

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E METEOROLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

GUSTAVO DIEGO BLELOW

MODELAGEM DINÂMICA ESPACIAL:
CARTOGRAFIA PROSPECTIVA E O VALOR DA TERRA

PORTO ALEGRE

2023

GUSTAVO DIEGO BLEADOW

**MODELAGEM DINÂMICA ESPACIAL:
CARTOGRAFIA PROSPECTIVA E O VALOR DA TERRA**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto como requisito para a obtenção do título de mestre em Sensoriamento Remoto e Geoprocessamento.

Orientadora: Profa. Dra. Andrea Lopes Iescheck

PORTO ALEGRE

2023

CIP - Catalogação na Publicação

Bledow, Gustavo Diego
MODELAGEM DINÂMICA ESPACIAL: CARTOGRAFIA
PROSPECTIVA E O VALOR DA TERRA / Gustavo Diego Bledow.
-- 2023.
88 f.
Orientadora: Andrea Lopes Iescheck.

Dissertação (Mestrado) -- Universidade Federal do Rio Grande do Sul, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Programa de Pós-Graduação em Sensoriamento Remoto, Porto Alegre, BR-RS, 2023.

1. Modelagem Dinâmica Espacial. 2. Redes Neurais Artificiais. 3. Autômatos Celulares. 4. Valor da Terra. 5. Geoprocessamento. I. Iescheck, Andrea Lopes, orient. II. Título.

Dedico este trabalho a minha família e amigos, em especial a todos que valorizam a pesquisa e o desenvolvimento educacional como ferramenta de modificação da sociedade.

AGRADECIMENTOS

Aos meus amigos e colaboradores, pelo incentivo e apoio nos momentos necessários. À Universidade Federal do Rio Grande do Sul, pelas oportunidades, experiências e por fornecer os elementos e a inspiração necessária para o desenvolvimento da presente dissertação.

À minha orientadora Profa. Dra. Andrea Lopes Iescheck, pelas sábias contribuições, calma nos momentos de aflição, paciência e principalmente por topar o desafio de encarar o tema proposto.

Aos demais professores da pós-graduação, pelas ideias, espaços e incentivos apresentados no período do mestrado.

Aos meus familiares, pelo incentivo e pela compreensão nos momentos em que não me fiz presente ou que deixei de vê-los para me dedicar à construção deste trabalho. Em especial, à Gabriela Falavigna, que em todos os momentos esteve presente nas minhas ideias, loucuras, desabafos, por tudo, agradeço!

É tempo de explicar que quanto aqui se diz ou venha a dizer é verdade pura e pode ser comprovado em qualquer mapa, desde que ele seja bastante minucioso para conter informações aparentemente insignificantes, pois a virtude dos mapas é essa, exibem a redutível disponibilidade do espaço, previnem que tudo pode acontecer nele.

E acontece.

José Saramago, *Jangada de Pedra*

RESUMO

A modelagem dinâmica espacial concentra-se na obtenção e calibração de regras de transição que possibilitam a construção de cenários futuros, isto é, a simulação da ocupação espacial com base nos modelos obtidos. O processo de utilização do solo envolve externalidades que, de maneira mais ampla, geram as chamadas sinergias urbanas; estando associado a uma lógica de valorização intrínseca à reprodução do capital incorporador, exercendo um papel fundamental no processo de estruturação dos espaços das cidades. Nesse sentido, o presente estudo objetiva examinar a influência do valor da terra na construção de modelos urbanos, verificando se sua inserção como variável explicativa auxilia na estimativa de cenários futuros de uso e cobertura do solo. A metodologia adotada associou técnicas de aprendizagem de máquina, baseadas em Redes Neurais Artificiais, para modelagem do potencial de transição, com autômatos celulares para simular cenários futuros de uso do solo. Nesse processo foram realizadas duas modelagens. Na primeira foram inseridas as variáveis referentes à estrutura viária, à rede hidrográfica, às morfometrias de relevo e ao Plano Diretor Municipal, que normalmente são utilizadas em modelagens dinâmicas espaciais. E na segunda, além dessas variáveis, foi agregado o parâmetro valor da terra. Foi realizado um estudo de caso na região do município de Taquari/RS, para analisar modificações temporais espaçadas em 10 anos. Ambos os modelos obtidos convergiram com a realidade, apresentando pequena diferença entre si. O primeiro modelo alcançou uma precisão geral equivalente a 86,51%, com fator Kappa geral de 0,625. O modelo com o valor da terra apresentou leve melhora com precisão geral equivalente a 86,93% e fator Kappa geral de 0,651.

Palavras-chave: Modelagem Dinâmica Espacial. Redes Neurais Artificiais. Autômatos Celulares. Variáveis explicativas. Valor da Terra.

ABSTRACT

Spatial dynamic modeling focuses on obtaining and calibrating transition rules that enable the construction of future scenarios, that is, the simulation of spatial occupation based on the obtained models. The land use process involves externalities that, more broadly, generate the so-called urban synergies; being associated with a logic of valorization intrinsic to the reproduction of incorporating capital, playing a fundamental role in the process of structuring the spaces of cities. In this sense, this dissertation objectively examines the influence of land value in the construction of urban models, verifying whether its inclusion as an explanatory variable helps in predicting future land use and land cover scenarios. The adopted methodology associated machine learning techniques, based on Artificial Neural Networks, for modeling the transition potential, with cellular automata to simulate future land use scenarios. In this process, two models were carried out, in the first, variables referring to the road structure, hydrographic network, relief morphometrics and those referring to the Municipal Master Plan were inserted, normally used in spatial dynamic modeling and in the second, in addition to these, a value parameter was added from the earth. The study carried out a case study in the region of the municipality of Taquari/RS, analyzing temporal changes spaced over 10 years. Both models obtained converged with reality, revealing little difference between them. The first model achieved an overall accuracy equivalent to 86.51%, with an overall Kappa factor of 0.625. The model with land value showed a slight improvement with an overall result equivalent to 86.93% and an overall Kappa factor of 0.651.

Keywords: Spatial Dynamic Modeling. Artificial neural networks. Cellular Automata. Explanatory variables. Land Value.

LISTA DE ILUSTRAÇÕES

Figura 1 – Inteligência Artificial, <i>Machine Learning</i> e <i>Deep Learning</i>	21
Figura 2 – Estrutura básica de uma RNA com múltiplas entradas.	23
Figura 3 – Etapas da metodologia.....	33
Figura 4 – Fluxograma do procedimento metodológico.	34
Figura 5 – Localização do município de Taquari/RS.	36
Figura 6 – Distribuição das zonas cadastrais de Taquari/RS.	37
Figura 7 – Módulos do <i>plugin</i> MOLUSCE.	43
Figura 8 – Cobertura e Uso do Solo em 2000 – Taquari/RS.....	48
Figura 9 – Cobertura e Uso do Solo em 2010 – Taquari/RS.....	49
Figura 10 – Cobertura e Uso do Solo em 2020 – Taquari/RS.....	50
Figura 11 – Proximidade a Vias – Taquari/RS.	51
Figura 12 – Proximidade a Vias – Taquari/RS.	53
Figura 13 – Declividade – Taquari/RS.....	54
Figura 14 – Sombreamento – Taquari/RS.....	55
Figura 15 – Áreas Conforme Plano Diretor Municipal – Taquari/RS.	57
Figura 16 – Declividade de Valores Genéricos de Terrenos – Taquari/RS.....	58
Figura 17 – Mudanças de cobertura e uso do solo entre 2000 e 2010.	61
Figura 18 – Mudanças de cobertura e uso do solo entre 2010 x 2020.....	63
Figura 19 – Comparação de dados simulados com a referência.	66
Figura 20 – Treinamento RNA na Simulação 1.....	68
Figura 21 – Treinamento RNA na Simulação 2.....	69
Figura 22 – Simulação 1 para 2020 – Taquari/RS.	70
Figura 23 – Simulação 2 para 2020 – Taquari/RS.	71
Figura 24 – Gráfico de validação da Simulação 1.....	72
Figura 25– Gráfico de validação da Simulação 2.....	73
Figura 26 – Simulação 1 para 2030 – Taquari/RS.	74
Figura 27 – Simulação 1 para 2040 – Taquari/RS.	75
Figura 28 – Simulação 2 para 2030 – Taquari/RS.	76
Figura 29 – Simulação 2 para 2040 – Taquari/RS.	77

LISTA DE TABELAS E QUADROS

Tabela 1 – Correlação das variáveis na Simulação 1.	59
Tabela 2 – Correlação das variáveis na Simulação 2.	60
Tabela 3 – Mudanças de cobertura e uso do solo entre 2000 e 2010.	61
Tabela 4 – Matriz de transição de classes de cobertura e uso do solo, 2000 x 2010.	62
Tabela 5 – Mudanças de cobertura e uso do solo entre 2010 e 2020.	63
Tabela 6 – Matriz de transição de classes de cobertura e uso do solo, 2010 x 2020.	64
Tabela 7 – Análise comparativa da Simulação 1 e classificação de referência 2020.	65
Tabela 8 – Análise comparativa da Simulação 2 e classificação de referência 2020.	65
Tabela 9 – Dados simulados para 2030 e 2040 – Simulação 1.	67
Tabela 10 – Dados simulados para 2030 e 2040 – Simulação 2.	67
Quadro 1 – Lista de dados utilizados no estudo.	38
Quadro 2 – Reclassificação dos dados MapBiomas.	42

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
AHP	<i>Analytic Hierarchy Process</i>
CA	<i>Cellular Automata</i>
FLUS	<i>Future Land Use Simulation</i>
LCA	<i>Land Change Analysis</i>
LUCC	<i>Land Use and Cover Change</i>
LULC	<i>Land Use and Land Cover</i>
MOLUSCE	<i>Modules for Land Use Change Evaluation</i>
NASA	<i>National Aeronautics and Space Administration</i>
PVG	Planta de Valores Genéricos
RNA	Rede Neural Artificial
<i>SLEUTH</i>	<i>Slope, Land cover, Excluded regions, Urban extent, Transportation and Hill shade</i>
SRTM	<i>Shuttle Radar Topography Mission</i>

SUMÁRIO

1	INTRODUÇÃO.....	12
2	REFERENCIAL TEÓRICO	17
2.1	Modelagem Dinâmica Espacial.....	18
2.2	Rede Neural Artificial	21
2.3	Autômatos Celulares.....	25
2.4	Valor da terra e avaliação em massa de imóveis.....	29
3	METODOLOGIA	33
3.1	Área de estudo.....	35
3.2	Aquisição e geração dos dados geoespaciais	38
3.3	Geração de imagens de cobertura e uso do solo	40
3.4	Tratamento das variáveis de entrada.....	41
3.5	Modelagem espacial e geração do potencial de transição	42
3.6	Entrada dos dados.....	44
3.7	Obtenção do potencial de transição.....	44
3.8	Validação do modelo e simulação da ocupação territorial	45
4	RESULTADOS	47
4.1	Imagens de uso e cobertura do solo reclassificadas	47
4.2	Base viária municipal	50
4.3	Base hidrográfica municipal	52
4.4	Modelo Digital de Terreno.....	53
4.5	Divisão de atividades espaciais	56
4.6	Base cartográfica de valores genéricos	57
4.7	Correlação das variáveis.....	59
4.8	Análise de variação de área.....	60
4.9	Análise comparativa dos dados	64
4.10	Validação da simulação	72
4.11	Dados simulados 2030 e 2040.....	73
5	CONCLUSÕES.....	79

1 INTRODUÇÃO

Mapeamentos prospectivos têm por objetivo simular a dinâmica dos mais diversos fatores, buscando representar, por meio de mapas preditivos, como um fenômeno se comportará espacialmente em um cenário futuro. Nessa linha, a cartografia prospectiva trata da construção de cenários futuros com base nos conceitos da modelagem dinâmica espacial, objetivando a construção de mapas preditivos que tratam de representar a realidade (CANEPARO; RICOBOM, 2014). Os princípios do mapeamento prospectivo são utilizados nas mais diversas aplicações, conforme o fator a ser estudado e de acordo com o objeto a ser analisado.

Um exemplo de aplicação desses princípios foi realizado por Al Kindi et al. (2021), que analisou variáveis demográficas e socioeconômicas que influenciaram as infecções por Covid-19, em Omã. Nesse estudo, os autores utilizaram técnicas de modelagem espacial para construção de mapas preditivos a fim de classificar áreas com potenciais surtos futuros. Na mesma linha, Hart (2020) utilizou as técnicas do mapeamento prospectivo para explorar dados da dinâmica espacial com o objetivo de determinar os chamados “pontos quentes”, locais com alta tendência a ocorrência de crimes, fundamentando um policiamento preditivo e realizando uma análise espaço-temporal para implementação de políticas eficazes na linha da segurança, com alocação proativa de recursos.

Ainda, Ruz *et al.* (2020) realizaram mapeamentos prospectivos para avaliar os possíveis impactos gerados pelas mudanças climáticas para duas comunidades costeiras do norte francês, avaliando os riscos e as estratégias a serem aderidas pelas famílias locais. Já Rodrigues (2014) desenvolveu propostas de métodos de espacialização dos impactos da disponibilização dos recursos hídricos, através da cartografia prospectiva, construindo alternativas que objetivam melhorar a eficácia das políticas de gestão dos recursos hídricos.

A modelagem espacial e a obtenção e calibração de regras de transição possibilitam a construção de cenários, isto é, a simulação da ocupação espacial com base nos modelos obtidos para descrição de cenários futuros (DELANEZE *et al.*, 2014). A construção de simulações espaciais pode ser realizada, por exemplo, utilizando um processo markoviano, como realizado por Dadhich e Hanaoka (2010), que utilizaram o modelo de Markov para simular o uso da terra. No entanto, conforme destacado por Ricobom (2005), modelos como a Cadeia de Markov apresentam

limitação ao responder às modificações de maneira espacial, pois apresentam probabilidades de transição que não mudam espacialmente com o tempo, ou seja, sozinho o modelo da Cadeia de Markov será deficitário por considerar probabilidades arbitradas, que não levam em conta variáveis explicativas da dinâmica espacial.

Kim (2009) buscou realizar a parametrização dos padrões evolutivos, utilizando como base os conceitos do processo hierárquico analítico (AHP), desenvolvendo uma superfície potencial de modificação espacial através deste método determinístico. Parker *et al.* (2011) analisaram métodos para avaliação de cenários através do índice de aptidão da terra, analisando as respostas dos métodos AHP e Rede Neural Artificial (RNA), encontrando diferentes pontos fortes e limitações, em ambos. Análises realizadas através da matriz de comparação pareada, presente no modelo AHP, conforme apresentado por Saaty (2008), pressupõem o conhecimento do fenômeno a ser avaliado por um especialista, que compara par a par a importância de um elemento em relação a outro, com base em uma escala de julgamentos.

Outras pesquisas, como a de Foroutan e Delavar (2012), apresentaram um método para avaliação da dinâmica espacial baseado no conhecimento de especialistas para determinação de regras de transição, com geração de mapas preditivos empregando a lógica Fuzzy. Al-Khender *et al.* (2008) empregaram a lógica Fuzzy para aplicar o conhecimento semântico da modelagem espacial urbana e definir regras de transição para modelagem ocupacional de Indianápolis (EUA). Os autores utilizaram os conceitos da lógica Fuzzy para traduzir em termos matemáticos um conjunto de regras linguísticas expressas inicialmente de forma imprecisa, isto é, definir linguisticamente os conceitos relacionados à dinâmica espacial.

Da necessidade de representação e predição espacial fundamenta-se a utilização de modelos baseados em autômatos celulares, pois apresentam semelhança entre as unidades espaciais presentes na estrutura do modelo, células, e a estrutura fundiária, lotes, quadras, bairros, entre outros. Além disso, esses modelos têm capacidade operacional de transcender as questões lineares, de realizar a modelagem do ambiente utilizando os relacionamentos de vizinhança, bem como de espacializar tais relações (POLIDORI; KRAFTA, 2005).

Conforme apresentado por Wolfram (1984), os autômatos celulares (CA – *Cellular Automata*) são idealizações matemáticas do meio físico, modelos constituídos por um espaço em que cada célula apresenta um estado, respeitando as relações de vizinhança com as oito células contíguas. São compostos por um conjunto de regras

de transição e evoluem ao longo de um período temporal sincrônico definido, isto é, apresentam um conjunto finito de valores associado a uma escala temporal discreta. Em modelos baseados em autômatos celulares, a espacialização e simulação da mudança espacial, o estado futuro de uma célula estará diretamente relacionando ao comportamento e estado atual de suas vizinhas (RICOBOM; CANAPARO, 2017). Nesse método, além das informações anteriores do estado da célula analisada, dado de entrada de modelos de RNA e Cadeia de Markov, por exemplo, também é computado o estado das classes vizinhas para suas regras de transição (ADHIKARI; SOUTHWORTH, 2012). Modelos baseados em CA possuem a vantagem de terem uma abordagem descentralizada, relativa facilidade com que os resultados do modelo podem ser visualizados, são flexíveis em suas aplicações, bem como apresentam compatibilidade com os sistemas de informação geográfica e dados de sensoriamento remoto (TORRENS; O'SULLIVAN, 2001).

A questão dos modelos baseados em autômatos celulares é desenvolver cenários futuros considerando as variáveis explicativas que determinam a modificação do espaço. São exemplos de programações que utilizam modelos baseados em CA (RIENOW; GOETZKE, 2015): FLUS (*Future Land Use Simulation*), LCA (*Land Change Analysis*), MOLUSCE (*Modules for Land Use Change Evaluation*) e SLEUTH (*Slope, Land cover, Excluded regions, Urban extent, Transportation and Hill shade*). Nesse estudo optou-se por utilizar o plugin MOLUSCE pela possibilidade de abordagens metodológicas e do fator estudado. Conforme Abba *et al* (2021) no software é possível utilizar abordagens conhecidas como redes neurais artificiais e autômatos celulares, possibilitando a análise de transição espaço temporal e simulação futura com algoritmos conhecidos

De acordo com Gharbia *et al.* (2016), a parte mais importante para geração de um modelo espacial é a determinação das regras de transição, pois são elas que definirão a qualidade da modelagem a ser executada. Destacam ainda a importância em determinar variáveis de significativo impacto para a dinâmica espacial, nas mais diversas esferas, naturais, socioeconômicas, de planejamento territorial e relacionadas às atividades humanas. Nessa linha, conforme Liu *et al.* (2008), as regras de transição devem ser determinadas da forma mais realista possível, considerando regras de transição diferentes de acordo com a área e o período estudados. Sendo assim, a modelagem espacial e suas variáveis temporais necessitam ser calibradas de acordo com as modificações do espaço.

Conforme Polidori e Krafta (2005), as limitações desses modelos estão relacionadas às teorias subjacentes à lógica de ocupação do espaço, sendo predominantemente estocásticos. Segundo os autores, fatores naturais têm inclusão limitada nas representações dos modelos, com restrições às variáveis (normalmente só participam os atributos naturais previstos na estrutura do modelo) e ao papel que exercem na dinâmica espacial (na maioria das vezes atuam somente como restrições à ocupação).

A maioria dos estudos de modelagem espacial considera apenas variáveis que mantêm os estados de células que permanecem inalteradas ou que retardam o desenvolvimento do solo (AL-AHMADI *et al.*, 2009) ou metas de planejamento em uma escala não espacial (HUANG *et al.*, 2014). No entanto, o planejamento regional não se concentra apenas em estabelecer políticas urbanas de grande escala. Nos planos municipais, além de se especificar regiões restritivas à ocupação, também são delineadas as áreas nas quais o desenvolvimento é incentivado, como o planejamento de zonas de desenvolvimento e de produção (LIANG *et al.*, 2018).

Smolka (1987) destaca que o processo de utilização do solo envolve externalidades que, de maneira mais ampla, geram as chamadas sinergias urbanas. Essas sinergias estão associadas a uma lógica de valorização intrínseca à reprodução do capital incorporador, exercendo um papel fundamental no processo de estruturação dos espaços das cidades. As dinâmicas econômicas imobiliárias e suas interações apreciam o valor de um terreno em função das vantagens, em termos objetivos monetários (lucros) ou subjetivos (utilidade) que o lote em questão permite realizar quando comparado a outros lotes disponíveis. Nesse sentido, Barcella (2018) destaca que os processos de ocupação territorial têm sua origem, direcionamento e planejamento associados aos interesses estratégicos de agentes imobiliários específicos, que determinam os vetores de expansão e de valorização imobiliária.

O valor da terra está diretamente associado ao crescimento urbano e a seus reflexos no cenário municipal, sendo diretamente correlacionado às políticas públicas municipais, bem como à lógica do sistema de produção econômica, vinculado ao plano econômico local. Dessa forma, o valor da terra desempenha um relevante papel na indicação do desenvolvimento territorial, de maneira análoga ao que acontece em relação aos fatores econômicos, objetos das pesquisas censitárias (HANG, 2020).

A obtenção de valores da terra compõe uma das etapas da formulação do valor imóvel. Möller (1995) destaca que a formação do valor do imóvel se dá pela

adição do valor do terreno (do solo, da terra) mais o valor da edificação. Nesse estudo o interesse está em compor, a partir de técnicas de avaliação o valor da terra, ou seja, o valor do terreno urbano e rural para área estudada. Santos (2014) destaca que as dificuldades embora da existência de dificuldades em compor sistemas cadastrais urbanos e rurais, as técnicas de avaliação em massa têm evoluído, gerando resultados mais precisos, com utilização de modelos espaciais e métodos de geoestatística para tratamento dos dados.

A questão levantada por Karakayaci (2018) está concentrada em entender quais as variáveis que condicionam a modificação do espaço e conseqüentemente o valor da terra, tendo em vista a atratividade econômica que uma região periférica assume ao se tornar urbanizável. Nesse sentido, muitos dos fatores que condicionam o valor da terra podem influenciar indiretamente na dinâmica espacial. Desta forma, se questiona: A introdução da variável explicativa valor da terra na modelagem dinâmica espacial melhora a simulação de cenários futuros de uso e cobertura do solo?

Hipoteticamente, se existem variáveis que determinam a dinâmica espacial, se for incrementado o valor da terra e estabelecida uma simulação de cenários futuros a partir de um modelo baseado em autômatos celulares, então é possível verificar a influência do valor da terra na ocupação do espaço. Nesse sentido, o objetivo principal deste estudo é examinar a influência do valor da terra na construção de modelos dinâmicos espaciais, verificando se essa inclusão resulta em melhora do modelo ao estimar cenários futuros de uso e cobertura do solo.

Inserido no objetivo geral encontram-se os seguintes objetivos específicos:

- a. Construir e analisar cenários de dinâmica espacial baseados em redes neurais artificiais e simulados com autômatos celulares;
- b. Apresentar um método para análise de tendência da modificação do espaço com base em modelo implementado com valores da terra, oriundos de Plantas de Valores Genéricos;
- c. Analisar e quantificar aos modelos gerados e examinar a influência do valor da terra na estimativa de cenários futuros de uso e cobertura do solo.

2 REFERENCIAL TEÓRICO

Previsões precisas sobre a maneira como se dá a mudança de uso da terra são necessidades dos gestores municipais, tendo em vista o controle e a regulação do solo. A complexidade da dinâmica de ocupação e uso do solo decorre do avanço da urbanização associado ao desenvolvimento de regiões com intensas interações sociais e ambientais (KOURTIT; NIJKAMP, 2013). Essa complexidade deve ser representada em mapas preditivos que, baseados em modelos espaciais, devem caracterizar o espaço e sua organização para construção de diretrizes componentes dos Planos Diretores.

A construção de uma cartografia de cobertura e uso do solo é fundamental para análise das mudanças da paisagem. O registro das mudanças do solo em documentos cartográficos permite entender como se deu a ocupação do espaço e os movimentos urbanos, rurais e naturais. Prever a tendência de ocupação torna-se um desafio, dado o número de variáveis e agentes envolvidos. Para tanto, as técnicas de modelagem e análise espacial, apoiadas nos recursos do sensoriamento remoto e de sistemas de informações geográficas, podem ser utilizadas para monitoramento e geração de cenários da expansão urbana, embasando as decisões e políticas de planejamento urbano (MASSABKI *et al.*, 2017).

A dinâmica de ocupação do espaço provoca permanentes mudanças nas configurações das cidades, cujo entendimento está condicionado ao conhecimento dos processos de transformação que modificam a configuração espacial (O'SULLIVAN; TORRENS, 2000). Essa dinâmica de permanente mutação transforma a paisagem urbana e, conseqüentemente, a destinação de regiões externas ao atual cenário urbano num processo de crescimento urbano e de suporte ao mesmo. Os efeitos desse crescimento são visíveis espacialmente, no entanto seus padrões variam de forma não linear, tema explorado por diversos estudos da modelagem espacial. Nesse sentido, é necessário reconhecer um conjunto de variáveis que influenciam na organização do espaço, bem como nas suas relações temporais. As teorias que tomam como base a modelagem espacial, a teoria de sistemas e da auto-organização objetivam explicar como se dão essas interações (POLIDORI, 2004).

O presente capítulo é destinado à apresentação teórica pertinente ao desenvolvimento metodológico do presente estudo. Os conceitos aqui expostos se referem aos elementos necessários para composição dos produtos da cartografia

prospectiva, resultante da modelagem dinâmica espacial. São apresentadas definições a respeito de Redes Neurais Artificiais, Autômatos Celulares, bem como os conceitos de avaliação em massa, para obtenção do valor da terra, necessários ao atendimento dos objetivos propostos.

2.1 Modelagem Dinâmica Espacial

A modelagem dinâmica espacial trata matematicamente de um processo do mundo real, com o objetivo de representar as variações de forças direcionais que interagem na superfície terrestre. Essa representação está associada à elaboração de ideias sequenciais e abstrações da realidade espacial, amparadas em um conjunto de hipóteses e previsões que expressam as relações entre os elementos. Esse processo objetiva a verificação e o entendimento dos processos dinâmicos que constituem o mundo real e conduzem ao procedimento de pesquisa associado à construção de modelos espaciais (Kawashima *et al.*, 2016). Burrough (1998) destaca que um modelo espacial passa a ser dinâmico quando em seu processo a localização superficial de um fenômeno modifica de acordo com as respostas às forças direcionais, superando as limitações estáticas dos demais modelos.

Conforme apresentado por Soares-Filho *et al.* (2007), no contexto da simulação de uso e cobertura da terra, os modelos dinâmicos espaciais visam à construção de paisagens futuras do objeto avaliado tomando por base padrões de evolução reconhecidas no passado. De acordo com os autores, para a elaboração desses modelos é necessário entender a configuração inicial e desenvolver uma função de mudança, que descreva as regras de transição e explique os padrões temporais de modificação, levando a uma configuração de saída, que seria o cenário futuro, representado por meio de mapas de simulação espacial.

Modelos dinâmicos pressupõe regras de transição que descrevem a mudança do espaço, ou seja, preveem um conjunto de previsões que explicam como ocorrerá a mudança da paisagem. Tal definição é a base para a realização de simulações de cenários que levam à construção dos mapas preditivos. Para tanto, torna-se necessário realizar a calibração do modelo e definir as regras de transição, que podem ser realizadas tendo como aporte vários modelos matemáticos e descritivos (SOARES-FILHO *et al.*, 2007).

A construção de um modelo, com detalhamento das relações entre os elementos, permite ao pesquisador explicar como os processos ocorrem e realizar projeções de resultados em determinadas configurações. Nessa perspectiva, um modelo pode ser constituído de pelo menos três elementos, variáveis, relacionamento e processo, podendo na sua construção dar ênfase a qualquer um deles (TRENTIN; FREITAS, 2010).

O modelo deve apresentar respostas que indiquem como as variáveis, os processos e os seus relacionamentos condicionam a ocorrência de determinado fenômeno. Para tanto, o modelo apresenta um conjunto de predições calibradas e validadas, que estão associadas às medidas do fenômeno, cuja ocorrência é balizada pelo comportamento do fenômeno no mundo real (SOARES-FILHO, 1998).

