

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

ANDRESSA GARCIA FONTANA

**MAPEAMENTO TEMPORAL E PREDIÇÃO DA ÁREA DA MANCHA URBANA DA
REGIÃO METROPOLITANA DE PORTO ALEGRE – RS, UTILIZANDO
GEOTECNOLOGIAS E SENSORES REMOTOS**

PORTO ALEGRE

2022

ANDRESSA GARCIA FONTANA

**MAPEAMENTO TEMPORAL E PREDIÇÃO DA ÁREA DA MANCHA URBANA DA
REGIÃO METROPOLITANA DE PORTO ALEGRE – RS, UTILIZANDO
GEOTECNOLOGIAS E SENSORES REMOTOS**

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

Orientador: Prof. Dr. Victor Fernandez Nascimento

PORTO ALEGRE

2022

CIP - Catalogação na Publicação

Fontana, Andressa Garcia

Mapeamento temporal e predição da área da mancha urbana da região metropolitana de Porto Alegre - RS, utilizando geotecnologias e sensores remotos. /

Andressa Garcia Fontana. -- 2022.

118 f.

Orientador: Victor Fernandez Nascimento.

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, 2022.

1. Sensoriamento Remoto. 2. Geoprocessamento. 3. Mapeamento urbano. 4. Expansão urbana. I. Nascimento, Victor Fernandez, orient. II. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UFRGS com os dados fornecidos pelo(a) autor(a).

ATA AUTENTICADA

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia

Programa de Pós-Graduação em Sensoriamento Remoto
SENSORIAMENTO REMOTO - Mestrado Acadêmico
Ata de defesa de Dissertação

Aluno: Andressa Garcia Fontana, com ingresso em 11/02/2019

Título: MAPEAMENTO TEMPORAL E PREDIÇÃO DA ÁREA DA MANCHA URBANA DA REGIÃO METROPOLITANA DE PORTO ALEGRE – RS, UTILIZANDO GEOTECNOLOGIAS E SENSORES REMOTOS

Data: 23/05/2022

Horário: 14:00

Local: online

Banca Examinadora	Avaliação	Origem
Alessandro Carvalho Miola	Aprovado	UFMS
Guilherme Garcia de Oliveira	Aprovado	UFRGS
Marcos Wellausen Dias de Freitas	Aprovado	UFRGS

Avaliação Geral da Banca: Aprovado

Data da homologação: 02/09/2022

Porto Alegre, 15 de fevereiro de 2024

Programa de Pós-Graduação em Sensoriamento Remoto
Av. Bento Gonçalves, 9500 Prédio 44202 Setor 5 - Bairro Agronomia - Telefone 3308-6221
Porto Alegre - RS

Documento gerado sob autenticação nº MSS.127.607.IDT
Pode ser autenticado, na Internet, pela URL <http://www.ufrgs.br/autenticacao>,
tendo validade sem carimbo e assinatura.

Dedico este trabalho a Deus.

AGRADECIMENTOS

Agradeço a Deus. Quando eu pedi forças, Deus permitiu dificuldades para me fazer forte. Quando pedi coragem, Deus permitiu perigos para eu superar.

Agradeço à Universidade Federal do Rio Grande do Sul e ao Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, pela estrutura disponibilizada para o desenvolvimento desta dissertação.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela bolsa de estudos em nível de pós-graduação.

À minha mãe e amiga Fabiane Garcia, pelo amor incondicional e apoio diário.

Ao meu orientador Professor Dr. Victor Fernandez Nascimento, pela orientação na construção desse trabalho e em minha formação.

A banca examinadora, composta pelos professores Alessandro Carvalho Miola, Guilherme Garcia de Oliveira e Marcos Wellausen Dias de Freitas, pelas valiosas contribuições neste trabalho.

Aos professores do Programa de Pós-Graduação em Sensoriamento Remoto que enriqueceram a minha formação profissional e pessoal.

Aos meus amigos, pelos sorrisos proporcionados em momentos difíceis.

Aos autores e pesquisadores citados, pelo conhecimento imprescindível para a construção desse trabalho.

Até aqui o Senhor me ajudou.

“Feliz é quem persevera na provação, porque depois de aprovado receberá a coroa da vida, que Deus prometeu aos que o amam”.
Tiago 1:12

MAPEAMENTO TEMPORAL E PREDIÇÃO DA ÁREA DA MANCHA URBANA DA REGIÃO METROPOLITANA DE PORTO ALEGRE – RS, UTILIZANDO GEOTECNOLOGIAS E SENSORES REMOTOS

RESUMO

A expansão urbana tem um impacto substancial na dinâmica de uso e cobertura da terra (LULC). Os mapas históricos servem como referência para realizar a análise espacial de previsão do LULC. Esta pesquisa tem como objetivo identificar a mudança do LULC na Região Metropolitana de Porto Alegre (RMPA) para os anos de 1991, 2000, 2010 e 2020 usando imagens do satélite Landsat e prever as mudanças futuras para os anos de 2030 e 2040 usando um modelo *Multilayer Perceptrons* (MLP) através de *Artificial Neural Network* (ANN). As variáveis utilizadas como entrada no modelo de previsão são as distâncias de rodovias, centros urbanos, Porto Alegre, estação ferroviária, além do relevo sombreado, declividade e os dados históricos de LULC. Os resultados apontaram que todas as variáveis têm efeitos significativos na condução da expansão urbana histórica e futura. Além disso, o índice de expansão da paisagem (LEI) foi utilizado como métrica espacial para analisar as formas de expansão urbana. Para a análise histórica do primeiro artigo foi considerado os municípios que faziam parte da RMPA em cada ano mapeado. O segundo artigo considerou os 34 municípios da RMPA para os quatro anos em estudo. Os resultados do primeiro artigo mostraram que a RMPA experimentou uma mudança inédita de LULC, aumentando sua área urbana em 336,2 km², sendo Porto Alegre e Canoas os municípios com a maior taxa de expansão. A precisão dos mapas LULC teve um excelente desempenho com coeficiente Kappa 0,83, 0,81, 0,84, e 0,82 para os anos em estudo, respectivamente. Além disso, o LEI apontou que entre 1991 e 2020 houve maior expansão na forma borda-expansão, principalmente nos municípios de Porto Alegre, Alvorada, Canoas, Cachoeirinha, Esteio, Sapucaia do Sul e São Leopoldo. Essa forma de expansão foi a mais verificada na RMPA nos últimos 30 anos, com 562 km² resultando em 81%, os outros 17% foram periféricos e 2% foram de preenchimento. Esses municípios estão localizados próximos ao centro da capital da RMPA, à estação ferroviária e ao Aeroporto Internacional Salgado Filho, fatores considerados importantes para o aumento da expansão urbana. A precisão dos mapas históricos de LULC do segundo artigo apresentou um excelente desempenho com coeficiente Kappa de 0,82, 0,87, 0,86, e 0,83 para os anos em estudo, respectivamente. Os resultados históricos mostraram que entre 1991 e 2020, a classe urbanização teve um aumento de 298 km², enquanto as áreas de vegetação arbórea diminuíram um total de 322 km². O LEI no segundo artigo entre 1991 e 2020 apresentou como forma de expansão urbana predominante na RMPA a expansão de borda com cerca de 93%, principalmente nos municípios de Porto Alegre, Alvorada, Canoas, Esteio e São Leopoldo. A forma de expansão periférica e de preenchimento ocorreram em 5% e 2%, respectivamente, nos municípios mais afastados de Porto Alegre, principalmente em Capela de Santana, Montenegro, Viamão e Guaíba. Por fim, as mudanças nas previsões de modelagem futuras no LULC para os anos de 2030 e 2040 apresentaram um aumento significativo na área urbana da RMPA de 323,3 km² e 335,4 km², respectivamente. O LEI para os mapeamentos futuros apresentou resultados diferentes dos analisados historicamente, a forma expansão de borda diminuiu, mas mesmo assim continuou predominante com 79%, enquanto que a forma periferia e de preenchimento aumentaram alcançando 18% e 3%, respectivamente. Para o futuro, é previsto que as áreas urbanas aumentem mais de 650 km² até 2040 na RMPA. Esses resultados podem auxiliar os tomadores de decisão no desenvolvimento das cidades, e políticas detalhadas de gestão e planejamento urbano devem ser feitas considerando a heterogeneidade espacial e interna.

Palavras-chave: LULC previsto; métricas espaciais; LEI; ANN.

ABSTRACT

Urban sprawl substantially impacts land use and land cover (LULC) dynamics. Historical maps serve as a reference to perform predictive spatial analysis. This research aims to identify the change in LULC in the Metropolitan Region of Porto Alegre (RMPA) for the years 1991, 2000, 2010, and 2020 using Landsat satellite images and predict future changes for the years 2030 and 2040 using a model Multilayer Perceptrons (MLP) through Artificial Neural Network (ANN). The variables used as input in the forecast model are the distances from highways, urban centers, Porto Alegre, and railway stations, in addition to shaded relief, slope, and historical data from LULC. The results showed that all variables significantly affect the historical and future urban expansion. In addition, the landscape expansion index (LEI) was used as a spatial metric to analyze the urban growth forms. For the first article, the municipalities were inserted accordingly to their inclusion year in the RMPA. However, in the second article, all the 34 towns in the RMPA were considered for the four years under study. The first article's results showed that the RMPA experienced an unprecedented LULC change, increasing its urban area by 336.2 km², with Porto Alegre and Canoas being the municipalities with the highest expansion rate. The LULC map's accuracy performed excellently with Kappa coefficients of 0.83, 0.81, 0.84, and 0.82 for the four years under study, respectively. In addition, the LEI showed that between 1991 and 2020, there was a more significant expansion in the edge-expansion form, mainly in Porto Alegre, Alvorada, Canoas, Cachoeirinha, Esteio, Sapucaia do Sul and São Leopoldo municipalities. This expansion was the most verified in the RMPA in the last 30 years, with 562 km² resulting in 81% of the new urban areas, the other 17% outlying, and 2% infilling. These municipalities are close to the capital state center, the railway station, and the International Airport, factors considered important for urban sprawl increase. The LULC historical map's accuracy from the second article also performed excellently with Kappa coefficients of 0.82, 0.87, 0.86, and 0.83 for the four years under study, respectively. The historical results showed that between 1991 and 2020, the urbanization class had an increase of 298 km², while the arboreal vegetation areas decreased by 322 km². The LEI observed between 1991 and 2020 in the second article showed that the predominant urban expansion form in the whole RMPA was edge expansion with 93%, mainly in Porto Alegre, Alvorada, Canoas, Esteio, and São Leopoldo municipalities. The outlying and infilling urban expansion form occurred in 5% and 2%, respectively, mainly far from Porto Alegre, in Capela de Santana, Montenegro, Viamão, and Guaíba municipalities. Finally, LULC's future modeling predictions for 2030 and 2040 showed a significant urban area increase of 323.3 km² and 335.4 km², respectively. The LEI for the future presented different results from those analyzed previously historically. The edge-expansion form occurs in fewer areas, but still, the majority with 79%, while the outlying and infilling increased to 18% and 3%, respectively. Therefore, in the future, urban areas are predicted to increase by more than 650 km² by 2040 in the RMPA. These results can help decision-makers in the development of cities, and detailed urban management and planning policies must be made considering spatial and internal heterogeneity.

Keywords: predicted LULC; spatial metrics; LEI; ANN.

LISTA DE FIGURAS

Figura 1 - Localização da Região Metropolitana de Porto Alegre.	17
Figura 2 - Configuração territorial da RMPA em 2020.	18
Figura 3 - Fluxograma da metodologia.	20
Figura 4 - Mapa de LULC dos municípios que faziam parte da RMPA em 1991.	26
Figura 5 - Mapa de LULC dos municípios que faziam parte da RMPA em 2000.	27
Figura 6 - Mapa de LULC dos municípios que faziam parte da RMPA em 2010.	28
Figura 7 - Mapa de LULC dos municípios que faziam parte da RMPA em 2020.	29
Figura 8 - Relação entre população e área construída dos municípios da RMPA em 2020.	31
Figura 9 - Quantificação da validação do uso e cobertura da terra para os anos em estudo.	36
Figura 10 - Distribuições espaciais da mancha urbana na RMPA de 1991 a 2020.	37
Figura 11 - Quantificação do uso e cobertura da terra para os anos em estudo.	39
Figura 12 - a) Expansão de borda; b) preenchimento; c) periférico.	41
Figura 13 - Localização da Região Metropolitana de Porto Alegre.	49
Figura 14 - Fluxograma da metodologia.	50
Figura 15 - (A) Mapa do Modelo Digital de Elevação; (B) mapa de declividade; (C) mapa de relevo sombreado; (D) mapa de distância de Porto Alegre; (E) mapa de distância da estação ferroviária; (F) mapa de distância dos centros urbanos; (G) mapa de distâncias das estradas.	52
Figura 16 - Comparação entre o dado modelado para 2020 e LULC de 2020.	58
Figura 17 - Treinamento para a simulação de 2020.	59
Figura 18 - Mapa de uso e cobertura da terra da RMPA em 1991.	60
Figura 19 - Mapa de uso e cobertura da terra da RMPA em 2000.	61
Figura 20 - Mapa de uso e cobertura da terra da RMPA em 2010.	62
Figura 21 - Mapa de uso e cobertura da terra da RMPA em 2020.	63
Figura 22 - Relação entre população e área construída dos municípios da RMPA em 2020.	65
Figura 23 - Quantificação da validação do uso e cobertura da terra para os anos em estudo.	70
Figura 24 - Distribuições espaciais históricas do aumento da mancha urbana na RMPA entre 1991 e 2020.	71
Figura 25 - Quantificação de LULC para os anos de 1991, 2000, 2010, e 2020.	73
Figura 26 - a) preenchimento; b) expansão de borda; c) periférico.	74
Figura 27 - Distribuições espaciais da previsão da mancha urbana na RMPA.	76
Figura 28 - Mapa LULC de 2020 comparado com o dado modelado para 2020.	78
Figura 29 - Cenário de uso e cobertura da terra na RMPA para 2030.	79
Figura 30 - Mapa de transição de classes de uso e cobertura da terra entre 2020 e 2030.	80
Figura 31 - Cenário de uso e cobertura da terra na RMPA para 2040.	81
Figura 32 - Mapa de transição de classes de uso e cobertura da terra entre 2030 e 2040.	82

LISTA DE TABELAS

Tabela 1 - Características dos municípios da RMPA.	19
Tabela 2 - Áreas das classes de uso e cobertura da terra nos anos de estudo.	29
Tabela 3 - Acurácia da classificação do uso e cobertura da terra em 1991.	32
Tabela 4 - Acurácia da classificação do uso e cobertura da terra em 2000.	32
Tabela 5 - Acurácia da classificação do uso e cobertura da terra em 2010.	33
Tabela 6 - Acurácia da classificação do uso e cobertura da terra em 2020.	34
Tabela 7 - Índices de precisão para as classes classificadas nos três períodos.	35
Tabela 8 - Matriz de transição de LULC entre 1991 e 2000.	62
Tabela 9 - Matriz de transição de LULC entre 2000 e 2010.	63
Tabela 10 - Matriz de transição de LULC entre 2010 e 2020.	64
Tabela 11 - Áreas das classes de uso e cobertura da terra nos anos de estudo.	64
Tabela 12 - Acurácia da Classificação do uso e cobertura da terra em 1991.	66
Tabela 13 - Acurácia da Classificação do uso e cobertura da terra em 2000.	66
Tabela 14 - Acurácia da Classificação do uso e cobertura da terra em 2010.	67
Tabela 15 - Acurácia da Classificação do uso e cobertura da terra em 2020.	68
Tabela 16 - Avaliação de precisão para as classes classificadas nos quatro anos.	69
Tabela 17 - Matriz de transição de LULC entre 2020 e 2030.	80
Tabela 18 - Áreas das classes de LULC previstas para o 2030 e 2040.	81
Tabela 19 - Matriz de transição de LULC entre 2030 e 2040.	83

LISTA DE QUADROS

Quadro 1 - Imagens dos satélites Landsat.....	21
Quadro 2 - Definições dos valores de Coeficiente Kappa.	23
Quadro 3 - Classes de LULC deste estudo e as classes agrupadas do MapBiomias.	24
Quadro 4 - Imagens dos satélites Landsat.....	51
Quadro 5 - Interpretação dos valores de Coeficiente Kappa.	55
Quadro 6 - Classes de LULC dessa pesquisa e as classes agrupadas do MapBiomias.	55

LISTA DE SIGLAS E ACRÔNIMOS

ANN	<i>Artificial Neural Network</i>
CA	Autômatos Celulares
CEPSRM	Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia
ESA	<i>European Space Agency</i>
ETM +	<i>Enhanced Thematic Mapper Plus</i>
FEE	Fundação de Economia e Estatística
FNEM	Fórum Nacional de Entidades Metropolitanas
GOES	<i>Geostationary Operational Environmental Satellite</i>
IA	Inteligência Artificial
IBGE	Instituto Brasileiro de Geografia e Estatística
INPE	Instituto Nacional de Pesquisas Espaciais
IR	Infravermelho
LANDSAT	<i>Land Remote Sensing Satellite</i>
LEI	<i>Landscape Expansion Index</i>
LULC	<i>Land Use Land Cover</i>
MCA	<i>Multicriteria Analysis</i>
MDE	Modelo Digital de Elevação
MERCOSUL	Mercado Comum do Sul
MLP	<i>Multilayer Perceptrons</i>
MOLUSCE	<i>Modules of Land Use Change Evaluation</i>
NASA	<i>National Aeronautics and Space Administration</i>
NIR	<i>Near-Infrared</i>
OLI	<i>Operational Land Imager</i>
PPGSR	Programa de Pós-Graduação em Sensoriamento Remoto
PDI	Processamento Digital de Imagens
RGB	<i>Red, Green, Blue</i>
RMPA	Região Metropolitana de Porto Alegre
RS	Rio Grande do Sul
SEMA	Secretaria do Meio Ambiente e Infraestrutura
SCP	<i>Semi-Automatic Classification Plugin</i>

SIG	Sistema de Informações Geográficas
SIRGAS	Sistema de Referência Geocêntrico para as Américas
SLEUTH	<i>Slope, land use, exclusion, urban extent, transportation, hillshade</i>
SRTM	<i>Shuttle Radar Topography Mission</i>
SVM	Support Vector Machine
TM	<i>Thematic Mapper</i>
UFRGS	Universidade Federal do Rio Grande do Sul
UGM	<i>Urban Growth Model</i>
USGS	<i>United States Geological Survey</i>
UTM	Universal Transversa de Mercator

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Objetivo geral	3
1.1.1	<i>Objetivos específicos.....</i>	<i>3</i>
2	ORGANIZAÇÃO DA DISSERTAÇÃO.....	4
3	REFERENCIAL TEÓRICO	5
3.1	Transformações na paisagem no decorrer do tempo.....	5
3.2	Classificação digital de imagens para mapeamento de LULC.....	6
3.3	Modelagem da dinâmica da paisagem e modelos de simulação baseados em autômato celular.....	7
3.4	<i>Artificial Neural Network (ANN)</i>	<i>9</i>
3.5	<i>Redes Multilayer Perceptrons (MLP).....</i>	<i>10</i>
4	DESENVOLVIMENTO.....	13
4.1	Artigo 1 - Análise espacial da expansão urbana na Região Metropolitana de Porto Alegre – RS, nos últimos 30 anos.....	13
4.2	Artigo 2 - Modelagem de uso e cobertura da terra e geração de cenários futuros da mancha urbana da Região Metropolitana de Porto Alegre – RS, utilizando <i>Artificial Neural Network (ANN)</i>	47
5	CONSIDERAÇÕES FINAIS	88
	REFERÊNCIAS.....	89

1 INTRODUÇÃO

A Região Metropolitana de Porto Alegre (RMPA), conhecida como a Grande Porto Alegre, é a maior região metropolitana da Região Sul do Brasil sendo a quinta mais populosa do país e encontra-se localizada numa área estratégica para o desenvolvimento do estado do Rio Grande do Sul. A população da RMPA é ultrapassada apenas pelas regiões metropolitanas de São Paulo, Rio de Janeiro, Belo Horizonte e Brasília. Além disso, a RMPA possui o quarto maior PIB do Brasil e na atualidade é a 82ª maior aglomeração urbana do mundo (SECRETARIA DE PLANEJAMENTO, 2018).

A RMPA faz parte da Mesorregião Metropolitana de Porto Alegre, numa posição estratégica em referência ao Mercado Comum do Sul (MERCOSUL), que abrange os principais países da América do Sul (SCHERER *et al.*, 2016). Compreende uma área de aproximadamente, 10.330 Km² contemplando 30 folhas, na escala 1:50.000, representando 3,7% da superfície do estado e, atualmente, abrange 34 municípios (IBGE, 2018).

A respeito dos aspectos demográficos, (LIMA, 2018) descreve que em 1973 a RMPA era composta originalmente por 14 municípios com uma população total de 1.531.257 habitantes, que representavam 23% da população total do estado do Rio Grande do Sul. No ano de 2010, segundo informações do Censo, a RMPA abrangia 32 municípios e a população total alcançou 3.978.470 habitantes, representando mais de 37% da população total do estado. Posteriormente, mais dois municípios foram inseridos na RMPA, aumentando para 4.032.062 o número de habitantes, representando aproximadamente 38%, da população do estado.

A expansão urbana é um processo que abrange vários fatores tais como políticos, ambientais e geográficos. Dessa forma, as modificações da paisagem vem resultando interesse em pesquisadores a respeito da expansão urbana e suas respectivas consequências, nas últimas décadas (GONÇALVES *et al.*, 2019).

No Brasil, estima-se que 84% da população do país esteja em áreas urbanas e como essa concentração está aumentando, certamente este valor crescerá ainda mais (IBGE, 2018).

Compreender as mudanças na expansão urbana é imprescindível, uma vez que esse fenômeno é capaz de resultar em um planejamento e desenvolvimento incerto nas cidades. Dados de satélite e de sensoriamento remoto possibilitam que esse monitoramento aconteça com precisão (SONDE; BALAMWAR; OCHAWAR, 2020).

A disponibilidade de terrenos e casas nos arredores das cidades, o aumento da população e o desenvolvimento industrial são alguns dos fatores que influenciam para que a expansão urbana aconteça aceleradamente. Pesquisar as dinâmicas de expansão urbana envolve alguns procedimentos importantes como definir a área de abrangência do estudo, escolher o satélite e sua resolução espacial e temporal, realizar o processamento das imagens de satélite utilizadas, entre outros (PADMANABAN et al., 2017).

Planejar as cidades acompanhando como as transformações urbanas acontecem é necessário. Nas próximas décadas haverá mais problemas de super adensamento nas cidades como por exemplo, ondas de calor, tempestades severas e o aumento do nível do mar, os quais aumentam os riscos ambientais causados pela expansão acelerada e mal planejada dos centros urbanos (IBGE, 2020).

A expansão urbana tem impactado excessivamente o mundo inteiro, resultando em muitas mudanças no uso e cobertura da terra, pois as superfícies terrestres estão sendo modificadas e substituídas por áreas urbanas (FORGET *et al.*, 2021).

As primeiras classificações de uso e cobertura da terra baseavam-se em trabalhos de campo e em meados da década de 1970 o monitoramento das mudanças do uso do solo começou a ser detectado e analisado através das imagens de satélite e técnicas de classificação (STEINER, 1970).

Esse estudo verifica o processo de expansão urbana da Região Metropolitana de Porto Alegre (RMPA), com o objetivo de explicar os padrões da expansão urbana através de uma análise espacial e temporal da área de estudo nas últimas três décadas, utilizando geotecnologias e técnicas de sensoriamento remoto. Além disso, também é realizada uma modelagem de uso e cobertura da terra (LULC) e elaboração de cenários futuros da mancha urbana utilizando a metodologia de *Artificial Neural Network* (ANN), onde o Modelo Digital de Elevação (MDE), relevo sombreado, declividade, distância da estrada, da estação ferroviária, dos centros urbanos e distância de Porto Alegre são os critérios usados como mapas de variáveis espaciais

nos processos de aprendizagem em um modelo *Multilayer Perceptrons* (MLP) para prever suas influências no LULC.

1.1 Objetivo geral

Analisar a mudança de uso e cobertura da terra na Região Metropolitana de Porto Alegre (RMPA) nos últimos 30 anos utilizando dados de sensoriamento remoto orbital focando na dinâmica espacial do crescimento das áreas urbanas para, posteriormente, modelar cenários futuros de expansão destas áreas.

1.1.1 Objetivos específicos

- Realizar a classificação de uso e cobertura da terra para os anos de 1991, 2000, 2010 e 2020 usando imagens dos satélites Landsat.
- Elaborar cenários futuros de LULC para os anos de 2030 e 2040 utilizando um modelo *Multilayer Perceptrons* (MLP) através de *Artificial Neural Network* (ANN).

2 ORGANIZAÇÃO DA DISSERTAÇÃO

O presente estudo está organizado em duas seções, sendo a primeira o referencial teórico sobre conceitos abordados e estudados para a elaboração do trabalho. A segunda parte consiste no desenvolvimento da dissertação composta por dois artigos intitulados:

- Artigo 1 – Análise espacial da expansão urbana na Região Metropolitana de Porto Alegre – RS, nos últimos 30 anos.
- Artigo 2 - Modelagem de uso e cobertura da terra e geração de cenários futuros da mancha urbana da Região Metropolitana de Porto Alegre – RS, utilizando *Artificial Neural Network* (ANN).

3 REFERENCIAL TÉORICO

Nesse capítulo o referencial bibliográfico é apresentado com a finalidade de realizar um embasamento teórico contextualizando os temas abordados na dissertação, com foco principal na metodologia utilizada.

3.1 Transformações na paisagem no decorrer do tempo

O estudo da paisagem busca entender a relação entre paisagem e tempo e a considera como algo correlacionado. Portanto, a existência da paisagem está associada ao tempo e às influências humanas (GINZBURG, 1989).

Assim, a paisagem apresenta constantes transformações ocorridas no espaço ao longo do tempo. Conforme Milton Santos (1988), as mudanças na paisagem possuem uma relação direta com o tempo e o autor ainda afirma que:

[...] a paisagem não é dada para todo o sempre, é objeto de mudança. É um resultado de adições e subtrações sucessivas. É uma espécie de marca da história do trabalho, das técnicas. [...] As casas, a rua, os rios canalizados, o metrô etc., são resultados do trabalho corporificado em objetos culturais. Não faz mal repetir: suscetível a mudanças irregulares ao longo do tempo, a paisagem é um conjunto de formas heterogêneas, de idades diferentes, pedaços de tempos históricos representativos das diversas maneiras de produzir as coisas, de construir o espaço (Santos, 1988, p.24).

Portanto, a paisagem constantemente passa por um processo de transformação que é resultante das ações do homem no meio em que habita. Nesse sentido, compreender as mudanças que ocorrem no solo é fundamental para um planejamento de como as cidades estão se expandindo. O Sensoriamento Remoto aliado às técnicas de Geoprocessamento, possibilita analisar as mudanças na paisagem através de estudos em imagens orbitais que proporcionam informações imprescindíveis para essa finalidade (MUSA; HASHIM; REBA, 2017), tais como a expansão de áreas urbanizadas.

A velocidade com que as cidades expandem resulta em inúmeros problemas urbanos, como a poluição ambiental e a ordem pública caótica (REBA; SETO, 2020). É possível minimizar esses problemas ocasionados pela expansão urbana através de planejamento ambiental, onde os tomadores de decisão devem fazer julgamentos precisos sobre a extensão da expansão urbana, estabelecendo assim os limites do desenvolvimento urbano (LI *et al.*, 2021). Por conseguinte, a simulação da expansão urbana tem sido interesse de pesquisa de muitos planejadores urbanos e funcionários do governo.

3.2 Classificação digital de imagens para mapeamento de LULC

As classificações de uso e cobertura da terra realizadas inicialmente eram feitas através de trabalhos de campo. No ano de 1950, muitos pesquisadores de vários lugares do mundo começaram a explorar estudos de identificação detalhada de fotografias aéreas e, a partir de 1970, iniciou o monitoramento das mudanças do uso da terra através das imagens de satélite por meio de técnicas de classificação (STEINER, 1970).

As técnicas de processamento digital de imagens (PDI) e os sistemas de informações geográficas (SIG) permitem a manipulação de dados aplicáveis em diversos estudos, como por exemplo em pesquisas de previsão ou simulação de determinados fenômenos. Além disso, essas ferramentas possibilitam a detecção de mudanças do uso e cobertura da terra no decorrer do tempo. Dessa maneira, o sensoriamento remoto possui muita utilidade em monitoramentos e mapeamentos ambientais (JENSEN, 1996).

As metodologias mais utilizadas em estudos para analisar o uso e cobertura da terra, usam a classificação de imagens orbitais através de técnicas pixel-a-pixel, árvore de decisão, redes neurais ou orientada a objetos e análises multitemporais de imagens para a detecção de mudanças baseados na classificação de imagens (LANG; BLASCHKE, 2009).

De acordo com CHANDER; MARKHAM; HELDER (2009), em estudos de detecção de mudanças de uso e cobertura da terra, é muito utilizada a série Landsat (*Land Remote Sensing Satellite*), disponibilizada gratuitamente para a comunidade

científica ela iniciou em 1972 com o lançamento do satélite ERTS-1. A série Landsat continuou com os Landsat 2, 3, 4 e posteriormente com o 5 e 7. Por último, em 2013 foi lançado o Landsat 8 e em 2022 o Landsat 9, ambos em atividade atualmente.

A principal finalidade do sistema Landsat foi o mapeamento multiespectral em alta resolução da superfície da Terra e suas imagens representam registros valiosos e contínuos da superfície terrestre nas últimas cinco décadas, significando uma riqueza de informações para identificar e monitorar mudanças no uso e cobertura da terra em escala global (CHANDER; MARKHAM; HELDER, 2009). Visto que, desde o ano de 1980, muitas pesquisas tem sido realizadas no intuito de tentar identificar e explicar os fatores que causam as mudanças no uso e cobertura da terra (ALLEN; BARNES, 1985; LAMBIN, 1994).

3.3 Modelagem da dinâmica da paisagem e modelos de simulação baseados em autômato celular

O Sensoriamento Remoto e o Geoprocessamento proporcionam avanços no monitoramento das transformações das paisagens e, com o uso de séries temporais, é possível compreender como acontecem essas dinâmicas.

Pesquisadores de diferentes áreas estudam e utilizam modelos de simulação, que por sua vez, são muito importantes pela sua capacidade de multiplicar modelos mentais independentemente de sua complexidade (SOARES-FILHO; ASSUNCÃO; PANTUZZO, 2001).

Existem modelos de simulação que são representados pelos métodos espaciais e simulam mudanças na paisagem a partir do território geográfico. A utilização desses modelos auxilia na compreensão das dinâmicas da paisagem e dos processos de desenvolvimento de sistemas ambientais.

Conforme SOARES-FILHO; ASSUNCÃO; PANTUZZO (2001), os modelos espaciais de simulação possuem grande importância no planejamento territorial. Esses modelos possibilitam a compreensão das alterações globais e suas consequências ao planeta, pois reproduzir padrões espaciais de mudanças, permitem o conhecimento de complexos temas ambientais em escala local, regional e global.

O autômato celular (CA) foi elaborado no início da computação digital pelo matemático John Conway em 1970, que o chamou de “jogo da vida” em razão da analogia com ascensão, queda e alternância de sociedades de organismos. Conway escolheu como regras locais de transição, arranjos espaciais que impossibilitassem que colônias de células morressem ou expandissem depressa. Assim sendo, os modelos de CA são utilizados em muitos estudos nos mais diferentes temas científicos e pertencem à classe de jogos de simulação que se assemelham a processos da vida real (WOLFRAM, 2002).

Os modelos de CA são formados por conjuntos de células nas quais reproduzem movimentos que consistem num arranjo de células, em que o estado de cada célula depende de seu estado prévio e de uma série de regras de transição, conforme um arranjo específico de uma certa vizinhança (SIRAKOULIS; KARAFYLLIDIS; THANAILAKIS, 2000).

Segundo BATTY (1997) os modelos de CA são compreendidos através de características específicas muito importantes, em que as células possuem relações espaciais de vizinhança. Cada célula apresenta um único estado em cada instante de tempo e o conjunto de estados define os atributos do sistema, o estado de cada célula depende dos estados e configurações das células vizinhas, existem regras de transição uniformes e locais que controlam as mudanças de cada célula.

Softwares de Sistemas de Informações Geográficas (SIG) disponibilizam modelos de simulação espacial baseados em autômatos celulares. Os modelos de CA são aplicados em estudos sobre expansão urbana (CLARKE; GAYDOS, 1998), e em pesquisas sobre mudanças de uso e cobertura do solo (SOARES-FILHO; ASSUNÇÃO; PANTUZZO, 2001).

Pesquisas realizadas anteriormente mostram que um modelo de CA é eficaz em processos de simulações geográficas complexas, principalmente no estudo de simulação espacial sobre mudanças urbanas. Na década de 1990, os modelos de CA começaram ser escolhidos por muitos estudiosos do mundo para simular o crescimento urbano (CLARKE; HOPPEN; GAYDOS, 1997).

Essas pesquisas revelaram a possibilidade de simular estruturas complexas a partir de várias regras previamente definidas, que proporcionam uma base para análises geográficas relevantes (LI; YEH, 2000).

