

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

EDUARDO ANDRÉ KAISER

**DINÂMICA DA TEMPERATURA DE SUPERFÍCIE NO MUNICÍPIO DE PORTO
ALEGRE, RS: DIAGNÓSTICO E PROGNÓSTICO A PARTIR DE
SENSORIAMENTO REMOTO**

PORTO ALEGRE

2023

EDUARDO ANDRÉ KAISER

**DINÂMICA DA TEMPERATURA DE SUPERFÍCIE NO MUNICÍPIO DE PORTO
ALEGRE, RS: DIAGNÓSTICOS E PROGNÓSTICOS A PARTIR DE
SENSORIAMENTO REMOTO**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto como requisito para a obtenção do título de doutor em Sensoriamento Remoto e Geoprocessamento.

Orientador: Profa. Dra. Silvia Beatriz Alves Rolim

Coorientador: Prof. Dr. Atilio Efrain Bica Grondona

PORTO ALEGRE

2023

CIP - Catalogação na Publicação

Kaiser, Eduardo Andre
DINÂMICA DA TEMPERATURA DE SUPERFÍCIE NO MUNICÍPIO
DE PORTO ALEGRE, RS: DIAGNÓSTICO E PROGNÓSTICO A
PARTIR DE SENSORIAMENTO REMOTO / Eduardo Andre Kaiser.
-- 2023.
139 f.
Orientadora: Silvia Beatriz Alves Rolim.

Coorientador: Atilio Efrain Bica Grondona.

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

1. Sensoriamento Remoto . 2. Infravermelho Termal.
3. Temperatura de Superfície. 4. Ilhas de Calor
Urbanas. 5. Índice de Vegetação. I. Rolim, Silvia
Beatriz Alves, orient. II. Grondona, Atilio Efrain
Bica, coorient. III. Título.

Eduardo André Kaiser

**DINÂMICA DA TEMPERATURA DE SUPERFÍCIE NO MUNICÍPIO DE PORTO
ALEGRE, RS: DIAGNÓSTICOS E PROGNÓSTICOS A PARTIR DE
SENSORIAMENTO REMOTO PROXIMAL A ORBITAL**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto como requisito parcial para a obtenção do título de **Doutor em Sensoriamento Remoto e Geoprocessamento**.

Aprovado em:

Silvia Beatriz Alves Rolim, Dra. (UFRGS)
(Presidente/Orientadora)

Atilio Efrain Bica Grondona, Dr. (UFRGS)
(Coorientador)

Waterloo Pereira Filho, Dr. (UFSM)

Guilherme Garcia de Oliveira, Dr. (UFRGS)

Clódis de Oliveira Andrade Filho, Dr. (UFRGS)

Porto Alegre, RS
2023

Dedico aos meus pais Lírio e Clair, à minha
irmã Deise e à minha esposa Caren.

AGRADECIMENTOS

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de pesquisa.

À Universidade Federal do Rio Grande do Sul, pela oportunidade de crescimento acadêmico e profissional.

Aos meus orientadores Profa. Dra. Silvia Beatriz Alves Rolim e Prof. Dr. Atilio Efrain Bica Grondona pelo incentivo, amizade e pelas contribuições inestimáveis na construção desse trabalho e em minha formação.

Aos meus colegas do Laboratório de Sensoriamento Remoto Geológico (LabSRGeo) que participaram, em vários momentos, da construção desse estudo.

Aos meus familiares e em especial à esposa Caren da Silva Bertoldo pelo incentivo, paciência e pela presença em todos os momentos da minha vida.

Aos professores, coordenação, secretaria e colegas do Programa de Pós-Graduação em Sensoriamento Remoto (PPGSR) da Universidade Federal do Rio Grande do Sul.

Por fim, agradeço a todos que de alguma forma contribuíram comigo e com a presente tese.

RESUMO

No Brasil em 2015 a população urbana era de 85,7%, com a projeção de aumento para 91% em 2050. Entre os impactos causados pelo rápido processo de urbanização estão as mudanças drásticas no uso e cobertura da terra (LULC), alterações meteorológicas e principalmente o aumento da Temperatura de Superfície Terrestre (LST). Sendo assim, a presente pesquisa tem como objetivo o estudo da dinâmica de crescimento urbano no município de Porto Alegre-RS, a partir da recuperação da LST e técnicas de redução de dados de sensoriamento remoto proximal a orbital. A primeira etapa constituiu a análise da evolução da LST entre áreas vegetadas e urbanizadas a partir da correlação de 30 anos de dados calculados de LST e o Índice de Vegetação por Diferença Normalizada (NDVI), em três bairros do município de Porto Alegre-RS. A segunda etapa foi a expansão da área de estudo da primeira etapa, para o limite territorial do município. Nesta etapa, imagens da primavera de 1995, 2006 e 2017 foram utilizadas na caracterização histórica, previsão e relação do crescimento urbano e LST. A terceira etapa compõe uma análise da LST a partir de agrupamentos (k-médias) de NDVI obtidos em 1989 e 2018 especificamente sobre a área urbana dos bairros citados na primeira etapa. Na análise espaço-temporal do LULC e LST da primeira etapa foi possível observar que a retirada de 98% e 79% das áreas de floresta e campo, respectivamente, e o crescimento da mancha urbana de 31% em 1989 para 75% em 2018 contribuiram para o aumento de 4,18°C na LST média entre a primeira e última década. Entre os mesmos períodos, a influência sazonal pode ser observada no aumento de 6,36°C no outono, 4,40°C na primavera, 4,09°C no verão e 2,41°C no inverno. Além disso, a relação entre NDVI e LST em áreas urbanizadas mostrou um aumento associado ao coeficiente de correlação de -0,55 em 1989 para -0,76 em 2018. Na segunda discussão, observou-se o aumento da área urbana de Porto Alegre em 10,16% e aumento 2,03 das áreas com LST entre 35 e 40°C, no período de 1995 a 2017. A previsão para 2028 caracterizou o aumento de 1,41% e 2,33% até 2039 na área urbana e previsão de aumento de 2,39% e 2,64% nas áreas com LST entre 35 e 40°C, respectivamente. Na terceira discussão, a retirada de ~89% da vegetação da área de estudo para ocupação urbana aliada ao aumento de aproximadamente 21% para ~43% das áreas urbanas classificadas como baixo índice de vegetação, ocasionou o aumento da amplitude térmica (diferença de

LST média das áreas de baixo e alto NDVI em 1989 e 2018) de 1,12°C. As informações acerca da evolução e previsão da LST frente as mudanças no LULC contribuem para tomada de decisões e mitigação do fenômeno de Ilhas de Calor Urbanas (ICUs) por parte de administradores responsáveis pelo planejamento urbano e pela manutenção dos serviços públicos no município de Porto Alegre- RS.

Palavras-chave: Uso e cobertura da terra, Landsat, Redes Neurais Artificiais, Temperatura de Superfície, NDVI.

ABSTRACT

In Brazil, in 2015, the urban population was 85.7%, with a projected increase to 91% in 2050. Among the impacts caused by the rapid urbanization process are drastic changes in land use and land cover (LULC), meteorological changes and mainly the increase in the Land Surface Temperature (LST). Thus, this research aims to study the dynamics of urban growth in the city of Porto Alegre-RS, based on the recovery of LST and data reduction techniques from proximal to orbital remote sensing. The first stage consisted of analyzing the evolution of LST between vegetated and urbanized areas based on the correlation of 30 years of data calculated from LST and the Vegetation Index by Normalized Difference (NDVI), in three districts of the city of Porto Alegre-RS. The second stage was the expansion of the study area of the first stage, to the territorial limit of the municipality. In this step, images from the spring of 1995, 2006 and 2017 were used in the historical characterization, forecast and relationship of urban growth and LST. The third stage comprises an analysis of the LST based on groupings (k-means) of NDVI obtained in 1989 and 2018 specifically on the urban area of the neighborhoods mentioned in the first stage. In the spatiotemporal analysis of the LULC and LST of the first stage, it was possible to observe that the removal of 98% and 79% of the forest and field areas, respectively, and the growth of the urban area from 31% in 1989 to 75% in 2018 contributed for the 4.18°C increase in mean LST between the first and last decade. Between the same periods, the seasonal influence can be observed in the increase of 6.36°C in autumn, 4.40°C in spring, 4.09°C in summer and 2.41°C in winter. Furthermore, the relationship between NDVI and LST in urbanized areas showed an increase associated with the correlation coefficient from -0.55 in 1989 to -0.76 in 2018. In the second discussion, the increase in the urban area of Porto Alegre was observed by 10.16% and a 2.03 increase in areas with LST between 35 and 40°C, in the period from 1995 to 2017. The forecast for 2028 characterized an increase of 1.41% and 2.33% by 2039 in the urban area and a forecast increase of 2.39% and 2.64% in areas with LST between 35 and 40°C, respectively. In the third discussion, the removal of ~89% of the vegetation in the study area for urban occupation, together with the increase from approximately 21% to ~43% of urban areas classified as low vegetation index, caused an increase in the thermal

amplitude (difference of LST average of low and high NDVI areas in 1989 and 2018) of 1.12°C. Information about the evolution and prediction of LST in the face of LULC changes contribute to decision-making and mitigation of the phenomenon of ICUs by administrators responsible for urban planning and maintenance of public services in Porto Alegre city.

Keywords: Land use and land cover, Landsat, Neural Network, Land Surface Temperature, NDVI.

SUMÁRIO

1	CAPÍTULO I. ASPECTOS INTRODUTÓRIOS	13
1.1	Introdução	13
1.2	Objetivos	17
1.2.1	Objetivo geral:.....	17
1.2.2	Objetivos específicos:	17
1.3	Localização e características da área de estudo	18
1.4	Considerações teóricas e práticas e nível atual do conhecimento.....	20
1.4.1	Aspectos físicos e climáticos das Ilhas de Calor Urbanas	20
1.4.2	Sensoriamento Remoto aplicado a estudos da Temperatura da Superfície Terrestre.....	27
1.4.2.1	Caracterização de Ilhas de Calor Urbanas	27
1.4.2.2	Índice de Vegetação por Diferença Normalizada	29
1.4.2.3	Dados do Infravermelho Termal.....	31
1.4.3	Previsão de séries temporais a partir de Redes Neurais Artificiais.....	35
2	CAPÍTULO II. SPATIOTEMPORAL INFLUENCES OF LULC CHANGES ON LAND SURFACE TEMPERATURE IN RAPID URBANIZATION AREA BY USING LANDSAT-TM AND TIRS IMAGES.....	44
3	CAPÍTULO III. AVALIAÇÃO E PREVISÃO DO USO E COBERTURA DA TERRA E DA TEMPERATURA DE SUPERFÍCIE NO MUNICÍPIO DE PORTO ALEGRE-RS, BRASIL, A PARTIR DE DADOS DE SENSORIAMENTO REMOTO E ALGORITMO CA-ANN	63
4	CAPÍTULO IV. IMPACT ASSESSMENT OF URBAN GROWTH ON LAND SURFACE TEMPERATURE THROUGH CHANGES IN THE NORMALIZED DIFFERENCE VEGETATION INDEX USING LONG TERM LANDSAT SERIES DATA	94
5	CAPÍTULO V. CONSIDERAÇÕES GERAIS	125

ESTRUTURA DA TESE

A proposta da presente tese consiste na organização de 5 capítulos, apresentados em maiores detalhes na sequência:

-Primeiro capítulo: aborda aspectos introdutórios e metodológicos referentes a temática da pesquisa, no que tange a relevância e introdução do tema, objetivos gerais e específicos, localização e características das áreas de estudo e referencial teórico.

-Segundo capítulo: comprehende o primeiro artigo dos resultados. Este foi publicado na revista *Atmosphere* (<https://doi.org/10.3390/atmos13030460>) e é intitulado como “Spatiotemporal Influences of LULC Changes on Land Surface Temperature in Rapid Urbanization Area by Using Landsat-TM and TIRS Images”, (KAISER *et al.*, 2022).

-Terceiro capítulo: apresenta o segundo artigo dos resultados. Este foi submetido na revista *Geo UERJ* e é intitulado como “Avaliação e previsão do Uso e Cobertura da Terra e da Temperatura de Superfície no município de Porto Alegre-RS, Brasil, a partir de dados de sensoriamento remoto e algoritmo CA-ANN”.

-Quarto capítulo: comprehende o terceiro artigo dos resultados. Este foi submetido na revista *Journal of Applied Remote Sensing* e é intitulado “Impact assessment of urban growth on Land Surface Temperature through changes in the Normalized Difference Vegetation Index using long term Landsat series data”.

-Quinto capítulo: são apresentadas as considerações finais sobre os resultados obtidos e técnicas utilizadas nos artigos apresentados nos capítulos anteriores.

1 CAPÍTULO I. ASPECTOS INTRODUTÓRIOS

1.1 Introdução

Os impactos das diferentes ações antrópicas no clima do planeta têm alcançado magnitudes sem precedentes (SILVA *et al.*, 2015). Nos últimos 50 anos, a transformação dos ecossistemas tem sido mais rápida do que em qualquer outro período da história, e o crescente aumento do uso antrópico da terra tem acarretado em fortes mudanças nos balanços energéticos superficiais (LEITE, 2011). Estas mudanças provocam consideráveis aumentos térmicos nos diferentes elementos da paisagem urbana (SILVA *et al.*, 2015). Conforme Gartland (2010) em grande parte das cidades a redução das áreas verdes e o elevado aumento de locais asfaltados têm provocado o surgimento de um fenômeno climático denominado Ilhas de Calor Urbanas (ICUs).

ICUs caracterizam um termo muito comum usado para indicar a tendência de áreas urbanas em experimentar elevados níveis de temperatura quando comparados com sua periferia rural (FAVRETTTO, 2018). De forma técnica, pode-se definir ICU como padrões locais marcantes de maior aquecimento com relação ao ambiente circundante, especialmente em centros urbanos densamente construídos com pouca ou nenhuma vegetação aonde as temperaturas tendem a ser mais altas (DE SOUZA ; DOS SANTOS ALVALÁ, 2014; LIMA ;LOPES, 2017; PERES *et al.*, 2018).

Nos dias atuais mais da metade da população mundial vive em áreas urbanizadas e, até o ano de 2030, as cidades devem acomodar mais de 60% da população global, sendo que 1 a cada 3 pessoas viverão em cidades com pelo menos 500.000 habitantes (DE SOUZA; DOS SANTOS ALVALÁ, 2014; FAVRETTTO, 2018). Desta forma as ICUs são consideradas uma questão global tendo implicações na saúde humana, na poluição do ar, no gerenciamento de energia e planejamento urbano, nas chuvas intensas no verão, no desconforto térmico e eventualmente em altas taxas de mortalidade em pessoas fisicamente vulneráveis (LIMA; LOPES, 2017; FAVRETTTO, 2018 ; PERES *et al.*, 2018).

Diante destes fatos, Souza (2004) investigou que cidades mal planejadas sofrem graves problemas com o fenômeno de ICU. O aumento da temperatura vem prejudicando não somente o meio ambiente e o microclima local como também a

população. Entre os principais problemas de saúdes originados pelas as grandes emissões de calor podemos citar: desidratação, oscilação de pressão arterial, problemas respiratórios, problemas renais, dentre outros (LIMA; LOPES, 2017; RAMOS *et al.*, 2017; FAVRETTO, 2018). Uma forma de avaliar a ocorrência das ICUs se dá através da Temperatura de Superfície.

A Temperatura de Superfície (do inglês *Land Surface Temperature*- LST) é uma variável que está relacionada com superfícies impermeáveis e permeáveis as quais dependem dos tipos de Uso e Cobertura da Terra (do inglês *Land Use and Land Cover*- LULC) (vegetação, corpos de água, áreas construídas e solo) e suas mudanças (MUSHORE *et al.*, 2017; HALDER; BANDYOPADHYAY; BANIK, 2021; KAFY *et al.*, 2021; ASHWINI; SIL, 2022). O aumento da LST está fortemente relacionada com os processos de urbanização, industrialização e o planejamento inapropriado de expansão das cidades, criando áreas densamente preenchidas com prédios e superfícies como concreto e asfalto que possuem propriedades de alta retenção de calor (LIMA; LOPES, 2017; FAVRETTO, 2018). Além disto, a falta de áreas verdes, áreas de pouca permeabilidade, ou áreas com material de baixo albedo tem papel importante no aumento da LST, que pode ainda ser agravado pela geometria da área urbanizada devido à redução na velocidade dos fluxos de ar (ventos) (DE SOUZA; DOS SANTOS ALVALÁ, 2014; DE LUCENA *et al.*, 2015; LIMA ; LOPES, 2017; FAVRETTO, 2018).

Assim, o diagnóstico da LST tem se mostrado um instrumento importante para a gestão do espaço urbano, pois oferece subsídios para tomada de decisões no intuito de amenizar a magnitude das ICUs (AMORIM *et al.*, 2015). Atenuar os efeitos das ICU em climas tropicais e subtropicais é indiscutivelmente um ponto chave no planejamento urbano para lidar com as mudanças climáticas nas cidades (ALVES; LOPES, 2017).

Vários autores vem estudando o fenômeno ICU a partir de dados de LST através do Sensoriamento Remoto ao redor do mundo, dentre eles: Feyisa *et al.*, (2014); Akbari *et al.* (2015) e Aflaki *et al.* (2017) estudaram métodos de mitigação para o fenômeno de ICU para cidades da África e Ásia; Mirzaei (2015) avaliou as causas das ICU para a região da Europa; Ward *et al.*, (2016) desempenharam um estudo comparativo entre modelos de previsão de ICU; Li *et al.*, (2009); Weng, (2009); Buyantuyev e Wu (2010); Li *et al.*, (2016); Wang *et al.*, (2016) e Estoque *et al.*,(2017)

estudaram os padrões de distribuição espacial das ICU, a influência da arquitetura e da composição superficial do solo nesses padrões; Haashemi *et al.*, (2016) estudaram as variações sazonais das ICU para a cidade de Teerã; Liu e Zhang (2011); *et al.*, (2016) estudaram os efeitos da ICU em metrópoles chinesas; Rasul *et al.* (2017) realizaram um estudo sobre as ICUs e as Ilhas de Resfriamento Urbano (IRU) e os métodos de quantificação e comparação dos mesmos; enquanto Peng *et al.* (2012) realizaram um estudo sobre 419 metrópoles globais com o intuído de identificar quais os potenciais fatores biofísicos e socioeconômicos causadores do fenômeno de ICU.

No Brasil, predominantemente, os estudos sobre LST e Ilhas de Calor Urbanas (ICUs) estão voltados para as capitais e, mesmo assim, há uma carência de pesquisas detalhadas e multitemporais de análise evolutiva deste fenômeno. Dentre os mais recentes trabalhos de pesquisadores brasileiros pode-se citar Barros (2016) que estudou a relação entre a ICU, o LULC e o balanço de energia para a cidade de São Paulo; De Moraes *et al.*, (2013); De Souza e Dos Santos Alvalá (2014); Amorim *et al.* (2015); De Lucena *et al.* (2015); Filho *et al.*, (2016); Gomes *et al.*, (2017) e *et al.* (2017) realizaram a identificação de ICUs para as cidades de Cáceres (MT), Patos de Minas (MG), Ubatuba (SP), Presidente Prudente (SP), Belo horizonte (MG), Manaus (AM) e Rio de Janeiro (RJ), respectivamente; Grondona *et al.* (2013) fizeram um estudo da variação das ICUs para a cidade de Porto Alegre para um período de 20 anos; Peres *et al.* (2018) estudaram o fenômeno de ICU para a região metropolitana da cidade do Rio de Janeiro (RJ) nos últimos 30 anos analisando a temperatura de superfície e os padrões do LULC; enquanto Alves e Lopes (2017) analisaram a influência de variáveis geográficas urbanas na determinação de ICU e propuseram um modelo para estimar e espacializar a intensidade máxima das ICUs.

A motivação desta tese surgiu devido tanto pela falta de estudos aprofundados sobre a caracterização da LST em uma escala local, no caso para a cidade de Porto Alegre- RS, quanto pelas projeções de mudanças climáticas destacas pelo sexto relatório (AR6) do Painel Intergovernamental sobre Mudanças Climáticas (IPCC). As projeções indicam o aquecimento da superfície em 1,5°C entre os anos de 2030 e 2035. As duas primeiras décadas do século XXI (2001-2020) apresentaram aumento de 1 °C em comparação ao aumento verificado em cinquenta anos do período de 1850 a 1900 (IPCC, 2022).

As cidades desempenham cerca de 40% das emissões de Gases do Efeito Estufa (GEE) (ROSENZWEIG *et al.*, 2011; ECF, 2014). Estimativas da Organização das Nações Unidas (ONU) apontam que em 2050 a população mundial urbana chegará a dois terços da população mundial. No Brasil em 2015 a população urbana era de 85,7%, com a previsão de que esse valor chegue a 91% em 2050 (ONU, 2014). Segundo o Painel Brasileiro de Mudanças Climáticas (PBMC), mudanças climáticas principalmente em escala local já estão acontecendo, cujas consequências em ambientes urbanos abrangem o aumento da temperatura, formação e aumento de intensidade de ilhas de calor, inundações, escassez de água e alimentos e eventos extremos (PBMC, 2016).

Diante desta abordagem, a hipótese da presente pesquisa considerou que as variáveis destacadas pelos índices de uso e cobertura da terra, principalmente o NDVI, apresentam relação direta com o crescimento urbano, e assim atuam como condicionantes do comportamento térmico das cidades. Pressupõe-se que a combinação de diferentes bandas do satélite Landsat e utilização de técnicas de Processamento Digital de Imagens (PDI) possibilite avaliar a evolução espaço-temporal destas variáveis e então realizar o prognóstico das alterações no uso e cobertura da terra e temperatura de superfície.

Nesse contexto, o objetivo geral da pesquisa foi o estudo da dinâmica de crescimento urbano no município de Porto Alegre- RS, a partir da recuperação da LST com de técnicas de redução de dados de sensoriamento remoto proximal a orbital. A definição da área de estudo foi motivada devido a histórica e pioneira preocupação ambiental voltada para a mancha urbana do município. Porto Alegre foi a primeira cidade a nível nacional a criar a Secretaria Municipal do Meio Ambiente em 1976, que aliada ao Plano Diretor de Desenvolvimento Urbano de 1979, exigiam a ocupação de 2% dos loteamentos para parques verdes. Vinte anos depois o município já contava com um índice de áreas verdes (índice que expressa a quantidade de espaços livres de uso público pela quantidade habitantes residentes em determinada cidade) de 13,35 m²/hab. Atualmente a arborização viária caracteriza patrimônio ambiental do município. Assim, entender e modelar a dinâmica da LST associada aos índices de LULC, especialmente ao NDVI, pode contribuir para o plano de desenvolvimento da cidade e facilitar a tomada de decisão dos órgãos gestores do espaço urbano.

A fim de atender o objetivo supracitado, a pesquisa foi dividida em etapas, cada uma delas compreendeu a construção de um artigo, conforme exposto nos capítulos 2, 3 e 4. Na primeira etapa buscou-se caracterizar a LST de 1985 a 2018 (117 imagens dos sensores TM/OLI/TIRS dos satélites Landsat 5 e 8) de acordo com variações sazonais na atual área urbana de três bairros que sofreram rápido processo de urbanização, localizados no município de Porto Alegre- RS. Além disto, neste mesmo intervalo foram estudadas as variações de LULC e a relação de LST e NDVI. Na segunda etapa realizou-se a caracterização da LULC e LST, ampliada para todo município. Nesta etapa, imagens Landsat de 1995, 2006 e 2017 foram utilizadas na recuperação, classificação, caracterização histórica e previsão do LULC e LST. Na terceira etapa buscou-se atenuar o efeito das condições meteorológicas locais a partir do estudo da diferença de amplitude da LST recuperada em anos diferentes. Para isso, foram extraídos valores de LST, apenas da área urbana dos bairros citados anteriormente, de acordo com grupos de baixo, moderado e alto NDVI em 1989 e 2018. A avaliação da LST em relação aos agrupamentos de NDVI está atribuída à maior dependência deste em relação variações sazonais da vegetação e do clima (Moreira et al., 2019).

1.2 Objetivos

1.2.1 Objetivo geral:

O objetivo desta pesquisa foi o estudo da dinâmica de crescimento urbano no município de Porto Alegre- RS, a partir da recuperação da LST e técnicas de redução de dados de sensoriamento remoto proximal a orbital.

1.2.2 Objetivos específicos:

- Analisar a evolução da LST correlacionando 30 anos de dados calculados de LST e NDVI e identificando possíveis influências sazonais por meio de análise de regressão;

-Estimar o LULC e LST atual e futuro usando uma combinação de dados de sensoriamento remoto, algoritmos CA-ANN e índices de LULC no município de Porto Alegre-RS;

- Propor um método alternativo de comparação da LST de diferentes anos a partir das variações no NDVI de uma área urbana que apresentou rápido crescimento durante 1989-2018.

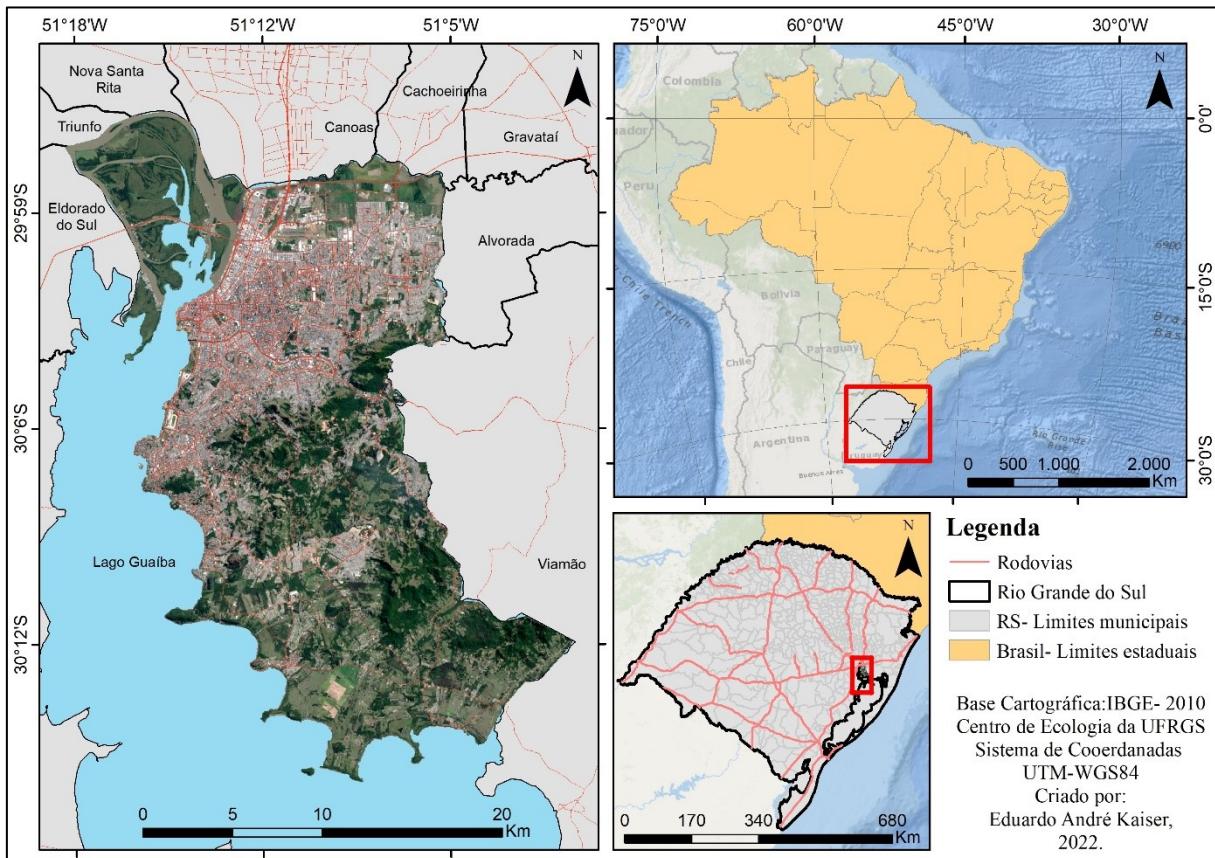
1.3 Localização e características da área de estudo

A área de estudo comprehende a capital político administrativa do estado do Rio Grande do Sul, o município de Porto Alegre. A porção oeste e o sudoeste do território municipal são banhados pelo lago Guaíba, enquanto os municípios de Viamão e Alvorada fazem divisa pelo lado leste e a norte os municípios de Canoas e Cachoeirinha. Conforme a Figura 6, tal área está localizada entre as coordenadas geográficas 30° 01' 59" S e 51° 13' 48"O.

Porto Alegre caracteriza uma área de 49.680 hectares, sendo 4.445 hectares de ilhas, localizadas ao norte do lago Guaíba no delta do rio Jacuí. Sobre essas áreas aproximadamente 1.409.351 habitantes exercem suas atividades, o que representa uma densidade média populacional de 29,58 habitantes/ha (Instituto Brasileiro de Geografia e Estatística- IBGE, 2010).

O crescimento populacional do município assumiu taxas expressivas até 1970, quando a população já alcançava 903.175 habitantes. A partir da década de 1980 o caráter de ocupação passou a predominar sobre a área urbana quando comparada a área rural, marcada pela expansão urbana principalmente sobre uma área de colinas graníticas, caracterizada por entornos de estreitas faixas de planície junto ao lago Guaíba. Frente as limitações impostas pelo relevo (áreas elevadas de alta declividade e planícies atingidas por inundação) o crescimento urbano se deu inicialmente sobre morros de altitudes medianas próximos a zona portuária, atual bairro Centro Histórico de Porto Alegre e ao longo do lago Guaíba estendendo-se atualmente para praticamente metade da área do município. Ademais, a população que era de 1.158.709 habitantes em 1980, passou para 1.263.239 habitantes em 1991, 1.360.033 habitantes no ano de 2000 e 1.409.351 habitantes em 2010 (DIAS, 2011).

Figura 1. Localização do município de Porto Alegre em relação ao estado do Rio Grande do Sul e Brasil.



Fonte: Elaboração própria.

O relevo de Porto Alegre caracteriza-se por uma região de contato entre o Escudo Sul-rio-grandense e a Planície e/ou Terras Baixas Costeiras, além dos sedimentos provenientes da Depressão Periférica (SUERTEGARAY; FUJIMOTO, 2004). Tal caráter se reflete na variedade em termos paisagísticos no município, já que podem ser encontradas áreas de colinas, morros e extensas áreas planas no entorno de canais fluviais. Em termos altimétricos, o Porto Alegre possui altitudes que variam entre 0,1m na Ilha das Flores a 311,20m em seu ponto culminante, o Morro Santana.