Podemos distinguir os modelos de acordo com a técnica utilizada como conceituais e empíricos. Conforme exposto por Pinheiro (2022), os fenômenos conceituais, ou teóricos, são mais rígidos, baseados em equações, que buscam representar processos físicos e fenômenos da natureza. Quanto aos modelos empíricos, são ajustados de acordo com a observação dos fenômenos, isto é, não levam em conta a física do processo, bem como equações previamente conhecidas, mas a característica do fenômeno observado. Modelos empíricos podem estar apoiados em técnicas de inteligência artificial, como, por exemplo, os modelos autorregressivos e as redes neurais artificiais (PINHEIRO, 2022).

Uma das técnicas mais aplicadas na modelagem espacial da dinâmica de ocupação e uso do solo é a Cadeia de Markov. Seu modelo matemático está fundamentado em um processo estocástico, onde o sistema futuro está baseado no estado presente e nas possibilidades de transição (DADHICH; HANAOKA, 2010). Ricobom (2011) destaca que para a Cadeia de Markov todas as informações de mudanças que ocorreram no passado estão concentradas no estado atual do cenário estudado; sendo assim, a probabilidade de estar em certo estado no futuro dependerá apenas do presente. A utilização da Cadeia de Markov como técnica para modelagem da mudança do uso e cobertura da terra (LUCC – *Land Use and Cover Change*) apresenta considerável utilização nos estudos da área, possibilitando a análise de várias variáveis que alteram a paisagem no decorrer do tempo, descrevendo regras de transição que se mostram adequadas para entendimentos da dinâmica espacial (OLMEDO *et al.*, 2015). Folharini e Oliveira (2020) ressaltam que apesar das limitações, referentes à baixa capacidade de previsão de fenômenos resultantes da

atividade humana no processo de modificação de ocupação, a Cadeia de Markov apresenta resultados positivos no que tange à cartografia prospectiva de mudança de uso e cobertura do solo.

Além desses modelos, pesquisas para geração de resultados de LUCC utilizam as propriedades da RNA para obtenção das regras de transição. Li e Yeh (2001) apresentam que em Redes Neurais Artificiais os elementos básicos são os neurônios, estando estes configurados em diferentes camadas, trabalhando de maneira conjunta, em paralelo, com o objetivo de transformar os dados de entrada nas entidades de saída, apresentando uma configuração não linear, que se assemelha aos elementos da dinâmica espacial. Os autores descrevem que a utilização de RNA como técnica para modelagem apresenta algumas vantagens, como a estrutura robusta, a possibilidade de utilizar dados de diferentes tipos e origens, a capacidade de adaptação para distribuições não normais, bem como a possibilidade de solução de problemas altamente não-lineares, como o caso dos sistemas dinâmicos. Maithani (2009) destaca a RNA como uma técnica não paramétrica, que permite realizar análises de relacionamentos e padrões complexos, como a modelagem dos efeitos da ocupação territorial.

Conforme Olmedo (2015), a modelagem dinâmica espacial está condicionada à capacidade de representação do modelo a ser utilizado. Um método para ser preciso deve ser resultado das variações do espaço e descrito pelas variáveis explicativas da mudança do espaço, as quais são as variáveis de entrada para a análise realizada. Nesse sentido, torna-se mais adequada a utilização do modelo que melhor se adaptar ao espaço estudado, ou seja, daquele descrito pelas variáveis representativas da paisagem do local.

Para representar a dinâmica espacial, modelos buscam determinar as variáveis que influenciam a modificação do espaço. Alguns modelos, como o SLEUTH, desenvolvido por Keith Clarke, apresentam dados de entrada previamente definidos (CLARKE; HOPPEN; GAYDOS, 1997). Estudos de modelagem dinâmica espacial com o SLEUTH realizam modelagens inserindo variáveis de uso da terra, relacionados ao relevo e à infraestrutura de transportes (Bihamta *et al.*, 2014; Delaneze *et al.*, 2014; Marques *et al.*, 2021; Rienow e Goetzke, 2015).

A possibilidade de integrar variáveis distintas na modelagem fundamentam estudos realizados empregando modelos mais flexíveis, cuja aplicabilidade está condicionada à disponibilidade de dados e interesse do operador. Como exemplos,

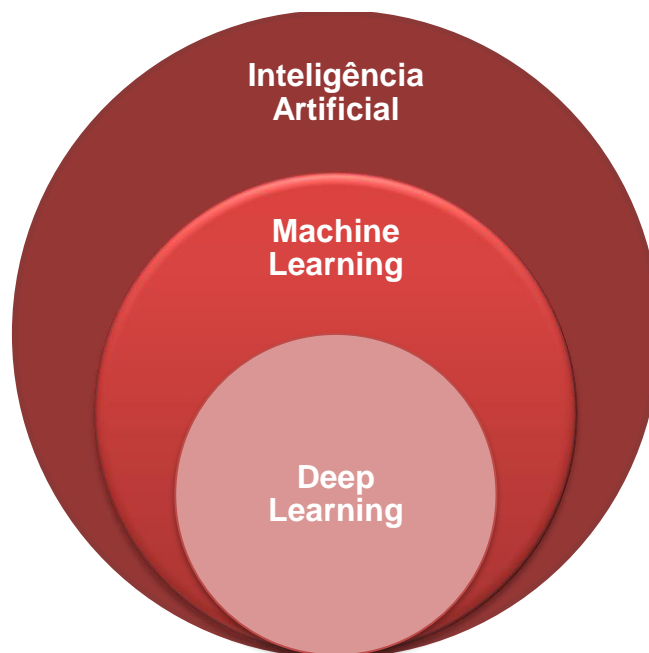
temos estudos desenvolvidos por Liu *et al.* (2017) e Liang *et al.* (2018), envolvendo o modelo FLUS, e estudos realizados com o modelo MOLUSCE, como apresentado por Nugroho, Hasyim e Usman (2018), Aslan e Koc-San (2016) e Al-Rubkhi (2017).

2.2 Rede Neural Artificial

Redes Neurais Artificiais (RNA), em inglês *Artificial Neural Networks* (ANN), são tentativas de simular o raciocínio humano (ALMEIDA; GLERIANI, 2005). Segundo Tayyebi, Pijanowski e Tayyebi (2011), a RNA é uma técnica computacional de aprendizado de máquina que reconhece padrões complexos em dados. Essa técnica é elaborada segundo a maneira como uma rede de neurônios no cérebro de mamíferos processa vários sinais de entrada (TAYYEBI; PIJANOWSKI; TAYYEBI, 2011).

O estudo da RNA está inserido nas áreas do aprendizado de máquina (*Machine Learning*) e da aprendizagem profunda (*Deep Learning*). Essas áreas, por sua vez, estão contidas no campo de estudo da inteligência artificial (Figura 1).

Figura 1 – Inteligência Artificial, *Machine Learning* e *Deep Learning*.



Fonte: Adaptado de CHAGAS, 2019.

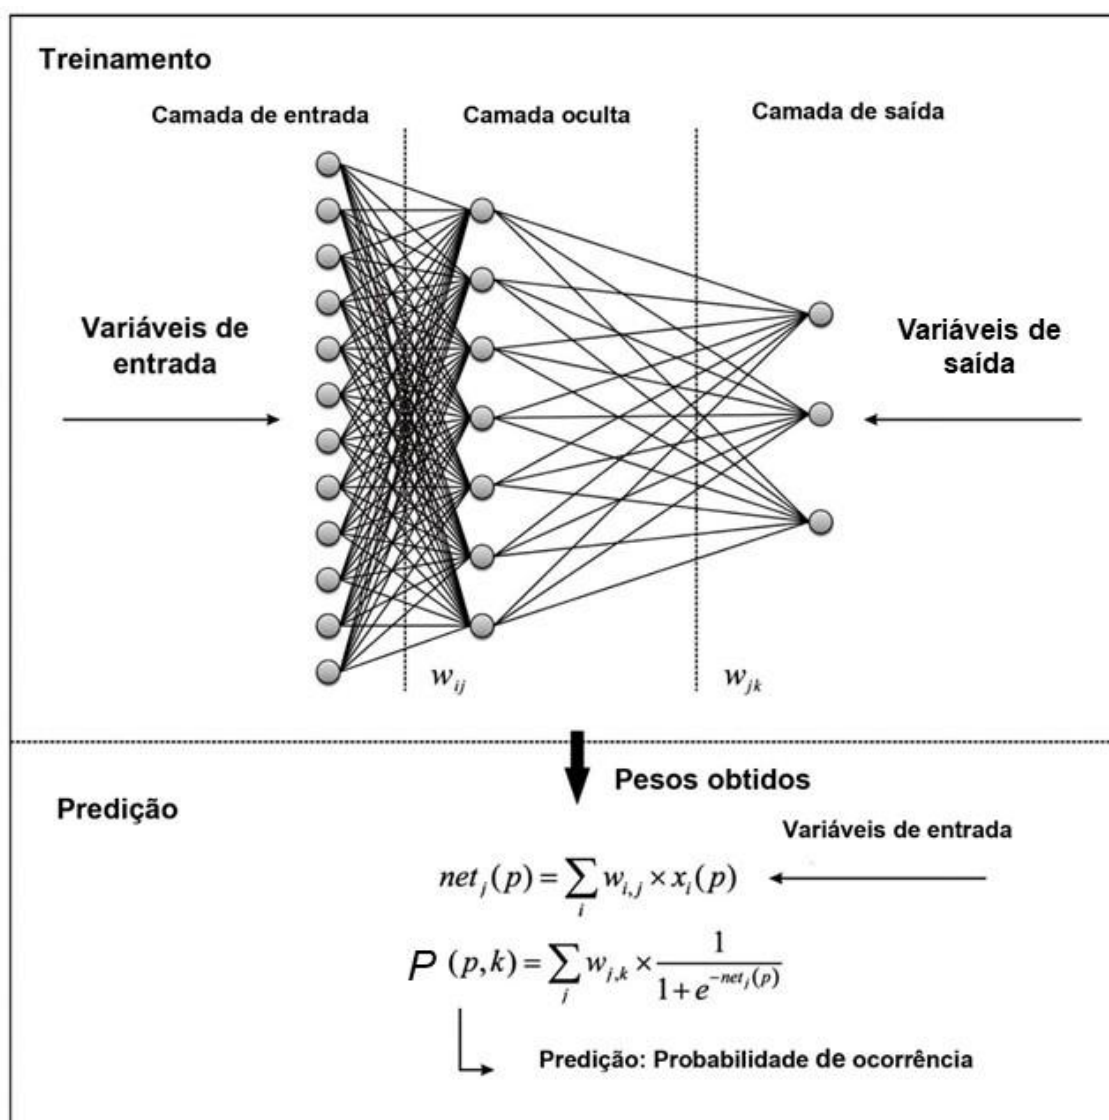
O campo de estudo da inteligência artificial compreende pesquisas e projetos de sistemas que consigam tomar decisões com base em uma característica inteligente (CHAGAS, 2019). O *Machine Learning* se baseia em algoritmos com a habilidade de aprender sem programação expressa. Já o *Deep Learning* é uma subdivisão do *Machine Learning*, na qual as Redes Neurais Artificiais se adaptam e aprendem utilizando um grande volume de informações (CHAGAS, 2019). As principais diferenças entre o *Machine Learning* e o *Deep Learning* são a necessidade e o impacto do volume de informações, do poder computacional e da flexibilidade na modelagem dos problemas (CHAGAS, 2019).

O uso da RNA tem crescido substancialmente na última década em várias áreas do conhecimento, devido aos avanços computacionais (TAYYEBI; PIJANOWSKI; TAYYEBI, 2011) e a pesquisas sobre inteligência artificial. A RNA pode ser usada para reconhecimento de padrões ou classificação (ALMEIDA; GLERIANI, 2005), sendo muito adequada para solução de problemas geoespaciais (LI; YEH, 2001). Li e Yeh (2001) elencam as seguintes vantagens da RNA: a) a estrutura dos algoritmos permite que as redes neurais sejam robustas e resistentes a ruídos, independentemente do uso de dados incompletos; b) permite lidar com problemas altamente não-lineares em sistemas complexos; c) não requer equações ou expressões exatas, sendo um método bastante simples; d) permite obter o melhor nível de performance; e) não existe restrição quanto ao uso de dados não-numéricos; f) se adapta a distribuições de frequência não-normais; g) permite misturar diferentes tipos de mensuração; h) permite o uso de várias variáveis e de redundância.

Os primeiros conceitos sobre RNA foram apresentados nos estudos de McCulloch e Pitts (1943), Hebb (1949) e Roseblatt (1958). McCulloch e Pitts (1943) criaram uma rede neural simples e elaboraram um modelo computacional para redes neurais (CHAGAS, 2019). A partir desse estudo, surgiram pesquisas sobre redes neurais considerando os processos biológicos cerebrais e sobre a aplicação das redes neurais voltada à inteligência artificial (CHAGAS, 2019). Hebb (1949), em seu trabalho, apresentou que a essência da aprendizagem dos circuitos neurais está na utilização dos circuitos e que os mesmos se fortalecem quanto maior for seu uso (CHAGAS, 2019). Roseblatt (1958) apresentou o Perceptron, um modelo probabilístico para armazenamento e organização de informações no cérebro. Apesar de suas limitações, o Perceptron é a rede neural mais antiga utilizada atualmente (CHAGAS, 2019).

A unidade básica de processamento em uma rede neural é o chamado neurônio ou nó, o qual é organizado em camadas (LI; YEH, 2001). Normalmente, conforme demonstrado na Figura 2, uma rede neural tem uma configuração de três níveis: uma camada de entrada, uma camada de saída e entre essas nenhuma ou algumas camadas ocultas (ALMEIDA; GLERIANI, 2005). Todos os neurônios, exceto aqueles da camada de entrada, realizam duas funções de processamento simples: coletam a ativação dos neurônios na camada anterior e geram uma ativação como entrada para a próxima camada. Os neurônios da camada de entrada apenas enviam sinais para a próxima camada (LI; YEH, 2001).

Figura 2 – Estrutura básica de uma RNA com múltiplas entradas.



Funções muito simples estabelecem as interações entre os neurônios (ALMEIDA; GLERIANI, 2005). Se i é igual ao neurônio remetente na camada de entrada e j é o neurônio receptor da próxima camada, a função coletora é dada por (1) (LI; YEH, 2001):

$$net_j(p) = \sum_i w_{i,j} x_i(p), \quad (1)$$

onde $x_i(p)$ é o sinal proveniente do neurônio i da camada remetente, $net_j(p)$ é o sinal coletor para o neurônio receptor j da próxima camada e $w_{i,j}$ é o parâmetro ou o peso para a soma dos sinais de diferentes nós de entrada. O neurônio receptor gera ativação em resposta ao sinal $net_j(p)$. A ativação se tornará a entrada para a próxima camada e essa ativação é normalmente gerada na forma da função sigmoid (LI; YEH, 2001):

$$\frac{1}{1 + e^{-net_j(p)}} \quad (2)$$

O sinal de entrada da próxima camada será a ativação e as equações (1) e (2) serão usadas para processar de novo o sinal. Essas rotinas continuarão até que os sinais finais sejam obtidos pela camada de saída (LI; YEH, 2001).

A parte crucial das redes neurais é determinar parâmetros (pesos) adaptáveis (LI; YEH, 2001), pois tais pesos são decisivos para definir os sinais finais (ALMEIDA; GLERIANI, 2005). Os valores dos pesos não são dados pelos usuários, mas sim determinados pela rede durante o treinamento (LI; YEH, 2001). O treinamento consiste em processos iterativos de ajustes aplicados aos pesos e o aprendizado de uma RNA ocorre quando a rede neural atinge uma solução generalizada para um determinado problema (FLECK *et al.*, 2016). Em resumo, treinar uma rede neural consiste em ajustar a matriz de pesos de forma que o vetor de saída coincida com um valor desejado para cada vetor de entrada (FLECK *et al.*, 2016).

Para o treinamento de uma RNA existem três paradigmas de aprendizado (GUIMARÃES *et al.*, 2008): aprendizado supervisionado, aprendizado não-supervisionado e reforço. Denomina-se “aprendizado supervisionado” quando um agente externo indica à RNA a saída desejada para um padrão de entrada. Ao se comparar a resposta da RNA com a desejada, pode-se então obter o erro da rede e, assim, ajustar os pesos de forma a minimizar esse erro (FLECK *et al.*, 2016). Quando não há esse agente externo no processo de aprendizagem, chama-se de “aprendizado não-supervisionado”. Aqui, a própria RNA deve encontrar alguma correlação ou redundância nos dados de entrada para obter uma resposta satisfatória

(FLECK *et al.*, 2016). Por fim, denomina-se “reforço” quando um crítico externo avalia a resposta fornecida pela rede. Nesse caso, o aprendizado da rede se dá através de avaliações do tipo sucesso e insucesso, fornecidas pelo crítico, as quais estão associadas às respostas da rede (GUIMARÃES *et al.*, 2008).

As redes neurais são definidas por meio de algoritmos de aprendizado (BARCA; SILVEIRA; MAGINI, 2005). Um algoritmo de aprendizado consiste em um conjunto pré-estabelecido de regras para a solução de um problema. Existem vários tipos de algoritmos de aprendizado e a principal diferença entre eles está no modo como os pesos da rede são ajustados. Assim, a escolha de um determinado algoritmo de aprendizado depende do tipo de aprendizagem que a rede neural deve executar (BARCA; SILVEIRA; MAGINI, 2005).

Um dos algoritmos de aprendizado mais populares, definido por Rumelhart, é o *back-propagation*, o qual minimiza iterativamente uma função erro entre as saídas (calculadas) da rede e as saídas desejadas, com base em um conjunto de dados de treinamento. A vantagem da rede neural *back-propagation* é que o algoritmo de aprendizado não é programado, a priori, na rede. Os pesos são inicialmente definidos por um processo randômico. O erro, computado como a diferença entre a resposta calculada e a desejada, é propagado de volta através da rede e usado para ajustar os pesos. O processo de ajustar os pesos de acordo com os erros é repetido até que a taxa de erro seja mínima ou atinja um nível aceitável (LI; YEH, 2001).

Uma vez obtidos os pesos ótimos do conjunto de dados de treinamento, a rede está pronta para classificação ou predição. A classificação ou predição está baseada no nível de resposta da camada de saída, o qual segue uma escala de 0 a 1. Essa escala reflete a variação de força dos componentes, onde zero (0) significa extremamente baixa e um (1) extremamente alta. Na classificação, por exemplo, um evento será alocado para a classe associada ao neurônio de saída com o maior nível de resposta (LI; YEH, 2001).

2.3 Autômatos Celulares

A origem dos Autômatos Celulares (CA – *Cellular Automata*) está associada às atividades de John Von Neumann, em seu estudo objetivando a comprovação matemática ligada à evolução de organismos biológicos, que iniciam os estudos da neurofisiologia, na década de 50. O interesse de Von Neumann (1966) estava em

encontrar uma configuração lógica em que uma célula pudesse se controlar de forma que agisse por vontade própria (autômato), podendo, portanto, se autorreproduzir. Para tanto, foi seguindo as orientações do matemático Stanislaw Ulam, que trouxe a perspectiva da autorreprodução seguindo uma sequência lógica, um algoritmo que levou à construção de uma máquina, semelhante a uma Máquina de Turing, com a capacidade de autorreprodução, composta por espaços celulares organizados de maneira matricial que apresentavam comportamento próprio (LANGTON, 1986).

Ricobom (2011) destaca que a capacidade de autorreprodução diferenciava a máquina desenvolvida da mecânica tradicional. A máquina de Von Neumann apresentava etapas metódicas estabelecidas de maneira ordenada e por singular formulação matemática. Segundo o autor, embora todas as células componentes do sistema estavam sujeitas às mesmas regras, a situação de um conjunto, definido pela vizinhança, poderia variar de maneira complexa e indefinidamente, o que levaria à situação de autorreprodução.

Com a definição teórica do conceito de autômatos realizada pelos matemáticos Stanislaw Ulam e John Von Neumann, foi possível a aplicação do conceito em 1970 por John Horton Conway, ao formular o Jogo da Vida. O Jogo da Vida era um autômato celular que simulava, a partir de regras simples, a interação entre uma população, onde o nascimento ou a morte de uma célula está associada às células vizinhas, tendendo o jogo à geração de padrões estáveis ou à morte de todas as células. Nesse jogo, há uma matriz de transição que apresenta cada célula em um dos estados possíveis, viva ou morta, tendo sua vizinhança definida a partir das oito células adjacentes. As regras de transição são definidas de acordo com critérios seguindo a lógica temporal, que podem manter a célula viva, morta (por solidão ou sufocamento) ou até determinar o seu renascimento (AGUIAR *et al.*, 2004).

Um autômato celular é composto por uma grade regular de células, análogas à configuração matricial de um tabuleiro de xadrez, distribuídas em um espaço n -dimensional. As células são variáveis discretas, distribuídas uniformemente sobre o campo matricial, onde o estado de cada campo está associado a um instante de tempo t ($t = 0, 1, 2, 3, \dots$), e a uma função, regra de transição, simples. O estado de uma célula evolui discretamente de acordo com o tempo e os valores associados à vizinhança, seguindo um conjunto de regras locais pré-definidas (DELANEZE *et al.*, 2014).

Um modelo baseado em CA possui características de auto-organização, amparado em um sistema aberto, capaz de representar e reproduzir espacialmente fenômenos complexos. Por tal característica, o uso de CA estende-se sobre vários estudos ambientais, hídricos, de termodinâmica, de engenharia de tráfego, climatológicos, de controle epidêmicos, entre outros (ALMEIDA & GLERIANI, 2005).

Stephen Wolfram (1984) foi o responsável por estudos sistemáticos da mecânica, estatística e de formações de padrões dos autômatos celulares. Seus estudos levaram a entender um autômato celular como uma idealização matemática de sistemas físicos em uma configuração espaço-temporal discreta, analogamente para sistemas biológicos e computacionais. O estado de cada célula evolui no tempo, influenciando a configuração tanto das células vizinhas, quanto das subjacentes diretas, de acordo com as regras previamente definidas. Segundo o mesmo autor, um CA unidimensional consiste em um conjunto de células, que assume um valor 0 ou 1 (generalizando, 0, ..., k-1), de acordo com uma regra de transição determinística, variando em um tempo discreto. Os padrões gerados pelos autômatos celulares evoluem no tempo, a partir de células com valores diferentes de zero. As regras de transição estabelecidas produzem padrões que levam ao desaparecimento das células no tempo, limitam o desenvolvimento das células a um espaço fixo, resultando no crescimento a uma velocidade constante e em um padrão irregular (crescimento e retração irregulares).

Gremonini e Vicentini (2008) caracterizam as propriedades dos autômatos celulares conforme a geometria, dimensão, forma e distribuição das células. De acordo com os autores, para termos um autômato celular é preciso que exista uma malha de geometria regular, uma matriz, onde as células possuem o mesmo tamanho e estão dispostas em uma configuração de rede ou malha. Nessa distribuição, as células podem assumir variados formatos geométricos, desde que todos os autômatos de uma mesma grade possuam a mesma forma, compondo grades formadas por triângulos, quadrados, hexágonos, etc.

Modelos tradicionais baseados em autômatos celulares têm sua regra de transição definidas por regras determinísticas, quando não há aleatoriedade associada ao modelo, tratando o fenômeno de maneira linear, baseando a modelagem em sistemas de reprodução mais simples. No entanto, quando há a necessidade de introduzir alguma perturbação, aleatoriedade, são utilizadas modelagens estocásticas, que podem reproduzir um conjunto de aspectos não representados por

modelos tradicionais. Existe ainda uma abordagem baseada em modelos de aprendizagem de máquinas como, por exemplo, as redes neurais, em que os valores dos parâmetros são determinados por treinamento da rede, a partir dos dados de entrada. Essa abordagem torna mais completa a simulação, facilitando a sua utilização, diminuindo por vezes a necessidade de dados, tornando, no entanto, as regras de transição em equações extremamente complexas e de difícil compreensão (MASSABKI *et al.*, 2017). Massabki *et al.* (2017) descrevem que as regras de transição são determinadas de maneira análoga à forma como acontecem os fenômenos no mundo real, sendo obtidas através de algoritmos capazes de reproduzir as condições que definem as células e simular o comportamento das mesmas no futuro.

Fernandes (2016) diferencia os modelos determinísticos de estocásticos, segundo a influência dos valores de entrada no resultado do modelo. Segundo o autor, modelos determinísticos são consequência direta dos valores das variáveis de entrada do modelo, apresentando sempre o mesmo resultado, se mantidas as condições e os valores iniciais e de contorno. Já os modelos estocásticos, levam em considerações incertezas, flutuações randômicas, que atribuem certa aleatoriedade ao modelo. Desta forma, simulações realizadas com os mesmos valores de entrada, aplicadas em modelos estocásticos, podem fornecer dados de saída (resultados) distintos.

Polidori (2009) descreve que, pelas características e possibilidades de espacialização e de representação, os CA podem ser utilizados para auxiliar na modelagem e solução de fenômenos espaço-temporais. Conforme apresentado por Portugali (2000), a questão de utilizar autômatos celulares para o estudo das cidades está na similaridade entre as unidades espaciais (quadras, lotes) e as células, bem como na convergência entre as distribuições matricial e espacial. Nesse sentido, Polidori (2009) destaca o potencial de realização de análises de diferenciação da morfologia, a partir de cenários históricos, que possibilitam a detecção de resistências espaciais, bem como de limiares ambientais.

Liu *et al.* (2018) afirmam que modelos baseados em autômatos celulares têm sido amplamente utilizados em estudos voltados à definição de padrões de expansão urbana. Segundo os autores, esses modelos são aplicados principalmente pela possibilidade de operar em uma superfície composta por células, como é o caso da distribuição matricial, e de representar as transições urbanas, a partir de uma variedade de métodos capazes de recuperar as regras de transição. Além disso, Batty (1999) destaca a possibilidade de interpretação desses fenômenos em diversas

escalas, estabelecendo modelos que podem variar o tamanho da célula de poucos metros até alguns quilômetros. Por tais aspectos, Polodori (2009) define as possibilidades de replicar as características dos autômatos celulares à realidade urbana. Destaca a similaridade espacial entre o arranjo urbano, em sua morfologia bidimensional, e a célula, unidade espacial básica de modelos baseados em CA. O estado da célula, similar ao que acontece em modelos de classificação do uso do solo, assume apenas um estado em determinado período. A vizinhança é fator importante para o entendimento do espaço urbano, uma vez que há modificação do espaço a partir das interações da região circunvizinha; da mesma forma, na modelagem baseada em CA, o estado da célula depende diretamente do estado da vizinhança. Assim, padrões de vizinhança são aplicados para explicar os avanços das dinâmicas urbanas. A interação espacial e a forma como ocorre o crescimento urbano são aplicadas para obtenção de regras de transição, que permitem definir como uma célula se comporta em respostas ao estado das células vizinhas, apresentando similaridade com os processos urbanos. Por fim, a questão temporal, relacionada às interações espaciais que modificam o solo de acordo com o avanço do tempo, a possibilidade de simulação associada ao CA permite representar a realidade urbana de acordo com as diferentes velocidades de crescimento e em diferentes regiões da cidade.

2.4 Valor da terra e avaliação em massa de imóveis

A configuração do espaço territorial, com a distribuição espacial de atividades, funções e interações, se dá de maneira variável, de acordo com a localização, formando uma colcha de retalhos de regiões funcionais de diferentes formas. As limitações de espaço das cidades levam às disputas pela terra para diferentes interesses e propósitos e, por consequência, interferem diretamente nas políticas de desenvolvimento espacial. Os gestores municipais usam o planejamento do solo para gerenciar e desenvolver políticas que devem suprir as necessidades da comunidade e, concomitantemente, proteger os recursos naturais. Essas políticas são baseadas em avaliações sistemáticas do potencial da terra, de acordo com suas possibilidades de uso, e atreladas ao seu potencial econômico e social. Nesse sentido, concentra-se a questão da falta de um sistema integrado que oriente as mudanças de uso do solo

e que levem em consideração o valor da terra como variável significativa que afeta a mudança espacial do uso do território (EL-BARMELGY *et al.*, 2014).