A criação da tecnologia computacional proporcionou a entrada dos algoritmos de aprendizado de máquina nos estudos utilizando modelos de CA. Algoritmos como *Artificial Neural Network* (ANN) (LI; YEH, 2002), *Support Vector Machine* (SVM) (YANG; LI; SHI, 2008) e Algoritmo Genético (GA) (LI *et al.*, 2013), foram utilizados para lidar com as dificuldades na otimização de parâmetros dos modelos de CA. Tais métodos possibilitam otimizar os parâmetros do modelo alcançando o melhor resultado, o que resolve os complexos problemas de simulação associados as inúmeras variáveis espaciais.

3.4 Artificial Neural Network (ANN)

As redes neurais artificiais são técnicas que objetivam solucionar problemas complexos semelhante à maneira que o cérebro humano resolveria (MATHER, 1987). De acordo com HAYKIN (2001), uma *Artificial Neural Network* (ANN) é determinada como um processador massivo e paralelamente distribuído, constituído de unidades de processamento simples capaz de armazenar conhecimento experimental e torná-lo disponível para uso.

As redes neurais podem ser utilizadas como classificadores de imagens digitais, também na fase de pré-processamento, na etapa de classificação e até mesmo durante a etapa pós-classificatória, como filtros passa-baixa, essas são algumas das possíveis aplicações de ANN (HAYKIN, 2001).

O modelo ANN-CA possui múltiplos neurônios de saída para simular as mudanças de uso da terra. A camada de saída define as probabilidades de transição de variados usos da terra usando inúmeros neurônios de saída e os parâmetros necessários para a simulação são determinados automaticamente através de um treinamento de redes neurais (LI; YEH, 2002).

É imprescindível no modelo ANN-CA treinar a rede neural para obter valores de parâmetros baseados em dados empíricos. O modelo consegue trabalhar com as relações complexas entre as variáveis, pois as ANNs têm grande habilidade de mapeamento não linear (ALAM *et al.*, 2021).

Uma rede neural pode ser utilizada para classificar um conjunto de observações de diferentes variáveis. Além disso, possui uma camada de entrada, uma camada de saída e nenhuma ou algumas camadas ocultas. Também possuem neurônios conhecidos como nós que são as unidades básicas para processar sinais.

Cada neurônio aceita um único valor na camada de entrada que corresponde a um determinado elemento, então cada neurônio gera um valor de saída e esse valor pode ser usado como entrada para todos os neurônios da próxima camada. A importância dos pesos está em obter os pontos fortes da ligação de rede entre neurônios associados (GANTUMUR *et al.*, 2020).

Existem variados modelos de redes neurais, como por exemplo, as redes *Multilayer Perceptrons (MLP)*, formadas por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída em que os processamentos são realizados por funções matemáticas (HAYKIN, 2001).

Segundo LIPPMANN (1987), as redes MLP foram preparadas para solucionar problemas complexos que não poderiam ser resolvidos pelo modelo de neurônio básico. As redes neurais MLP têm sido frequentemente usadas no Sensoriamento Remoto (KANELLOPOULOS; WILKINSON, 1997).

As redes MLP conseguem aproximar virtualmente qualquer função de interesse para qualquer grau de precisão desejado, sempre que for possível definir uma taxa de convergência aceitável para o algoritmo de treinamento, avaliada pelos erros entre os resultados preditos e esperados (TSO; MATHER, 2001).

3.5 Redes *Multilayer Perceptrons (MLP)*

As redes *Multilayer Perceptrons* também chamada de *Perceptron* de Múltiplas Camadas (MLP), são um tipo de *Artificial Neural Network (ANN)* com aprendizagem supervisionada, que são frequentemente utilizadas na classificação de padrões e em problemas complexos com o algoritmo denominado retropropagação de erro em razão das suas regras de treinamento (HAYKIN, 2001).

As redes MLP são modelos não lineares organizados em várias camadas que mapeiam as entradas para as saídas desejadas, diminuindo os erros entre estas e as

saídas calculadas. A rede pode ser ajustada e melhorada variando o número de camadas e o número de unidades em cada camada. As MLPs podem ser treinadas com vários algoritmos diferentes, mas é mais comumente utilizado o *backpropagation*, onde todos os dados das camadas de entrada nas MLPs são passados para as camadas de saída (ZHAO; CUI; MURAYAMA, 2012).

Cada neurônio calcula um valor combinado que é o resultado da multiplicação dos valores nos nós da camada anterior pelos pesos de conexão entre os mesmos. Este valor é a entrada para uma função de ativação do nó, sendo uma função de ativação não linear, como uma função sigmoide (LOSIRI *et al.*, 2016).

A finalidade do treinamento é conseguir a combinação de pesos que resulte no menor erro do MLP. Na fase de treinamento, o MLP é apresentado com os dados de treinamento e os pesos na rede são ajustados até que ocorra o mapeamento de entrada e saída desejado. Dessa maneira, o MLP pode generalizar dados de entrada não vistos e o treinamento se torna fundamental para compreender a natureza dos dados específicos (ZHAO; CUI; MURAYAMA, 2012).

O treinamento ensina as redes a distinguir padrões de entrada e respostas de saída. Os dados de calibração podem ser divididos em dois tipos de treinamento e amostras de teste. Alguns fatores influenciam as capacidades da rede para generalizar e interpolar dados que a rede não notou anteriormente como os números de nós e arquitetura, o tamanho das amostras de treinamento e a taxa de aprendizado (HAYKIN, 2001).

O interesse no uso de MLPs é resultado de sua capacidade de gerar limites de decisão não lineares e de generalizar entradas, bem como aprender padrões complexos. Os métodos estatísticos dependem do modelo, mas uma rede neural depende de dados. Além disso, as redes neurais são adequadas para integrar dados de diferentes fontes. Todas as aplicações de MLPs podem ser descritas como classificação de padrões, predição e aproximação de funções. Uma aplicação muito importante de um MLP é a classificação de padrões (OZTURK, 2015).

Vale ressaltar que nos MLPs, a quantidade de neurônios da primeira camada coincide com o número de atributos dos dados de entrada e o número de neurônios da camada de saída condiz com a quantidade de classes a serem mapeadas (LOSIRI *et al.*, 2016).

Em uma pesquisa foi realizada a comparação entre métodos de classificação e observaram que as redes neurais *Multilayer Perceptron* (MLP) obtiveram 97% de precisão enquanto que ARTMAP Fuzzy e *Linear Discriminant Analysis* (LDA) tiveram 92% e 85%, respectivamente na classificação de imagens orbitais (LI *et al.*, 2013).

Por último, ressalta-se que a rede MLP possui um grande poder computacional em consequência de suas características estruturais e sua habilidade de aprendizado através do treinamento. Por este motivo, o uso de redes neurais artificiais vem sendo aplicado em muitas pesquisas em diferentes escalas territoriais (AL-HAMEEDI *et al.*, 2021).

4 DESENVOLVIMENTO

4.1 Artigo 1 - Análise espacial da expansão urbana na Região Metropolitana de Porto Alegre – RS, nos últimos 30 anos.

RESUMO

A expansão urbana acelerada sem planejamento causa diversos problemas para a sociedade e o meio ambiente. Consequentemente, é importante compreender a dinâmica destes processos de crescimento destas áreas. Nesta pesquisa é realizado o mapeamento dos últimos 30 anos de mudanças de uso e cobertura do solo em Porto Alegre, a capital do estado do Rio Grande do Sul, e sua Região Metropolitana (RMPA). As características espaço-temporais e os mecanismos de condução de expansões urbanas nesta região são ainda mal compreendidos e o objetivo desta pesquisa é compreender como este processo vem ocorrendo ao longo dos anos, através de dados de sensoriamento remoto e análises espaciais. O levantamento foi realizado para os anos 1991, 2000, 2010 e 2020 utilizando imagens dos satélites Landsat e demonstrou que a RMPA experimentou uma expansão urbana sem precedentes aumentando em 4.495 km² sua área territorial, sendo Porto Alegre e Canoas os municípios com maior taxa de expansão. A acurácia dos mapeamentos realizada através do coeficiente Kappa, foi respectivamente de 0,83, 0,81, 0,84 e 0,82 para os anos em estudo, as quais podem ser consideradas como excelentes. Os resultados indicam que a forma de expansão mais frequente na área de estudo é na borda de áreas já urbanizadas totalizando 562 km² e aproximadamente 81% de todo o crescimento urbano na RMPA nos últimos 30 anos. Houve a expansão de áreas urbanas isoladas em cerca de 17% e dentro de áreas já urbanizadas em 2%, sendo esta em sua maior parte nos municípios de Guaíba, Eldorado do Sul e Triunfo. A gestão urbana detalhada e as políticas de planejamento devem ser feitas considerando a heterogeneidade espacial e interna. A compreensão desses resultados auxilia os formuladores de políticas no planejamento de cidades resilientes no futuro.

Palavras-chave: Sensoriamento remoto; Classificação supervisionada, Áreas Urbanas.

INTRODUÇÃO

A expansão urbana é o tipo de mudança de solo mais frequentemente monitorado por ser na maioria dos casos irreversível (REBA; SETO, 2020), ou seja, uma área florestal ou agrícola quando é transformada em área urbana dificilmente retornará ser sua classe de origem. Por este motivo, a avaliação da adequação do uso da terra é considerada um pré-requisito para o planejamento de áreas urbanas (RAMYA; DEVADAS, 2019).

A expansão urbana é considerada a expressão mais evidente da mudança na cobertura do solo em todo o mundo (LI *et al.*, 2021). Ao analisar este processo, pesquisas levam em consideração a atividade social e dados demográficos de uma área de interesse (GONÇALVES *et al.*, 2019).

De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), o mapeamento de uso e cobertura da terra no Brasil objetiva acompanhar o estágio de crescimento destas áreas urbanizadas. Esse mapeamento obtido com uso de imagens de satélite resulta em uma camada vetorial que delimita as áreas construídas das cidades do país, acatando a uma demanda crescente da sociedade e do Estado que buscam entender o histórico de expansão das cidades e compreender suas dinâmicas geográficas (IBGE, 2018).

Nas últimas décadas, um processo de urbanização sem precedentes ocorreu globalmente. De 1900 a 2018, a taxa de população global residindo em áreas urbanas aumentou de 10% para mais do que 55% (ONU, 2019). Este rápido processo sem planejamento intensifica a degradação ambiental e deteriora a qualidade de vida (MUGIRANEZA; BAN; HAAS, 2019). Dentre vários fatores, pode se considerar o aumento populacional uma das principais causas da expansão urbana (PAIVA *et al.*, 2020). De acordo com as Nações Unidas (UNESCO, 2018), um pouco mais da metade da população mundial reside em áreas urbanas e estimativas revelam que esse percentual é capaz de atingir 68% até 2050.

Em 2030 cerca de 9% da população mundial viverá em megacidades, isto é, áreas urbanas com 10 milhões de habitantes ou mais (ONU, 2019). Sabendo que a expansão urbana influencia na mudança do uso do solo e que pode vir a ocasionar problemas ecológicos e humanos, o primeiro passo para encontrar possíveis soluções é planejar a dinâmica de sua expansão.

Diversas pesquisas enfatizam sobre a importância de estudos para verificar essas dinâmicas de expansão urbana bem como as suas consequências, dentre as inúmeras pesquisas pode-se destacar (ALJOUFIE *et al.*, 2013) que analisou espaço-temporalmente o crescimento urbano na cidade de Jeddah na Arábia Saudita; (CLARKE; HOPPEN; GAYDOS, 1997) que elaborou um modelo de autômatos celulares histórico para a urbanização na área da Baía de São Francisco nos EUA; e (DUBOVYK; SLIUZAS; FLACKE, 2011) que estudou como a modelagem espaço-

temporal interfere no desenvolvimento de assentamentos informais no distrito Sancaktepe, Istambul, na Turquia.

Roberto Ferreira Tavares, coordenador de Estruturas Territoriais do IBGE, enfatiza que desde o último Censo Demográfico em 2010, o território brasileiro passou por grandes transformações decorrentes do processo de ocupação territorial (IBGE, 2020). E o avanço das geotecnologias possibilita a utilização de dados de sensoriamento remoto na modelagem da expansão urbana, uma vez que se faz possível unir modelos estatísticos, algoritmos e dados remotos (BERBEROĞLU; AKIN; CLARKE, 2016).

A rápida expansão urbana, sobretudo nos países em desenvolvimento, provoca a necessidade da modelagem a fim de prever a expansão e o sensoriamento remoto possui as ferramentas qualificadas para esse fim (SAXENA; JAT, 2019). Um monitoramento adequado deste processo é útil para o poder público, pois facilita o seu controle e planejamento (BATTY, 1997).

Os avanços tecnológicos como o sensoriamento remoto e informações geográficas, permitem acompanhar e monitorar a dinâmica da expansão urbana através de modelagem e simulação de processos (GONÇALVES et al., 2019). O processo de urbanização e o crescimento acelerado das cidades têm despertado interesses nos mais diversos setores sociais, principalmente no meio acadêmico, levando estudiosos das mais variadas áreas do conhecimento a tentar compreender e explicar este fenômeno.

Dados procedentes de sensoriamento remoto, em conjunto com técnicas de geoprocessamento, podem proporcionar melhorias no monitoramento contínuo das transformações das paisagens. Dessa maneira, através do uso de séries temporais torna-se possível compreender as mudanças ao longo do tempo bem como entender sua estrutura e dinâmica.

A classificação digital de imagens de satélite é o procedimento em que, a partir de dados observados se obtém uma imagem em que é atribuído um rótulo para cada classe de uso, o que é realizado através do agrupamento dos pixels de uma feição específica, ou seja, são identificadas regiões que apresentam características semelhantes em relação ao uso e ocupação do solo (ABBURU; BABU GOLLA, 2015).

O mapeamento de uso e cobertura do solo realizado para todo Brasil pelo projeto MapBiomass, mostra que as maiores áreas urbanizadas do país em 2020 estão

localizadas nas capitais de São Paulo - SP, Rio de Janeiro - RJ, Curitiba - PR, Goiânia - GO, Belo Horizonte - MG, Fortaleza - CE e Porto Alegre – RS (MAPBIOMAS, 2021).

Nesse estudo é analisado o caso específico da Região Metropolitana de Porto Alegre (RMPA) que é uma das maiores concentrações urbanas do Brasil, com 4,4 milhões de habitantes e é considerada uma área importante para esse estudo de análise histórica da mudança de uso e cobertura do solo devido ao fato de estar expandindo consideravelmente nas últimas décadas (IBGE, 2020).

Portanto, visando compreender o processo de expansão urbana de forma conjunta e em particular para cada município de acordo com o seu ano de inserção na RMPA o objetivo desta pesquisa é verificar os seus padrões através de uma análise espacial e temporal da área de estudo nas últimas três décadas, utilizando geotecnologias e técnicas de sensoriamento remoto.

METODOLOGIA

Área de estudo

A área de estudo é a Região Metropolitana de Porto Alegre (RMPA) (Figura 1), localizada no estado do Rio Grande do Sul. A RMPA foi criada em 1973 pela Lei Complementar Federal nº. 14/73 e é constituída atualmente por 34 municípios contendo área total de 10.334 km² sendo a quinta região metropolitana mais populosa do país (SECRETARIA DE PLANEJAMENTO, 2020).

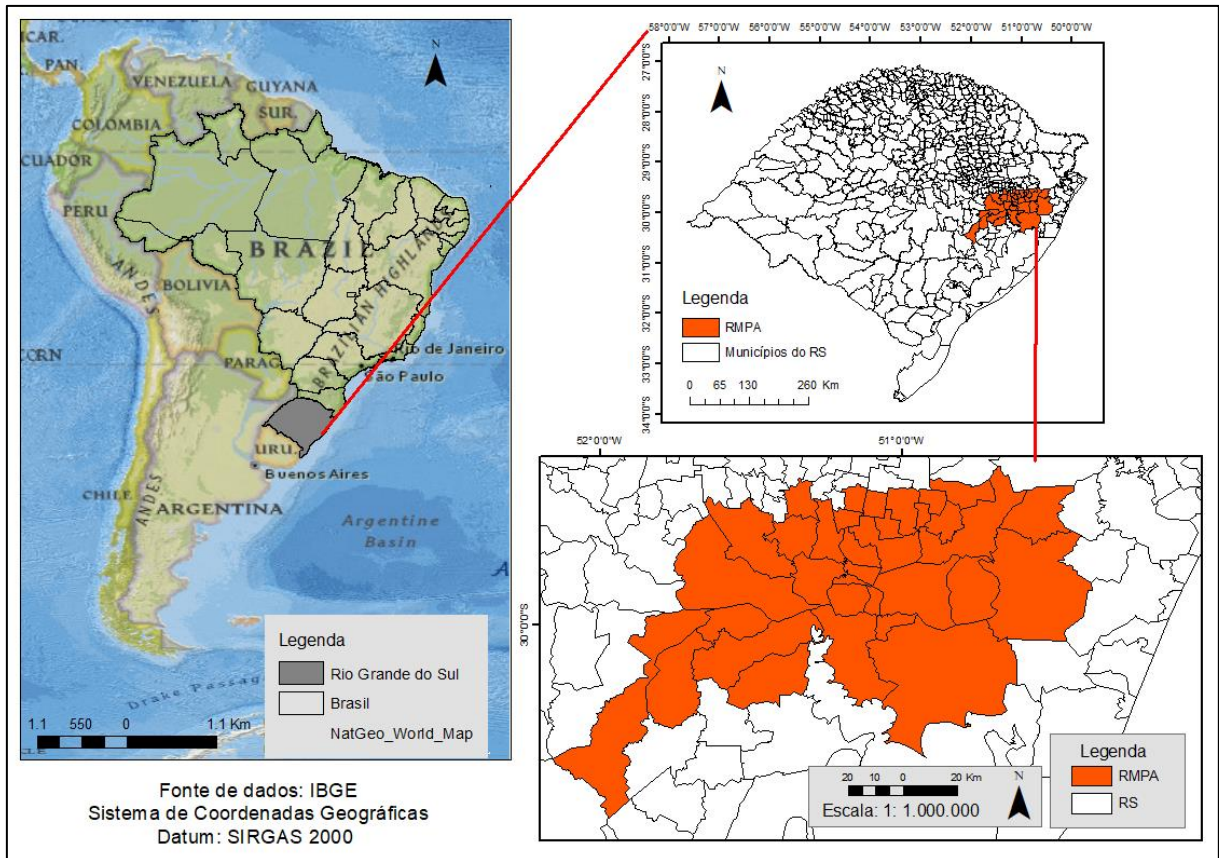


Figura 1 - Localização da Região Metropolitana de Porto Alegre.

Dentre os municípios que atualmente fazem parte da RMPA, vale ressaltar que nem todos foram inseridos no mesmo período (Figura 2), e cada um deles possui características diferenciadas de acordo com a sua população, área, densidade e Produto Interno Bruto (PIB) (Tabela 1).

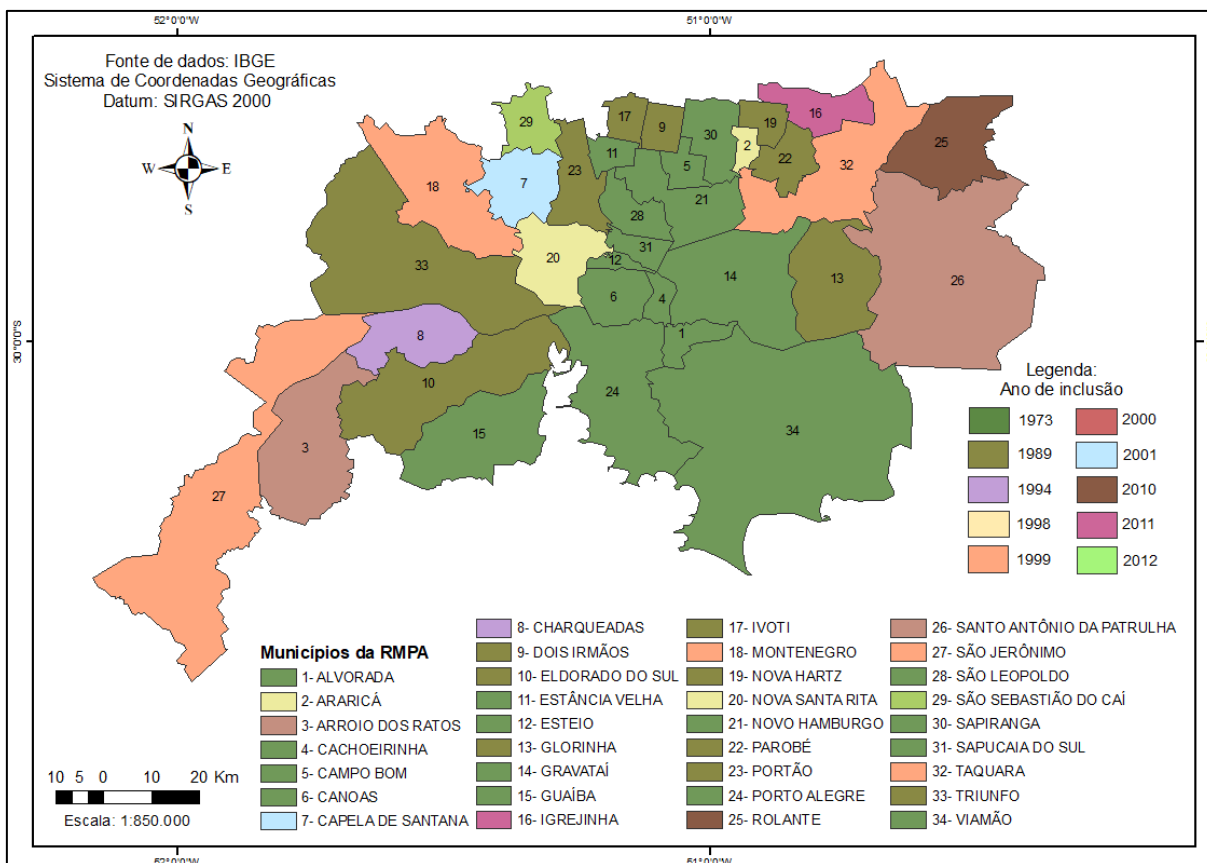


Figura 2 - Configuração territorial da RMPA em 2020.

Considerando a participação dos municípios no PIB per *capta* da RMPA (Tabela 1), em 2019 Porto Alegre, concentrava 38,40% do PIB, seguido de Canoas, com 14,76%, e somadas à participação dos municípios de Gravataí (6,32%), Triunfo (5,15%), Novo Hamburgo (4,81%), Cachoeirinha (3,89%), São Leopoldo (3,68%), Esteio (2,29%) e Guaíba (2,20%) chega-se a 81,52% do PIB metropolitano. Entre os municípios com menor participação encontram-se Capela de Santana, com 0,10%, e Araricá, com 0,06%.

Tabela 1 - Características dos municípios da RMPA.

Ano de inclusão na RMPA	Municípios	População (hab) 2010	Área (km²)	Densidade (hab/km²) 2010	PIB per capita (R\$ 1.000,00) 2019
1973	Alvorada	195.673	71,31	2.743,94	13.520,93
1973	Cachoeirinha	118.278	44,02	2.687,04	43.649,77
1973	Campo Bom	60.074	60,51	992,79	48.004,71
1973	Canoas	323.827	131,10	2.470,15	59.519,12
1973	Estância Velha	42.574	52,15	816,42	30.854,19
1973	Esteio	80.755	27,68	2.917,87	41.305,97
1973	Gravataí	255.660	463,50	551,59	44.034,18
1973	Guaíba	95.204	376,95	252,57	65.607,03
1973	Novo Hamburgo	238.940	223,82	1.067,55	39.592,60
1973	Porto Alegre	1.409.351	496,68	2.837,53	55.555,39
1973	São Leopoldo	214.087	102,74	2.083,82	42.740,23
1973	Sapiranga	74.985	138,31	542,14	42.829,26
1973	Sapucaia do Sul	130.957	58,31	2.245,91	25.082,24
1973	Viamão	239.384	1.497,02	159,91	15.830,63
1989	Dois Irmãos	27.572	65,16	423,17	63.947,67
1989	Eldorado do Sul	34.343	509,73	67,38	52.785,94
1989	Glorinha	6.891	323,64	21,29	32.951,24
1989	Ivoti	19.874	63,15	314,71	40.758,91
1989	Nova Hartz	18.346	62,56	293,26	31.759,49
1989	Parobé	51.502	108,65	474,03	23.180,55
1989	Portão	30.920	159,89	193,38	34.120,19
1989	Triunfo	25.793	818,80	31,50	283.449,62
1994	Charqueadas	35.320	216,51	163,13	33.757,46
1998	Araricá	4.864	35,29	137,83	33.932,70
1998	Nova Santa Rita	22.716	217,87	104,26	61.968,54
1999	Montenegro	59.415	424,01	140,13	60.162,81
1999	São Jerônimo	22.134	936,38	23,64	25.171,99
1999	Taquara	54.643	457,86	119,35	24.898,78
2000	Arroio dos Ratos	13.606	425,93	31,94	18.980,09
2000	Santo Antônio da Patrulha	39.685	1.049,81	37,80	33.598,69
2001	Capela de Santana	11.612	183,76	63,19	19.045,97
2010	Rolante	19.485	295,64	65,91	30.611,38
2011	Igrejinha	31.660	135,86	233,03	52.771,02
2012	São Sebastião do Caí	21.932	111,44	196,81	27.962,06

Fonte: Adaptação da Secretaria de Planejamento, Governança e Gestão (2021).

Cada uma das etapas da metodologia realizadas para a efetivação dessa pesquisa será descrita com mais detalhamento a seguir e pode ser visualizada no fluxograma da (Figura 3).

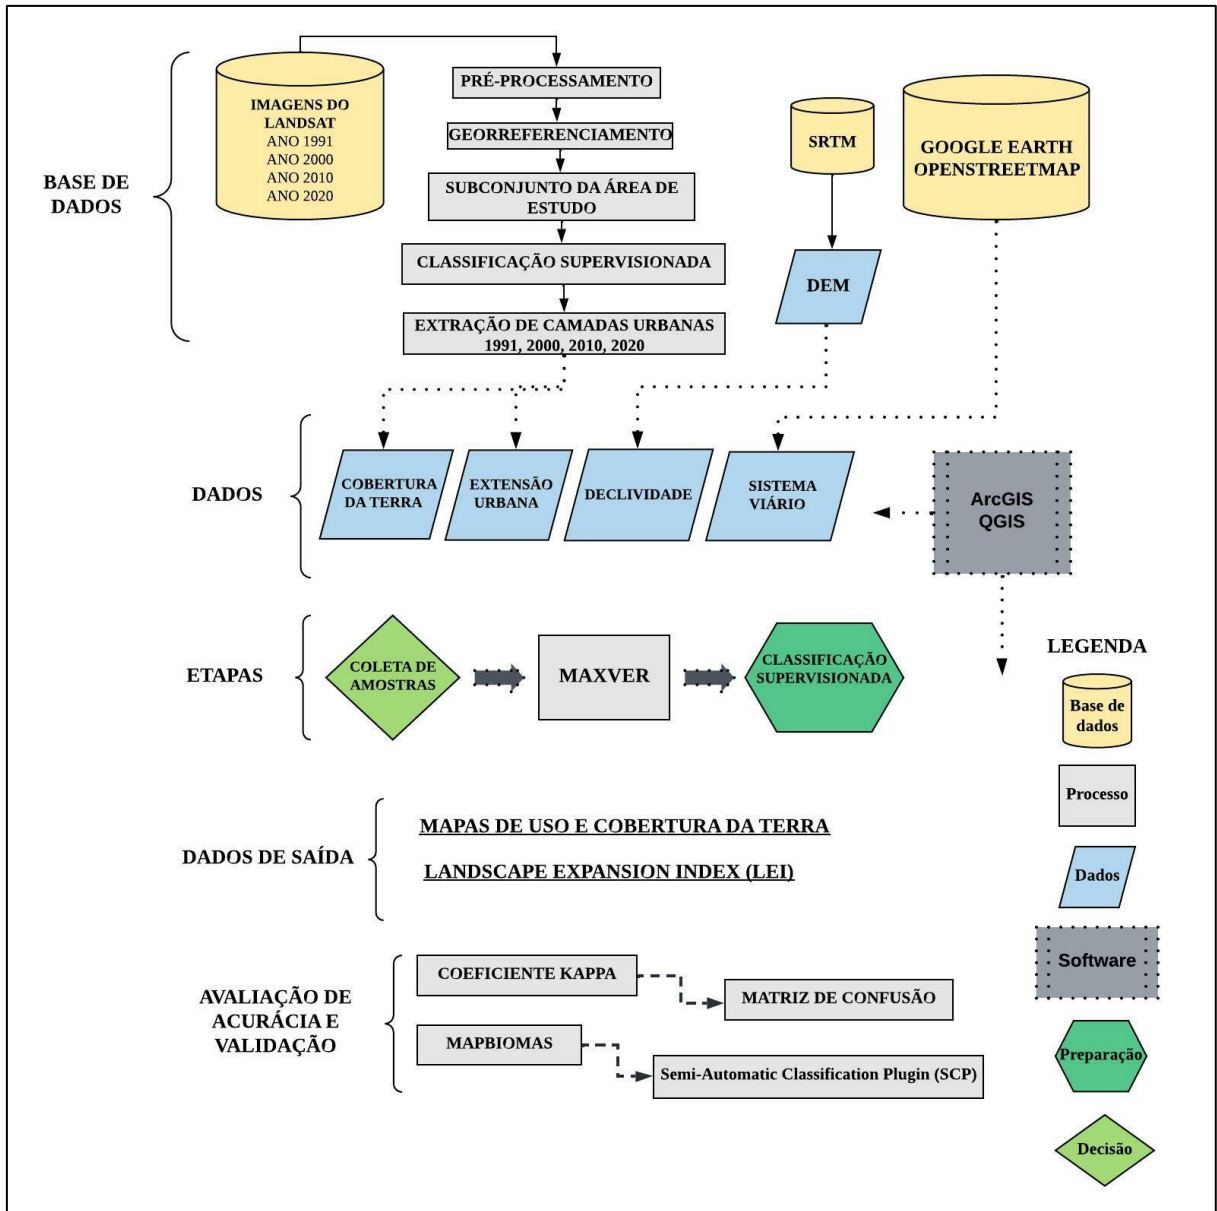


Figura 3 - Fluxograma da metodologia.

Conjunto de dados e pré-processamento

Para a elaboração dos mapas temáticos, foram adquiridas imagens dos satélites Landsat e processadas diretamente no *Living Atlas* dentro do software ArcGIS PRO, onde as imagens são disponibilizadas com correções atmosféricas e não se faz necessário o seu *download*, uma vez que o processamento é realizado na

nuvem. Foram então escolhidas imagens Landsat com resolução espacial de 30 metros de diferentes anos com menos de 10% de presença de nuvens (Quadro 1).

Quadro 1 - Imagens dos satélites Landsat.

Satélite	Sensor	Resolução (m)	Cenas	Data	Cobertura de Nuvens
Landsat 5	TM	30 x 30	84790	23/08/1991	0%
			84789	16/09/1991	0%
Landsat 7	ETM+	30 x 30	77412	24/02/2000	0%
			77411	15/06/2000	0%
			59087	07/05/2010	0%
Landsat 5	TM	30 x 30	10416	05/05/2010	0%
Landsat 8	OLI	30 x 30	3524712	09/02/2020	0,05%
			3577558	02/05/2020	0,46%

Fonte: *Living Atlas*.

Posteriormente, foram elaboradas as composições falsa-cor para auxiliar na interpretação do processo de classificação supervisionada, onde foi utilizada a composição R4G3B2 para as imagens do Landsat 5 e Landsat 7, e R5G4B3 para as imagens do Landsat 8. A escolha dos anos de obtenção das imagens neste estudo é coincidente com os anos em que foi realizado o Censo Demográfico para todo o Brasil pelo IBGE, com exceção para o último ano de 2020. Vale ressaltar que o censo que deveria ter ocorrido em 2020 ainda não foi realizado devido à diversos fatores, dentre eles a pandemia de COVID-19 e questões orçamentárias (CANO; UCHÔAS; GALLINA, 2021) e é esperado que aconteça até o final de 2022.

Classificação das imagens

Essa pesquisa utilizou o classificador de máxima verossimilhança (MAXVER) como metodologia de classificação supervisionada das imagens de satélite. Este classificador é considerado um dos mais utilizados em mapeamentos de uso e cobertura do solo (YADAV; GHOSH, 2019). O algoritmo se baseia na probabilidade de um pixel pertencer a uma determinada classe, pressupõe que as classes têm a mesma probabilidade e as bandas possuem distribuição normal (JENSEN, 1996).

Para a realização da classificação supervisionada é imprescindível que o analista determine as classes de informação de seu interesse, assim o *software* compara cada pixel da imagem com as classes determinadas pelo analista e o rotula

com o nome da classe que mais se assemelha. Sendo assim, para auxiliar o processo de classificação foram coletadas manualmente neste estudo 250 amostras de cada classe observada na imagem colorida, obtidas através da percepção do analista e comparadas com as suas respectivas áreas no *Google Earth Pro*.

Dessa forma, realizou-se a classificação da cena com base na semelhança de cada pixel com as classes fornecidas nas amostras. Para este estudo foram definidas cinco classes de uso e cobertura da terra, são elas: corpo hídrico, solo exposto, urbanização, vegetação arbórea e vegetação rasteira.

No método de classificação supervisionada de máxima verossimilhança (MAXVER) foram selecionadas amostras de treinamento em diferentes locais para cada classe de uso e cobertura da terra, através de um arquivo de assinatura abrangendo as estatísticas multivariadas de cada classe (BAKR; MORSY; YEHA, 2022).