A vegetação da região onde está inserido o município caracteriza-se pela cobertura da Floresta Estacional Semidecidual em conjunto com formação vegetais pioneiras, restingas e banhados (TEIXEIRA *et al.*, 1986). Tal cobertura constitui-se por gemas foliares deciduais cuja perda de folhas ocorre de 20% a 50% sobre condições de baixas temperaturas verificadas no inverno (LEITE; KLEIN, 1990). De acordo com a classificação de Koeppen, corresponde ao subtipo "cfa", cuja temperatura média

anual resulta em 19,5 °C e precipitação pluviométrica de 1.300 mm anuais (MENEGAT et al., 1999; SILVA, 2019).

1.4 Considerações teóricas e práticas e nível atual do conhecimento

A proposta de trabalho tem como teoria central o cálculo da Temperatura da Superfície Terrestre (LST) para a cidade de Porto Alegre - RS no período de 1985 a 2018, e a determinação da relação com as características locais no que se refere ao LULC e seus índices e atributos físicos do terreno. Estes dados servirão como principais entradas para as Redes Neurais Artificiais (RNAs) para a construção de modelos de previsão do crescimento urbano e da LST. Como a formação das Ilhas de Calor Urbanas está diretamente atrelada ao aumento da LST e são consideradas um fenômeno urbano, alguns aspectos referentes as características físicas e climáticas destas são tratadas no presente tópico. Entretanto cabe ressaltar o enfoque da pesquisa na LST associada ao crescimento urbano e alterações nos índices de LULC, onde as ICUs são caracterizadas de maneira indireta.

1.4.1 Aspectos físicos e climáticos das Ilhas de Calor Urbanas

No intuito de entender as relações existentes entre a formação das ICUs e as características físicas e meteorológicas locais, inicialmente faz-se necessária a compreensão dos conceitos de clima e tempo. O primeiro é determinado através de médias estatísticas de dados observacionais referentes à precipitação pluviométrica, temperatura do ar média, vento, pressão atmosférica e nuvens obtidos em, no mínimo, 30 anos (HARTMANN, 1994; AYOADE, 1998). O segundo pode ser definido como um conjunto de atributos atmosféricos e meteorológicos cujos impactos ocorrem sobre a superfície terrestre em determinado local e momento (SORRE, 1934). Ademais, o autor pressupõe que o clima caracteriza um conjunto de tipos de tempo encontrados em determinada região, resultado de valores médios apenas.

A alteração dos elementos do clima ocorre tanto por características meteorológicas naturais quanto pelas modificações no LULC, sendo estas últimas inerentes principalmente do processo de urbanização (MONTEIRO, 1976). Segundo o autor, as consequências deste processo competem: formação de ICUs, desconforto térmico, inundações e alagamentos, inversão térmica, chuva ácida e poluição do ar.

Tais consequências são, principalmente, produto da troca de energia atmosfera/superfície e ocorrem principalmente em escala local.

As trocas de energia entre a dinâmica atmosférica e a superfície terrestre pode ocorrer tanto em escala local como planetária, sendo propostos três níveis de escalas de abrangência: macroclimático, mesoclimático e microclimático (RIBEIRO, 1993; AYOADE, 1998). A principal diferença entre o macroclima e mesoclima está na influência das características topográficas e morfológicas verificadas sobre esta última em escala local, enquanto o primeiro está relacionado ao clima geral de uma região do planeta com movimentos atmosféricos em larga escala. Por sua vez o microclima tem sua descrição definida pela interferência antrópica sobre a superfície, por meio de modificações espaciais. Como consequência dessas modificações tem-se mudanças no clima próximo à superfície e em pequenas extensões (menores que 100 metros).

Partindo dos pressupostos apresentados por Sorre (1934), Monteiro (1976) em sua proposta teórica e metodológica denominada “Sistema Clima Urbano” (SCU), define o clima urbano como o clima de determinado local vinculado ao processo de urbanização ocorrente, expresso pelas condições atmosféricas e as características da superfície atuantes de maneira conjunta. Tal proposta sugere a adoção de três subsistemas de análise: o termodinâmico (temperatura do ar e conforto térmico), físico-químico (poluição e qualidade do ar) e hidrometeorológico (impactos pluviais). A organização dos subsistemas teve como referência os impactos ocasionados pelas características da atmosfera sobre a vida cotidiana da população. Para o autor, os seres humanos constituem o foco do problema e análise do clima urbano propicia resultados principalmente utilizados para planejamento da cidade.

Frente a alterações na compartimentação ecológica, morfológica, funcional e urbana, ou seja, a estrutura do SCU, tem-se como resultado modificações nos fluxos normais de absorção, reflexão e armazenamento de energia (MONTEIRO, 1976). Assim a forma urbana, densidade de ocupação, tipo de material, verticalização das construções e principalmente a retirada de cobertura vegetal modificam o ritmo de ganho e perda de energia, cuja consequência resulta em anomalias térmicas, diagnosticadas como ICUs.

A revisão de literaturas referentes a estudos de clima urbano permitiu verificar a predominância da definição de ICU como um fenômeno que ocorre quando a

temperatura urbana é superior a temperatura verificada em ambientes naturais ou rurais vizinhos (OKE, 1978; LANDSBERG, 1982; GARCIA, 1996; ARNFIELD, 2003; DAN *et al.*, 2010; SCHWARZ *et al.*, 2011), cujas consequências conduzem para ocorrência de altas temperaturas locais (LI *et al.*, 2015; FOUNDA; SANTAMOURIS, 2017) principalmente devido a substituição da cobertura vegetal por superfícies pavimentadas.

Frente às diferenças de temperatura verificadas em ambiente rural e urbano, Garcia (1996) propõe basicamente 4 níveis de magnitude e intensidade de ICUs conforme exposto na Tabela 1.

Tabela 1. Intensidades das ilhas de calor.

Magnitude	Diferença térmica entre área urbana e rural
Fraca	0°C a 2°C
Média	2°C a 4°C
Forte	4°C a 6°C
Muito Forte	Diferenças acima de 6°C

Fonte: Adaptado de Garcia, 1996.

A temperatura do ar nas cidades, a formação de ilhas de calor e frescor urbano, a inversão térmica e as situações de desconforto térmico foram documentadas pela primeira vez em 1818 por Luke Howard em estudo realizado sobre a cidade de Londres (OKE, 1982). Tais situações são intensificadas em áreas tropicais onde há ocorrência do processo de urbanização (MENDONÇA, 2015). Ademais, o autor verifica que no Brasil houve predominância dos estudos dos subsistemas físico-químicos (poluição e qualidade do ar) e termodinâmicos (temperatura do ar e conforto térmico).

A formação das ICUs prejudica o conforto térmico da população principalmente idosa. O excesso de calor agrava problemas respiratórios, cardíacos e doenças como a diabetes, devido à troca de calor entre o corpo humano e o meio ambiente, além da execução de atividades ser dificultada frente a condições ambientais desfavoráveis associadas ao desconforto térmico. Além disso, o impacto das ICUs afeta também populações vulneráveis economicamente visto que habitações precárias expõem os

citadinos as condições adversas do ambiente atmosférico, o que leva a maior incidência de doenças (SOUZA *et al.*, 2010; SILVA *et al.*, 2014).

Para Lombardo (1985) o fenômeno denominado como ICU é formado por bolsões de ar oriundos das mudanças no balanço de energia ocasionados principalmente pelo processo de urbanização. Oke (1981) elencou as alterações de trocas de energia e condições térmicas devido os seguintes atributos da urbanização:

- Poluição do ar: a maior absorção de radiação solar de ondas-curtas de entrada e saída em ondas-longas ocasionada pela presença de poluentes;
- Propriedades térmicas dos materiais: aumento da admitância térmica da superfície (taxa de fluxo de calor entre a superfície interna de um elemento ou componente construtivo e o ar, por unidade de variação de temperatura) e dos materiais utilizados em construções favorecem à absorção de calor durante o dia e emissão durante a noite;
- Calor antropogênico: calor liberado no processo de combustão;
- Geometria da superfície: aumento da absorção da radiação em ondas-curtas devido a interceptação interna dos cânions urbanos (combinação geométrica de superfícies horizontais e verticais intraurbanas) e retenção de calor e radiação de ondas-longas devido à redução do fator de visão do céu e;
- Presença de superfícies impermeáveis: redução da evaporação e diminuição do fluxo de calor latente e assim, aumento calor sensível.

Deste modo, a formação das ICUs está diretamente associada à ocorrência de fatores locais de ordem natural e urbana. As condições meteorológicas e o relevo constituem os fatores naturais enquanto as mudanças do LULC configuram os fatores urbanos. Diante da necessidade de adoção de medidas, métodos e análise para auxiliar o planejamento e gestão urbana, Gartland (2010) propôs três métodos básicos para verificar o efeito da urbanização sobre a formação das ICUs: estações físicas, transectos móveis e sensoriamento remoto.

Na presente tese será dada uma maior ênfase ao Sensoriamento Remoto (SR), conforme apresentado nos Capítulos 3.2 ao 3.4, devido o potencial da sua utilização para recuperação da LST. Este potencial refere-se à capacidade de fornecer

observações consistentes e repetíveis acerca da superfície da Terra, possibilitando o estudo do ambiente térmico urbano tanto em escala local como global e temporal (diurna, sazonal e interanual) (WENG, 2009; DEILAMI *et al.*, 2018). Deste modo, o SR pode ser usado para definir ICUs de maneira espacialmente explícita e ao longo do tempo (PICHIERRI *et al.*, 2012; HO *et al.*, 2014). As primeiras observações a respeito do fenômeno de ICUs foram relatadas por Rao (1972) em uma área de estudo localizada no leste dos Estados Unidos e desde então o número e a qualidade de estudos sobre ICUs aumentou consideravelmente justamente devido aos avanços no SR.

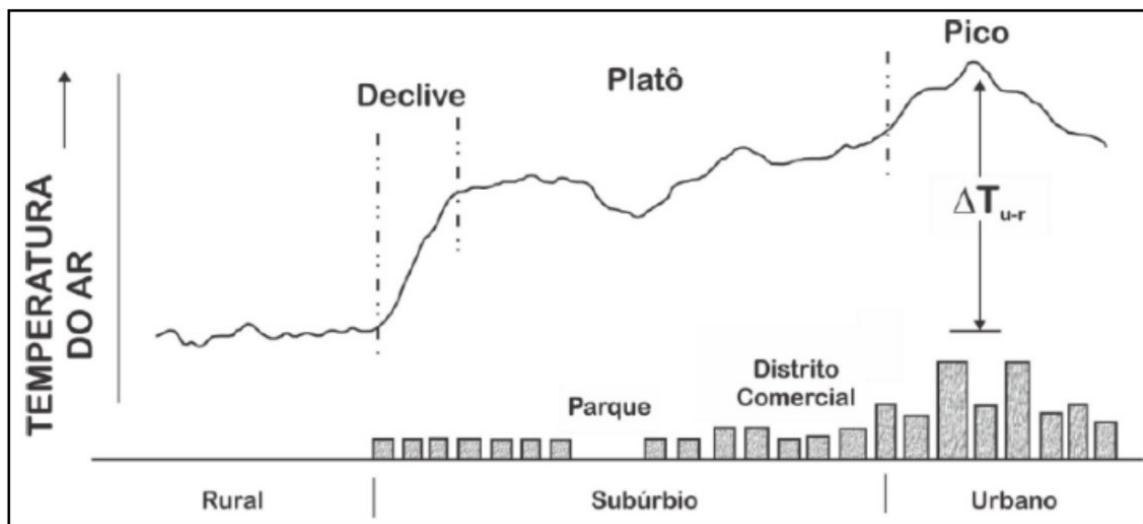
O tipo de LULC compõe um papel importante nas mudanças ocorrentes em ambiente urbano no que se refere a evolução das ilhas de calor. As diferentes refletâncias da superfície e rugosidades dos tipos de LULC, determinam as diferenças nos valores de LST (HOU *et al.*, 2010). Portanto, análises mais precisas dos efeitos da LULC sobre a distribuição, faixa e intensidade das LSTs são úteis para entender os mecanismos subjacente à causa e evolução das ICUs.

A principal causa da formação das ICUs está atrelada a substituição das áreas de cobertura vegetal por material sintético. A complexidade verificada na estrutura urbana justificada pelo excesso de superfícies verticais e horizontais, propicia maior absorção da radiação solar, influencia no albedo, altera os fluxos de ar (ventos) e armazenamento de calor durante o dia (STEWART, 2011). Visto que as superfícies artificiais desempenham resfriamento com menor velocidade, o calor recebido durante o dia é liberado a noite tornando a atmosfera localizada sobre a cidade mais quente. Se comparadas a temperaturas encontradas em ambiente rural e urbano, a diferença entre elas são menores no período da manhã e maiores no período da tarde (GARTLAND, 2010). Segundo o autor, as áreas de baixa temperatura do ar possuem relação com a presença de vegetação por basicamente dois motivos:

- 1. O processo de evapotranspiração que transforma o calor sensível em calor latente devido a mudança de fase da água, do estado líquido para gasoso, através da evaporação e;
- 2. A sombra desempenhada pela cobertura vegetal protege a superfície da incidencia direta dos raios solares, assim diminuido a absorção e consequente armazenamento de calor.

A introdução de vegetação essencialmente arbórea em ambiente urbano configura a principal estratégia para mitigar o aumento da LST e consequente formação das ICUs. Conforme descrito por Chen e Wong (2006) uma vez diminuída a temperatura do ar em determinado local comparado as temperaturas mais elevadas no entorno, cria-se o efeito “oásis”. Tal efeito pode ser verificado principalmente em parques e praças altamente vegetados (Figura 1). O contrário deste efeito, o “oásis inverso” caracteriza-se por temperaturas do ar mais elevadas do que áreas circundantes, atribuídas principalmente ao tipo de material utilizado na construção das cidades (GARTLAND, 2010).

Figura 2. Seção transversal genérica de uma ilha de calor urbana típica.



Fonte. OKE, 1987.

No LULC do tipo urbano o acúmulo de calor é justificado pela alta densidade de construções e estradas pavimentadas com concreto ou asfalto. Visto que os materiais artificiais retêm mais calor, se comparados com superfícies naturais, a capacidade de reflexão determinada pelo albedo e a eficiência de emissão (emissividade) atuam como principais mediadores desse calor, cujas superfícies mais frias estão associadas a elevados valores de albedo e emissividade enquanto a maior absorção de calor está diretamente associada a valores de albedo e emissividade mais baixos (SANT'ANNA NETO, 2011).

A tabela 2 sintetiza as propriedades radiativas dos principais tipos de LULC comuns em ambiente tropical.

Tabela 2. Propriedades radiativas de diferentes tipos de uso e cobertura da terra (LULC).

LULC	ALBEDO (α)	EMISSIVIDADE (ϵ) DE 8~14 μ m
Área urbana		
Variações	0.10 - 0.27	0.85 - 0.96
Médias	0.15	0.95
Solo exposto		
Escuro, úmido	0.05	0.90
Claro, seco	0.5	0.98
Grama		
Alta (1m)	0.16	0.90
Baixa (0.02m)	0.26	0.95
Florestas		
Sem folhas	0.15	0.97
Com folhas	0.20	0.98
Água		
Pequeno ângulo zenital	0.03 - 0.10	0.92 - 0.97
Grande ângulo zenital	0.10 - 1.00	0.92 - 0.97

Fonte: Adaptado de Oke (1987).

As variações da Temperatura da Superfície Terrestre (LST) também estão associadas às características topográficas da superfície. Tanto em ambiente rural como urbano, tais características influenciam a distribuição espacial da temperatura a partir de três aspectos principais: altimetria, declividade e orientação das vertentes.

Na área urbana a variação de temperatura acompanha as variações do relevo, pois em locais de vale a temperatura tende a ser diferente se comparada às áreas localizadas no topo das montanhas. Dorigon e Cardoso (2015) verificaram que essas diferenças são mais significativas durante o período noturno e sobre a influência de massas de ar de origem polar. Tal fenômeno caracteriza principalmente situações de inversão térmica, já que o ar mais frio tende a se concentrar próximo a superfícies de baixa altitude enquanto o ar mais quente em regiões do terreno mais elevadas. Porém a presença de superfícies urbanizadas altera esse fenômeno principalmente nas áreas de vale, justificado pela capacidade de armazenamento de calor.

Uma vez associadas as variáveis de LST e elevação do terreno, a relação espacial ocorre de maneira inversa, ou seja, à medida que a altitude aumenta os

valores de LST diminuem. Frente o estabelecimento da tendência linear entre as variáveis, Deng et al., (2018) verificaram a forte correlação negativa de 0.78 com uma taxa de queda de 7,6 °C/Km. Khandelwal et al., (2018) sob a mesma tendência linear negativa dos dados, constataram a diferença de 3,5 °C a 4,6 °C/Km de elevação para diferentes estações do ano. Os autores também ressaltam a necessidade de quantificação dos efeitos de mudança na elevação para estudos relacionados à distribuição espacial do LST, evapotranspiração, mudanças climáticas e ICUs.

A orientação de vertentes caracteriza um papel importante no aquecimento da superfície, pois define a quantidade de radiação solar recebida dependente da direção de incidência. No hemisfério sul, por exemplo, a incidência de raios solares sobre as vertentes voltadas para o norte provoca maior aquecimento se comparadas as vertentes voltadas para o lado sul. Tal efeito é potencializado frente a maior inclinação do sol, principalmente verificada na estação do ano correspondente ao inverno (UGEDA JUNIOR, 2011).

1.4.2 Sensoriamento Remoto aplicado a estudos da Temperatura da Superfície Terrestre

1.4.2.1 Caracterização de Ilhas de Calor Urbanas

O uso de sensoriamento remoto orbital aplicado ao estudo do clima urbano iniciou juntamente com os primeiros lançamentos de sistemas orbitais. Conforme Stewart (2011), os primeiros estudos desempenhavam maior preocupação com as mudanças de temperatura ocorrentes em ambiente urbano enquanto na atualidade verifica-se o predomínio de estudos sobre a caracterização das Ilhas de Calor Urbanas (ICUs) e também de frescor, diante os fatores que afetam sua formação e assim a mitigação destes, principalmente para fins de planejamento urbano.

Frente às constantes evoluções tecnológicas, no que se refere ao desenvolvimento de novos sensores a bordo de plataformas orbitais com resoluções espectrais, espaciais, temporais e radiométrica cada vez mais refinadas, os procedimentos desempenhados para detecção da Temperatura da Superfície Terrestre (LST) são melhorados, o que favorece a ascensão no número de trabalhos publicados sobre a temática. Deste modo, as estratégias de desenvolvimento e

gerenciamento do território são facilitadas, já que tais tecnologias permitem analisar as mudanças no ambiente natural como consequência da urbanização em diferentes escalas espaciais e temporais (NETZBAND; JURGES, 2010).

Nas últimas décadas foram conduzidos alguns estudos referentes à relação entre as variáveis de Uso e Cobertura da Terra (LULC) e Temperatura da Superfície Terrestre (LST) em grandes cidades como Tokyo com dados de um único dia (variações durante o dia e noite) (KAWASHIMA, 1994), em Bangkok a partir de imagens do sensor TIRS durante a estação seca de 2014 (ESTOQUE *et al.*, 2017) e Inner Hanoi com imagens TIRS durante o período de 2016 a 2017 (THANH HOAN *et al.*, 2018) e com baixa resolução espacial, NOAA-AVHRR - 1km (SMITH *et al.*, , 1990; GALLO *et al.*, 1993), NOAA-16 e NOAA-17 – 8km (JULIEN; SOBRINO, 2009), MODIS – 1km (YUAN *et al.*, 2017). Portanto, grande parte destes relaciona as variáveis segundo condições específicas de suas áreas de estudo e em curtos períodos de tempo. Cabe destacar que a relação LST, NDVI e LULC ocorre de maneira distinta ao longo do tempo e de acordo com o uso e cobertura da terra em uma grande região metropolitana se comparada com um centro urbano de médio porte.

O aumento da resolução temporal e espacial dos sensores orbitais desenvolvidos nas últimas décadas condicionou novas oportunidades para o estudo da LST (PATINO; DUQUE, 2013). A exemplo disto, a gama de dados de média resolução espacial da plataforma Landsat 5-sensor TM utilizada para quantificação da paisagem urbana no âmbito das ciências exatas e sociais (ALBERT *et al.*, 2004). Embora a média resolução espacial das imagens obtidas por este sensor possa prejudicar o estudo de superfícies urbanas devido a sua heterogeneidade (concreto, asfalto, árvores, telhas, metal, dentre outros) (SMALL, 2002), as características multiespectrais se tornam um atributo favorável, visto que oferecem dados tanto na banda de espectro refletido (obtenção do LULC) quanto nas bandas termais (características térmicas da superfície) tomadas no mesmo instante (VOOGT; OKE, 2003).

A série histórica dos últimos trinta anos do programa Landsat apresenta um expressivo acervo de imagens, no que se refere as missões Landsat 5 (sensor Thematic Mapper-TM), Landsat 7 (sensor Enhanced Thematic Mapper -ETM+) e Landsat 8 (sensores Operational Land Imager- OLI e Thermal Infrared Sensor- TIRS).

A presente tese faz uso das imagens obtidas pelo sensor TM durante o período de 1985 a 2011 e sensores OLI e TIRS a partir de 2013 até 2018. As características das bandas de cada satélite podem ser observadas nas tabelas 3 e 4, respectivamente.

Tabela 3. Características das bandas Landsat 5.

Sensor	Band number	Band name	Wavelength (μm)	Resolution (m)
TM	1	Blue	0.45 - 0.52	30
TM	2	Green	0.52 - 0.60	30
TM	3	Red	0.63 - 0.69	30
TM	4	NIR	0.76 - 0.90	30
TM	5	SWIR 1	1.55 - 1.75	30
TM	6	Thermal	10.40 - 12.50	120
TM	7	SWIR 2	2.08 - 2.35	30

Fonte: Adaptado de USGS, 2011.

Tabela 4. Características das bandas Landsat 8.

Sensor	Band number	Band name	Wavelength(μm)	Resolution (m)
OLI	1	Coastal	0.43 - 0.45	30
OLI	2	Blue	0.45 - 0.51	30
OLI	3	Green	0.53 - 0.59	30
OLI	4	Red	0.63 - 0.67	30
OLI	5	NIR	0.85 - 0.88	30
OLI	6	SWIR 1	1.57 - 1.65	30
OLI	7	SWIR 2	2.11 - 2.29	30
OLI	8	Pan	0.50 - 0.68	15
OLI	9	Cirrus	1.36 - 1.38	30
TIRS	10	TIRS 1	10.60 - 11.19	30 (100)
TIRS	11	TIRS 2	11.50 - 12.51	30 (100)

Fonte: Adaptado de USGS, 2018 e Landsat 8 User Handbook, 2016.

1.4.2.2 Índice de Vegetação por Diferença Normalizada

De maneira geral, os índices de vegetação possuem a função de realçar o comportamento espectral da vegetação dependendo de aspectos biofísicos como

Índice de Área Foliar (IAF), biomassa, uso e cobertura da terra, nitrogênio, atividade fotossintética, entre outros fatores. Assim, tais índices são basicamente utilizados para dois objetivos: caracterizar a presença de vegetação fotossinteticamente ativa e determinar a distribuição temporal e espacial da vegetação associada aos ciclos fenológicos anuais e condições do clima (EPIPHANIO *et al.*, 1996; PONZONI; SHIMABUKURO, 2010).

A utilização dos índices de vegetação com dados derivados das imagens de satélite caracteriza uma ferramenta de análise ambiental altamente eficiente devido à capacidade de inferir sobre as modificações ocorrentes na paisagem e na dinâmica da vegetação. Frente a grande quantidade de dados sobre a natureza da superfície da Terra coletados por Sensoriamento Remoto (SR) nas diferentes resoluções espaciais, espectrais e temporais, abre-se a possibilidade de para a combinação de bandas e assim o desempenho da extração de informações acerca da vegetação e suas mudanças nas últimas décadas (HILKER *et al.*, 2015; MARSTON *et al.*, 2017; ZHAO *et al.*, 2019).

Como definição, os índices de vegetação são obtidos a partir da combinação aritmética de duas ou mais bandas relacionadas de acordo com as características espectrais da cobertura vegetal (MATSUSHITA *et al.*, 2007). A relação é dada a partir da densidade da cobertura vegetal em certa área, ou seja, quanto maior a densidade menor a reflectância na faixa do visível (de 0,4 a 0,5 µm). Essa relação está associada à absorção da radiação solar pela ação de pigmentos fotossintetizantes encontrados nas folhas das plantas. Enquanto que na faixa do NIR (0,7 a 1,1 µm) é observada maior reflectância em função do espalhamento múltiplo da radiação causado pelas diferentes camadas das folhas (PONZONI; SHIMABUKURO, 2010).

Desenvolvido por Rouse *et al.* (1973) o Índice de Vegetação por Diferença Normalizada (NDVI) é frequentemente utilizado em diversos estudos devido a sua facilidade de cálculo e por fornecer boas informações sobre os alvos, principalmente para verificar mudanças na vegetação de determinada área ao longo do tempo (WEN *et al.*, 2016; ROKNI; MUSA, 2019; BAEZA; PARUELO, 2020) e relação com variáveis climáticas (LIU *et al.*, 2011; PENG *et al.*, 2011; LU *et al.*, 2018; YUAN *et al.*, 2019) . De acordo com JENSEN (2009) o NDVI é dado por:

$$NDVI = \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}} \quad (1)$$

com ρ_{nir} sendo a reflectância no infravermelho próximo e ρ_{red} a reflectância no vermelho.

Conforme Rouse et al. (1973) o cálculo do NDVI normaliza a razão simples para o intervalo de -1 a +1, sendo que as áreas com vegetação intensa (alto teor de verdor) alcançam valores próximos de +1. Embora os valores de NDVI possam variar conforme o intervalo acima mencionado, a presença de vegetação é apontada por valores positivos. De acordo com Silva et al. (2007) o limite superior aproxima-se de 0,8 mediado por uma vegetação mais vigorosa. Ademais, valores negativos de NDVI estão associados a alta reflexão na região do vermelho e valores próximos de zero refletem os dois comprimentos de onda em intensidade semelhante, resultado da ocorrência de solos descobertos e rochas expostas (JENSEN, 2009).

1.4.2.3 Dados do Infravermelho Termal

Uma vez que o registro de alvos terrestres por sistemas sensores passivos é impossibilitado nas faixas de comprimentos de onda onde ocorrem as bandas de absorção, na região do infravermelho termal (*Thermal Infrared- TIR*) do espectro eletromagnético ocorrem duas faixas de comprimento de onda onde os efeitos da atmosfera apresentam menor intensidade (atmosfera mais transparente), determinadas pelos intervalos de 3 a 5 μm e 8 a 14 μm . O primeiro intervalo é utilizado para o monitoramento de alvos quentes (principalmente de atividades geoteras e queimadas) enquanto o segundo caracteriza a utilização para estudos de rochas, atributos do solo e vegetação (JENSEN, 2009).

Em sua totalidade, corpos que apresentam temperatura superiores a zero absoluto (0 k ou -273,15°C) emitem radiação. Esta é resultado da mudança de estado de energia das partículas da matéria derivado do movimento aleatório das moléculas (calor cinético) (LI et al., 2013). Se a superfície terrestre fosse um corpo negro (ou corpo ideal, que reemite toda radiação absorvida por ele), a uma temperatura constante e sem a intervenção da atmosfera, a radiância (que neste caso é igual à

emitância) medida no sensor seria dada pela função de Planck (PLANCK, 1914) (Equação 2), ou na sua forma simplificada (Equação 3):

$$B(\lambda, T) = \frac{2\pi hc^2}{\lambda^5} \frac{1}{\left(e^{\frac{hc}{\lambda kT}} - 1\right)} \quad (2)$$

$$B(\lambda, T) = \frac{C_1}{\lambda^5 \pi \left(e^{\frac{C_2}{\lambda T}} - 1\right)} \left(\text{W/m}^2 \text{ sr } \mu\text{m} \right) \quad (3)$$

em que $B\lambda(T)$ é a radiância espectral em $\text{W m}^{-2} \mu\text{m}^{-1} \text{sr}^{-1}$ de um corpo negro a uma temperatura T em Kelvin (K) e λ (μm), C_1 e C_2 são constantes físicas ($C_1 = 1,191 \times 10^8 \text{ W } \mu\text{m}^4 \text{ sr}^{-1} \text{ m}^{-2}$, $C_2 = 1,439 \times 10^4 \mu\text{m} \cdot \text{K}$).

Entretanto, os objetos naturais não apresentam comportamento como dos corpos negros, ou seja, parte da energia incidente é dissipada de outras formas, necessita-se saber a capacidade de um material transformar a energia que incide sobre ele em radiação térmica. Esta medida é chamada de emissividade espectral (ε) (Equação 4), definida como a razão entre a radiância espectral, $R_\lambda(T_s)$, de um objeto e a de um corpo negro, $B_\lambda(T_s)$, à mesma temperatura (T_s) (BECKER; LI, 1990). O conjunto de emissividades espetrais de um alvo forma o espectro de emissividade, ao longo dos comprimentos de onda do TIR, sendo único para cada objeto, o que possibilita diferenciar alvos desde que este espectro seja adquirido de forma confiável (LI *et al.*, 2013; TANG; LI, 2014).

$$\varepsilon_{\lambda,T} = \frac{L(\lambda, T)}{B(\lambda, T)} \quad (4)$$

Partindo desse pressuposto, para qualquer material real, a radiância que atinge o sensor (Equação 5) é equivalente a radiância de corpo negro, sob mesma temperatura e comprimento de onda, ponderada pela emissividade espectral.

$$L(\lambda, T) = \varepsilon_{\lambda,T} B(\lambda, T) \quad (5)$$

Assim a radiância espectral no sensor pode ser escrita como:

$$L(\lambda, T) = \varepsilon_{\lambda,T} \frac{C_1}{\lambda^5 \pi \left(e^{\frac{C_2}{\lambda T}} - 1\right)} \quad (6)$$

em que $L(\lambda, T)$ é a radiância do corpo real medida no sensor e $B(\lambda, T)$ é a radiância de corpo negro, ambos na temperatura T e comprimento de onda λ .