O valor da terra está diretamente relacionado à localização do imóvel. O acesso às infraestruturas determina as atividades das regiões e, conseqüentemente, o valor do imóvel. Os valores mais altos de propriedades estão, geralmente, associados aos locais com maior acessibilidade, isto é, estão associados a um modelo de distribuição espacial que sugere que o preço da terra cai com o aumento da distância dos locais com instalações e infraestrutura de transporte, como o centro das cidades ou centros secundários, onde a oferta de empregos, por exemplo, é relativamente maior (GEURS; WEE, 2004).

Paiva e Antunes (2017) descrevem que o valor de mercado de um imóvel está relacionado à existência de equipamentos e serviços urbanos, à acessibilidade, às restrições de uso e cobertura e às características individuais do imóvel, como topografia, área, testada, posição, entre outras. Devido à impossibilidade de realização de avaliações individuais, relacionadas à peculiaridade de cada propriedade, as avaliações em massa de imóveis urbanos utilizam a técnica de geração de Plantas de Valores Genéricos (PVG).

A elaboração de plantas de valores no Brasil é norteada pela Norma de Avaliação de Bens (NBR 14.653) da Associação Brasileira de Normas Técnicas (ABNT), que define a PVG como a representação gráfica ou listagem de valores genéricos por metro quadrado de um terreno e de uma edificação em determinado período (ABNT, 2004). Os métodos utilizados para a construção das PVG buscam representar as características físicas e de infraestrutura de cada região, atribuindo um valor ao imóvel.

A avaliação em massa tem como objetivo principal determinar os valores dos imóveis a partir de metodologias e critérios de avaliação, que quando aplicados em larga escala devem representar a proporcionalidade de valores dos imóveis avaliados, em face da localização, das características e da infraestrutura disponibilizada. Sendo assim, para realizar a avaliação em massa e conseqüente construção de plantas de valores adequadas, são estabelecidas zonas homogêneas e definidos modelos para avaliação e representação espacial. As zonas homogêneas são áreas inseridas no perímetro urbano que apresentam um padrão construtivo e de tipologia, uma mesma finalidade de uso do solo, bem como uma mesma taxa de ocupação, o que resulta em uma mesma valorização imobiliária (LIPORONI, 2013).

Ao realizar a avaliação em massa, objetiva-se determinar os valores de todos os imóveis de uma determinada região, tendo como uma das principais aplicações a tributação imobiliária. Nesse contexto, Möller (1995) ressalta que a construção das Plantas de Valores Genéricos está vinculada ao estudo e à revisão do Código Tributário Municipal, sendo sua atualização necessária para justa aplicação dos impostos sobre a propriedade, como o IPTU e o ITBI.

Moller (1995) destaca que a formulação para obtenção dos valores de imóveis está associada a soma dos valores da terra, terreno, aos valores de benfeitorias, edificações. Conforme Paiva e Antunes (2017) para composição de valores da terra é preciso realizar uma pesquisa, baseada em dados cadastrais, que associem os valores de terrenos à localização do imóvel e suas características descritivas.

Cesare (2012) destaca que os modelos genéricos são originados a partir de uma amostra de dados, que está correlacionada ao banco de dados cadastral, sendo esses modelos normalmente baseados em métodos estatísticos, normalizados, ou em outro método capaz de estimar o valor do avaliando de maneira acurada. Paiva e Antunes (2017) citam que ao tratar estatisticamente as características amostrais é possível gerar um modelo capaz de representar o comportamento imobiliário que minimize a aleatoriedade do mercado e as interferências de padrões especulativos. A correta estimação de valores é preponderante para o alcance da equidade de valores, proporcionalidade constante entre o valor estimado e o real (UBERTI, 2016).

Zilli (2020) descreve que na avaliação em massa objetiva-se a geração de um modelo que permita a obtenção de valores de um imóvel de forma indireta e prática, possibilitando uma avaliação uniforme e coerente para um grande número de imóveis. Uberti (2016) destaca que a escala diferencia a avaliação individual da em massa, uma vez que ambas apresentam a mesma finalidade, estando a prática de avaliação de grandes grupos associada a uma definição de avaliação sistemática, isto é, quando há uma padronização de procedimentos.

A escolha adequada do método possibilita atingir o objetivo de equidade exposto. A NBR 14.653 indica o uso do método comparativo de dados de mercado, sempre que possível. “O método comparativo direto de dados de mercado identifica o valor de mercado do bem por meio de tratamento técnico dos atributos dos elementos comparáveis, constituintes da amostra” (NBR 14.653-1, item 8.2).

Dantas (2001) cita que o método comparativo de dados de mercado avalia o bem a partir de uma comparação de seus atributos com as características

semelhantes presentes nos dados de mercado. Segundo o autor, esse método normalmente está baseado em técnicas que envolvem a inferência estatística e, por essa razão, deve apresentar uma amostra adequada para realização da regressão linear, técnica clássica associada a esse método.

Paiva e Antunes (2017) citam que o tratamento dos dados pode ser realizado por métodos determinísticos, como a homogeneização ou fatores de ponderação, bem como utilizando técnicas probabilísticas, como a regressão linear múltipla ou, ainda, outras técnicas que sejam adequadas ao universo amostral avaliado. Assim sendo, torna-se possível avaliar um bem com alta confiabilidade e reduzida subjetividade do modelo. Ao se tratar estatisticamente os dados componentes da amostra de mercado, pode-se relacionar a variável dependente (valor do imóvel) com as variáveis independentes que a determinam, tais como localização, área, padrão, topografia, entre outros (ZILLI, 2020).

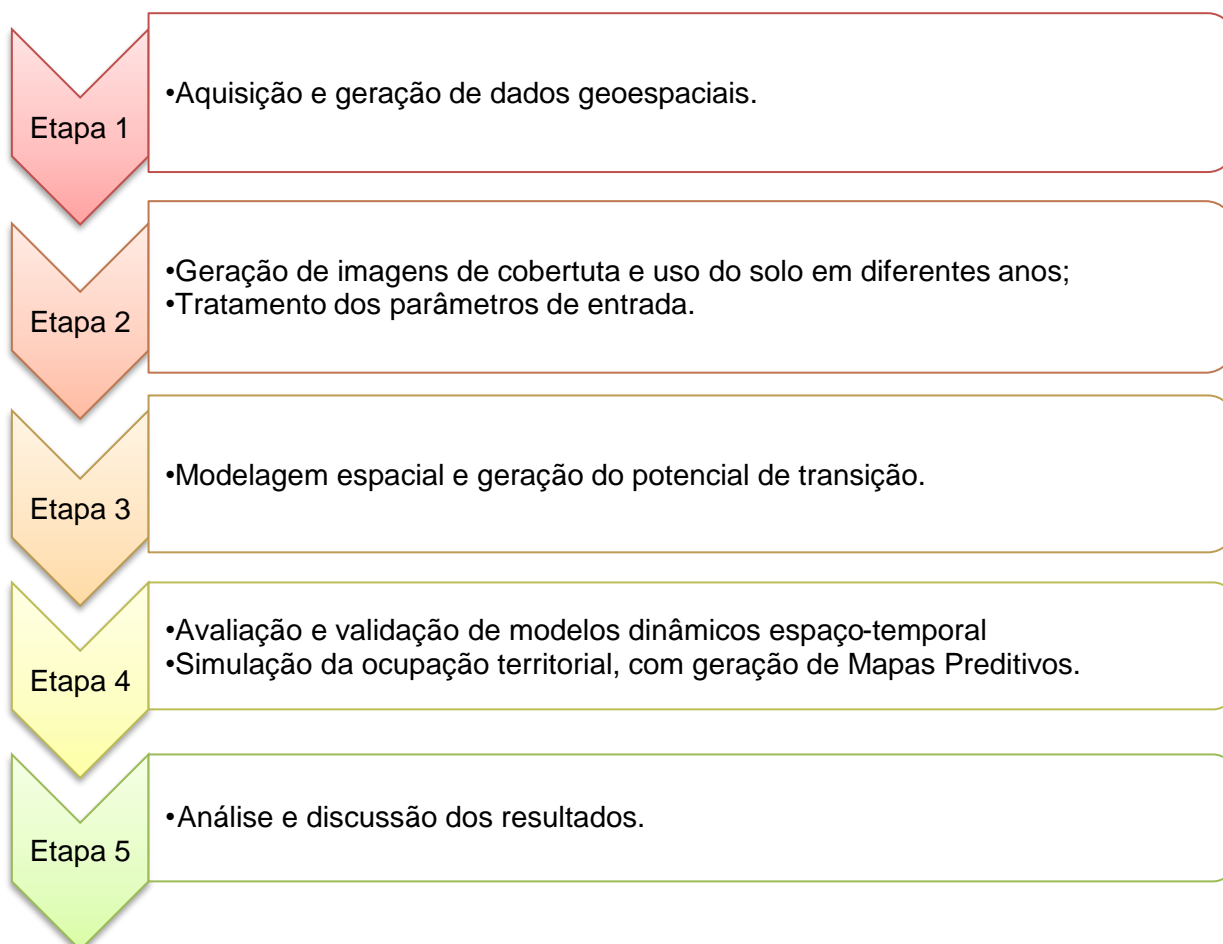
Uma importante distinção é dada por Liporoni (2013) no que tange a composição do valor do imóvel. Segundo Liporoni (2013), deve-se levar em consideração tanto o valor territorial quanto o predial. No que diz respeito ao terreno, seu valor unitário genérico corresponde à face da quadra na qual está inserido, bem como às suas características específicas, como posição, número de frentes, topografia, entre outras. Quanto à edificação, seu valor é definido de acordo com a tipologia, o padrão construtivo, o estado de conservação, entre outros. Ambas as composições fazem parte da PVG, sendo essas anexas ao Código Tributário Municipal, estando associadas às informações que compõem o banco de dados do Cadastro Técnico Municipal.

Conforme Paixão e Abramo (2009) o preço da terra está associado a ocupação do território segunda a dinâmica da oferta de terrenos e sua disponibilidade. Segundos os autores, nesse sentido os vetores de expansão da atividade imobiliária apontam no sentido de regiões consolidadas, onde em geral os preços dos terrenos são altos e o padrão tende a aumentar proporcionalmente.

3 METODOLOGIA

A metodologia da presente dissertação foi executada em cinco etapas, conforme destacado na Figura 3. Inicialmente, foi realizada a aquisição de imagens de cobertura e uso do solo e de informações referentes às variáveis de entrada do modelo e foi preparada a base de dados para processamento e compatibilização das informações. Posteriormente, foi executada a modelagem dos dados com geração de modelos dinâmicos, obtendo o potencial de transição. O modelo foi avaliado e validado, o que permitiu a geração de mapas preditivos, base analítica utilizada como objeto de análises e discussões finais.

Figura 3 – Etapas da metodologia.

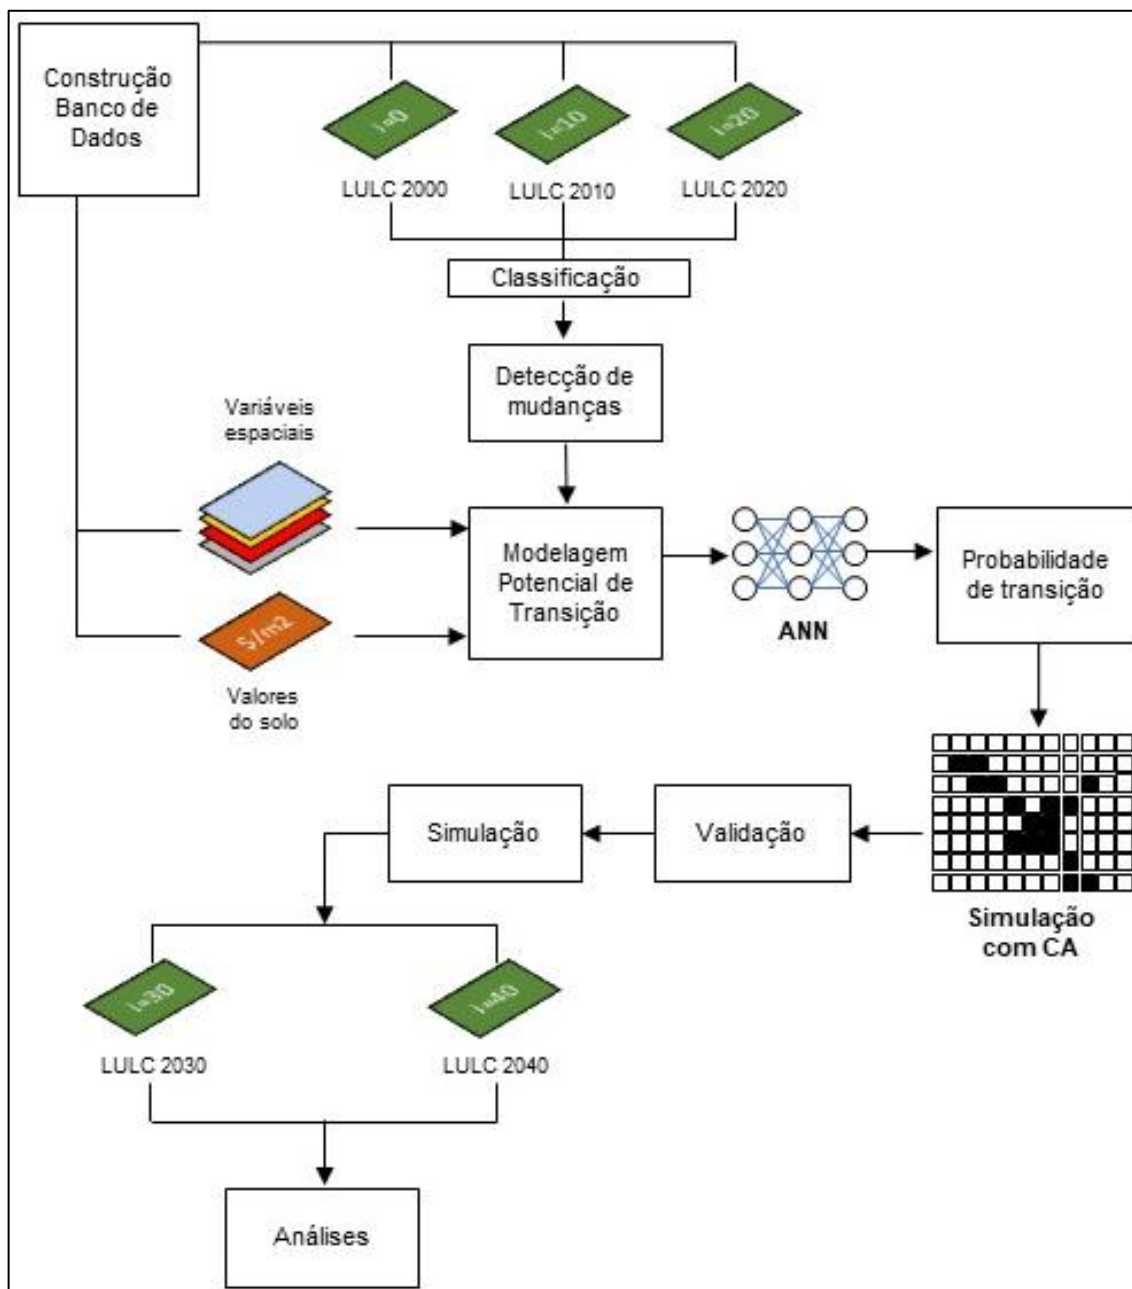


Fonte: Elaboração própria.

Na Figura 4 são detalhados os procedimentos metodológicos adotados em cada etapa. Foram destacados os passos metodológicos, a bibliografia estudada, bem

como os passos resultantes dos apoios metodológicos e computacionais utilizados no decorrer do presente estudo.

Figura 4 – Fluxograma do procedimento metodológico.



Fonte: Elaboração própria.

A primeira etapa consistiu na aquisição dos dados geoespaciais, que foram utilizados para a realização das análises do objeto de estudo. A segunda etapa compreendeu a aquisição e geração dos dados de entrada do modelo, dados de uso e cobertura do solo e variáveis atuantes sobre essa classificação. Os dados obtidos

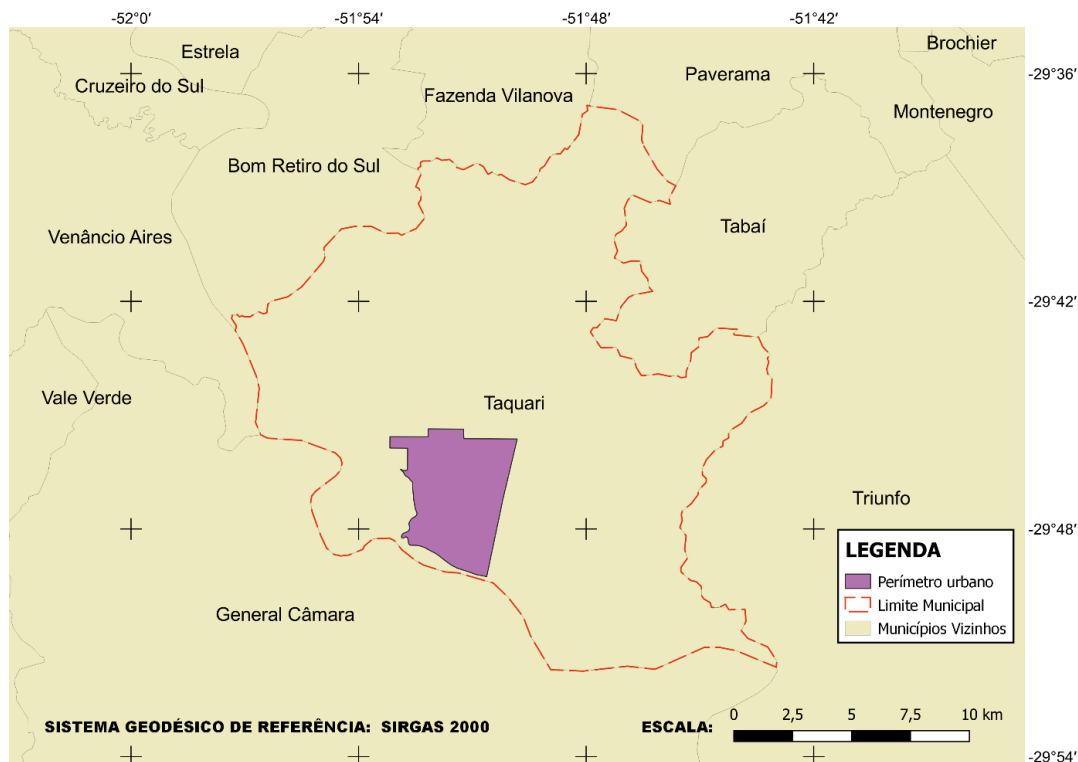
foram compatibilizados geometricamente e espacialmente para uma mesma extensão e formato matricial, sendo estes as imagens de cobertura e uso do solo e as variáveis independentes do estudo.

Para a entrada no *plugin*, os dados provenientes das diferentes bases tiveram que ser convertidos para uma mesma estrutura digital. Sendo assim, os dados foram rasterizados, formando um conjunto de dados em formato matricial (*raster*), que serviu de base para a realização das etapas metodológicas. Na terceira etapa realizou-se a modelagem dos dados espaciais, gerando os modelos de transição, que representam a dinâmica espaço-temporal, sendo estes avaliados e validados dentro do sistema utilizado. O modelo foi obtido através de técnicas computacionais de aprendizado de máquina, capazes de reconhecer padrões complexos de uso e cobertura do solo. A partir da modelagem de dados e com base no sistema de geração de modelos de evolução temporal e simulação via autômatos celulares, foram simulados cenários futuros, com geração de mapas preditivos, para a área de estudo. Com os cenários futuros gerados, foi possível avaliar a influência das variáveis analisadas e os impactos da utilização do valor da terra na modelagem espacial. Na quinta etapa, foi realizada a análise dos dados resultantes da metodologia empregada e a avaliação do cumprimento dos objetivos inicialmente propostos.

3.1 Área de estudo

O município de Taquari está localizado na região central do Rio Grande do Sul, distante 100 quilômetros da capital estadual, Porto Alegre. Conforme demonstrado na Figura 5, o município está localizado entre as latitudes 29°54'S e 29°36'S e as longitudes 52°00'W e 51°42'W. O acesso ao município se dá através da rodovia estadual RS-287, que liga o município à rodovia federal BR-386, rota de ligação com a capital estadual. Internamente, a ligação ao principal núcleo urbano é realizada, principalmente, pela rodovia estadual RS-436, que tem origem na RS-287 (TAQUARI, 2023).

Figura 5 – Localização do município de Taquari/RS.



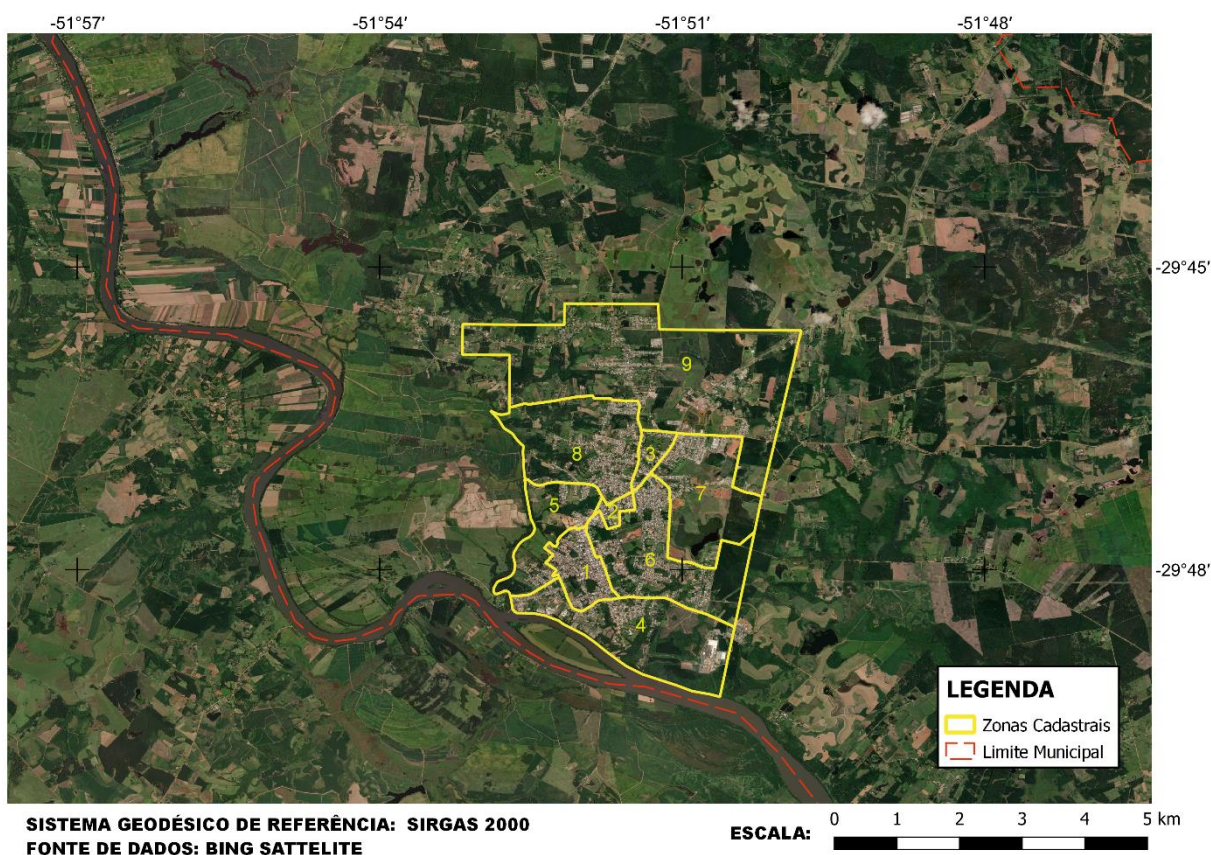
Fonte: Elaboração própria.

Com origem na colonização açoriana, Taquari foi a primeira cidade gaúcha cuja ocupação foi planejada pelo governo português, traço presente pela arquitetura herdada dessa colonização. Tem sua emancipação datada de 04 de julho de 1849, apresentando, atualmente, uma área em torno de 350 quilômetros quadrados, ocupados por uma população de aproximadamente 27 mil habitantes (IBGE, 2022).

O município de Taquari limita-se politicamente com os municípios de Triunfo, Tabai, Fazenda Vilanova, Bom Retiro do Sul e General Câmara e apresenta forte ligação ao Rio Taquari, o qual caracteriza o limite sul do perímetro municipal. As atividades econômicas do município estão voltadas preferencialmente aos setores de serviços (57%) e indústrias (32%), com menor representatividade no setor agrícola (11%) (TAQUARI, 2023).

A área urbana está distribuída em nove zonas, conforme ilustrado pela Figura 6, apresentando uma área total de 24 quilômetros quadrados. Apresenta um padrão de expansão urbana complexo, com zonas de diferentes extensões e um processo de crescimento urbano não padronizado, apresentando zonas periféricas de alta ocupação e, em contrapartida, a existência de glebas urbanas não loteadas na zona central do município.

Figura 6 – Distribuição das zonas cadastrais de Taquari/RS.



Fonte: Elaboração própria.

Conforme demonstrado na Figura 6, existem grandes setores cadastrais nas áreas periféricas do núcleo urbano municipal, zonas essas que apresentam ocupação mista, rural e urbana, decorrente do crescimento urbano para as regiões mais afastadas do centro, cujo valor da terra é proporcionalmente reduzido. Outro detalhe relevante refere-se à localização próxima ao Rio Taquari, configurando esse um limitante natural para o crescimento.

O município de Taquari foi escolhido para o desenvolvimento dessa pesquisa pela disponibilidade dos dados espaciais (base cartográfica cadastral municipal), políticos (Plano Diretor) e econômicos (PVG) do município. A extensão da área estudada vai um pouco além dos limites urbanos, com objetivo de facilitar o processamento de dados, com geração de imagens de formato regular.

Esses dados foram concedidos ao autor devido a realização de trabalho técnico para avaliação de imóveis no ano de 2015, o qual resultou em um banco de dados de valores municipais para geração de produtos de avaliação em massa, caso da PVG. A PVG data de 2015 e compreende a área urbana do município, mas foi

complementada nos anos de 2016 e 2017 com dados de valores da terra para as regiões além do perímetro urbano. Os dados da PVG estão armazenados na estrutura vetorial no padrão Esri *shapefile* (.shp) e os dados da base cartográfica cadastral municipal e do Plano Diretor na estrutura vetorial no padrão AutoCAD (.dxf). Os dados do levantamento cadastral do município são de 2015, ano de atualização da base cadastral, assim como o Plano Diretor de Desenvolvimento Urbano e Rural, que foi estabelecido pela Lei nº 3.832, de 17 de junho de 2015.

3.2 Aquisição e geração dos dados geoespaciais

Os dados necessários para a composição da presente dissertação são arquivos cartográficos e imagens classificadas da região estudada em diferentes épocas, utilizados para tornar operacional o método, obtenção dos parâmetros de transição e simulação da expansão urbana. Sendo assim, foram coletados, para a área de estudo, dados de cobertura e uso do solo, obtidos a partir da classificação de imagens de períodos sequenciais, igualmente espaçados. Quanto as variáveis independentes avaliadas, foram utilizadas as características presentes em grande parte da bibliografia estudada, estando resumidas no Quadro 1

Quadro 1 – Lista de dados utilizados no estudo.

Categoria	Dados
Uso do solo	Imagens classificadas
Terreno	Modelo digital do terreno Recursos hídricos
Infraestrutura	Rodovias
Variáveis políticas	Áreas do Plano Diretor Áreas não-urbanizáveis Áreas dedicadas à expansão urbana
Variáveis econômicas	Planta de Valores Genéricos

Fonte: Elaboração própria.

As variáveis de entrada do modelo estão presentes na maior parte dos estudos de dinâmica espacial, que objetivam a construção de mapas preditivos. A variável incrementada, destacada como variável econômica, foi obtida a partir do banco de valores de imóveis, proveniente de dados do autor em avaliação de massa realizada na região estudada.

As características de uso do solo alimentam basicamente o modelo para mapear a evolução da atividade humana na região. Verifica-se as alterações no espaço e como ocorreu o avanço das atividades exploratórias em um intervalo de tempo determinado. A configuração do uso e cobertura do solo no primeiro cenário é utilizada como base para iniciar o modelo, camadas sequenciais são usadas para calibrar a transição nos anos subsequentes, visando à identificação de como se dá a dinâmica espacial local. Em contrapartida, as áreas não urbanizáveis, também conhecidas como áreas de exclusão, definem os locais que impossibilitam a urbanização ou a condicionam, são exemplos os parques nacionais, áreas de preservação permanente, lagos entre outros.

Os produtos do mapeamento de uso e cobertura do solo apresentam as características da região para um intervalo de tempo previamente definido. Os dados foram introduzidos no modelo como variável dependente, isto é, buscou-se determinar um modelo que representa a transição espaço-temporal dessas características. Para tanto, a base de dados adotada respeita intervalos temporais iguais, de 10 em 10 anos, o que permite simulações igualmente espaçadas no tempo.

Variáveis que modificam a paisagem foram incrementadas no estudo para calibrar o modelo de transição. O modelo digital do terreno se mostra relevante na análise, uma vez que o desenvolvimento urbano se dá respeitando as peculiaridades do relevo local. A proximidade às vias de acesso é um fator de calibração muito importante para o modelo, pois há alta correlação entre as malhas viárias existentes e o desenvolvimento de uma região. No presente estudo, além das variáveis citadas, foi incrementado um fator econômico, ligado à avaliação em massa, que traz para modelagem variáveis indiretas de infraestrutura e localização, as quais não estariam previstos pelo modelo, mas estão inseridas no processo de obtenção dos valores da terra.

Os demais dados da base cartográfica, principalmente no que diz respeito aos impulsionadores de crescimento, foram obtidos em sítios públicos ou em bancos de dados de acesso gratuito. Alguns dados relevantes foram originados da base

cartográfica do cadastro municipal de Taquari, tais como malha viária principal, localização de principais corpos hídricos, zoneamentos municipais e a composição da base cartográfica de valores municipais. As informações complementares da malha viária foram vetorizadas a partir das imagens de satélite do município e, em último caso, obtidas junto à plataforma colaborativa de acesso aberto *OpenStreetMap*. Os dados altimétricos foram obtidos de modelos digitais do terreno SRTM, resultantes da missão espacial do ano 2000, realizada pelas agências espaciais americana (NASA e NGA), italiana (ASI) e alemã (DL), com resolução espacial de 30 metros.

Quanto ao *software* utilizado, optou-se por realizar as operações da presente dissertação no *software* livre QGIS. Foram utilizadas ferramentas do programa para geração das bases cartográficas, classificação de imagens, georreferenciamento e interpolação de dados.

O MOLUSCE (*Modules for Land Use Change Evaluation* – Módulos de Avaliação de Mudanças no Uso do Solo) foi a ferramenta utilizada para analisar as mudanças de uso da terra entre períodos temporais distintos, modelar o potencial de transição de uso do solo e simular cenários futuros de uso da terra e modificação na paisagem. O componente MOLUSCE é um *plugin* que opera na interface do QGIS, desenvolvido pela *NextGIS* em convênio com a *Asia Air Survey Co. Ltd. (AAS)*, o qual foi concebido para analisar, modelar e simular as modificações de cobertura e uso do solo através de algoritmos conhecidos (BOSSLE, 2022).

3.3 Geração de imagens de cobertura e uso do solo

As informações georreferenciadas referentes ao uso e cobertura da terra foram obtidas junto à plataforma aberta do Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil (MapBiomass, 2022). Tendo em vista a capacidade técnica do *software* utilizado para treinamento e simulação da rede, optou-se por utilizar uma base já existente, resultante da classificação de imagens obtidas a partir das missões LandSat e disponibilizadas no sítio eletrônico do referido projeto. Imagens de sensores CBERS, que inicialmente seriam utilizadas no modelo, apresentam resolução espacial incompatível (grande resolução) com a capacidade de atuação do modelo. Nesse sentido, as imagens de alta resolução serviram como base para construção, complementação e fiscalização das demais variáveis explicativas apresentadas no presente trabalho.

Para as atividades, estabeleceu-se um período temporal de acordo com os produtos disponibilizados pela base do projeto MapBiomias (2022) e compatível com as bases existentes para geração das variáveis independentes. Sendo assim, foram acessados os dados disponibilizados na base de dados virtual do projeto, onde foi feito diretamente o *download* dos dados.

3.4 Tratamento das variáveis de entrada

Os dados foram compatibilizados para entrada no modelo proposto. Para tal propósito se fez necessário o georreferenciamento dos dados de entrada para determinação de uma base de dados associada ao mesmo sistema geodésico de referência SIRGAS2000 e, da mesma forma, a um único sistema de projeção cartográfica (*Universal Transversa de Mercator* – UTM, fuso 22 Sul). Nesse sentido, tanto os dados de entrada quanto as variáveis que modificam o cenário municipal foram compatibilizadas, permitindo assim a entrada de dados no modelo.

As classes resultantes do mapeamento temático MapBiomias foram agrupadas, respeitando as classes demonstradas no Quadro 2. A reclassificação resultou em seis classes (área urbana, solo exposto, corpo d'água, área de campo ou agropecuária, formação florestal e campo alagado) e foi realizada com a finalidade de simplificar o estudo e a análise de transição entre os dados de entrada do modelo.

As imagens classificadas foram inseridas no modelo e calculou-se a porcentagem de mudança de área em um determinado ano, gerando uma matriz de transição que mostra a proporção de pixels que mudou de uma determinada classe de uso da terra para outra. Esta análise foi realizada através do *plugin* MOLUSCE, que só gera o modelo e analisa a transição se as imagens de entrada estiverem totalmente compatíveis.

No Quadro 2 a coluna da esquerda mostra a relação numérica adotada para cada classe, a coluna central a classificação utilizada e a coluna da direita as classes correlacionadas do banco de dados do projeto MapBiomias (2022). Essa classificação foi adotada para todas as imagens de cobertura e uso do solo e para todas as classificações e simulações realizadas na metodologia.

Quadro 2 – Reclassificação dos dados MapBiomias.

	Classes de uso da terra	Classes do MapBiomias
1	Área Urbana	Área Urbanizada
2	Solo Exposto	Praia, Duna e Areal; Outras Áreas não vegetadas e Afloramento Rochoso
3	Corpo D'água	Rio, Lago e Oceano
4	Área de campo / Agropecuária	Formação Campestre; Pastagem e Agriculturas
5	Formação Florestal	Formação florestal; Silvicultura
6	Campo Alagado	Campo Alagado e Área Pantanosa

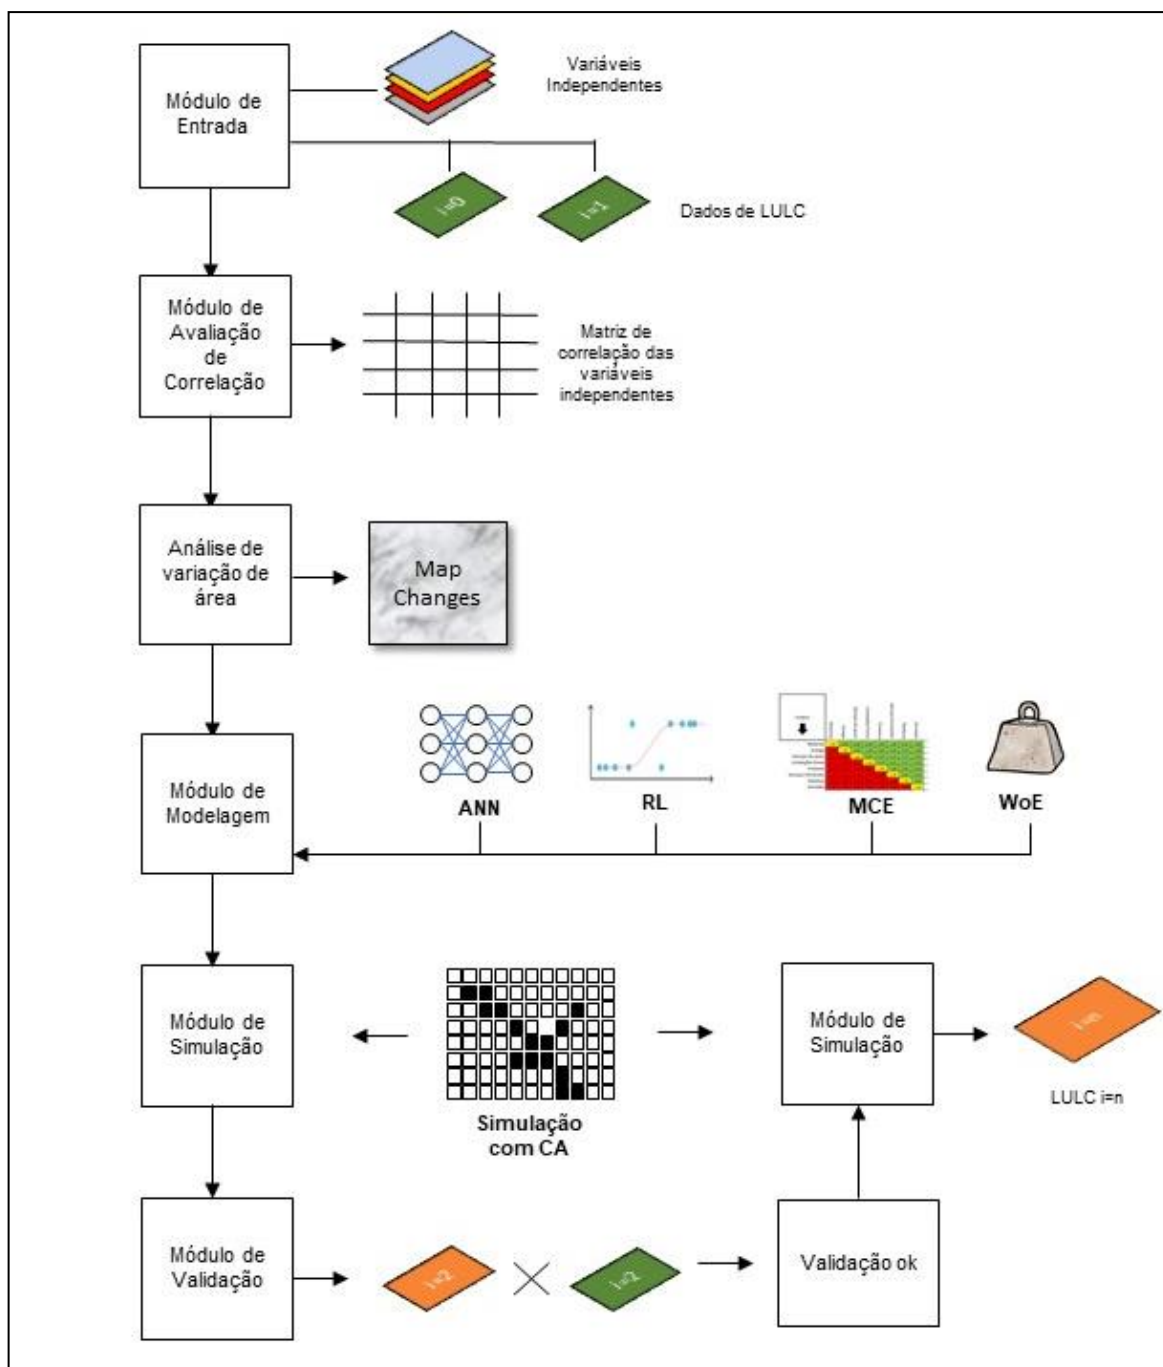
Fonte: Elaboração própria.

A reclassificação foi realizada no *software* QGIS e se deu através da relação dos números associados às classes de origem com as classes definidas para esse estudo, de acordo com a ordem numérica demonstrada no Quadro 2. Como resultado, foram reclassificadas três imagens, sendo essas as imagens de 2000, 2010 e 2020. As duas imagens mais antigas são base para treinamento do potencial de transição e a última, mais recente, foi utilizada para validação do modelo.

3.5 Modelagem espacial e geração do potencial de transição

Objetivando a simulação de cenários futuros, optou-se por utilizar um modelo baseado em aprendizagem de máquina com simulação aplicada através de autômatos celulares. Para tanto, foi utilizado o *plugin* MOLUSCE dentro do *software* QGIS.

O MOLUSCE consiste em uma ferramenta construída em plataforma de código aberto, concebida para avaliação de mudanças de ocupação e uso da terra em diferentes períodos. Permite ao operador estabelecer as variáveis independentes de entrada para o modelo, as variáveis explicativas, bem como o intervalo temporal desejado. Essa ferramenta apresenta conceitualmente os módulos ilustrados na Figura 7.

Figura 7 – Módulos do *plugin* MOLUSCE.

Fonte: Elaboração própria.

Conforme apresentado na Figura 7, as etapas metodológicas estabelecidas no *plugin* seguem uma ordem lógica de análise. Inicia-se pela consistência dos dados de entrada, passando à correlação das variáveis independentes, à geração do mapa de mudanças, à modelagem de transição e, por fim, à simulação e validação.

3.6 Entrada dos dados

As variáveis construídas para a estruturação do modelo de simulação foram selecionadas no módulo de entrada dos dados. Também foram carregados os arquivos inicial e final de uso e cobertura do solo, que serviram de base para a determinação da geometria de todos os arquivos de saída, tamanho do pixel, escala e projeção. Nesse ponto foram determinadas as datas para estruturação inicial do modelo, ou seja, as classificações de cobertura e uso e o respectivo período a ser analisado, bem como as variáveis que compõem o conjunto de dados independentes.

Os dados de entrada referentes às classificações de cobertura e uso, bem como os demais dados foram reamostrados para a resolução espacial de 25m por 25m, apresentando dimensões de 948 x 1116 (X, Y) pixels. Além disso, foram associados ao sistema geodésico de referência SIRGAS 2000 e projetados no sistema UTM (22S). Optou-se por utilizar essa resolução espacial por sua representatividade em relação aos lotes municipais, bem como às geometrias das quadras de maior parte do município, além disso de ser uma das dimensões das imagens classificadas originais.

Uma das variáveis explicativas do modelo é a própria imagem inicial. A entrada de dados no modelo se deu de forma sequencial, código sequencial, ou seja, as variáveis de entrada no modelo foram inseridas forma contínua no modelo, valor real do modelo, não foram realizados processos de classificação. Para realização do processo de obtenção do potencial de transição o próprio plugin MOLUSCE, realiza o escalonamento dos dados. são escalonados na entrada no modelo MOLUSCE.

3.7 Obtenção do potencial de transição

O potencial de transição obtido estabeleceu como se deu a mudança do espaço, isto é, consistiu em um conjunto de predições que definiram a mudança da paisagem. Tal definição foi a base para a realização de simulações de cenários futuros, que levaram à construção dos mapas preditivos, após realizar a calibração com a definição de regras de transição. Como demonstrado na Figura 7, o *plugin* MOLUSCE opera com quatro modelos para a geração de parâmetros de transição, sendo eles: Rede Neural Artificial (RNA), Avaliação Multicritério (MCE), Pesos de Evidência (WoE) e Regressão Logística (LR). Optou-se pelo algoritmo de aprendizagem de máquina

baseada em RNA, que definiu regras de transição para a modelagem da dinâmica espacial local.

Conforme apresentado nessa etapa, o modelo RNA-CA foi treinado, obtendo os parâmetros de transição para a simulação de cenários futuros da área de estudo. Dessa forma, tornou-se possível trabalhar com dados de interação complexa, realizando o mapeamento prospectivo de dados não lineares.

3.8 Validação do modelo e simulação da ocupação territorial

Partindo dos parâmetros estabelecidos na etapa de Modelagem do Potencial de Transição, realizou-se a simulação do modelo fazendo uso da propriedade dos Autômatos Celulares. O modelo de RNA-CA foi aplicado para simular o uso iminente da terra para os anos subsequentes, a partir do conjunto de dados preexistentes.

A partir do método de Autômatos Celulares o plugin MOLUSCE analisa os vizinhos com maior chance de transição e força que alteração ocorra de acordo com as regras de transição determinadas por meio das redes neurais. O método de simulação utilizada pelo software é determinístico, ou seja, o resultado apresentado para os mesmos dados de entrada será sempre igual.

Conforme demonstrado no fluxo da Figura 7, o módulo de simulação foi utilizado primeiramente para geração da classificação de uso e cobertura do solo para a última data existente, com entrada do resultado no módulo de validação. O modelo compilado foi implementado pela primeira vez, a fim de prever o uso da terra para o ano em que era possível realizar a validação, no caso 2020.

A imagem gerada foi analisada verificando a convergência entre os dados simulados e os da classificação original, para o ano em questão. Assim, realizou-se a avaliação da acurácia da imagem simulada, garantindo a aceitação dos resultados de previsão.

A validação é o procedimento que permite verificar a convergência entre um mapa simulado e um de referência para uma mesma data. Para validar os resultados, foram analisadas as classes inseridas nos mapas de cobertura do solo, verificando a precisão geral do mapa obtido, através da porcentagem de acerto e de fatores de precisão como o fator Kappa. Dentro do sistema integrado do *plugin* MOLUSCE, realizou-se a validação do mapa simulado, gerando o gráfico de validação e calculando a precisão geral do projeto simulado, bem como o fator Kappa do mesmo.

Uma vez validado o modelo, foi possível realizar a construção de mapas preditivos de uso e cobertura da terra.

4 RESULTADOS

No presente capítulo são apresentados os dados obtidos a partir das etapas descritas na metodologia. Inicialmente são apresentados os resultados preliminares, isto é, os produtos, imagens, que foram elaboradas para realizar a simulação de cenários para a área de estudo. Os resultados apresentados seguem a ordem que foram elaboradas para alimentar o *plugin* MOLUSCE, posteriormente são apresentados os resultados da operação do próprio *software*.

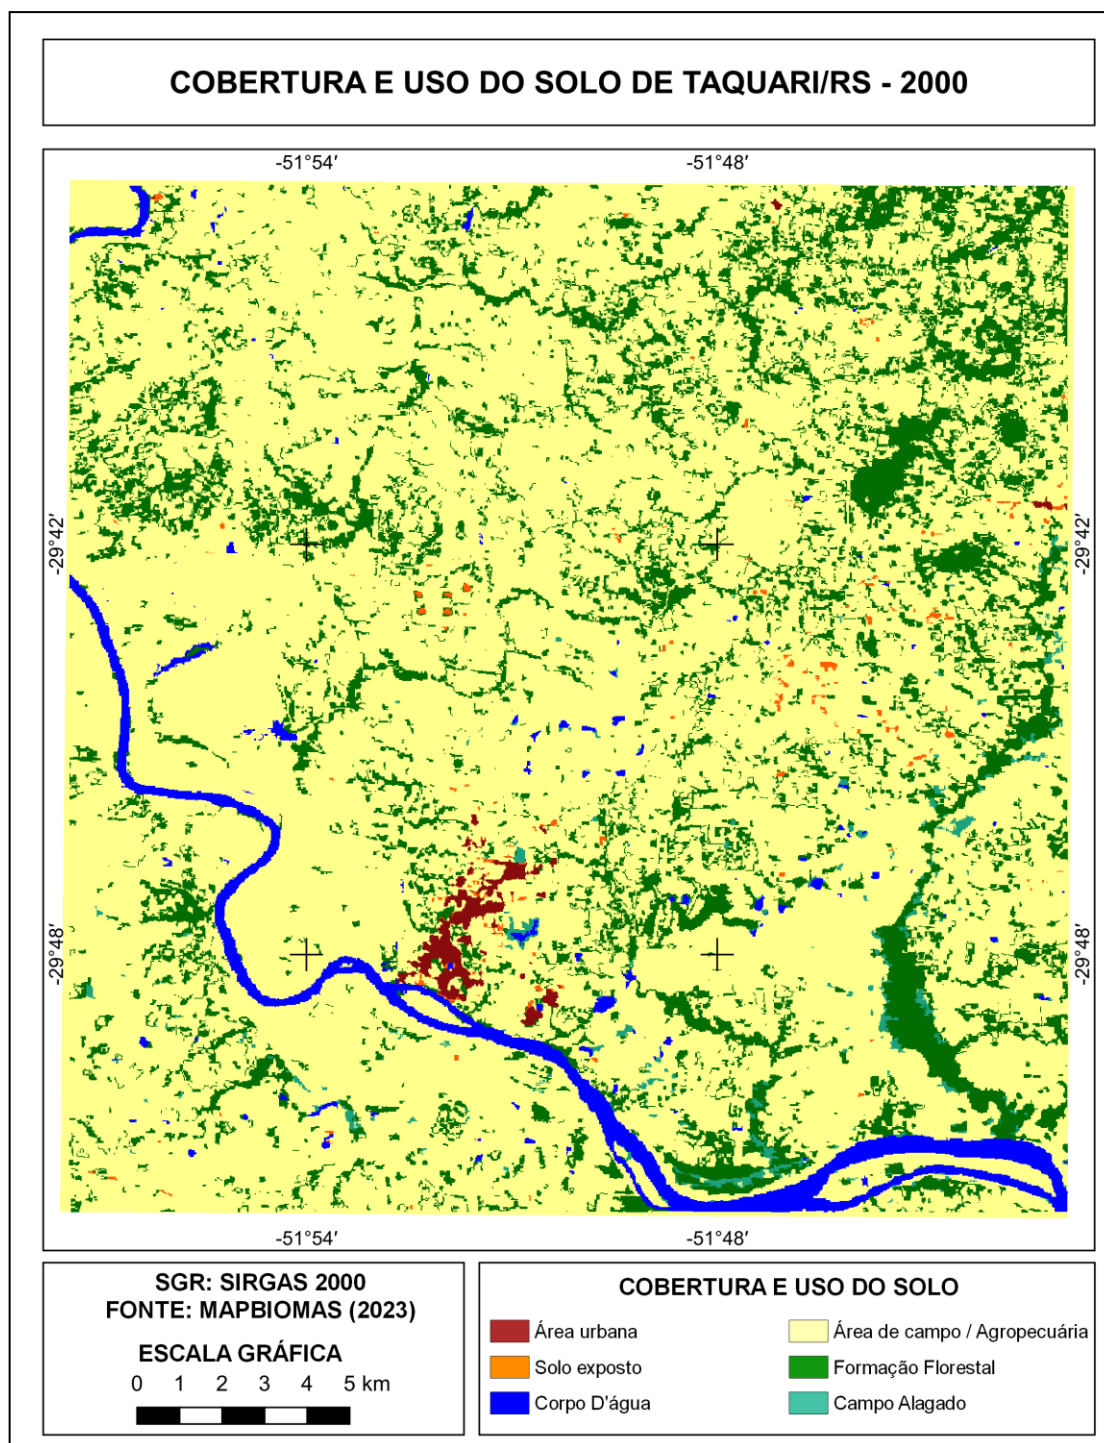
Ao executar os procedimentos descritos na metodologia foram geradas inicialmente imagens com as classes de cobertura e uso, as imagens foram reclassificadas e obtidas em intervalos de tempo regulares. Posteriormente foram elaboradas as imagens de entrada do modelo referentes as variáveis independentes. Para tanto foram utilizadas imagens da região estudada, bem como dos bancos de dados municipais e de plataformas disponíveis em sítios eletrônicos. Sendo assim, para realizar as etapas listadas foi necessário utilizar uma área de estudo da qual se dispunha dados e fosse possível realizar a metodologia descrita. Todos os softwares e dados utilizados na presente dissertação são disponibilizados de forma gratuita, exceção dada aos dados de avaliação em massa.

4.1 Imagens de uso e cobertura do solo reclassificadas

As classificações obtidas foram reamostradas para a resolução de 25m x 25m, menor distância de pixel apresentada pelas imagens originais. Esse procedimento foi adotado para convergência geométrica entre os dados de entrada do modelo, isto é, para que todas as bases presentes no estudo estejam com a mesma resolução e extensão espacial. Como resultado, obteve-se as imagens de 2000, 2010 e 2020 classificadas, ilustradas nas Figuras 8, 9 e 10, respectivamente.

A Figura 8 demonstra a região de Taquari, com o seu núcleo urbano principal localizado aproximadamente entre a latitude 29°47'S e a longitude 51°52'W. Nela é possível visualizar uma larga ocupação de áreas de campo ou cultiváveis, com baixa densidade urbana e alguns pontos de preservação de mata nativa (formação florestal).

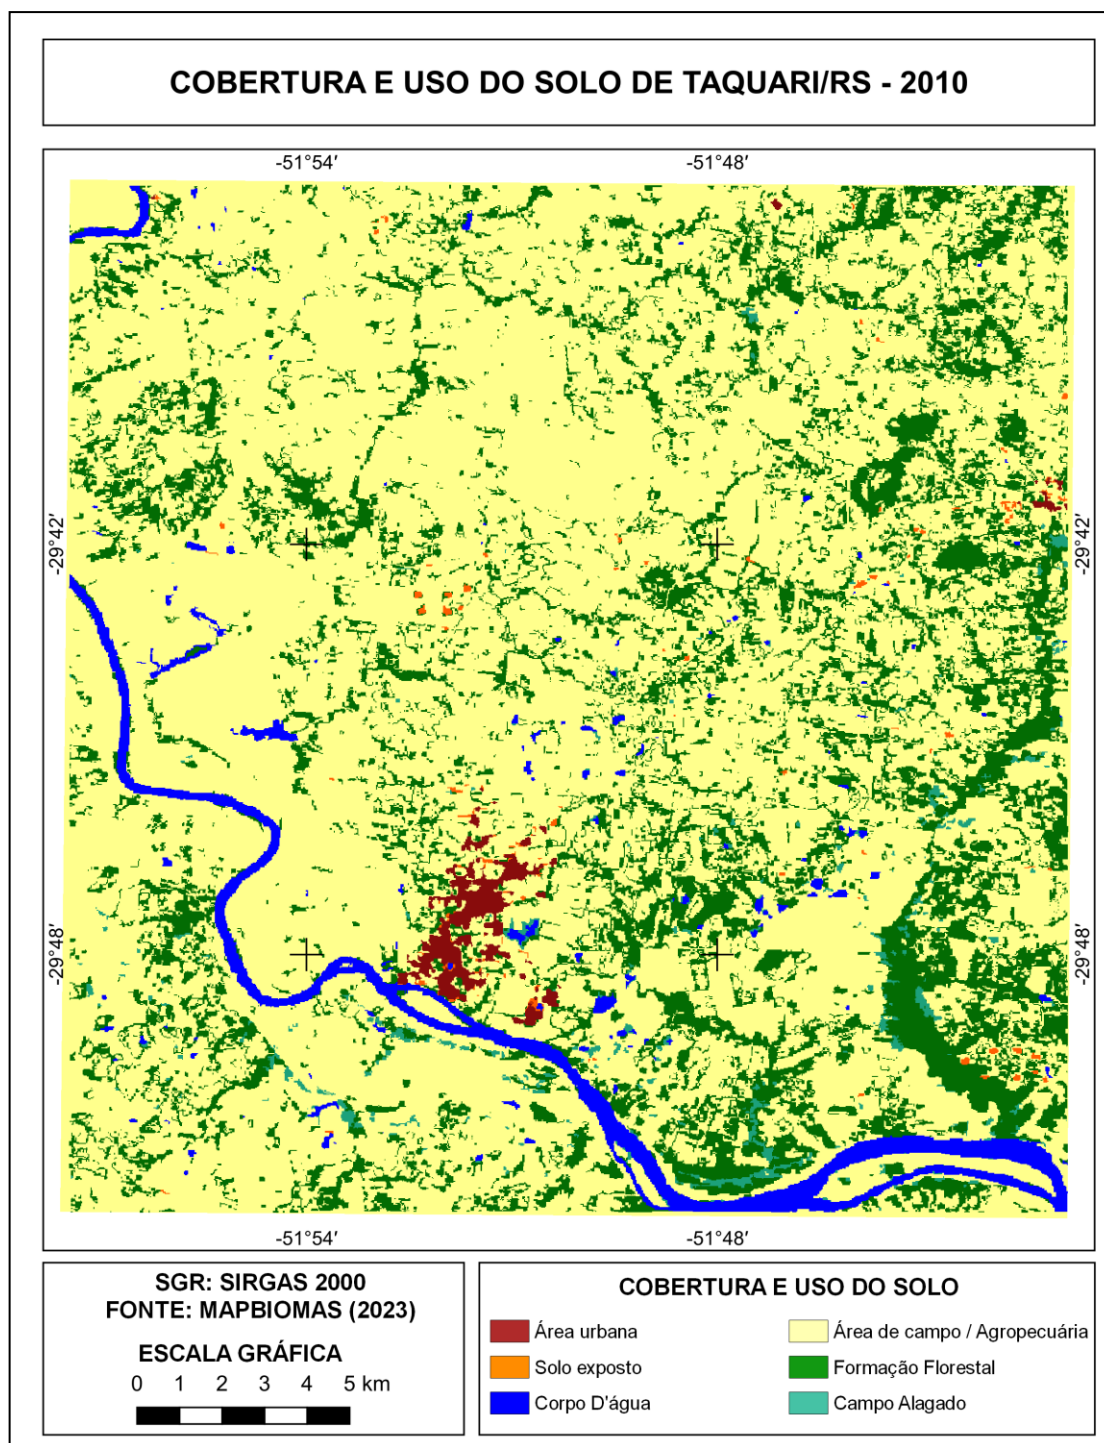
Figura 8 – Cobertura e Uso do Solo em 2000 – Taquari/RS



Fonte: Elaboração própria.