Validação do mapeamento do uso e cobertura do solo

Independentemente do método utilizado na classificação das imagens, é necessário realizar testes de validação para verificar a acurácia dos resultados encontrados. Por este motivo, a verificação da acurácia da classificação deste trabalho, foi avaliada através do coeficiente Kappa, muito indicado na avaliação da classificação de imagens de sensoriamento remoto, por considerar os erros de comissão e omissão utilizando uma matriz de confusão para cruzar as informações estimadas com informações reais, gerando um resultado que varia de 0 a 1 e que indica a probabilidade de um pixel de referência ser classificado corretamente (G; GREEN, 2019).

Após três testes com diferentes quantidades de pontos aleatórios gerados, observou-se que densidades menores podem superestimar os resultados devido à pouca quantidade de amostras, sendo indicado a utilização de mais pontos amostrais. Assim, para o cálculo do coeficiente Kappa foram utilizadas as densidades amostrais com 250 pontos distribuídos de forma aleatória e assim foram geradas as matrizes de confusão para cada ano de estudo. As análises realizadas foram processadas nos *softwares* ArcGis versão 10.5, ArcGIS Pro, e QGIS 3.16. e 2.18.

Para cada ano mapeado foi gerada uma matriz de confusão com valores como as acurácias do usuário, que são as estimativas das frações de pixels do mapeamento, para cada classe, corretamente classificados e está associada ao erro de comissão, que é o erro cometido ao atribuir um pixel à uma determinada classe, quando este pertence a outra classe (DE JESUS; KUPLICH, 2021).

Além disso, foram obtidas as acurácias do produtor, que são as frações amostrais de pixels de cada classe corretamente atribuídos às suas classes pelos classificadores e está associada ao erro de omissão, que ocorre quando deixamos de mapear um pixel na classe correta. Essas métricas estão associadas à sensibilidade do classificador, ou seja, a capacidade de distinguir corretamente determinada classe entre as demais (FERRAZ; VICENS, 2019).

A Acurácia Global, por sua vez, é a estimativa da proporção de acerto global dos classificadores e também foi um importante resultado, estimando a proporção de acerto global dos classificadores. Assim, as matrizes de confusão expressam os acertos e erros de cada classe. Analisa-se no (Quadro 2) as definições dos resultados do coeficiente Kappa obtidos para os algoritmos Máxima Verossimilhança.

Quadro 2 - Definições dos valores de Coeficiente Kappa.

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

Fonte: (FONSECA, 2000).

Além do processo de validação citado anteriormente, também foi realizada a comparação e avaliação das classes de uso e cobertura do solo dos anos de 1991, 2000, 2010 e 2020 na RMPA obtida na classificação com os dados da coleção 6 do projeto MapBiomas. Este projeto cobre o período de 1985 a 2020 e foi iniciado em 2015 com objetivo de desenvolver uma metodologia confiável e de baixo custo para produzir séries anuais de uso e cobertura da terra em todo território brasileiro (MAPBIOMAS, 2021).

Ambos os mapeamentos utilizam imagens dos satélites Landsat, com resolução espacial de 30 metros, no entanto, o MapBiomas utiliza o método de

classificação *Random Forest* para identificar 25 tipos de uso e cobertura do solo. Todavia, na RMPA foram identificadas 15 classes nos anos em estudo, que foram agrupadas posteriormente em cinco classes de acordo com o (Quadro 3) para que os resultados pudessem ser comparados.

Quadro 3 - Classes de LULC deste estudo e as classes agrupadas do MapBiomas.

Classes do MapBiomas	Classes de uso da terra	Descrição
Campo Alagado e Área Pantanosa; Praia, Duna e Areal; Rio, Lago e Oceano;	Corpo Hídrico	Mananciais hídricos como rios, açudes, riachos, entre outros.
Outras Áreas não vegetadas; Afloramento Rochoso;	Solo Exposto	Sem cobertura vegetal.
Área Urbanizada	Urbanização	Residencial, comercial, industrial e outras áreas urbanas.
Formação Florestal; Silvicultura;	Vegetação Arbórea	Florestas, arbustos e outros.
Formação Campestre; Pastagem; Mosaico de Agricultura e Pastagem; Arroz; Soja; Mineração; Outras Lavouras Temporárias.	Vegetação Rasteira	Pequenos arbustos, gramíneas, campos de cultivo, entre outros.

A validação do mapeamento de uso e cobertura do solo foi realizada através do *Semi-Automatic Classification Plugin* (SCP) do *software* QGIS 3.16 que apresenta desempenho adequado para validar mapeamentos de uso e cobertura da terra (PEREIRA; GUIMARÃES, 2018). A comparação entre os mapas de LULC teve foco na área total de cada tipo de uso da terra, visando avaliar as taxas de aumento ou redução dos diferentes usos ao longo dos anos.

Este *plugin* conceitualmente utilizado, fornece um conjunto de ferramentas eficientes e uma interface de usuário que automatizam as fases de classificação da cobertura do solo e validação desde o *download* de imagens de sensoriamento remoto até o processamento (CONGEDO, 2021).

Métricas espaciais da expansão urbana

De acordo com a relação entre áreas urbanas novas e antigas, as formas de expansão urbana são divididas principalmente em três tipos: novas áreas urbanas criadas dentro de vazios urbanos chamados de *infilling*, novas áreas urbanas criadas

em adjacências com áreas urbanas já consolidadas chamadas de *edge-expansion* e novas áreas urbanas criadas separadamente das antigas áreas urbanas, chamadas de *outlying* (LIU *et al.*, 2010).

Nesse estudo, para identificar os diferentes tipos de expansão de áreas urbanas foi utilizado o índice de expansão da paisagem, em inglês, *Landscape Expansion Index* (LEI) que é calculado de acordo com a (Equação 1).

$$LEI = \frac{S}{S+Sv} \times 100 \quad (1)$$

Onde S é a área de interseção entre a área do buffer da nova mancha e as manchas já existentes, Sv refere-se à área da categoria vaga na área do buffer e a distância do buffer para este estudo foi definida em 200 metros.

As formas de expansão urbana são classificadas como *outlying*, *infilling*, e *edge-expansion* quando resultam em um $LEI = 0$, $LEI > 50$ e $0 < LEI < 50$, respectivamente. Dessa maneira, a forma de expansão urbana compreendida como *infilling* é definida por um LEI maior que 50, *edge-expansion* definida por um LEI menor que 50, mas não igual a zero, e as manchas classificadas como zero são as *outlying* (JIAO; MAO; LIU, 2015).

O índice LEI é utilizado para classificar os tipos de crescimento urbano com dados de sensoriamento remoto multitemporal, isto é, objetiva fornecer um conhecimento mais aprofundado sobre os padrões da paisagem e da dinâmica temporal. O LEI varia na faixa de 0 a 100 e é aplicado a partir da análise de buffer, que é uma importante função de análise espacial (LIU *et al.*, 2014).

RESULTADOS

Análise da mudança espaço-temporal do uso e cobertura do solo na RMPA nos últimos 30 anos

Os resultados do mapeamento de uso e cobertura da terra para a região metropolitana de Porto Alegre de acordo com os municípios que faziam parte da mesma nos anos de 1991, 2000, 2010 e 2020 são apresentados nas (Figuras 4, 5, 6

e 7). A área total e a porcentagem de cada classe de uso e cobertura da terra, para os anos em estudo, são demonstradas na (Tabela 2).

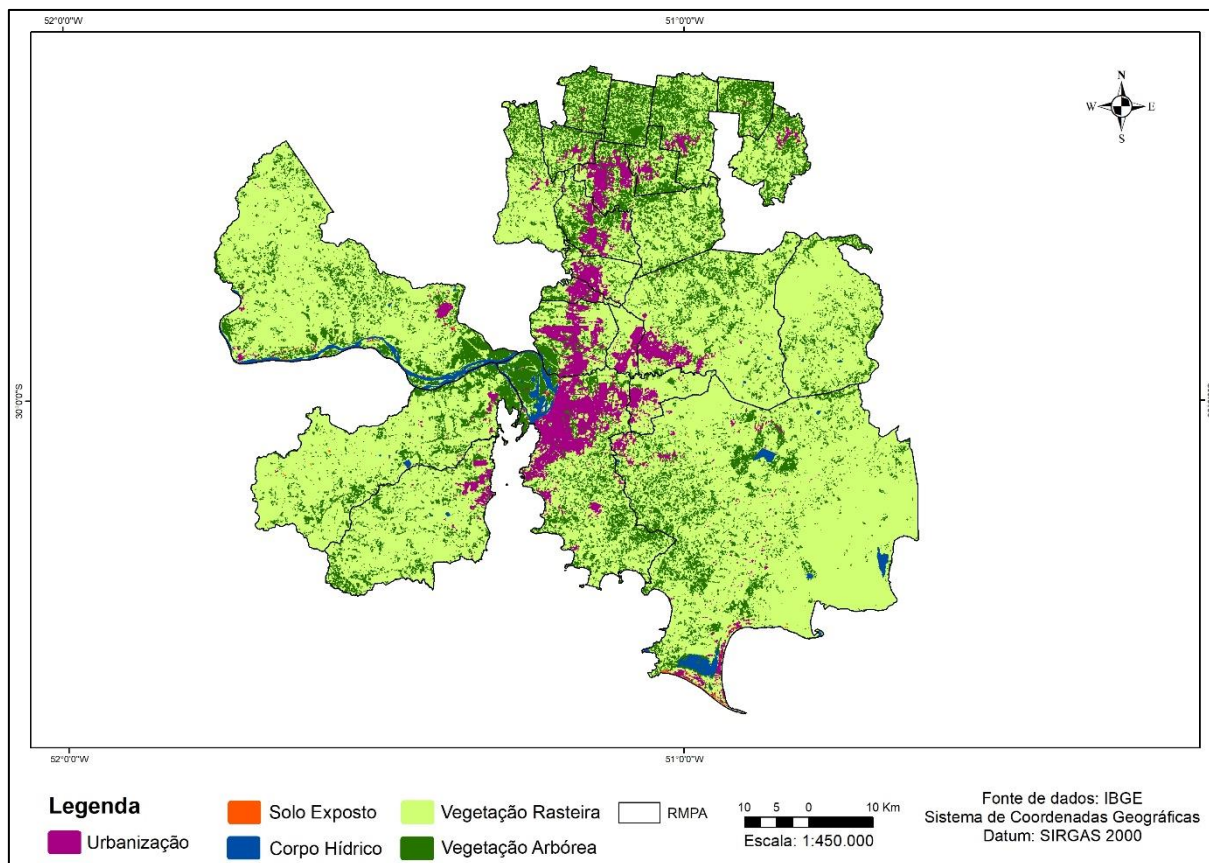


Figura 4 - Mapa de LULC dos municípios que faziam parte da RMPA em 1991.

A área territorial da RMPA em 1991 era 5.839,7 km², deste total 357,1 km² já eram áreas construídas, cerca de 6% do território. Em 2000 com a inserção dos demais municípios a área territorial passou a ser 7.648,9 km² com 377,5 km² de área construída totalizando cerca de 5% da área total. Isto demonstra que apesar das áreas urbanas terem aumentado mais de 20 km² na RMPA neste período, sua porcentagem diminuiu, pois, a área territorial de outras classes de uso do solo expandiu-se de forma mais acentuada.

Compreende-se que entre 1991 e 2000 a RMPA ganhou 1.809,2 km² de território ao incorporar os municípios Charqueadas (1994), Araricá (1998), Nova Santa Rita (1998), Montenegro (1999), Taquara (1999) e São Jerônimo (1999). Enfatizando que Araricá e Nova Santa Rita são municípios criados a partir de desmembramentos territoriais dos municípios Sapiranga, Nova Hartz e Canoas que já pertenciam à

RMPA. O município de Charqueadas, criado em 1982 através de parte do município de São Jerônimo, foi inserido na RMPA em 1994 (Figura 5).

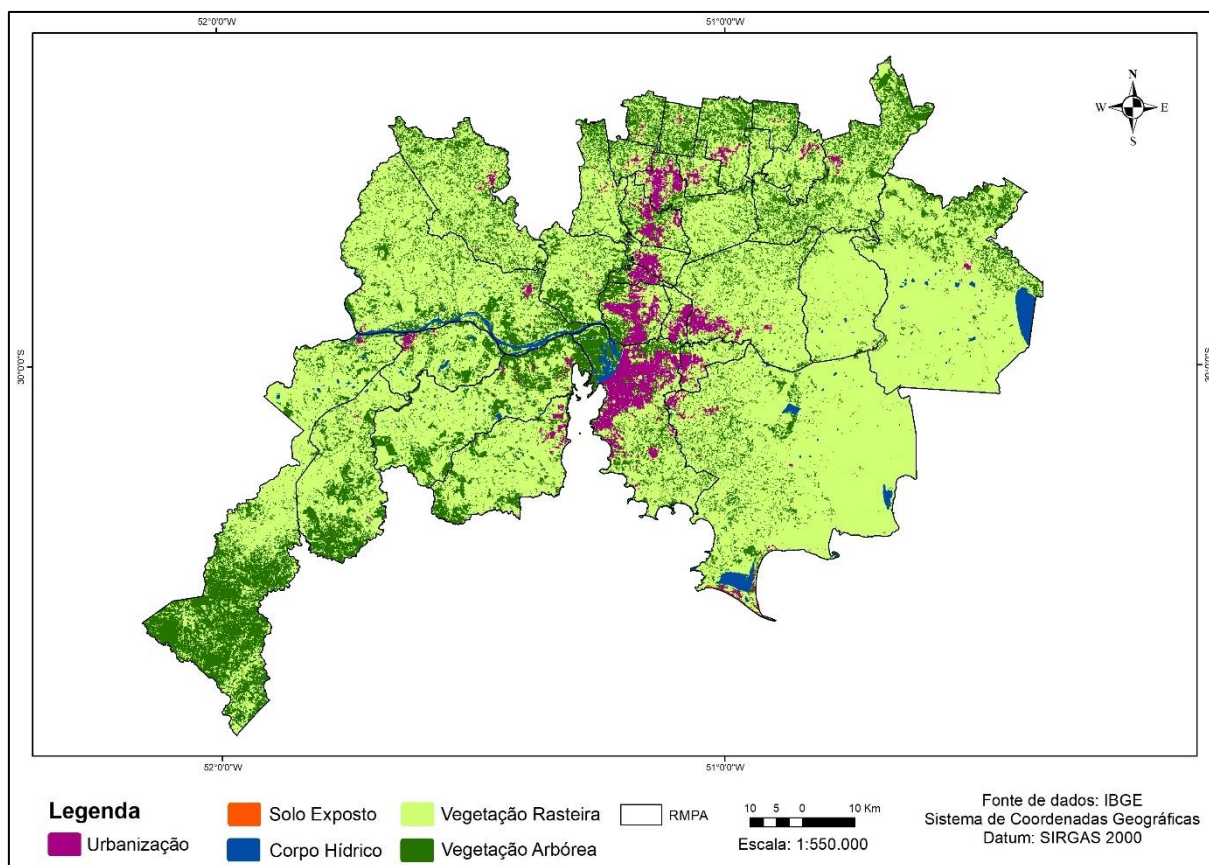


Figura 5 - Mapa de LULC dos municípios que faziam parte da RMPA em 2000.

Entre 2000 e 2010 a área de estudo aumentou 2.448,1 km² de território ao integrar os municípios Arroio dos Ratos (2000), Santo Antônio da Patrulha (2000) e Capela de Santana (2001). O município Capela de Santana foi criado em 1987 do desmembramento de parte dos territórios dos municípios de Portão e Canoas, que já pertenciam ao território metropolitano. E mais recentemente, a partir de 2010, foram incluídos Rolante (2010), Igrejinha (2011) e São Sebastião do Caí (2012), resultando em um aumento de 237,7 km² de território na RMPA. Em 2010 com 32 municípios, a RMPA totalizava 10.097 km², sendo que 463,5 km² eram de áreas construídas, cerca de 5% do território (Figura 6).

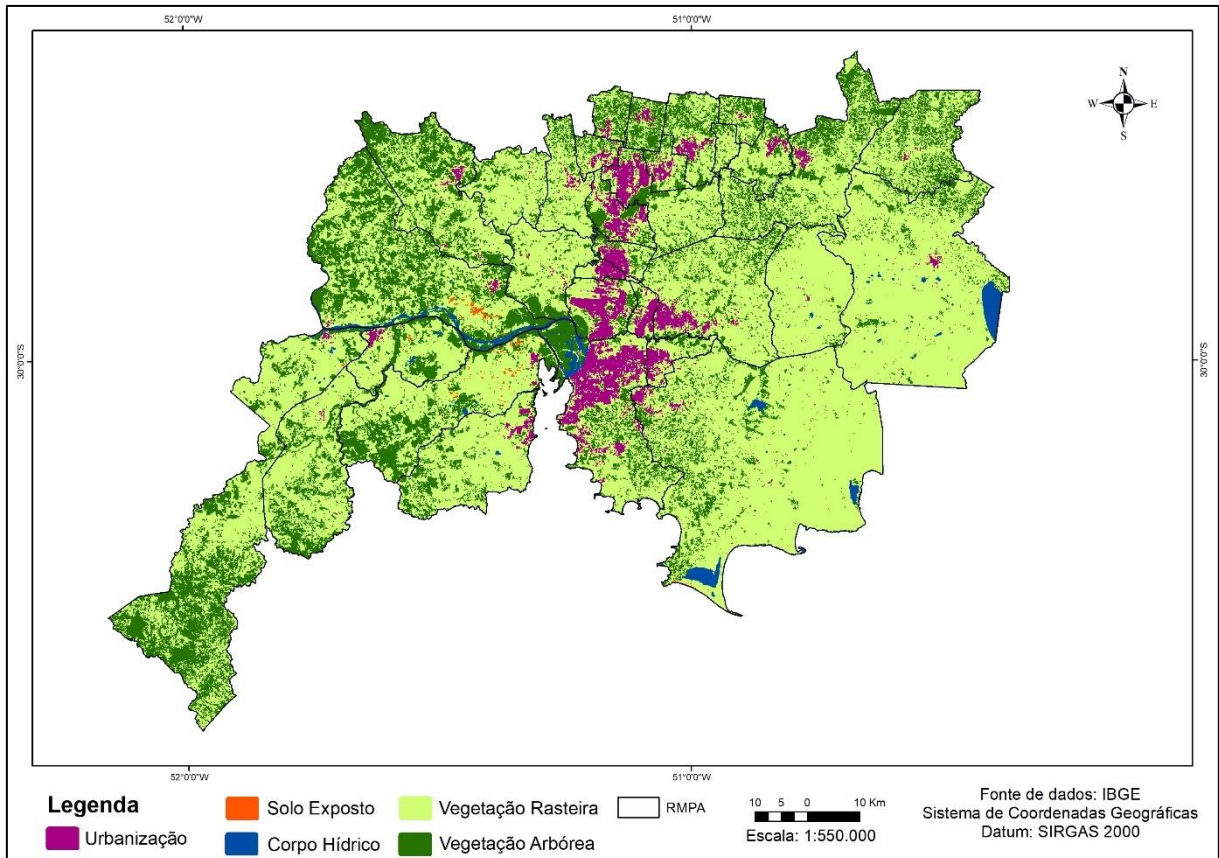


Figura 6 - Mapa de LULC dos municípios que faziam parte da RMPA em 2010.

Conforme o Censo Demográfico do IBGE, em 2010 Porto Alegre apresentava 1,409 milhões de habitantes sendo cerca de 35% da população metropolitana. Os municípios com população superior a 200 mil pessoas residentes, eram Canoas com 323 mil habitantes, Gravataí com 255 mil, Viamão possuindo 239 mil, Novo Hamburgo com 238 mil e São Leopoldo com 214 mil habitantes. Os municípios com menor população, considerando aqueles com menos de 10 mil habitantes, eram Araricá e Glorinha contendo aproximadamente 4 e 6 mil habitantes, respectivamente.

Dentre os 34 municípios integrantes da RMPA, 18 apresentavam população entre 20 e 100 mil habitantes. No ano de 2020 com a inserção de mais dois municípios, Igrejinha e São Sebastião do Caí (Figura 7), a área construída na RMPA passou a ser 693,3 km², resultando em 6,7% da área territorial da região que neste ano apresentava 10.334,7 km².

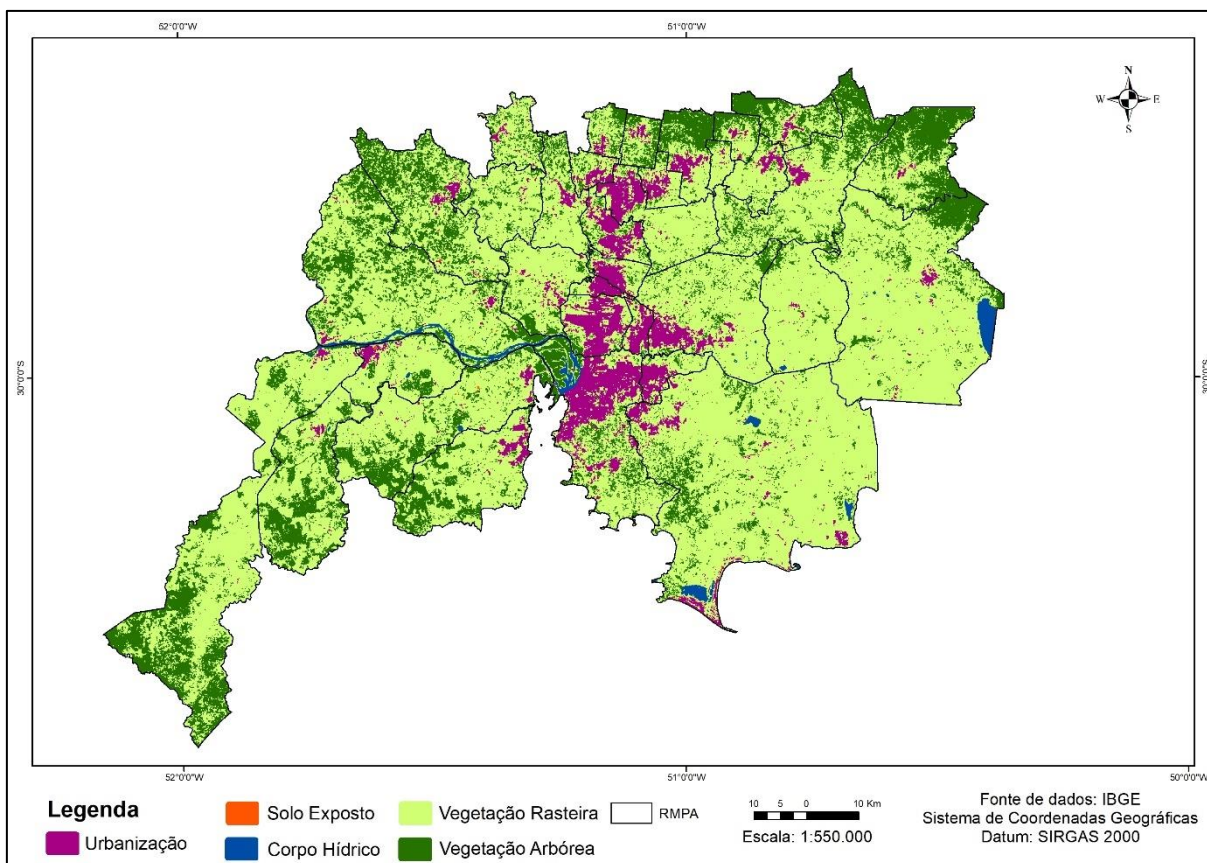


Figura 7 - Mapa de LULC dos municípios que fazem parte da RMPA em 2020.

Os mapas temáticos de uso e cobertura da terra gerados mostram as classes que aumentaram ou diminuíram com o passar do tempo, entre os 30 anos analisados. Primeiramente, pode-se perceber que a classe predominante para todos os anos de estudo na RMPA é a vegetação rasteira. Além disso, observou-se que as áreas urbanizadas aumentaram significativamente ao longo dos anos (Tabela 2).

Tabela 2 - Áreas das classes de uso e cobertura da terra nos anos de estudo.

Uso da terra	Área (km ²)							
	1991	(%)	2000	(%)	2010	(%)	2020	(%)
Corpo Hídrico	80,9	1,42	167,6	2,19	165,8	1,6	124,3	1,2
Solo Exposto	4,8	0,08	3,6	0,21	17,1	0,2	3,3	0,1
Urbanização	357,1	6,1	377,5	4,9	463,5	4,6	693,3	6,7
Vegetação Arbórea	1.214,7	20,8	217,6	2,8	2.576,5	25,5	2.289,9	22,1
Vegetação Rasteira	4.182,2	71,6	6.882,6	89,9	6.874,1	68,1	7.223,9	69,9
Total	5.839,7	100	7.648,9	100	10.097	100	10.334,7	100

Vale salientar que a porcentagem de áreas urbanizadas na RMPA ao longo dos anos foi maior em 1991 sendo 6,1% da área total e diminuiu em 2000 quando apresentou 4,9% da área total do território. Isso aconteceu devido ao fato de os municípios inseridos possuírem maiores áreas não construídas do que áreas urbanizadas. Isto é, mesmo que a mancha urbana tenha aumentado espacialmente, a sua porcentagem diminuiu em decorrência do aumento significativo da área total territorial da RMPA.

Os municípios com maior extensão territorial, acima de 800 km² são Viamão (1.497 km²), Santo Antônio da Patrulha (1.050 km²), São Jerônimo (935,5 km²) e Triunfo (817,6 km²), que juntos correspondem a mais que 40% da área metropolitana. Os municípios com menor extensão, abaixo de 50 km², são Esteio (27,6 km²), Araricá (35,3 km²) e Cachoeirinha (43,7 km²), caracterizando juntos apenas 1% do território da RMPA.

Dessa forma, observa-se que, apesar do significativo aumento da população da RMPA, devido ao aumento do seu território, a densidade média da região apresentou uma pequena diminuição no final destes trinta anos, passando de 409,3 hab/km, para 394 hab/km². Analisando os dados de densidade, verifica-se que os municípios inseridos na região nos últimos 20 anos, apresentam extenso território e baixa população com exceção de Montenegro.

No entanto, ao elaborar a densidade demográfica nas áreas urbanas considerando toda a população como urbana, pode-se perceber que em 2020 uma alta densidade demográfica é encontrada em Porto Alegre e Alvorada, enquanto Viamão, Nova Santa Rita, Charqueadas e Santo Antônio da Patrulha apresentaram uma baixa densidade demográfica, ou seja, elevado é o tamanho de área construída em relação à população total destes municípios (Figura 8).




Figura 8 - Relação entre população e área construída dos municípios da RMPA em 2020.

Análise da acurácia e validação do mapeamento

As acurácias da classificação para os anos de 1991, 2000, 2010 e 2020 encontram-se respectivamente nas (Tabelas 3, 4, 5, e 6). No mapeamento realizado para o ano de 1991 foi obtido um coeficiente Kappa de 0,83, classificado de acordo com a literatura como excelente. A precisão geral os erros e acertos estão disponibilizados na matriz de confusão e podem ser consultados na (Tabela 3).

Tabela 3 - Acurácia da classificação do uso e cobertura da terra em 1991.

Classes de Uso do Solo	Corpo Hídrico	Solo Exposto	Urbanização	Vegetação Arbórea	Vegetação Rasteira	Total
Corpo Hídrico	5	0	0	1	5	11
Solo Exposto	0	10	0	0	0	10
Urbanização	2	0	12	5	20	39
Vegetação Arbórea	0	0	0	66	4	70
Vegetação Rasteira	0	0	0	2	118	120
Total	7	10	12	74	147	250
Acurácia do produtor (%)	0,75	1	1	0,94	0,98	
Acurácia do usuário (%)	0,71	1	1	0,89	0,80	
Acurácia Global	0,84					
Coefficiente Kappa	0,83					

Em 2000, a classificação supervisionada apresentou um coeficiente Kappa definido como excelente com o resultado de 0,81. A (Tabela 4) expressa os valores resultantes da matriz de confusão, na qual mostra os erros que aconteceram na classificação supervisionada para o ano 2000, onde por exemplo do total de 148 pixels de vegetação rasteira 16 foi erroneamente classificado como urbanização.

Tabela 4 - Acurácia da classificação do uso e cobertura da terra em 2000.

Classes de Uso do Solo	Corpo Hídrico	Solo Exposto	Urbanização	Vegetação Arbórea	Vegetação Rasteira	Total
Corpo Hídrico	9	0	0	1	0	10
Solo Exposto	0	9	0	0	1	10
Urbanização	1	1	10	1	16	27
Vegetação Arbórea	1	0	0	63	2	66
Vegetação Rasteira	0	1	2	3	129	137
Total	11	11	12	68	148	250
Acurácia do produtor (%)	0,82	0,82	0,83	0,93	0,87	
Acurácia do usuário (%)	0,90	0,90	0,80	0,95	0,94	
Acurácia Global	0,82					
Coefficiente Kappa	0,81					

Da mesma maneira, obteve-se o resultado da matriz de confusão para a classificação supervisionada de 2010, que por sua vez apresentou um coeficiente Kappa de 0,84, também interpretado como excelente. A (Tabela 5) contém os valores totais de acertos e erros que ocorreram em cada classe de uso da terra, como na classe de urbanização que dos 16 pixels definidos como área urbana, 2 foram classificados erroneamente como vegetação rasteira, pois em ambas as classes o pixel foi interpretado como semelhante, devido ao fato de ser uma época de solo úmido na área de estudo.

Tabela 5 - Acurácia da classificação do uso e cobertura da terra em 2010.

Classes de Uso do Solo	Corpo Hídrico	Solo Exposto	Urbanização	Vegetação Arbórea	Vegetação Rasteira	Total
Corpo Hídrico	10	0	0	0	0	10
Solo Exposto	0	8	0	0	2	10
Urbanização	0	0	14	0	26	37
Vegetação Arbórea	0	0	0	85	2	87
Vegetação Rasteira	0	0	2	1	100	106
Total	10	8	16	86	130	250
Acurácia do produtor (%)	1	1	0,87	0,98	0,94	
Acurácia do usuário (%)	1	1	0,89	0,99	0,77	
Acurácia Global	0,86					
Índice Kappa	0,84					

O mapeamento realizado para o ano de 2020 mostrou maiores confusões nas classes vegetação arbórea e vegetação rasteira, porém mais acertos na classe urbanização. Sendo o foco principal desse estudo analisar a classe de urbanização, a escolha da composição das imagens utilizadas para a realização da classificação supervisionada priorizou a que melhor identificou áreas urbanas.

Dessa forma, de acordo com a (Tabela 6), obteve-se o resultado da matriz de confusão para a classificação supervisionada de 2020, com um coeficiente Kappa de 0,82, interpretado como excelente.

Tabela 6 - Acurácia da classificação do uso e cobertura da terra em 2020.

Classes de Uso do Solo	Corpo Hídrico	Solo Exposto	Urbanização	Vegetação Arbórea	Vegetação Rasteira	Total
Corpo Hídrico	10	0	0	0	0	10
Solo Exposto	0	8	0	0	2	10
Urbanização	1	1	13	0	16	30
Vegetação Arbórea	0	0	0	49	1	50
Vegetação Rasteira	0	0	1	17	131	150
Total	11	9	14	66	150	250
Acurácia do produtor (%)	1	0,80	0,92	0,98	0,87	
Acurácia do usuário (%)	0,91	0,89	0,86	0,74	0,87	
Acurácia Global	0,84					
Coefficiente Kappa	0,82					

A acurácia do mapeamento de uso e cobertura da terra foi avaliada pela matriz de confusão gerada a partir das amostras de validação para cada ano em estudo. A avaliação de acurácia é uma das principais formas de compreender a qualidade da classificação de imagens, então, após a realização da classificação do uso e cobertura da terra, é importante fazer a sua avaliação.

Portanto, as acurácias globais (AG), por classe (AC), e do usuário (AU), além do coeficiente Kappa foram calculados para as classes de uso da terra (Tabela 7). As AGs em 1991, 2000, 2010 e 2020 foram de 84,4%, 82,2%, 85,6% e 84,00%, respectivamente. Enquanto o Kappa foi 0,83, 0,81, 0,84 e 0,82, para os mesmos períodos. Esses fatores indicaram os resultados da cobertura do uso da terra em um mapeamento satisfatório e atendeu às necessidades da pesquisa.

Tabela 7 - Índices de precisão para as classes classificadas nos três períodos.

Ano	Uso do Solo	AC (%)	AU (%)	AG (%)	Kappa
1991	Corpo Hídrico	75,45%	71,42%		
	Solo Exposto	100%	100%		
	Urbanização	100%	100%	84,4%	0,83
	Vegetação Arbórea	94,28%	89,18%		
	Vegetação Rasteira	98,33%	80,27%		
2000	Corpo Hídrico	81,81%	90%		
	Solo Exposto	81,81%	90%		
	Urbanização	83,66%	80,62%	82,2%	0,81
	Vegetação Arbórea	92,64%	95,45%		
	Vegetação Rasteira	87,16%	94,16%		
2010	Corpo Hídrico	100%	100%		
	Solo Exposto	100%	100%		
	Urbanização	87,75%	89,75%	85,6%	0,84
	Vegetação Arbórea	98,83%	98,83%		
	Vegetação Rasteira	94,92%	77,92%		
2020	Corpo Hídrico	100%	91%		
	Solo Exposto	80%	88,88%		
	Urbanização	92%	85,71%	84,0%	0,82
	Vegetação Arbórea	98%	74,24%		
	Vegetação Rasteira	87%	87,33%		

Ao analisar o coeficiente Kappa para o algoritmo de Máxima Verossimilhança, é possível observar que todas as densidades amostrais foram classificadas como “excelentes”, sendo que o maior coeficiente Kappa foi de 0,84 obtido em 2010 e o menor de 0,81 em 2000. Foi possível observar também que quanto menor for a densidade amostral, possivelmente maior será o resultado do coeficiente Kappa.

Além da acurácia também foi realizada a validação do mapeamento da classificação supervisionada a partir do mapeamento realizado pelo MapBiomas. Analisou-se que as classes que apresentaram maiores confusões na classificação supervisionada coincidem com as áreas em que o mapeamento do MapBiomas também não classificou, e nomeou-as como não observado.

Além disso, o IBGE lançou uma coleção de mapas municipais para 2020 produzidos a partir da Malha Municipal Digital do IBGE com as áreas urbanas dos municípios (IBGE, 2020). Analisando os resultados da classificação supervisionada para o ano 2020 desta pesquisa, que considera aproximadamente 6,7% de toda a área como urbanizada, percebe-se a semelhança com as áreas urbanas mapeadas para 2020 pelo IBGE, que apresentou um total de áreas urbanas de aproximadamente 8% para o mesmo ano.

Com a finalidade de obter mais confiabilidade nos resultados do mapeamento de uso e cobertura do solo, também foi realizada a validação através do *Semi-Automatic Classification Plugin (SCP)* no software QGIS. A base inserida como verdade foi o mapeamento do MapBiomias a ser comparado com o mapeamento realizado nesse estudo e assim, o SCP gerou o cruzamento de ambos os mapas resultando em um terceiro mapa validado. O gráfico resultante da validação (Figura 9), mostrou a quantificação em porcentagem das classes assertivas, isto é, verificadas nos dois mapeamentos, bem como as classes classificadas como outro tipo de uso e cobertura da terra para os quatro anos em estudo.




Figura 9 - Quantificação da validação do uso e cobertura da terra para os anos em estudo.

Os resultados analisados anteriormente, expressam na cor verde as classes assertivas, ou seja, classificadas igualmente nos dois mapeamentos, e na cor azul observa-se a discrepância entre as classificações realizadas neste estudo e a disponibilizada pelo MapBiomas. Observa-se que em 2000, foi o ano que apresentou maior confusão de pixel na classe vegetação arbórea, isto é, ocorreu a maior porcentagem dessa classe de uso da terra interpretadas na classificação como outras classes. Os resultados desse gráfico também mostram que o mapeamento do ano de 2020 foi o que a classe urbanização das duas classificações mais coincidiu.

Análise da expansão urbana e métricas espaciais para a RMPA entre 1991 e 2020

Os resultados das distribuições espaciais das áreas urbanas e expansão da RMPA de 1991 a 2020 podem ser observados na (Figura 10) e serve como base para identificar o padrão da evolução da mancha urbana na região.

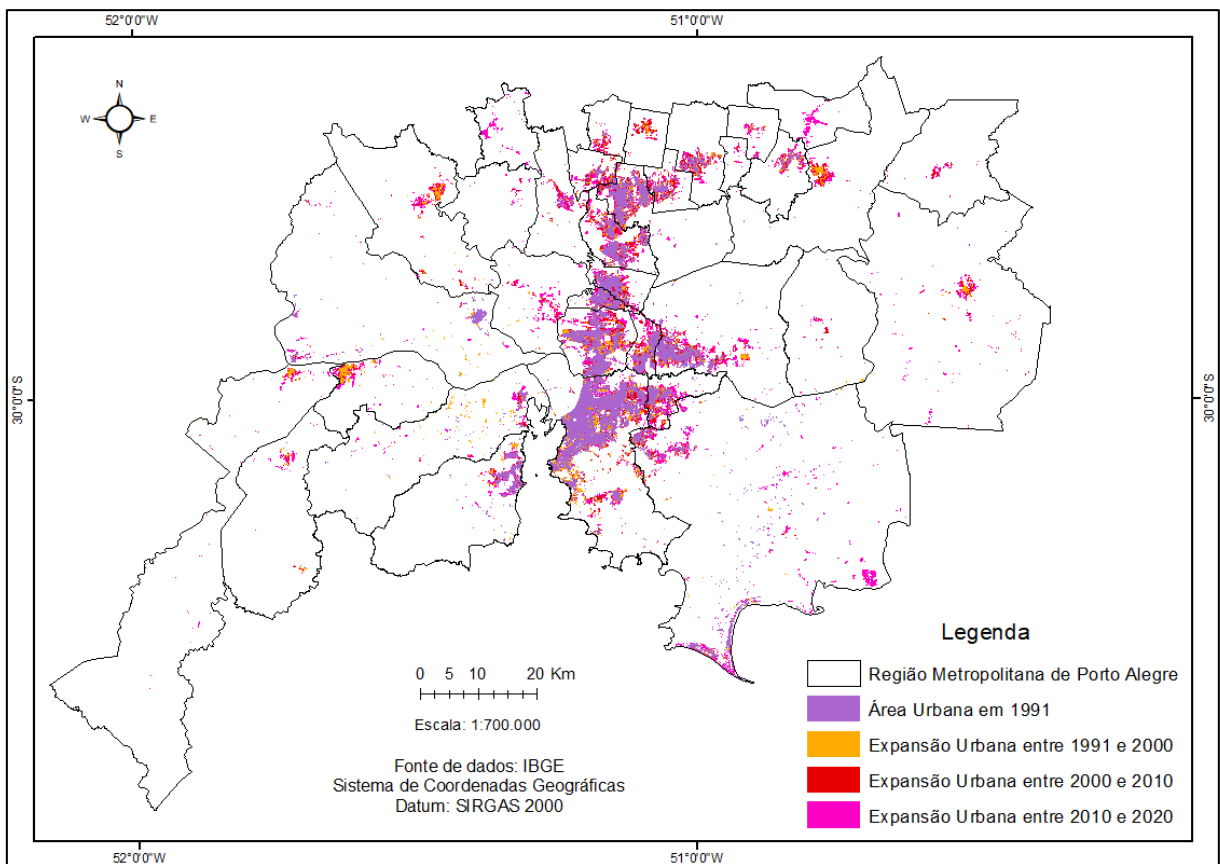


Figura 10 - Distribuições espaciais da mancha urbana na RMPA de 1991 a 2020.

Percebe-se que grande parte da expansão urbana da RMPA entre os anos de 1991 e 2000 acontecem principalmente nos municípios próximos da capital, Porto Alegre. No entanto, também nota-se que em Charqueadas, Cachoeirinha, Gravataí, Taquara e Santo Antônio da Patrulha aconteceu um aumento da urbanização neste intervalo de tempo analisado.

Entre os anos de 2000 e 2010 a expansão aconteceu em sua maior parte nos municípios Charqueadas, Taquara e Porto Alegre. Por último, entre os anos de 2010 e 2020 a urbanização expandiu nos municípios Viamão, Alvorada, Santo Antônio da Patrulha e Cachoeirinha.

Pode-se observar também que no município de Viamão, aconteceu uma concentração de áreas construídas recentes, localizadas na região oposta a Porto Alegre e perto do Guaíba. Locais assim são propícios para a população que busca morar mais longe da aglomeração das cidades e mais perto de áreas naturais, que buscam uma melhor qualidade de vida.

Os resultados do mapeamento apresentaram aumento na porcentagem de áreas urbanizadas de 1991 para 2000 e uma diminuição a partir de 2000 (Figura 11). Esse decréscimo acontece devido ao fato de os municípios inseridos ao longo dos anos possuírem maior área territorial do que área construída. Dessa forma, mesmo que a mancha urbana aumente na configuração total da RMPA, a porcentagem diminuiu em decorrência do aumento da área total territorial da RMPA ser maior do que a área construída.




Figura 11 - Quantificação do uso e cobertura da terra para os anos em estudo.

Com o passar dos anos, ocorreram diferentes transições de uso e cobertura da terra na RMPA, como a mudança de áreas de vegetação arbórea que passaram a ser locais de áreas construídas, pois à medida que as cidades crescem, outros usos da terra vão sendo modificados. No entanto, corpos hídricos é um uso do solo que apresentou poucas mudanças ao longo dos anos analisados, assim como solo exposto.

O gráfico mostrou que os municípios que apresentaram maior aumento percentual na mancha urbana foram Cachoeirinha, Canoas, Esteio, Porto Alegre, São Leopoldo e Sapucaia do Sul. De acordo com os resultados desse estudo, nesses municípios se encontram a maior área urbana total em km² na RMPA.

O aumento de área urbana no município de Cachoeirinha foi gradativo nos anos estudados, com aproximadamente 13 km² de área construída no ano de 1991, 14 km² em 2000, 18 km² em 2010 e 24 km² em 2020. Cachoeirinha abrange uma grande concentração de moradores que trabalham em Porto Alegre, a qual por sua vez, oferece muitas oportunidades de emprego, resultando em uma maior densidade populacional nos municípios vizinhos. De acordo com os resultados encontrados, as áreas urbanizadas se expandem rapidamente, ocorrendo uma grande perda de vegetação arbórea durante os últimos 30 anos.

Analisando os resultados das métricas espaciais para a RMPA, durante 1991 até 2020 os municípios que apresentaram maior expansão na forma *edge-expansion* foram Porto Alegre, Alvorada, Canoas, Cachoeirinha, Esteio, Sapucaia do Sul e São Leopoldo, essa forma de expansão foi a mais verificada na RMPA nos últimos 30 anos, apontando 562 km² resultando em aproximadamente 81% (Figura 12). Esses municípios estão dispostos próximos do centro de Porto Alegre, à estação Ferroviária, ao Aeroporto Internacional Salgado Filho que são fatores importantes para o aumento da concentração urbana.

Taquara, Santo Antônio da Patrulha, Viamão, Charqueadas e Montenegro foram os municípios com maior concentração de *outlying*, essa forma de expansão urbana é considerada uma nova expansão, em locais que não apresentaram evidências da existência de áreas urbanas nos anos anteriores. Essa forma espacial de expansão urbana foi responsável por 17% de todo o crescimento urbano na RMPA. Esses municípios apresentam em comum locais com menos aglomeração intensa de tráfego, urbanização e concentração de pessoas de outros municípios. Normalmente,

a forma de expansão urbana *outlying* acontece em pontos estratégicos para quem escolhe uma moradia mais afastada dos locais urbanos intensos.

Por último, a forma de expansão conhecida por *infilling*, ocorreu em apenas 2% das áreas e sua maior parte aconteceu nos municípios Triunfo e Porto Alegre. A (Figura 12) mostra a distribuição espacial dos três tipos de expansão urbana que aconteceram entre 1991 e 2020.

A ocorrência dessa forma de expansão acontece nos então conhecidos como vazios urbanos, ou seja, áreas dentro das áreas urbanas que não eram utilizadas como tal. Os municípios que mais apresentam este tipo de expansão urbana estão localizados próximos ao maior foco de urbanização que acontece em Porto Alegre.

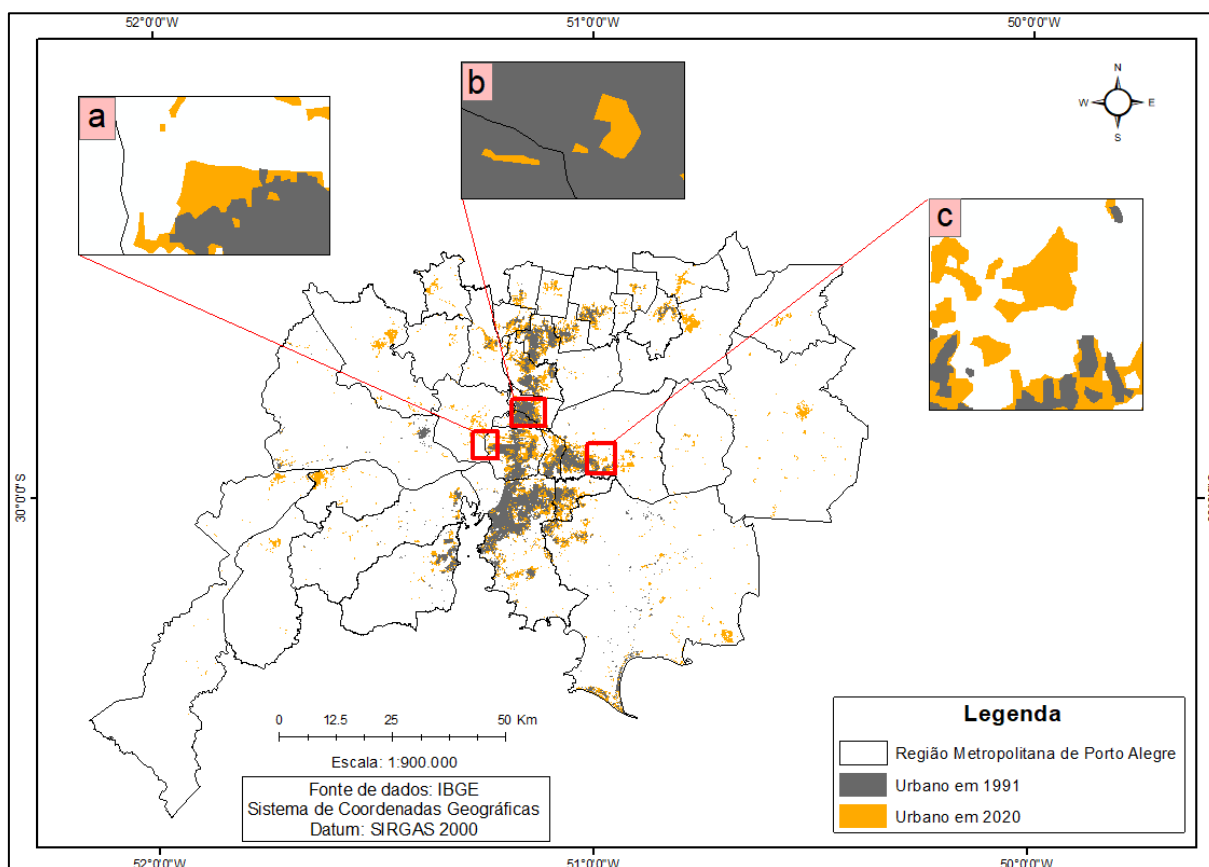


Figura 12 - a) Expansão de borda; b) preenchimento; c) periférico.

Uma representativa parcela da população da RMPA concentra-se num pequeno número de municípios. Cerca de 75% da população está situada em apenas 8 dos 34 municípios que compõe a RMPA, sendo que destes, cerca de 35% da população reside na capital Porto Alegre.

Dessa maneira, Porto Alegre continua sendo o principal centro urbano da RMPA, considerado um município de concentração e atração de pessoas pela possibilidade de emprego e estudo, proporcionando elevada expansão econômica, fazendo dela a área mais densamente povoada do Estado. De acordo com esse estudo, Porto Alegre apresenta uma densidade demográfica média de 2.689,9 habitantes por quilômetro quadrado, com uma população 97% urbana. Por último, vale ressaltar que a RMPA tem, em sua configuração territorial, 9 dos 18 municípios do Estado do RS com mais de 100 mil habitantes, o que também contribui para o seu adensamento populacional e conseqüentemente uma maior área urbanizada.

CONCLUSÕES

A avaliação e a compreensão do efeito da expansão urbana são de grande importância para a gestão dos recursos da superfície terrestre para o desenvolvimento e planejamento das cidades. A classificação supervisionada para os quatro anos em análise apresentou um alto coeficiente Kappa de mais de 80% de precisão, que é considerado aceitável para a realização das análises espaciais.

Em relação ao processo de institucionalização da RMPA, após 2001 houve um período de quase uma década sem inclusões de novos municípios na área metropolitana. No entanto, desde 2010 acontece uma retomada nas inclusões, com a integração de mais três municípios. A configuração territorial da área metropolitana apresenta municípios de diferentes portes.

Neste período acontece um aumento das áreas urbanas dos municípios da região e a consolidação do processo de urbanização, medido pela evolução da taxa de urbanização. Os dois municípios que concentram as maiores populações da RMPA são Porto Alegre e Canoas. O aumento de urbanização mais intensa aconteceu no eixo norte-sul, ao longo da BR 116, abrangendo principalmente estes dois municípios mais os municípios de Esteio, Sapucaia, São Leopoldo, Novo Hamburgo e Dois Irmãos. Além destes, Cachoeirinha e Gravataí, situados nas proximidades da capital também passaram pelo processo de intensa urbanização.

Dessa forma, analisar a mudança de uso e cobertura da terra na Região Metropolitana de Porto Alegre (RMPA) nos últimos 30 anos e compreender as diferentes dinâmicas da expansão urbana no decorrer do tempo, auxilia os

formuladores de políticas no planejamento de cidades mais organizadas no futuro. Além disso, pesquisas nesse âmbito proporcionam melhorias no monitoramento contínuo das transformações das paisagens.

Os resultados destacam a necessidade de considerar variados elementos físicos e fatores socioeconômicos em pesquisas semelhantes. Por conseguinte, uma sugestão para as pesquisas futuras, é utilizar outros dados de sensoriamento remoto e geoprocessamento para investigar mais minuciosamente os efeitos dessas mudanças que ocorrem na paisagem.

REFERÊNCIAS

ABBURU, S.; BABU GOLLA, S. Satellite Image Classification Methods and Techniques: A Review. **International Journal of Computer Applications**, v. 119, n. 8, p. 6, 2015. Disponível em: <https://doi.org/10.5120/21088-3779>

ALJOUFIE, M. *et al.* Spatial-temporal analysis of urban growth and transportation in Jeddah City, Saudi Arabia. **Cities**, v. 31, p. 57–68, 2013. Disponível em: <https://doi.org/10.1016/j.cities.2012.04.008>

BAKR, N.; MORSY, I.; YEHA, H. A. Spatio-temporal land use/cover detection and prediction in Mediterranean region: A case study in Idku ecosystem, Egypt. **Remote Sensing Applications: Society and Environment**, v. 25, n. December 2021, p. 16, 2022. Disponível em: <https://doi.org/10.1016/j.rsase.2021.100673>

BATTY, M. Cellular automata and urban form: A primer. **Journal of the American Planning Association**, v. 63, n. 2, p. 266–274, 1997. Disponível em: <https://doi.org/10.1080/01944369708975918>

BERBEROĞLU, S.; AKIN, A.; CLARKE, K. C. Cellular automata modeling approaches to forecast urban growth for adana, Turkey: A comparative approach. **Landscape and Urban Planning**, v. 153, p. 11–27, 2016. Disponível em: <https://doi.org/10.1016/j.landurbplan.2016.04.017>

CANO, E. C.; UCHÔAS, A. de A.; GALLINA, F. Os desafios do IBGE e a realização do censo demográfico 2022. v. 7, p. 1–15, 2021.

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 and Design**, v. 24, n. 2, p. 247–261, 1997. Disponível em: <https://doi.org/10.1068/b240247>

CONGEDO, L. Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. **Journal of Open Source**

Software, v. 6, n. 64, p. 3172, 2021. Disponível em:
<https://doi.org/10.21105/joss.03172>

DE JESUS, J. B.; KUPLICH, T. M. Use of SAR images for classification of Brazilian forest formations. **Ciencia Florestal**, v. 31, n. 3, p. 1547–1568, 2021. Disponível em:
<https://doi.org/10.5902/1980509837586>

DUBOVYK, O.; SLIUZAS, R.; FLACKE, J. Spatio-temporal modelling of informal settlement development in Sancaktepe district, Istanbul, Turkey. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 2, p. 235–246, 2011. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2010.10.002>

FERRAZ, D. da P. G. B.; VICENS, R. S. Desempenho do Descritor Máxima Diferença na Classificação de Plantações de Eucalipto no Estado do Rio de Janeiro. **Revista Brasileira de Cartografia**, v. 71, n. 1, p. 99–121, 2019. Disponível em:
<https://doi.org/10.14393/rbcv71n1-46143>

FONSECA, L. M. G. Processamento digital de imagens. **Instituto Nacional de Pesquisas Espaciais (INPE)**, 2000.

G, R. C.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data**. 3^a ed. 2019.

GONÇALVES, T. M. *et al.* Simulating Urban Growth Using Cellular Automata Approach (SLEUTH)-A Case Study of Praia City, Cabo Verde. **IEEE Access**, v. 7, p. 156430–156442, 2019. Disponível em:
<https://doi.org/10.1109/ACCESS.2019.2949689>

IBGE. **Cidades - Pesquisas**. 2018. Disponível em:
<https://cidades.ibge.gov.br/brasil/rs/rio-grande/panorama>. Acesso em: 1 ago. 2020.

IBGE. **Agência IBGE notícias**. 2020. Disponível em:
<https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/31471-ibge-lanca-colecao-de-mapas-municipais-2020>.

JENSEN, J. R. Introductory digital image processing: a remote sensing perspective. **New Jersey: Prentice Hall**, v. 2.ed., p. 316, 1996.

JIAO, L.; MAO, L.; LIU, Y. Multi-order Landscape Expansion Index: Characterizing urban expansion dynamics. **Landscape and Urban Planning**, v. 137, p. 30–39, 2015. Disponível em: <https://doi.org/10.1016/j.landurbplan.2014.10.023>

LI, S. *et al.* Impacts of Urban Expansion Forms on Ecosystem Services in Urban Agglomerations: A Case Study of Shanghai-Hangzhou Bay Urban Agglomeration. **Remote Sensing**, v. 13, n. 10, p. 24, 2021. Disponível em:
<https://doi.org/10.3390/rs13101908>

LI, X. *et al.* Calibrating cellular automata based on landscape metrics by using genetic algorithms. **International Journal of Geographical Information Science**, v. 27, n. 3, p. 594–613, 2013. Disponível em:

<https://doi.org/10.1080/13658816.2012.698391>

LIU, X. *et al.* A new landscape index for quantifying urban expansion using multi-temporal remotely sensed data. **Landscape Ecology**, v. 25, n. 5, p. 12, 2010. Disponível em: <https://doi.org/10.1007/s10980-010-9454-5>

LIU, X. *et al.* Simulating urban growth by integrating landscape expansion index (LEI) and cellular automata. **International Journal of Geographical Information Science**, v. 28, n. 1, p. 148–163, 2014. Disponível em: <https://doi.org/10.1080/13658816.2013.831097>

MAPBIOMAS. 2021. **Área urbanizada nos últimos 36 anos**. Disponível em: <https://mapbiomas.org/estatisticas>

MUGIRANEZA, T.; BAN, Y.; HAAS, J. Urban land cover dynamics and their impact on ecosystem services in Kigali, Rwanda using multi-temporal Landsat data. **Remote Sensing Applications: Society and Environment**, v. 13, p. 234–246, 2019. Disponível em: <https://doi.org/10.1016/j.rsase.2018.11.001>

ONU. **Perspectivas da População Mundial 2019: Destaques** | Biblioteca multimídia - Departamento de Assuntos Econômicos e Sociais das Nações Unidas.

PAIVA, A. C. da E. *et al.* Urban expansion and its impact on water security: The case of the Paraíba do Sul River Basin, São Paulo, Brazil. **Science of the Total Environment**, p. 50, 2020. Disponível em: <https://doi.org/10.1016/j.scitotenv.2020.137509>

PEREIRA, L. F.; GUIMARÃES, R. M. F. Mapeamento multicategórico do uso/cobertura da terra em escalas detalhadas usando Semi-automatic Classification Plugin. **Journal of Environmental Analysis and Progress**, v. 03, n. 04, p. 379–385, 2018.

RAMYA, S.; DEVADAS, V. Integration of GIS, AHP and TOPSIS in evaluating suitable locations for industrial development: A case of Tehri Garhwal district, Uttarakhand, India. **Elsevier Ltd**, 2019. v. 238. Disponível em: <https://doi.org/10.1016/j.jclepro.2019.117872>

REBA, M.; SETO, K. C. A systematic review and assessment of algorithms to detect, characterize, and monitor urban land change. **Elsevier**, 2020. Disponível em: <https://doi.org/10.1016/j.rse.2020.111739>

SAXENA, A.; JAT, M. K. Capturing heterogeneous urban growth using SLEUTH model. **Remote Sensing Applications: Society and Environment**, v. 13, p. 426–434, 2019. Disponível em: <https://doi.org/10.1016/j.rsase.2018.12.012>

SECRETARIA DE PLANEJAMENTO, G. e G. **Atlas Socioeconômico do Rio Grande do Sul**. 2020. Disponível em: <https://atlassocioeconomico.rs.gov.br/regiao-metropolitana-de-porto-alegre-rmpa>.

SECRETARIA DE PLANEJAMENTO, G. e G. **Atlas Socioeconômico do Rio**

Grande do Sul. 2021. Disponível em: <https://atlassocioeconomico.rs.gov.br/regiao-metropolitana-de-porto-alegre-rmpa>.

UNESCO. **Relatório Mundial das Nações Unidas sobre o Desenvolvimento dos Recursos Hídricos: Soluções baseadas na Natureza para a gestão da água.** 2018.

YADAV, V.; GHOSH, S. K. Assessment and prediction of urban growth for a mega-city using CA-Markov model. **Geocarto International**, p. 1–34, 2019. Disponível em: <https://doi.org/10.1080/10106049.2019.1690054>

4.2 Artigo 2 - Modelagem de uso e cobertura da terra e geração de cenários futuros da mancha urbana da Região Metropolitana de Porto Alegre – RS, utilizando *Artificial Neural Network* (ANN).

RESUMO

A pesquisa investiga a mudança de uso e cobertura da terra (LULC) na Região Metropolitana de Porto Alegre (RMPA) através de uma análise histórica entre 1991 e 2020 usando imagens dos satélites Landsat e prevê as mudanças futuras para os anos de 2030 e 2040 usando um modelo *Multilayer Perceptrons* (MLP) através de *Artificial Neural Network* (ANN). Os mapas de LULC servem como base para facilitar o monitoramento de como as áreas urbanas estão expandindo, e o Modelo Digital de Elevação (MDE), relevo sombreado, declividade, distância da estrada, da estação ferroviária, dos centros urbanos e da capital Porto Alegre são os critérios usados como mapas de variáveis espaciais nos processos de aprendizagem do modelo para os cenários futuros de urbanização. A precisão dos mapas históricos de LULC apresentou excelente desempenho com coeficiente Kappa de 0,82, 0,87, 0,86, e 0,83 para os anos em estudo, respectivamente. Os resultados históricos revelam que entre 1991 e 2020, a classe urbanização teve um aumento de 298 km², enquanto as áreas de vegetação arbórea diminuíram um total de 322 km². A métrica espacial utilizada observou que entre 1991 e 2020 a forma de expansão urbana predominante na RMPA totalizou 93% na forma borda-expansão, principalmente nos municípios de Porto Alegre, Alvorada, Canoas, Esteio, Nova Santa Rita e São Leopoldo. A forma de expansão periférica e de preenchimento ocorreram em 5% e 2%, respectivamente, nos municípios mais afastados de Porto Alegre, principalmente em Capela de Santana, Montenegro, Viamão e Guaíba. Notou-se que a concentração principal de áreas urbanizadas desde 1991 ocorrem em sua maior parte nas redondezas de Porto Alegre e Canoas. Essa pesquisa levou em consideração os fatores importantes para o aumento da expansão urbana. Por fim, as mudanças nas previsões de modelagem futuras de LULC para os anos de 2030 e 2040 apresentaram um aumento significativo na área urbana da RMPA de 323 km² e 335 km², respectivamente. O índice de expansão de paisagem para os mapeamentos futuros apresentou resultados diferentes dos analisados historicamente, a forma borda-expansão ocorre em 79%, 18% na forma periférica e 3% preenchimento. Os resultados obtidos podem auxiliar os tomadores de decisão no desenvolvimento e planejamento das cidades. Para o futuro, é previsto que as áreas urbanas aumentem mais de 650 km² até 2040. Os resultados demonstrados nesse estudo são importantes para o planejamento destas áreas urbanas. A combinação de dados de sensoriamento remoto e sistema de informação geográfica (SIG) possibilitam o monitoramento da expansão das áreas urbanas. As descobertas auxiliam os formuladores de políticas no desenvolvimento de planos urbanos mais conscientes e melhores técnicas de gestão para o desenvolvimento urbano.

Palavras-chave: LULC histórico; LULC previsto; LEI; ANN.

INTRODUÇÃO

As transições no uso e cobertura da terra (LULC) e o aumento de áreas construídas, influenciam diretamente na qualidade de vida da população (ASHAOLU; OLORUNFEMI; IFABIYI, 2019), sendo importante realizar simulações da expansão urbana.

Existem vários modelos para simular a expansão urbana, como os modelos de regressão (HU; LO, 2007), modelos de autômatos celulares (CHEN *et al.*, 2016), cadeia de Markov (ARSANJANI; KAINZ; MOUSIVAND, 2011), dentre outros.

Todavia, existem diferentes variantes dos Modelos de Autômatos Celulares (CA) criados para simular a mudança no uso da terra e a expansão urbana como o SLEUTH (CLARKE; HOPPEN; GAYDOS, 1997), o modelo dinâmico de evolução urbana (BATTY, 1997), o modelo de análise de multicritério (MCA-CA) (WU; WEBSTER, 2000), o modelo de simulação multiagente (MAS-CA) (LIGTENBERG; BREGT; VAN LAMMEREN, 2001), o modelo Voronoi-CA (SHI; PANG, 2000) e o modelo Markov-CA (VAZ; DE NORONHA; NIJKAMP, 2014).

Nessa pesquisa, é realizada a simulação da expansão urbana e a geração de cenários futuros da RMPA também utilizando-se CA, através do plugin *Modules of Land Use Change Evaluation* (MOLUSCE) do *software* QGIS que tem disponível quatro modelos de algoritmos bem conhecidos que são o modelo *Multilayer Perceptrons* (MLP) através de *Artificial Neural Network* (ANN), Regressão Logística (LR), Avaliação Multicritérios (MCE) e Pesos de Evidência (WoE) (ABBAS *et al.*, 2021).

O sensoriamento remoto unido ao sistema de informação geográfica possui ferramentas adequadas para gerenciar pesquisas de mudança de uso da terra. Compreender as mudanças regionais e temporais do LULC beneficia cientistas, ambientalistas, legisladores e planejadores urbanos (GUIDIGAN *et al.*, 2019).

Os modelos de transição LULC, objetivam prever quando e com que frequência essas mudanças ocorrerão. Modelos de previsão futura são usados por pesquisadores em todo o mundo e é extremamente útil para determinar como as mudanças de LULC anteriores e futuras acontecem (PEROVIĆ *et al.*, 2018).

Os modelos de previsão espaço-temporal, como o modelo de autômatos celulares (CA) foram desenvolvidos nos últimos anos para prever o LULC e suas detecções de mudança, como o modelo CA-ANN que é uma ferramenta confiável e utilizada por pesquisadores para análise de mudança de uso da terra (ALAM *et al.*, 2021). O modelo CA tem sido utilizado devido à sua simplicidade na integração dos elementos espaço-temporais dos processos e são usados em estudos de planejamento urbano. O mesmo também é usado para investigar mudanças temporais de LULC e prever o uso futuro da terra (SAPUTRA; LEE, 2019).

Esse estudo sobre a Região Metropolitana de Porto Alegre (RMPA) usa a abordagem MLP-ANN para detectar a mudança histórica de LULC da área de estudo entre 1991 e 2020, e prever o LULC para 2030 e 2040 em dois cenários diferentes.

METODOLOGIA

Área de estudo

A área de estudo dessa pesquisa é a Região Metropolitana de Porto Alegre (RMPA) (Figura 13), localizada no estado do Rio Grande do Sul. Atualmente a RMPA é composta por 34 municípios contendo área total de 10.335 km², sendo a quinta região metropolitana mais populosa do país. A RMPA foi criada em 1973 pela Lei Complementar Federal nº. 14/73 (SECRETARIA DE PLANEJAMENTO, 2020).

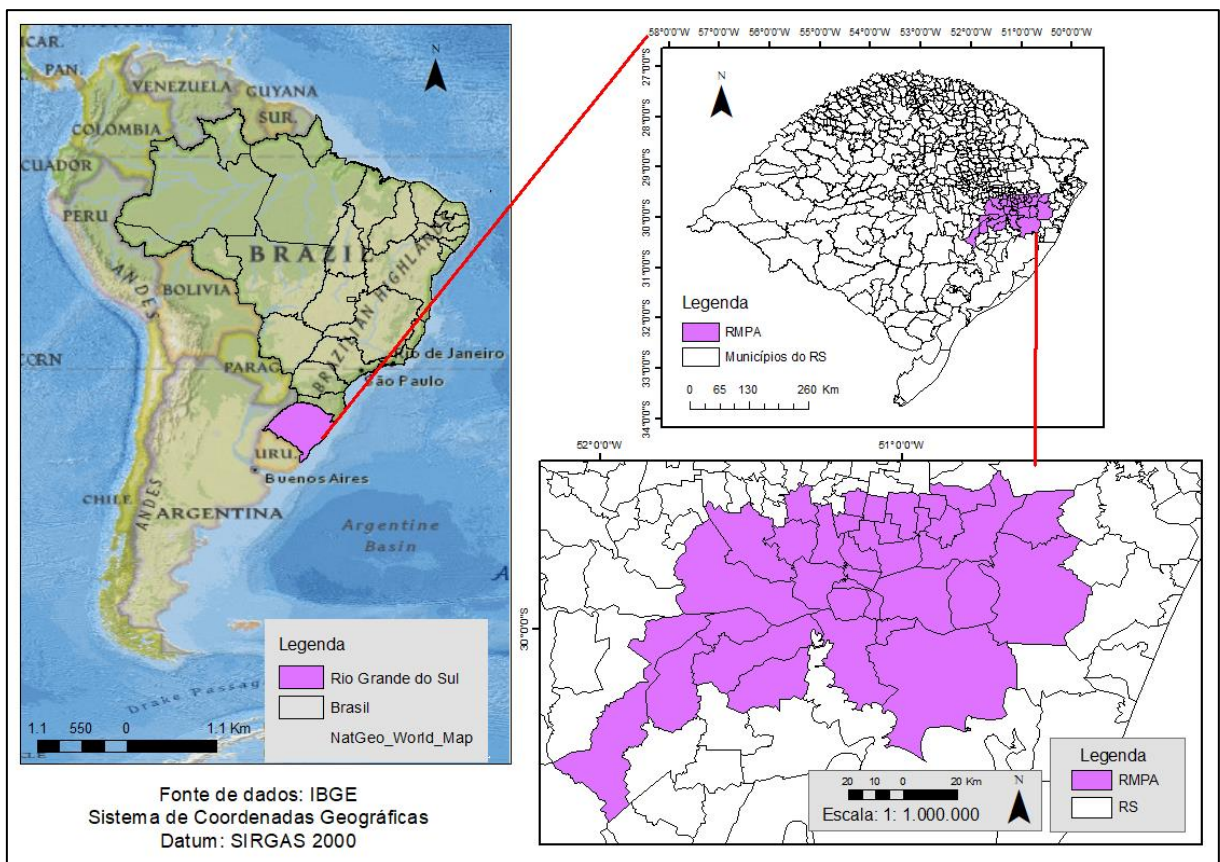


Figura 13 - Localização da Região Metropolitana de Porto Alegre.

Os processos metodológicos realizados nesse estudo serão especificados com detalhamento a seguir e podem ser visualizados no fluxograma da (Figura 14).

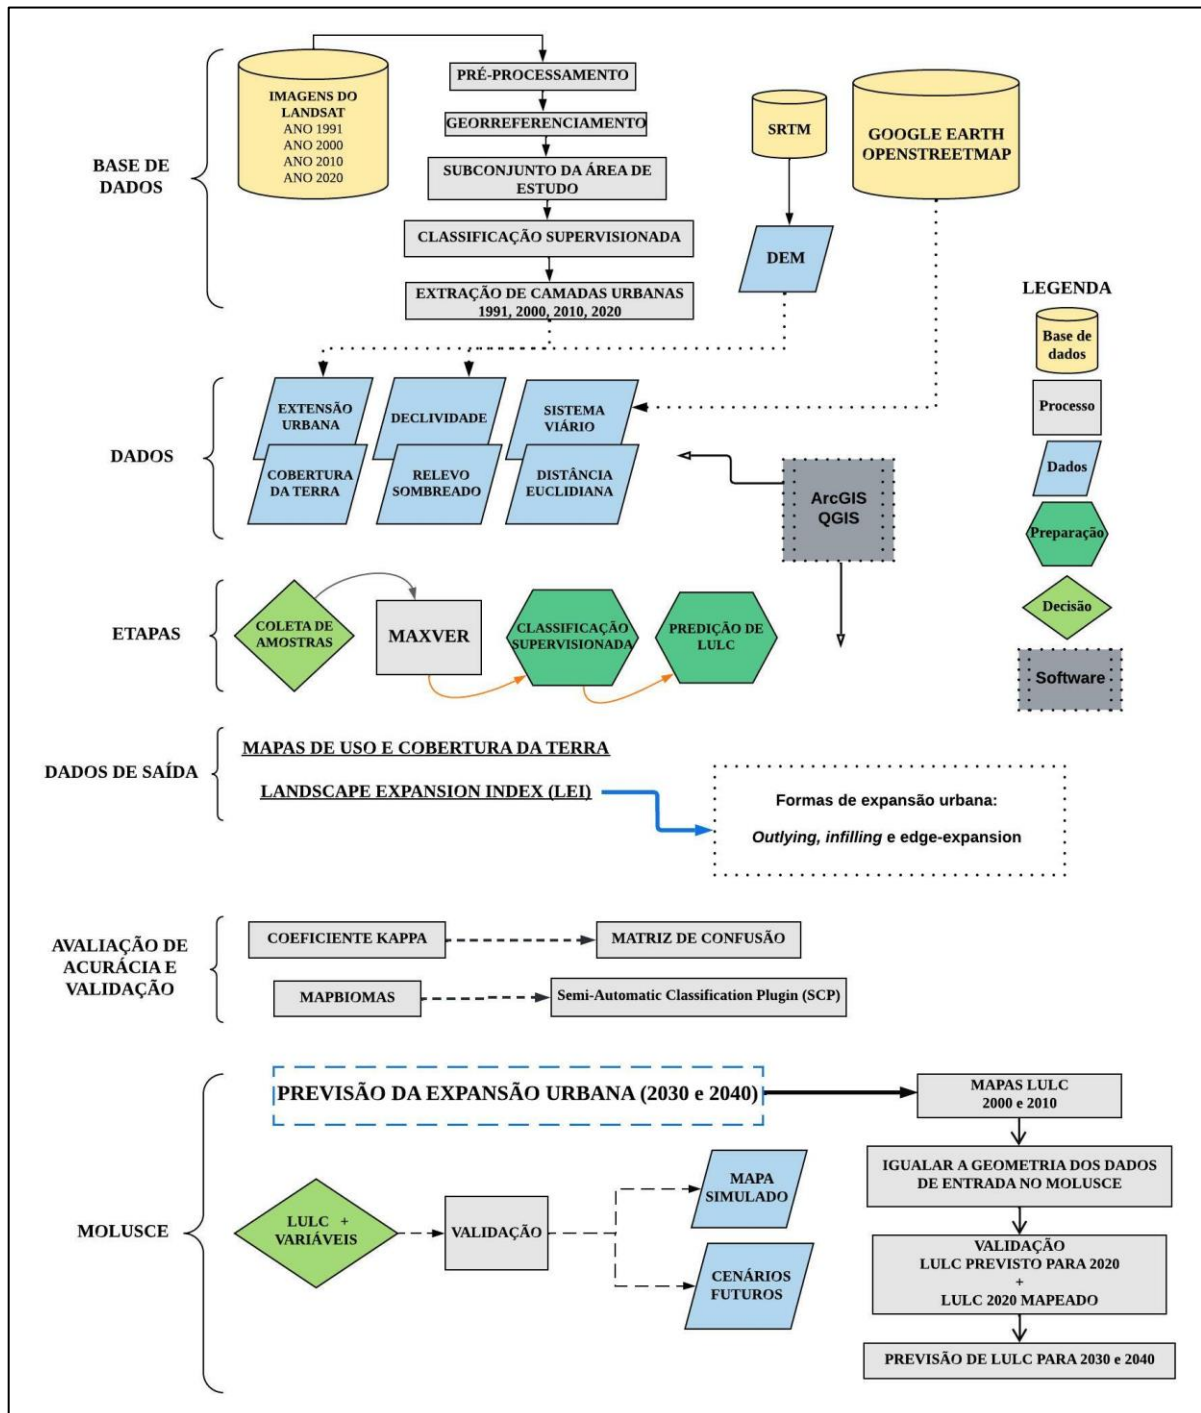


Figura 14 - Fluxograma da metodologia.

Conjunto de dados

Na fase de elaboração dos mapas temáticos, as imagens de satélites utilizadas foram do Landsat e processadas no *Living Atlas* dentro do *software* ArcGIS PRO, onde as imagens são disponibilizadas com correções atmosféricas e o processamento é realizado diretamente na nuvem. Dessa forma, foram adquiridas imagens Landsat para os anos em estudo com resolução espacial de 30 metros com menos de 10% de presença de nuvens (Quadro 4).

Quadro 4 - Imagens dos satélites Landsat.

Satélite	Sensor	Resolução (m)	Cenas	Data	Cobertura de Nuvens
Landsat 5	TM	30 x 30	84790	23/08/1991	0%
			84789	16/09/1991	0%
Landsat 7	ETM+	30 x 30	77412	24/02/2000	0%
			77411	15/06/2000	0%
			59087	07/05/2010	0%
Landsat 5	TM	30 x 30	10416	05/05/2010	0%
Landsat 8	OLI	30 x 30	3524712	09/02/2020	0,05%
			3577558	02/05/2020	0,46%

Fonte: *Living Atlas*.

Seguidamente foram escolhidas as composições falsa-cor para a interpretação do processo de classificação supervisionada, onde foi utilizada a composição R4G3B2 para as imagens do Landsat 5 e 7, e R5G4B3 para as imagens do Landsat 8.

As datas das imagens de satélites utilizadas nesse estudo foram escolhidas de acordo com o mapeamento do Censo Demográfico para todo o Brasil realizado pelo IBGE, que aconteceu em 1991, 2000 e 2010, com exceção para o último ano de 2020. O Censo estava previsto para ocorrer em 2020, mas não foi efetivado em consequência da pandemia de COVID-19 e questões orçamentárias (CANO; UCHÔAS; GALLINA, 2021) e possivelmente acontecerá até o final de 2022.

No site *United States Geological Survey* (USGS) foram adquiridas as cenas do Modelo Digital de Elevação (MDE) obtidas pelo *Shuttle Radar Topography Mission* (SRTM) com 30 metros de resolução espacial e a partir deste, foram gerados o relevo sombreado e a declividade da área de estudo. Além disso, a distância das estradas também foi uma variável utilizada. Embora a distância da estrada e características do relevo sejam utilizadas por muitos pesquisadores para estudos de modelagem de

LULC (SAPUTRA; LEE, 2019), nesse estudo também foi considerada a distância da estação ferroviária, dos centros urbanos, e do município de Porto Alegre. Estes dados foram obtidos a partir do site do *OpenStreetMap* (<https://www.openstreetmap.org>), e foram gerados usando a distância euclidiana no software ArcGIS 10.5 e QGIS 2.18.

Além disso, os quatro mapas temáticos de uso e cobertura da terra para os anos 1991, 2000, 2010 e 2020 serviram como base tanto na análise histórica como nos mapeamentos dos cenários futuros. No *plugin* MOLUSCE, o Modelo Digital de Elevação (MDE), relevo sombreado, declividade, distância da estrada, da estação ferroviária, dos centros urbanos e da capital Porto Alegre (Figura 15), foram os critérios utilizados como mapas de variáveis espaciais nos processos de aprendizagem em um modelo *Multilayer Perceptrons* (MLP) através de *Artificial Neural Network* (ANN).

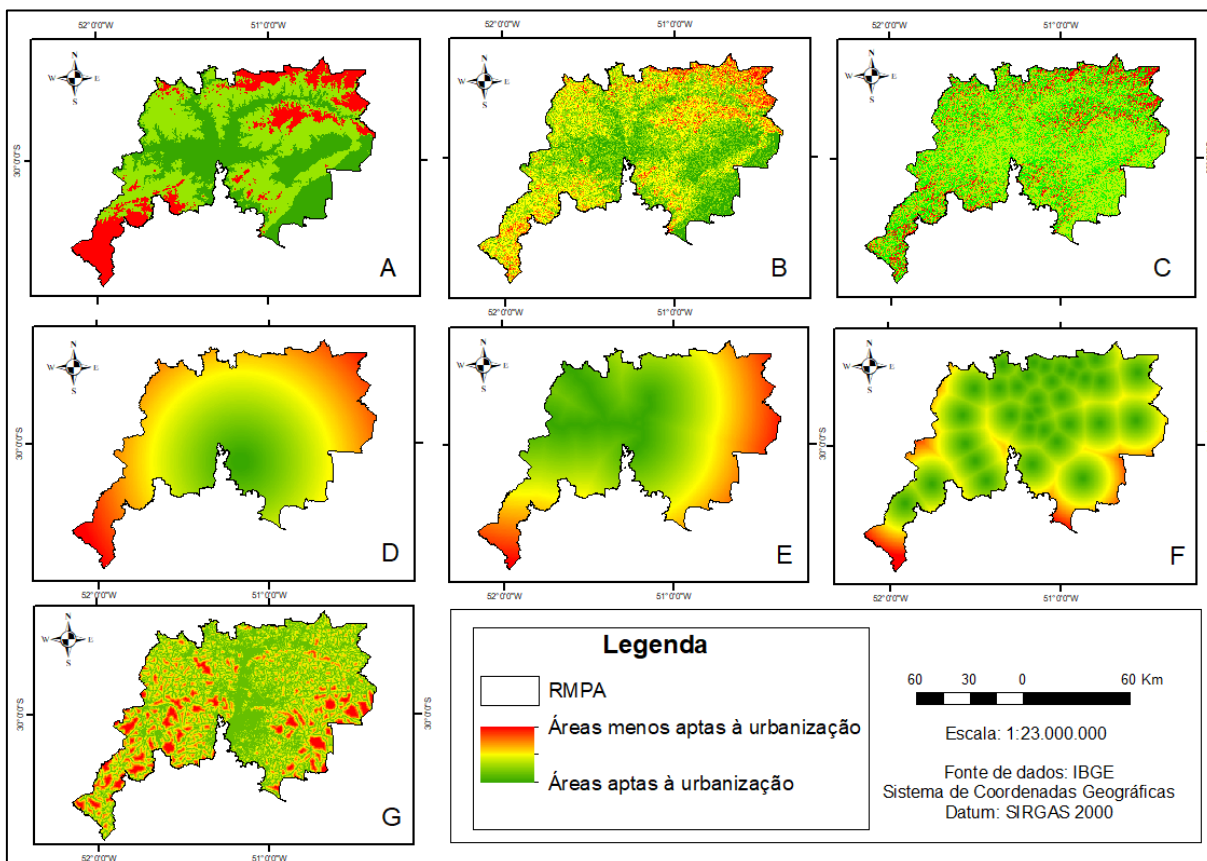


Figura 15 - (A) Mapa do Modelo Digital de Elevação; (B) mapa de declividade; (C) mapa de relevo sombreado; (D) mapa de distância de Porto Alegre; (E) mapa de distância da estação ferroviária; (F) mapa de distância dos centros urbanos; (G) mapa de distâncias das estradas.

A utilização de variáveis auxilia na identificação das probabilidades de transição de uma classe de uso do solo para outra. Essa etapa é importante para a calibração

ser bem-sucedida, uma vez que o MOLUSCE utiliza redes neurais para identificar os padrões de mudanças, fundamentadas nas variáveis e na sua relação com as transições do uso do solo nos anos em estudo.

Classificação das imagens

Para a realização das classificações supervisionadas das imagens de satélites, o classificador utilizado foi o de máxima verossimilhança (MAXVER), conhecido como um dos mais utilizados em mapeamentos de uso e cobertura da terra (YADAV; GHOSH, 2019). Conforme JENSEN (1996), esse algoritmo tem embasamento na probabilidade de um pixel pertencer a uma determinada classe.

Inicialmente, o analista escolhe as classes de informação de seu interesse para realizar a classificação supervisionada a partir de amostras, posteriormente o software compara cada pixel da imagem com as classes definidas pelo analista e o classifica na classe que mais se assemelha.

Foram definidas cinco classes de uso e cobertura da terra para esse estudo, corpo hídrico, solo exposto, urbanização, vegetação arbórea e vegetação rasteira. Posteriormente, 250 pontos amostrais de cada classe identificada na imagem colorida foram sorteados aleatoriamente sobre a área classificada para cada ano em estudo e, posteriormente, foram comparadas com as suas áreas no *Google Earth Pro*, a partir da percepção do analista. Dessa forma, foi elaborada a classificação supervisionada das cenas através da semelhança de cada pixel com as classes fornecidas nas amostras.

Validação do mapeamento do uso e cobertura da terra

A validação do mapeamento é necessária em qualquer método utilizado na classificação das imagens e é a fase posterior a classificação supervisionada que objetiva verificar a acurácia dos resultados obtidos.

Para a verificação da acurácia dos mapas de uso do solo foram utilizados 250 pontos amostrais, sorteados aleatoriamente sobre a área classificada para os anos de 1991, 2000, 2010 e 2020 e foi conferido ponto a ponto a checagem da classificação.

Dessa maneira, para avaliar a classificação e realizar a acurácia dos mapeamentos de uso e cobertura da terra foi utilizado o coeficiente Kappa. Segundo G; GREEN (2019), esse coeficiente considera os erros de comissão e omissão através de uma matriz de confusão para mesclar as informações previstas com as informações reais, resultando em um valor que varia de 0 a 1 mostrando a possibilidade de um pixel de referência ser classificado corretamente.

Foram realizados três testes com quantidades diferentes de pontos aleatórios, e foi notável que densidades menores podem superestimar os resultados em razão da pouca quantidade de amostras. Sendo assim, é importante o uso de mais pontos amostrais e, dessa forma, neste estudo, o cálculo do coeficiente Kappa foi realizado com 250 pontos distribuídos de forma aleatória na imagem.

Posteriormente, foram geradas as matrizes de confusão para os quatro anos de estudo. Para a efetivação dos processamentos foram utilizados o software ArcMap, do pacote ArcGis versão 10.5, o ArcGIS Pro e o QGIS 3.16. e 2.18. A matriz de confusão gerada com as acurácias do usuário, segundo DE JESUS; KUPLICH (2021), são as estimativas de erros e acertos das frações de pixels do mapeamento para cada classe e está relacionada ao erro de comissão, isso ocorre quando um pixel é identificado em uma classe, mas na realidade pertence a outra classe.

As acurácias do produtor são as frações amostrais de pixels de cada classe corretamente atribuídos às suas classes pelos classificadores e está relacionada ao erro de omissão, que ocorre quando um pixel não é mapeado na classe correta. Essa acurácia também foi resultado da matriz de confusão para os quatro anos analisados.

Conforme FERRAZ; VICENS (2019), essas métricas se referem a capacidade do classificador de diferenciar com precisão cada classe de uso e cobertura da terra. Além disso, a acurácia global também foi resultante da matriz e estima a proporção de acerto global dos classificadores.

Dessa maneira, as matrizes de confusão expressam os acertos e os erros de cada classe. No (Quadro 5) constam a interpretação dos resultados do coeficiente Kappa resultantes do algoritmo de Máxima Verossimilhança.

Quadro 5 - Interpretação dos valores de Coeficiente Kappa.

Coeficiente Kappa	Desempenho
< 0	Péssimo
0 < k ≤ 0,2	Ruim
0,2 < k ≤ 0,4	Razoável
0,4 < k ≤ 0,6	Bom
0,6 < k ≤ 0,8	Muito Bom
0,8 < k ≤ 1,0	Excelente

Fonte: (FONSECA, 2000).

O coeficiente Kappa é calculado de acordo com a (Equação 1) demonstrada abaixo (ULLAH, 2019), onde p_o significa a proporção real e p_e a proporção esperada.

$$Kappa = \frac{p_o - p_e}{1 - p_e} \quad (1)$$

Nesse estudo, cinco classes de uso e cobertura da terra foram consideradas e agrupadas a partir das classes de LULC definidas no mapeamento do MapBiomias conforme mostra o (Quadro 6).

Quadro 6 - Classes de LULC dessa pesquisa e as classes agrupadas do MapBiomias.

Classes do MapBiomias	Classes de LULC	Definição
Campo Alagado e Área Pantanosa; Praia, Duna e Areal; Rio, Lago e Oceano;	Corpo Hídrico	Mananciais hídricos como rios, açudes, entre outros.
Outras Áreas não vegetadas; Afloramento Rochoso;	Solo Exposto	Sem cobertura vegetal.
Área Urbanizada	Urbanização	Residencial, comercial, industrial e outras áreas urbanas.
Formação Florestal; Silvicultura;	Vegetação Arbórea	Florestas, arbustos e outros.
Formação Campestre; Pastagem; Mosaico de Agricultura e Pastagem; Arroz; Soja; Mineração; Outras Lavouras Temporárias.	Vegetação Rasteira	Pequenos arbustos, gramíneas, entre outros.

Para validar o mapeamento de uso e cobertura da terra, foi utilizado o *Semi-Automatic Classification Plugin* (SCP) do software QGIS 3.16 que, de acordo com CONGEDO (2021), demonstra um bom desempenho para validar mapeamentos de LULC. Segundo PEREIRA; GUIMARÃES (2018), o SCP possui ferramentas eficientes para automatizar as etapas de classificação e validação da cobertura da terra.

No processo de comparação entre os mapas de LULC, levou-se em consideração a área total de cada classe de uso da terra para classificar as taxas de aumento ou redução dos usos no decorrer dos anos.

Métricas espaciais da expansão urbana

Existem diferentes formas de expansão urbana, segundo LIU *et al.* (2010), a expansão pode ser interpretada como novas áreas urbanas criadas dentro de vazios urbanos nomeados como *infilling*. Além disso, o autor descreve também as novas áreas urbanas, formadas nas proximidades de áreas já existentes, como *edge-expansion* e novas áreas urbanas desenvolvidas longe das antigas, são classificadas como *outlying*.

Nessa pesquisa, foi utilizado o índice de expansão da paisagem (LEI) para reconhecer essas três formas de expansão de áreas urbanas na RMPA. O índice LEI pode ser interpretado conforme a (Equação 2).

$$LEI = \frac{S}{S+Sv} \times 100 \quad (2)$$

Na equação, o S significa a área de cruzamento entre a área do buffer da nova mancha e as manchas já existentes, Sv é a área da categoria vaga na área do buffer e a distância do buffer neste estudo foi determinada em 200 metros. O índice LEI classifica as formas de expansão urbana fornecendo conhecimento sobre os diferentes padrões da expansão da paisagem e da dinâmica temporal.

O LEI varia em intervalo de 0 a 100 e é feito a partir da análise de buffer (LIU *et al.*, 2014). As formas de expansão urbana são classificadas como *outlying*, *infilling*, e *edge-expansion* quando os resultados apresentam o $LEI = 0$, $LEI > 50$ e $0 < LEI < 50$, respectivamente. Assim sendo, conforme JIAO; MAO; LIU (2015), a expansão urbana compreendida como *infilling* é resultado de um LEI maior que 50, *edge-expansion* resultante de um LEI menor que 50, mas não igual a zero, e as manchas classificadas como zero são as *outlying*.

Nesse estudo, o índice LEI foi calculado para a análise histórica da mancha urbana na RMPA entre 1991 e 2020 e também foi aplicado na previsão de análise

futura entre 2020 e 2040, com o objetivo de gerar conhecimento sobre como a mancha urbana se modificou e expandiu nos últimos 30 anos, bem como compreender se futuramente essa dinâmica acontecerá da mesma forma ou não.

Elaboração dos Cenários futuros de LULC

O sistema CA é baseado em regras de transição, esse método é amplamente utilizado e apropriado para representar, analisar e prever processos geográficos (CLARKE; GAYDOS, 1998). Nesta pesquisa, para a elaborar os cenários futuros de LULC, foi utilizado CA através do *plugin* MOLUSCE do QGIS.

O modelo de previsão depende de dois tipos de variáveis, independentes e dependentes. Os mapas de LULC anteriormente classificados dos anos 2000, 2010 e 2020 foram usados nesta pesquisa como variáveis independentes. A função de distância euclidiana e a elevação digital foram utilizadas para medir as variáveis dependentes como elevação, declividade, distância das estradas, dos centros urbanos, da capital e da estação ferroviária.

Posteriormente, a matriz de potencial de transição foi gerada com base na regra do estado de cada célula para a próxima etapa, dependendo das propriedades das variáveis dependentes das células próximas a ela. As matrizes de transição levam o modelo CA a prever os futuros mapas de LULC dos anos 2030 e 2040.

A matriz de transição é importante em situações com muita ambiguidade na implementação de dados de entrada. Nesse processo, é gerado um índice que classifica a paisagem de zero a um, onde os resultados próximos a 1 nas entradas diagonais representam a estabilidade da classe, enquanto valores próximos a 0 indicam que ocorreram mudanças no período estudado (Sajan et al., 2022).

Para compreender o processo de LULC futuro, esta pesquisa objetiva identificar os fatores responsáveis por essas mudanças na modelagem futura de LULC. No modelo CA, as probabilidades de transição do processo de aprendizagem MLP-ANN são empregadas para descrever estas mudanças.

O *plugin* MOLUSCE no *software* QGIS 2.18 apresenta seis etapas bem definidas para realizar o processo de previsão de LULC. A primeira etapa inclui os mapas LULC para 2000 e 2010 e a partir destes, é realizada uma simulação para 2020

(Figura 16), objetivando comparar e validar a classificação supervisionada realizada para 2020 nesse estudo.

Os fatores de variáveis espaciais como MDE, mapa de declividade, relevo sombreado, distância da estrada, da estação ferroviária, dos centros urbanos e da capital são inseridos no modelo para obter um mapa de mudança de cobertura da terra a partir do qual o padrão de mudança para a área de estudo entre 2010 e 2020 é estabelecido.



Figura 16 - Comparação entre o dado modelado para 2020 e LULC de 2020.

Posteriormente, são calculadas as mudanças de classes de LULC em um determinado período e uma matriz de transição é gerada, a qual mostra a proporção de pixels que se alteraram de uma cobertura e uso da terra para outra. A matriz de transição é fundamental para monitorar a dinâmica espaço-temporal de LULC. A matriz possui linhas e colunas que representam as classes de LULC no início e no final do período analisado.

Os valores das diagonais da matriz são compostas pelo nível de estabilidade de cada classe, isto é, o número de pixels que permaneceram na mesma classe ao longo do período estudado. Os resultados fora da diagonal significam as transições entre as classes (Muhammad et al., 2022).

Além disso, também foi criado um mapa de mudança de área que mostra a mudança na terra entre 2010 e 2020 em todas as cinco classes. Este é um processo importante, uma vez que os futuros mapas de LULC são previstos presumindo que os

padrões e dinâmicas existentes estão sendo continuados. Dessa forma, com base nas imagens classificadas de 2010 e 2020 e com os dados utilizados, as previsões de LULC são geradas para 2030 e 2040.

Modelagem de potencial de transição

Embora existam vários métodos para calcular mapas de transição potencial, para calibrar e modelar mudanças de LULC, cada metodologia usa informações de mudança de LULC e fatores geográficos como dados de entrada. Na modelagem da previsão de LULC desse estudo, foi escolhida a técnica MLP-ANN para prever o mapa de LULC para os anos de 2030 e 2040.

Neste processo, é gerado um índice contínuo que descreve o terreno em uma escala de 0 a 1. As interações entre os neurônios ligados e a alteração do peso das conexões entre eles são os elementos essenciais da metodologia abordada. Depois de cinco testes, os seguintes parâmetros foram definidos ao prever o mapa LULC para o ano de 2030 e 2040: *Neighbourhood* = 1 pixel vizinho (vizinhança), iterações = 1000, camada oculta = 10, valor de momento 0,05 e taxa de aprendizado = 0,100 como pode ser observado na (Figura 17).

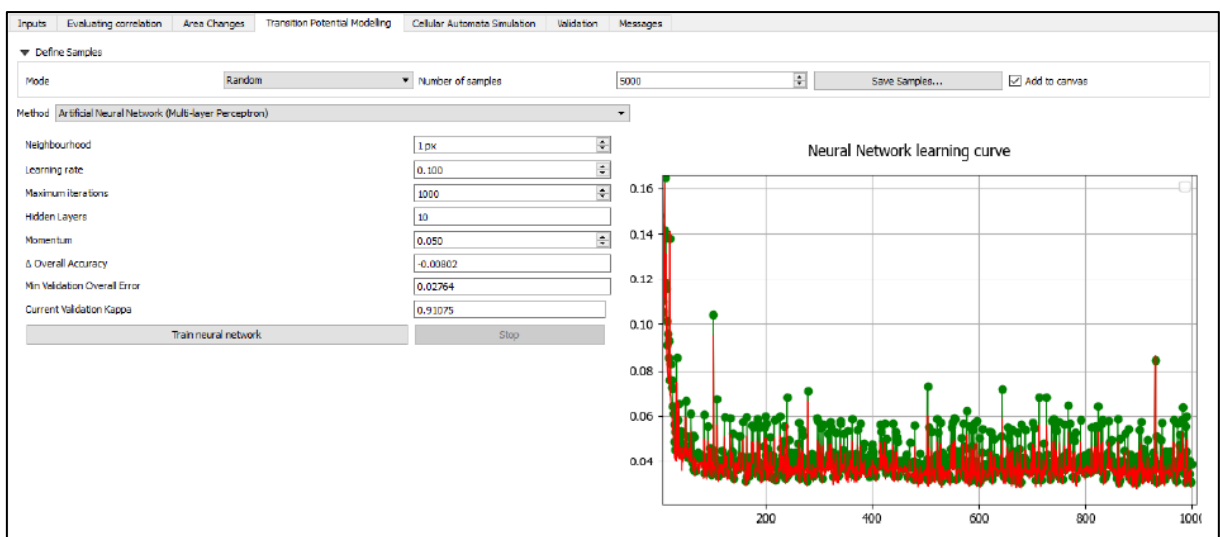


Figura 17 - Treinamento para a simulação de 2020.

A decisão da técnica foi por ser a que os pesquisadores obtêm resultados mais satisfatórios quando as variáveis são os dados de LULC, pois estes, são usados como uma entrada no MLP-ANN para calibrar e modelar as mudanças de LULC futuras.

RESULTADOS

Análise da mudança espaço-temporal do uso e cobertura da terra na RMPA nos últimos 30 anos

Os resultados do mapeamento de uso e cobertura da terra para a região metropolitana de Porto Alegre nos anos de 1991, 2000, 2010 e 2020 são apresentados nas (Figuras 18, 19, 20 e 21). A área total e a porcentagem de cada classe de uso e cobertura da terra nos diferentes anos de estudo estão apresentadas na (Tabela 11).

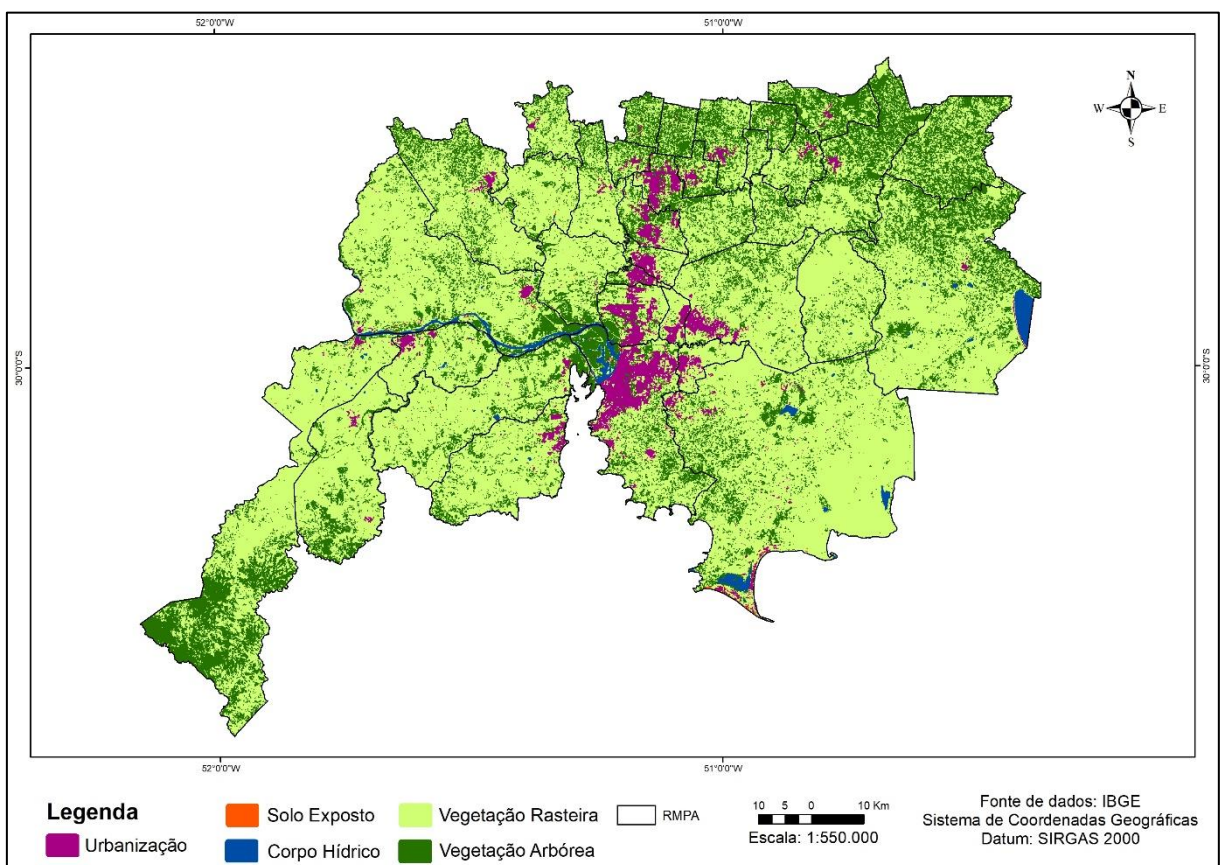


Figura 18 - Mapa de uso e cobertura da terra da RMPA em 1991.

A área territorial da RMPA é 10.334,7 km² e nos resultados do mapeamento compreende-se que no ano de 1991 havia 395,2 km² de área construída na área de estudo. Entre 1991 e 2000 observa-se um aumento de aproximadamente 14 km² de área construída na RMPA. No decorrer de 2000 até 2010 as áreas construídas aumentaram em 62 km² e de 2010 para 2020 houve um acréscimo de 221 km² de área construída. Os resultados são compreendidos a partir da classificação supervisionada de uso e cobertura da terra mapeados nesse estudo (Tabelas 8, 9, 10 e 11).

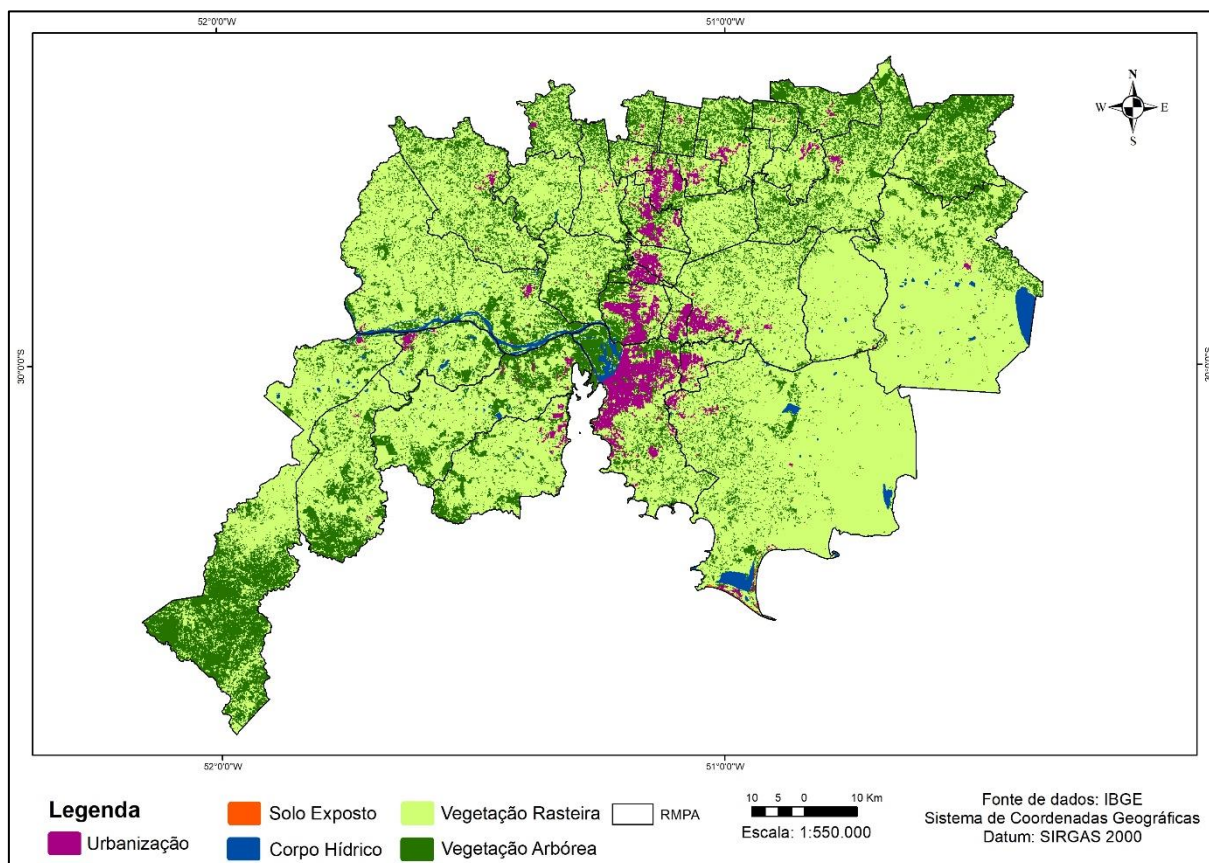


Figura 19 - Mapa de uso e cobertura da terra da RMPA em 2000.

Também foram resultados das classificações supervisionadas as matrizes de transição de LULC. Essa verificação é essencial na análise de mudanças temporais para mostrar como cada tipo de LULC foi projetada para mudar na área de estudo. Através do *plugin* MOLUSCE, a matriz de potencial de transição foi calculada durante os períodos de 1991 a 2000, 2000 a 2010, 2010 a 2020, 2020 a 2030 e 2030 a 2040 com base nas condições de LULC existentes e as variáveis consideradas.

Considerando as classes Urbanização, Solo Exposto, Corpo Hídrico, Vegetação Rasteira e Vegetação Arbórea como as classes 1, 2, 3, 4 e 5, respectivamente, a (Tabela 8) mostra a matriz de transição das classes de uso da

terra durante 1991 e 2000, em que a urbanização apresentou um acréscimo de aproximadamente 14 km², enquanto solo exposto apresentou uma diminuição de mais de 5 km² e corpo hídrico um aumento de 12 km² aproximadamente.

Tabela 8 - Matriz de transição de LULC entre 1991 e 2000.

Classes	1991 (Km ²)	2000 (Km ²)	Δ (Km ²)	1991%	2000%	Δ (%)
1	395,2	409,5	14,3	3,8	3,96	0,16
2	9,1	3,6	-5,5	0,1	0,03	-0,07
3	127,8	139,9	12,1	1,2	1,35	0,15
4	7.189,8	7.316,9	127,1	69,6	70,8	1,2
5	2.612,8	2.464,8	-148	25,3	23,86	-1,44

Seguidamente, a (Figura 20) mostra o mapa de classificação supervisionada da RMPA para o ano 2010 realizado nesse estudo.

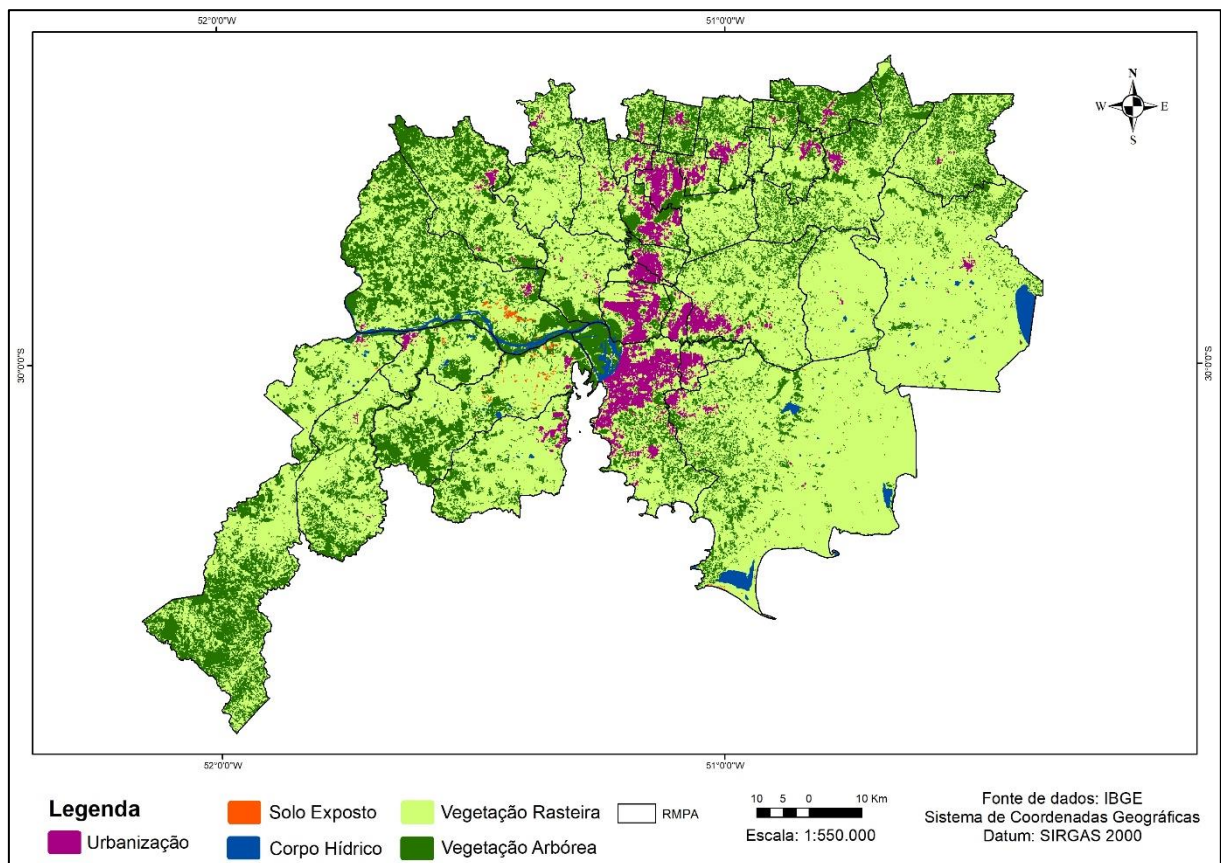


Figura 20 - Mapa de uso e cobertura da terra da RMPA em 2010.

Entre 2000 e 2010 (Tabela 9), houve um aumento de aproximadamente 62 km² na classe urbanização. O solo exposto também apresentou um aumento em 13 km² e

a classe corpo hídrico aumentou 14 km², aproximadamente. Além disso, notou-se uma redução de 312 km² na vegetação rasteira, enquanto a vegetação arbórea demonstrou um aumento de área em aproximadamente 222 km².

Tabela 9 - Matriz de transição de LULC entre 2000 e 2010.

Classes	2000 (Km ²)	2010 (Km ²)	Δ (Km ²)	2000%	2010%	Δ (%)
1	409,5	471,5	62	3,96	4,56	0,6
2	3,6	16,7	13,1	0,03	0,16	0,13
3	139,9	154,1	14,2	1,35	1,49	0,14
4	7.316,9	7.004,8	-312,1	70,8	67,77	-3,03
5	2.464,8	2.687,6	222,8	23,86	26,02	2,16

Posteriormente, a (Figura 21) apresenta o mapa de classificação supervisionada para o ano de 2020 realizado nesse estudo.

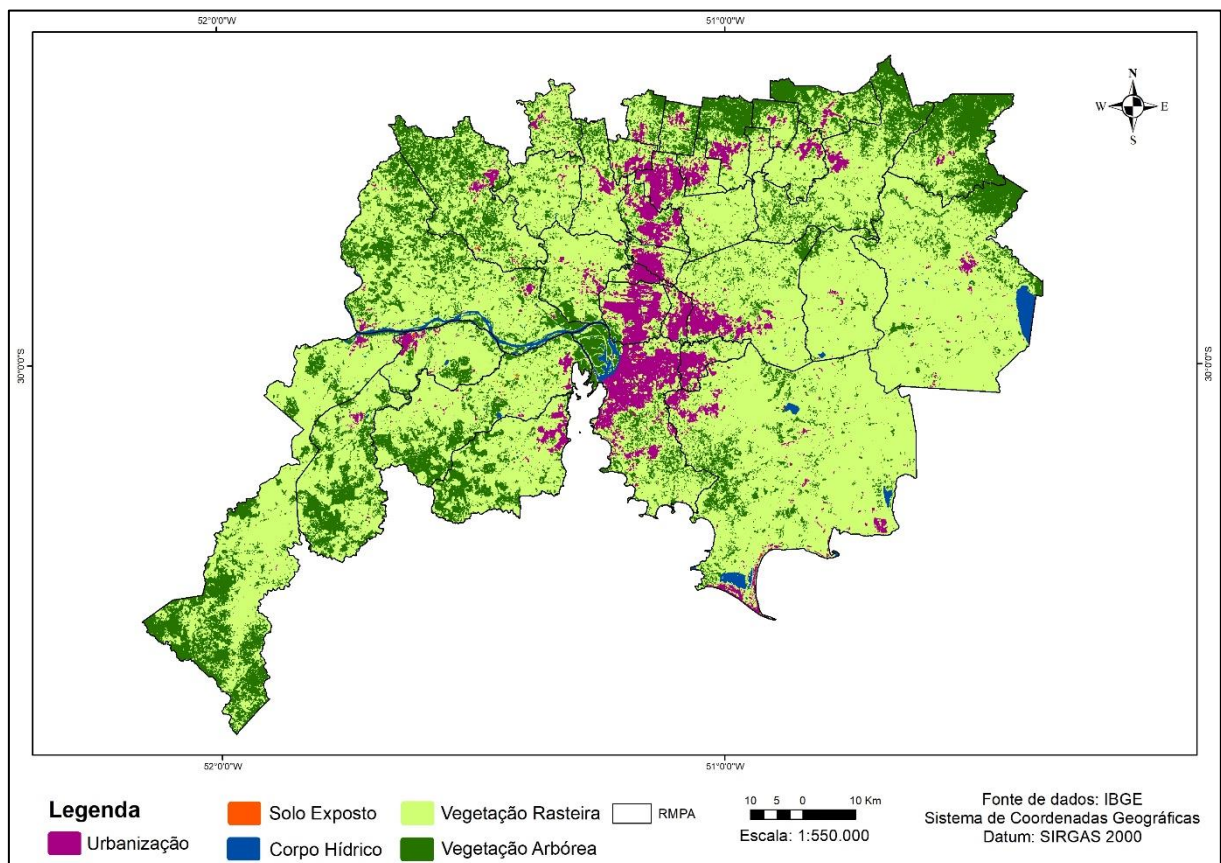


Figura 21 - Mapa de uso e cobertura da terra da RMPA em 2020.

Entre 2010 e 2020 (Tabela 10), aconteceu um aumento de aproximadamente 221 km² na classe urbanização. Outro resultado bastante significativo foram as áreas de vegetação arbórea, que diminuíram cerca de 397 km², aproximadamente.

Tabela 10 - Matriz de transição de LULC entre 2010 e 2020.

Classes	2010 (Km ²)	2020 (Km ²)	Δ (Km ²)	2010%	2020%	Δ (%)
1	471,5	693,3	221,8	4,56	6,71	2,15
2	16,7	3,3	-13,4	0,16	0,03	-0,13
3	154,1	124,3	-29,8	1,49	1,2	-0,29
4	7.004,8	7.223,9	219,1	67,77	69,9	2,13
5	2.687,6	2.289,9	-397,7	26,02	22,16	-3,86

Os mapas temáticos de uso e cobertura da terra mostram visualmente as classes que aumentaram ou diminuíram no decorrer dos 30 anos mapeados. Nota-se que a vegetação rasteira é a classe predominante para todos os anos de estudo na RMPA, seguida pela vegetação arbórea e pelas áreas urbanizadas (Tabela 11).

A análise de mudança LULC explorou as variações dinâmicas espaciais no padrão LULC durante o período de estudo. Os resultados de 1991 a 2020 mostraram uma notável expansão nas áreas urbanas. A (Tabela 11) mostra as áreas de cada classe determinada nesse estudo, juntamente com suas respectivas porcentagens.

Tabela 11 - Áreas das classes de uso e cobertura da terra nos anos de estudo.

Uso da terra	Área (km ²)							
	1991	(%)	2000	(%)	2010	(%)	2020	(%)
Corpo Hídrico	127,8	1,22	139,9	1,36	154,1	1,5	124,3	1,2
Solo Exposto	9,1	0,08	3,6	0,04	16,7	0,2	3,3	0,1
Urbanização	395,2	3,8	409,5	4,1	471,5	4,6	693,3	6,7
Vegetação Arbórea	2.612,8	25,3	2464,8	23,8	2.687,6	26	2.289,9	22,1
Vegetação Rasteira	7.189,8	69,6	7.316,9	70,7	7.004,8	67,7	7.223,9	69,9
Total	10.334,7	100	10.334,7	100	10.334,7	100	10.334,7	100

Os municípios Viamão (1.497 km²), Santo Antônio da Patrulha (1.050 km²), São Jerônimo (935,5 km²) e Triunfo (817,6 km²), possuem a maior extensão territorial entre os municípios da RMPA, onde juntos eles correspondem a mais que 40% da área metropolitana de Porto Alegre. No entanto, municípios de menor extensão, abaixo de 50 km², são Esteio (27,6 km²), Araricá (35,3 km²) e Cachoeirinha (43,7 km²).

De acordo com o Censo Demográfico do IBGE, em 2010 Porto Alegre possuía 1,409 milhões de habitantes, representando aproximadamente 35% da população

metropolitana. No entanto, ao calcular a densidade demográfica considerando toda a população como urbana e apenas as áreas urbanas identificadas nessa pesquisa, nota-se que em 2020 ocorre uma alta densidade demográfica em Porto Alegre e Alvorada. Nos municípios Eldorado do Sul, Arroio dos Ratos, Charqueadas, Santo Antônio da Patrulha e Viamão, ocorre uma baixa densidade demográfica, isto é, o tamanho de área construída é elevado em relação a população total destes municípios (Figura 22).




Figura 22 - Relação entre população e área construída dos municípios da RMPA em 2020.

Análise da acurácia e validação do mapeamento

As acurácias da classificação para os anos de 1991, 2000, 2010 e 2020 encontram-se respectivamente nas (Tabelas 12, 13, 14, e 15). No mapeamento realizado para o ano de 1991 foi obtido um coeficiente Kappa de 0,82, classificado como excelente. A precisão geral e matriz de confusão podem ser consultadas na (Tabela 12).

Tabela 12 - Acurácia da Classificação do uso e cobertura da terra em 1991.

Classes de Uso do Solo	Corpo Hídrico	Solo Exposto	Urbanização	Vegetação Arbórea	Vegetação Rasteira	Total
Corpo Hídrico	5	0	0	1	5	11
Solo Exposto	0	9	0	0	1	10
Urbanização	2	1	14	5	13	35
Vegetação Arbórea	0	0	0	55	4	59
Vegetação Rasteira	0	0	1	9	125	135
Total	7	10	15	70	148	250
Acurácia do produtor (%)	0,75	0,90	0,90	0,93	0,92	
Acurácia do usuário (%)	0,71	0,90	0,93	0,78	0,84	
Acurácia Global	0,83					
Coeficiente Kappa	0,82					

Em 2000, a classificação supervisionada apresentou um coeficiente Kappa de 0,87. A (Tabela 13) mostra os valores resultantes da matriz de confusão, na qual contém os erros que ocorreram na classificação supervisionada, por exemplo, do total de 151 pixels de vegetação rasteira foi erroneamente classificado 13 pixels como urbanização.

Tabela 13 - Acurácia da Classificação do uso e cobertura da terra em 2000.

Classes de Uso do Solo	Corpo Hídrico	Solo Exposto	Urbanização	Vegetação Arbórea	Vegetação Rasteira	Total
Corpo Hídrico	9	0	0	1	0	10
Solo Exposto	0	10	0	0	0	10
Urbanização	0	0	13	0	13	21
Vegetação Arbórea	0	0	0	59	4	63
Vegetação Rasteira	0	0	1	6	134	146
Total	9	10	14	66	151	250
Acurácia do produtor (%)	0,90	1	0,90	0,94	0,92	
Acurácia do usuário (%)	1	1	0,57	0,89	0,89	
Acurácia Global	0,88					
Coeficiente Kappa	0,87					

Posteriormente, obteve-se também o resultado da matriz de confusão para a classificação supervisionada do ano de 2010, que mostrou um coeficiente Kappa de 0,86 definido como excelente. A (Tabela 14) contém os valores totais de acertos e erros que ocorreram em cada classe de uso do solo, como na classe de urbanização que dos 12 pixels definidos como área urbana, 1 foi interpretado como vegetação rasteira, pois em ambas as classes o pixel foi identificado como semelhante, devido ao fato de ser uma época de solo úmido na área de estudo.

Tabela 14 - Acurácia da Classificação do uso e cobertura da terra em 2010.

Classes de Uso do Solo	Corpo Hídrico	Solo Exposto	Urbanização	Vegetação Arbórea	Vegetação Rasteira	Total
Corpo Hídrico	10	0	0	0	0	10
Solo Exposto	0	9	1	0	0	10
Urbanização	0	2	10	1	19	32
Vegetação Arbórea	1	0	0	82	4	87
Vegetação Rasteira	0	1	1	3	106	111
Total	11	12	12	86	129	250
Acurácia do produtor (%)	1	0,90	0,80	0,94	0,95	
Acurácia do usuário (%)	0,91	0,75	0,83	0,95	0,82	
Acurácia Global	0,87					
Coeficiente Kappa	0,86					

O mapeamento realizado para 2020 mostrou mais confusões nas classes vegetação arbórea e vegetação rasteira, e mais acertos na classe urbanização. Como nesse estudo o foco principal foi analisar as áreas de urbanização, a escolha da composição das bandas das imagens utilizadas para a realização da classificação supervisionada priorizou a que melhor identificou a classe de áreas urbanas.

Assim sendo, de acordo com a (Tabela 15), obteve-se o resultado da matriz de confusão para a classificação supervisionada de 2020, com um coeficiente Kappa de 0,83.

Tabela 15 - Acurácia da Classificação do uso e cobertura da terra em 2020.

Classes de Uso do Solo	Corpo Hídrico	Solo Exposto	Urbanização	Vegetação Arbórea	Vegetação Rasteira	Total
Corpo Hídrico	10	0	0	0	0	10
Solo Exposto	0	8	0	0	2	10
Urbanização	1	1	12	0	16	30
Vegetação Arbórea	0	0	0	49	1	50
Vegetação Rasteira	0	0	2	17	131	150
Total	11	9	14	66	150	250
Acurácia do produtor (%)	1	0,80	0,80	0,98	0,87	
Acurácia do usuário (%)	0,91	0,89	0,86	0,74	0,87	
Acurácia Global	0,84					
Coefficiente Kappa	0,83					

A acurácia do mapeamento da cobertura do uso da terra foi avaliada pela matriz de confusão gerada a partir das amostras de validação para os anos em estudo. As acurácias significam as formas de avaliar a qualidade da classificação de imagens, e após concluir a classificação do uso e cobertura da terra, é importante fazer a sua avaliação.

Nessa etapa da pesquisa, as acurácias globais (AG), por classe (AC), e do usuário (AU), e o coeficiente Kappa foram calculados para as classes de uso da terra (Tabela 16). As AGs em 1991, 2000, 2010 e 2020 foram de 83%, 88%, 87% e 84%, respectivamente. Enquanto o coeficiente Kappa foi 0,82, 0,87, 0,86 e 0,83, para os mesmos anos. Portanto, pode-se considerar que esses resultados do mapeamento do uso e cobertura da terra foram classificados como satisfatórios e atenderam às necessidades dessa pesquisa.

Tabela 16 - Avaliação de precisão para as classes classificadas nos quatro anos.

Ano	Uso do Solo	AC (%)	AU (%)	AG (%)	Kappa
1991	Corpo Hídrico	75%	71%	83%	0,82
	Solo Exposto	90%	90%		
	Urbanização	90%	93%		
	Vegetação Arbórea	93%	78%		
	Vegetação Rasteira	92%	84%		
2000	Corpo Hídrico	90%	100%	88%	0,87
	Solo Exposto	100%	100%		
	Urbanização	90%	87%		
	Vegetação Arbórea	94%	89%		
	Vegetação Rasteira	92%	89%		
2010	Corpo Hídrico	100%	91%	87%	0,86
	Solo Exposto	90%	75%		
	Urbanização	80%	83%		
	Vegetação Arbórea	94%	95%		
	Vegetação Rasteira	95%	82%		
2020	Corpo Hídrico	100%	91%	84%	0,83
	Solo Exposto	80%	89%		
	Urbanização	80%	86%		
	Vegetação Arbórea	98%	74%		
	Vegetação Rasteira	87%	87%		

Todas as densidades amostrais foram classificadas como “excelentes” ao analisar o coeficiente Kappa para o algoritmo Máxima Verossimilhança. O melhor resultado foi obtido em 2000, com coeficiente Kappa de 0,87 e o menor resultado em 1991 com Kappa de 0,82. Observa-se também que quanto menor a densidade amostral, melhor é o resultado do coeficiente Kappa.

Posteriormente, também foi realizada a validação do mapeamento da classificação supervisionada a partir de uma comparação com o mapeamento realizado pelo MapBiomias. Os resultados mostram que as classes onde houveram maiores confusões na classificação supervisionada desta pesquisa, são as mesmas áreas em que o MapBiomias classificou como não observado.

Para conseguir uma maior confiabilidade dos resultados do mapeamento de uso e cobertura da terra, também foi realizada a validação através do *Semi-Automatic Classification Plugin* (SCP) disponível no *software* QGIS. A base inserida como verdade foi o mapeamento do MapBiomias a ser comparado com o mapeamento realizado nesse estudo e dessa forma, o SCP gerou o cruzamento de ambos os mapas gerando um terceiro mapa validado. O gráfico resultante da validação (Figura 23), mostrou a quantificação em porcentagem das classes assertivas, verificadas nos

dois mapeamentos, assim como as classes classificadas como outro tipo de uso e cobertura do solo para os quatro anos em estudo.




Figura 23 - Quantificação da validação do uso e cobertura da terra para os anos em estudo.

Os resultados demonstrados no gráfico anterior, indicam na cor azul as classes que coincidiram, ou seja, foram classificadas igualmente nos dois mapeamentos. Na cor laranja observa-se a discrepância entre as classificações realizadas neste estudo e a disponibilizada pelo MapBiomias. Observou-se que em 1991, foi o ano que apresentou maior confusão de pixel entre a classe urbanização e corpo hídrico,

significando que aconteceu alta porcentagem dessas duas classes de uso do solo verificadas como outras classes, isso é perceptível no gráfico de validação pelo SCP. O mapeamento de 2020 foi o ano em que a classe de urbanização dos dois mapeamentos mais coincidiu e neste mesmo ano a classe vegetação rasteira do mapeamento desse estudo também coincidiu com o mapeamento do MapBiomias.

Análise da expansão urbana e métricas espaciais para a RMPA entre 1991 e 2020

Os resultados das distribuições espaciais das áreas urbanas e expansão da RMPA de 1991 a 2020 podem ser observados na (Figura 24) e serve como base para identificar o padrão da evolução da mancha urbana na região.

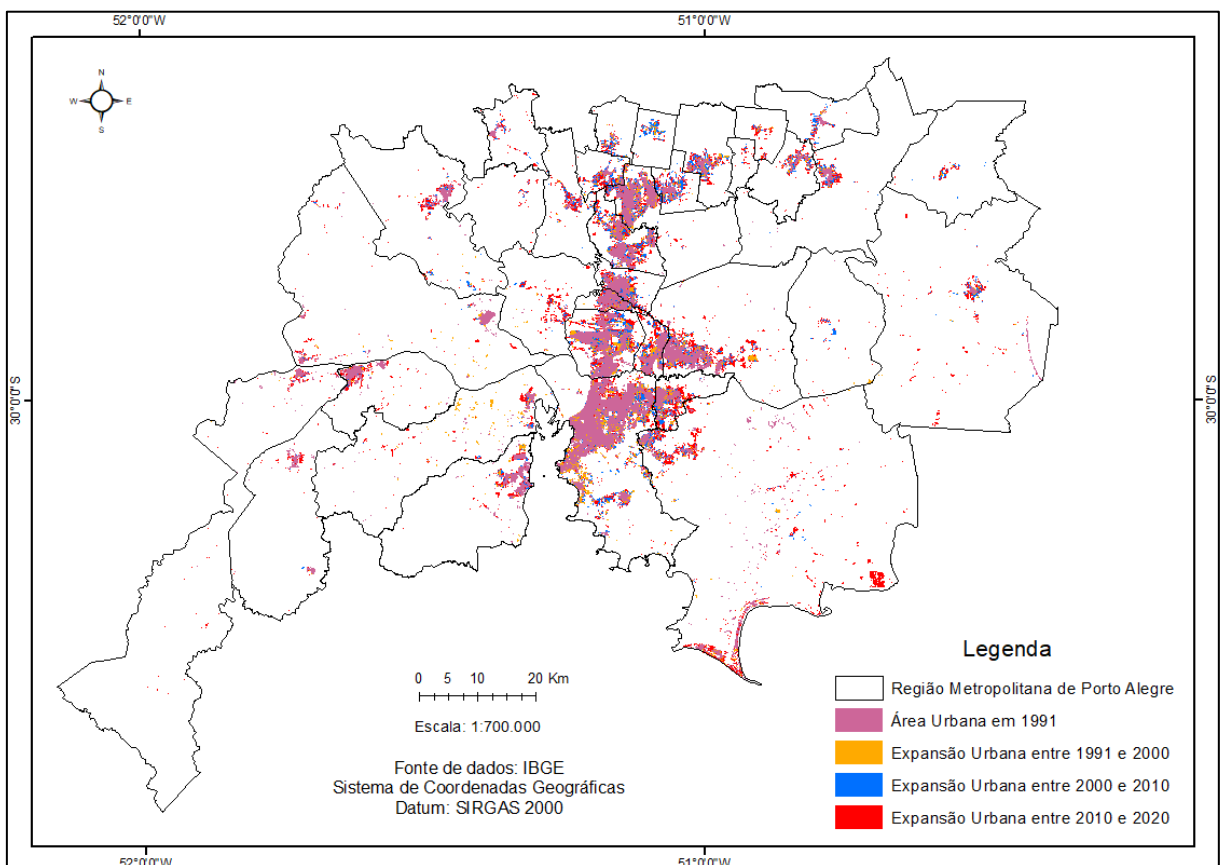


Figura 24 - Distribuições espaciais históricas do aumento da mancha urbana na RMPA entre 1991 e 2020.

Percebe-se que grande parte da expansão urbana entre os anos de 1991 e 2000 continuou acontecendo próximos a Porto Alegre, nos municípios Canoas,

Cachoeirinha, Alvorada, Sapucaia do Sul e Esteio. Entre os anos de 2000 e 2010 houve expansão também nos municípios Dois Irmãos, Ivoti e Canoas. E entre 2010 e 2020 aumentou principalmente em Viamão e Gravataí.

Conforme os resultados desse estudo, no município de Viamão aconteceu uma grande concentração de áreas construídas recentes, localizadas na região oposta a Porto Alegre e mais próximo do Guaíba. Esses locais mais afastados das grandes aglomerações urbanas são propícios para a população que busca morar mais longe das cidades e mais perto de áreas naturais, buscando uma melhor qualidade de vida.

Outrossim, ocorreram várias transições de uso e cobertura da terra na RMPA nos anos analisados, por exemplo, áreas com vegetação arbórea foram substituídas por áreas urbanas, pois conforme as cidades crescem o solo vai sendo modificado e as classes de LULC conseqüentemente também. Corpo hídrico e solo exposto foram usos que apresentaram poucas mudanças ao longo dos anos.

Os resultados também mostram que a mancha urbana aumentou consideravelmente em Cachoeirinha, Canoas, Esteio, Porto Alegre, São Leopoldo e Sapucaia do Sul, municípios onde se encontram a maior área urbana total em km² na RMPA. Cada um dos municípios nos quatro anos estudados, possui suas respectivas mudanças de LULC e algumas classes mostraram um aumento na porcentagem de áreas enquanto outras indicam uma diminuição significativa (Figura 25).




Figura 25 - Quantificação de LULC para os anos de 1991, 2000, 2010, e 2020.

O aumento de área urbana no município de Cachoeirinha foi gradativo nos anos estudados, e isso é explicado por ser um município onde reside uma grande concentração de trabalhadores em Porto Alegre, que por sua vez oferece muitas oportunidades, resultando no aumento da densidade populacional em municípios vizinhos. O mesmo ocorre nos municípios ao redor da capital Porto Alegre, tornando a dinâmica da expansão urbana um assunto almejado por pesquisadores que auxiliam no planejamento das cidades.

Dessa maneira, a métrica espacial utilizada indicou que entre 1991 e 2020 a forma de expansão urbana predominante na RMPA totalizou 93% na forma borda-expansão, principalmente nos municípios de Porto Alegre, Alvorada, Canoas, Esteio, Nova Santa Rita e São Leopoldo. A (Figura 26) mostra a distribuição espacial dos três tipos de expansão urbana identificados nos três períodos analisados.

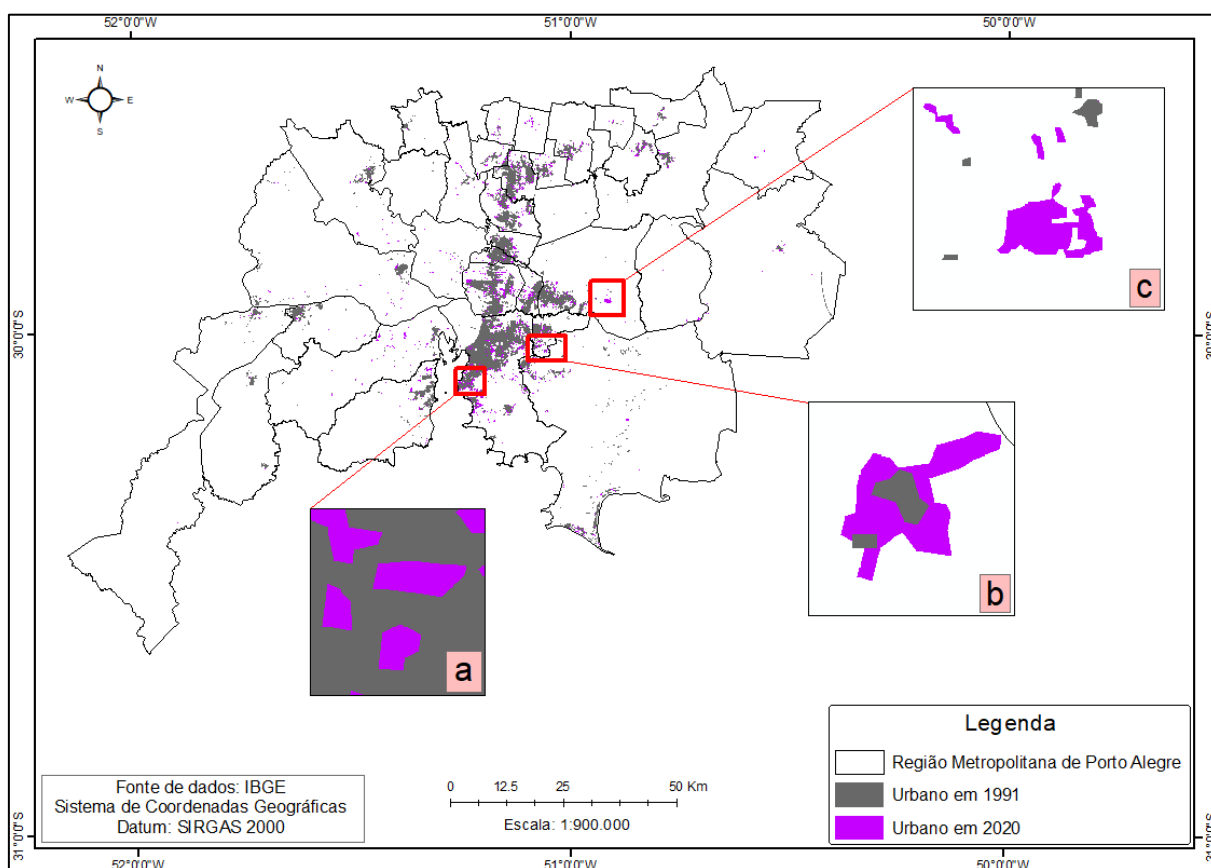


Figura 26 - a) preenchimento; b) expansão de borda; c) periférico.

De acordo com os resultados, a forma de expansão urbana compreendida por borda-expansão foi a mais verificada na RMPA nos últimos 30 anos. Já a forma de

expansão periférica e de preenchimento ocorreram em 5% e 2%, respectivamente, nos municípios mais afastados de Porto Alegre, principalmente em Capela de Santana, Montenegro, Viamão e Guaíba.

Observou-se também que a concentração principal de áreas urbanizadas desde 1991 continuou ocorrendo principalmente nas redondezas de Porto Alegre e Canoas. Os municípios que não apresentaram expansão urbana nas bordas de áreas já construídas anteriormente, se encontram em locais com menos aglomeração intensa de tráfego, urbanização e concentração de pessoas dos municípios vizinhos. A forma de expansão urbana *outlying* acontece por quem escolhe uma moradia mais afastada dos locais urbanos intensos.

O mapeamento histórico também revela que entre 1991 e 2020, a classe urbanização teve um aumento de 298 km², enquanto as áreas de vegetação diminuíram um total de 323 km².

Análise da previsão de expansão da mancha urbana entre 2020 e 2040

Os resultados das distribuições espaciais das áreas urbanas e expansão da RMPA entre 2020 e 2040 podem ser observados na (Figura 27) e servem como base para identificar o padrão da evolução da mancha urbana na região.

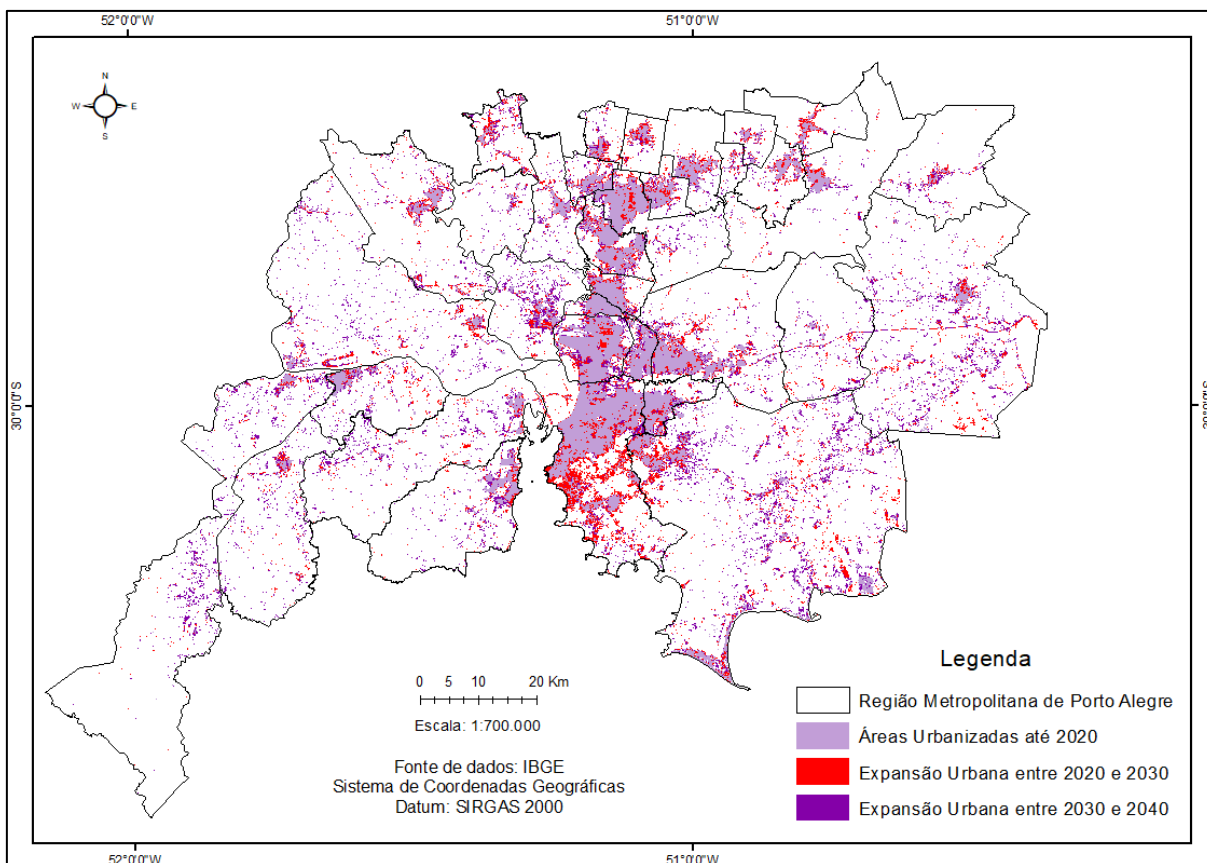


Figura 27 - Distribuições espaciais da previsão da mancha urbana na RMPA.

É observado que os padrões de expansão seguem semelhantes desde 1991 e na análise futura possivelmente o foco continuará sendo expandir nas redondezas da capital Porto Alegre. O mapa da (Figura 27) expressa na cor lilás as áreas urbanas construídas até o ano 2020. Na legenda, a cor vermelha mostra a expansão urbana prevista para ocorrer entre 2020 e 2030, onde os resultados apontam maior concentração na parte sul de Porto Alegre e em locais que ainda não foram urbanizados no município de Canoas. Por último, na cor roxa, nota-se que a maior parte da expansão entre 2030 e 2040 continuará sendo nas redondezas dos municípios que ainda existem espaço para moradia.

Se assim for, percebe-se que o foco principal continuará sendo a busca por residir em áreas mais perto possíveis de Porto Alegre e municípios que possuem maiores oportunidades. Porém, mesmo que seja em menor ocorrência, também acontecerá segundo as previsões de LULC futuros, expansões em locais mais afastados dos municípios centrais.

Projeção para o uso e ocupação da terra

Estudos históricos de mudanças de uso e cobertura da terra são necessários para a projeção de mudanças futuras (LI *et al.*, 2021). As ferramentas para efetivar essas previsões de mudanças de LULC são estabelecidas em processos como análises das mudanças, transições, e previsões de mudanças.

Ao analisar as mudanças, o modelo identifica as transições que ocorreram entre um tipo de uso do solo e outro, assim sendo, a abordagem CA-ANN para modelagem e previsão de potencial de transição se mostra eficiente para essa análise. Os dados de LULC de 2000 e 2010 juntamente com variáveis espaciais consideradas possibilitaram a simulação para 2020.

Dessa forma, foi possível validar a classificação supervisionada realizada nesse estudo com a simulação realizada no MOLUSCE. A validação apresentou um valor Kappa de 0,75, sendo considerado muito bom a partir da literatura. Então, foi realizada com a comparação entre o dado modelado para 2020 e o mapeamento de LULC inicial realizado nesse estudo (Figura 28).

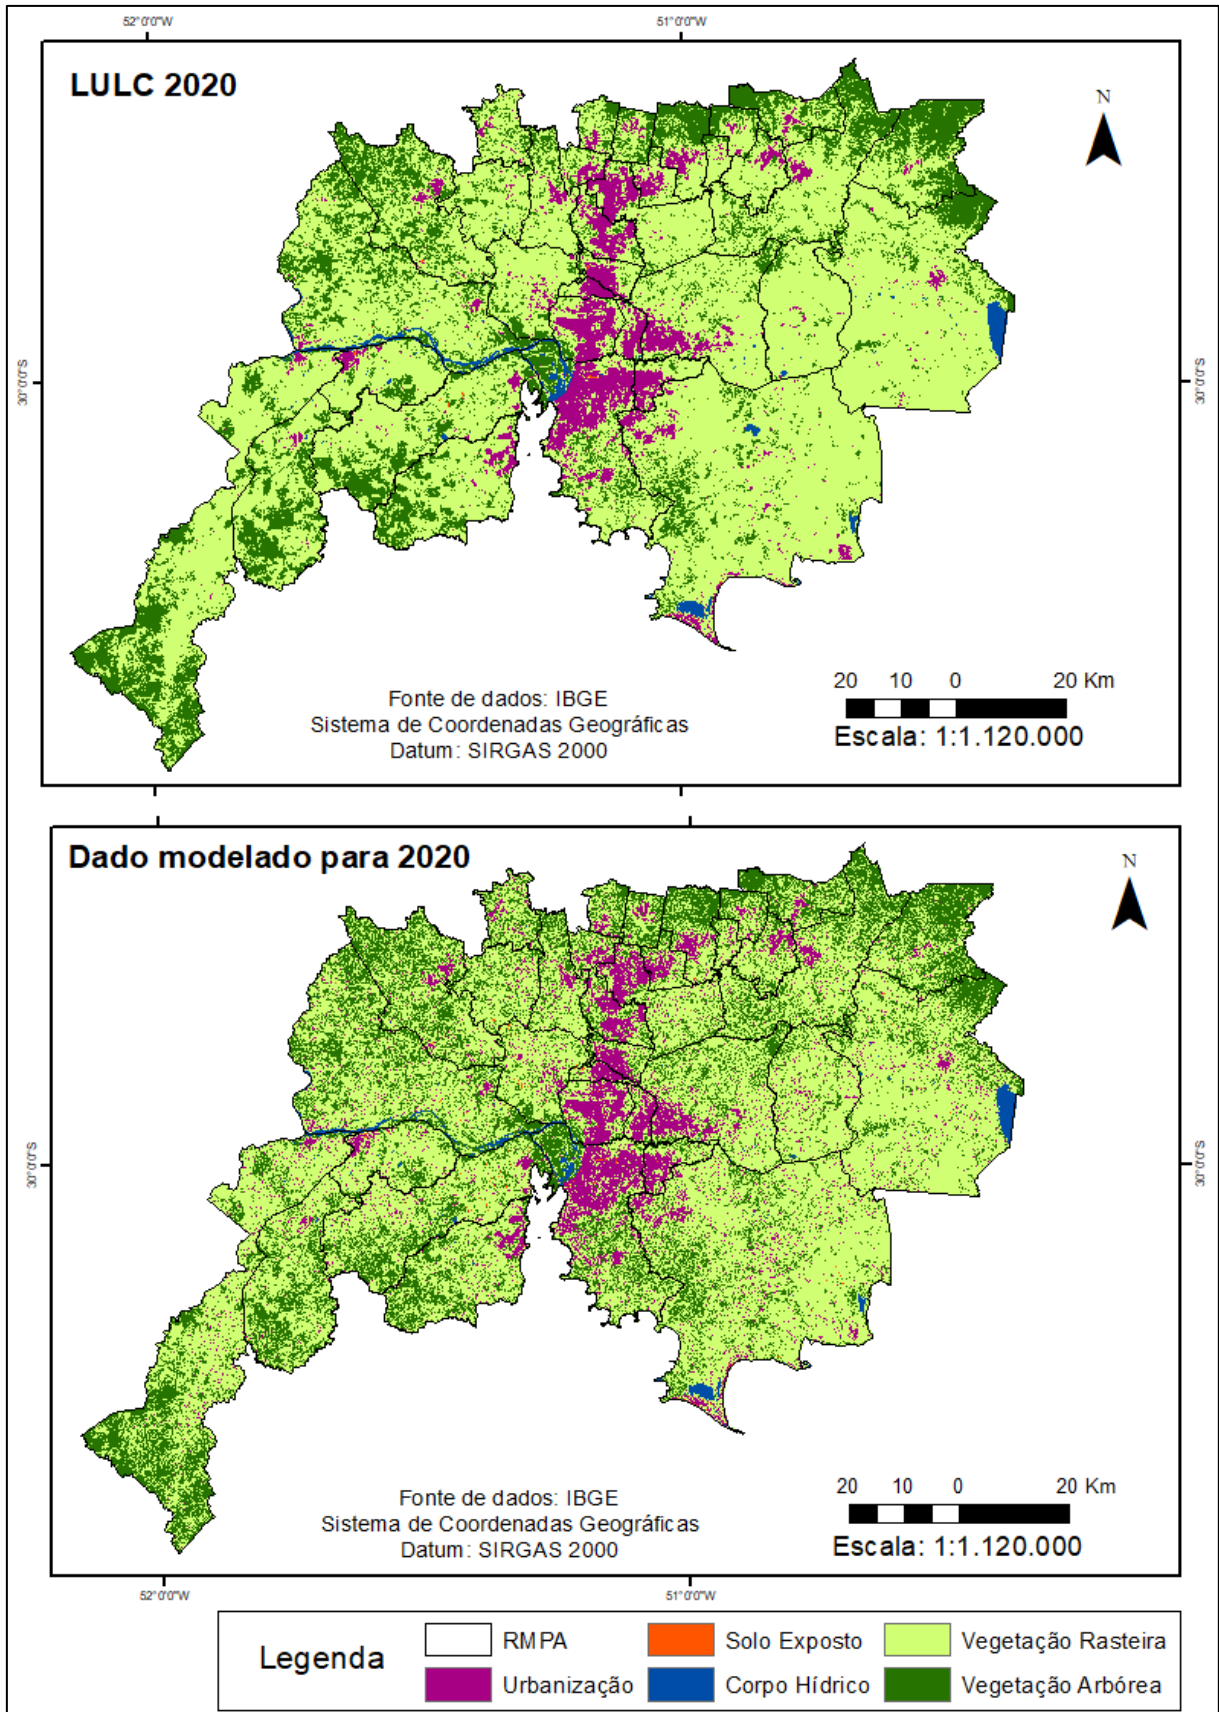


Figura 28 - Mapa LULC de 2020 comparado com o dado modelado para 2020.

Dessa forma, a análise da mudança espaço-temporal de LULC prevista para a RMPA em 2030 é expressa na (Figura 29).

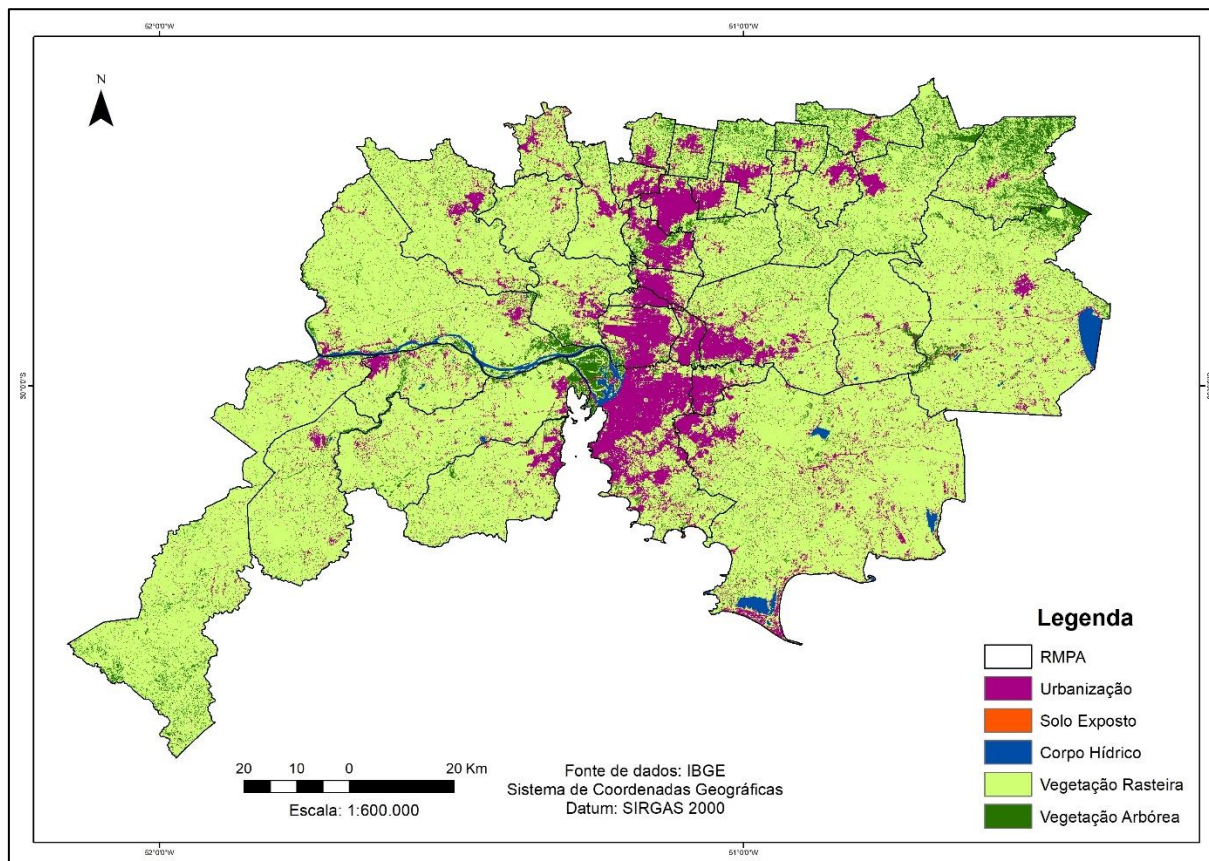


Figura 29 - Cenário de uso e cobertura da terra na RMPA para 2030.

O cenário futuro de LULC para o ano de 2030 apresentou um aumento significativo na área urbana de aproximadamente 323 km² na RMPA. O índice de expansão de paisagem para o mapeamento futuro entre 2020 e 2040 apresentou resultados diferentes dos analisados historicamente, onde a forma borda-expansão ocorre em 79%, 18% na forma periférica e 3% preenchimento.

O mapa de probabilidade de transição entre 2020 e 2030 (Figura 30), apresenta visualmente as possíveis transições de classes de uso e cobertura da terra futuramente.

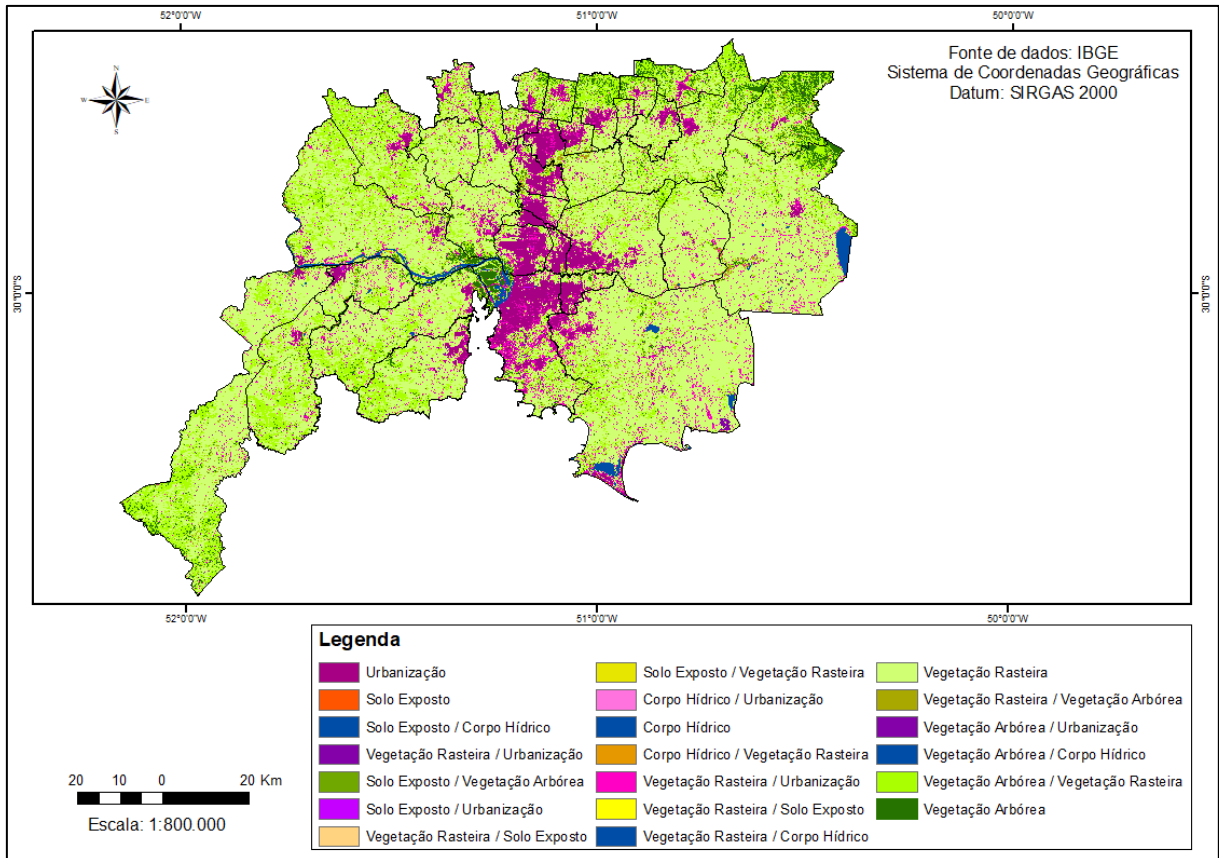


Figura 30 - Mapa de transição de classes de uso e cobertura da terra entre 2020 e 2030.

Na matriz de probabilidade de transição prevista para 2020 e 2030 (Tabela 17), as áreas construídas apresentam um possível aumento de aproximadamente 323 km². Através dos resultados é previsto uma intensa diminuição nas áreas com vegetação arbórea, em mais de 1.800 km².

Tabela 17 - Matriz de transição de LULC entre 2020 e 2030.

Classes	2020 (Km ²)	2030 (Km ²)	Δ (Km ²)	2020%	2030%	Δ (%)
1	693,3	1.016,6	323,3	6,71	9,84	3,13
2	3,3	6,5	3,2	0,03	0,06	0,03
3	124,3	126,9	2,6	1,2	1,23	0,03
4	7.223,9	8.774,4	1.550,5	69,9	84,9	15,00
5	2.289,9	410,3	-1.879,6	22,16	3,97	-18,19

Nesse sentido, a análise da mudança espaço-temporal de LULC prevista para a RMPA em 2040 é expressa na (Figura 31). E as áreas das classes de LULC previstas para o 2030 e 2040 são identificadas na (Tabela 18).

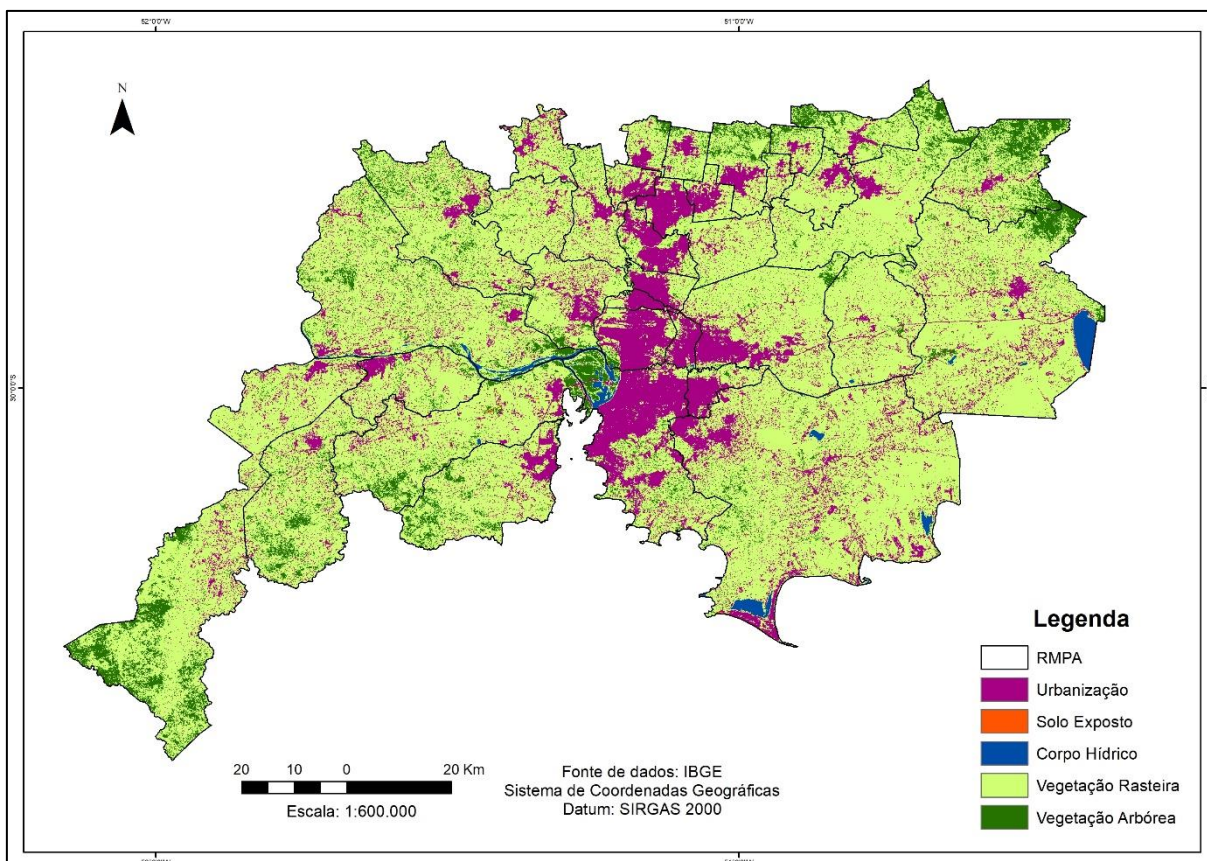


Figura 31 - Cenário de uso e cobertura da terra na RMPA para 2040.

As mudanças previstas através da modelagem futura no LULC entre 2030 e 2040, apresenta um aumento significativo na área urbana da RMPA de 335,4 km². As novas áreas de urbanização são previstas para continuar ocorrendo próximo ao centro de Porto Alegre, Canoas, estação ferroviária e rodovias principais (Tabela 18).

Tabela 18 - Áreas das classes de LULC previstas para o 2030 e 2040.

Uso e cobertura da terra	Área (Km ²)			
	2030	(%)	2040	(%)
Urbanização	1.016,6	9,8	1.352	13,07
Solo Exposto	6,5	0,06	12,8	0,13
Corpo Hídrico	126,9	1,22	101,5	0,9
Vegetação Rasteira	8.774,4	84,9	8.181,2	79,2
Vegetação Arbórea	410,3	4,02	687,2	6,7
Total	10.334,7	100	10.334,7	100

Para o futuro, é previsto que as áreas urbanas aumentem mais de 650 km² até 2040 (Tabela 18) e essas novas áreas urbanas serão possivelmente o resultado da substituição de áreas de vegetação arbórea e vegetação rasteira, como pode ser observado no mapa de probabilidade de transição entre 2030 e 2040 (Figura 32).

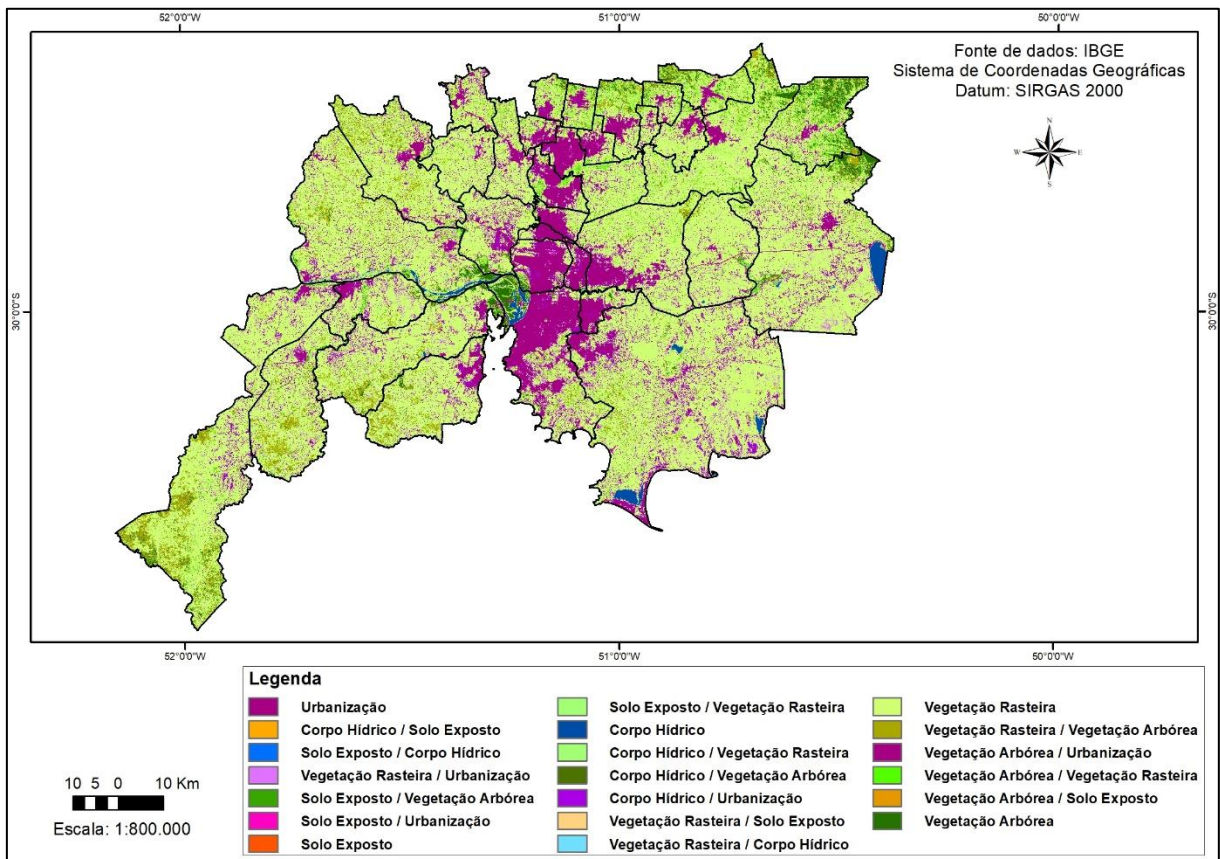


Figura 32 - Mapa de transição de classes de uso e cobertura da terra entre 2030 e 2040.

Na matriz de probabilidade de transição das classes prevista para acontecer entre 2030 e 2040 (Tabela 19), as áreas construídas apresentam um possível aumento em 335 km². No entanto, para a classe vegetação rasteira é previsto um decréscimo de aproximadamente 590 km².

Tabela 19 - Matriz de transição de LULC entre 2030 e 2040.

Classes	2030 (Km ²)	2040 (Km ²)	Δ (Km ²)	2030%	2040%	Δ (%)
1	1.016,6	1.352	335,4	9,84	13,08	3,24
2	6,5	12,8	6,3	0,06	0,12	0,06
3	126,9	101,5	-25,4	1,23	0,98	-0,25
4	8.774,4	8.181,2	-593,2	84,9	79,17	-5,73
5	410,3	687,2	276,9	3,97	6,65	2,68

Os resultados indicam que fatores determinantes físicos e socioeconômicos têm impactos significativos nos padrões da paisagem. Nas últimas três décadas, a área de estudo experimentou uma rápida expansão urbana e os resultados projetados para 2030 e 2040 também apresentam a tendência crescente na classe urbanização.

CONCLUSÕES

A compreensão do efeito da expansão urbana é importante para o desenvolvimento e planejamento das cidades. Essa pesquisa levou em consideração fatores importantes para o aumento da expansão urbana.

A classificação supervisionada para os quatro anos em análise apresentou um alto coeficiente Kappa de mais de 80% de precisão, aceitável para a realização das análises espaciais. E as variáveis utilizadas no modelo ANN foram fatores de condução críticos, pois afetaram significativamente o mecanismo de mudança de LULC. Neste estudo, considerou-se apenas fatores físicos e socioeconômicos para compreensão e modelagem de previsão.

Compreende-se com os resultados que os fatores utilizados se mostraram muito influentes na forma com que a expansão ocorreu e possivelmente continuará ocorrendo. As métricas espaciais analisadas entre 1991 e 2020 apresentaram maior expansão na forma *edge-expansion*, sendo a forma mais verificada na RMPA nas últimas três décadas. Os municípios com essa característica estão dispostos próximos do centro de Porto Alegre e da estação ferroviária, que são fatores importantes para o aumento da concentração urbana e do desenvolvimento da cidade.

Os municípios Santo Antônio da Patrulha, Viamão, Charqueadas e Montenegro também mostraram um aumento na urbanização, onde ocorreu maior concentração de *outlying*, sendo considerada uma nova expansão, em locais que não apresentaram a existência de áreas urbanas anteriormente.

Por último, a forma de expansão conhecida por *infilling*, ocorreu nos municípios Guaíba, Eldorado do Sul e Triunfo, aconteceu nos locais conhecidos como vazios urbanos, ou seja, áreas dentro das áreas urbanas que não eram utilizadas como tal. Os municípios que mais apresentaram este tipo de expansão urbana também estão localizados próximos ao maior foco de urbanização que acontece em Porto Alegre.

A grande parte da expansão urbana entre os anos de 1991 e 2000 continuou acontecendo próximos a Porto Alegre, nos municípios Canoas, Cachoeirinha, Alvorada, Sapucaia do Sul e Esteio. Entre os anos de 2000 e 2010 houve expansão também nos municípios Dois Irmãos, Ivoti e Canoas. E entre 2010 e 2020 aumentou principalmente em Viamão e Gravataí.

Segundo os resultados desse estudo, no município de Viamão aconteceu uma concentração de áreas construídas recentes, localizadas na região oposta a Porto Alegre e perto do Guaíba. Esses locais mais afastados dos grandes centros urbanos são procurados pela população que busca morar mais longe da aglomeração das cidades e mais perto de áreas naturais, para uma melhor qualidade de vida.

Os resultados indicam que as áreas urbanizadas se expandem rapidamente, ocorrendo uma grande perda de vegetação arbórea durante os últimos 30 anos. Se assim continuar, as previsões futuras mostram que o foco principal continuará sendo a busca por residir em áreas mais perto possíveis de Porto Alegre e municípios que possuem maiores oportunidades. Porém, mesmo que seja em menor ocorrência, também acontecerá segundo as previsões de LULC futuros, expansões em locais mais afastados dos municípios centrais.

Esses resultados podem auxiliar os tomadores de decisão no desenvolvimento das cidades e para pesquisas futuras, se faz necessário analisar outros fatores condicionantes da expansão urbana e mais dados de sensoriamento remoto e geoprocessamento para investigar e compreender ainda mais detalhadamente os efeitos desses elementos nos padrões da paisagem.

REFERÊNCIAS

ABBAS, Z. *et al.* Spatiotemporal change analysis and future scenario of lulc using the CA-ANN approach: A case study of the greater bay area, China. **Land**, v. 10, n. 6, 2021. Disponível em: <https://doi.org/10.3390/land10060584>

ARSANJANI, J. J.; KAINZ, W.; MOUSIVAND, A. J. Tracking dynamic land-use change using spatially explicit markov chain based on cellular automata: The case of Tehran. **International Journal of Image and Data Fusion**, v. 2, n. 4, p. 329–345, 2011. Disponível em: <https://doi.org/10.1080/19479832.2011.605397>

ASHAOLU, E. D.; OLORUNFEMI, J. F.; IFABIYI, I. P. Assessing the Spatio-Temporal Pattern of Land Use and Land Cover Changes in Osun Drainage Basin, Nigeria. **Journal of Environmental Geography**, v. 12, n. 1–2, p. 41–50, 2019. Disponível em: <https://doi.org/10.2478/jengeo-2019-0005>

BATTY, M. Cellular automata and urban form: A primer. **Journal of the American Planning Association**, v. 63, n. 2, p. 266–274, 1997. Disponível em: <https://doi.org/10.1080/01944369708975918>

CHEN, Y. *et al.* Capturing the varying effects of driving forces over time for the simulation of urban growth by using survival analysis and cellular automata. **Landscape and Urban Planning**, v. 152, p. 59–71, 2016. Disponível em: <https://doi.org/10.1016/j.landurbplan.2016.03.011>

CLARKE, K. C.; GAYDOS, L. J. Loose-coupling a cellular automaton model and GIS: Long-term urban growth prediction for San Francisco and Washington/Baltimore. **International Journal of Geographical Information Science**, v. 12, n. 7, p. 699–714, 1998. Disponível em: <https://doi.org/10.1080/136588198241617>

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 and Design**, v. 24, n. 2, p. 247–261, 1997. Disponível em: <https://doi.org/10.1068/b240247>

CONGEDO, L. Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. **Journal of Open Source Software**, v. 6, n. 64, p. 3172, 2021. Disponível em: <https://doi.org/10.21105/joss.03172>

DE JESUS, J. B.; KUPLICH, T. M. Use of SAR images for classification of Brazilian forest formations. **Ciencia Florestal**, v. 31, n. 3, p. 1547–1568, 2021. Disponível em: <https://doi.org/10.5902/1980509837586>

FERRAZ, D. da P. G. B.; VICENS, R. S. Desempenho do Descritor Máxima Diferença na Classificação de Plantações de Eucalipto no Estado do Rio de Janeiro. **Revista Brasileira de Cartografia**, v. 71, n. 1, p. 99–121, 2019. Disponível em: <https://doi.org/10.14393/rbcv71n1-46143>

FONSECA, L. M. G. Processamento digital de imagens. **Instituto Nacional de Pesquisas Espaciais (INPE)**, 2000.

G, R. C.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data**. 3ª ed. 2019.

GUIDIGAN, M. L. G. *et al.* Assessing Land Use/Land Cover Dynamic and Its Impact in Benin Republic Using Land Change Model and CCI-LC Products. **Earth Systems and Environment**, v. 3, n. 1, p. 127–137, 2019. Disponível em: <https://doi.org/10.1007/s41748-018-0083-5>

HU, Z.; LO, C. P. Modeling urban growth in Atlanta using logistic regression. **Computers, Environment and Urban Systems**, v. 31, n. 6, p. 667–688, 2007. Disponível em: <https://doi.org/10.1016/j.compenvurbsys.2006.11.001>

JENSEN, J. R. Introductory digital image processing: a remote sensing perspective. **New Jersey: Prentice Hall**, v. 2.ed., p. 316, 1996.

JIAO, L.; MAO, L.; LIU, Y. Multi-order Landscape Expansion Index: Characterizing urban expansion dynamics. **Landscape and Urban Planning**, v. 137, p. 30–39, 2015. Disponível em: <https://doi.org/10.1016/j.landurbplan.2014.10.023>

LI, S. *et al.* Impacts of Urban Expansion Forms on Ecosystem Services in Urban Agglomerations: A Case Study of Shanghai-Hangzhou Bay Urban Agglomeration. **Remote Sensing**, v. 13, n. 10, p. 24, 2021. Disponível em: <https://doi.org/10.3390/rs13101908>

LIGTENBERG, A.; BREGT, A. K.; VAN LAMMEREN, R. Multi-actor-based land use modelling: Spatial planning using agents. **Landscape and Urban Planning**, v. 56, n. 1–2, p. 21–33, 2001. Disponível em: [https://doi.org/10.1016/S0169-2046\(01\)00162-1](https://doi.org/10.1016/S0169-2046(01)00162-1)

LIU, X. *et al.* A new landscape index for quantifying urban expansion using multi-temporal remotely sensed data. **Landscape Ecology**, v. 25, n. 5, p. 12, 2010. Disponível em: <https://doi.org/10.1007/s10980-010-9454-5>

LIU, X. *et al.* Simulating urban growth by integrating landscape expansion index (LEI) and cellular automata. **International Journal of Geographical Information Science**, v. 28, n. 1, p. 148–163, 2014. Disponível em: <https://doi.org/10.1080/13658816.2013.831097>

MAPBIOMAS. 2021. **Área urbanizada nos últimos 36 anos**. Disponível em: <https://mapbiomas.org/estatisticas>

MUHAMMAD, R.; ZHANG, W.; ABBAS, Z.; GUO, F.; and GWIAZDZINSKI, L. (2022). Spatiotemporal Change Analysis and Prediction of Future Land Use and Land Cover Changes Using QGIS MOLUSCE Plugin and Remote Sensing Big Data: A Case Study of Linyi, China. **Land**, 11, 419.

PEREIRA, L. F.; GUIMARÃES, R. M. F. Mapeamento multicategórico do

uso/cobertura da terra em escalas detalhadas usando Semi-automatic Classification Plugin. **Journal of Environmental Analysis and Progress**, v. 03, n. 04, p. 379–385, 2018.

PEROVIĆ, V. *et al.* Spatio-temporal analysis of land use/land cover change and its effects on soil erosion (Case study in the Oplenac wine-producing area, Serbia). **Environmental Monitoring and Assessment**, v. 190, n. 11, p. 1–18, 2018. Disponível em: <https://doi.org/10.1007/s10661-018-7025-4>

SAJAN, B.; MISHRA, V. N.; KANGA, S.; MERAJ, G.; SINGH, S. K.; and KUMAR, P. (2022). Cellular Automata-Based Artificial Neural Network Model for Assessing Past, Present, and Future Land Use/Land Cover Dynamics. **Agronomy**, 12, 2772. Disponível em: <https://doi.org/10.3390/agronomy12112772>

SAPUTRA, M. H.; LEE, H. S. Prediction of land use and land cover changes for North Sumatra, Indonesia, using an artificial-neural-network-based cellular automaton. **Sustainability (Switzerland)**, v. 11, n. 11, p. 1–16, 2019. Disponível em: <https://doi.org/10.3390/su11113024>

SECRETARIA DE PLANEJAMENTO, G. e G. **Atlas Socioeconômico do Rio Grande do Sul**. 2020. Disponível em: <https://atlassocioeconomico.rs.gov.br/regiao-metropolitana-de-porto-alegre-rmpa>.

SHI, W.; PANG, M. Y. C. Development of voronoi-based cellular automata -an integrated dynamic model for geographical information systems. **International Journal of Geographical Information Science**, v. 14, n. 5, p. 455–474, 2000. Disponível em: <https://doi.org/10.1080/13658810050057597>

ULLAH, S. Remote sensing-based quantification of the relationships between land use land cover changes and surface temperature over the lower Himalayan region. **Sustainability**, v. 45, p. 95–98, 2019.

VAZ, E.; DE NORONHA, T.; NIJKAMP, P. Exploratory landscape metrics for agricultural sustainability. **Agroecology and Sustainable Food Systems**, v. 38, n. 1, p. 92–108, 2014. Disponível em: <https://doi.org/10.1080/21683565.2013.825829>

WU, F.; WEBSTER, C. J. Simulating artificial cities in a GIS environment: Urban growth under alternative regulation regimes. **International Journal of Geographical Information Science**, v. 14, n. 7, p. 625–648, 2000. Disponível em: <https://doi.org/10.1080/136588100424945>

YADAV, V.; GHOSH, S. K. Assessment and prediction of urban growth for a mega-city using CA-Markov model. **Geocarto International**, p. 1–34, 2019. Disponível em: <https://doi.org/10.1080/10106049.2019.1690054>

5 CONSIDERAÇÕES FINAIS

Esta pesquisa teve como objetivo determinar a dinâmica espaço-temporal presente nas classes de LULC entre 1991 e 2020 e, posteriormente, desenvolver cenários futuros LULC para 2030 e 2040 para a Região Metropolitana de Porto Alegre (RMPA), localizada no estado do Rio Grande do Sul, Brasil.

A metodologia apresentada nesse trabalho se mostrou válida para analisar a mudança de uso e cobertura da terra na RMPA nos últimos 30 anos utilizando dados de sensoriamento remoto orbital focando na dinâmica espacial da expansão das áreas urbanas para modelar cenários futuros de expansão destas áreas.

Vale ressaltar a importância de analisar a urbanização da RMPA, que é a maior região metropolitana da Região Sul do Brasil e a quinta mais populosa do Brasil, localizada numa área estratégica para o desenvolvimento do estado do Rio Grande do Sul. A capital Porto Alegre continua sendo o principal centro urbano da região considerado um município de concentração populacional no Estado do Rio Grande do Sul, atraindo pessoas pela possibilidade de emprego e serviços e fazendo dela a área mais densamente povoada do Estado.

Os resultados mostraram que a RMPA aumentou sua área urbana em 298 km² de 1991 a 2020, e para o futuro, é previsto que as áreas urbanas aumentem mais de 650 km² até 2040. A expansão urbana é um processo que abrange vários fatores tais como políticos, ambientais e geográficos.

Dessa forma, as modificações da paisagem vêm resultando interesse em pesquisadores a respeito da expansão urbana e suas respectivas consequências, nas últimas décadas. Os resultados desta pesquisa expressam que fatores determinantes físicos e socioeconômicos têm impactos significativos no aumento da mancha urbana. Além disso, os cenários futuros de LULC para 2030 e 2040 mostram que a urbanização na RMPA continuará acontecendo próxima a capital Porto Alegre.

As técnicas de modelagem espaço-temporal e simulação estão evoluindo rapidamente para estudar o monitoramento de LULC. Modelos de simulação de transição e previsão de LULC são técnicas eficazes para avaliar as causas e a significância de cenários passados, presentes e futuros.

Planejar as cidades acompanhando como as transformações urbanas acontecem é necessário. A gestão urbana detalhada e as políticas de planejamento

devem ser feitas considerando a heterogeneidade espacial e interna e compreender estes resultados favorecem os formuladores de políticas a promover cidades resilientes no futuro. Dados de sensoriamento remoto e análises espaciais utilizando-se de sistema de informação geográfica (SIG) possibilitam o monitoramento da expansão destas áreas urbanas.

Portanto, os resultados obtidos nessa pesquisa são importantes para o planejamento e conseqüentemente ajudam os formuladores de políticas no desenvolvimento de planos urbanos mais conscientes. Além disso, comportamentos de padrão LULC semelhantes observados na RMPA também foram encontrados em outras regiões do país e do mundo, indicando que a metodologia deste estudo pode ser replicada em outras regiões metropolitanas.

Em pesquisas futuras, podem ser consideradas outras feições passíveis de influenciar o crescimento de áreas urbanas, bem como a utilização de mais dados de entradas no modelo de ANN, além de poder comparar com outros modelos de previsão futura. A metodologia desenvolvida no estudo poderia ser aplicada utilizando-se de outros sensores remotos, com diferentes resoluções espaciais, possibilitando uma melhor acurácia das predições de novas áreas urbanas.

REFERÊNCIAS

ABBAS, Z. *et al.* Spatiotemporal change analysis and future scenario of lulc using the CA-ANN approach: A case study of the greater bay area, China. **Land**, v. 10, n. 6, 2021. Disponível em: <https://doi.org/10.3390/land10060584>

ABBURU, S.; BABU GOLLA, S. Satellite Image Classification Methods and Techniques: A Review. **International Journal of Computer Applications**, v. 119, n. 8, p. 6, 2015. Disponível em: <https://doi.org/10.5120/21088-3779>

AL-HAMEEDI, W. M. M. *et al.* Remote sensing-based urban sprawl modeling using multilayer perceptron neural network markov chain in Baghdad, Iraq. **Remote Sensing**, v. 13, n. 20, p. 1–26, 2021. Disponível em: <https://doi.org/10.3390/rs13204034>

ALAM, N. *et al.* Prediction modelling of riverine landscape dynamics in the context of sustainable management of floodplain: a Geospatial approach. **Annals of GIS**, v. 27, n. 3, p. 299–314, 2021. Disponível em: <https://doi.org/10.1080/19475683.2020.1870558>

- ALJOUFIE, M. *et al.* Spatial-temporal analysis of urban growth and transportation in Jeddah City, Saudi Arabia. **Cities**, v. 31, p. 57–68, 2013. Disponível em: <https://doi.org/10.1016/j.cities.2012.04.008>
- ALLEN, J. C.; BARNES, D. F. The Causes of Deforestation in Developing Countries. **Annals of the Association of American Geographers**, v. 75, n. 2, p. 163–184, 1985. Disponível em: <https://doi.org/10.1111/j.1467-8306.1985.tb00079.x>
- ARSANJANI, J. J.; KAINZ, W.; MOUSIVAND, A. J. Tracking dynamic land-use change using spatially explicit markov chain based on cellular automata: The case of Tehran. **International Journal of Image and Data Fusion**, v. 2, n. 4, p. 329–345, 2011. Disponível em: <https://doi.org/10.1080/19479832.2011.605397>
- ASHAOLU, E. D.; OLORUNFEMI, J. F.; IFABIYI, I. P. Assessing the Spatio-Temporal Pattern of Land Use and Land Cover Changes in Osun Drainage Basin, Nigeria. **Journal of Environmental Geography**, v. 12, n. 1–2, p. 41–50, 2019. Disponível em: <https://doi.org/10.2478/jengeo-2019-0005>
- BAKR, N.; MORSY, I.; YEHA, H. A. Spatio-temporal land use/cover detection and prediction in Mediterranean region: A case study in Idku ecosystem, Egypt. **Remote Sensing Applications: Society and Environment**, v. 25, n. December 2021, p. 16, 2022. Disponível em: <https://doi.org/10.1016/j.rsase.2021.100673>
- BATTY, M. Cellular automata and urban form: A primer. **Journal of the American Planning Association**, v. 63, n. 2, p. 266–274, 1997. Disponível em: <https://doi.org/10.1080/01944369708975918>
- BERBEROĞLU, S.; AKIN, A.; CLARKE, K. C. Cellular automata modeling approaches to forecast urban growth for adana, Turkey: A comparative approach. **Landscape and Urban Planning**, v. 153, p. 11–27, 2016. Disponível em: <https://doi.org/10.1016/j.landurbplan.2016.04.017>
- CANO, E. C.; UCHÔAS, A. de A.; GALLINA, F. Os desafios do IBGE e a realização do censo demográfico 2022. v. 7, p. 1–15, 2021.
- CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Remote Sensing of Environment**, v. 113, n. 5, p. 893–903, 2009. Disponível em: <https://doi.org/10.1016/j.rse.2009.01.007>
- CHEN, Y. *et al.* Capturing the varying effects of driving forces over time for the simulation of urban growth by using survival analysis and cellular automata. **Landscape and Urban Planning**, v. 152, p. 59–71, 2016. Disponível em: <https://doi.org/10.1016/j.landurbplan.2016.03.011>
- CLARKE, K. C.; GAYDOS, L. J. Loose-coupling a cellular automaton model and GIS: Long-term urban growth prediction for San Francisco and Washington/Baltimore. **International Journal of Geographical Information Science**, v. 12, n. 7, p. 699–714, 1998. Disponível em: <https://doi.org/10.1080/136588198241617>

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 and Design**, v. 24, n. 2, p. 247–261, 1997. Disponível em: <https://doi.org/10.1068/b240247>

CONGEDO, L. Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. **Journal of Open Source Software**, v. 6, n. 64, p. 3172, 2021. Disponível em: <https://doi.org/10.21105/joss.03172>

DE JESUS, J. B.; KUPLICH, T. M. Use of SAR images for classification of Brazilian forest formations. **Ciencia Florestal**, v. 31, n. 3, p. 1547–1568, 2021. Disponível em: <https://doi.org/10.5902/1980509837586>

DUBOVYK, O.; SLIUZAS, R.; FLACKE, J. Spatio-temporal modelling of informal settlement development in Sancaktepe district, Istanbul, Turkey. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 2, p. 235–246, 2011. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2010.10.002>

FERRAZ, D. da P. G. B.; VICENS, R. S. Desempenho do Descritor Máxima Diferença na Classificação de Plantações de Eucalipto no Estado do Rio de Janeiro. **Revista Brasileira de Cartografia**, v. 71, n. 1, p. 99–121, 2019. Disponível em: <https://doi.org/10.14393/rbcv71n1-46143>

FONSECA, L. M. G. Processamento digital de imagens. **Instituto Nacional de Pesquisas Espaciais (INPE), 2000.**

FORGET, Y. *et al.* Mapping 20 years of urban expansion in 45 urban areas of sub-Saharan Africa. **Remote Sensing**, v. 13, n. 3, p. 1–20, 2021. Disponível em: <https://doi.org/10.3390/rs13030525>

G, R. C.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data**. 3ª ed. 2019.

GANTUMUR, B. *et al.* Spatiotemporal dynamics of urban expansion and its simulation using CA-ANN model in Ulaanbaatar, Mongolia. **Geocarto International**, v. 0, n. 0, p. 1–16, 2020. Disponível em: <https://doi.org/10.1080/10106049.2020.1723714>

GINZBURG, C. **Mitos, emblemas, sinais: morfologia e história**. 2ª ed. São Paulo: 1989.

GONÇALVES, T. M. *et al.* Simulating Urban Growth Using Cellular Automata Approach (SLEUTH)-A Case Study of Praia City, Cabo Verde. **IEEE Access**, v. 7, p. 156430–156442, 2019. Disponível em: <https://doi.org/10.1109/ACCESS.2019.2949689>

GUIDIGAN, M. L. G. *et al.* Assessing Land Use/Land Cover Dynamic and Its Impact in Benin Republic Using Land Change Model and CCI-LC Products. **Earth Systems**

and Environment, v. 3, n. 1, p. 127–137, 2019. Disponível em:
<https://doi.org/10.1007/s41748-018-0083-5>

HAYKIN, S. S. Redes Neurais: princípios e prática. **Bookman**, v. 2, p. 900, 2001.

HU, Z.; LO, C. P. Modeling urban growth in Atlanta using logistic regression. **Computers, Environment and Urban Systems**, v. 31, n. 6, p. 667–688, 2007. Disponível em: <https://doi.org/10.1016/j.compenvurbsys.2006.11.001>

IBGE. **Cidades - Pesquisas**. 2018. Disponível em:
<https://cidades.ibge.gov.br/brasil/rs/rio-grande/panorama>. Acesso em: 1 ago. 2020.

IBGE. **Agência IBGE notícias**. 2020. Disponível em:
<https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/31471-ibge-lanca-colecao-de-mapas-municipais-2020>.

JENSEN, J. R. Introductory digital image processing: a remote sensing perspective. **New Jersey: Prentice Hall**, v. 2.ed., p. 316, 1996.

JIAO, L.; MAO, L.; LIU, Y. Multi-order Landscape Expansion Index: Characterizing urban expansion dynamics. **Landscape and Urban Planning**, v. 137, p. 30–39, 2015. Disponível em: <https://doi.org/10.1016/j.landurbplan.2014.10.023>

KANELLOPOULOS, I.; WILKINSON, G. G. Strategies and best practice for neural network classification. **International Journal of Remote Sensing**, v. 18, n. 4, p. 711–725, 1997.

LAMBIN, E. F. Modelling Deforestation Processes. **International Journal of Remote Sensing**, v. 17, n. 5, p. 46, 1994. Disponível em:
<https://doi.org/10.1080/01431169608949066>

LANG, S.; BLASCHKE, T. Análise da paisagem com SIG. **Oficina de Textos**, v. 21, n. 1, p. 424, 2009.

LI, S. *et al.* Impacts of Urban Expansion Forms on Ecosystem Services in Urban Agglomerations: A Case Study of Shanghai-Hangzhou Bay Urban Agglomeration. **Remote Sensing**, v. 13, n. 10, p. 24, 2021. Disponível em:
<https://doi.org/10.3390/rs13101908>

LI, X. *et al.* Calibrating cellular automata based on landscape metrics by using genetic algorithms. **International Journal of Geographical Information Science**, v. 27, n. 3, p. 594–613, 2013. Disponível em:
<https://doi.org/10.1080/13658816.2012.698391>

LI, X.; YEH, A. G. O. Modelling sustainable urban development by the integration of constrained cellular automata and GIS. **International Journal of Geographical Information Science**, v. 14, n. 2, p. 131–152, 2000. Disponível em:
<https://doi.org/10.1080/136588100240886>

LI, X.; YEH, A. G. O. Neural-network-based cellular automata for simulating multiple

land use changes using GIS. **International Journal of Geographical Information Science**, v. 16, n. 4, p. 323–343, 2002. Disponível em: <https://doi.org/10.1080/13658810210137004>

LIGTENBERG, A.; BREGT, A. K.; VAN LAMMEREN, R. Multi-actor-based land use modelling: Spatial planning using agents. **Landscape and Urban Planning**, v. 56, n. 1–2, p. 21–33, 2001. Disponível em: [https://doi.org/10.1016/S0169-2046\(01\)00162-1](https://doi.org/10.1016/S0169-2046(01)00162-1)

LIMA, M. J. G. de. **Proximidade e Governança Metropolitana: Cooperação e Conflitos nas Políticas Públicas Ambientais da Região Metropolitana de Porto Alegre (RMPA)**. 2018.

LIPPMANN, R. P. An introduction to computing with neural nets. **ACM SIGARCH Computer Architecture News**, v. 4, n. 2, p. 4–22, 1987. Disponível em: <https://doi.org/10.1145/44571.44572>

LIU, X. *et al.* A new landscape index for quantifying urban expansion using multi-temporal remotely sensed data. **Landscape Ecology**, v. 25, n. 5, p. 12, 2010. Disponível em: <https://doi.org/10.1007/s10980-010-9454-5>

LIU, X. *et al.* Simulating urban growth by integrating landscape expansion index (LEI) and cellular automata. **International Journal of Geographical Information Science**, v. 28, n. 1, p. 148–163, 2014. Disponível em: <https://doi.org/10.1080/13658816.2013.831097>

LOSIRI, C. *et al.* Modeling urban expansion in Bangkok Metropolitan region using demographic-economic data through cellular Automata-Markov Chain and Multi-Layer Perceptron-Markov Chain models. **Sustainability (Switzerland)**, v. 8, n. 7, p. 2–23, 2016. Disponível em: <https://doi.org/10.3390/su8070686>

MAPBIOMAS. 2021. **Área urbanizada nos últimos 36 anos**. Disponível em: <https://mapbiomas.org/estatisticas>

MATHER, P. M. Computer processing of remotely-sensed images — an introduction. **Geocarto International**, v. 2, n. 4, p. 64, 1987. Disponível em: <https://doi.org/10.1080/10106048709354125>

MUGIRANEZA, T.; BAN, Y.; HAAS, J. Urban land cover dynamics and their impact on ecosystem services in Kigali, Rwanda using multi-temporal Landsat data. **Remote Sensing Applications: Society and Environment**, v. 13, p. 234–246, 2019. Disponível em: <https://doi.org/10.1016/j.rsase.2018.11.001>

MUHAMMAD, R.; ZHANG, W.; ABBAS, Z.; GUO, F.; and GWIAZDZINSKI, L. (2022). Spatiotemporal Change Analysis and Prediction of Future Land Use and Land Cover Changes Using QGIS MOLUSCE Plugin and Remote Sensing Big Data: A Case Study of Linyi, China. **Land**, 11, 419.

MUSA, S. I.; HASHIM, M.; REBA, M. N. A review of geospatial-based urban growth models and modelling initiatives. **Geocarto International**, v. 6049, p. 1–21, 2017. Disponível em: <https://doi.org/10.1080/10106049.2016.1213891>

ONU. **Perspectivas da População Mundial 2019**: Destaques. Biblioteca multimídia - Departamento de Assuntos Econômicos e Sociais das Nações Unidas.

OZTURK, D. Urban growth simulation of Atakum (Samsun, Turkey) using cellular automata-Markov chain and Multi-layer Perceptron-Markov chain models. **Remote Sensing**, v. 7, n. 5, p. 5918–5950, 2015. Disponível em: <https://doi.org/10.3390/rs70505918>

PADMANABAN, R. *et al.* Modelling Urban Sprawl Using Remotely Sensed Data : A Case Study of Chennai City , Tamilnadu. **Entropy**, p. 1–14, 2017. Disponível em: <https://doi.org/10.3390/e19040163>

PAIVA, A. C. da E. *et al.* Urban expansion and its impact on water security: The case of the Paraíba do Sul River Basin, São Paulo, Brazil. **Science of the Total Environment**, p. 50, 2020. Disponível em: <https://doi.org/10.1016/j.scitotenv.2020.137509>

PEREIRA, L. F.; GUIMARÃES, R. M. F. Mapeamento multicategórico do uso/cobertura da terra em escalas detalhadas usando Semi-automatic Classification Plugin. **Journal of Environmental Analysis and Progress**, v. 03, n. 04, p. 379–385, 2018.

PEROVIĆ, V. *et al.* Spatio-temporal analysis of land use/land cover change and its effects on soil erosion (Case study in the Oplenac wine-producing area, Serbia). **Environmental Monitoring and Assessment**, v. 190, n. 11, p. 1–18, 2018. Disponível em: <https://doi.org/10.1007/s10661-018-7025-4>

RAMYA, S.; DEVADAS, V. Integration of GIS, AHP and TOPSIS in evaluating suitable locations for industrial development: A case of Tehri Garhwal district, Uttarakhand, India. **Elsevier Ltd**, 2019. v. 238. Disponível em: <https://doi.org/10.1016/j.jclepro.2019.117872>

REBA, M.; SETO, K. C. A systematic review and assessment of algorithms to detect, characterize, and monitor urban land change. **Elsevier**, 2020. Disponível em: <https://doi.org/10.1016/j.rse.2020.111739>

SAJAN, B.; MISHRA, V. N.; KANGA, S.; MERAJ, G.; SINGH, S. K.; and KUMAR, P. (2022). Cellular Automata-Based Artificial Neural Network Model for Assessing Past, Present, and Future Land Use/Land Cover Dynamics. **Agronomy**, 12, 2772. Disponível em: <https://doi.org/10.3390/agronomy12112772>

SANTOS, M. **Metamorfoses do Espaço Habitado**: fundamentos teóricos e metodológicos da geografia. São Paulo: 1988. Disponível em: <https://doi.org/10.30612/mvt.v5i09.6981>

SAPUTRA, M. H.; LEE, H. S. Prediction of land use and land cover changes for North Sumatra, Indonesia, using an artificial-neural-network-based cellular automaton. **Sustainability (Switzerland)**, v. 11, n. 11, p. 1–16, 2019. Disponível em: <https://doi.org/10.3390/su11113024>

SAXENA, A.; JAT, M. K. Capturing heterogeneous urban growth using SLEUTH model. **Remote Sensing Applications: Society and Environment**, v. 13, p. 426–434, 2019. Disponível em: <https://doi.org/10.1016/j.rsase.2018.12.012>

SCHERER, O. L. B. *et al.* **Projeto materiais de construção da Região Metropolitana de Porto Alegre**. Porto Alegre - RS: 2016.

SECRETARIA DE PLANEJAMENTO, G. E. G. **Fórum nacional de entidades metropolitanas**. 2018. Disponível em: <https://fnem brasil.org/regiao-metropolitana-de-porto-alegre-rs/>. Acesso em: 10 jan. 2021.

SECRETARIA DE PLANEJAMENTO, G. e G. **Atlas Socioeconômico do Rio Grande do Sul**. 2020. Disponível em: <https://atlassocioeconomico.rs.gov.br/regiao-metropolitana-de-porto-alegre-rmpa>.

SECRETARIA DE PLANEJAMENTO, G. e G. **Atlas Socioeconômico do Rio Grande do Sul**. 2021. Disponível em: <https://atlassocioeconomico.rs.gov.br/regiao-metropolitana-de-porto-alegre-rmpa>.

SHI, W.; PANG, M. Y. C. Development of voronoi-based cellular automata -an integrated dynamic model for geographical information systems. **International Journal of Geographical Information Science**, v. 14, n. 5, p. 455–474, 2000. Disponível em: <https://doi.org/10.1080/13658810050057597>

SIRAKOULIS, G. C.; KARAFYLLIDIS, I.; THANAILAKIS, A. A cellular automaton model for the effects of population movement and vaccination on epidemic propagation. **Ecological Modelling**, v. 133, n. 3, p. 209–223, 2000. Disponível em: [https://doi.org/10.1016/S0304-3800\(00\)00294-5](https://doi.org/10.1016/S0304-3800(00)00294-5)

SOARES-FILHO, B. S.; ASSUNÇÃO, R. M.; PANTUZZO, A. E. Modeling the spatial transition probabilities of landscape dynamics in an Amazonian colonization frontier. **BioScience**, v. 51, n. 12, p. 1059–1067, 2001. Disponível em: [https://doi.org/10.1641/0006-3568\(2001\)051\[1059:MTSTPO\]2.0.CO;2](https://doi.org/10.1641/0006-3568(2001)051[1059:MTSTPO]2.0.CO;2)

SONDE, P.; BALAMWAR, S.; OCHAWAR, R. S. Urban sprawl detection and analysis using unsupervised classification of high resolution image data of Jawaharlal Nehru Port Trust area in India. **Remote Sensing Applications: Society and Environment**, v. 17, p. 1–9, 2020. Disponível em: <https://doi.org/10.1016/j.rsase.2019.100282>

STEINER, D. Time dimension for crop surveys from space. **Photogrammetric Engineering**, v. 36, n. 9, p. 187–194, 1970.

TSO, B.; MATHER, P. **Classification methods for remotely sensed data**. 2. ed. London: 2001.

ULLAH, S. Remote sensing-based quantification of the relationships between land use land cover changes and surface temperature over the lower Himalayan region. **Sustainability**, v. 45, p. 95–98, 2019.

UNESCO. **Relatório Mundial das Nações Unidas sobre o Desenvolvimento dos**

Recursos Hídricos: Soluções baseadas na Natureza para a gestão da água. 2018.

VAZ, E.; DE NORONHA, T.; NIJKAMP, P. Exploratory landscape metrics for agricultural sustainability. **Agroecology and Sustainable Food Systems**, v. 38, n. 1, p. 92–108, 2014. Disponível em: <https://doi.org/10.1080/21683565.2013.825829>

WOLFRAM, S. A new kind of science. **Champaign**, p. 13, 2002.

WU, F.; WEBSTER, C. J. Simulating artificial cities in a GIS environment: Urban growth under alternative regulation regimes. **International Journal of Geographical Information Science**, v. 14, n. 7, p. 625–648, 2000. Disponível em: <https://doi.org/10.1080/136588100424945>

YADAV, V.; GHOSH, S. K. Assessment and prediction of urban growth for a mega-city using CA-Markov model. **Geocarto International**, p. 1–34, 2019. Disponível em: <https://doi.org/10.1080/10106049.2019.1690054>

YANG, Q.; LI, X.; SHI, X. Cellular automata for simulating land use changes based on support vector machines. **Computers and Geosciences**, v. 34, n. 6, p. 592–602, 2008. Disponível em: <https://doi.org/10.1016/j.cageo.2007.08.003>

ZHAO, Y.; CUI, B.; MURAYAMA, Y. **Neighborhood interaction in urban land-use changes using cellular automata-based geo-simulation**. London: 2012. Disponível em: https://doi.org/10.1007/978-4-431-54000-7_15

