, p. 47470–47484, 2023.
- [25] USP. Dados Geoespaciais do Brasil. 2023. Disponível em: <http://www.usp.br/nereus/?dados=brasil>. Acesso em: 2 jun. 2025.
- [26] VAN DUYNHOVEN, A.; DRAGIĆEVIĆ, S. The Geographic Automata Tool: A New General-Purpose Geosimulation Extension for ArcGIS Pro. *Applied Sciences*, v. 14, n. 15, p. 6530, 2024.