A Figura 9 demonstra a ocupação do espaço territorial em 2010, onde é possível verificar um leve aumento na região urbanizada, com a consolidação de núcleos urbanos mais afastados do Rio Taquari. A ocupação se manteve, de maneira geral, muito próxima da evidenciada 10 anos antes.

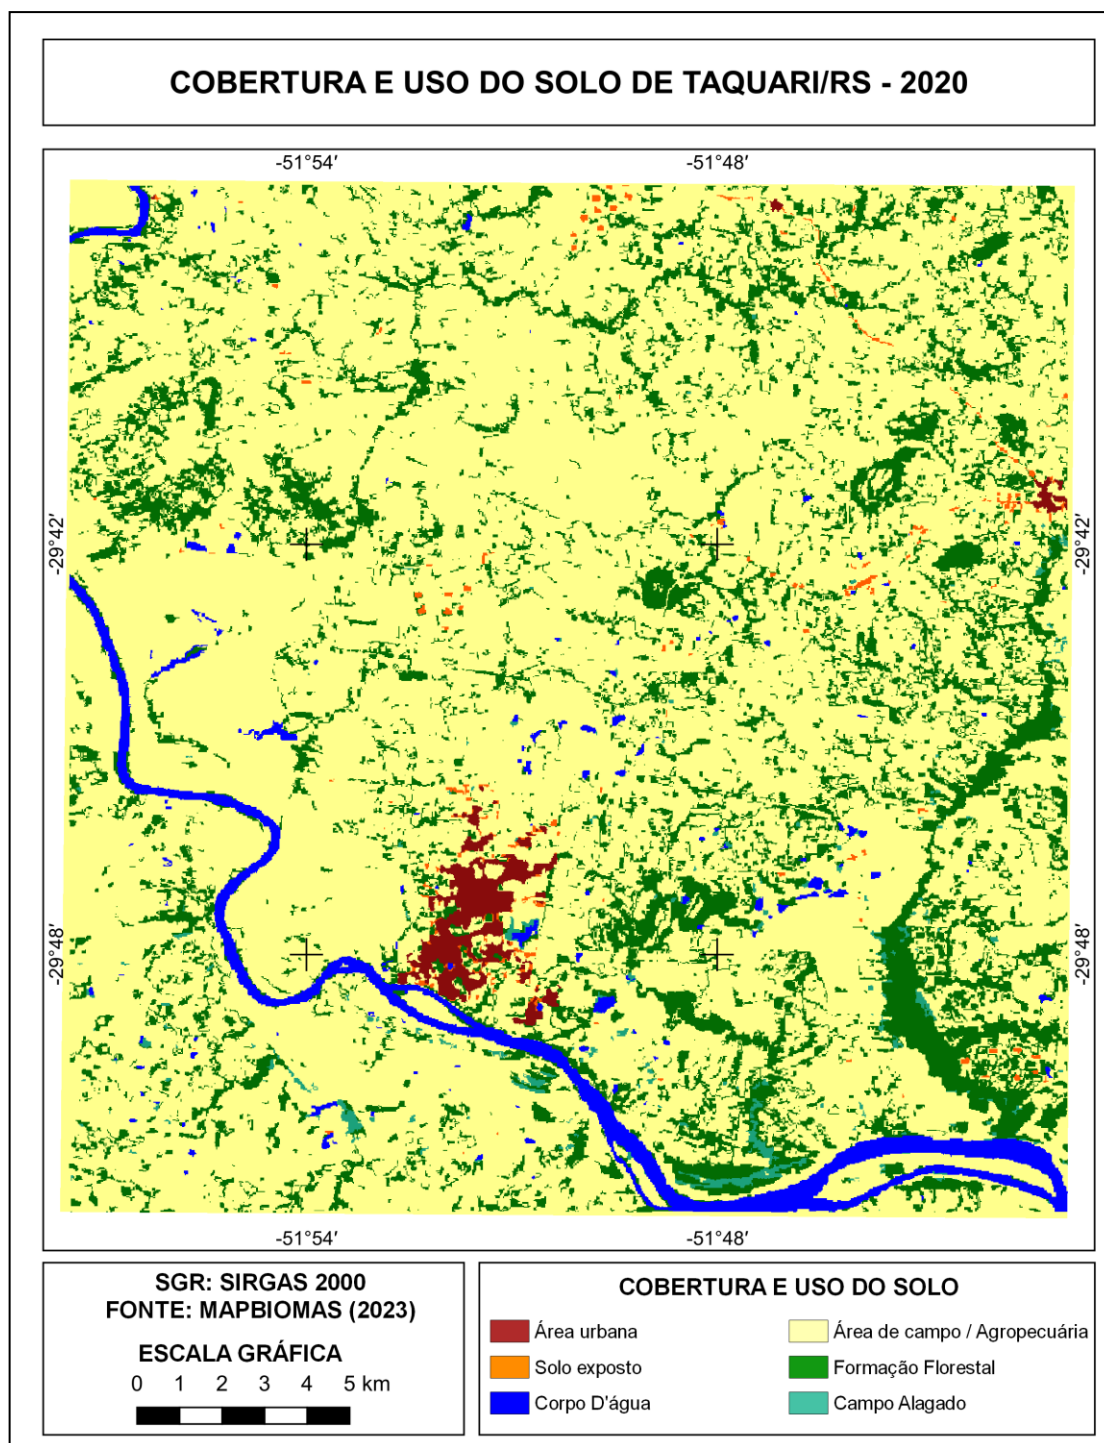
Figura 9 – Cobertura e Uso do Solo em 2010 – Taquari/RS



Fonte: Elaboração própria.

Na Figura 10 destaca-se a ocupação para o ano de 2020, dado mais recente estudado. Essa classificação serviu de base para a análise da convergência dos modelos gerados, apresentando ocupação do espaço muito semelhante às duas décadas anteriores.

Figura 10 – Cobertura e Uso do Solo em 2020 – Taquari/RS



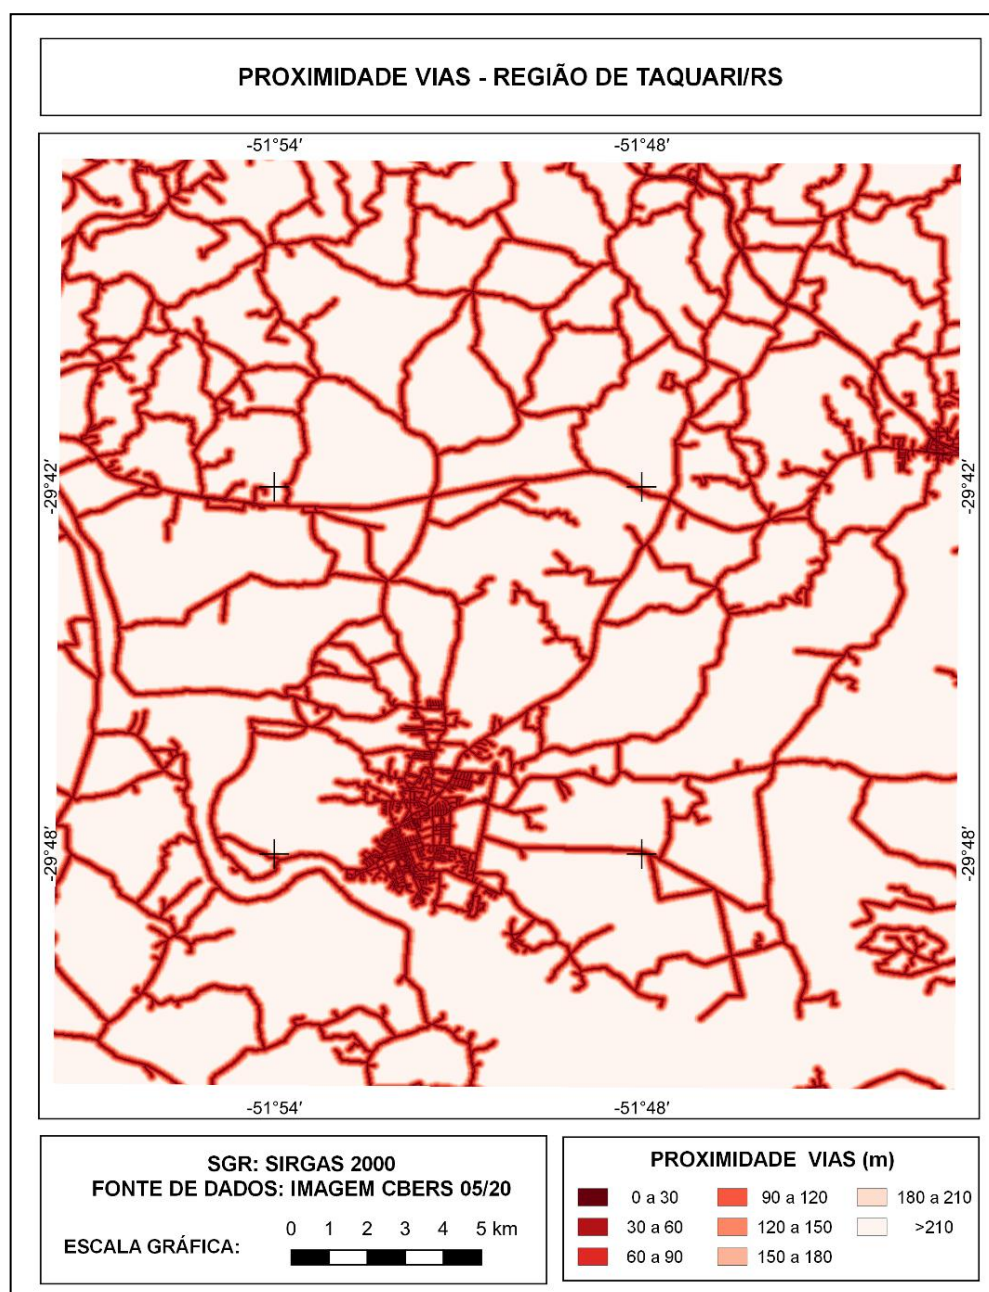
Fonte: Elaboração própria.

4.2 Base viária municipal

Com base nos mapas municipais, bem como nas feições vetorizadas a partir de uma cena da região, obtida pelo satélite CBERS-4 em 14 de março de 2020,

complementadas e avaliadas segundo bases digitais virtuais (*OpenStreetMap*), obteve-se a base viária municipal. Os dados vetoriais resultantes foram transformados no formato matricial (rasterizados). A Figura 11 exibe a proximidade às vias municipais.

Figura 11 – Proximidade a Vias – Taquari/RS.



Fonte: Elaboração própria.

A imagem foi construída para convergência e parametrização dos dados de entrada, calculando o valor de proximidade às vias. Sendo assim, o dado de entrada dessa variável foi um dado na estrutura matricial, com a representação da proximidade às rodovias municipais para a área de estudo.

A partir do procedimento apontado, o resultado foi uma imagem com resolução espacial de 25m, representando a proximidade (distância) para a infraestrutura viária. O produto, apresentado na Figura 11, demonstra uma maior concentração de vias próximo ao centro econômico municipal, junto à divisa sul, às margens do Rio Taquari, com demais eixos determinados pela extensão da rodovia RS-436 (Aleixo Rocha) e pelas vias de acesso locais.

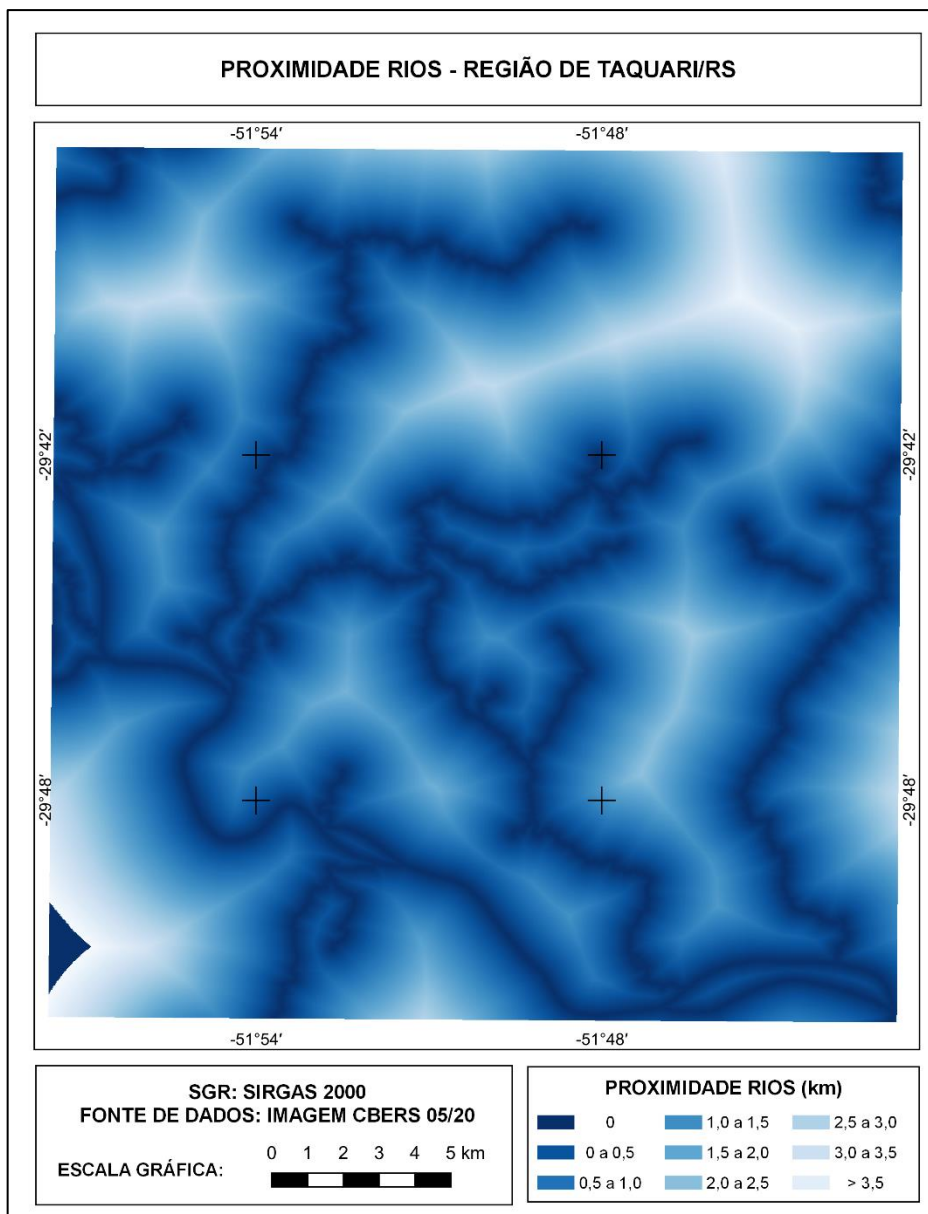
4.3 Base hidrográfica municipal

Com base nos mapas municipais, bem como nas feições vetorizadas a partir de uma cena da região, obtida pelo satélite CBERS-4 em 14 de março de 2020, complementadas e avaliadas segundo bases digitais municipais, realizou-se a construção da base de dados da hidrografia da região.

De maneira análoga ao realizado com as vias, inicialmente foram vetorizados os eixos dos cursos hídricos da região. A partir de procedimentos de buffer, com geração de uma base da distância aos rios. Os dados vetoriais resultantes foram transformados no formato matricial (rasterizados). Como resultado, demonstrado na Figura 12, foi gerada uma imagem da proximidade aos corpos hídricos municipais.

A imagem apresentada demonstra que grande parte da região estudada apresenta proximidade de regiões ribeirinhas. Essa característica destaca a origem da ocupação da região, com atividade econômica voltada a disponibilidade de recursos hídricos. Além disso, pode ajudar a entender as regiões onde a ocupação do solo é restrita, no que tangem questões políticas e ambientais.

Figura 12 – Proximidade a Vias – Taquari/RS.



Fonte: Elaboração própria.


4.4 Modelo Digital de Terreno

A partir dos modelos digitais do terreno da missão SRTM (*Shuttle Radar Topography Mission*), disponibilizados digitalmente na plataforma *Earth Data* da NASA, foram obtidos variáveis morfométricas presentes nos estudos realizados em modelagem espacial como variáveis de entrada relacionados à altimetria do município. A informação da altimetria está presente na maioria dos estudos

relacionados à dinâmica espacial, podendo ser inseridos de forma direta ou por meio de suas variáveis morfométricas.

No presente estudo, tendo como base a bibliografia apresentada, bem como as características da região estudada, optou-se por utilizar como variáveis independentes dados de declividade e sombreamento da região. As Figuras 13 e 14 representam, respectivamente, a declividade e o sombreamento da área de estudo, obtidas por ferramentas de geoprocessamento realizadas no *software* QGIS.


Figura 13 – Declividade – Taquari/RS.



Fonte: Elaboração própria.

Os pontos mais escuros da Figura 13 representam áreas de maior declividade (próxima a 40%). Conforme observado, a topografia da área de estudo é majoritariamente plana, principalmente nas regiões próximas ao Rio Taquari, apresentando poucas regiões declivosas. A área urbana de Taquari está localizada em uma região de terreno predominantemente plano, as demais áreas do município (planas e íngremes) são aproveitadas para atividades rurais ou de preservação.

Figura 14 – Sombreamento – Taquari/RS.



Fonte: Elaboração própria.

A Figura 14 mostra as regiões da área de estudo que recebem a maior iluminação, cores mais claras, bem como as mais sombreadas, cores mais escuras, em função do relevo local. Pela imagem é possível verificar as áreas de topo de morro, mais claras, bem como de fundos de vale, mais escuras.

4.5 Divisão de atividades espaciais

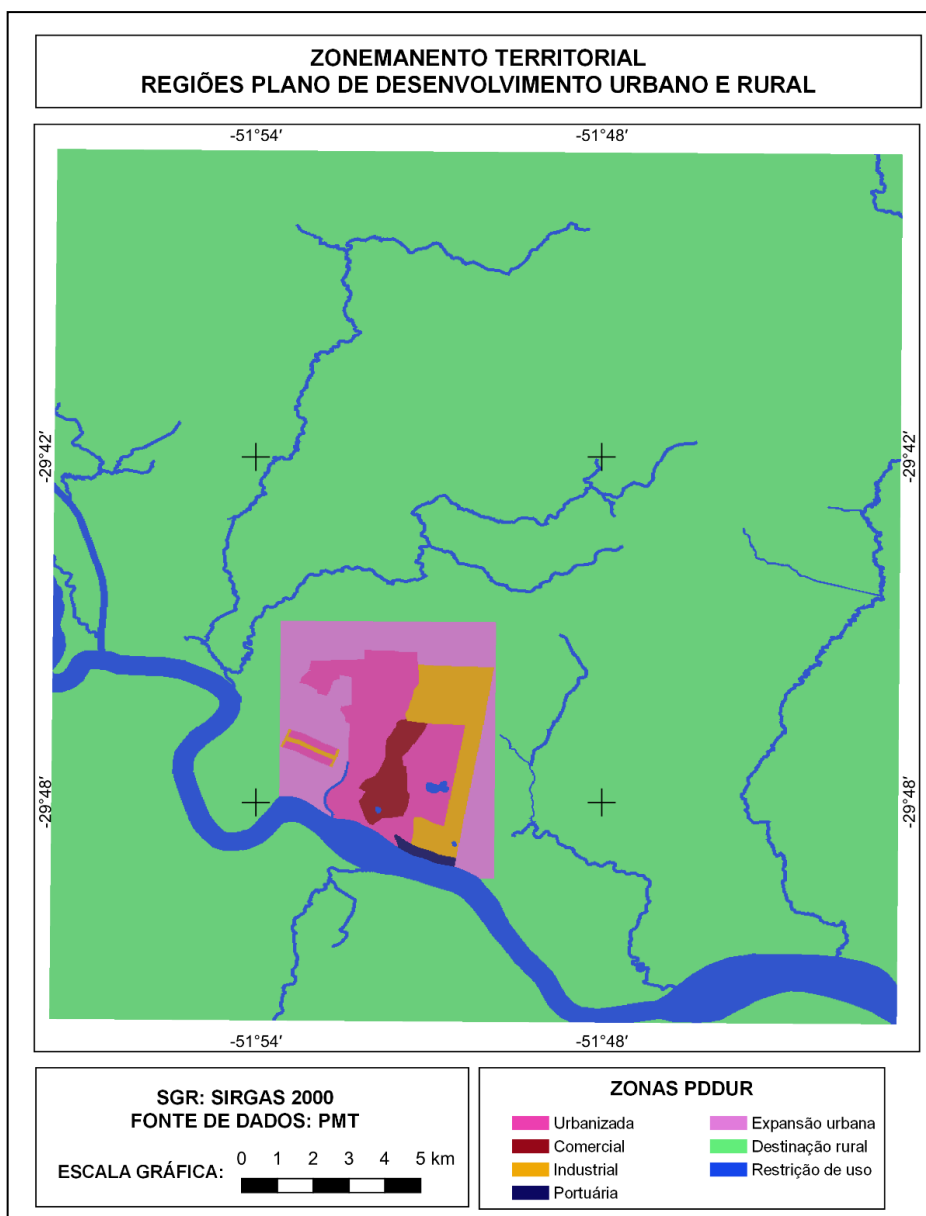
Parâmetro político apontado no Quadro 1, a divisão espacial de atividades apresenta o zoneamento municipal subdividido em áreas comerciais, residenciais, industriais, de expansão urbana e rurais. O produto cartográfico também localiza as áreas municipais onde não são permitidas ocupações, isto é, regiões que por questões naturais e/ou de política urbana, são destacadas como não urbanizáveis.

Tem origem no banco de Dados da Prefeitura Municipal de Taquari/RS (2023). É reflexo do planejamento urbano do município estando de acordo com a última revisão do Plano Diretor Municipal datado de 2015.

O zonamento territorial destaca a existência de grande porção do território destinada a exploração rural. Destaca a existência de um núcleo urbano consolidado com expansão urbana para suas regiões vizinhas e previsão de algumas áreas de exploração comercial, industrial e para atividade portuária.

A imagem com a divisão de áreas do Plano Diretor (Figura 15) foi derivada da base em formato digital vetorial (.dxf) e, para a elaboração da mesma, foi necessário realizar edições e conversões entre as geometrias (linhas para polígonos) e entre os formatos vetorial e matricial. Os dados de área de preservação permanente e demais áreas de restrição de uso do plano diretor foram agregados no mesmo produto.

Figura 15 – Áreas Conforme Plano Diretor Municipal – Taquari/RS.

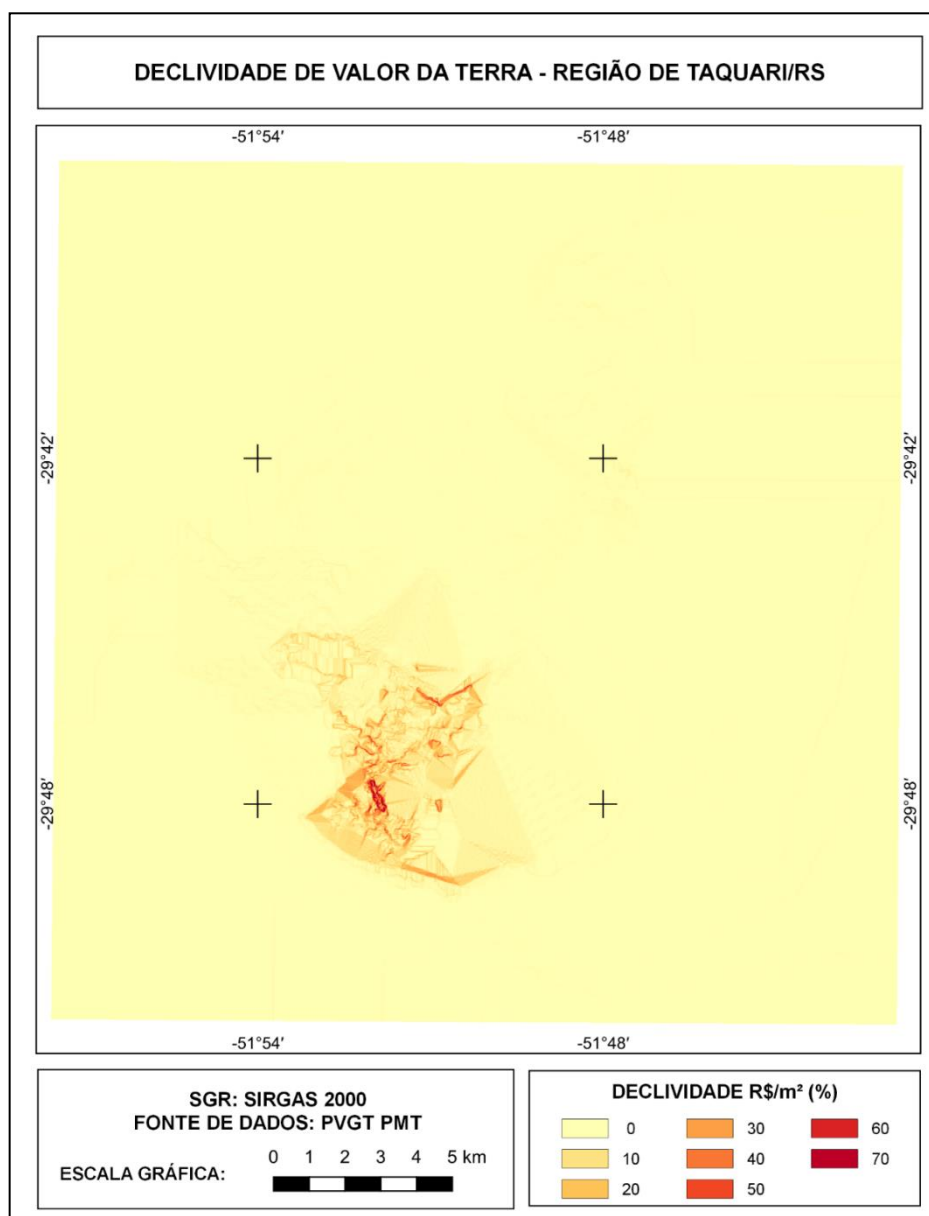


Fonte: Elaboração própria.

4.6 Base cartográfica de valores genéricos

Aprovada pela Assembleia Legislativa Municipal de Taquari, a Planta de Valores Genéricos Municipal foi elaborada seguindo os ritos da Norma Brasileira para Avaliação de Imóveis (NBR 14.653). A Figura 16, resultante da interpolação da declividade dos valores da terra, é o produto que aponta a declividade dos valores genéricos territoriais da região.

Figura 16 – Declividade de Valores Genéricos de Terrenos – Taquari/RS.



Fonte: Elaboração própria.

A planta de valores de terrenos, utilizada no presente estudo, foi realizada a partir da modelagem de valores obtidos através do Método Comparativo de Dados de Mercado. Para a realização deste método, é necessário o levantamento de informações de imóveis na proximidade do imóvel avaliado e, a partir de características semelhantes, estipular um valor condizente com o aplicado pelo mercado imobiliário. No caso das plantas de valores, avaliam-se imóveis de meia quadra, com condições referencias, isto é, que não depreciem o imóvel. Da mesma forma, procedeu-se a avaliação de imóveis rurais, complementando o banco de dados

municipais para a região rural e atribuindo valores comparativos para toda a área de estudo. Os valores tabulados foram inseridos na sua referida localização espacial e interpolados em uma superfície de valores municipais, método análogo ao Modelo Digital de Elevação. O dado de entrada nesse modelo representa a variação dos valores de mercado, isto é, a inclinação dos valores da terra para a região estudada.

4.7 Correlação das variáveis

Após inserir os dados no módulo de entrada, foram analisadas as correlações das variáveis independentes que compõem o modelo. No modelo é possível realizar a análise por três coeficientes de correlação, Pearson, Cramer ou da Incerteza de Informação Conjunta. Para o referido projeto, utilizou-se a correlação de Pearson, técnica adotada para verificar se duas variáveis estão relacionadas de maneira linear. Com isso, verificou-se a existência de variáveis altamente correlacionadas que poderiam condicionar o modelo.

Por se tratar de uma análise comparativa e buscando entender a relação e o incremento na modelagem do fator valor da terra, a modelagem do potencial de transição resultou em dois modelos. O primeiro modelo envolveu os impulsionadores do crescimento já descritos na bibliografia analisada e apresentou os resultados dessa análise; já o segundo, apresentou as características de uma regra de transição combinada, com incremento da influência dos dados referentes às variáveis econômicas. Sendo assim, na Tabela 1 é exposta a correlação das variáveis da simulação inicial (Simulação 1), sem o incremento de dados de valores de terrenos; já na Tabela 2, é mostrada a correlação obtida com a inserção dessa variável no modelo (Simulação 2).

Tabela 1 – Correlação das variáveis na Simulação 1.

	Prox. Rios	Plano Dir.	Prox. Vias	Decliv.	Sombr.
Prox. Rios	1	-0,066	-0,142	0,200	-0,009
Plano Dir.		1	0,197	0,125	-0,017
Prox. Vias			1	-0,062	-0,015
Decliv.				1	-0,218
Sombr.					1

Fonte: Elaboração própria.

Tabela 2 – Correlação das variáveis na Simulação 2.

	Prox. Rios	Plano Dir.	Prox. Vias	Decliv.	Sombr.	PVG
Prox. Rios	1	-0,066	-0,142	0,200	-0,009	-0,072
Plano Dir.		1	0,197	0,125	-0,017	-0,531
Prox. Vias			1	-0,062	-0,015	-0,122
Decliv.				1	-0,218	-0,033
Sombr.					1	0,008
PVG						1

Fonte: Elaboração própria.

Na Tabela 1 é possível verificar que as variáveis já consolidadas pela bibliografia apresentam baixa correlação. Fávero e Belfiore (2017) descrevem que quando duas variáveis explicativas são altamente correlacionadas, apresentando uma relação linear, elas se sobrepõem, desequilibram o modelo, apontando tendências muito semelhantes, efeito que pode ser reduzido com a utilização de RNA. Nesse sentido, variáveis com baixa correlação conseguem atender a necessidades e características distintas para explicação da variável dependente. Assim, mesmo variáveis que têm a mesma origem, como declividade e sombreamento, apresentaram baixa correlação. Quando do incremento da variável valor da terra, demonstrado na Tabela 2, verificou-se que o mesmo apresenta correlação com as áreas do Plano Diretor, o que já era esperado, tendo em vista que o valor da terra está diretamente vinculado às zonas determinadas politicamente pelo Plano Diretor Municipal.

4.8 Análise de variação de área

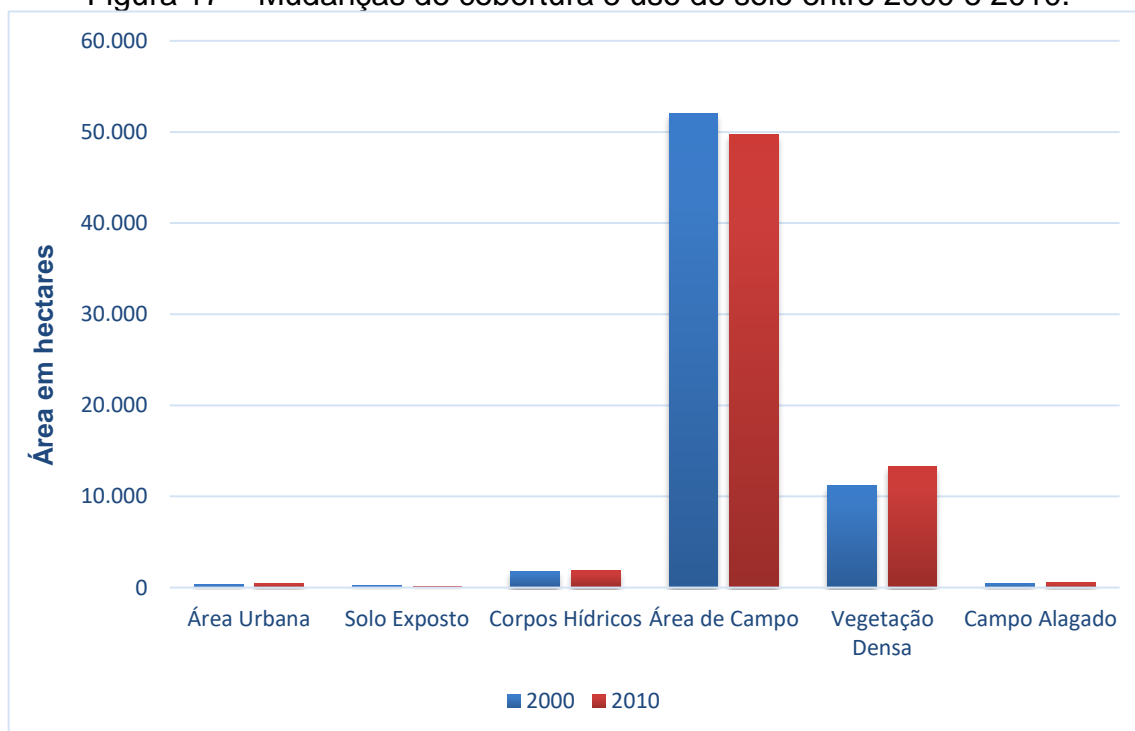
Nesse módulo foram analisadas as variações de classes de uso e cobertura do solo nos períodos do estudo. Inicialmente foram analisadas as modificações ocorridas entre os anos de 2000 e 2010. Nessa análise, foram computadas as diferenças entre o intervalo dado, analisando a diferença de área ocupada por classe de cobertura e uso do solo em hectares e em porcentagem, conforme dados expostos na Tabela 3 e na Figura 17.

Tabela 3 – Mudanças de cobertura e uso do solo entre 2000 e 2010.

	2000 ha	2010 ha	Δ ha	2000	2010	Δ
Área Urbana	337,88	485,00	147,12	0,51%	0,73%	0,22%
Solo Exposto	184,25	140,31	-43,94	0,28%	0,21%	-0,07%
Corpos Hídricos	1787,00	1868,12	81,12	2,71%	2,83%	0,12%
Área de Campo	52028,31	49717,38	-2310,93	78,84%	75,34%	-3,50%
Vegetação Densa	11222,25	13280,69	2058,44	17,00%	20,12%	3,12%
Campo Alagado	434,38	502,56	68,18	0,66%	0,76%	0,10%

Fonte: Elaboração própria.

Figura 17 – Mudanças de cobertura e uso do solo entre 2000 e 2010.



Fonte: Elaboração própria.

Conforme apresentado na Tabela 3 e na Figura 17, houve uma diminuição entre 2000 e 2010 das áreas de campo, com aumento de áreas de vegetação densa na região. Pela tabela, verificou-se o avanço da área urbana, com um aumento de 147,12 ha entre o período avaliado. A matriz de transição gerada aponta quantos pixels de uma classe migraram para outra classe, conforme Tabela 4.

Tabela 4 – Matriz de transição de classes de cobertura e uso do solo, 2000 x 2010.

	Área Urbana	Solo Exposto	Corpos Hídricos	Área de Campo	Vegetação Densa	Campo Alagado
Área Urbana	99,6%	0,2%	0,0%	0,1%	0,1%	0,0%
Solo Exposto	12,1%	29,9%	0,3%	46,5%	11,2%	0,1%
Corpos Hídricos	0,0%	0,0%	94,5%	3,5%	1,1%	0,8%
Área de Campo	0,2%	0,1%	0,3%	88,1%	10,9%	0,3%
Vegetação Densa	0,0%	0,1%	0,1%	32,4%	66,8%	0,6%
Campo Alagado	0,3%	0,1%	5,6%	19,1%	18,3%	56,6%

Fonte: Elaboração própria.

A Tabela 4 mostra que a transição mais expressiva foi das classes solo exposto e vegetação densa para áreas de campo. Uma das principais transições verificadas é a relação de troca, mudança entre classes, de campo para vegetação densa e vice-versa. Essa relação, bem como suas respectivas modificações percentuais, destaca que a maior parte do território analisado está sujeito a modificações espaciais entre as áreas de campo e de vegetação densa.

A classe solo exposto é a que apresentou menor constância, isto é, sua composição em 2010 está associada, em maior parte, a áreas que anteriormente eram da classe campo. A relação dada toma como base o referencial utilizado, as classes reamostradas para a elaboração das imagens de cobertura e uso do solo, mas é preciso destacar que a própria classificação está sujeita a erros de interpretação e ou classificação.

De maneira análoga, foram analisados os dados entre 2010 e 2020, sendo apresentadas as transições de classes na Tabela 5 e na Figura 18, bem como a matriz de transição na Tabela 6.


Tabela 5 – Mudanças de cobertura e uso do solo entre 2010 e 2020.

	2010 ha	2020 ha	Δ ha	2010	2020	Δ
Área Urbana	485,00	626,69	141,69	0,73%	0,95%	0,21%
Solo Exposto	140,31	245,81	105,50	0,21%	0,37%	0,16%
Corpos Hídricos	1868,12	1787,12	-81,00	2,83%	2,71%	-0,12%
Área de Campo	49717,38	51659,06	1941,68	75,34%	78,28%	2,94%
Vegetação Densa	13280,69	11295,19	-1985,50	20,12%	17,12%	-3,01%
Campo Alagado	502,56	380,19	-122,37	0,76%	0,58%	-0,19%

Fonte: Elaboração própria.

Ao analisar a Tabela 5, é perceptível o novo aumento da área urbana, em proporção parecida ao apontado entre 2000 e 2010. Entretanto, diferentemente do ocorrido na década anterior, nesse novo período há um aumento na área de campo e diminuição das áreas de vegetação densa. Outro fato interessante destacado é o aumento de solo exposto no período, o que deve refletir, conforme evidência anteriores, no aumento da urbanização local.

Figura 18 – Mudanças de cobertura e uso do solo entre 2010 x 2020.



Fonte: Elaboração própria.

Na Figura 18 verifica-se como ainda é significativa, proporcionalmente, a área de campo em relação às demais classes. A partir das Figuras 17 e 18, percebe-se o aumento de áreas urbanas e solo exposto. No entanto, também é possível destacar como as mesmas são pouco significativas na área de estudo como um todo. A Tabela 6 apresenta dados de transição de uso e cobertura do solo, no período entre 2010 e 2020.

Tabela 6 – Matriz de transição de classes de cobertura e uso do solo, 2010 x 2020.

	Área Urbana	Solo Exposto	Corpos Hídricos	Área de Campo	Vegetação Densa	Campo Alagado
Área Urbana	99,5%	0,1%	0,0%	0,3%	0,1%	0,0%
Solo Exposto	13,5%	55,5%	0,7%	26,9%	3,3%	0,0%
Corpos Hídricos	0,0%	0,0%	91,0%	6,3%	1,4%	1,2%
Área de Campo	0,2%	0,3%	0,1%	93,6%	5,6%	0,1%
Vegetação Densa	0,1%	0,1%	0,1%	36,3%	63,1%	0,4%
Campo Alagado	0,0%	0,1%	3,1%	29,7%	19,0%	48,0%

Fonte: Elaboração própria.

Na Tabela 6 é possível verificar a conversão de áreas de campo em solo exposto, bem como a transição de 36,3% de área de vegetação densa em áreas de campo. Destaque dado à proporção, uma vez que os 5,6% de área de vegetação densa que se tornaram áreas de campo representam 2.892,91ha, mais do que os 26,9% de área de campo que viraram solo exposto, o que corresponde a 66,12ha.

4.9 Análise comparativa dos dados

Com base nos produtos das simulações realizadas, foram analisadas as diferenças entre os produtos das duas simulações. Numa análise de dados direta, de acordo com o realizado no módulo de transição, avaliou-se a capacidade de acerto

por classe de cada uma das simulações. Sendo assim, a Tabela 7 apresenta a área em hectares de acerto por classe da Simulação 1.

Tabela 7 – Análise comparativa da Simulação 1 e classificação de referência 2020.

Classes	2020 (ha)	SIM1(ha)	Diferença(ha)	AC
Área Urbana	626,69	481,88	144,81	76,89%
Solo Exposto	245,81	137,12	108,69	55,78%
Corpos Hídricos	1787,12	1857,88	-70,76	96,19%
Área de Campo	51659,06	51279,50	379,56	99,27%
Vegetação Densa	11295,19	11747,06	-451,87	96,15%
Campo Alagado	380,19	490,62	-110,43	77,49%

Fonte: Elaboração própria.

Na Tabela 8 a mesma análise foi realizada, com inserção de dados referentes ao valor da terra, observando o retorno da Simulação 2.

Tabela 8 – Análise comparativa da Simulação 2 e classificação de referência 2020.

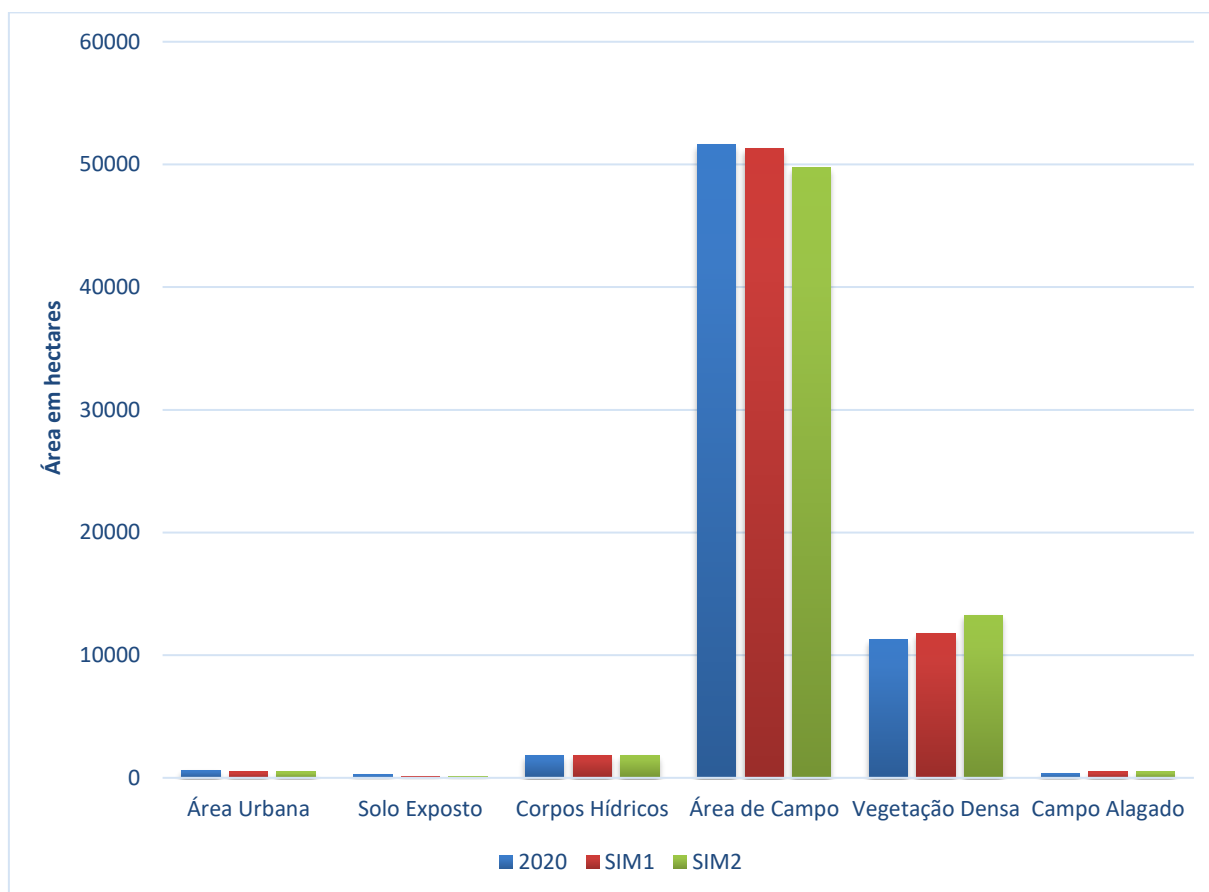
Classes	2020 (ha)	SIM2 (ha)	Diferença (ha)	AC. %
Área Urbana	626,69	484,19	142,50	77,26%
Solo Exposto	245,81	140,31	105,50	57,08%
Corpos Hídricos	1787,12	1842,38	-55,26	97,00%
Área de Campo	51659,06	49771,00	1888,06	96,35%
Vegetação Densa	11295,19	13256,69	-1961,50	85,20%
Campo Alagado	380,19	499,49	-119,30	76,12%

Fonte: Elaboração própria.

Através do módulo de validação foi observado que os resultados apresentados na Simulação 2, com inserção do valor da terra, apresentou melhora em relação aos valores obtidos pela Simulação 1. Não houve melhora significativa do modelo, entretanto os padrões de validação apresentaram melhor resultado com a inserção da variável econômica.

Verificou-se na comparação realizada, que houve uma melhora na análise das classes de menor ocorrência, tais como áreas urbanizadas e solo exposto. No entanto, no que diz respeito às análises de área de campo e vegetação densa, o valor da terra levou a uma diminuição da porcentagem de acerto. Nesse sentido, a Figura 19 traz um panorama das diferenças apontadas.

Figura 19 – Comparação de dados simulados com a referência.



Fonte: Elaboração própria.

Para as simulações subsequentes, espaçadas de 10 em 10 anos verificou-se a manutenção das diferenças entre classes, com pouca diferença em área e, conseqüentemente, em participação percentual. Tal relação se manteve para ambas as simulações, levando a resultados muito semelhantes entre os casos estudados. As Tabelas 9 e 10 trazem a relação evolutiva para os anos de 2030 e 2040.

Tabela 9 – Dados simulados para 2030 e 2040 – Simulação 1.

Classes	2030			2040		
	ha	Δ	Part.	ha	Δ	Part.
Área Urbana	481,88	-144,81	0,73%	481,88	0	0,73%
Solo Exposto	137	-108,81	0,21%	137	0	0,21%
Corpos Hídricos	1856,88	69,76	2,81%	1856,19	-0,69	2,81%
Área de Campo	51331,81	-327,25	77,78%	51346,99	15,18	77,81%
Vegetação Densa	11696,69	401,5	17,72%	11682,62	-14,07	17,70%
Campo Alagado	489,8	109,61	0,74%	489,38	-0,42	0,74%
TOTAL	65994,06		100,00%	65994,06		100,00%

Fonte: Elaboração própria.

Tabela 10 – Dados simulados para 2030 e 2040 – Simulação 2.

Classes	2030			2040		
	ha	Δ	Part.	ha	Δ	Part.
Área Urbana	484,06	-142,6	0,73%	484	-0,06	0,73%
Solo Exposto	140,31	-105,5	0,21%	140,31	0	0,21%
Corpos Hídricos	1836,19	49,07	2,78%	1832,5	-3,69	2,78%
Área de Campo	49785,44	-1874	75,44%	49792,31	6,87	75,45%
Vegetação Densa	13249,12	1953,9	20,08%	13246,25	-2,87	20,07%
Campo Alagado	498,94	118,75	0,76%	498,69	-0,25	0,76%
TOTAL	65994,06		100,00%	65994,06		100,00%

Fonte: Elaboração própria.

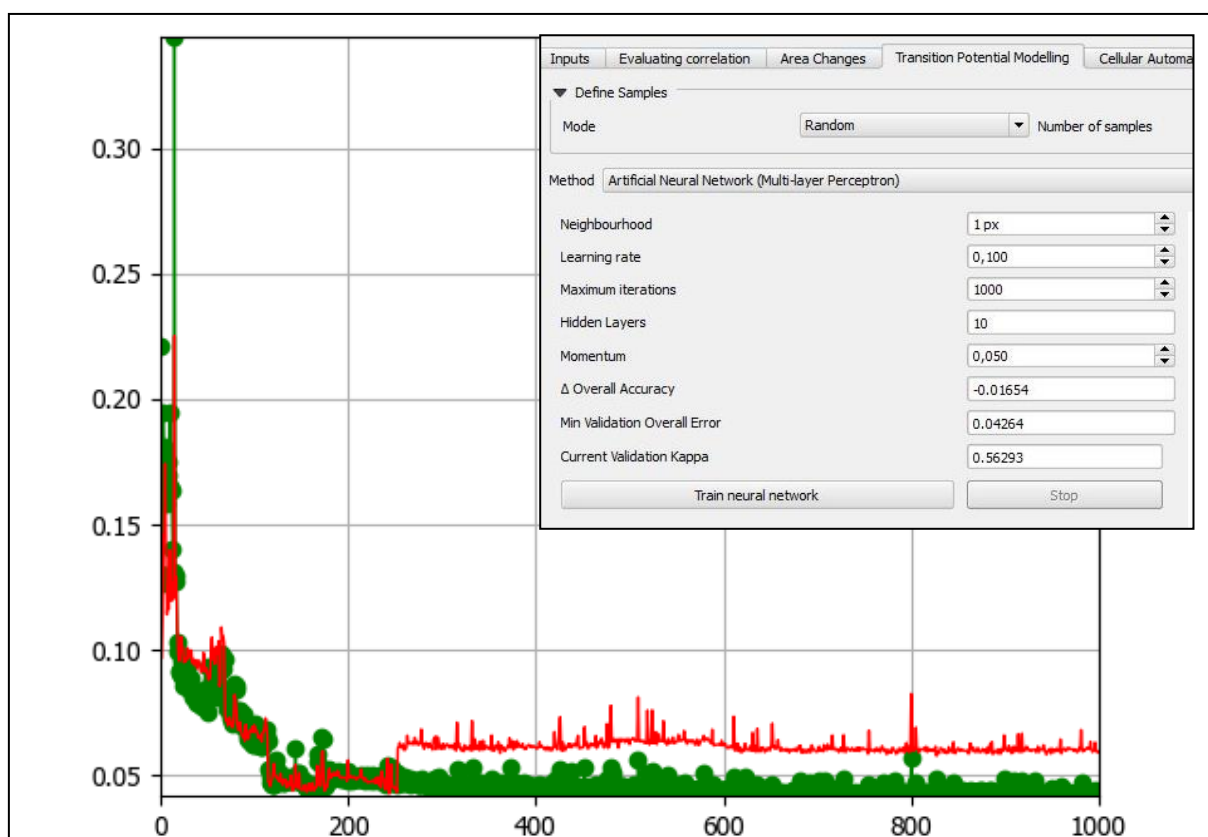
Com o passar das décadas, as tendências simuladas da área de estudo apontam para uma estabilidade do local, ou seja, para a preservação das classes atuais de cada região. Essa conclusão está baseada na baixa redução ou aumento da cobertura das classes no local com o passar das décadas. Nesse sentido, com o passar dos anos, pode-se afirmar que será necessário o acontecimento de algum

evento externo que impulsiona alguma das atividades, pois, caso contrário, de acordo com as simulações realizadas, não haverá significativas modificações no cenário atual do município.

Grande parte da cobertura atual se dá por vegetação e áreas de cultivo agrícola. A tendência é que as mesmas atividades continuem presentes, representando juntas aproximadamente 95% da ocupação local. Nesse sentido, o avanço da urbanização no cenário do município como um todo apresenta baixa representação, menor que 1%.

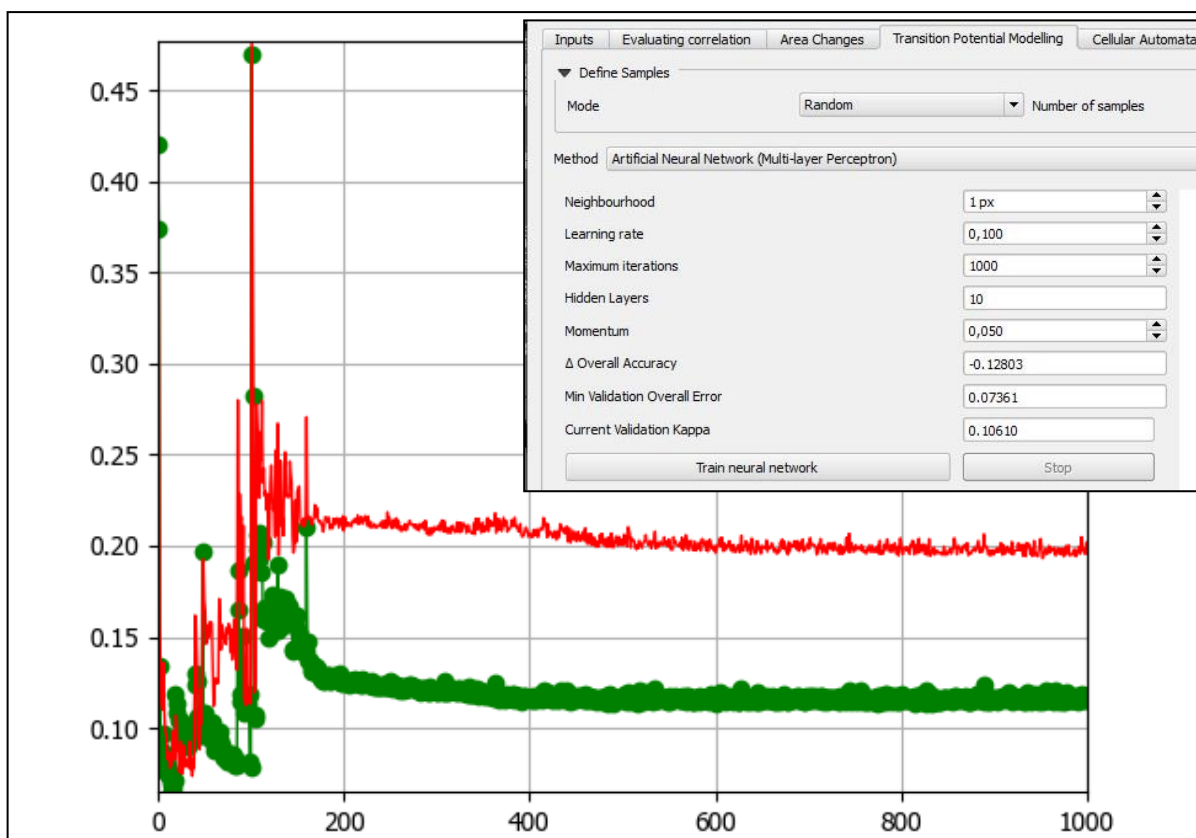
O modelo obtido foi o resultado de um número definido de camadas, neurônios e interações, que resultou na melhor precisão para o cenário estudado. A Figura 20 demonstra o treinamento realizado para a Simulação 1 e a Figura 21, para a Simulação 2.

Figura 20 – Treinamento RNA na Simulação 1.



Fonte: Elaboração própria.

Figura 21 – Treinamento RNA na Simulação 2.




Fonte: Elaboração própria.

Nesse processo, cinco definições básicas são solicitadas pelo programa. Primeiramente, define-se a vizinhança, isto é, a quantidade de pixels vizinhos ao pixel que será analisado na transição. No caso deste estudo foi utilizada a opção de tamanho 1, ou seja, a análise de vizinhança de 3 x 3 pixels. Posteriormente, foram definidas as taxas de aprendizagem, o momento e o número de interações realizadas pelo *plugin* para retornar com a simulação. Neste trabalho, foi adotada uma taxa de aprendizado de 0,10, com momento de 0,05 e 1000 iterações, para possibilitar a convergência do modelo. Os parâmetros utilizados foram os pré-definidos pelo *plugin* MOLUSCE, com valores determinados para atender a uma taxa de aprendizagem estável, com uma relativa margem para interação. Por fim, definiu-se o número de camadas ocultas do processamento, após testes iniciais, optou-se por utilizar 10 camadas ocultas. Em ambos os casos, Simulações 1 e 2, foram utilizados os mesmos parâmetros, possibilitando a análise da hipótese inicial.

Após validar o resultado, tornou-se possível gerar as classificações de cobertura e uso para as décadas posteriores. O módulo de simulação gerou a imagem simulada em intervalos de tempo igualmente espaçados, iguais aos previamente estabelecidos. Foram geradas imagens espaçadas em dez anos a partir da última imagem classificada, ou seja, a primeira imagem obtida, figura 22, foi a classificação simulada para 2020, que foi validada no modelo.


Figura 22 – Simulação 1 para 2020 – Taquari/RS.



Fonte: Elaboração própria.

O resultado apresentado na Figura 22 é a entrada do módulo de validação e foi comparado à classificação apresentada na Figura 10. A mesma metodologia foi aplicada para o modelo incrementado com o valor da terra, a Simulação 2 é apresentada na Figura 23.

Figura 23 – Simulação 2 para 2020 – Taquari/RS.




Fonte: Elaboração própria.

As imagens classificadas de 2030 e 2040 equivalem ao intervalo 2 e 3, respectivamente, e foram geradas após a validação do modelo. Verificou-se visualmente, comparando as Figuras 22 e 23, resultados muito semelhantes para ambos os modelos obtidos. Alguns pontos de concentração de solo exposto e ocupação urbana presentes na imagem simulada do primeiro modelo não estão presentes na segunda simulação. No entanto, numa comparação direta, os modelos apresentaram, num panorama geral, resultados convergentes, que foram validados no módulo seguinte do *plugin*.

4.10 Validação da simulação

A validação realizada para a simulação inicial alcançou uma precisão geral do modelo equivalente a 86,51%, com fator Kappa geral de 0,625. Os resultados apresentaram em sua maior parte boa localização, com média qualidade de informação, atingindo em certos pontos um fator Kappa de 0,643. A Figura 24 mostra o gráfico de validação da simulação realizada com os dados da Simulação 1, que resultou nos parâmetros apontados.

Figura 24 – Gráfico de validação da Simulação 1.

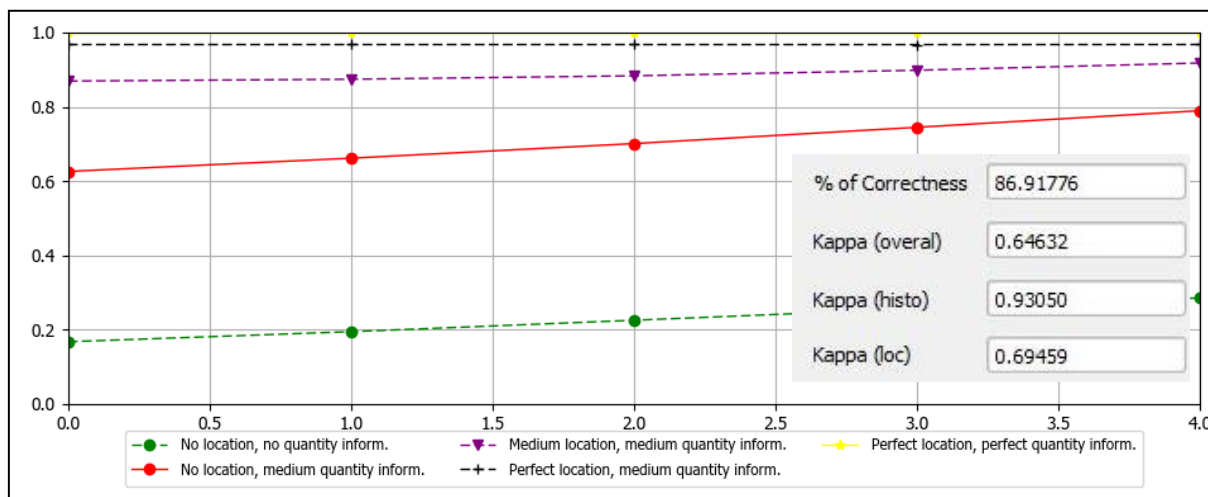


Fonte: Elaboração própria.

Da mesma forma, foi realizada a validação do modelo com os dados de valor da terra. Nessa segunda etapa, alcançou-se um aumento da precisão geral do modelo para um valor equivalente a 86,93%, com fator Kappa geral de 0,651. A Figura 25, de

maneira análoga, mostra os resultados da validação para a Simulação 2, com a inserção do parâmetro valor da terra.

Figura 25– Gráfico de validação da Simulação 2.



Fonte: Elaboração própria.

Conforme verificado, houve leve variação dos parâmetros de precisão apresentados pelo *plugin*. O resultado do gráfico para ambas as classificações apresentou significativa semelhança. Na segunda simulação, o fator Kappa alcançou resultados de 0,695, em alguns locais, o que destaca a melhora do modelo com a inserção do fator econômico estudado.

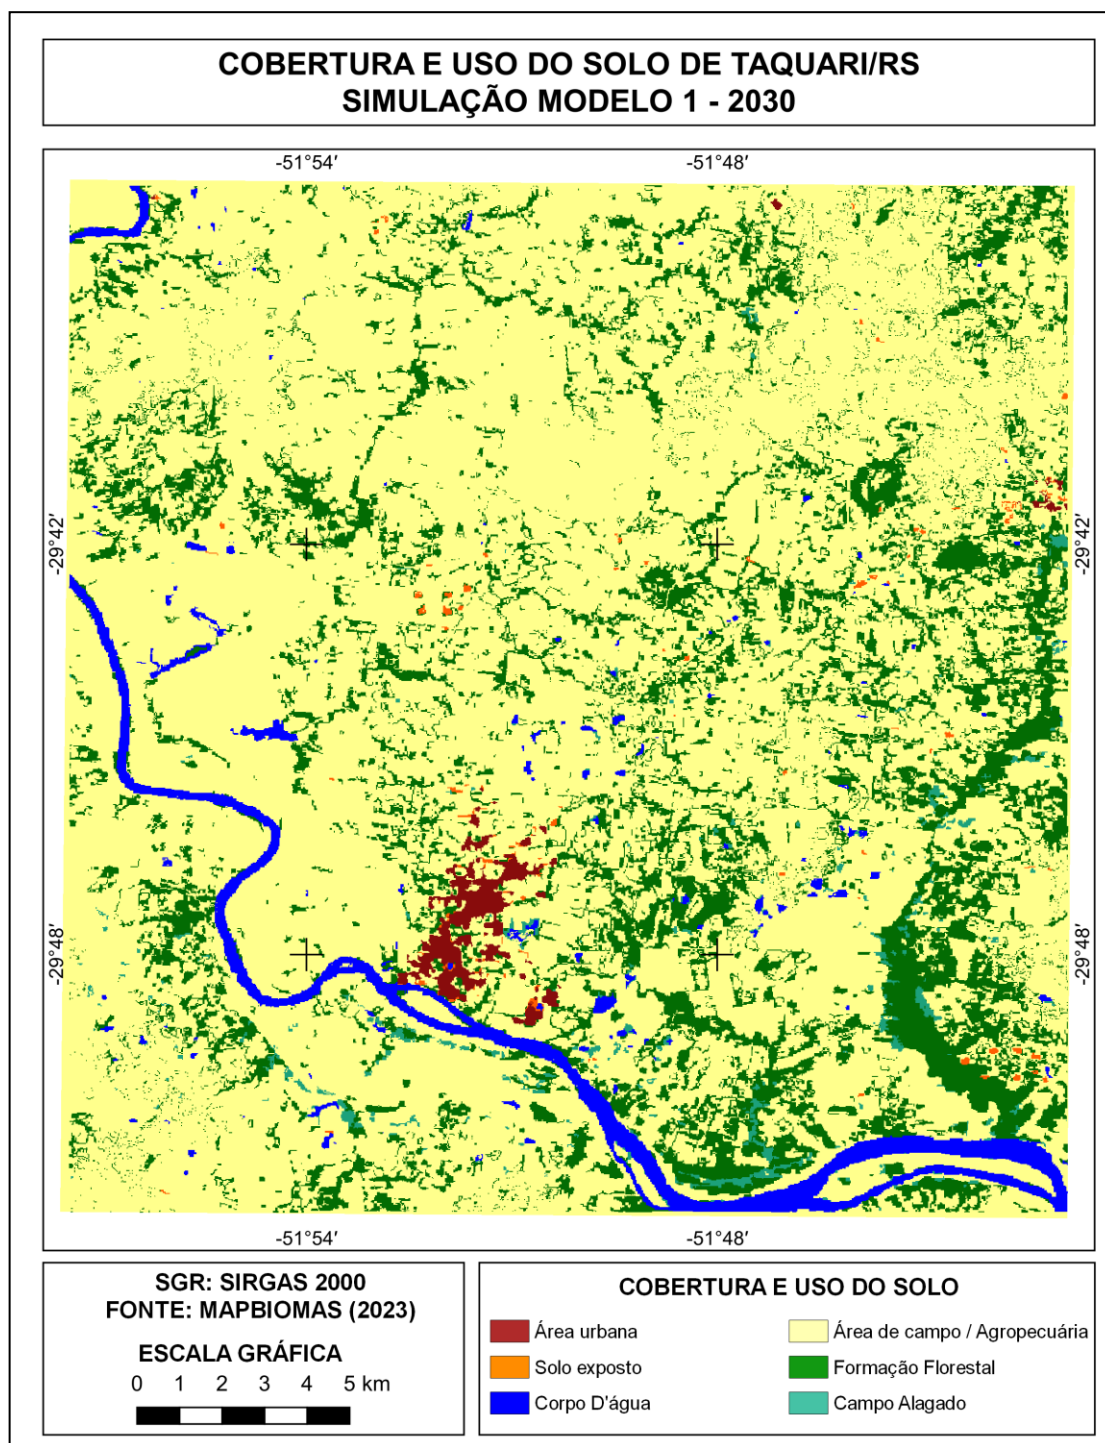
Para a região estudada realizou-se teste de persistência, isto é, foi adotado que a situação atual permaneceria inalterada na década subsequente. Assim sendo, de acordo com a validação adotada, sugeriu-se que o cenário em 2020 seria o mesmo de 2010. Neste caso, obteve-se para precisão geral um valor equivalente a 86,99%, com fator Kappa geral de 0,653. Fica evidente com tal consideração que não ocorrem modificações significativas no cenário da área de estudo em décadas subsequentes, a menos da ocorrência de um fenômeno externo que modifique drasticamente a região ou um local dela.

4.11 Dados simulados 2030 e 2040

Uma vez validado o modelo e analisada a convergência entre os dados simulados em comparação com o dado referência, realizou-se a simulação de

cobertura e uso da região estudada. Nessa etapa, no sistema integrado do *plugin* MOLUSCE, foram simulados os cenários futuros para os anos sequenciais de 2030 e 2040. A partir da Simulação 1, obteve-se para 2030 o resultado demonstrado na Figura 26 e para 2040, o apresentado na Figura 27.

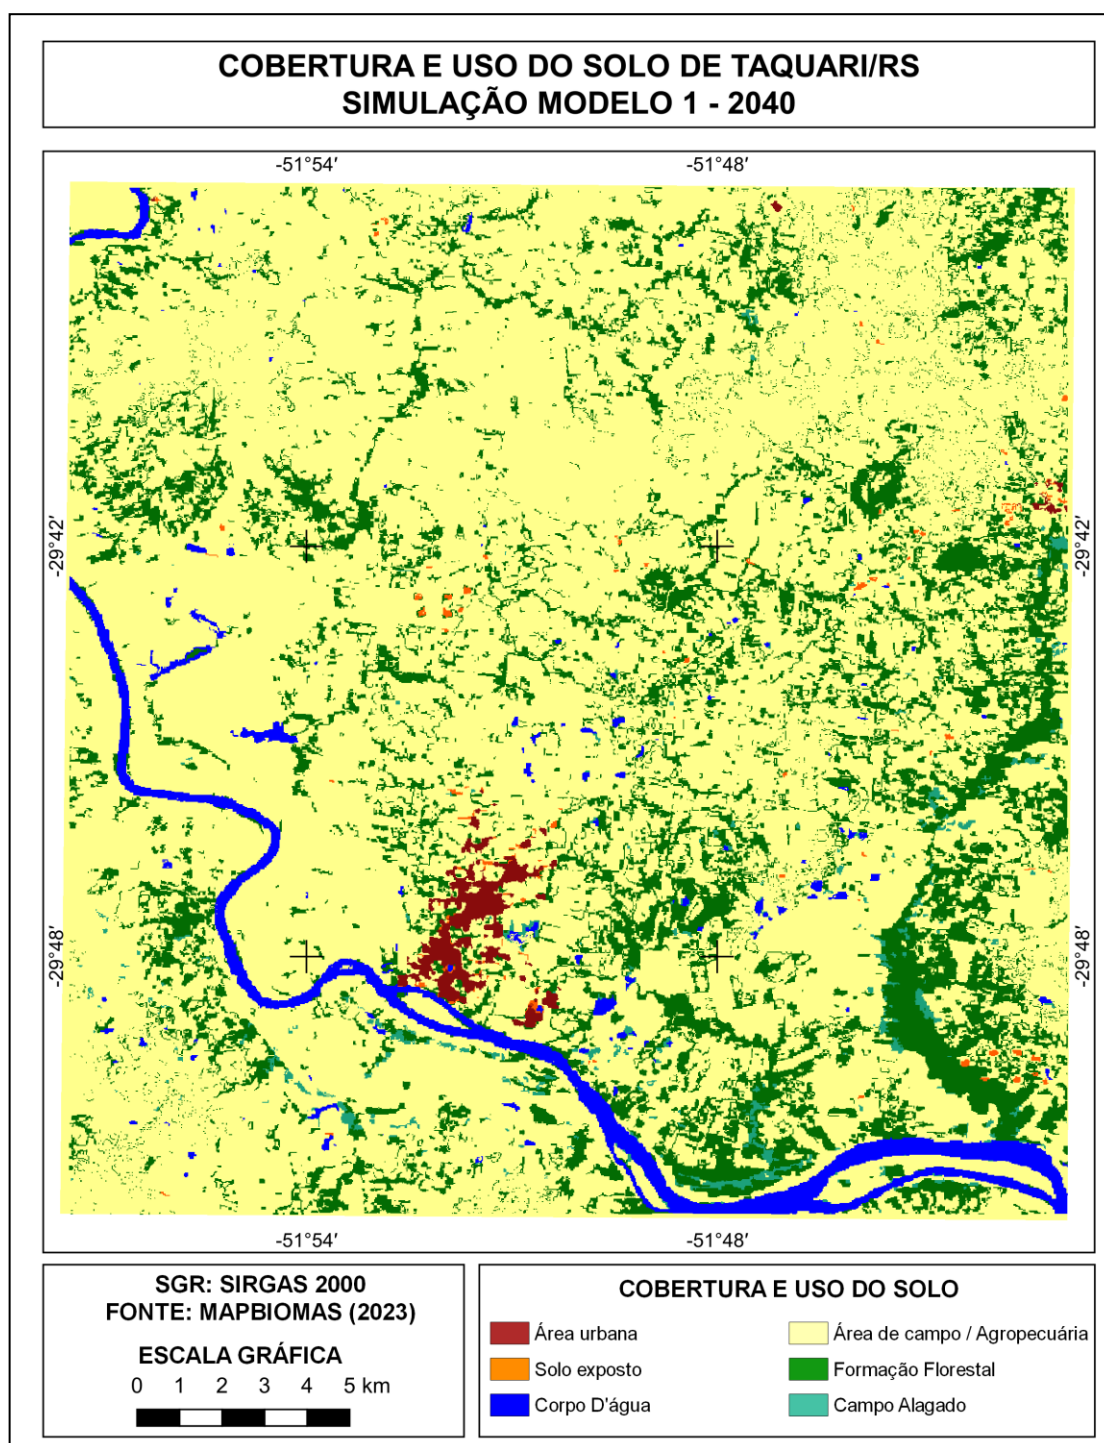
Figura 26 – Simulação 1 para 2030 – Taquari/RS.



Fonte: Elaboração própria.

A Figura 26 mostra a previsão de desaceleração do crescimento urbano municipal, bem como a estabilização das classes de cobertura e uso, de acordo com as classes da década anterior. A simulação para 2040 (Figura 27), aponta para a previsão de estabilidade ocupacional, com leves diferenças das classes estudadas.

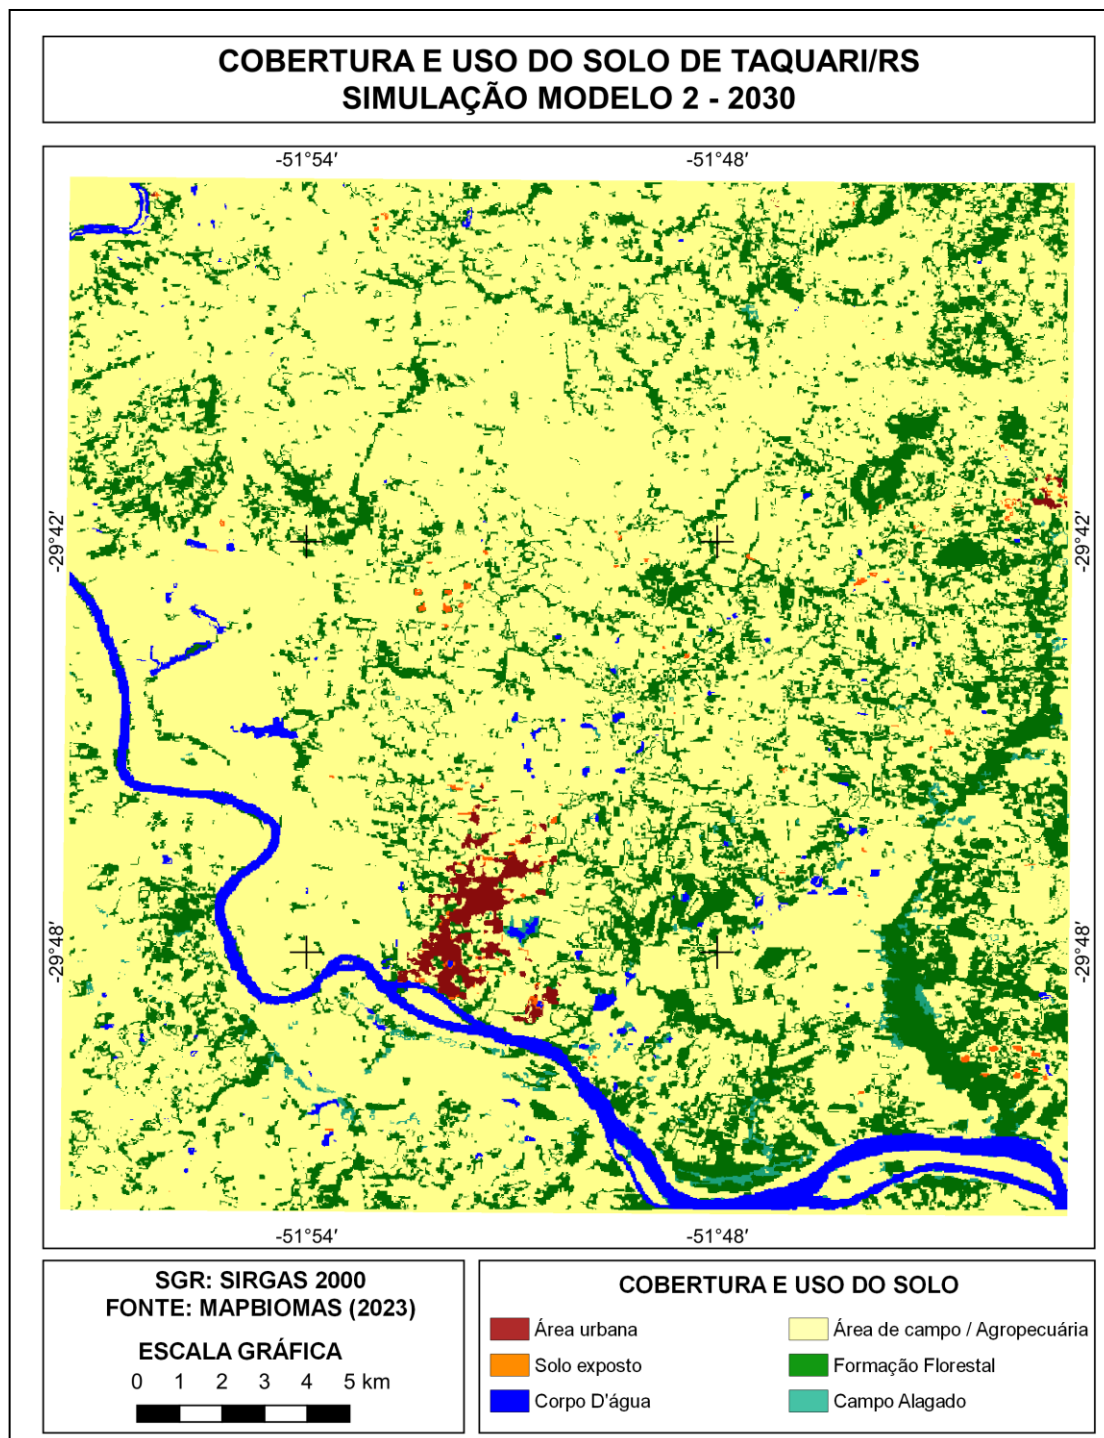
Figura 27 – Simulação 1 para 2040 – Taquari/RS.



Fonte: Elaboração própria.

De maneira análoga, foram geradas as classificações de cobertura e uso do solo através da Simulação 2, para os anos de 2030, conforme a Figura 28, e para o ano de 2040, de acordo com a Figura 29.

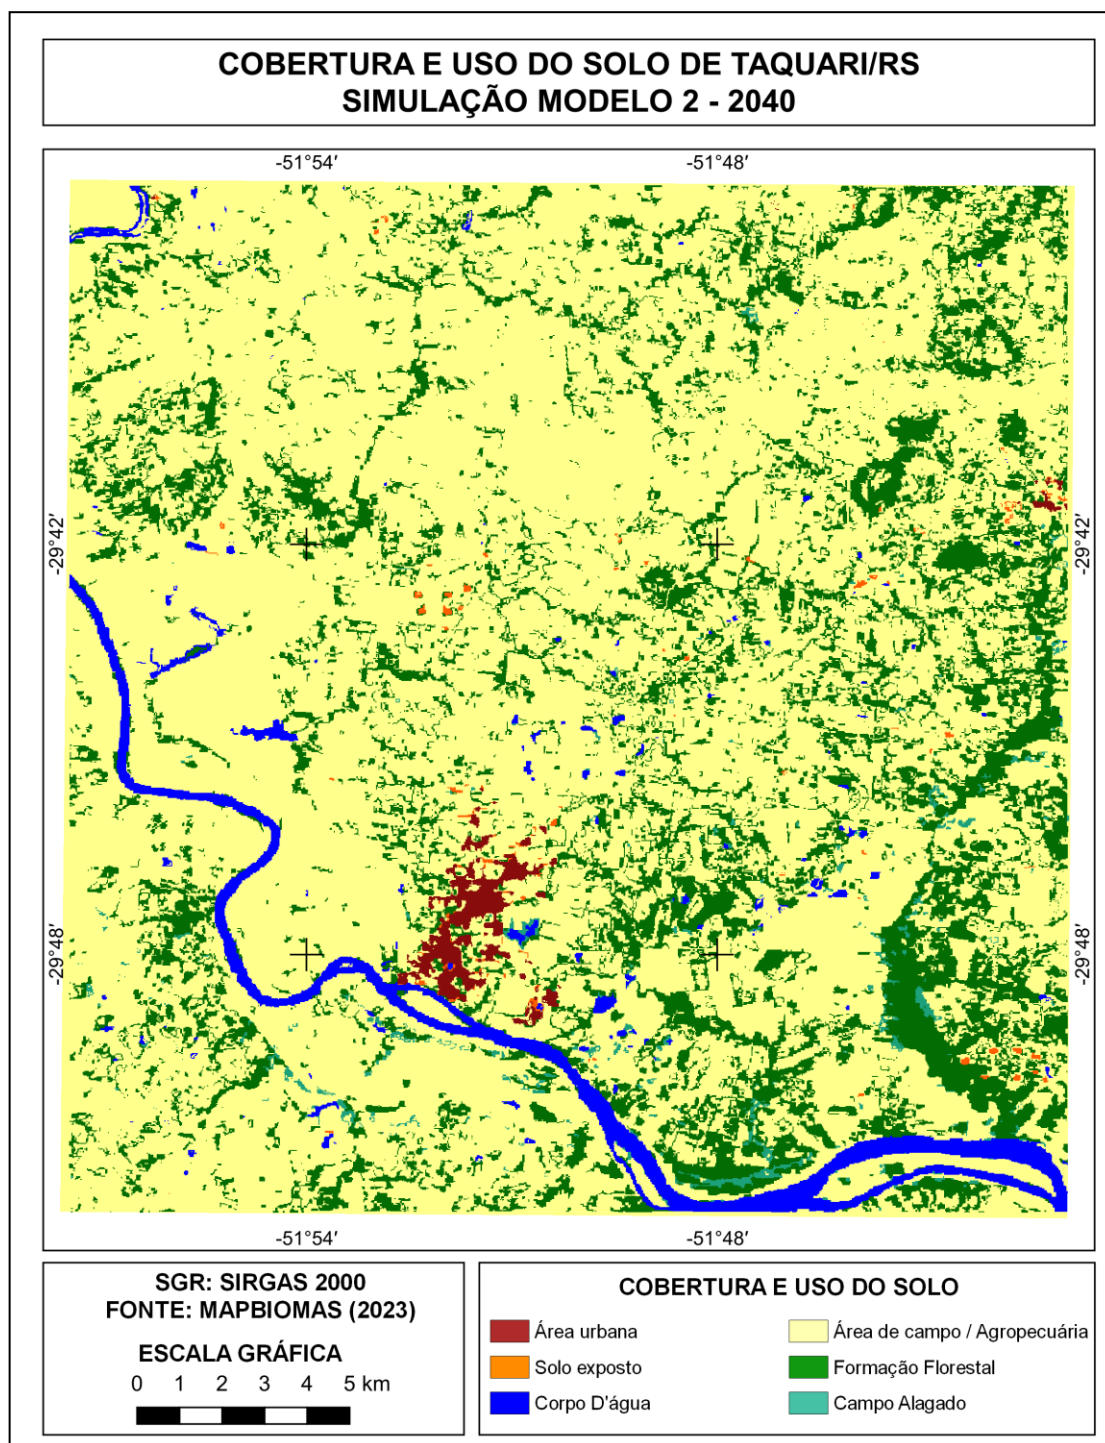
Figura 28 – Simulação 2 para 2030 – Taquari/RS.



Fonte: Elaboração própria.

A Figura 28 apresenta o resultado da Simulação 2, que converge com o princípio de estabilização, apresentando diferença espacial referente ao adensamento vegetal. Tal fato indica provável recuperação de áreas de campo por formação florestal, em relação à base de referência de 2020.

Figura 29 – Simulação 2 para 2040 – Taquari/RS.



Fonte: Elaboração própria.

Resultante da Simulação 2 para 2040, a Figura 29 aponta para um cenário quase idêntico ao apresentado por esse modelo para 2030, levando a um cenário de estabilização de classes e preservação das características espaciais da década anterior. Em ambos os casos simulados ficou evidente que nos cenários futuros de curto prazo, estabelecidos pelas décadas sequenciais, não ocorrerão modificações significativas no cenário espacial estudado. Além disso, verificou-se a convergência entre os resultados comparados. A diferença presente na Simulação 2 leva a percepção de que áreas menos valiosas e de difícil exploração podem ter suas características vegetais restauradas.

5 CONCLUSÕES

O estudo conduzido tratou da modelagem dinâmica espacial e da simulação de uso e cobertura do solo. Apresenta possibilidades de integração com políticas públicas voltadas ao planejamento ambiental e de aplicação ao planejamento urbano. Especificamente, traz simulações de cenários futuros de uso e cobertura do solo do município de Taquari, para os anos de 2030 e 2040.

A partir dos resultados demonstrados no presente estudo, foram verificadas as capacidades e limitações de simulação e antecipação de processos de modificação do território. Além disso, foi possível verificar alterações nos resultados devido à influência de diferentes variáveis relativas à ocupação e uso do solo analisados.

Para a realização desse trabalho partiu-se da premissa de utilização de tecnologias disponibilizadas em *softwares* e bases de acessos livres. Para tanto, gerou-se um banco de dados de informações georreferenciadas e, com auxílio de técnicas de geoprocessamento e dos produtos resultantes de sensoriamento remoto, foi possível criar cenários futuros de ocupação do espaço territorial. O desenvolvimento da modelagem dinâmica e espacial inicialmente proposta apoiou-se nos conhecimentos e técnicas relacionados à aprendizagem de máquina e aos autômatos celulares.

Os modelos apresentados cumpriram o objetivo inicial de construir e analisar cenários de dinâmica espacial baseados em redes neurais artificiais e simulados com autômatos celulares. A realização de modelagem de transição apoiada em redes neurais artificiais têm como possibilidade a calibragem dos modelos de transição, com adição de camadas e/ou neurônios, bem como a modificação do modelo utilizado, visando sempre à calibragem de modelos fiduciais ao crescimento orgânico do espaço. Nesse sentido, metodologias, como a adotada, auxiliam no avanço de estudos, tanto inerentes às questões de planejamento, como de controle e regulação do espaço territorial, destacando questões de interesse urbano e ambiental.

A possibilidade de simular e entender os movimentos dinâmicos são de grande valia para o planejamento e ordenamento urbano e regional. Nessa linha, entender as variáveis que explicam a modificação do espaço é de grande importância para conseguir representar e entender as mudanças do espaço. Conforme abordado, existem variáveis que muitas vezes não estão inseridos em estudos de dinâmica espacial, mas que podem ser relevantes para a construção desses modelos. De

acordo com os resultados apresentados, notou-se que as variáveis econômicas estão correlacionadas com as variáveis políticas, permitindo assim a sua substituição, quando um deles não estiver disponível para a realização de estudos evolutivos da ocupação territorial.

Nesse sentido, a inserção de variáveis urbanas, políticas, naturais e econômicas possibilitam a melhor compreensão do sistema ocupacional. Variáveis, por vezes não usuais, podem ser inseridos no sistema, ou até, na ausência de variáveis comumente utilizadas em estudos da linha da dinâmica espacial, podem substituir variáveis inexistentes ou indisponíveis em certos cenários. Modelar e compreender mecanismos de mudança das cidades levam à necessidade de uma refinada análise, que possibilite explorar os mais diversos campos do conhecimento, visando a representação das diversas formas que os movimentos urbanos podem moldar. Diante disso, experimentos como o realizado podem auxiliar na exploração, simulação e no conhecimento dos processos de modificação do espaço territorial.

Seguindo essa linha foi apresentado um método para análise de tendência da modificação do espaço com base em modelo implementado variáveis explicativas derivadas dos valores da terra, oriundos de Plantas de Valores Genéricos. Com base nos dados levantados e nas premissas da presente pesquisa, buscou-se verificar a influência do valor da terra na prospecção do uso e utilização da terra. Verificou-se com o desenvolvimento do presente estudo que o valor da terra é um fator influente na decisão e que apresenta correlação com variáveis políticas, pois está amplamente vinculado à disponibilidade de infraestrutura e às políticas públicas. Sendo assim, deve-se levar em conta que os variáveis reguladoras do espaço podem carregar consigo informações indiretas vinculadas as mais diversas esferas municipais. A Planta de Valores Genéricos, por exemplo, apresenta informações indiretas sobre a infraestrutura urbana e as políticas públicas e sociais, pois tais características estão intrínsecas ao valor da terra.

Um estudo focado na área urbanizada e nas regiões circunvizinhas poderia apresentar considerações mais relevantes para o estudo da expansão urbana. Questões inerentes à disponibilidade temporal de dados de satélite de alta resolução, como os provenientes do convênio Brasil e China (CBERS), apresentam fragilidade de garantia de dados num período representativo do tempo. Além disso, ao se estudar regiões de larga extensão, dados de sensores de alta resolução tendem a gerar produtos classificados de grande tamanho, ocasionando uma limitação de capacidade

técnica para processamento dos dados de entrada, levando o plugin a uma situação de estresse.

Dentro do contexto apresentado, é possível afirmar que foram gerados modelos dinâmicos espaciais capazes de construir cenários futuros, com base em simulações realizadas através de autômatos celulares. Os modelos dinâmicos espaciais apresentados, combinando RNA e CA, mostraram-se satisfatórios para estimativas de uso e cobertura do solo para a área avaliada na região de Taquari/RS. No que tange a incrementação de variáveis que impulsionam a modificação das características de ocupação do solo, verificou-se leve melhora dos resultados do modelo com a inserção do valor da terra. Os modelos apresentaram grau satisfatório de convergência com a realidade. O modelo que considerou a variável valor da terra apresentou melhora nos índices de validação Kappa e na Precisão Geral do Modelo. Já na avaliação comparativa, pixel a pixel, não existiu melhora com inserção do fator econômico, havendo maior assertividade do modelo sem a variável econômica.

Ainda, conforme apresentado, as alterações previstas para a ocupação do espaço territorial de Taquari nos próximos vinte anos tendem a uma baixa taxa de modificação do espaço. Optou-se por avaliar esse município pela disponibilidade de dados, entretanto, em trabalhos futuros pode-se reproduzir a pesquisa para locais com maior taxa de ocupação e com movimentos urbanos mais intensos, a fim de ratificar a modelagem dinâmica apresentada. A hipótese de estabilidade local foi comprovada em estudo de teste de persistência, o que demonstra que a dinâmica local apresenta pouca ou quase nenhuma alteração. Nesse sentido, seria interessante realizar pesquisas que envolvam variáveis explicativas de cunho econômico para outras áreas de estudo, com uma dinâmica urbana mais acentuada e maior dinamismo urbano. Entretanto, vale salientar a dificuldade em conseguir dados amostrais para variável de valores da terra em municípios com essa característica, dado a falta de atualização do dado e o dinamismo da própria variável.

Uma maneira de melhorar a simulação proposta seria realizar uma complementação do banco de dados da pesquisa de valores da terra, bem como manter um sistema de avaliação municipal atualizado. O diferencial desse trabalho foi introduzir na modelagem dinâmica espacial um fator econômico ausente em estudos prospectivos até o presente momento. Outras variáveis que também influenciam no cenário municipal, podem ser incrementadas, visando à melhora do modelo e à convergência dos resultados obtidos.

Ainda, no estudo realizado optou-se por utilizar o modelo MOLUSCE, pela facilidade de acesso e possibilidade de inserção de variáveis independentes. Modelos dinâmicos com possibilidade de inclusão de variáveis e maior controle conceitual, uma vez da descontinuidade do *plugin*, podem ser interessantes para um maior controle metodológico e possibilidades de interação e desenvolvimento.

Uma das dificuldades de utilização de modelos pronto, como o *plugin* utilizado, está em entender alguns passos metodológicos executados. Apesar do material de utilização apresentar todos os passos operacionais, alguns pontos de entendimento necessitam de complementação. Conforme apresentado, existem vários projetos que trabalham com modelos dinâmicos espaciais, com diferentes interesses, programações e variáveis avaliadas. Julga-se interessante, em softwares como utilizado, a possibilidade de operação com certa liberdade para inserção de variáveis, bem como a possibilidade de utilização de outras metodologias para obtenção de regras de transição.

Estudos futuros podem realizar a modelagem apoiadas em outros modelos combinamos, como a utilização de pesos de evidências ou regressão linear, por exemplo, para testar as interações com a variável estudada. A comparação entre os modelos seria interessante para entender como as variáveis se relacionam.

Uma das limitações decorrentes de modelos dinâmicos espaciais, como o apresentado, está na inserção de variáveis explicativas como variáveis estáticas, ou seja, que não se alterariam com o decorrer do tempo para descrever a variável dinâmica do Uso e Cobertura da Terra. Entretanto, variáveis de entrada como o valor da terra e o zoneamento do Plano Diretor municipal são variáveis dinâmicas, que se alteram no decorrer do tempo, de acordo com as questões de interesse público e mercadológicas. Atualizações desses valores de entrada poderiam ser utilizados para retroalimentar o modelo, como é o caso das próprias imagens da região reclassificadas. Nesse sentido, a utilização de modelos que se retroalimentam, ou seja, que atualizam os resultados com as modificações temporais das variáveis explicativas são soluções interessantes para buscar a melhoria do modelo e a solução das limitações apontadas.

REFERÊNCIAS

- ABBAS, Zaheer.; YANG, Guang; ZHONG, Yuanjun; ZHAO, Yaolong **Spatiotemporal Change Analysis and Future Scenario of LULC Using the CA-ANN Approach: A Case Study of the Greater Bay Area, China.** *Land* 2021, 10, 584.
- ABNT. ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 14653-1: Avaliação de Bens. Parte 1: Procedimentos Gerais.** Rio de Janeiro, 2019. 12 p.
- ABNT. ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 14653-2: Avaliação de Bens. Parte 2: Imóveis Urbanos.** Rio de Janeiro, 2011. 53 p.
- AGUIAR, Marilton Sanchotene de; DIMURO, Graçaliz Pereira; COSTA, Fabia Amorinda. **Modelos Matemáticos Baseados em Autômatos Celulares para Geoprocessamento.** Editora SBMAC, São Carlos-SP, Brasil 2004.
- ALMEIDA, Cláudia Maria de; GLERIANI, José Marinaldo. **Cellular automata and neural networks as modeling framework for the simulation of urban land use change.** Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, 16–21 April 2005, INPE, pp. 3697–3705.
- AL-AHMADI, Khalid; HEPPENSTALL, A. J.; HOGG, Jim; SEE, Linda M. **A Fuzzy Cellular Automata Urban Growth Model (FCAUGM) for the City of Riyadh, Saudi Arabia. Part 2: scenario testing.** *Applied Spatial Analysis and Policy*, 2 (2), 85–105. 2009
- AL-KHEDER Sharaf, WANGA Jun, SHANA Jie **Fuzzy inference guided cellular automata urban-growth modelling using multi-temporal satellite images.** *Int J Geogr Inf Sci* 22(11–12):1271–1293. 2008.
- AL KINDI, Khalifa. M.; AL-MAWALI, Adhra, AKHARUSI, Amira; ALSHUKAILI, Duhai; ALNASIRI, Noura; AL-AWADHI, Talai; CHARABI, Yassini; EL KENAWY, Ahmed M. **Demographic and socioeconomic determinants of COVID-19 across Oman - A geospatial modelling approach.** *Geospatial Health*, 16(1). 2021.
- AL-RUBKHI, ALGhaliya Nasser Mohammed. **Land Use Change Analysis and Modeling Using Open Source (QGIS): Case Study: Boasher Willayat.** Dissertação. Department of Geography. Sultan Qaboos University Oman. Sultanato de Omã, 2017.
- ASLAN, N. KOC-SAN, D.: **Spatiotemporal land use change analysis and future urban growth simulation using remote sensing: a case study of antalya,** *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLIII-B3-2020, 657–662.
- BATTY, Michael. **Urban evolution on the desktop: simulation with the use of extended cellular automata.** *Environment and Planning A*, v. 30. p. 1943-1967. 1998.
- BIHAMTA, Neda; SOFFIANIAN, Alireza; FAKHERAN, Sima; GHOLAMALIFARD, Mehdi. **Using the SLEUTH Urban Growth Model to Simulate Future Urban Expansion of the Isfahan Metropolitan Area, Iran.** *Journal of the Indian Society of Remote Sensing*, 2014.

BOSSLE, Renato Cabral. **MOLUSE - Modules for Land Use Change Evaluation. Guia Rápido.** Ecojustos, Responsabilidade Socioambiental. São José dos Pinhias, PR. Disponível em: <http://ecojustus.com.br/molusce-guia-rapido/> Acesso em: 10 fev. 2022

BURROUGH, Peter Alan. **Dynamic modelling and geocomputation.** In: LONGLEY, P. A.; BROOKS, S. M.; McDONNELL, R.; MacMILLAN, B. (Ed.). *Geocomputation: a primer.* Chichester: John Wiley, 1998. p. 165-192.

CANEPARO, Sony Cortese; RICOBOM, Arnaldo Eugênio. **A cartografia prospectiva e a geração de mapas preditivos do uso e cobertura da terra – estudo de caso: perímetro urbano de Paranaguá.** Paraná – Brasil. *Revista Ra'e Ga*, 31, 227-259. 2014

CESARE, Claudia Monteiro de. **Avaliação em massa de imóveis para fins fiscais: discussão, análise e identificação de soluções para problemas e casos práticos.** In: programa nacional de capacitação das cidades e Lincoln Institute of Land Policy. Org. CUNHA, E. P. C.; ERBA, D. A. Brasília: Ministério das Cidades, 2012. 116 p.

CLARKE, K. C.; HOPPEN, S.; GAYDOS, L. **A self-modifying cellular automaton model of historical urbanization in the San Francisco Bay area.** *Environment and Planning B-Planning & Design*, v. 24, n. 2, p. 247-261. Mar, 1997.

DADHICH Pran Nath; HANAOKA Shinya. **Markov method integration with multilayer perceptron classifier for simulation of urban growth of Jaipur city. Selected topics in power systems and remote sensing,** 10th WSEAS/IASME international conference on electric power systems, high voltages, electric machines (power'10) and 6th Wseas international conference on remote sensing (remote '10), Iwate Prefectural University, Japan, October 4–6, 2010, pp 118–123. 2010

DANTAS, Rubens Alves; MAGALHÃES, André Matos; ROCHA, Francisco José Sales; LIMA, Ricardo Chaves. **Uma nova metodologia para avaliação de imóveis utilizando regressão espacial.** Anais do IBAPE - XI COBREAP - Congresso brasileiro de engenharia de avaliações e perícias, Guarapari - ES. 2001.

DELANEZE, Marcelo Elias; RIEDEL, Paulina Setti; MARQUES, Mara Lúcia; FERREIRA, Mateus Vidotti. **Modelagem dinâmica espacial para o monitoramento do crescimento urbano no entorno do duto orbel.** *Revista Brasileira de Cartografia*, [S. l.], v. 66, n. 3, 2014.

EL-BARMELGY, Mohamed; SHALABY, Ahmad. M; NASSAR, Usama. A; ALI, Shima. M. **Economic land use theory and land value in a value model.** *International Journal of Economics and Statistics*, 2(2014), 91–98. 2014.

FÁVERO, L. P.; BELFIORE, P. **Manual de análise de dados.** Rio de Janeiro: Elsevier, 2017.

FERNANDES, Nelson. **Modelagem em Geografia Física: Teoria, Potencialidades e Desafios.** Espaço Aberto. 6. 209-247. 2016.

FOLHARINI, Saulo; OLIVEIRA, Regina. **Utilização do Land Change Modeler na modelação prospectiva do uso e cobertura do solo na microrregião de Santos,**

Brasil para o ano de 2022. GOT : Revista de Geografia e Ordenamento do Território; Porto Ed. 19, p57-73. 2020.

FOROUTAN, Ehsan, DELAVAR, Mahmoud Reza. **Urban growth modeling using fuzzy logic.** ASPRS 2012 Annual Conference Sacramento, California, March 19–23, 2012.

GHARBIA, Salem S.; ALFATAH, Sara Abd; GILL, Laurence; JOHNSTON, Paul; PILLA, Francesco. **Land use scenarios and projections simulation using an integrated GIS cellular automata algorithms.** Model. Earth Syst. Environ. 2, 151. 2016.

GEURS, Karst T.; WEE, Van Bert. **Accessibility evaluation of land use and transport strategies: Review and research directions.** Journal of Transport Geography. v.12, p. 127-140. 2004.

GREMONINI, Lucas; VICENTINI, Eduardo. **Autômatos celulares: revisão bibliográfica e exemplos de implementações.** Revista Eletrônica Lato Sensu – UNICENTRO, Ed. 6, p 3-19: 2008.

HAN, Wenjing; ZHANG, Xiaoling; ZHENG, Xian. **Land use regulation and urban land value: Evidence from China.** Land Use Policy, 92, 104432. 2020.

HART, Timothy C. **Hot Spots of Crime: Methods and Predictive Analytics.** In: Lersch K., Chakraborty J. (eds) Geographies of Behavioural Health, Crime, and Disorder. GeoJournal Library, vol 126. Springer, Cham. 2020.

HUANG, Qingxu; HE, Chunyang; LIU, Zhifeng; SHI, Peijun. **Modeling the impacts of drying trend scenarios on land systems in northern China using an integrated SD and CA model.** Science China Earth Sciences, 57 (4), 839–854. 2014.

IBGE CIDADES. **Taquari – Rio Grande do Sul.** Disponível em: <<http://www.cidades.ibge.gov.br/xtras/perfil.php?lang=&codmun=432130&search=rio-grande-do-sul|taquari>>. Acesso: 23 set. 2022.

KAWASHIMA, Renata Sayuri; GIRNAOTTI, Mariana Abrantes; ALMEIDA, Cláudia Maria; QUINTANILHA, José Alberto. **Modelagem Dinâmica Espacial como ferramenta para simulação de cenários da paisagem na região portuária da Baixada Santista.** Boletim de Ciências Geodésicas, v. 22, n. 4, p. 703-718, 2016.

KIM, Dae-Sik. **Development of an Optimization Technique for a Potential Surface of Spatial Urban Growth Using Deterministic Modeling Methodology,** Journal of Urban Planning and Development – ASCE, 135(2):74-85. 2009.

KOURTIT, Karima; NIJKAMP, Peter. **In praise of megacities in a global world.** Regional Science Policy and Practice, V5, P167–182 .2013.

LANGTON, Christopher Gale. **Self-reproduction in cellular automata.** Physica D: Nonlinear Phenomena, V.10, N. 1-2, JAN. 1986, p.135-144.

LI, Xia; Yeh, Anthony Gar-On. **Calibration of cellular automata by using neural networks for the simulation of complex urban systems**, Environmental and Planning A, v. 33, p. 1445-1462, 2001.

LIANG, Xun; LIU, Xiaoping; LI, Dan; ZHAO, Hui; CHEN, Guangzhao Chen. **Urban growth simulation by incorporating planning policies into a CA-based future land-use simulation model**. International Journal of Geographical Information Science, 2018.

LIPORONI, Antônio Sérgio. **Avaliação em massa com ênfase em planta de valores**. In: ALONSO, Nelson Roberto Pereira (Coord). Engenharia de Avaliações. 2. ed. São Paulo: PINI, 2013.

LIU, Xiaoping; LI, Xia, LIU, Lin; HE, Jinqiang; Ai, Bin. **A bottom-up approach to discover transition rules of cellular automata using ant intelligence**. International Journal of Geographical Information Science, 22:1247–1269, 2008.

LIU, Xiaoping; HU, Guohua; AI, Bin; LI, Xia; TIAN, Guangjin; CHEN, Yimin; LI, Shaoying. **Simulating urban dynamics in China using a gradient cellular automata model based on S-shaped curve evolution characteristics**, International Journal of Geographical Information Science, 32:1, 73-101, 2017.

MAITHANI, Sandeep. **A neural network based urban growth model of an Indian city**. Journal of the Indian Society of Remote Sensing. Volume 37, p 363–376, 2009.

MARQUES, Mara-Lúcia; MÜLLER-PESSÔA, Vinícius; CAMARGO, Danilo; CECAGNO, Camila. **Simulación de escenarios urbanos mediante autómatas celulares para modelar el crecimiento de Campinas – SP, Brasil**. Revista EURE - Revista de Estudios Urbano Regionales. 47.142, 2021.

MASSABKI, José Augusto; PEIXOTO, Anna Silvia Palcheco; KAISER, Ilza Machado.; MANZATO, Gustavo Garcia. **Modelagem dos padrões da expansão urbana da Região Metropolitana de São Paulo baseada em Autômatos Celulares**. Revista Brasileira de Gestão Urbana, v. 9, n. 1, p. 361 - 371, 2017.

MÖLLER, Luiz Fernando Carvalho. **Planta de valores genéricos: avaliação coletiva de imóveis para fins tributários**. Porto Alegre: Sagra-DC Luzzatto, 1995.

MONDAL, Biswajit; DAS, Dipendra; BHATTA, Baudeb. **Integrating cellular automata and Markov techniques to generate urban development potential surface: A study on Kolkata agglomeration**. Geocarto International, V32, p401–419, 2017.

NUGROHO, Agung Bayu; HASYIM, Abdul Wahid; USMAN, Fadly. **Urban Growth Modelling of Malang City using Artificial Neural Network Based on Multi-temporal Remote Sensing**. Civil and Environmental Science Journal (CIVENSE), Malang, Indonesia, v. 1, n. 2, p. pp.52–61, 2018.

OLIVEIRA, Anderson Magalhães de. **Avaliação em massa do potencial de retorno econômico de terrenos urbanos por modelagem espacial**. 104 f. Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, Recife, Pernambuco, 2018.

OLMEDO, Maria Teresa Camacho; PONTIUS Jr, Robert Gilmore; PAEGELOW, MARTIN; MAS, Jean-François. **Comparison of simulation models in terms of quantity and allocation of land change**. Environmental Modelling & Software. V69, p 214-221, 2015.

O'SULLIVAN, David, TORRENS, Paul M. **Cellular models of urban systems**. Theoretical and Practical Issues on Cellular Automata. Eds Bandini, S, Worsch, T Springer, London, p 108–116, 2001.

PARK, Soyoung; JEON, Seongwoo; KIM, Shinyup; CHOI, Chuluong. **Prediction and comparison of urban growth by land suitability index mapping using GIS and RS in South Korea**. Landsc. UrbanPlan. V99 (2), p 104–114, 2011

PAIVA, Caio dos Anjos; ANTUNES, Felipe Buffara Antunes. **Geração de planta de valores genéricos a partir do cadastro territorial urbano**. Revista Brasileira de Cartografia, [S. l.], v. 69, n. 3, 2017.

PAIXÃO, Luiz Andrés; ABRAMO, Pedro. **Os vetores de expansão da atividade imobiliária em Belo Horizonte: 1994-2003**. Nova Economia, [S. l.], v. 18, n. 2, 2009.

PINHEIRO, Evanice Gomes. **Avaliação de Modelo de Inteligência Artificial Híbridos na Estimativa de Precipitações**. Tese (Doutorado) – Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Civil, Belém, 2022.

POLIDORI, Mauricio Couto. **Crescimento urbano e ambiente – Um estudo de exploratório sobre as transformações e o futuro das cidades**. 328 f. tese (Doutorado em Ecologia – linha de pesquisa Ecologia da paisagem) Instituto de Biociências, Universidade Federal do Rio Grande do Sul, 2004.

POLIDORI, Mauricio Couto; KRAFTA, Romulo. **Simulando crescimento urbano com integração de fatores naturais, urbanos e institucionais**. GeoFocus (Artículos), nº 5 , p. 156-179, 2005.

PORTUGALI, Juval. **Self-organization and the city**. Berlin: Springer. 352 p. 2000.

RICOBOM, Arnaldo Eugênio. **Metodologia Auxiliar para revisão de Planos Diretores Municipais através da Aplicação da Cartografia Prospectiva -Estudo de Caso -Perímetro Urbano de Paranaguá**. Tese (Doutorado) -Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba. 2011.

RIENOW, Andreas; GOETZKE, Roland. **Supporting SLEUTH – enhancing a cellular automaton with support vector machines for urban growth modeling**. Computers, Environment and Urban Systems, V49, p66–81, 2015.

RODRIGUES, Luís; JULIÃO, Rui. **Espacialização de cenários do balanço da água: uma metodologia de apoio à decisão para a gestão dos recursos hídricos**. Revista de Geografia e Ordenamento do Território (GOT), n. 5 (junho). Centro de Estudos de Geografia e Ordenamento do Território, p. 233-257, 2014.

RUZ, Marie-Hélène; RUFIN-SOLER, Caroline; HÉQUETTE, Arnaud; RÉVILLON, Rachel; HELLEQUI, Anne-Peggy; DEBOUDT, Philippe; HEBERT, Vincent; COHEN,

Olivier; LEBRETON, Florian; GOFF, Lucie Le; SCHMITT, François G.; MARIN, Denis. **Climate Change and Risk Perceptions in Two French Coastal Communities**. Journal of Coastal Research, Coastal Education and Research Foundation, 95 (sp1), pp.875, 2020.

SAATY, Thomas Lorie. **Decision making with the analytic hierarchy process**. International Journal of Services Sciences, v. 1, n. 1, p. 83-98, 2008.

SANTOS, Hélder Gramacho; **Efeitos espaciais em mercados de terras rurais: modelagem, validação e avaliação de desempenho**. (Dissertação de Mestrado) Programa de Pós-graduação em Ciências Geodésicas e Tecnologias da Geoinformação. Universidade Federal de Pernambuco, Recife. 2014.

SOAREAS-FILHO, Britaldo Silveira. **Análise de paisagem: Fragmentação e mudança**. Belo Horizonte, FMG, Departamento de Geografia, Centro de Sensoriamento Remoto, 90p, 1998.

SOAREAS-FILHO, Britaldo Silveira; CERQUEIRA, Gustavo Coutinho; ARAÚJO, William Leite; VOLL, Eliane. **Modelagem de dinâmica de paisagem: concepção e potencial de aplicação de modelos de simulação baseados em autômato celular**. Megadiversidade V3, p74-86, 2007.

TAQUARI, Prefeitura Municipal de. **Dados do Município**. Disponível em: <<https://www.taquari.rs.gov.br/pagina/id/3/?dados-do-municipio.html>>. Acesso em 10 de jun. 2023.

TRENTIN, Gracieli; FREITAS, Maria Isabel Castreghini de. **Modelagem da dinâmica espacial urbana: modelo de autômato celular na simulação de cenários para o município de Americana-SP**. Revista Brasileira de Cartografia, n. 62, Edição Especial n.1, p. 291-305, 2010.

UBERTI, Marlene Salete. **Avaliação em massa de imóveis rurais através de modelagem clássica, espacial e geoestatística**. 2016. 151 f. Tese (Doutorado em Ciência, Tecnologia e Inovação) – Universidade Federal Rural do Rio de Janeiro (UFRRJ), Rio de Janeiro, 2016.

VON NEUMAAN, John. **The Theory os Self-REproducind Automata**, A. W. Burks (Ed.), Champaign, IL, USA: University of Illinois Press, 1966, 388p.mm

WOLFRAM, Stephen. **Universality and complexity in cellular automata**. Physica 10D: p1-35. 1984.

ZILLI, Carlos Augusto. **Regressão geograficamente ponderada aplicada na avaliação em massa de imóveis urbanos**. 192 p. Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia de Transportes e Gestão Territorial, Florianópolis, 2020.