Uma das principais dificuldades encontradas ao se trabalhar com imagens do infravermelho termal consiste em se obter medidas precisas para a temperatura e a emissividade do alvo, já que a relação entre a temperatura e a radiância do alvo não é linear (Equação 6). Essas não uniformidades contribuem para multiplicar os efeitos emissivos devido à influência de constituintes atmosféricos (DASH *et al.*, 2002; TANG; LI, 2014). Quando a contribuição da atmosfera não pode ser desprezada, a quantidade de radiação medida que chega ao sensor é dada por:

$$L_{sensor,\lambda} = [\varepsilon_\lambda B_\lambda(T_s) + (1 - \varepsilon_\lambda)L_{atm,\lambda}^\downarrow]\tau_\lambda + L_{atm,\lambda}^\uparrow \quad (7)$$

em que L_{sensor} é a radiância de topo da atmosfera (TOA) medida pelo sensor, $B_\lambda(T_s)$ é a radiância do corpo negro dada pela lei de Planck e T_s é a LST, L_{atm}^\downarrow é a radiância atmosférica descendente, τ é a transmitância atmosférica total entre a superfície e o sensor, L_{atm}^\uparrow é a radiância atmosférica ascendente. Os parâmetros L_{atm}^\downarrow , τ e L_{atm}^\uparrow podem ser calculados por meio de dados de radiossondagem *in-situ*. Desta maneira, a LST é encontrada (Equação 7) por meio da inversão da lei de Planck (Equação 6).

1.4.2.3.1 Separação de Temperatura e Emissividade

Diversos métodos de separação de temperatura e emissividade foram desenvolvidos nas últimas décadas e muitos outros estão atualmente em estudo; uma revisão detalhada destes métodos pode ser encontrada em Li *et al.*, (2013) e também em Rolim *et al.*, (2016). Todos os métodos tem o objetivo de separar informações de temperatura e emissividade.

Na atualidade, dentre os diferentes algoritmos utilizados para recuperação da LST a partir de dados obtidos por sensores orbitais na região do TIR: (1) algoritmos de canal único ou *single-channel* (SC) (QIN *et al.*, 2001; JIMÉNEZ-MUÑOZ e SOBRINO, 2003), (2) algoritmos multicanais ou *split-window* (SW) (BECKER; LI, 1990; COLL; CASELLES, 1997) e métodos de separação de temperatura e

emissividade (TES) (GILLESPIE *et al.*, 1998; ISLAM *et al.*, 2017). Um enfoque maior será dado ao método *single-channel* devido a sua utilização para recuperação da LST na presente tese.

Os métodos *single-channel* caracterizam a única maneira de recuperar a LST a partir de sensores orbitais que compõem apenas uma banda na região do TIR. É caso da série Landsat 4 e 5 (sensor *Thematic Mapper*- TM) e Landsat 7 (*Thematic Mapper Plus*- ETM+). Deste modo, três métodos SC foram propostos em estudos prévios: método da equação de transferência radiativa (RTE), o método SC de Qin (QIN *et al.*, 2001) e método de SC de Jiménez-Muñoz e Sobrino (JIMÉNEZ-MUÑOZ; SOBRINO, 2003).

Para recuperação de LST, os métodos *single-channel* aplicam a inversão da RTE (Equação 6) sobre uma única banda e corrigem os efeitos atmosféricos. Tais efeitos são calculados a partir de um código de transferência radiativa, cuja entrada corresponde a perfis atmosféricos, geralmente obtidos por radiossondagens e a saída são os parâmetros de radiância downwelling ($L\downarrow$), radiância upwelling ($L\uparrow$) e transmitância atmosférica (τ). Porém, a limitação deste método está submetida ao conhecimento prévio da Emissividade da Superfície Terrestre (LSE) (LI *et al.*, 2013).

A primeira e maior limitação dos métodos de separação de LST e LSE está associada a uma incógnita matemática (HOOK *et al.*, 1992; KEALY; HOOK, 1993). A RTE descrita na Equação 6 mostra que, se a radiância medida em N canais, sempre haverá N + 1 incógnitas, já que são obtidas N emissividades em cada canal e um LST desconhecido. Tal problema torna a solução dos conjuntos de RTE sub-determinada ao nível de superfície, independente da precisão em que as quantidades atmosféricas são obtidas. A melhor solução encontrada aponta para o estabelecimento prévio da LSE ou a obtenção simultânea de LST e LSE com base em suposições ou restrições sobre as LSEs (HOOK *et al.*, 1992; KEALY; HOOK, 1993; GILLESPIE *et al.*, 1996; DASH *et al.*, 2002).

A maneira alternativa encontrada para estimar a LSE a partir de imagens orbitais, leva em consideração os valores de NDVI obtidos por pixel (VAN DE GRIEND; OWE, 1993; VALOR; CASELLES, 1996). Sobrino e Raissouni (2000) introduziram o método do NDVI Threshold (NDVI^{THM}) e aplicaram a dados Advanced Very High Resolution Radiometer (AVHRR) em uma área de estudo localizada em Marrocos. A aplicação do método a dados Landsat 5 TM foi feita por Sobrino et al.

(2004), aplicadas em uma área localizada em Valência- Espanha, cujos resultados foram comparados com medidas *in-situ* usando o *Box-Method*. O *Root-Mean-Square Deviation* (RMSE) obtido foi inferior a 0,01. Zhang *et al.*, (2006) posteriormente seguido por Grondona *et al.*, (2013) atrelaram valores emissividade da superfície para intervalos específicos de NDVI, conforme exposto na Tabela 5. Ademais, os autores pressupõem a aquisição de dados atmosféricos especialmente durante o horário de passagem do satélite para obter valores mais precisos de LST.

Tabela 5. Relação entre o Índice de Vegetação por Diferença Normalizada e a Emissividade.

NDVI	Emissividade (ϵ)
NDVI < -0.185	0.995
-0.185 ≤ NDVI < 0.157	0.970
0.157 ≤ NDVI ≤ 0.727	$1.0094 + 0.047\ln(\text{NDVI})$
NDVI > 0.727	0.990

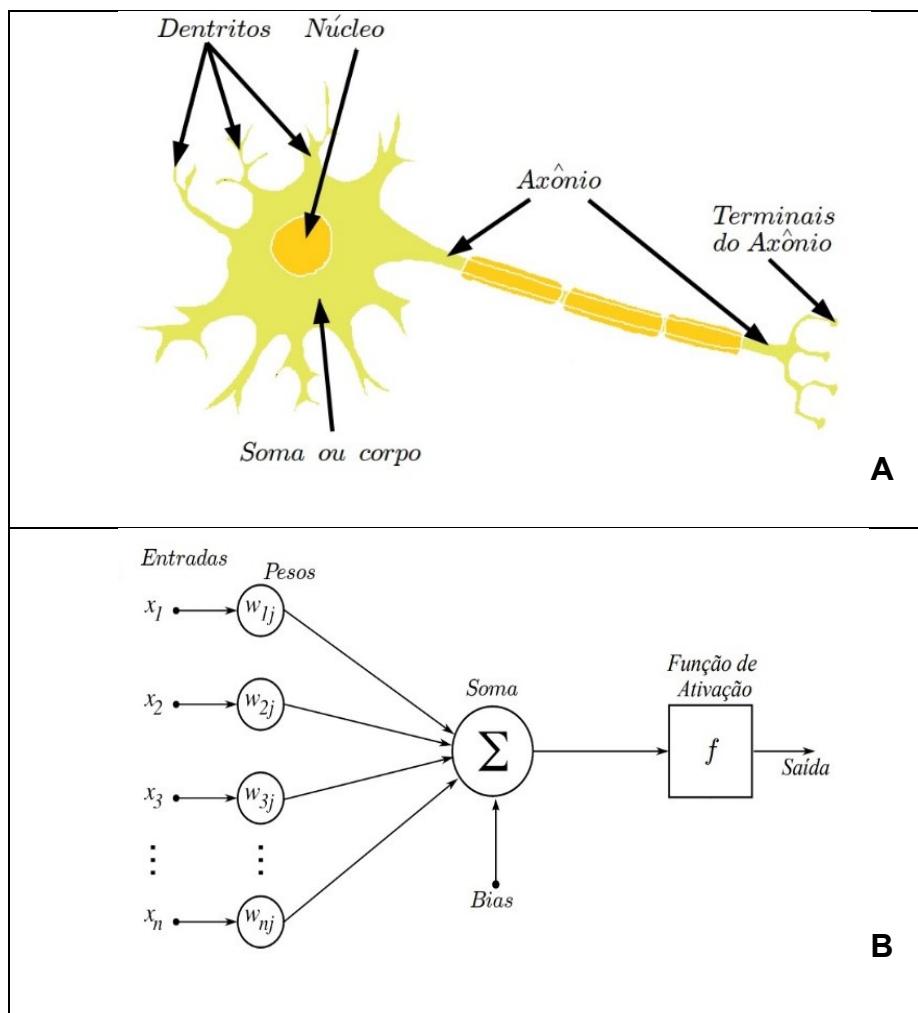
Fonte: Adaptado de Zhang *et. al.*, 2006.

1.4.3 Previsão de séries temporais a partir de Redes Neurais Artificiais

McCulloch e Pitts (1943) realizaram a primeira representação matemática do funcionamento dos neurônios biológicos. A arquitetura de uma rede neural artificial associa-se basicamente a um neurônio biológico. A Figura 3A apresenta a composição de um neurônio biológico, expresso pelos dendritos (entradas de informações oriundas de outros neurônios), núcleo, corpo do neurônio (armazenamento de informações), axônio (transporte e alteração de informações) e terminais do axônio (saídas da unidade neural). Deste modo, o modelo análogo artificial referente a este neurônio é ilustrado pela Figura 3B. O comportamento do corpo celular é determinado por um mecanismo que realiza a soma ponderada dos valores recebidos (cálculo do net). No modelo simples, tal soma é comparada com um limiar θ . Neste modelo, a função de ativação que relaciona a resposta do neurônio com a soma ponderada dos valores recebidos é uma função degrau: se $x_1w_1 + x_2w_2$

$+ \dots + x_N w_N \geq \theta$ o neurônio é ativado e produz uma saída igual a 1, caso contrário o neurônio não dispara e a saída é zero. Deste modo, o corpo celular realiza o mapeamento dos sinais de entrada em um único sinal de saída.

Figura 3. A) Esquema de um neurônio biológico e; B) Esquema de um neurônio artificial a partir de um neurônio biológico.



Fonte: Adaptado de Oliveira, 2008.

Rosenblatt (1958) propôs a primeira rede neural aplicável a problemas práticos e inspirada na retina do olho humano. Sua estrutura era composta por uma camada e denominada *Perceptron*. Neste, a função de ativação é a função limiar com entradas e saídas binárias, ou seja, as representações compõem valores de 0 e 1. Cabe ressaltar que esta foi a primeira rede neural com um algoritmo de treinamento deduzido por álgebra vetorial.

Na sequência, Widrow e Hoff (1960), propuseram a regra delta (Equação 8), um método de treinamento aplicado em redes *Perceptron*. Foi somente a partir desta regra que problemas mais complexos poderiam ser resolvidos, já que tratava as saídas nos domínios dos números reais, funções de ativação contínuas, lineares e não lineares. O principal objetivo desta era diminuir o valor da função de erro e para isso baseava-se no treinamento do gradiente descendente buscando pesos sinápticos ótimos.

$$W_{k+1} = W_k + (\tau \cdot e_k \cdot \delta_k \cdot P_k) \quad (8)$$

Em que: W são os pesos sinápticos; τ é a taxa de aprendizado; e_k são os erros das saídas; P_k é a entrada na própria camada e δ_k é a derivada das funções de ativação.

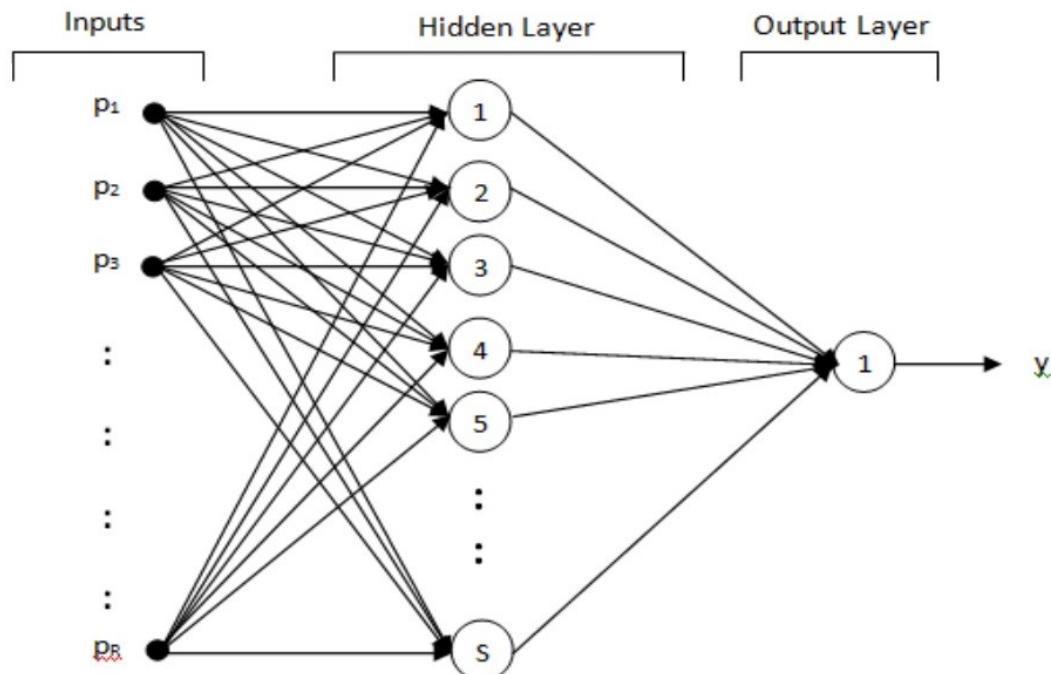
Entretanto o modelo *Perceptron* apresentava limitações no que se refere a capacidade de detecção de paridade, conectividade e simetria, ou seja, quando os problemas são não-linearmente separáveis (MINSKY; PAPERT, 1969). No intuito de atender essa limitação, Rumelhart, Hinton e Willian (1986) propuseram um treinamento de Perceptron com mais de uma camada, denominada *Perceptron* de Multicamadas (do inglês *Multilayer Perceptron*- MLP), que generalizava a regra delta mediante o cálculo dos erros gerados pela camada de saída e sua retropopulação sucessiva para as camadas anteriores. Em outras palavras, o treinamento é baseado em uma regra de corrige o erro durante o próprio treinamento. Assim, o procedimento foi denominado retro propagação de erro (do inglês *Back Propagation*) e seu cálculo matemático pode ser observado na Equação 9.

$$e_h = \sum(W_s \cdot e_s \cdot \delta_s) \quad (9)$$

Em que: e_h é o erro na camada anterior; W_s são os pesos sinápticos na camada de saída; e_s são os erros na camada de saída e δ_s é a derivada da função de ativação na camada de saída.

Conforme Rumelhart, Hinton e William (1986) o funcionamento do algoritmo *backpropagation* (BP) (Figura 4) está condicionado a duas fases: a primeira denominada *forward* onde uma entrada é aplicada à rede neural e seu sinal funcional propaga-se pelas camadas até a saída, mantendo os pesos fixos e; a segunda denominada *backward* onde a saída é comparada com o alvo gerando um sinal de erro que por sua vez é novamente propagado, agora em direção a entrada. Neste retorno os pesos são ajustados com o objetivo de minimizar o erro.

Figura 4. Rede neural artificial de retropropagação *Feed forward* com as camadas de entrada (*inputs*), oculta (*hidden layer*) e saída (*output layer*).



Fonte: Adaptado de Akhand et al., 2018.

A partir de então, diferentes definições para as Redes Neurais Artificiais (RNA) foram criadas, cita-se algumas delas: Zurada (1992) define como uma notação gráfica para alguns algoritmos matemáticos ou como sendo uma réplica simplificada que emula as redes neurais biológicas encontradas em organismos vivos, ou uma interconexão de neurônios, onde as saídas de um neurônio são conectadas, por meio de pesos, com outros neurônios. Haykin (1999) define como um processador paralelo distribuído com uma vocação natural para armazenar o conhecimento experimental e disponibilizar seu uso posteriormente. Ademais o autor ressalta o funcionamento

deste associado ao cérebro humano, por dois motivos básicos: 1. A rede obtém conhecimento a partir do processo de aprendizado e; 2. As amplitudes das conexões entre os neurônios artificiais (pesos sinápticos) são usadas para armazenar o conhecimento. Para Carvalho *et al.*, (1998), as redes neurais são compostas por sistemas paralelos distribuídos e constituídos por unidades de processamento simples (neurônios) que computam determinadas funções matemáticas (geralmente não-lineares). Por conexões unidirecionais, tais neurônios são posicionados em uma ou várias camadas interligadas. Essas conexões estão associadas a pesos responsáveis por armazenar o conhecimento representado no modelo e por ponderar a entrada recebida por cada neurônio da rede.

No lugar da função degrau, a função de ativação pode assumir diferentes formas, em geralmente não-lineares, o que transformam as redes neurais em sistemas computacionais capazes de resolver problemas complexos. A função de ativação pode ser determinada por três tipos de funções: 1. Função linear (neurônios como aproximadores lineares); 2. Função Logística sigmoidal (determina os sinais de entrada dos neurônios no intervalo $[0,1]$) e; 3. Função tangente hiperbólica (determina os sinais de entrada dos neurônios no intervalo $[-1,+1]$) (HAYKIN, 2001).

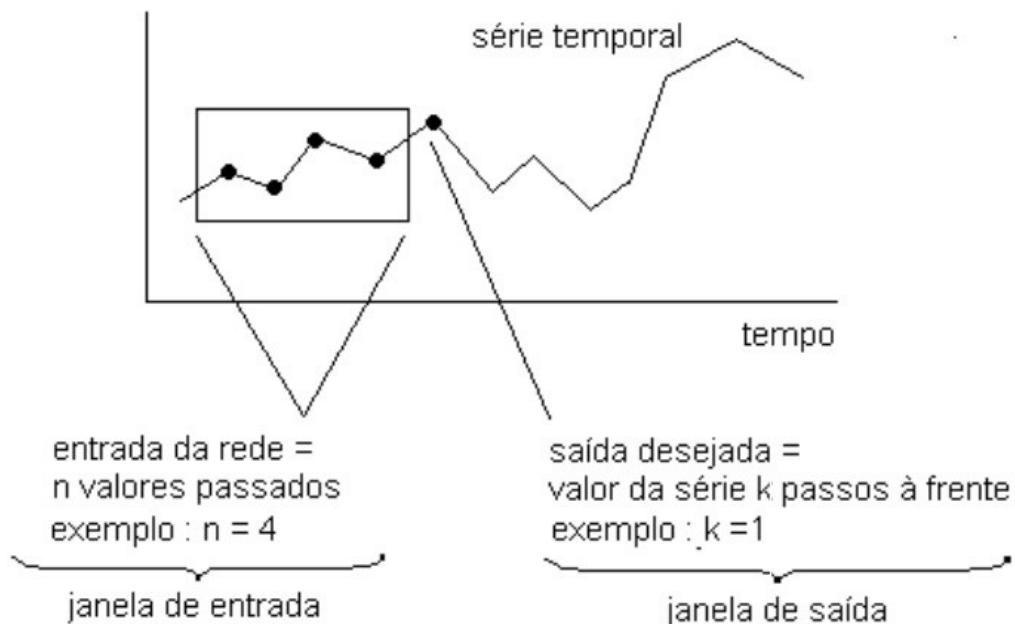
A principal característica das RNAs está associada à sua capacidade de aprendizado a partir de exemplos e generalizar a informação aprendida para solucionar um problema. Para Haykin (1999) destacam-se a capacidade de auto-organização e de processamento temporal, além de operar como mapeadores universais de funções multivariáveis, cujo custo computacional caracteriza linearidade proporcional ao número de variáveis de entrada.

Uma RNA caracteriza duas fases básicas de processamento: aprendizado e utilização. Na fase de aprendizado, os pesos entre as conexões são ajustados de acordo com a informação que foi inserida. Enquanto na fase de utilização a rede responde a entrada inserida sem ocorram modificações em sua estrutura (FLECK *et al.*, 2016). Os tipos de aprendizado podem ser supervisionados (conjunto de exemplos de entrada-saída são apresentados a rede e a partir dessa entrada, a rede realiza seu processamento e a saída obtida é comparada com a saída esperada) ou não supervisionado (um padrão de entrada fornecido permite que a rede escolha livremente o padrão de saída a partir das regras de aprendizado adotadas).

Deste modo, o emprego do retro propagação está associado ao cálculo das derivadas parciais das variáveis de saída da rede em relação aos parâmetros de ajuste ou pesos sinápticos. Diferentes métodos fazem uso desse processo, divididos em duas categorias distintas: métodos de treinamento determinísticos (gradiente, gradiente com momentum, *Quasi-Newton* e o método de Levenberg-Marquardt) e métodos de treinamento estocásticos (filtragem de Kalman na versão completa ou com processamento paralelo e recursivo).

Para desempenho da previsão de valores futuros de uma série temporal a partir de RNAs, define-se o conjunto de treinamento segundo o tamanho da janela de tempo para os valores passados de cada uma das variáveis explicativas e da própria variável que se deseja prever, bem como do horizonte de previsão. Em outras palavras, a entrada é formada pelos valores passados da própria série histórica (modelo auto-regressivo) e a saída são os valores no horizonte de previsão. A obtenção dos padrões de treinamento consiste em mover as janelas tanto de entrada como de saída ao longo da série temporal (WERBOS, 1990). A Figura 4 ilustra um exemplo de previsão a partir de quatro últimos valores passados.

Figura 5. Montagem de um conjunto de treinamento.



Uma vez que o comportamento de determinados dados são variantes no tempo ou dependentes dele, a aplicabilidades de redes neurais *Perceptron Multi Camadas*

(PMC) passa a configurar um sistema dinâmico (SILVA *et al.*, 2016). Segundo o autor, no mapeamento de problemas envolvendo sistemas dinâmicos a partir da rede PMC, a saída atual depende das saídas e entradas anteriores e do ajuste dos parâmetros internos da rede na fase de treinamento/teste.

Para o desenvolvimento de uma RNA existem diferentes arquiteturas e estratégias de aprendizado (algoritmos treinamento). Na presente tese, a abordagem está limitada a uma rede de Feed-forward (Figura 4) de múltiplas camadas treinada por um algoritmo de retro propagação de erro (*Back Propagation*). A RNA utilizada é adaptada para o software QGis versão 2.18 através do *plug-in* MOLUSCE (do inglês *modules for Land Use Change Evaluation*) (https://wiki.gis-lab.info/w/Landscape_change_analysis_with_MOLUSCE_-_methods_and_algorithms#Multilayer_perceptron). O *plug-in* usa uma rede neural Perceptron multicamadas clássicas onde os inputs são uma coleção de pixels referentes ao raster no estado inicial bem como os fatores determinantes também em formato raster, e o output corresponde ao mapa final (também em formato raster). A função sigmoide é utilizada e as variáveis de destino (as categorias do mapa de mudança) são dimensionadas para o intervalo (0, 1). O usuário pode definir um número arbitrário de camadas ocultas (uma ou mais) e um número arbitrário (um ou mais) de neurônios nas camadas. Assim, a rede criada configura-se matematicamente da seguinte forma:

- $(C-1)(2N + 1)^2 + B(2N + 1)^2$ neurônios de entrada e ;
- M neurônios de saída (dependentes do modo de amostragem).

Em que, C é a contagem de categorias (classes), N é o tamanho da vizinhança especificado pelo usuário, B é a contagem de bandas correspondentes aos rasters determinantes (fatores determinantes), M é a contagem de categorias do mapa final (C^2). Os pesos da correção na retropropagação são realizados conforme exposto na Equação 10.

$$w(n + 1) = r^* dw(n) + m^* dw(n - 1) \quad (10)$$

Em que , w é um vetor de pesos dos neurônios, dw é um vetor de peso de mudanças, n é o número de interações, r é a taxa de aprendizado e m é o *momentum*.

Além disso, o módulo Molusce utiliza aprendizagem estocástica simultânea, onde são selecionadas amostras aleatórias dos dados de treinamento e os pesos da rede são atualizados durante as fases forward e backward da propagação, conforme descrito anteriormente. O ajuste de erro (para cada amostra) é o erro quadrado médio das saídas parciais da rede (Equação 11).

$$E = \frac{t_i - o_i}{d} \quad (11)$$

Em que, E é o erro da amostra, t_i é o valor alvo do neurônio de saída de uma dada amostra, o_i é o valor de saída real do neurônio e d é a contagem dos neurônios de saída.

A partir de imagens dos sensores TM-Landsat 5 e OLI-TIRS- Landsat 8 obtidas no período de 2000 a 2016, Shatnawi e Abu Qdais (2019) utilizaram uma rede neural para realizar a previsão de LST para os anos seguintes. As entradas da rede corresponderam a valores médios de NDVI, Índice por Diferença Normalizada para Áreas Construídas (NDBI), umidade, população, evaporação, velocidade do vento, precipitação pluviométrica e temperatura do ar, no verão e inverno. A rede apresentou significativa acurácia no processo de validação, cujo coeficiente de correlação alcançou 0,91, demonstrando a capacidade de prever valores futuros de LST. Além disso, os autores previram o aumento de 1,1°C na temperatura no norte da Jordânia quando comparado o período de 2016 a 2026.

Imagens de satélite no período de 1986 a 2014 e RNAs também foram utilizadas por Maduako *et al.*, 2016 para prever valores de LST em 2028 e 2042. Os resultados apresentaram o coeficiente de correlação igual a 0,85 no processo de validação da RNA e previsão de aumento de temperatura em 10% ao longo dos períodos 2014 a 2028 e 2028 a 2042.

Em trabalho sobre o desenvolvimento de um modelo de previsão das ICUs realizado na Grécia, Gobakis *et al.*, 2011 a partir de uma rede neural do tipo *Feed-forward* encontrou valores de R^2 superiores a 0,9 entre a temperatura e radiação solar real e aquela estimada pelo modelo, o melhor desempenho deu-se pelo método determinístico gradiente como função treino. Resultados semelhantes foram

encontrados por Kolokotroni et al., (2009) em estudo sobre previsão de calor e frescor diárias frente a ocorrência de ilhas de calor urbana, cujo erro médio quadrático (MSE) e o erro relativo em % quantizaram 0,60 e 4,6%, respectivamente, para a rede *Feed-forward*, comparadas a 5,1% e 5,6% e 0,64 e 0,68, respectivamente, para as redes *Cascade-forward* e *Elman*.

Partindo desse pressuposto, Haykin (1999) destaca as limitações da arquitetura de uma RNA associado ao tipo de problema que se objetiva resolver. Geralmente redes caracterizadas por apenas uma camada de neurônios são utilizadas para solucionar problemas linearmente separáveis enquanto redes resolvem problemas que envolvem processamento temporal. Assim, para definir a arquitetura de uma RNA, inicialmente determina-se o número de camadas, número de neurônios em cada camada, tipo de conexões entre os neurônios, topologia da rede e conectividade. Cabe ressaltar a importância de se determinar tais atributos antes do processo de treinamento e visto que esse pode não atingir a significância desejada, novos pesos e diferentes arquiteturas devem ser utilizadas, já que a definição da RNA ocorre a partir do processo de tentativa e erro.

Para previsões baseadas em avaliações espaço-temporais, a utilização das RNAs com algoritmo de retropropagação de erro apresentam algumas limitações e possibilidades, conforme descrito por Nigussie, Zurita-Milla e Clevers (2011). Segundo os autores, a acurácia da RNA apresenta visível declínio com o aumento do fator de escala (tamanho das células agregadas em um raster) e o número de categorias de entrada. No estudo realizado, em casos complexos de previsão (geralmente sobre áreas de contato de classes onde ocorre alta mistura de pixels) a acurácia geral foi de ~38% enquanto em casos simples (pouca mistura) a RNA teve acurácia de ~99%.

A simulação e previsão de mudanças futuras no LULC apresentam complexidade devido a variedade de aspectos que afetam seu ecossistema e assim, são dependentes de cada área de estudo (ABURAS; AHAMAD; OMAR, 2019). Dentre eles ganham destaque os aspectos dinâmicos sociais, físicos e econômicos e de infraestrutura (ALSHARIF; PRADHAN, 2014). A dependência da área de estudo está relacionada as propriedades nela verificadas (ABURAS *et al.*, 2016). Por exemplo, a coleta de dados de inclinação do relevo se torna desnecessária para simulações do LULC em áreas planas, já que não há interferência no processo de modelagem.

RESULTADOS

2 CAPÍTULO II. SPATIOTEMPORAL INFLUENCES OF LULC CHANGES ON LAND SURFACE TEMPERATURE IN RAPID URBANIZATION AREA BY USING LANDSAT-TM AND TIRS IMAGES

Artigo publicado na revista internacional *Atmosphere* (ISSN: 2073-4433) no ano de 2022.

Referência:

Kaiser, E.A.; Rolim, S.B.A.; Grondona, A.E.B.; Hackmann, C.L.; de Marsillac Linn, R.; Käfer, P.S.; da Rocha, N.S.; Diaz, L.R. Spatiotemporal Influences of LULC Changes on Land Surface Temperature in Rapid Urbanization Area by Using Landsat-TM and TIRS Images. *Atmosphere* **2022**, *13*, 460. <https://doi.org/10.3390/atmos13030460>

Article

Spatiotemporal Influences of LULC Changes on Land Surface Temperature in Rapid Urbanization Area by Using Landsat-TM and TIRS Images

Eduardo Andre Kaiser ^{1,*†}, Silvia Beatriz Alves Rolim ^{1,†}, Atilio Efrain Bica Grondona ^{1,†}, Cristiano Lima Hackmann ^{1,†}, Rodrigo de Marsillac Linn ^{2,†}, Pâmela Suélen Käfer ^{1,†}, Nájila Souza da Rocha ^{1,†} and Lucas Ribeiro Diaz ^{1,3,†}

¹ State Research Center for Remote Sensing and Meteorology (CEPSRM), Federal University of Rio Grande do Sul (UFRGS), Porto Alegre 90040-060, RS, Brazil; silvia.rolim@ufrgs.br (S.B.A.R.); atilio.grondona@ufrgs.br (A.E.B.G.); cristiano.hackmann@ufrgs.br (C.L.H.); pamela.kafer@ufrgs.br (P.S.K.); najila.rocha@ufrgs.br (N.S.d.R.); lribeiro.diaz@vu.nl (L.R.D.)

² Coordination of Evaluation of Public Policies and Results, Prefeitura Municipal de Porto Alegre, Porto Alegre 90010-170, RS, Brazil; rodrigoml@portoalegre.rs.gov.br

³ Faculty of Science, Vrije Universiteit Amsterdam, 1081 HV Amsterdam, The Netherlands

* Correspondence: eduardo.kaiser@ufrgs.br; Tel.: +55-55-996961633

† These authors contributed equally to this work.



Citation: Kaiser, E.A.; Rolim, S.B.A.; Grondona, A.E.B.; Hackmann, C.L.; de Marsillac Linn, R.; Käfer, P.S.; da Rocha, N.S.; Diaz, L.R.

Spatiotemporal Influences of LULC Changes on Land Surface Temperature in Rapid Urbanization Area through Landsat-TM and TIRS Images. *Atmosphere* **2022**, *13*, 460. <https://doi.org/10.3390/atmos13030460>

Academic Editor: Jan-Peter Schulz

Received: 25 January 2022

Accepted: 3 March 2022

Published: 11 March 2022

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: The inverse correlation between NDVI and LST is widely known for its long time series. However, when more specific statistical tests were performed, subtle differences in the correlation behavior over time are more clearly observed. In this work, regression analyses were performed between NDVI and LST at intervals of approximately 10 years, quantifying this relationship for an area of transition from vegetation to urban occupation from 1985 to 2018. The removal of vegetation cover (reduction of 51% to 7% in grassland and 14.4% to 0.6% in forest) to occupy impermeable surfaces (increase of 31% to 91% in urban areas) caused an average LST increase of 4.18 °C when compared to the first and last decades of the historical series. Temporal analysis allowed us to verify the increase in temperature in the four seasons. The largest difference was 6.36 °C between the first and last decade of autumn, 4.40 °C in spring, 4.09 °C in summer, and 2.41 °C in winter. The results also show that LST has a negative correlation with NDVI, especially in urban areas, with an increase in this correlation during the period (1989: $R = -0.55$; 1999: $R = -0.58$; 2008: $R = -0.59$; 2018: $R = -0.76$). Our study results will help policymakers understand the dynamics of temperature increases by adding scientifically relevant information on the sustainable organization of the urban environment.

Keywords: vegetation and urban modeling; land use and land cover change; land surface processes; Porto Alegre four districts

1. Introduction

In view of the urbanization process, which has intensified since the 18th century and is mainly associated with the occurrence of the rural exodus and the industrialization process, it is possible to verify the unrestrained growth of the population and urban spots in the global scenario. According to the World Urbanization Prospects report, produced by the United Nations Division, on a global scale, the urban population has been larger than the rural population since 2007 [1]. In Brazil, according to data from the census conducted by the Brazilian Institute of Geography and Statistics (IBGE) in 2010, 84.4% (169.9 million) of the population lived in an urban area [2].

The expansion of cities severely alters the natural biophysical environment through changes in land use and land cover (LULC). The removal of vegetation covers to develop urban activities causes changes not only in the hydrological cycle but mainly in energy balance, with regard to energy storage and transfer that occurred naturally before anthropic

interference [3,4]. As a consequence, there are changes in air temperature and humidity, wind speed, and direction. In this manner, the city starts to develop its own urban climate determined by these changes, by the regional climate, and by the local physical environment, configuring a Superficial Urban Heat Island (SUHI) [5,6]. According to Zhang and Sun [7], as the main urbanization reflection, there is an increase in the Earth's surface temperature (LST) and the consequent formation of SUHI, also known as heat core, thermal or humid cores, heated core, or even as heat pockets. This increase occurs because of anthropic interferences occurring in the environment by replacing natural surface covers with materials with high heating capacity. In addition, there is a decrease in urban green areas that would be responsible for reducing LST through the evapotranspiration process [8,9].

Vegetation presence influences LST through the absorption and selective reflection of solar radiation, regulating the exchange of latent and sensitive heat [10–12]. In an urban environment, the correlation between this presence and lower temperature areas is established. Such correlations can be observed by using generalized definitions of surface greenness or by using the Normalized Difference Vegetation Index (NDVI) values detected using remote sensing techniques [13–16].

In the last decades, some studies were conducted regarding the relationship between LULC and LST variables in large cities such as Tokyo [17], Bangkok [9] and Inner Hanoi [18] and with low spatial resolution [13,15,19,20]. The impact of urbanization combined with changes in LULC and seasonal effects on LST and SUHI intensity was also verified in seven major urban districts (Barisal, Chattogram, Dhaka, Mymensingh, Rajshahi, Rangpur, and Sylhet) of Bangladesh [21] and in cities such as Raipur [22], Chittagong [23], Shiraz [24], Wuhan [25], Bengaluru [26], Calcutá [27], and Tehran [28]. Furthermore, most of these studies related variables according to specific conditions in the areas of study. However, the LST, NDVI, and LULC relationship occurs differently over time and according to land use and cover in a large metropolitan area compared to a medium-sized urban center.

The inverse correlation between NDVI and LST is widely known for long time series [22,24,29–31]. However, this approach does not always work, because some changes can occur at specific periods without being registered. This subtle anomalous behavior is enhanced and characterized in this study, by using appropriated statistical performance. Regression analyses were used in NDVI and LST data at adjusted intervals of approximately 10 years. The results allowed quantifying a different pattern between NDVI and LST for an area of transition from vegetation to urban occupation from 1985 to 2018. This unnoticed behavior can help to better understand the dynamics of temperature increases, adding scientifically relevant information on the sustainable organization of urban environments.

From the beginning of the 20th century to the present, the municipality of Porto Alegre-Rio Grande do Sul, Brazil, has experienced accelerated urban growth mainly due to the industrial and labor occupation process becoming an economic and population center at the regional level. The urban spot rapid transformation and expansion caused not only central and rural area densification but also urban conurbation phenomenon. According to Frumkin [32], this phenomenon is known as the urban sprawl and human activities diversification, demanding enormous planning and management capacity from the municipalities governments and technical staff. The city is among the ten smartest and most connected cities in Brazil (ninth position), being the 4th in entrepreneurship, 6th in technology and innovation, 13th in economy, and 15th in health. Although most large urban centers have agencies responsible for urban planning and the maintenance of public services, many lack space-time data and information that serve as a basis for decision making.

In this sense, the LST evolution diagnosis and characterization have been shown to be a potential instrument for urban space management [33]. However, the lack of detail regarding the LST and LULC spatial and temporal variation in urban environments ends up harming mitigation actions by the government. Once data on the spatial differences between the intraurban and rural temperatures are acquired, it is possible to measure and mitigate possible SUHI formation. Thus, urban planners and designers are allowed to

suggest measures to adjust LST and the associated effects of SUHI from the management of LULC composition [18]. LST, NDVI, and LULC spatio-temporal variations can be dimensioned using remote sensing techniques. Several works on the urban surfaces' thermal characterization from data obtained by a sensor can be observed in the world literature [34–39]. In Brazil, it is worth mentioning the work of [40–43]. The advent of these techniques made it possible to study SUHI, both on a local and global scale, since it allows the transformation of data in the thermal infrared spectral range for apparent surface temperature.

The objective of this work is to analyze the evolution of surface temperature between vegetated and urbanized areas, correlating 30 years of calculated data from LST and NDVI and identifying possible seasonal influences by using regression analysis. The study shows the relationship between LST and NDVI during a rapid urbanization process and how changes in land use and land cover can affect this relationship.

2. Materials and Methods

The area of this study comprises the current urban location belonging to four districts located in Porto Alegre city, Rio Grande do Sul state (Brazil: Hípica, Campo Novo, Aberta dos Morros, and Restinga), as shown in Figure 1. This spot covers an area of 534.61 hectares, with an approximate population of 120,000 inhabitants (IBGE, 2010), and is located between the coordinates $51^{\circ}15' - 51^{\circ}20'$ W and $30^{\circ}14' - 30^{\circ}18'$ S. This area was defined by considering the changes in LULC due to the rapid urbanization process that occurred between the period of 1985 and 2018. As exposed by [36,44,45], this acceleration of urban growth resulted in significant changes in LULC and is responsible for increasing density and height-built areas.

The relief of Porto Alegre is characterized by a region of contact between the Planalto Uruguaio Sul-Rio-Grandense and the Lowland and/or Terras Baixas Costeiras, in addition to the sediments from the Peripheral Depression [46]. In altimetric terms, the municipality has altitudes ranging from 0.1 m on Ilha das Flores to 311.20 at its peak, Morro Santana. The study area has altitudes ranging from 14 m in the Hípica neighborhood (far west of the study area) to 21 m in the Restinga neighborhood (far east of the study area).

In turn, Porto Alegre's climate, according to the Koeppen classification, corresponds to the subtype "Cfa", for which its mean annual temperature results in 19.5°C , an annual rainfall of 1300 mm [47], and an evapotranspiration annual mean of 937.38 mm [48].

The methodological procedures took place in five stages: 1. Definition of the study area; 2. LULC classification based on images from the Landsat 5 satellite TM sensor and the Landsat 8 satellite OLI sensor; 3. Calculation of LST from the TM sensor band 6 and the OLI sensor band 10; 4. LST temporal and spatial evolution analysis over the historical series; and 5. Spatio-temporal relationship between LST and LULC classes. The flowchart in Figure 2 shows each of the steps performed to construct the present study.

The choice of the period from 1985 to 2018 is based on two reasons: 1. The history of the study area districts is associated with the appropriation of space from the creation of popular subdivisions and industrial parks. The Hípica district, which covers most of the study area, was officially created in 1991, the Restinga neighborhood (eastern region of the study area) was created in 1990, and the Campo Novo district was created in 2011. All of these areas have two characteristics in common: accelerated urban growth and consequent loss of the previously predominant rural landscape. Thus, they coincide with the history of the districts and the period used in the present study, and 2. the ideal period of a climate modeling study should cover series with at least 30 years of data. Faced with the difficulties associated with the availability of images with clear sky conditions, a longer time series allows the acquisition of a greater number of images in order to mainly cover seasonal variations of LST, NDVI, and LULC.

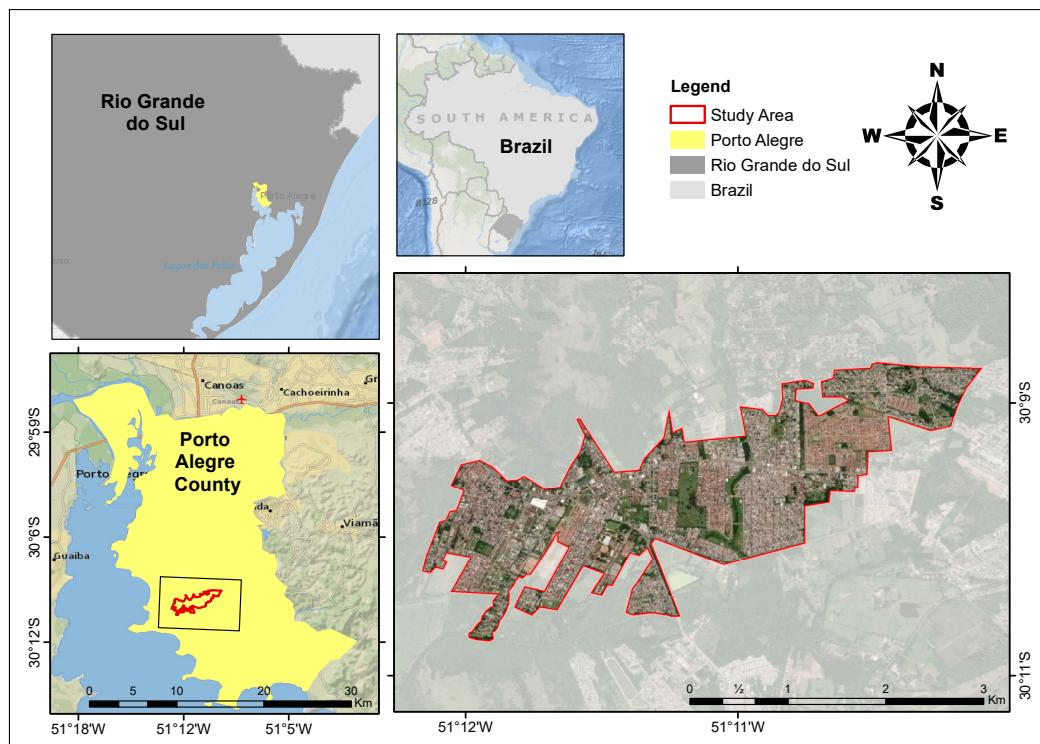


Figure 1. Location map of the urban spot of Hípica, Campo Novo, Aberta dos Morros, and Restinga neighborhoods in the municipality of Porto Alegre, Rio Grande do Sul, Brazil.

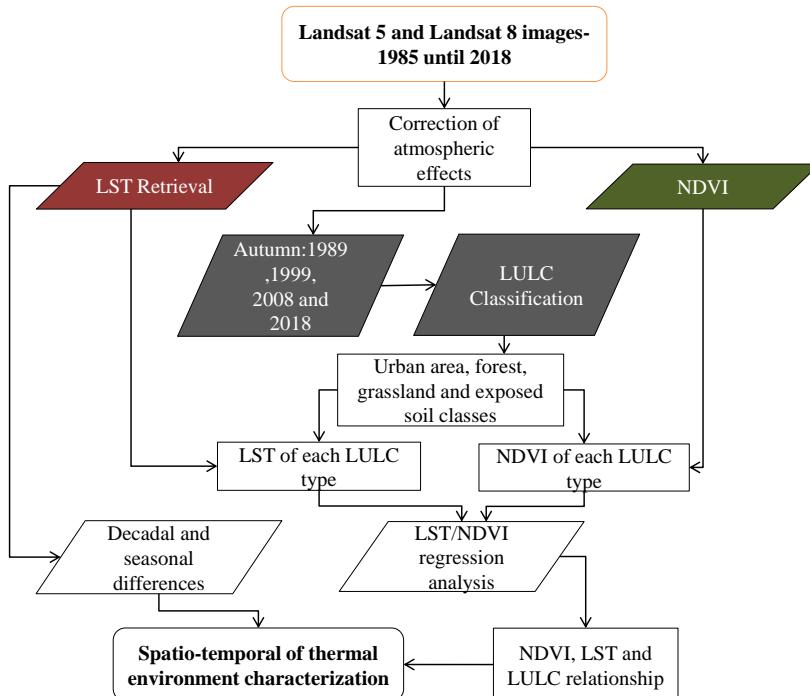


Figure 2. Flowchart of the methodological procedures used in the present study.

NDVI and thermal infrared images from the Landsat8 satellite Operational Terra Imager (OLI) and Thermal Infrared Sensor (TIRS) sensors were used to extract information about LULC and LST, respectively. The specific objectives are as follows: (1) derive LST from Landsat 5 and 8 satellites Thematic Mapper (TM) and TIRS sensors from 1985 to 2018;

(2) examine the LULC and LST spatial pattern and temporal variation for the same period; and (3) investigate the relationship between LST and LULC from NDVI.

Images from the TM- Landsat 5 sensor (30 m) and the OLI- Landsat 8 sensor (30 m) referring to four dates of the 34-year historical series studied in the present work were used to perform LULC classification: 29 September 1989, 25 October 1999, 3 October 2008, and 16 November 2018. The definition of dates took into account the approximate interval of 10 years, availability of images without the presence of clouds, and the associated seasonality; in this case, it is the spring season. The classification supervised by Maximum Likelihood was carried out [49]. Such a classifier qualifies as one of the most commonly used parametric algorithms for image classification, mainly due to its robustness [49–51]. The LULC classes used comprised those that are visually verified on the study area, which are named as follows: Forest, Urban Area, Grassland, and Exposed Soil.

Currently, different algorithms are used to retrieve LST from data obtained by orbital sensors, highlighting the mono-window algorithm [52], single-channel algorithm [53], radiation conduction equation [54], and split window algorithm [55]. The calculation of the surface temperature (LST) was performed as described by [56] using a single-channel algorithm. According to the authors, the first step consists in converting the digital number (DN) of each pixel in the image into spectral radiance and converting it to brightness temperature using the Planck function.

Since Landsat 8 and 5 satellites TIRS and TM sensors bands 10 and 6, respectively, have similar spectral ranges, several studies have carried out the use of these bands to retrieve LST [53,57–59] against TIRS sensor band 11 contamination by thermal energy outside the normal field of view (stray light effect) [60], which is also corroborated the results of indirect calibration [61].

Following the procedures, the present study retrieved superficial emissivity from NDVI (Equation (1)) [62] for the 117 images obtained:

$$\text{NDVI} = \frac{\rho_{\text{nir}} - \rho_{\text{red}}}{\rho_{\text{nir}} + \rho_{\text{red}}} \quad (1)$$

where NDVI is the Normalized Difference Vegetation Index, *nir* is the Near Infrared region, and *red* is the Red region. After obtaining NDVI values for each pixel, emissivity was estimated from the four cases shown in Table 1.

Table 1. Relationship between the Normalized Difference Vegetation Index and the Emissivity proposed by [62].

NDVI	Land Surface Emissivity (ϵ_i)
$\text{NDVI} < -0.185$	0.995
$-0.185 \leq \text{NDVI} < 0.157$	0.970
$0.157 \leq \text{NDVI} \leq 0.727$	$1.0094 + 0.047\ln(\text{NDVI})$
$\text{NDVI} > 0.727$	0.990

LST retrieval presents some complexity due to the surface not having characteristics similar to a blackbody in terms of thermal emission capacity. Moreover, the atmosphere and soil effects must be considered [63,64]. Therefore, to retrieve LST, Radiative Transfer Equation (RTE) inversion (Equation (2)) is applied to a given sensor channel and wavelength range:

$$L(\text{sensor}, \lambda) = [\epsilon_\lambda B_\lambda(T_s) + (1 - \epsilon_\lambda)L_{\text{atm}, \lambda}^\downarrow]\tau_\lambda + L_{\text{atm}, \lambda}^\uparrow \quad (2)$$

where L_{sensor} is the radiance measured by the sensor in $\text{W/m}^{-2} \text{m}^{-1} \text{sr}^{-1}$, ϵ_λ is the land surface emissivity (LSE), $B_\lambda(T_s)$ is the Planck's function given by Equation (3), L^\downarrow is the

descending atmospheric radiation in $W/m^{-2} m^{-1} sr^{-1}$, L^{\downarrow} is the ascending atmospheric radiation in $W/m^{-2} m^{-1} sr^{-1}$, and T is the atmospheric transmittance:

$$B_{\lambda}(T_s) = \frac{C1\lambda^{-5}}{(exp(C2/\lambda T) - 1)} \quad (3)$$

where $C1$ and $C2$ are Planck radiation constants, with values of (each type of sensor has a value).

The parameters include the following: Descending and ascending atmospheric radiation and transmittance used in Equation (2) can be accessed through a website of the National Aeronautics and Space Administration (NASA, Washington, DC, USA) (<http://atmcorr.gsfc.nasa.gov>, accessed on 15 August 2021), where image information (such as sensor passing time, latitude and longitude, and season) is inserted to calculate these parameters. These parameters are available on the website from the year 2000, between 1985 and 1999, and the values of $L^{\downarrow}, L^{\uparrow}$, and T generated by Moderate Spectral Resolution Atmospheric Transmittance Algorithm and Computer Model (MODTRAN) 4.0 v3r1 version 1.2 were used.

Since the relationship between vegetation areas and urban temperatures varies across space [65,66], for a comprehensive view of the impact caused by rapid urbanization on the LST, the LST means were calculated for each land use and land cover class, obeying the area covered by it on the different dates. Subsequently, simple linear regressions at pixel level were established between the classes of LULC (represented by NDVI values) and LST. This relationship took into account the LULC images (obtained on 29 September 1989, 25 October 1999, 3 October 2008, and 16 November 2018) and corresponding LST.

In order to verify the surface temperature evolution over the historical series, the data were divided by season. Thus, under similar seasonal conditions, the data were grouped and compared using descriptive statistical analysis performed for the variables mean and standard deviation. From the surface temperatures obtained in each of the 117 images, the variables per year and respective season were calculated. It is noteworthy that there was an absence of images in some seasons, mainly due to the presence of cloudiness and/or technical failure in data collection by the sensor.

3. Results

The main changes in LULC during the analyzed period can be observed in the area occupied by the urban spot (Figure 3). Table 2 shows the LST and area values for each class by year of study. In 1989 the total area corresponding to urban settlements was approximately 165 hectares, that is, approximately 31% of the study area, increasing to 91% in 2018 (486.54 hectares). It is worth mentioning that the most expressive variations of this class in the period from 2008 to 2018, where its cover increased by 25.4%, compared to the 21.5% were verified between 1999 and 2008 and 13.1% between 1989 and 1999.

An adverse situation can be observed on the LULC evolution in areas classified as forest and grassland. In 1989, the areas with forest cover occupied 14.44% of the area, and in 2018, they changed to only 0.6% just as the grassland areas decreased from approximately 51% to 7.8% in the same period. This result was probably associated with the expansion process of the urban area, which, as shown in Figure 3, occurs over areas previously covered by native forest, areas in reforestation, and grassland.

The areas represented by the exposed soil class showed an oscillation in their occupation between the years 1989 and 2018. In 1989, these covered an approximate area of 19 ha, changing to 2.67 ha in 2018, that is, a decrease from 3.6% to 0.5% of the total area. However, between 1999 and 2008, there was an increase from 0.2% to 8.9%, which was probably associated with the increase in the areas of soil preparation for planting temporary crops since not all areas were urbanized and/or soil exposure due to the occurrence of deforestation since the forest areas had the greatest reduction in this period among the analyzed intervals (reduction from 13.3% to 5.6% of the total area).

In turn, the LST mean values (Table 2) obtained in each of the LULC classes, for the four years covered, were ranked as follows: Exposed Soil > Urban area > Grassland > Forest. The covers classified as Exposed Soil and Urban area qualified for intense human activity and obtained LST mean values superior to the Grassland and Forest covers. In the four classified images (Figure 4), minimum and maximum LST mean differences of 3.7 °C in 1989 and 4.5 °C in 2008 were observed between covers classified as forest and urban area. An even greater difference can be observed between the exposed soil and forest classes, in which the smallest difference reached 3.6 °C in 2008 and 5.6 °C in 2018. Therefore, measures for planning the land use and cover and cooling the surface should consider the implementation of green areas in environments where civil construction and soil exposure predominate.

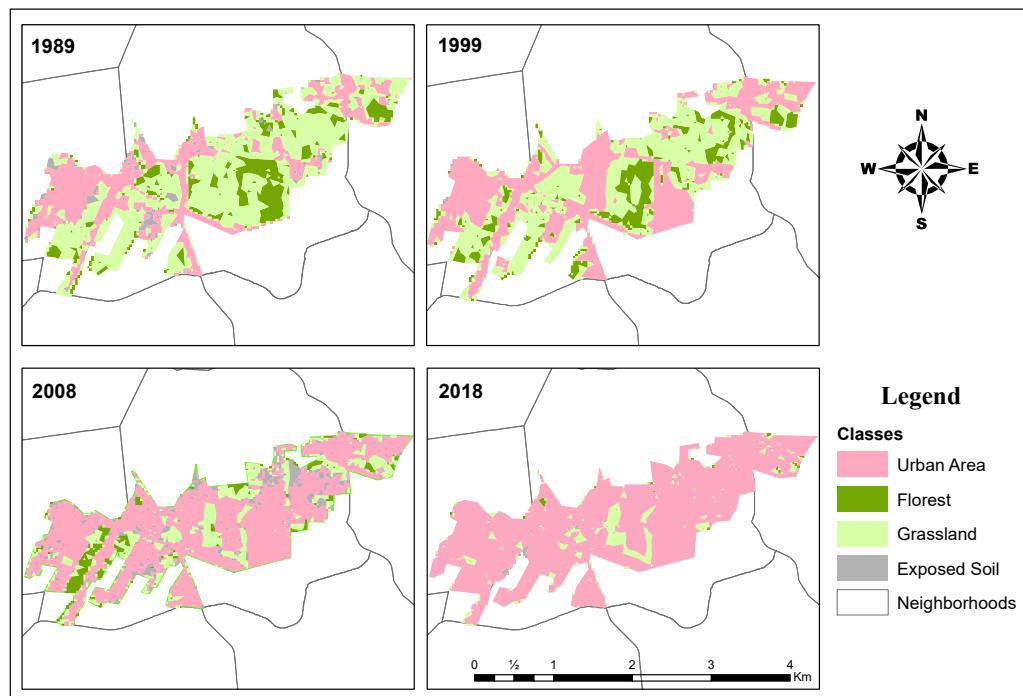


Figure 3. LULC maps of 1989, 1999, 2008, and 2018 of the study area.

Table 2. LST (°C) and area (%) means obtained in the 1989, 1999, 2008, and 2018 images from the LULC types.

Years	Urban Area	Grassland	Forest	Exposed Soil
	LST (°C)/Area (%)	LST (°C)/Area (%)	LST (°C)/Area (%)	LST (°C)/Area (%)
1989	22.5/31.0	20.8/51.0	18.9/14.4	22.6/03.6
1999	30.9/44.1	28.3/42.4	26.7/13.3	31.5/00.2
2008	29.2/65.6	26.9/19.9	24.7/05.6	28.3/08.9
2018	36.5/91.0	33.9/07.8	32.5/00.6	38.1/00.5

LST mean values obtained in areas classified as exposed soil qualified the most heated surfaces in the years 1989, 1999, and 2018 (Table 2). This result is attributed to the high thermal amplitude in short periods seen in this type of LULC, which favors the sudden increase in temperature in the face of prolonged exposure to sunlight. Thus, as a consequence, there is an intensification of the heat irradiation process for the environment, mainly on a local scale.

The annual graphic behavior of the average LST values of each LULC type associated with area variations, as well as the average decennial values presented in Table 2, pointed

to the temperature growth in all classes, as shown in the graphs in Figure 5. The annual correlation between LST values and areas of each LULC class resulted in $R = 0.36$ for urbanized surfaces, $R = -0.34$ for grassland covers, $R = -0.22$ for forest areas, and 0.21 for exposed soil surfaces. However, seasonally, there were better correlations between the variables for the Urban Area and Grassland classes ($R = 0.49$ and $R = -0.50$, respectively) in the autumn season and Exposed Soil ($R = 0.51$) in the summer, as shown in Table 3. It is associated with high annual amplitudes in the areas of Forest and Exposed Soil classes, probably associated with silviculture and soil management practices for planting annual crops, respectively.

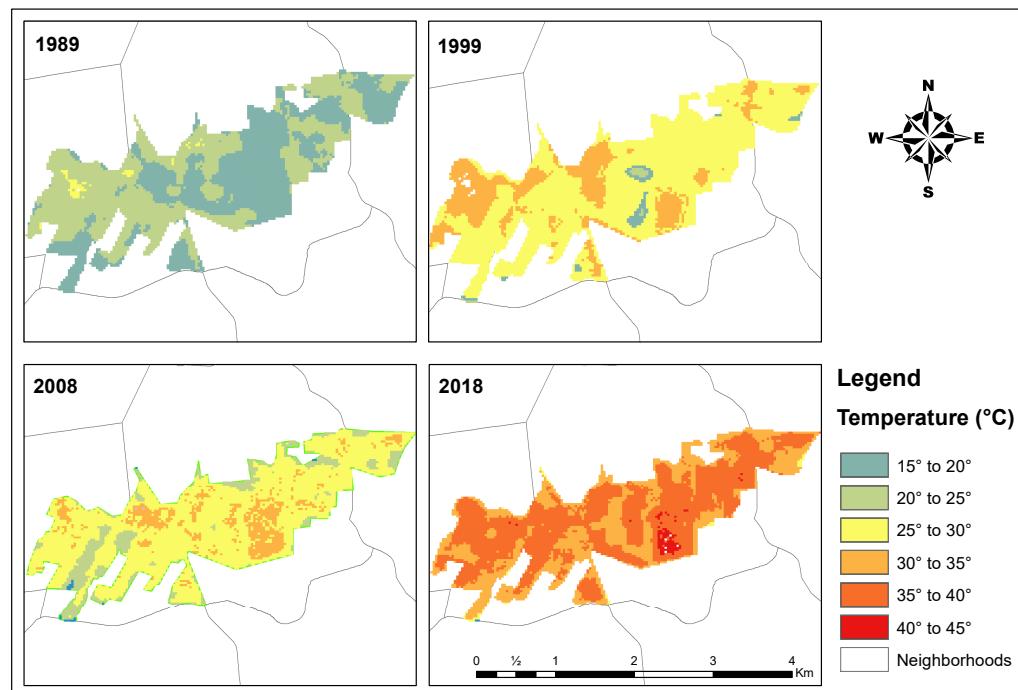


Figure 4. LST maps for September 1989, October 1999, October 2008, and November 2018.

The seasonal analysis of the time series shown in Figure 6 allows verifying the increase in LST of the study area in all seasons. This result is justified by the increasing average values obtained over the decennial intervals classified in Table 4. The greater amplitude between the average values of the first and last decade was verified in the autumn season. In this season, the difference between the mean temperatures verified between the first (mean of $20.20\text{ }^{\circ}\text{C}$) and the last decade (mean of $26.56\text{ }^{\circ}\text{C}$) of the analyzed period was $6.36\text{ }^{\circ}\text{C}$. Between the same periods, this difference was $4.09\text{ }^{\circ}\text{C}$ in summer, $4.40\text{ }^{\circ}\text{C}$ in spring, and $2.41\text{ }^{\circ}\text{C}$ in winter. Probably, this difference observed in the autumn is associated with the amplitude of the LST values verified over the years, since the standard deviation resulted in the highest value among the other seasons, reaching $7.75\text{ }^{\circ}\text{C}$. It is worth mentioning the high amplitude of these average annual values (Figure 6) due to the low availability and even the absence of orbital images with good atmospheric conditions in some intervals of the historical series.

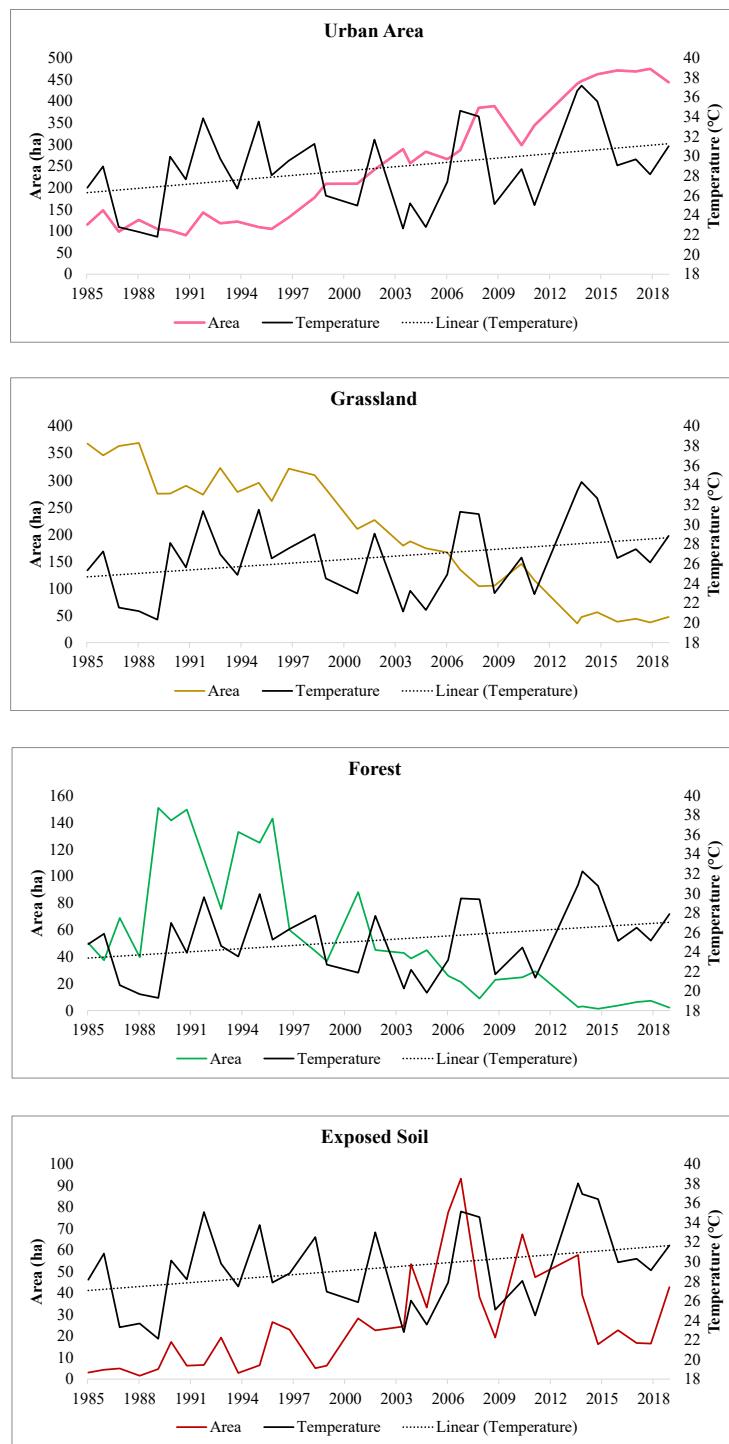


Figure 5. LST annual means for each land use and land cover areas in the period of 1985 to 2019.

Table 3. Correlation Coefficient (R) between LST seasonal means and respective areas for each LULC type.

	Urban Area	Grassland	Forest	Exposed Soil
Summer	0.26	-0.35	-0.13	0.51
Autumn	0.49	-0.50	-0.26	0.12
Winter	0.25	-0.16	-0.32	-0.06
Spring	0.25	-0.20	-0.16	-0.04

The greatest reduction in the mean LST was observed in the winter season between the periods 1985–1999 and 2000–2008. In addition to the biggest difference observed in autumn, associated with the high standard deviation value (7.75—Table 4), this reduction in winter also resulted from the high amplitude of LST values in the 2000–2008 period (7.50 standard deviation). Thus, there are uncertainties as to whether cooling actually occurred in this season in the period of 1985–2008.

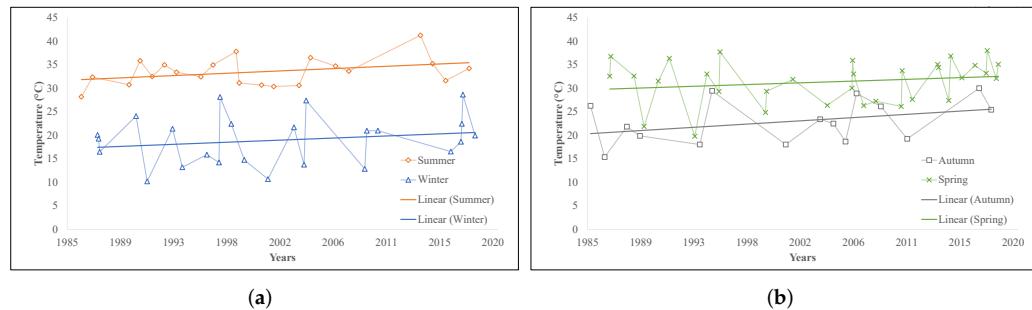


Figure 6. Land surface temperature means by year in the period from 1985 to 2019 of the study area. (a) Annual LST means for Summer and Winter. (b) Annual LST means for Autumn and Spring.

A trend analysis was carried out using the Mann–Kendall non-parametric test [67] at a 95% confidence interval, as shown in Table 5. The first scenario is to test the null hypothesis (H_0)—there is no trend in the series against the alternative hypothesis (H_a), and there is a trend in the series. If the computed p -value is lower than the significance level alpha = 0.05, one should reject null hypothesis H_0 and accept alternative hypothesis H_a . If the computed p -value is greater than the significance level of alpha = 0.05, one cannot reject null hypothesis H_0 . Thus, in autumn and spring, the LST follows an upward trend across the years, when the p -value was lower (0.02 and 0.03, respectively) than the significance level. On the other hand, in summer and winter, no trend was found since the p -values were above the significance level, 0.08 and 0.38, respectively.

Table 4. Mean and STD (° C) of the seasons in the 1985–1999, 2000–2008, and 2009–2018 intervals.

Intervals	Summer		Autumn		Winter		Spring	
	Mean	STD	Mean	STD	Mean	STD	Mean	STD
1989–1999	32.85	3.07	20.20	5.85	18.38	4.83	29.88	5.70
1999–2008	32.81	3.06	22.76	7.75	16.95	7.50	31.14	3.57
2008–2018	36.94	4.14	26.56	3.88	20.79	4.69	34.28	3.84

Table 5. Trend Analysis using the Mann–Kendall test.

	Summer	Autumn	Winter	Spring
Observations	29	27	26	33
Minimum	27.85	12.64	9.74	18.88
Maximum	42.66	32.20	29.50	39.42
Mean	33.40	22.79	18.84	31.92
Std. deviation	3.41	5.92	5.33	4.84
Kendall's tau	0.23	0.32	0.13	0.27
S	94	111	41	144
p-value	0.08	0.02	0.38	0.03

It was verified a negative linear regression between NDVI and LST (Table 6). In this manner, the reduction in surface temperature is confirmed by the increase in NDVI both in urbanized areas and in their surroundings occupied by rural activities demonstrated by soil exposure and areas covered by forest and grassland. Therefore, the implementation of green spaces in areas of intense human activity contributes to improving the thermal

comfort of the population on a local scale. The low values of correlation coefficient found in the grassland and forest classes in 1989 may be associated with the influence of local meteorological conditions and forest in 2008 and 2018 and exposed soil classes in 2018, justified by the reduced number of samples due to the reduction in their areas, as shown in Table 2. In addition, smaller areas may have greater influence from the surroundings, either by the action of winds, humidity, air temperature, and by the spectral mixture.

Table 6. Results of Correlation Coefficient (R) obtained from the LULC classes in the years 1989, 1999, 2008, and 2018.

Year	Urban Area	Grassland	Forest	Exposed Soil
1989	−0.55	−0.03	0.12	−0.40
1999	−0.58	−0.30	−0.30	−0.72
2008	−0.59	−0.39	−0.07	−0.56
2018	−0.76	−0.28	−0.16	−0.06

In particular, demonstrated by the higher values of the Correlation Coefficient (R), the cover designated by the urban area quantified greater dependence on its LST compared to variations in NDVI when compared to the other covers in 1989, 1999, 2008, and 2018. In addition, there was an increase in this dependence over the study period and since in 1989, approximately 55% of the LST values were explained by the NDVI variation, whereas in 2018, this ratio increased to 76%. This result is probably attributed to the high decrease in vegetation covers (forest and grassland), as demonstrated in Table 2, and its cooling effect on the surrounding areas over the approximate 34 years period. This effect was already related by Marzban et al. [29] in a study where all LULC classes depict an inverse correlation between LST and NDVI.

The relationship between the variables can also be observed over the area characterized by soil exposure in the years 1999 and 2008 when NDVI explained 72% and 56% of the LST values, respectively. This result was probably associated with the significant increase in urban areas occurring in 1989 to 2008 (34.6% increase), given the similarity between the two types LULC mean temperatures and surrounding effects. In this manner, it is possible to affirm the relationship between the two classes in the years 1999 and 2008 justified by the correlation coefficient. The not-significant correlation value verified for this LULC type in 2018 results from the very low area classified; thus, the low number of pixels in the date is exposed in Figure 3. Furthermore, such a relationship occurred mainly in areas where the highest values of LST were recorded (anthropized surfaces).

Regarding the direct relationship between NDVI and LST in the aforementioned four years, regardless of LULC, in general, satisfactory R values were obtained. As shown in Table 7, in 1989, NDVI explained 64% of LST values, 79% in 1999, 79% in 2008, and 78% in 2018. The lowest R value verified in 1989 was associated with the predominance of grassland areas (Table 2) for which its correlation coefficient between NDVI and LST was close to zero (Table 7). Thus, probably the highest R values obtained in the following years were associated with the predominance of urbanized areas, where NDVI explained LST variations better.

Table 7. Results of correlation coefficient (R) obtained from the LULC classes in the years 1989, 1999, 2008, and 2018.

Statistic	1989	1999	2008	2018
Mean LST (°C)	21.10	29.25	28.43	36.42
STD LST (°C)	2.02	2.27	2.18	2.29
Mean (NDVI)	0.59	0.57	0.40	0.40
STD (NDVI)	0.15	0.21	0.19	0.18
R (LST-NDVI)	−0.64	−0.79	−0.79	−0.78

4. Discussion

In the present study, visible, near infrared, and thermal infrared images from the TM-Landsat 5 and OLI/TIRS-Landsat 8 sensors were used to classify LULC and to calculate NDVI and LST. RTE inversion was used to retrieve the LST of images collected by the sensors throughout the historic series (1985–2019), and LULC classification was performed in the spring of the years 1989, 1999, 2008, and 2018 in order to verify the influence of LULC classes on the temperature from NDVI on a temporal and spatial scale.

Seasonally, the highest correlations between LST and area size were verified on the Urban Area and Grassland classes classified in the autumn season and Exposed Soil in the summer. The surfaces classified as Urban Area, Grassland, and Exposed Soil had approximately 50% of the LST values explained as a function of the variation in the occupied area over the period covered. In turn, in areas classified as Forest, this correlation was relatively weak (32% in winter). Zhou et al. [68] verified an adverse situation in a study carried out in the northeast of the USA, state of Maryland, where the percentage of imperviousness explained approximately 50% of the total variation in LST in the wintertime and up to 77.9% during summer.

This study also analyzed long-term seasonal trends in LST during the last three decades. The calculation of the average decadal differences of LST allowed verifying the increases for all seasons, which were more expressive in autumn (6.36 °C), intermediate in spring and summer (4.40 °C and 4.09 °C, respectively), and less expressive in winter (2.41 °C). However, for annual averages, by using the Mann–Kendall test, trends of temperature increase were observed only in the autumn and spring seasons. In a similar study carried out in Spain, Khorchani et al. [69] verified the Mann–Kendall trend of temperature increases in the four seasons of the year, which were more expressive in summer, intermediate in spring and autumn, and less expressive in winter. In addition, the authors attributed the increase in summer temperature to the strong increase in Summer sunshine duration (SUN) in Spain between 1982 and 2014. Thus, for future research, we recommend the analysis of this variable together with the trends of increase or decrease in LST.

The highest values of the correlation coefficient, between the LST and NDVI variables, were calculated in the LULC classes designated as Urban Area and Exposed Land. This result points to the dependence of LST values on the presence of vegetation in areas where anthropogenic interference occurred exactly, either through soil impermeability or the removal of vegetation cover exposing the surface. Thus, human actions qualified the increase in temperature in these areas in relation to neighboring environments, quantifying the phenomenon of Urban Heat Islands (UHIs). Similar results were verified in Yue et al. [70] and Hereher [71].

The increase in temperature observed for each season from 1985 to 2018 is in line with the scenario projected by the IPCC (Intergovernmental Panel on Climate Change, Geneva, Switzerland) in its Fifth Assessment Report (AR5) [72]. According to the report, at the end of the century, the increase in mean temperature should be 2.6 to 4.8 °C, which is mainly attributed to the growth of cities and their emission of 40% of the gases responsible for potentiating the greenhouse effect [73,74].

In a study carried out on the municipality of Porto Alegre- Rio Grande do Sul, Brazil, Grondona et al. [75] verified an increase in the average LST during the period from 1985 to 2005 with a 4.13% reduction in the vegetated area and an increase of 24.22% in the urbanized area. The present study found that the removal of vegetation cover and the impacts caused on the LST are of great complexity. Smaller correlation coefficients (from 0.12 to −0.39), between LST and NDVI, were found in vegetated areas (field and forest) and higher (from −0.55 to −0.76) in urbanized areas. It is important to note that, in terms of remote sensing, vegetated areas present greater homogeneity (lower spectral variability and types of materials) when compared to urbanized areas (greater geometric and spectral variability, especially of the materials used in construction). Such a result is probably associated with local meteorological variables (rainfall, air humidity, and wind) and physicochemical factors inherent to these roofs.

Although many factors (meteorological, topography, and roughness) are responsible for LST variations, the extension and arrangement of the areas are fundamental for understanding the relationship of this variable with vegetation. The results of this study demonstrate the temporal and spatial evolution of the interaction between vegetation and thermal dynamics through linear regression analysis at the pixel level. For urban areas, the correlation strength between LST and NDVI increased with time. In the study carried out in Shanghai, China, Weng et al. [35] concluded that when urban structures and built-up areas occupy most of a study area, their thermal surface will become spatially homogenized. Thus, we conclude that the highest values of R (0.72 in 2018) between LST and NDVI may be associated with the expansion of the urban area (195% increase for 1989 until 2018 period), causing changes in the energy balance and changes in local weather conditions, which are responsible for configuring an environment urban area with homogeneous thermal conditions.

Since several studies report high correlation coefficients (above 0.9) between NDVI and LST for urbanized areas that were already large at the beginning of the historical series, as shown in Baghdad, Iraq with 227,800 ha in 1984 [76], Adama Zuria District-Ethiopia with 64,800 ha in 1989 [77], and Dhaka metropolitan area-Bangladesh with 802,200 ha in 2000 [78], we observed the smaller correlation value (-0.55) obtained where the small urban nucleus occupied only 165 ha in 1989. Thus, for urban planners and urban policymakers, it is necessary to understand that the influence of vegetation presence to mitigate the increase in temperature is dependent on the spatial arrangement and coverage area of urbanized surfaces. The urban thermal environment planning of new neighborhoods, condominiums, and industrial parks must take into account not only the presence of vegetation but also biophysical, meteorological, and topographic parameters, and other LULC indices (e.g., Normalized difference built-up index, Enhanced vegetation index, Soil adjusted vegetation index, Modified normalized difference water index, Normalized difference mud index, etc.) may be examined to find a better correlation with LST.

LST is considerably influenced by vegetation dynamics [20,79]. NDVI is widely used to assess changes in LST [14,79,80]. Therefore, we chose to use it in this work. NDVI can suppress a significant amount of the noise caused by atmospheric effects, clouds or cloud shadow, topography, and changing sun angles [31,81]. However, it is worth noting that it is sensitive to canopy background variations and more saturated at high biomass levels [31,82–84]. The Enhanced Vegetation Index (EVI), with a more dynamic range, can be considered as an improvement of the NDVI, concerning the saturation in dense forest, soil reflectance influence, and atmospheric correction [31,85]. Some papers have analyzed the relationship between LST and EVI [31,79,84,86,87] and so we intend to include this index in future research.

5. Conclusions

The main conclusions were as follows: (1) The LST retrieved by the RTE inversion of Landsat 5 and 8 data showed consistency both for atmospheric parameters obtained from MODTRAN (1985–1999) and for NASA's online calculator (2000–2018). (2) Throughout the period from 1989 to 2018, the area where the current urban spot belonging to the Hípica, Aberta dos Morros, and Restinga neighborhoods has undergone significant changes in its LULC. The forest and grassland classes showed a decrease of approximately 98% and 79% in their areas, respectively, while the classes represented by the urban spot and surface exposure areas suffered an increase of 31% and 3.5% in 1989 to 75% and 14% in 2018 of the study area, respectively. (3) From annual mean values of temperature, the Mann–Kendall test allowed observing the trend of temperature growth in the autumn and spring seasons. In autumn, LST growth was more expressive, and its difference reached $6.36\text{ }^{\circ}\text{C}$ when compared to the first and last decades of the historical series. In spring, this difference was $4.4\text{ }^{\circ}\text{C}$. (4) Multiple comparative analyses indicated that the difference in LST between most types of LULC was significant, with areas of exposed soil with the highest LST (mean of the study area $38.1\text{ }^{\circ}\text{C}$) and forest land with the lowest LST (mean of $18.9\text{ }^{\circ}\text{C}$), which may

indicate the formation of urban heat islands on the study area. (5) The study allowed the demonstration of the influence of the urbanization process and the removal of vegetation cover on the significant increase in temperature. High surface temperatures were associated with areas of high urban concentration for both the images classified in 1989 and 2018, but an increase in a mean of 4.18°C was observed when compared to the first and last decade of the historical series in the four seasons. This conclusion is attributed to the significant expansion of the urban spot and the areas of exposed soil over the forest and grassland areas. Thus, the interference of the characteristics of the materials covering the surface over the heat of the environment where they are located is evident. (6) The relationship between NDVI and LST verified for the urban area, exposed soil, grassland, and forest classes showed a negative linear correlation, as expected. A higher correlation coefficient (R) was obtained between NDVI and LST in the areas classified as urbanized area and exposed soil, where the highest temperatures were found. (7) The relationship between NDVI and LST in urbanized areas showed an increase associated with the correlation coefficient from -0.55 in 1989 to -0.76 in 2018. This result is probably related to the growth of the urban area (from 31% of the area in 1989 to 91% in 2018), causing surface homogeneity (lesser meteorological variations, reduced effect of the surrounding areas, and less spectral mixing). A different behavior was observed in other areas (field, forests, and exposed soil), where R did not present any pattern of evolution.

Some drawbacks to this work should not be overlooked. First, the meteorological variables, land surface albedo, [88] and landscape metrics [89] can provide greater accuracy to the results and discussions, since these variables directly influence LST. Second, the low availability of satellite images, especially during the winter when clear sky conditions are less frequent, render the trend analysis of increases or decreases in LST over the period difficult. Future studies should make use of complementary products to meet this demand, for example, the Aster sensor LST product. Finally, the results obtained were generated from high-resolution remote sensing images and geoprocessing tools; however, the LST was not validated with field measurements.

The information gathered about the surface temperature, land use, and cover using remote sensing techniques, using visible and thermal infrared bands from the Landsat 5 and 8 satellites, TM, and OLI sensors, respectively, allowed the visualization and understanding of the microclimate dynamics of an urban area in the city of Porto Alegre, RS-Brazil, over the period studied, as well as its relationship with the different types of surface cover. The historical characterization of the relationship between LST and NDVI according to the types of LULC made it possible to quantify the impacts of the rapid urbanization process in a small urban nucleus as a model for future decision making regarding urban expansion and planning. Thus, the study highlights the importance of air humidity and evapotranspiration processes, which should be maintained through the adoption of policies that mitigate the effects caused by urban expansion and densification.

Author Contributions: Conceptualization, E.A.K., S.B.A.R. and A.E.B.G.; methodology, E.A.K., A.E.B.G. and C.L.H.; software, E.A.K.; investigation, E.A.K., S.B.A.R., A.E.B.G., C.L.H., R.d.M.L., P.S.K., N.S.d.R. and L.R.D.; writing—original draft preparation, E.A.K., S.B.A.R., A.E.B.G. and C.L.H.; writing—review and editing, E.A.K., S.B.A.R., A.E.B.G., C.L.H., P.S.K., N.S.d.R. and L.R.D.; supervision, S.B.A.R., A.E.B.G., C.L.H. and R.d.M.L.; project administration, S.B.A.R. All authors have read and agreed to the published version of the manuscript.

Funding: This research received support from Coordenação de Aperfeiçoamento de Pessoal de Nível Superior—Brazil (CAPES).

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Not applicable.

Acknowledgments: The authors would like to thank the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior—Brazil (CAPES) and the Laboratory of Geological Remote Sensing (Lab-SRGeo/UFRGS) for supporting this study.

Conflicts of Interest: The authors declare no conflicts of interest.

References

1. Nations, U. *World Urbanization Prospects: The 2014 Revision, Highlights*; Department of Economic and Social Affairs, Population Division: New York, NY, USA, 2014; Volume 32.
2. IBGE, C.D. Censo Demográfico 2010: Características da População e dos Domicílios: Resultados do Universo. 2011. Available online: https://biblioteca.ibge.gov.brvisualizacaoperiodicos93cd_2010_caracteristicas_populacao_domicilios.pdf (accessed on 24 January 2021).
3. Tomlinson, C.J.; Chapman, L.; Thornes, J.E.; Baker, C. Remote sensing land surface temperature for meteorology and climatology: A review. *Meteorol. Appl.* **2011**, *18*, 296–306. [CrossRef]
4. Hao, X.; Li, W.; Deng, H. The oasis effect and summer temperature rise in arid regions—case study in Tarim Basin. *Sci. Rep.* **2016**, *6*, 1–9. [CrossRef] [PubMed]
5. Oke, T.R. *Boundary Layer Climates*; Routledge: London, UK, 2002. [CrossRef]
6. Andrade, H. O clima urbano-natureza, escalas de análise e aplicabilidade. *Finisterra* **2005**, *40*. [CrossRef]
7. Zhang, Y.; Sun, L. Spatial-temporal impacts of urban land use land cover on land surface temperature: Case studies of two Canadian urban areas. *Int. J. Appl. Earth Obs. Geoinf.* **2019**, *75*, 171–181. [CrossRef]
8. Rasul, A.; Balzter, H.; Smith, C.; Remedios, J.; Adamu, B.; Sobrino, J.A.; Srivani, M.; Weng, Q. A review on remote sensing of urban heat and cool islands. *Land* **2017**, *6*, 38. [CrossRef]
9. Estoque, R.C.; Murayama, Y.; Myint, S.W. Effects of landscape composition and pattern on land surface temperature: An urban heat island study in the megacities of Southeast Asia. *Sci. Total. Environ.* **2017**, *577*, 349–359. [CrossRef]
10. Bounoua, L.; Zhang, P.; Mostovoy, G.; Thome, K.; Masek, J.; Imhoff, M.; Shepherd, M.; Quattrochi, D.; Santanello, J.; Silva, J.; et al. Impact of urbanization on US surface climate. *Environ. Res. Lett.* **2015**, *10*, 084010. [CrossRef]
11. Norton, B.A.; Coutts, A.M.; Livesley, S.J.; Harris, R.J.; Hunter, A.M.; Williams, N.S. Planning for cooler cities: A framework to prioritise green infrastructure to mitigate high temperatures in urban landscapes. *Landsc. Urban Plan.* **2015**, *134*, 127–138. [CrossRef]
12. Ellison, D.; Morris, C.E.; Locatelli, B.; Sheil, D.; Cohen, J.; Murdiyarso, D.; Gutierrez, V.; Van Noordwijk, M.; Creed, I.F.; Pokorny, J.; et al. Trees, forests and water: Cool insights for a hot world. *Glob. Environ. Chang.* **2017**, *43*, 51–61. [CrossRef]
13. Smith, R.; Choudhury, B.J. On the correlation of indices of vegetation and surface temperature over south-eastern Australia. *Int. J. Remote Sens.* **1990**, *11*, 2113–2120. [CrossRef]
14. Hope, A.S.; McDowell, T. The relationship between surface temperature and a spectral vegetation index of a tallgrass prairie: effects of burning and other landscape controls. *Int. J. Remote Sens.* **1992**, *13*, 2849–2863. [CrossRef]
15. Julien, Y.; Sobrino, J.A.; Verhoef, W. Changes in land surface temperatures and NDVI values over Europe between 1982 and 1999. *Remote Sens. Environ.* **2006**, *103*, 43–55. [CrossRef]
16. Deng, Y.; Wang, S.; Bai, X.; Tian, Y.; Wu, L.; Xiao, J.; Chen, F.; Qian, Q. Relationship among land surface temperature and LUCC, NDVI in typical karst area. *Sci. Rep.* **2018**, *8*, 1–12. [CrossRef] [PubMed]
17. Kawashima, S. Relation between vegetation, surface temperature, and surface composition in the Tokyo region during winter. *Remote Sens. Environ.* **1994**, *50*, 52–60. [CrossRef]
18. Thanh Hoan, N.; Liou, Y.A.; Nguyen, K.A.; Sharma, R.C.; Tran, D.P.; Liou, C.L.; Cham, D.D. Assessing the effects of land-use types in surface urban heat islands for developing comfortable living in Hanoi City. *Remote Sens.* **2018**, *10*, 1965. [CrossRef]
19. Gallo, K.; McNab, A.; Karl, T.R.; Brown, J.F.; Hood, J.; Tarpley, J. The use of NOAA AVHRR data for assessment of the urban heat island effect. *J. Appl. Meteorol. Climatol.* **1993**, *32*, 899–908. [CrossRef]
20. Yuan, X.; Wang, W.; Cui, J.; Meng, F.; Kurban, A.; De Maeyer, P. Vegetation changes and land surface feedbacks drive shifts in local temperatures over Central Asia. *Sci. Rep.* **2017**, *7*, 1–8. [CrossRef]
21. Rahman, M.; Rony, M.; Hasan, R.; Jannat, F.A.; Chandra Pal, S.; Islam, M.; Alam, E.; Islam, A.R.M. Impact of Urbanization on Urban Heat Island Intensity in Major Districts of Bangladesh Using Remote Sensing and Geo-Spatial Tools. *Climate* **2022**, *10*, 3. [CrossRef]
22. Guha, S.; Govil, H.; Diwan, P. Monitoring LST-NDVI relationship using Premonsoon Landsat datasets. *Adv. Meteorol.* **2020**, *2020*, 4539684. [CrossRef]
23. Abdullah, S.; Barua, D.; Abdullah, S.; Abubakar, M.; Rabby, Y.W. Investigating the Impact of Land Use/Land Cover Change on Present and Future Land Surface Temperature (LST) of Chittagong, Bangladesh. *Earth Syst. Environ.* **2022**, *6*, 221–235. [CrossRef]
24. Fatemi, M.; Narangifard, M. Monitoring LULC changes and its impact on the LST and NDVI in District 1 of Shiraz City. *Arab. J. Geosci.* **2019**, *12*, 1–12. [CrossRef]
25. Gui, X.; Wang, L.; Yao, R.; Yu, D.; Li, C. Investigating the urbanization process and its impact on vegetation change and urban heat island in Wuhan, China. *Environ. Sci. Pollut. Res.* **2019**, *26*, 30808–30825. [CrossRef] [PubMed]

26. Sussman, H.S.; Raghavendra, A.; Zhou, L. Impacts of increased urbanization on surface temperature, vegetation, and aerosols over Bengaluru, India. *Remote Sens. Appl. Soc. Environ.* **2019**, *16*, 100261. [CrossRef]
27. Biswas, S.; Ghosh, S. Estimation of land surface temperature in response to land use/land cover transformation in Kolkata city and its suburban area, India. *Int. J. Urban Sci.* **2021**, *1*–28. [CrossRef]
28. Tayyebi, A.; Shafizadeh-Moghadam, H.; Tayyebi, A.H. Analyzing long-term spatio-temporal patterns of land surface temperature in response to rapid urbanization in the mega-city of Tehran. *Land Use Policy* **2018**, *71*, 459–469. [CrossRef]
29. Marzban, F.; Sodoudi, S.; Preusker, R. The influence of land-cover type on the relationship between NDVI-LST and LST-T air. *Int. J. Remote Sens.* **2018**, *39*, 1377–1398. [CrossRef]
30. Guha, S.; Govil, H. Seasonal variability of LST-NDVI correlation on different land use/land cover using Landsat satellite sensor: A case study of Raipur City, India. *Environ. Dev. Sustain.* **2021**, *1*–17. [CrossRef]
31. Al-Ademomi, A.S.; Okolie, C.J.; Daramola, O.E.; Agboola, R.O.; Salami, T.J. Assessing the relationship of LST, NDVI and EVI with land cover changes in the Lagos Lagoon environment. *Quaest. Geogr.* **2020**, *39*, 87–109. [CrossRef]
32. Frumkin, H. Urban sprawl and public health. *Public Health Rep.* **2016**, *117*, 201–217. [CrossRef]
33. Dubreuil, V.; Quénol H.; Foissard, X.; Planchon, O. *Climatologie Urbaine et îlot de Chaleur Urbain à Rennes*; Ville et biodiversité, Clergeau P. (dir.); Presses Universitaires de Rennes: Rennes, France, 2011; pp. 105–122.
34. Voogt, J.A.; Oke, T.R. Thermal remote sensing of urban climates. *Remote Sens. Environ.* **2003**, *86*, 370–384. [CrossRef]
35. Weng, Q.; Lu, D.; Schubring, J. Estimation of land surface temperature–vegetation abundance relationship for urban heat island studies. *Remote Sens. Environ.* **2004**, *89*, 467–483. [CrossRef]
36. Chen, X.L.; Zhao, H.M.; Li, P.X.; Yin, Z.Y. Remote sensing image-based analysis of the relationship between urban heat island and land use/cover changes. *Remote Sens. Environ.* **2006**, *104*, 133–146. [CrossRef]
37. Abou El-Magd, I.; Ismail, A.; Zanaty, N. Spatial variability of urban heat islands in Cairo City, Egypt using time series of Landsat Satellite images. *Int. J. Adv. Remote Sens. Gis* **2016**, *5*, 1618–1638. [CrossRef]
38. Keeratikasikorn, C.; Bonafoni, S. Urban heat island analysis over the land use zoning plan of Bangkok by means of Landsat 8 imagery. *Remote Sens.* **2018**, *10*, 440. [CrossRef]
39. Dissanayake, D.; Morimoto, T.; Ranagalage, M.; Murayama, Y. Land-use/land-cover changes and their impact on surface urban heat islands: Case study of Kandy City, Sri Lanka. *Climate* **2019**, *7*, 99. [CrossRef]
40. Lombardo, M. Ilha de Calor nas Metrópoles, o Exemplo de São Paulo. In *Ilha de Calor Nas Metrópoles*; SA Comércio Indústria: Aveiro, Portugal, 1985.
41. Coelho, A.L.N.; Correa, W.d.S.C. Temperatura de Superfície Celsius do Sensor TIRS/Landsat-8: Metodologia e aplicações. *Revista Geográfica Acadêmica* **2013**, *7*, 31–45. [CrossRef]
42. Teixeira, D.C.F.; Amorim, M.C.d.C.T. Ilhas de calor: Representações espaciais de cidades de pequeno porte por meio de modelagem. *GEOUSP Espaço e Tempo (Online)* **2017**, *21*, 239–256. [CrossRef]
43. Romero, M.; Baptista, G.; Azevedo, E.; Werneck, D.; Vianna, E.; Sales, G. *Mudanças Climáticas Ilhas Calor Urbanas*; Universidade de Brasília, Faculdade de Arquitetura e Urbanismo: Brasília, Brazil, 2019.
44. Deosthal, V. Impact of rapid urban growth on heat and moisture islands in Pune City, India. *Atmos. Environ.* **2000**, *34*, 2745–2754. [CrossRef]
45. Xiong, Y.; Peng, F.; Zou, B. Spatiotemporal influences of land use/cover changes on the heat island effect in rapid urbanization area. *Front. Earth Sci.* **2019**, *13*, 614–627. [CrossRef]
46. Suertegaray, D.M.A.; Moura, N.S.V. Morfogênese do relevo do Estado do Rio Grande do Sul. In *Rio Grande do Sul: Paisagens e Territórios em Transformação*, 2nd ed.; Editora da UFRGS: Porto Alegre, Brazil, 2012; pp. 11–26. Available online: <https://lume.ufrgs.br/handle/10183/218532> (accessed on 24 January 2022).
47. Ferraro, L.M.W.; Hasenack, H. *Carvão e Meio Ambiente*; Editora da Universidade/UFRGS: Porto Alegre, Brazil, 2000. Available online: http://multimidia.ufrgs.br/conteudo/labgeo-ecologia/Arquivos/Publicacoes/Livros_ou_capitulos/2000/Centro_de_Ecologia_2000_Carvao_e_Meio_Ambiente.pdf (accessed on 24 January 2022).
48. Kuinchner, A.; Buriol, G.A. Clima do Estado do Rio Grande do Sul segundo a classificação climática de Köppen e Thornthwaite. *Disciplinarum Scientiarum Naturais e Tecnológicas* **2001**, *2*, 171–182.
49. Lillesand, T.; Kiefer, R.W.; Chipman, J. *Remote Sens. Image Interpret.*; John Wiley & Sons: Hoboken, NY, USA, 2015. [CrossRef]
50. Bailly, J.S.; Arnaud, M.; Puech, C. Boosting: A classification method for remote sensing. *Int. J. Remote Sens.* **2007**, *28*, 1687–1710. [CrossRef]
51. Lu, D.; Weng, Q. A survey of image classification methods and techniques for improving classification performance. *Int. J. Remote Sens.* **2007**, *28*, 823–870. [CrossRef]
52. Qin, Z.; Karnieli, A.; Berliner, P. A mono-window algorithm for retrieving land surface temperature from Landsat TM data and its application to the Israel-Egypt border region. *Int. J. Remote Sens.* **2001**, *22*, 3719–3746. [CrossRef]
53. Jiménez-Muñoz, J.C.; Sobrino, J.A. A generalized single-channel method for retrieving land surface temperature from remote sensing data. *J. Geophys. Res. Atmos.* **2003**, *108*. [CrossRef]
54. Luo, H.; Shao, J.; Zhang, X. Retrieving land surface temperature based on the radioactive transfer equation in the middle reaches of the Three Gorges Reservoir Area. *Resour. Sci.* **2012**, *34*, 256–264.
55. Rozenstein, O.; Qin, Z.; Derimian, Y.; Karnieli, A. Derivation of land surface temperature for Landsat-8 TIRS using a split window algorithm. *Sensors* **2014**, *14*, 5768–5780. [CrossRef]

56. Liu, L.; Zhang, Y. Urban heat island analysis using the Landsat TM data and ASTER data: A case study in Hong Kong. *Remote Sens.* **2011**, *3*, 1535–1552. [[CrossRef](#)]
57. Azmi, R.; Saadane, A.; Kacimi, I. Estimation of spatial distribution and temporal variability of land surface temperature over Casablanca and the surroundings of the city using different Landat satellite sensor type (TM, ETM⁺ and OLI). *Int. J. Innov. Appl. Stud.* **2015**, *11*, 49.
58. Isaya Ndossi, M.; Avdan, U. Application of open source coding technologies in the production of land surface temperature (LST) maps from Landsat: A PyQGIS plugin. *Remote Sens.* **2016**, *8*, 413. [[CrossRef](#)]
59. Chatterjee, R.; Singh, N.; Thapa, S.; Sharma, D.; Kumar, D. Retrieval of land surface temperature (LST) from landsat TM6 and TIRS data by single channel radiative transfer algorithm using satellite and ground-based inputs. *Int. J. Appl. Earth Obs. Geoinf.* **2017**, *58*, 264–277. [[CrossRef](#)]
60. Zanter, K. *Landsat 8 (L8) Data Users Handbook*; Department of the Interior U.S. Geological Survey: Reston, VA, USA, 2016; p. 33.
61. Barsi, J.A.; Schott, J.R.; Hook, S.J.; Raqueno, N.G.; Markham, B.L.; Radocinski, R.G. Landsat-8 thermal infrared sensor (TIRS) vicarious radiometric calibration. *Remote Sens.* **2014**, *6*, 11607–11626. [[CrossRef](#)]
62. Cheng, H.-L.; Xia, D.-Q.; Wu, T.-T.; Meng, X.-P.; Ji, H.-J.; Dong, Z.-G. Land Surface Temperature Retrieval from CBERS-02 IRMSS Thermal Infrared Data and Its Applications in Quantitative Analysis of Urban Heat Island Effect. *J. Remote Sens.* **2006**, *33*, 702–710. [[CrossRef](#)]
63. Li, Z.L.; Tang, B.H.; Wu, H.; Ren, H.; Yan, G.; Wan, Z.; Trigo, I.F.; Sobrino, J.A. Satellite-derived land surface temperature: Current status and perspectives. *Remote Sens. Environ.* **2013**, *131*, 14–37. [[CrossRef](#)]
64. Wang, C.; Myint, S.W.; Wang, Z.; Song, J. Spatio-temporal modeling of the urban heat island in the Phoenix metropolitan area: Land use change implications. *Remote Sens.* **2016**, *8*, 185. [[CrossRef](#)]
65. Deilami, K.; Kamruzzaman, M. Modelling the urban heat island effect of smart growth policy scenarios in Brisbane. *Land Use Policy* **2017**, *64*, 38–55. [[CrossRef](#)]
66. Li, X.; Zhou, Y.; Asrar, G.R.; Imhoff, M.; Li, X. The surface urban heat island response to urban expansion: A panel analysis for the conterminous United States. *Sci. Total. Environ.* **2017**, *605*, 426–435. [[CrossRef](#)]
67. Gilbert, R.O. *Statistical Methods for Environmental Pollution Monitoring*; John Wiley & Sons: Hoboken, NJ, USA, 1987.
68. Zhou, W.; Qian, Y.; Li, X.; Li, W.; Han, L. Relationships between land cover and the surface urban heat island: Seasonal variability and effects of spatial and thematic resolution of land cover data on predicting land surface temperatures. *Landscape Ecol.* **2014**, *29*, 153–167. [[CrossRef](#)]
69. Khorchani, M.; Vicente-Serrano, S.M.; Azorin-Molina, C.; Garcia, M.; Martin-Hernandez, N.; Peña-Gallardo, M.; El Kenawy, A.; Domínguez-Castro, F. Trends in LST over the peninsular Spain as derived from the AVHRR imagery data. *Glob. Planet. Chang.* **2018**, *166*, 75–93. [[CrossRef](#)]
70. Yue, W.; Xu, J.; Tan, W.; Xu, L. The relationship between land surface temperature and NDVI with remote sensing: Application to Shanghai Landsat 7 ETM+ data. *Int. J. Remote Sens.* **2007**, *28*, 3205–3226. [[CrossRef](#)]
71. Hereher, M.E. Effect of land use/cover change on land surface temperatures-The Nile Delta, Egypt. *J. Afr. Earth Sci.* **2017**, *126*, 75–83. [[CrossRef](#)]
72. Sabine, C. Ask the Experts: The IPCC Fifth Assessment Report. *Carbon Manag.* **2014**, *5*, 17–25. [[CrossRef](#)]
73. Rosenzweig, C.; Solecki, W.D.; Romero-Lankao, P.; Mehrotra, S.; Dhakal, S.; Ibrahim, S.A. *Climate Change and Cities: Second Assessment Report of the Urban Climate Change Research Network*; Cambridge University Press: Cambridge, UK, 2018.
74. Revi, A.; Satterthwaite, D.; Aragón-Durand, F.; Corfee-Morlot, J.; Kiunsi, R.B.; Pelling, M.; Roberts, D.; Solecki, W.; Gajjar, S.P.; Sverdlik, A. Towards transformative adaptation in cities: The IPCC's Fifth Assessment. *Environ. Urban.* **2014**, *26*, 11–28. [[CrossRef](#)]
75. Grondona, A.E.B.; Veettil, B.K.; Rolim, S.B.A. Urban Heat Island development during the last two decades in Porto Alegre, Brazil and its monitoring. In Proceedings of the Joint Urban Remote Sensing Event 2013, Sao Paulo, Brazil, 21–23 April 2013; pp. 061–064.
76. Hashim, B.M.; Al Maliki, A.; Sultan, M.A.; Shahid, S.; Yaseen, Z.M. Effect of land use/land cover changes on land surface temperature during 1984–2020: A case study of Baghdad city using landsat image. *Nat. Hazards* **2022**, *1–24*. [[CrossRef](#)]
77. Tafesse, B.; Suryabhagavan, K. Systematic modeling of impacts of land-use and land-cover changes on land surface temperature in Adama Zuria District, Ethiopia. *Model. Earth Syst. Environ.* **2019**, *5*, 805–817. [[CrossRef](#)]
78. Kafy, A.A.; Al Rakib, A.; Akter, K.S.; Jahir, D.M.A.; Sikdar, M.S.; Ashrafi, T.J.; Mallik, S.; Rahman, M.M.; Faisal, A.A. Assessing and predicting land use/land cover, land surface temperature and urban thermal field variance index using Landsat imagery for Dhaka Metropolitan area. *Environ. Chall.* **2021**, *4*, 100192.
79. Bari, E.; Nipa, N.J.; Roy, B. Association of vegetation indices with atmospheric & biological factors using MODIS time series products. *Environ. Chall.* **2021**, *5*, 100376.
80. Guha, S.; Govil, H. An assessment on the relationship between land surface temperature and normalized difference vegetation index. *Environ. Dev. Sustain.* **2021**, *23*, 1944–1963. [[CrossRef](#)]
81. Matsushita, B.; Yang, W.; Chen, J.; Onda, Y.; Qiu, G. Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: A case study in high-density cypress forest. *Sensors* **2007**, *7*, 2636–2651. [[CrossRef](#)]
82. Huete, A.R. A soil-adjusted vegetation index (SAVI). *Remote Sens. Environ.* **1988**, *25*, 295–309. [[CrossRef](#)]
83. Gao, X.; Huete, A.R.; Ni, W.; Miura, T. Optical–biophysical relationships of vegetation spectra without background contamination. *Remote Sens. Environ.* **2000**, *74*, 609–620. [[CrossRef](#)]

84. Sobrino, J.A.; Julien, Y. Trend analysis of global MODIS-Terra vegetation indices and land surface temperature between 2000 and 2011. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2013**, *6*, 2139–2145. [[CrossRef](#)]
85. Rankine, C.; Sánchez-Azofeifa, G.; Guzmán, J.A.; Espírito-Santo, M.; Sharp, I. Comparing MODIS and near-surface vegetation indexes for monitoring tropical dry forest phenology along a successional gradient using optical phenology towers. *Environ. Res. Lett.* **2017**, *12*, 105007. [[CrossRef](#)]
86. Khalil, U.; Aslam, B.; Azam, U.; Khalid, H.M.D. Time Series Analysis of Land Surface Temperature and Drivers of Urban Heat Island Effect Based on Remotely Sensed Data to Develop a Prediction Model. *Appl. Artif. Intell.* **2021**, *1*–26. [[CrossRef](#)]
87. Sahani, N. Assessment of spatio-temporal changes of land surface temperature (LST) in Kanchenjunga Biosphere Reserve (KBR), India using Landsat satellite image and single channel algorithm. *Remote Sens. Appl. Soc. Environ.* **2021**, *24*, 100659. [[CrossRef](#)]
88. Oleson, K.W.; Bonan, G.B.; Schaaf, C.; Gao, F.; Jin, Y.; Strahler, A. Assessment of global climate model land surface albedo using MODIS data. *Geophys. Res. Lett.* **2003**, *30*. [[CrossRef](#)]
89. Peng, J.; Hu, Y.; Dong, J.; Liu, Q.; Liu, Y. Quantifying spatial morphology and connectivity of urban heat islands in a megacity: A radius approach. *Sci. Total. Environ.* **2020**, *714*, 136792. [[CrossRef](#)]

3 CAPÍTULO III. AVALIAÇÃO E PREVISÃO DO USO E COBERTURA DA TERRA E DA TEMPERATURA DE SUPERFÍCIE NO MUNICÍPIO DE PORTO ALEGRE-RS, BRASIL, A PARTIR DE DADOS DE SENSORIAMENTO REMOTO E ALGORITMO CA-ANN

Artigo submetido na revista Geo UERJ (ISSN: 1415-7543) em 2023.

AVALIAÇÃO E PREVISÃO DO USO E COBERTURA DA TERRA E DA TEMPERATURA DE SUPERFÍCIE NO MUNICÍPIO DE PORTO ALEGRE-RS, BRASIL, A PARTIR DE DADOS DE SENSORIAMENTO REMOTO E ALGORITMO CA-ANN

Eduardo. André. Kaiser^{a*}, Silvia. Beatriz. Alves. Rolim^b, Atílio. Efrain. Bica. Grondona^c

^{a*} Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Rio Grande do Sul, Brazil – kaiser-eduardo@hotmail.com

^b Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Rio Grande do Sul, Brazil - silvia.rolim@ufrgs.br

^c Universidade do Vale dos Sinos (UNISINOS) -Programa de graduação em Engenharia Civil, São Leopoldo, RS, Brazil, - atilio.grondona@ufrgs.br

RESUMO

O objetivo do presente estudo é avaliar e prever o uso e cobertura da terra (LULC) e a temperatura de superfície (LST) no município de Porto Alegre-RS. Para isso, foram calculadas as mudanças espacotemporais do LULC e da LST a partir de imagens Landsat-TM-OLI/TIRS de 1995 a 2017, com intervalo de 11 anos, e com as matrizes de transição e algoritmo CA-ANN, modelados os cenários futuros, de 2028 e 2039. As variáveis independentes declividade, distância das estradas e distância da área construída foram utilizadas na previsão do LULC e o NDVI, NDBI, UI e LULC na previsão da LST. Os resultados mostraram que durante o período de 1995 a 2017 a área urbana do município apresentou crescimento de 10,16% com previsão de aumento em 1,41% até 2028 e 2,33% até 2039, enquanto as áreas cobertas por vegetação tiveram uma redução de 10,01% (1995-2017), 2,65% até 2028 e 3,69% até 2039. As áreas correspondentes a LST de 35 a 40°C que tiveram um aumento de 2,03% no intervalo passado de 22 anos (1995-2017), passaram a ter previsão de aumento de 2,39% já no intervalo de 11 anos seguintes (2017-2028) e 0,25% no intervalo 2028-2039. Por outro lado, verificou-se o aumento das áreas de baixo LST, menores que 30°C, de 1,13% no período 1995-2017 e 0,36% previsto para 2017-2039. Assim, o estudo alerta para a previsão do crescimento tanto urbano quanto das temperaturas elevadas e redução nas áreas verdes, as quais Porto Alegre tem sido referência positiva no cenário nacional.

PALAVRAS CHAVE: Crescimento urbano, QGIS, plugin Molusce, Sensoriamento Remoto, Ilha de Calor Urbana.

ABSTRACT

The aim of the present study is to evaluate and predict Land Use and Land Cover (LULC) and Land Surface Teperature (LST) in Porto Alegre city, RS. For this, the spatiotemporal changes of LULC and LST were calculated from Landsat-TM-OLI/TIRS images from 1995 to 2017, with the transition matrices and with CA-ANN algorithm, modeled the future scenarios, from 2028 and 2039. The independent variables slope, distance from roads and distance from built-up area were used in the prediction of the LULC and the NDVI, NDBI, UI and LULC in the prediction of the LST. The results showed that during the period from 1995 to 2017, the Área urbana of the municipality grew by 10.16% with a forecast increase of 1.41% until 2028 and 2.33% until 2039, while the areas covered

by vegetation had a reduction of 10.01% (1995-2017), 2.65% until 2028 and 3.69% until 2039. The areas corresponding to LST from 35 to 40°C that had an increase of 2.03% in the past interval of 22 years (1995-2017), now forecast an increase of 2.39% in the next 11 years (2017-2028) and 0.25% in the 2028-2039 interval. On the other hand, there was an increase in areas of low LST, below 30°C, of 1.13% in the period 1995-2017 and 0.36% predicted for 2017-2039. Thus, the study draws attention to the prediction of both urban growth and high temperatures and a reduction in green areas, which Porto Alegre has been a positive reference on the national scene.

KEYWORDS: Urban growth. QGIS. Molusce plugin. Remote Sensing. Urban Heat Island.

INTRODUÇÃO

O crescimento populacional ocorrido principalmente nas últimas sete décadas atingiu a marca de 8 bilhões de habitantes em 2022 com projeção de aumento para 8,5 bilhões em 2030 e 9,7 bilhões em 2050 (UN, 2022). Aliado e como consequência deste crescimento está o aumento da porcentagem da população urbana mundial. Em 1950 era de 30% e ocupava área de 3% da superfície terrestre e a previsão é de aumentar para 68% da população mundial e 66% da área habitável do planeta em 2050 (UN, 2018). A marca deste processo de mudança do uso e cobertura da terra (do inglês *Land Use and Land Cover -LULC*) está na crescente urbanização e industrialização, que embora sinalizam para o desenvolvimento econômico, alteram o ecossistema, a biodiversidade e colocam pressão sobre o meio ambiente (KAFY et al., 2020; PIRACHA e CHAUDHARY, 2022).

As mudanças no LULC tornaram-se uma preocupação global visto que alteram principalmente o clima local e regional, e quando associadas a substituição das superfícies naturais por impermeáveis, características das cidades (asfalto, edificações, calçadas), contribuem para a formação das Ilhas de Calor Urbanas (do inglês *Urban Heat Island- UHI*) (ZHANG et al., 2017; GIANNAROS et al., 2018). Os impactos da ocorrência das UHIs são o alto consumo de energia e água (ARNFIELD, 2003; HIRANO e FUGITA, 2012), poluição do ar (LAI e CHENG, 2009) e riscos graves à saúde (morte de crianças e idosos por asma e insolação, por exemplo) (PRIYADARSINI, 2009; LAI e CHENG, 2010). Assim, o rápido processo de urbanização sobre o ponto de vista termodinâmico, hidrológico e de atividades radiativas caracteriza a mudança no LULC mais expressiva, o que amplia os efeitos de mudanças climáticas e principalmente das ondas de calor (YUEN e KONG, 2009; FU e WENG, 2017; ZHANG et al., 2017).

A Temperatura de Superfície (do inglês *Land Surface Temperature- LST*) é uma variável que está relacionada com superfícies impermeáveis e permeáveis as quais dependem dos tipos de LULC (vegetação, corpos de água, áreas construídas e solo) e suas mudanças (MUSHORE et la., 2017; HALDER, BANDYOPADHYAY e BANIK, 2021b; KAFY et al., 2021; ASHWINI e Sil, 2022). Tantos os tipos de LULC e seus índices como a LST podem ser obtidas por Sensoriamento Remoto

(do inglês Remote Sensing- RS) e Sistemas de Informação Geográfica (SIG). A LST obtida por RS tem sido amplamente utilizada por pesquisadores para determinar as UHIs (MENDELSOHN et al., 2007; HALDER, BANDYOPADHYAY e BANIK, 2021; MAIMAITIYIMING et al., 2014; ZHAO et al., 2021; MOAZZAM, DOH e LEE, 2022), vista a disponibilidade de imagens com longas séries históricas (imagens Landsat por exemplo), refinadas resoluções espaço-temporais e espectrais, que com o uso dos SIGs permitem monitorar simultaneamente as mudanças do LULC e LST (CHOUDHURY, DAS e DAS, 2019; KAFY et al., 2020).

Existem diversos métodos e algoritmos capazes de monitorar as mudanças de LULC e LST e de prever a evolução espaço-temporal destas, embora encontrem-se poucos estudos sobre este último. Os modelos mais comumente utilizados para simular a progressão de mudanças no LULC são: Markov Chain (MC) (SANTÉ et al., 2010; HASHEM e BALAKRISHNAN, 2015; SIDDIQUE et al., 2020), Cellular Automata (CA) (ZENIL, 2009; TRIPATHY e KUMAR, 2019) e Artificial Neural Network (ANN) (CIVCO, 1993; MOZUMDER e TRIPATHI, 2014; ABDULLAH et al., 2022). O modelo MC apresenta bom desempenho para produzir uma matriz de probabilidade de transição quando as alterações do LULC e da LST são conhecidas, mas é limitado para análise de dados não espaciais bem como sua distribuição (ULLAH et al., 2019). A combinação com o modelo CA caracteriza uma excelente alternativa já que este modela o estado do fenômeno dependente do estado anterior das células dentro de uma vizinhança de acordo com um conjunto de regras de transição (HADI et al., 2014; RAHAMAN, AHMED e HASSAN, 2018; SAPUTRA e LEE, 2019). Finalmente a complexidade do comportamento e padrões de mudanças do LULC e da LST demanda a utilização de ANNs vista a capacidade de prever cenários futuros com abordagem de relações não lineares entre fatores determinantes e variáveis previstas (THAPA e MURAYAMA, 2012; ULLAH et al., 2019). A integração CA-MC e ANN favorece estudos de previsão já que a ANN facilita a calibração automática do modelo CA-MC e oferece maior precisão de mudanças em cenários futuros (GHARAIBEH et al., 2020; DEY et al., 2021).

Vários estudos indicam a relação entre o LULC e LST (DENG et al., 2018; GOGOI et al., 2019; GRIGORAS e URITESCU, 2019; TRAORE et al., 2021; GOHAIN et al., 2021; HASHIM et al., 2022; NEOG, 2022). Destes estudos, poucos avaliaram a relação entre as variáveis para simular projeções futuras e os fatores determinantes tanto na previsão do LULC quanto da LST não são comuns entre os trabalhos. MUSHORE et al., 2017 utilizaram uma série de índices de LULC para prever LST na região metropolitana de Harare, Zimbabwe, a partir dos modelos CA-MC e concluiu que o Índice Urbano (do inglês Urban Index-UI) apresentou melhor desempenho comparado aos índices de vegetação, de solo e água. Ullah et al., (2019) correlacionaram os índices Normalized

Difference Built-up (NDBI), Normalized Difference Bareness Index (NDBaI), Normalized Difference Vegetation Index (NDVI) e Urban Index (UI) com a variável LST para posterior previsão desta na região do baixo Himalaia e verificaram a melhor relação ocorreu entre UI e LST, com Coeficiente de Correlação de Pearson de 0,41 e Root Mean Square Error (RMSE) de 0,094. Das et al., (2021) utilizaram os modelos CA-MC e ANN e como variável determinante a distância entre canais fluviais para prever as mudanças de LST em West Bengal, leste da Índia. Na mesma porção geográfica, a partir do modelo ANN, Ashwini e Sil, (2022) realizaram a previsão da LST com o NDVI, Normalized Difference Água Index (NDWI), NDBI e LST (série histórica) em intervalos de 10 e 20 anos como variáveis determinantes, e Halder, Bandyopadhyay e Banik (2021) utilizaram o modelo CA-MC e ANN, as variáveis NDWI, NDVI, Normalized Difference Snow Index (NDSI) e NDBI para prever a LST. Deste modo percebe-se a relação entre fatores determinantes para previsão de LST e características principalmente físicas (clima e relevo) de cada área de interesse dos estudos, localizados em sua maioria na região tropical-equatorial do planeta.

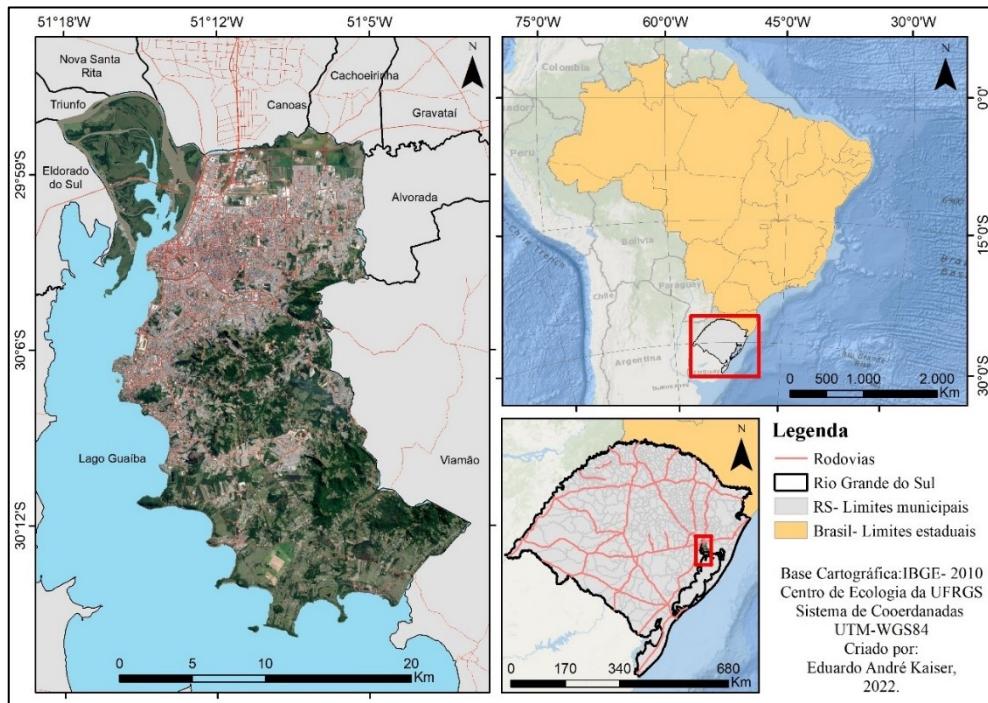
Em áreas subtropicais, essencialmente no sul da América existe carência de estudos voltados para previsão de LST, que com diagnóstico, estimativas e monitoramento podem fornecer informações acerca da formação das UHI. Assim possibilitam medidas mitigatórias e tomadas de decisões apuradas como subsídio para planejadores urbanos e gestores dos recursos naturais. Portanto, o presente estudo tem como objetivo avaliar os impactos das mudanças de LULC sobre a LST nos anos de 1995, 2006 e 2017 e modelar cenários futuros destes utilizando os algoritmos CA-ANN e índices de LULC para o município de Porto Alegre-RS, sul do Brasil.

METODOLOGIA

Área de estudo

Como área de estudo utilizou-se o limite territorial do município de Porto Alegre, Rio Grande do Sul, localizado no extremo sul do Brasil (Figura 1). A população total alcançou a marca de aproximadamente 1,5 milhões em 2021 que com uma área de 496,682 km² resulta na densidade demográfica de 3.005 hab/km² (IBGE, 2021). A área urbana do município é de 306,36 km² (Embrapa, 2015).

Figura 6. Mapa de localização da área de estudo correspondente ao limite territorial do município de Porto Alegre, Rio Grande do Sul, Brasil.



Fonte: Dos autores.

O espaço urbano do município está submetido a intenso processo de metropolização o qual teve início em 1945 e se estende até os dias atuais, marcado pela ocorrência de verticalização da cidade com início na década de 90 (MENEGAT et al., 1999). Porto Alegre é conhecida, no Brasil, como a capital da melhor qualidade de vida e um dos índices utilizados para avaliar esta faz referência a gestão ambiental que, segundo os autores mencionados, tem destaque pela extensiva arborização da área urbana com mais de 1 milhão de árvores em vias públicas, 8 parques verdes e cerca de 350 praças de recreação.

O crescimento populacional do município assumiu taxas expressivas até 1970, quando a população já alcançava 903.175 habitantes. A partir da década de 1980 o caráter de ocupação passou a predominar sobre a área urbana quando comparada a área rural, marcada pela expansão urbana principalmente sobre uma área de colinas graníticas, caracterizada por entornos de estreitas faixas de planície junto ao lago Guaíba. Frente as limitações impostas pelo relevo (áreas elevadas de alta declividade e planícies atingidas por inundação) o crescimento urbano se deu inicialmente sobre morros de altitudes medianas próximos a zona portuária, atual bairro Centro Histórico de Porto Alegre e ao longo da margem direita do lago Guaíba estendendo-se atualmente para praticamente metade da área do município. Ademais, a população que era de 1.158.709 habitantes em 1980, passou para

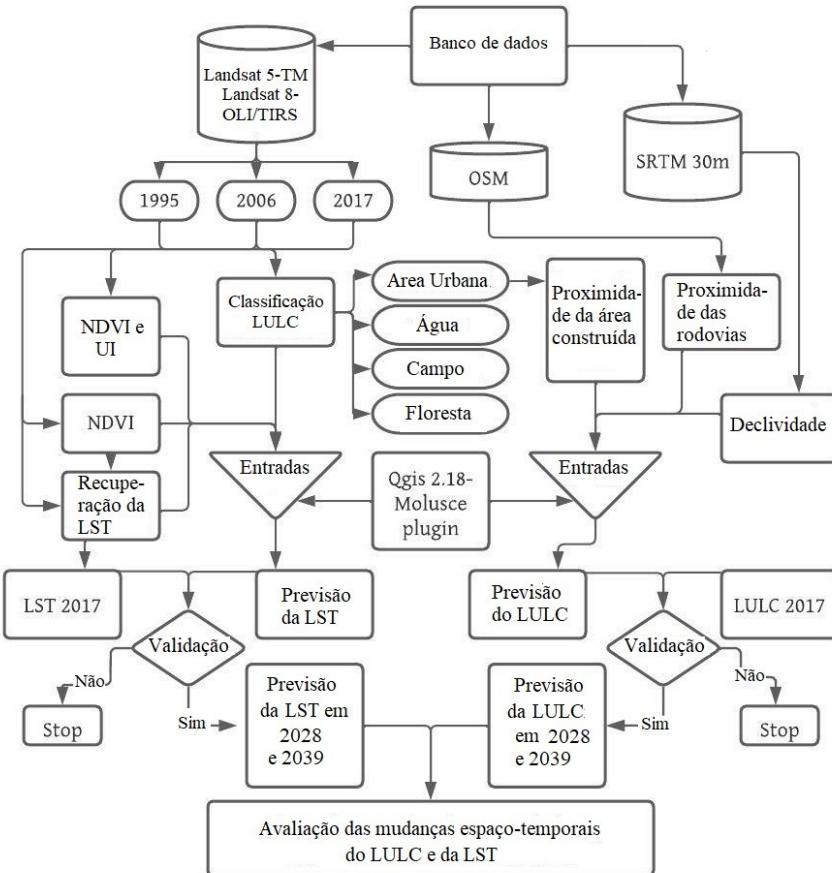
1.263.239 habitantes em 1991, 1.360.033 habitantes no ano de 2000 e 1.409.351 habitantes em 2010 (DIAS, 2011).

Materiais e Métodos

Os procedimentos metodológicos se deram em cinco etapas: 1. Classificação do LULC a partir de imagens do sensor TM do satélite Landsat 5 e do sensor OLI do satélite Landsat 8; 2. Recuperação da LST a partir do método de inversão da equação de transferência radiativa; 3. Preparo dos fatores determinantes como distância das estradas, declividade e distância da área construída para previsão do LULC, e NDVI, NDBI, UI e o próprio LULC para previsão da LST; 4. Análise de mudança e previsão do LULC e LST para os anos de 2028 e 2039 a partir da utilização de algoritmos CA-MC e ANN. Cada uma das etapas de processamento realizadas no presente estudo está exposta no fluxograma da Figura 2.

Tanto a classificação do LULC e seus índices (NDVI, NDBI e UI) quanto a recuperação da LST foram aplicadas sobre três imagens, obtidas pelos sensores orbitais nas seguintes datas: 01/11/1995, 01/12/2006 e 13/11/2017. Para o cálculo da declividade do terreno foi utilizada a imagem da missão *Shuttle Radar Topography Mission* (SRTM) com escala espacial de 30 metros. As imagens Landsat e SRTM são disponibilizadas gratuitamente através da plataforma da United States Geological Survey (USGS) (<https://earthexplorer.usgs.gov>). Como critério para definição das imagens buscou-se intervalos decanais, ausência de nuvens e a sazonalidade associada. Os dados da rede viária foram extraídos através da utilização do plugin *Open Street Maps* (OSM) no software *Quantum Gis* (QGIS) na versão 3.28.0. Os detalhes das imagens Landsat podem ser observados na Tabela 1.

Figura 2. Fluxograma dos procedimentos metodológicos utilizados no presente estudo.



Fonte: Autores (2023).

Tabela 1. Detalhes das imagens utilizadas no presente estudo.

Date	Sensor	Cloud cover (%)
01 de novembro de 1995	Landsat 5 TM	~1.0%
01 de dezembro de 2006	Landsat 5 TM	~1.0%
13 de novembro de 2017	Landsat 8 OLI/TIRS	~0.18%

Fonte: Organização dos autores.

A classificação do LULC compreendeu a predefinição de quatro classes correspondentes aos tipos de coberturas existentes na área de estudo: área urbana, floresta, campo e água. A classe de área urbana compreendeu as ocupações comerciais, residenciais, industriais, solo em exposição e estradas. Além das coberturas florestais, a classe designada como floresta engloba também a vegetação arbustiva. A classe correspondente ao campo abrange as áreas de vegetação rasteira de gramíneas, típicas da área de estudo. Finalmente a classe de água faz referência aos corpos hídricos como rios, lagos e reservatórios.

O método supervisionado Maximum Likelihood foi utilizado para desenvolvimento da classificação do LULC (LILLESAND, KIEFER, CHIPMAN, 2004). O método apresenta acurácia para mapear superfícies com grande variedade de coberturas, assim como avaliar desenvolvimento urbano (RIMAL et al. 2017; RIJAL et al. 2018).

Para recuperar a LST das três imagens mencionadas anteriormente, o método descrito por Liu e zhang (2011) a partir do algoritmo single-channel foi aplicado. Dentre os diferentes algoritmos utilizados para recuperação da LST, como o *mono window algorithm* (QIN et al., 2001), *single-channel algorithm* (JIMÉNEZ-MUÑOZ et al., 2009), *radiation conduction equation* (LUO et al., 2012) and *split window algorithm* (ROZENSTEIN et al., 2014), a escolha do *single-channel* se deu devido a disponibilidade de uma única banda no infravermelho termal (banda 6) para o sensor TM-Landsat 5, um dos sensores utilizados no presente estudo.

A emissividade superficial foi recuperada a partir do NDVI (Equação 1) (ZHANG et al., 2006) para as quatro imagens obtidas nos dois sensores.

$$\text{NDVI} = \frac{\text{NIR}-\text{R}}{\text{NIR}+\text{R}} \quad (1)$$

Em que, NDVI é o Índice de Vegetação por Diferença Normalizada, NIR é o Infravermelho Próximo e RED é a faixa do espectro eletromagnético correspondente ao Vermelho. Uma vez calculados os valores de NDVI, a emissividade foi estimada a partir dos intervalos apresentados na Tabela 2.

Tabela 2. Relação entre o Índice de Vegetação por Diferença Normalizada e a Emissividade proposta por Zhang et. Al (2006).

NDVI	Emissividade de superfície (ϵ_i)
NDVI < -0.185	0.995
-0.185 ≤ NDVI < 0.157	0.970
0.157 ≤ NDVI ≤ 0.727	$1.0094 + 0.047\ln(\text{NDVI})$
NDVI > 0.727	0.990

Fonte: Adaptado de Zhang et al., (2006)

Uma vez estimada a emissividade, a inversão da Equação de Transferência Radiativa (RTE) (Equação 2) é aplicada a um determinado canal do sensor e intervalo de comprimento de onda.

$$L_{\text{sensor},\lambda} = [\epsilon_\lambda B_\lambda(T_s) + (1-\epsilon_\lambda) L_\lambda^\downarrow] r_\lambda + L_\lambda^\uparrow \quad (2)$$

Em que, L_{sensor} = radiância medida pelo sensor em $\text{Wm}^{-2} \mu\text{m}^{-1} \text{sr}^{-1}$, ε =emissividade da superfície terrestre (LSE) $B_\lambda(T_s)$ = Função de Planck dada pela Equação (3), L^\downarrow = radiação atmosférica descendente em $\text{W/m}^{-2} \mu\text{m}^{-1} \text{sr}^{-1}$, L^\uparrow = radiação atmosférica ascendente em $\text{W/m}^{-2} \mu\text{m}^{-1} \text{sr}^{-1}$, τ = transmitância atmosférica.

$$B_\lambda(T_s) = \frac{C1\lambda^5}{\exp(C2/\lambda\tau)-1} \quad (3)$$

Em que C1 e C2 são constantes de radiação de Planck, com valores de (cada tipo de sensor possui um valor).

A obtenção dos parâmetros atmosféricos utilizados na Equação 2 se deu através do acesso ao website da National Aeronautics and Space Administration (NASA) (<http://atmc当地>). Entretanto, como tais parâmetros são disponibilizados apenas a partir do ano 2000, para a recuperação da LST na imagem de 1995 foram utilizados valores de L^\downarrow , L^\uparrow and τ gerados pelo *Moderate Spectral Resolution Atmospheric Transmittance Algorithm and Computer Model* (MODTRAN) 4.0 v3r1 versão 1.2.

No intuito de avaliar e realizar a previsão de LST a partir de imagens de anos diferentes, foi necessária a aplicação da normalização *z-score* (SALAMA et al., 2012) (Equação 4). A imagem do ano de 2017 foi utilizada como referência nesta aplicação.

$$LST_{nj} = \left(\frac{LST_j - \bar{LST}_j}{LST_{\sigma j}} \right) LST_{\sigma i} + \bar{LST}_i \quad (4)$$

onde e- a nível de pixel, LST_{nj} são os valores LST normalizados para o ano j (no caso, 1995 ou 2006); LST_j são os valores de LST da imagem original antes da normalização; \bar{LST}_j é o valor de LST médio da imagem a ser normalizada (1995 ou 2006); $LST_{\sigma j}$ é o desvio padrão dos valores de LST da imagem a ser normalizada (1995 ou 2006); $LST_{\sigma i}$ é o desvio padrão dos valores de LST da imagem de referência ($i = 2017$); e \bar{LST}_i é a média dos valores de LST da imagem de referência (2017).

No intuito de preparar as entradas para simulação da LST para os anos de 2028 e 2039, foram calculados os índices de LULC. A equação de cada um dos índices é dependente das bandas dos sensores Landsat 5-TM e Landsat 8-OLI (Tabela 3).

Tabela 3. Índices utilizados para realizar a previsão da LST para 2028 e 2039. NDVI: normalized difference vegetation index (Tucker, 1979); NDBI: normalized difference built-up index (Zha et al., 2003); UI: urban index (Kawamura, 1996).

Índice de LULC	Equation	
	Landsat 5	Landsat 8
NDVI	B4–B3/B4+B3	B5–B4/B5+B4
NDBI	B5–B4/B5+B4	B6–B5/B6+B5
UI	B7–B4/B7+B4	B7–B5/B7+B5

Fonte: Organização dos autores.

Existem vários métodos tanto de previsão do LULC (TRIANTAKONSTANTIS e MOUNTRAKIS, 2012) como da LST (FAHIMI NEZHAD, FALLAH GHALHARI e BAYATANI, 2019; NURWANDA e HONJO, 2020; KHALIL et al., 2021). No presente estudo o plugin MOLUSCE (do inglês *Modules for Land Use Change Evaluation*) foi utilizado a partir do software QGIS. Tal *plug-in* é composto por elementos de entrada (módulo de *inputs*, avaliação da correlação, análise da tendência de mudança), previsão (métodos de modelagem) e validação (avaliação da acurácia da simulação) (KAFY et al., 2020).

As variáveis de entrada (*inputs*) correspondem aos elementos dependentes e independentes. Neste caso, para simulação do LULC (dependente) foram selecionadas as variáveis correspondentes a distância das estradas, distância da área construída e declividade (independentes) (KAMARAJ e RANGARAJAM, 2022), e na simulação da LST, o NDVI, NDBI, UI e LULC. As variáveis independentes foram selecionadas de acordo com aquelas comumente utilizadas para simulações de LULC e LST (MUSHORE et al., 2017; ULLAH et al., 2019; KAFY et al., 2021; HALDER, BANDYOPADHYAY e BANIK, 2021) e que apresentam relação com a área de estudo.

Uma vez que o MOLUSCE realiza a modelagem de variáveis categóricas, as imagens LST de 1995, 2006 e 2017 foram classificadas em intervalos de temperatura: <25°C, 25 até <30, 30 até <35, 35 até 40 e >40°C. Os intervalos foram definidos no intuito de possibilitar a comparação da LST em diferentes anos, visto que estes apresentam amplitudes térmica distintas. Tanto a resolução espacial quanto a projeção cartográfica das variáveis dependentes e independentes citadas anteriormente, devem ser as mesmas.

Os mapas de uso e cobertura da terra e temperatura de superfície de 1995 e 2006 foram usados para a simulação do LULC e LST de 2017. O modelo ANN foi selecionado como método potencial de transição, onde a vizinhança a ser considerada foi de 1 pixel, ou seja 3 x 3 (9 células), taxa de

aprendizagem de 0,001, máximo de 100 interações, 12 camadas ocultas e 0,05 de *momentum*. Assim a partir do modelo CA-ANN a simulação foi criada e os dados estão preparados para validação.

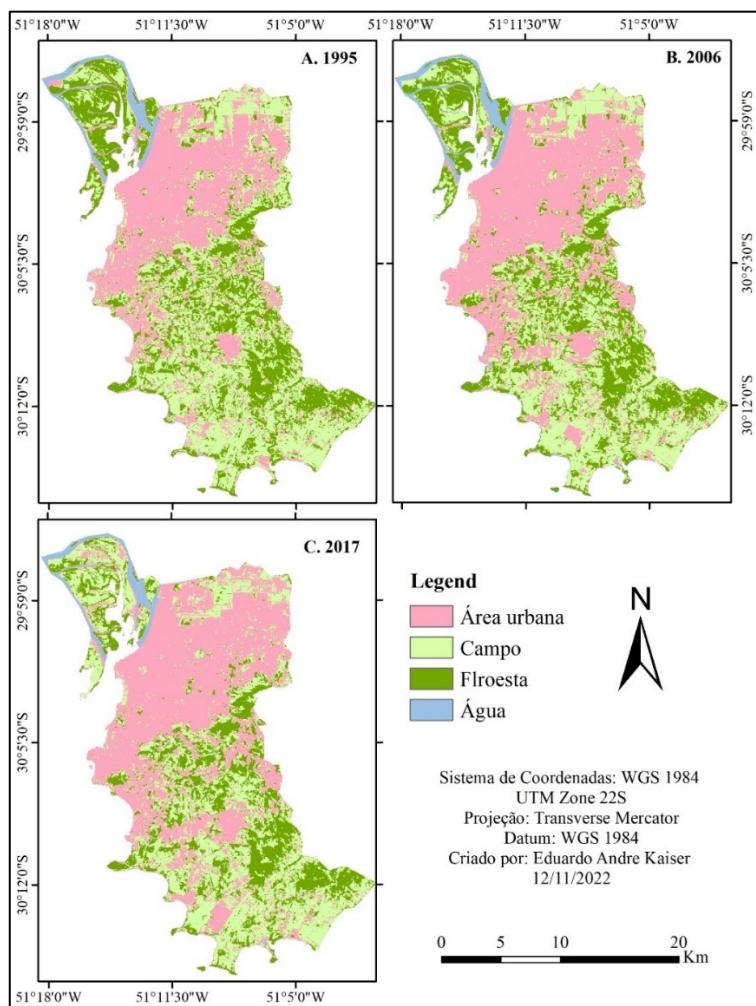
O último passo compreende a comparação estatística entre os mapas de LULC e LST simulados e observados para o ano de 2017 a partir do processo de validação oferecido pelo MOLUSCE. Neste processo, o módulo calcula a porcentagem de acerto, *Kappa overall* (acurácia total do número de pixels corretamente classificados entre o mapa de referência e simulado), *Kappa histogram* (estimativa de frequência de distribuição da simulação) e *Kappa location* (teste de habilidade da simulação em especificar perfeitamente as localidades entre os mapas de referência e simulados). Valores de Kappa entre 0,61 e 0,80 indicam a concordância moderada entre os mapas enquanto aqueles entre 0,81 e 1,00 indicam concordância quase perfeita (LANDIS e KOCH, 1997). Somente após a validação realizada a simulação foi aplicada para os instantes seguintes, no caso, a previsão de 2028 e 2039, a partir dos padrões passados de LULC e LST da área de estudo.

RESULTADOS E DISCUSSÃO

Análise das mudanças de uso e cobertura da terra

O mapeamento do uso e cobertura da terra (LULC) nos anos de 1995, 2006 e 2017 foi realizado a partir da classificação de quatro classes, designadas como área urbana, campo, floresta e água. De acordo com os mapas de LULC da Figura 3 é possível observar a tendência de crescimento urbano e consequente redução das áreas cobertas por vegetação. No intervalo de 1995 a 2017 tal crescimento foi de ~10% (Tabela 4) principalmente sobre as áreas de floresta e campo que reduziram ~6% e 4%, respectivamente, em relação a totalidade da área de estudo. Em estudo de modelagem da relação entre LULC e LST realizado na capital de Bangladesh, Dhaka, Kafy et al., (2021) verificaram o incremento de 13,84% das superfícies urbanizadas e consequente retirada da cobertura vegetal, cuja redução foi de 5,26%. As causas de tais mudanças, segundo os autores, estão associadas ao êxodo rural, desenvolvimento aleatório das infraestruturas e expansão urbana sem planejamento aliada ao crescimento da população nestas áreas.

Figura 3. Mapas de uso e cobertura da terra dos anos de 1995(A), 2006(B) e 2017(C).



Fonte: Dos autores.

A tabela 3 apresenta a evolução espacial de cada um dos tipos de LULC ao longo das três imagens classificadas. Em intervalos de onze anos entre as imagens, o maior crescimento urbano foi de 5,23% no intervalo de 2006 a 2017, o que corresponde ao aumento de ~2548 hectares. No intervalo de 1995 a 2006 este aumento foi de 4,93%, ou seja, ~2398 hectares. Por sua vez as áreas classificadas como floresta quantificaram a maior redução no intervalo de 2006 a 2017, de 4,06% (-1978,38 hectares) enquanto as áreas de campo tiveram a maior redução entre 1995 e 2006, 3,73%. As mudanças das áreas classificadas como água estiveram associadas a ocorrência de lavouras de cultivo do arroz, nos extremos norte e sul da área de estudo.

Tabela 3. Quantificação da área (ha) e percentual de cada um dos tipos de uso e cobertura da terra em 1995, 2006 e 2017.

Classes de LULC	1995		2006		2017	
	Area em ha	%	Area em ha	%	Area em ha	%
Área urbana	16544,52	34,0	18943,11	38,9	21491,28	44,1
Campo	18243,54	37,5	16426,62	33,7	16294,68	33,5
Floresta	12690,54	26,1	11742,39	24,1	9764,01	20,0
Água	1221,12	2,5	1587,60	3,3	1149,75	2,4

Fonte: Dos autores.

A expansão urbana ocasionou a conversão de superfícies permeáveis (áreas de floresta e campo) em impermeáveis (áreas urbanas), conforme exposto na Tabela 4. No intervalo de 1995 a 2006 aproximadamente 21,11% (3852,09 hectares) das áreas de campo e 5,94% (755,01 hectares) das áreas de floresta foram convertidos para ocupação urbana. Entre 2006 e 2017 essa conversão foi menor, de 20,06% (3295,44 hectares) e 5,60% (658,08 hectares), respectivamente. A mudança geral observada para o intervalo de 1995 até 2017 permitiu quantificar a transição de 5457,51 hectares de campo (29% das áreas de campo de 1995) e 1294,02 hectares de floresta (10,19% das áreas de floresta de 1995) para o uso urbano.

Tabela 4. Transição dos diferentes tipos de LULC para áreas urbanas.

Transformação para área urbana	Área em hectares		
	1995 -2006	2006-2017	1995-2017
Área urbana (sem mudança)	14329.08	17134.02	14622.75
Campo para área urbana	3852.09	3295.44	5457.51
Floresta para área urbana	755.01	658.08	1294.02
Água para área urbana	6.93	403.74	117.00

Fonte: Dos autores.

A matriz de transição das classes de LULC para os períodos 1995-2006 (Tabela 5), 2006-2017(Tabela 6) e 1995-2017 (Tabela 7) foram geradas a partir do plugin *Molusce*. Na matriz de transição de 1995-2006 as classes correspondentes a área urbana e água apresentaram maior estabilidade, 0,87 e 0,98, respectivamente, enquanto campo e floresta diminuíram com probabilidade de transição de 0,68 e 0,76, respectivamente e contribuíram 0,21 e 0,06 para a área urbana. Durante 2006-2017 (Tabela 6), a área urbana apresentou 0,90 de estabilidade enquanto as classes de campo, floresta e água apresentaram 0,72, 0,71 e 0,72, respectivamente. O campo e floresta contribuíram 0,20

e 0,06 para a área urbana. A contribuição de 0,25 da água para área urbana se deu devido a dois fatores principais: a ocorrência de lavouras de arroz em fases de cultivo distintas em 2006 e 2017, onde a presença da água e/ou exposição do solo (tipo de uso considerado como urbano no presente estudo) variam e; áreas alagadas localizadas no noroeste do município, onde o rio Jacuí caracteriza seu delta, que apresentam variação ao longo dos anos devido as oscilações de precipitação pluviométrica. A matriz de transição geral, 1995-2017 a estabilidade das classes área urbana e água, com 0,88 e 0,90. Destaque se dá na contribuição das classes de campo e floresta para a área urbana, de 0,30 e 0,10, respectivamente.

Tabela 5. Matriz de transição das classes de uso e cobertura da terra de 1995 a 2006.

	Área urbana	Campo	Floresta	Água
Área urbana	0.87	0.10	0.01	0.02
Campo	0.21	0.68	0.10	0.00
Floresta	0.06	0.17	0.76	0.00
Água	0.01	0.01	0.00	0.98

Fonte: Dos autores.

Tabela 6. Matriz de transição das classes de uso e cobertura da terra de 2006 a 2017.

	Área urbana	Campo	Floresta	Água
Área urbana	0.90	0.09	0.00	0.00
Campo	0.20	0.72	0.08	0.00
Floresta	0.06	0.23	0.71	0.00
Água	0.25	0.02	0.01	0.72

Fonte: Dos autores.

Tabela 7. Matriz de transição das classes de uso e cobertura da terra de 1995 a 2017.

	Área urbana	Campo	Floresta	Água
Área urbana	0.88	0.10	0.01	0.00
Campo	0.30	0.61	0.09	0.00
Floresta	0.10	0.27	0.62	0.00
Água	0.10	0.00	0.00	0.90

Fonte: Dos autores.

Análise das mudanças de temperatura de superfície

Imagens do sensor TM-Landsat 5 correspondentes ao verão de 1995 e 2006 e TIRS-Landsat 8 do verão de 2017 foram utilizadas para quantificação das mudanças espaciais e temporais de LST da

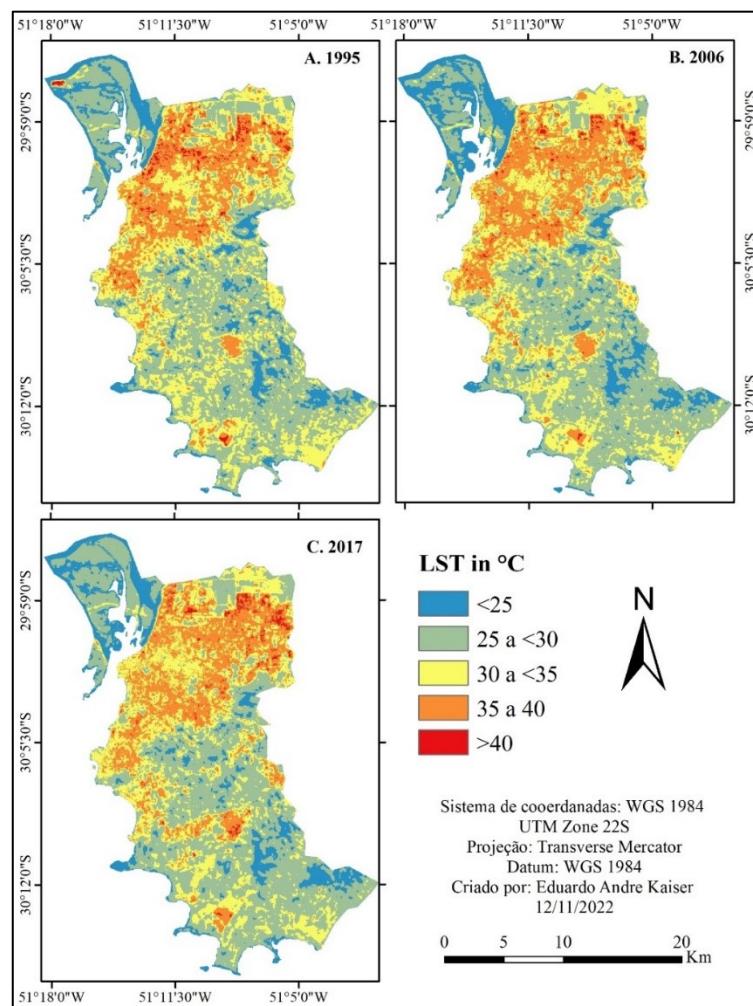
área de estudo. Posterior ao processo de normalização dos valores de LST de 1995 e 2006 com base na imagem de 2017, estes foram divididos em cinco intervalos (<25 , $25-30$, $30-35$, $35-40$, e >40) e na sequência computadas as áreas de abrangência bem como as matrizes de transição entre os anos. Nos mapas da Figura 4 é possível observar a distribuição espacial dos intervalos e evolução temporal ao longo dos três anos quando os valores de LST foram recuperados.

A Tabela 8 apresenta a área (em hectares) e a porcentagem de cobertura em relação a área de estudo dos intervalos de LST. Entre 1995 e 2006 as áreas com LST <25 aumentaram 1,82% (884,70 hectares), entretanto aquelas com LST entre 35 e 40 aumentaram 1,95% (de ~8075 hectares para ~9024 hectares). Destaque se dá para a redução de 2,36% (~1147 hectares) e 1% (~486 hectares) nas áreas correspondentes ao intervalo de 30 a <35 , e 25 a <30 , respectivamente. No intervalo de 2006 a 2017 as áreas com LST <25 reduziram 1,51% (de ~5922 hectares para ~5186 hectares) e entre 25 e <30 aumentaram 1,82%, o que aponta o aquecimento das áreas comuns nos dois anos. As áreas com LST de 30 a <35 reduziram 0,58% (~280 hectares) e aquelas entre 35 e 40, e acima de 40 aumentaram 0,08% (~38 hectares) e 0,19% (~92 hectares), respectivamente. A mudança geral de 1995 a 2017 quantificou o aumento de 2,03% (~987 hectares) nas áreas correspondentes a LST entre 35 e <40 e a redução de 2,93% naquelas entre 30 e <35 . Mudanças menores foram observadas nas áreas de LST <25 , 25 a 30 e >40 , com aumento de 0,31% e 0,82% nas duas primeiras e redução de 0,22% na última.

Os intervalos de LST observados na Tabela 8 cujas temperaturas são características das áreas urbanas e entornos não urbanizados, entre 30°C e 40°C, apresentaram as maiores mudanças no que se refere a área de abrangência no período de 22 anos (1995 -2017). Provavelmente estas mudanças estão associadas ao efeito das áreas vizinhas com presença de vegetação sobre o resfriamento das periferias urbanizadas e, entornos urbanizados influenciam no aquecimento das superfícies vegetadas próximas, como pode ser observado nos mapas da Figura 4. Esse efeito pode ser melhor estudado em pesquisas futuras aliado a análise das condições meteorológicas locais, principalmente o vento, precipitação pluviométrica e temperatura do ar.

A evolução espaço-temporal caracterizou o aumento das áreas de LST mais baixo e diminuição daquelas com LST mais alto. Somadas, as áreas de temperatura entre <25 e <30 quantificaram 53,3% da área de estudo em 1995, 54,1% em 2006 e 54,4% em 2017 enquanto no intervalo classificado de 30 a >40 as áreas foram 46,7%, 45,9% e 45,6%, respectivamente. Comparados os mapas das figuras 3 e 4 é possível afirmar que estas áreas, correspondentes aos intervalos de classes de LST que tiveram aumento, predominam sobre as superfícies onde ocorreram vegetação de campo e floresta, enquanto as áreas que sofreram redução ao longo do tempo predominam sobre as superfícies urbanizadas.

Figura 4. Mapas de Temperatura da Superfície Terrestre dos anos de 1995(A), 2006(B) e 2017(C).



Fonte: Dos autores.

Tabela 8. Quantificação da área (ha) e percentual de cada uma das classes de LST em 1995, 2006 e 2017.

Classes de LST	1995		2006		2017	
	Área em ha	%	Área em ha	%	Área em ha	%
<25	5037.93	10.3	5922.63	12.2	5186.70	10.7
25 a <30	20917.26	43.0	20430.81	42.0	21316.68	43.8
30 a <35	14044.68	28.8	12897.36	26.5	12616.65	25.9
35 a 40	8075.52	16.6	9024.39	18.5	9062.91	18.6
>40	624.33	1.3	424.53	0.9	516.78	1.1

Fonte: Dos autores.

Avaliação da transição da temperatura de superfície

Assim como realizado no cálculo da matriz de transição das classes de LULC, através do MOLUSCE obtiveram-se as matrizes para 1995-2006 (Tabela 9), 2006-2017 (Tabela 10) e 1995-2017 (Tabela 11). A transição das classes de LST de 1995-2006 (Tabela 11) aponta a estabilidade das áreas que apresentaram temperaturas <25°C (0,79), 25 a <30°C (0,75) e 35 a 40°C (0,79). As áreas com LST de 30 a <35°C tiveram uma contribuição de 0,25 para a classe de 25 a <30°C, ou seja, uma redução na temperatura e de 0,14 para a classe de 35 a 40°C, ou seja, áreas que tiveram aumento na temperatura. As áreas que tiveram LST >40°C por sua vez tiveram uma maior contribuição na classe de 35 a 40°C, de 0,69, vista a menor estabilidade (0,24) que pode ser observada na transição. Assim, o destaque se dá no aquecimento das áreas com LST <25°C e de 25 a <30°C, e resfriamento daquelas com intervalo de 30 a 35°C, 35 a 40°C e >40°C.

Tabela 9. Matriz de transição das classes de LST de 1995 a 2006.

Classes de LST	<25°C	25 a <30°C	30 a <35°C	35 a 40°C	>40°C
<25°C	0.79	0.20	0.01	0.00	0.00
25 a <30°C	0.09	0.75	0.14	0.01	0.00
30 a <35°C	0.00	0.25	0.61	0.14	0.00
35 a 40°C	0.00	0.01	0.17	0.79	0.03
>40°C	0.00	0.04	0.04	0.69	0.24

Fonte: Dos autores.

Assim como no intervalo de 1995 a 2006 (Tabela 9), a matriz de transição de 2006 a 2017 (Tabela 10) quantificou áreas das classes <25°C e 25 a <30°C com aumento de temperatura e redução nas classes 30 a 35°C, 35 a 40°C e >40°C, porém em diferentes proporções e estabilidades. Com estabilidade menor (0,69) em relação a 1995-2006, a classe <25°C apresentou a contribuição de 0,31 para o intervalo 25 a <30°C, 0,11 a mais que no intervalo de 11 anos anterior. A menor estabilidade da transição pode ser observada na classe >40°C, de 0,40, assim como a maior contribuição para a classe de 35 a 40°C, de 0,58.

Tabela 10. Matriz de transição das classes de LST de 2006 a 2017.

Classe de LST	<25°C	25 a <30°C	30 a <35°C	35 a 40°C	>40°C
<25°C	0.69	0.31	0.00	0.00	0.00
25 a <30°C	0.05	0.84	0.10	0.01	0.00
30 a <35°C	0.00	0.18	0.68	0.14	0.00
35 a 40°C	0.00	0.01	0.19	0.76	0.04

>40°C	0.00	0.00	0.02	0.58	0.40
-----------------	------	------	------	------	-------------

Fonte: Dos autores.

A matriz de transição geral, ou seja, que avaliou a transição entre o início (1995) e final (2017) do período, caracterizou um cenário de transição semelhante aos demais períodos avaliados, conforme esperado. Entretanto as classes de LST que apresentaram menor estabilidade (30 a <35°C e >40°C) quantificaram uma maior contribuição sobre as classes de temperatura menor, o que qualifica o resfriamento destas superfícies ao longo do período. Maior destaque é dado para as áreas com LST acima de 40°C em 1995 que tiveram estabilidade de 0,16 para 2017 e contribuíram com 0,71 para aquelas com LST entre 35 e 40°C. Assim como a classe de 30 a <35°C (estabilidade de 0,54) contribuiu com 0,28 para a classe 25 a <30°C, e de 0,25 na transição de 35 a 40°C para 30 a <35°C, no mesmo período. Como ressaltado anteriormente, tal redução ocorreu principalmente sobre as superfícies urbanizadas, onde temperaturas mais elevadas em relação aos entornos vegetados são comuns.

Tabela 11. Matriz de transição geral das classes de LST de 1995 a 2017.

Classe de LST	<25°C	25 a <30°C	30 a <35°C	35 a 40°C	>40°C
<25°C	0.72	0.27	0.01	0.00	0.00
25 a <30°C	0.07	0.76	0.14	0.03	0.00
30 a <35°C	0.00	0.28	0.54	0.17	0.01
35 a 40°C	0.00	0.02	0.25	0.70	0.04
>40°C	0.00	0.04	0.09	0.71	0.16

Fonte: Dos autores.

Relação entre uso e cobertura da terra e temperatura de superfície

Os valores de LST mínimo, máximo e média dos anos de 1995, 2006 e 2017 foram calculados para cada uma das classes de LULC e expostos na Tabela 12. A análise espacial de cada uma das imagens permitiu quantificar os maiores valores de LST das áreas urbanas em relação as áreas de campo e floresta nos três anos. A diferença entre a média de LST das superfícies urbanizadas (área urbana) e vegetadas (campo e floresta) foi de 5,58°C em 1995, 7,03°C em 2006 e 6,93°C em 2017. Esse contraste que aumentou ao longo dos anos pode ser caracterizado como efeito da formação das Ilhas de Calor Urbanas, onde as temperaturas de determinada região são significativamente mais quentes que os entornos.

Tabela 12. Distribuição do LST sobre diferentes classes de LULC para os anos de 1995, 2006 e 2017.

Classes de LULC	1995 -LST(°C)			2006 - LST(°C)			2017 -LST (°C)		
	Min	Max	Mean	Min	Max	Mean	Min	Max	Mean
Área urbana	20.60	44.08	33.19	23.02	47.76	36.37	22.25	46.80	33.99
Campo	22.23	40.36	29.20	23.85	41.75	30.95	22.79	40.36	28.46
Floresta	21.54	35.36	26.02	23.58	36.93	27.73	22.69	33.04	25.67
Água	20.60	31.67	22.45	21.88	34.57	24.25	22.29	29.96	23.54

Fonte: Dos autores.

Temporalmente, a amplitude térmica se manteve em torno dos 24°C na área urbana dos três anos, porém um aumento de 1,65°C e 2,72°C e 0,79°C pode ser observado na mínima, máxima e média LST, respectivamente, entre as imagens de 1995 e 2017. Cabe ressaltar o aumento de 3,17°C entre 1995-2006 e a redução de 2,38°C entre 2006-2017 para as respectivas médias das áreas urbanas. Assim, no primeiro intervalo de onze anos ocorreu um maior aumento da LST média das áreas urbanas comparado ao aumento ocorrido ao longo de todo o período. Tal comportamento pode estar relacionado a redução das áreas de campo (~1816 hectares), especialmente nos entornos da área urbana, que ocorreu durante este período cuja contribuição se deu campo-área urbana (Tabela 4) foi de 0,21.

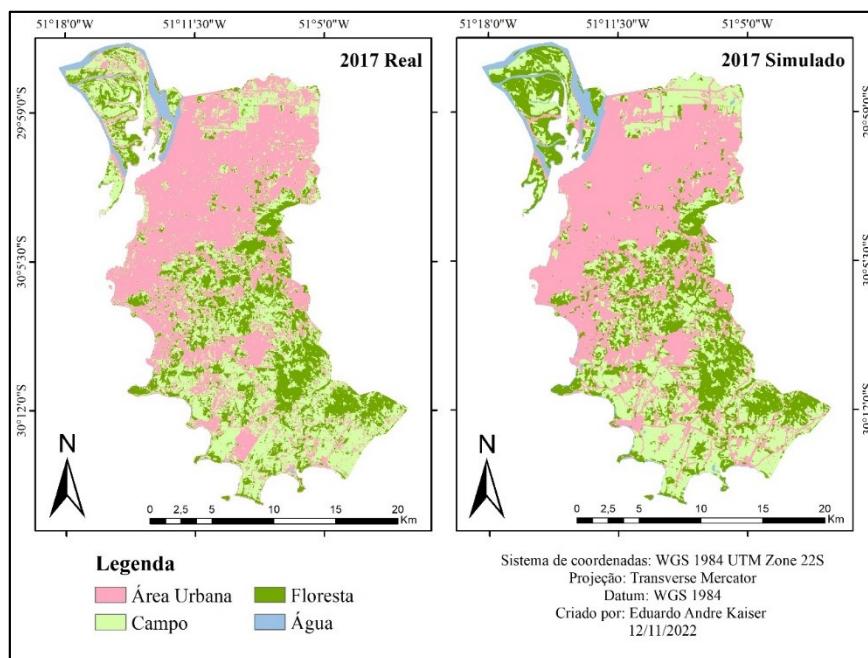
Modelagem do LULC e LST para os anos de 2028 e 2039

Após o cálculo da matriz de transição de 1995-2006 das classes tanto de LULC quanto de LST, ainda por meio do plug-in Molusce foi realizada a simulação de 2017. Assim, a abordagem CA-ANN utilizada pelo plug-in emprega os dados raster de LULC de 1995 e 2006 junto com as variáveis espaciais (declividade, distância da área construída e distância das estradas) no caso da previsão de LULC e dados de LST de 1995 e 2006 junto com variáveis espaciais (LULC, NDVI, NDBI e UI) para previsão de LST. Posteriormente a simulação de LULC e LST de 2017, o processo de validação consistiu na comparação entre os mapas reais classificados e simulados, conforme exposto na Figura 5, e assim medidos os índices Kappa (geral, histograma e localização) e a porcentagem de precisão.

A simulação do LULC de 2017 alcançou a porcentagem de precisão de 77,6%, Kappa geral de 0,66, Kappa histograma de 0,93 e Kappa localização de 0,71. Os valores de validação são considerados aceitáveis conforme diversos estudos de previsão do LULC (ULLAH et al., 2019; ANEESHA et al., 2020; ALAM et al., 2021; MUHAMMAD et al., 2022). Assim, pode-se concluir que as variáveis determinantes correspondentes a declividade, distância da área construída e distância das estradas tem uma grande influência na previsão do LULC do município de Porto Alegre.

A comparação entre as áreas correspondentes a cada uma das classes de LULC na classificação real e simulada de 2017 (Tabela 13) quantificou a menor diferença na classe de área urbana (-0,96%) e maior sobre o campo (-3,60%) e floresta (3,43%). As áreas classificadas como água tiveram uma diferença de 1,14% entre o real e simulado. Assim obtidas medidas de acurácia satisfatórias (porcentagem de precisão, Kappa geral) e menores diferenças entre classes simuladas e reais, o modelo foi ajustado para os instantes seguintes, 2028 e 2039, conforme exposto na Figura 6.

Figura 7. Mapas de uso e cobertura da terra real e simulado para o município de Porto Alegre em 2017.



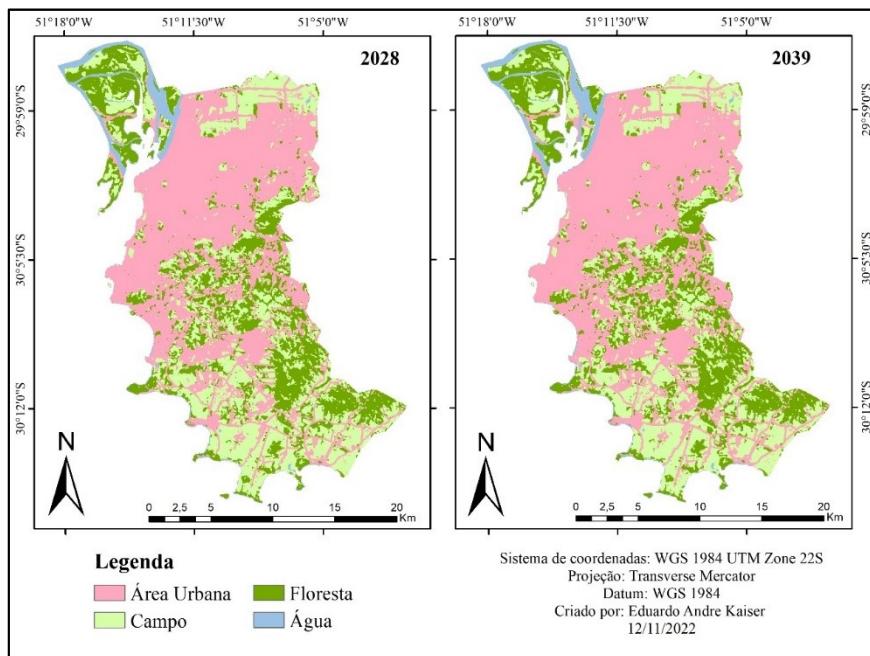
Fonte: Dos autores.

De maneira geral, o município de Porto Alegre apresentou crescimento urbano maior durante a série histórica avaliada se comparado com as projeções futuras de 2028 e 2039. O crescimento observado sobre as superfícies urbanizadas em relação a área de estudo, entre 1995-2017, foi de 10,16% (de 16544,5 hectares em 1995 para 21491,3 hectares em 2017) e entre 2017-2039 foi de 2,32%. Resultados semelhantes foram observados em estudo realizado por Muhammad et al., (2022) na cidade de Linyi, província de Shandong-China, onde o modelo CA-ANN adaptado no MOLUSCE previu crescimento urbano de 34,36% para 34,50% entre 2030 e 2040 e redução no período 2040-2050, de 34,50% para 30,75%.

Em contraste com o crescimento urbano, as áreas de campo tiveram uma redução ao longo de todos os períodos, entretanto menor durante o intervalo 1995-2017 (4%) (Tabela 3) comparado com o intervalo previsto 2017-2039 (6,67%) (Tabela 15). Visto o aumento nas áreas de floresta (3,16%) durante 2017-2028, pressupõe-se que o crescimento das áreas urbanizadas deverá ocorrer

principalmente sobre as áreas de campo que neste período que tiveram uma redução de 5,81%. As principais consequências da mudança de superfícies permeáveis por impermeáveis abrangem alterações nas trocas de calor, no processo de evapotranspiração e condições meteorológicas locais, e assim o aumento da temperatura (MUSHORE et al., 2017; HALDER, BANDYOPADHYAY e BANIK, 2021; ULLAH et al., 2022).

Figura 6. Mapas de uso e cobertura da terra simulados para o município de Porto Alegre em 2028 e 2039.



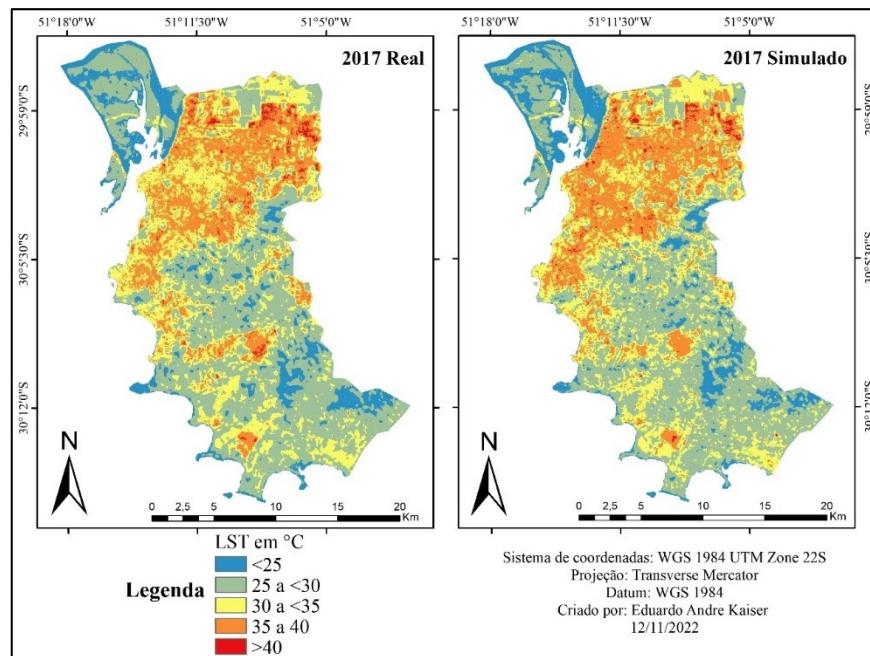
Fonte: Dos autores.

Assim como na previsão de LULC, imagens de 1995 e 2006 foram utilizadas para simular a LST do município de Porto Alegre em 2017. Após este procedimento, a imagem real de LST de 2017 foi utilizada para validação. Os mapas correspondentes as imagens de 2017, real e simulado podem ser observadas na Figura 7. A porcentagem de precisão entre as imagens (validação) foi de 74,67%, Kappa geral de 0,64, Kappa histograma de 0,97 e Kappa localização de 0,66. Em relação a área de estudo, a menor diferença entre a áreas correspondentes as classes de LST reais e simuladas em 2017 foi de 0,19% (~92 hectares), em áreas com LST >40°C e a maior diferença foi de 1,79% (~870 hectares) nas áreas de LST entre 35 e 40°C, conforme exposto na Tabela 16. Essa diferença foi de 0,5%, 1,24% e 0,86% nas classes de <25°C, de 25 a <30°C e de 30 a <35°C, respectivamente.

A Figura 8 mostra os mapas de LST simulados para 2028 e 2039 e as estatísticas zonais são apresentadas na Tabela 14. O maior aumento, em termos de área de abrangência, ocorreu na classe de 35 a 40°C no período de 2017 a 2028 (2,39%), de ~9062 hectares (2017) para ~10225 hectares (2028). De 2028 para 2039 esse aumento foi de 0,25 (122,40 hectares). Estes resultados corroboram

com o maior crescimento urbano previsto (Tabela 13) no intervalo 2017-2028 (1,41%) se comparado com o intervalo 2028-2039 (0,92%). Assim fica evidente o aumento das áreas de LST características das superfícies impermeáveis, que no presente estudo caracterizaram aumento no cenário de previsão, principalmente dos próximos 11 anos. Resultado semelhante pode ser observado em estudo realizado por Ashwini e Sil (2022) na região do Cachar, noroeste da Índia, cuja previsão apontou crescimento de 9,48% das áreas com LST igual e superior a 35°C entre 2020 e 2030, e de 1,16% entre 2030 e 2040. Neste estudo, o crescimento urbano previsto para a década seguinte (2020-2030) foi de 2,34 % e de 0,69% na próxima (2030-2040).

Figura 7. Mapas de Temperatura de Superfície real e simulado para o município de Porto Alegre em 2017.



Fonte: Dos autores.

Tabela 13. Mudanças de uso cobertura da terra em relação área total de estudo entre 2017 real e simulado, e nos períodos de 2017 real-2028 e 2028-2039.

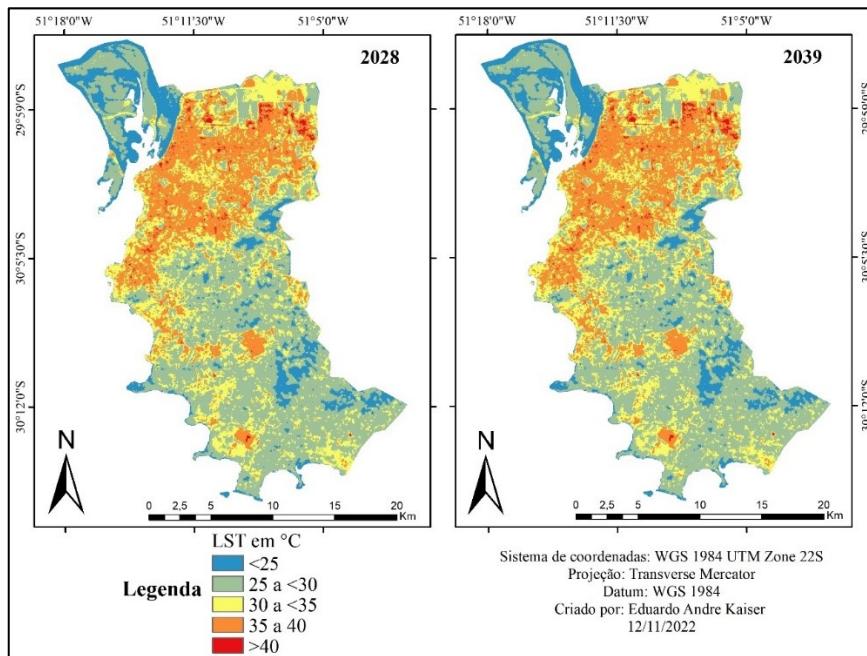
Classes de LULC	2017 Simulado - 2017 real		2017 real-2028		2028-2039	
	Δ (ha)	%	Δ (ha)	%	Δ (ha)	%
Área urbana	-468.81	-0.96	684.99	1.41	446.4	0.92
Campo	-1753.65	-3.60	-2830.95	-5.81	-415.35	-0.85
Floresta	1668.6	3.43	1538.82	3.16	-88.74	-0.18
Água	553.86	1.14	607.14	1.25	57.69	0.12

Fonte: Dos autores.

Enquanto as áreas com LST entre 35 e 40°C apresentaram o maior aumento no primeiro intervalo de 11 anos (2,39%), a maior redução pode ser observada nas áreas de LST entre 30 e <35°C.

Dada a redução de 0,02% nas áreas correspondentes ao intervalo 25 a <30°C, pressupõe-se a existência de uma relação entre a redução de 2,34% na classe de 30 a <35°C e o aumento de 2,39% das áreas da classe de 35 a 40°C. Variações menores foram observadas nas classes com LST <25°C e >40°C tanto no intervalo 2017-2028 quanto 2028-2039.

Figura 8. Mapas de Temperatura de Superfície simulados para o município de Porto Alegre em 2028 e 2039.



Fonte: Dos autores.

Tabela 14. Mudanças de Temperatura de Superfície em relação área total de estudo entre 2017 real e simulado, e nos períodos de 2017 real-2028 e 2028-2039.

Classes de LST	2017 Simulado - 2017 real		2017 real-2028		2028-2039	
	Δ (ha)	%	Δ (ha)	%	Δ (ha)	%
<25	243.99	0.50	78.57	0.16	-78.03	-0.16
25 a <30	-601.83	-1.24	-8.82	-0.02	181.17	0.37
30 a <35	-420.30	-0.86	-1139.49	-2.34	-225.36	-0.46
35 a 40	870.57	1.79	1162.44	2.39	122.40	0.25
>40	-92.43	-0.19	-92.70	-0.19	-0.18	0.00

Fonte: Dos autores.

Quando comparadas as áreas correspondentes a LST menor de 30°C (soma das áreas classificadas como <25°C e 25 a <30°C) e acima de 35°C (soma das áreas de 35 a 40°C e >40°C) percebe-se o aumento das áreas de temperaturas inferiores (menor de 30°C). Em 2017 54,42% da área de estudo resultou em LST menor de <30°C, 54,56% em 2028 e 54,77% em 2039. Enquanto que aquelas áreas com LST acima de 35°C quantificaram 45,57% em 2017, 45,43% em 2028 e 45,22% em 2039.

CONCLUSÕES

O objetivo do presente estudo foi avaliar e prever a evolução espaço-temporal do Uso e Cobertura da Terra e da Temperatura de Superfície no município de Porto Alegre. Imagens Landsat do verão de 1995, 2006 e 2017 e modelo CA-ANN a partir do software Molusce-Qgis foram utilizados na previsão do LULC e LST de 2028 e 2039. Os resultados mostram o crescimento urbano de 10,16% e redução de 10,01% nas áreas de cobertura vegetal, no período de 1995 a 2017. Como consequência deste crescimento, as áreas de LST elevadas e típicas de superfícies impermeáveis, entre 35 e 40°C, caracterizaram o aumento de 2,03%. O crescimento urbano previsto para 2017-2028 foi de 1,41% e 0,92% para 2028-2039, enquanto as áreas com LST entre 35 e 40°C devem crescer 2,39% já no primeiro intervalo de 11 anos (2017-2028) e 0,25% no seguinte (2028-2039).

Embora as áreas de LST entre 35 e 40°C tenham aumentado e devem seguir aumentando ao longo do período de 1995-2039, verificou-se também o aumento das áreas de baixo LST, especificamente menores que 30°C. Apesar destas últimas ocorrerem em maior escala de abrangência na zona rural do município e sobre os corpos hídricos, cabe ressaltar também a sua ocorrência na área urbana, como pequenos núcleos de resfriamento. Tal resultado está atribuído a antiga preocupação ambiental convergente ao planejamento urbano existente no município. Porto Alegre foi o primeiro município a nível nacional a criar a Secretaria Municipal do Meio Ambiente em 1976, que aliada ao Plano Diretor de Desenvolvimento Urbano de 1979, exigiam a ocupação de 2% dos loteamentos para parques verdes. Vinte anos depois o município já contava com um índice de áreas verdes (índice que expressa a quantidade de espaços livres de uso público pela quantidade habitantes residentes em determinada cidade) de 13,35m²/hab. Atualmente a arborização viária caracteriza patrimônio ambiental do município.

Como a previsão aponta uma tendência de aumento nas áreas de LST elevadas, entre 35 e 40°C, para 2028 e 2039, algumas estratégias e soluções de planejamento urbano devem ser definidas. Primeiro, é de fundamental importância a manutenção e preservação dos parques verdes e da arborização viária localizados na área urbana, afim de manter o efeito de resfriamento que pode ser observado no presente estudo em termos de microclima. Segundo, a descentralização urbana pode ser uma solução para atenuar os efeitos da formação das Ilhas de Calor, visto que as áreas onde houveram maior concentração de superfícies impermeáveis, principalmente nos centros urbanos, apresentaram os valores superiores de LST em relação aos entornos menos urbanizados. Deste modo o crescimento urbano esperado deve continuar sendo monitorado, e os produtos de sensoriamento remoto se mostraram de grande valia para avaliar e prever alterações na superfície bem como no comportamento térmico.

Algumas limitações deste trabalho e recomendações futuras não devem ser negligenciadas. Primeiro, o modelo CA-ANN utilizado no Molusce, considerado como “caixa preta”, apresenta algumas funções automatizadas independentes da apuração do operador, como a relação entre os fatores determinantes e a produção e início das amostras de treinamento (Van Gerven and Bohte, 2017). Além disso, o sistema não possibilita a ponderação individual de cada uma das camadas de entrada (Shatnawi e Abu Qdais, 2019). Um modelo também incluso no Molusce e que utiliza pesos de evidência (que permite ponderar os parâmetros de entrada) poderia ser utilizado para comparação com o modelo CA-ANN, no intuito de avaliar o melhor desempenho para a área de estudo. Segundo, a previsão tanto do LULC quanto da LST não levou em consideração fatores socioeconômicos da área de estudo. Pesquisas futuras podem relacionar o crescimento populacional, poder aquisitivo, valor das propriedades, por exemplo, por distritos e uma vez espacializados, inserir como uma das variáveis determinantes das previsões. Terceiro, dados e informações territoriais podem enriquecer a entrada do modelo, como por exemplo a ocorrência de áreas protegidas, principalmente localizadas em áreas urbanas.

Agradecimentos

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de doutorado concedida ao primeiro autor.

Referências bibliográficas

ALAM, Nasibul 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.

ANEESHA, Satya, ; SHASHI, M.; DEVA, Pratap. Future land use land cover scenario simulation using open source GIS for the city of Warangal, Telangana, India. **Applied Geomatics**, v. 12, n. 3, p. 281-290, 2020.

ARNFIELD, A. John. Two decades of urban climate research: a review of turbulence, exchanges of energy and water, and the urban heat island. **International Journal of Climatology: a Journal of the Royal Meteorological Society**, v. 23, n. 1, p. 1-26, 2003.

ASHWINI, Kumar; SIL, Briti Sundar. Impacts of Land Use and Land Cover Changes on Land Surface Temperature over Cachar Region, Northeast India—A Case Study. **Sustainability**, v. 14, n. 21, p. 14087, 2022.

CHOUDHURY, Deblina; DAS, Kalikinkar; DAS, Arifit. Assessment of land use land cover changes and its impact on variations of land surface temperature in Asansol-Durgapur Development Region. **The Egyptian Journal of Remote Sensing and Space Science**, v. 22, n. 2, p. 203-218, 2019.

- CIVCO, Daniel L. Artificial neural networks for land-cover classification and mapping. **International journal of geographical information science**, v. 7, n. 2, p. 173-186, 1993.
- DENG, Yuanhong et al. Relationship among land surface temperature and LUCC, NDVI in typical karst area. **Scientific reports**, v. 8, n. 1, p. 1-12, 2018.
- DEY, Nataraj Narayan et al. Geospatial modelling of changes in land use/land cover dynamics using Multi-layer perception Markov chain model in Rajshahi City, Bangladesh. **Environmental Challenges**, v. 4, p. 100148, 2021.
- DIAS, Tielle Soares. **A Expansão da Ocupação Urbana sobre o Relevo do Município de Porto Alegre - RS**. Trabalho de Graduação – Instituto de Geociências, Departamento de Geografia. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.
- EMBRAPA- Empresa Brasileira de Pesquisa Agropecuária. Áreas Urbanas no Brasil em 2015. Disponível em: http://geoinfo.cnpm.embrapa.br/layers/geonode%3Aareas_urbanas_br_15#more. Acesso em: 03 de dezembro de 2022.
- FAHIMI NEZHAD, Elham; FALLAH GHALHARI, Gholamabbas; BAYATANI, Fateme. Forecasting maximum seasonal temperature using artificial neural networks “Tehran case study”. **Asia-Pacific Journal of Atmospheric Sciences**, v. 55, n. 2, p. 145-153, 2019.
- FERRARO, Lilian Waquil; HASENACK, Heirich. Avaliação das variáveis climáticas de superfície do Baixo Jacuí, RS. **Progress Report**, v. 6, 1995.
- FU, Peng; WENG, Qihao. Responses of urban heat island in Atlanta to different land-use scenarios. **Theoretical and applied climatology**, v. 133, n. 1, p. 123-135, 2018.
- GHARAIBEH, Anne et al. Improving land-use change modeling by integrating ANN with Cellular Automata-Markov Chain model. **Heliyon**, v. 6, n. 9, p. e05092, 2020.
- GIANNAROS, Christos et al. A comprehensive approach for the simulation of the Urban Heat Island effect with the WRF/SLUCM modeling system: The case of Athens (Greece). **Atmospheric Research**, v. 201, p. 86-101, 2018.
- GOGOI, Partha Pratim et al. Land use and land cover change effect on surface temperature over Eastern India. **Scientific reports**, v. 9, n. 1, p. 1-10, 2019.
- GOHAIN, Kashyap Jyoti; MOHAMMAD, Pir; GOSWAMI, Ajanta. Assessing the impact of land use land cover changes on land surface temperature over Pune city, India. **Quaternary International**, v. 575, p. 259-269, 2021.
- GRIGORAS, Georgiana; URIȚESCU, Bogdan. Land use/land cover changes dynamics and their effects on surface urban heat island in Bucharest, Romania. **International Journal of Applied Earth Observation and Geoinformation**, v. 80, p. 115-126, 2019.
- HADI, Sinan Jasim; SHAFRI, Helmi ZM; MAHIR, Mustafa D. Modelling LULC for the period 2010-2030 using GIS and Remote sensing: a case study of Tikrit, Iraq. In: **IOP conference series: earth and environmental science**. IOP Publishing, 2014. p. 012053.

HALDER, Bijay; BANDYOPADHYAY, Jatisankar; BANIK, Papiya. Evaluation of the climate change impact on urban heat island based on land surface temperature and geospatial indicators. **International Journal of Environmental Research**, v. 15, n. 5, p. 819-835, 2021.

HALDER, Bijay; BANDYOPADHYAY, Jatisankar; BANIK, Papiya. 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**, v. 74, p. 103186, 2021.

HASHEM, Nadeem; BALAKRISHNAN, Perumal. Change analysis of land use/land cover and modelling urban growth in Greater Doha, Qatar. **Annals of GIS**, v. 21, n. 3, p. 233-247, 2015.

HASHIM, Bassim Mohammed et al. Effect of land use/land cover changes on land surface temperature during 1984–2020: A case study of Baghdad city using landsat image. **Natural Hazards**, v. 112, n. 2, p. 1223-1246, 2022.

HIRANO, Y.; FUJITA, T. Evaluation of the impact of the urban heat island on residential and commercial energy consumption in Tokyo. **Energy**, v. 37, n. 1, p. 371-383, 2012.

IBGE, Instituto Brasileiro de Geografia e Estatística. Estimativas da população residente no Brasil e Unidades da Federação com data de referência em 1º de julho de 2021, 2021. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/9103-estimativas-de-populacao.html?=&t=resultados>. Acesso em: 03 de dezembro de 2022.

KAFY, Abdulla-Al et al. Modeling the relationship between land use/land cover and land surface temperature in Dhaka, Bangladesh using CA-ANN algorithm. **Environmental Challenges**, v. 4, p. 100190, 2021.

KAFY, Md S. et al. Modelling future land use/land cover changes and their impacts on land surface temperatures in Rajshahi, Bangladesh. **Remote Sens. Appl. Soc. Environ.**, v. 18, p. 100314, 2020.

KAMARAJ, Manikandan; RANGARAJAN, Sathyananthan. Predicting the future land use and land cover changes for Bhavani basin, Tamil Nadu, India, using QGIS MOLUSCE plugin. **Environmental Science and Pollution Research**, p. 1-12, 2022.

KAWAMURA, Makoto. Relation between social and environmental conditions in Colombo Sri Lanka and the urban index estimated by satellite remote sensing data. In: **Proc. 51st Annual Conference of the Japan Society of Civil Engineers**. 1996. p. 190-191.

KHALIL, Umer et al. Time Series Analysis of Land Surface Temperature and Drivers of Urban Heat Island Effect Based on Remotely Sensed Data to Develop a Prediction Model. **Applied Artificial Intelligence**, v. 35, n. 15, p. 1803-1828, 2021.

LAI, Li-Wei; CHENG, Wan-Li. Air quality influenced by urban heat island coupled with synoptic weather patterns. **Science of the total environment**, v. 407, n. 8, p. 2724-2733, 2009.

LAI, Li-Wei; CHENG, Wan-Li. 0> urban heat island and air pollution—an emerging role for hospital respiratory admissions in an urban area. **Journal of environmental health**, v. 72, n. 6, p. 32-36, 2010.

LANDIS, J. Richard; KOCH, Gary G. The measurement of observer agreement for categorical data. **biometrics**, p. 159-174, 1977.

LEITE, P. F.; KLEIN, R. M. **Vegetação**. Levantamento de recursos naturais. Rio de Janeiro: IBGE, 1990.

MAIMAITIYIMING, Matthew et al. