MODELAGEM DO USO E COBERTURA DA TERRA E DA TEMPERATURA DA SUPERFÍCIE DE PORTO ALEGRE – RS POR MEIO DE REDES NEURAIS ARTIFICIAIS

Rodrigo Passos Fernandes [1],Victor Fernandez Nascimento [2], Fernanda Casagrande [3], Andressa Garcia Fontana [4]

[1]Programa de Pós-graduação em Sensoriamento Remoto (PPGSR) da Universidade Federal do Rio Grande do Sul (UFRGS), rodrigopassosufrgs@gmail.com; [2]Universidade Federal do ABC (UFABC), PPGSR/UFRGS, victor.fernandez@ufabc.edu.br; [3]PPGSR/UFRGS, fernanda.casagrande@inpe.br; [4]PPGSR/UFRGS, andressagfontana94@gmail.com;

RESUMO

A Ilha de calor da superfície (SUHI), pode ser identificado por meio da temperatura da superfície (LST). Além disso, as mudanças do uso e cobertura da terra (LULC) estão estritamente relacionadas com alterações da LST. Portanto, este trabalho tem como objetivo primeiramente simular cenários futuros de LULC e LST para a cidade de Porto Alegre, utilizando autômato celular (CA) através de Redes Neurais Artificiais (ANN). Para isso, variáveis explicativas geomorfológicas e índices de vegetação, como elevação e NDVI foram utilizados. Os resultados demonstraram que a simulação para cenários futuros de LULC foi considerada satisfatória, enquanto para a simulação do LST este não foi considerado bom. Porém, os cenários futuros tanto de LULC como LST, são importantes para o planejamento urbano e tomadores de decisão. Portanto, para estudos futuros, recomenda-se a utilização de mais variáveis explicativas ou até mesmo o uso de outras metodologias para simular a LST mais efetivamente.

Palavras-chave — SUHI, LST, LULC, CA-ANN.

ABSTRACT

The Surface Heat Island (SUHI) can be identified through the surface temperature (LST). In addition, changes in land use and land cover LULC are closely related to changes in the LST. Therefore, this work aims firstly at simulating future scenarios of LULC and LST for the city of Porto Alegre, using cellular automata (CA) through Artificial Neural Networks (ANN). For this, geomorphological explanatory variables and vegetation indices, such as elevation and NDVI were used. The results showed that the simulation for future LULC scenarios was considered satisfactory, while for the LST simulation it was not considered good. However, future scenarios for both LULC and LST are important for urban planning and decision makers. Therefore, for future studies, it is recommended the use of more explanatory variables or even the use of other methodologies to simulate the LST more effectively.

Key words — *SUHI, LST, LULC, CA-ANN.*

1. INTRODUÇÃO

As áreas urbanas vêm chamando bastante atenção, principalmente pela sua grande expansão em todo o mundo. Enquanto a parte da população que vivia em áreas urbanas em 1950 era de apenas 30%, em 2014 esse número passou a representar 54% da população. Esse aumento caso acontece de forma não planejada, pode ser prejudicial para o meio ambiente e consequentemente a saúde e bem-estar da população [1]

A urbanização acelerada e sem planejamento causa diversos impactos negativos, dentre eles as Ilhas de Calor urbanas. Para pode entender este fenômeno normalmente são utilizados dados de sensoriamento remoto que medem a temperatura da superfície, em inglês *Land Surface Temperature* (LST), e, portanto, o fenômeno é chamado ilha de calor urbana da superfície, em inglês *Surface Urban Heat Island* (SUHI), a qual, é uma das formas mais abordadas na literatura para estudos de clima urbano.

Segundo [2], as mudanças no uso e cobertura da terra, do inglês *Land Use Land Cover* (LULC), especialmente vegetação, áreas alagadas, floresta, áreas urbanas e solos expostos são os principais elementos que contribuem no aumento ou diminuição da LST, pois áreas com presença de água e vegetação tendem a diminuir o acúmulo de temperatura, enquanto os materiais impermeáveis tendem ao aumento dela.

Os Autômato Celular e Rede Neural Artificial, em inglês *Cellular Automata-Artificial Neural* Network (CA-ANN), recentemente é vinculado ao sistema de informações geográficos, provendo uma tomada de decisão baseada em conhecimento, no qual fornece detalhes abrangentes, além disso, as redes neurais possuem facilidade na compreensão de processos complexos. Elas são ferramentas potentes para o entendimento dos sistemas de uso da terra e suas dinâmicas.

Portanto, é importante termos conhecimento do comportamento da LULC e LST para um planejamento urbano adequado. Por este motivo, o estudo tem como objetivo elaborar cenários futuros de LULC e da LST utilizando CA-ANN para a cidade de Porto Alegre no Rio Grande do Sul e verificar sua efetividade.

2. MATERIAL E MÉTODOS

A seguir, encontra-se um fluxograma das etapas realizadas neste artigo (Figura 1). Primeiramente, foi realizado a aquisição de imagens dos satélites Landsat 5 e 8 através da plataforma do *Google Earth Engine* (GEE), em seguida foram extraídas as informações de LST. Além destas imagens, dados de relevo, estradas e drenagem também foram utilizados. A seguir estão descritas com mais detalhe uma destas etapas.

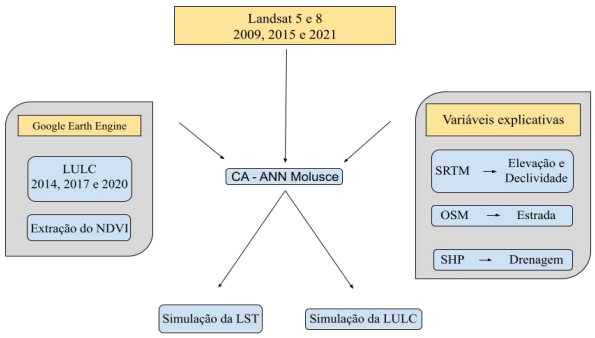


Figura 1. Fluxograma seguido no estudo.

2.1. Área de estudo

A área de estudo da pesquisa foi o município de Porto Alegre, no estado do Rio Grande do Sul localizada na região Sul do Brasil (Figura 2).

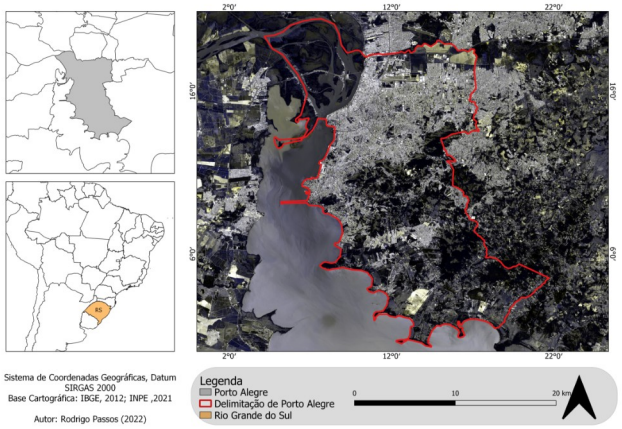


Figura 2. Mapa de localização de Porto Alegre, RS.

2.2. Obtenção da LST

O método *Statistical Mono-Window* foi utilizado para estimar a LST através da plataforma do GEE para os meses de janeiro dos anos de 2015, 2017 e 2021 para a área de estudo. O código para o procedimento foi disponibilizado por [3] e através dele é possível acessar dados de LST de diversos satélites, porém neste trabalho apenas os dados do Landsat 5 e 8 foram utilizados.

2.3. Extração de variáveis

2.3.1. NDVI

O Índice Normalizado da Vegetação, em inglês *Normalized Difference Vegetation Index* (NDVI) é um índice adimensional que descreve a diferença entre a banda do vermelho e do infravermelho próximo é normalmente utilizado para estimar a densidade de verde em uma área. Neste estudo o NDVI foi extraído utilizando-se das mesmas imagens utilizadas para se estimar a LST na plataforma do GEE.

2.3.2. Elevação e Declividade

O modelo digital de elevação (MDE) utilizado foi o obtido pelo *Shuttle Radar Topography* Mission (SRTM) adquirido no banco de dados do Serviço Geológico dos Estados Unidos (USGS). O recorte da área de estudo e a geração da declividade foram realizados no software Qgis 3.16.1.

2.3.3. Uso e cobertura da terra

Os dados de LULC foram obtidos para os anos de 2014, 2017 e 2020, através de dados disponibilizados pelo MapBiomas coleção 6. Vale destacar que os anos de coleta de dados de LULC não foram os mesmos da LST por questões operacionais, além da própria disponibilidade dos dados.

2.3.4. Distância das estradas e rios

Os dados vetoriais de estradas foram adquiridos pelo *plugin Open Steet Map* e os de drenagem foram obtidos pela Fundação Estadual de Proteção Ambiental Henrique Luis Roessler (FEPAM). Ambos foram transformados em dados *raster* para ser calculada a distância euclidiana.

2.4. Predição da LULC e LST

Para se elaborar os cenários futuros de LULC e LST utilizando o CA-ANN para a cidade de Porto Alegre foi utilizado o *plugin* disponível no software QGIS 2.18 denominado de *Modules for Land Use Change Evaluation* (Molusce).

Os dados do MDE, declividade, distância das estradas e de rios foram utilizados como variáveis explicativas para elaborar o cenário futuro de LULC para o ano de 2023. No entanto, para a previsão da LST de 2027, além das variáveis mencionadas anteriormente, foram utilizados também os dados de NDVI e LULC.

3. RESULTADOS E DISCUSSÃO

A seguir, os resultados encontrados tanto para a classificação do LULC como do LST são brevemente apresentados e discutidos.

3.1. Mudanças de LULC

Os mapas de uso e cobertura da terra de 2014 e 2017 (Figura 3a e 3b) e 2020 (Figura 4c) para a área de estudo apresentam as respectivas classes: formação florestal, silvicultura, campo alagado e área pantanosa, formação campestre, mosaico de agricultura e pastagem, área urbana, outras áreas não vegetadas, corpos hídricos, soja, arroz e lavouras temporárias.

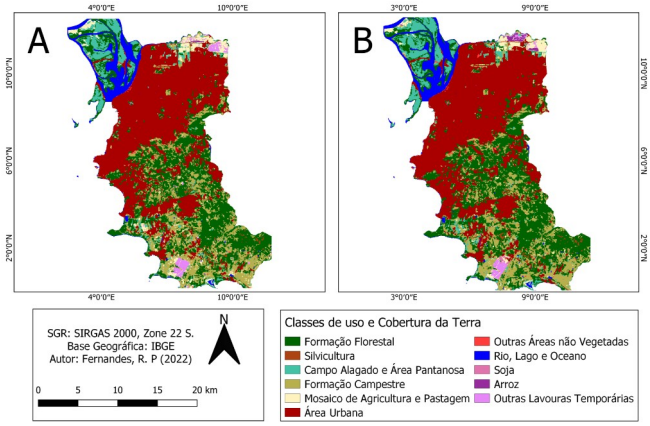


Figura 3. Uso e cobertura da terra de 2014 (A) e 2017(B).

As classes com alterações mais significativas foram a formação florestal e área urbana como pode ser observado no (Tabela 1).

Classe	2014 (%)	2017(%)	2020(%)
Formação Florestal	28,6	29,6	30,6
Área Urbana	39,3	39,6	39,9

Tabela 1. Diferença entre o LULC de 2014 e 2017; 2017 e 2020.

A formação florestal teve um aumento de 1%, resultado esse aparentemente contraditório, pois a classe urbana também sofreu um aumento, porém mais discreto. Este fato pode ser explicado pelas ações de proteção do meio ambiente e conservação das vegetações remanescentes de Mata Atlântica que Porto Alegre possui em seu território.

3.1.1. Predição de LULC

Com os dados observados de LULC 2014 e 2017 (Figura 3a e 3b), foi realizada uma simulação para o ano de 2020 (Figura 04d) o qual, foi comparado com o dado observado para este mesmo ano (Figura 04c) demonstrados na (Tabela 2).

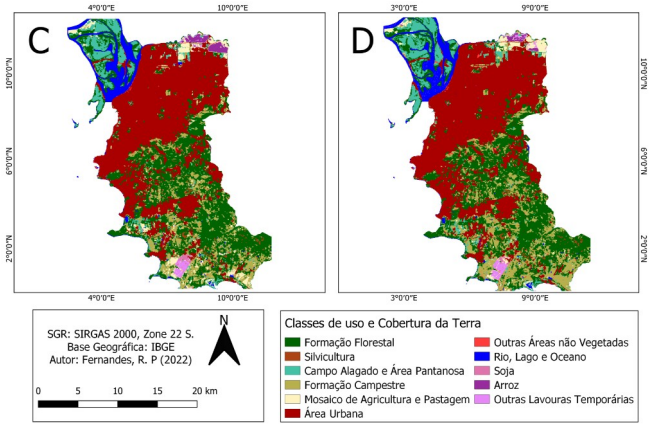


Figura 4. Uso e cobertura da terra de 2020 observado (C) e simulado (D).

Índice Kappa	
% de correlação	99,75
Kappa (geral)	0,99
Kappa (histo)	0,99
Kappa (loc)	0,99

Tabela 2. Cálculo do Índice Kappa para a LULC simulada 2020.

Posteriormente, com os dados de 2017 e 2020 observados, foi gerado o cenário futuro de LULC para o ano de 2023 para o município de Porto Alegre (Figura 5).

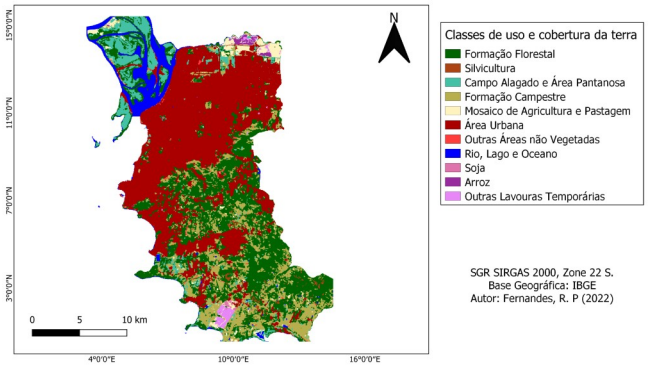


Figura 5. LULC simulada para o ano de 2023.

3.2. Classificação da LST

Os mapas de temperatura da superfície de 2015, 2017 e 2021 (Figura 6 e 7) foram divididos em cinco classes, de acordo com a menor e a maior temperatura dada em Kelvin de cada ano.

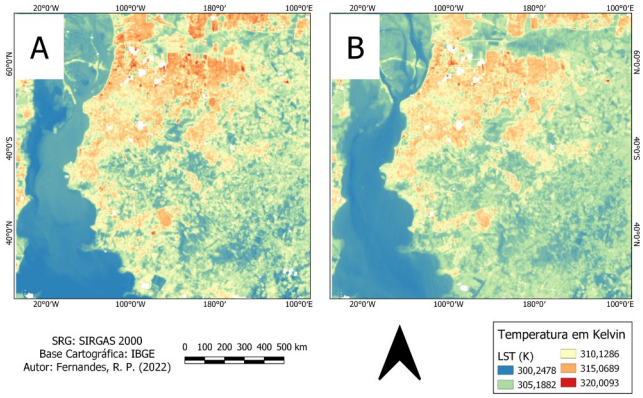


Figura 6. LST de 2015(A) e LST de 2017(B).

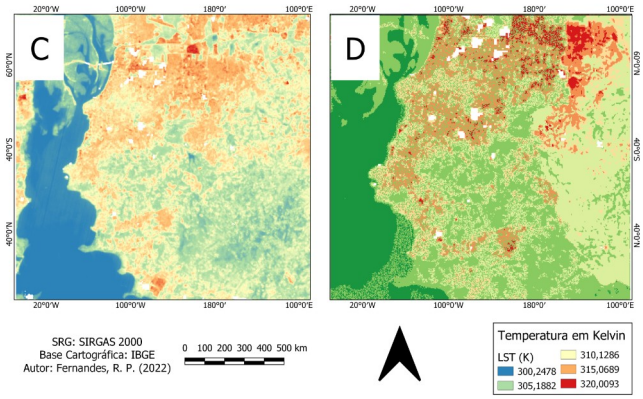


Figura 7. LST de 2021 observada (C) e simulada (D).

A simulação da LST de 2021 (Figura 7D) não demonstrou boa correlação quando comparada com a LST obtida da imagem Landsat deste mesmo ano (Figura 7C), o que pode ser observado pelo baixos valores do Índice Kappa demonstrado na (Tabela 3). Como as duas imagens não estão bem correlacionadas, não recomendável extrapolar essa simulação da LST para os próximos anos.

O primeiro motivo para este problema pode ser falta de variáveis explicativas, por exemplo, segundo o artigo de [4], onde é realizado a predição de LST para o município de Calcutá, Índia, os autores utilizaram outras diversas variáveis explicativas, além das utilizadas em nosso estudo para a modelagem, tal como o *Normalized Difference Built-Up Index* (NDBI).

Além disso no artigo de [2] uma simulação para a LST na cidade de Zonguldak foi considerada satisfária, porém os autores utilizaram o modelo *Markov Chain*, ao invés do CA-ANN utilizado em nosso estudo. Portanto, outros tipos de modelos devem ser considerados e testados para a geração de cenários futuros de LST que consequentemente poderão servir para análises de ilhas de calor urbana.

Índice Kappa	
% de correlação	22,43
Kappa (geral)	0,12
Kappa (histo)	0,59
Kappa (loc)	0,20

Tabela 3. Índice Kappa para a LST simulada de 2021.

5. CONCLUSÕES

A modelagem com o modelo CA-ANN foi considerada adequada para o uso e cobertura da terra para a cidade de Porto Alegre, com um excelente resultado entre o simulado e observado para o ano de 2020, que por sua vez é um primeiro fato para que a simulação de LULC para 2023 esteja mais próximo do que provavelmente pode acontecer. Entretanto, a modelagem para a temperatura de superfície da região não apresentou uma boa correlação entre a simulada e observada para o ano de 2021, dificultando portanto o acerto dessa simulação da LST para anos posteriores.

Algumas hipóteses são levantadas para os problemas na modelagem da LST, uma delas, talvez a principal seja a falta de variáveis explicativas para treinar o modelo CA-ANN ou até mesmo a ineficiência deste método para a predição futura da LST.

Portanto, para estudos futuros recomenda-se além de utilizar mais variáveis explicativas, utilizar outros modelos para gerar cenários futuros de LST, tais estudos podem servir como uma ferramenta de avaliação por parte dos gestores públicos de como lidar com o agravamento do aquecimento urbano e assim melhor adequar o planejamento ambiental da cidade.

8. REFERÊNCIAS

[1] ZHAO, C. et al. A Geographically Weighted Regression Analysis of the Underlying Factors Related to the Surface Urban Heat Island Phenomenon. Remote Sensing, [S.L.], v. 10, n. 9, p. 1428, 7 set. 2018. MDPI AG. http://dx.doi.org/10.3390/rs10091428.

[2] SEKERTEKIN, A. et *al*. Simulation of future land surface temperature distribution and evaluating surface urban heat island based on impervious surface area. Ecological Indicators, [S.L.], v. 122, p. 107230, mar. 2021. Elsevier BV. http://dx.doi.org/10.1016/j.ecolind.2020.107230.

[3] ERMIDA, S. L. et al. Google Earth Engine Open-Source Code for Land Surface Temperature Estimation from the Landsat Series. **Remote Sensing**, [S.L.], v. 12, n. 9, p. 1471, 6 maio 2020. MDPI AG. http://dx.doi.org/10.3390/rs12091471.

[4] HALDER, Bijay *et al*. Monitoring the effect of urban development on urban heat island based on remote sensing and geo-spatial approach in Kolkata and adjacent areas, India. Sustainable Cities And Society, [S.L.], v. 74, p. 103186, nov. 2021. Elsevier BV. http://dx.doi.org/10.1016/j.scs.2021.103186.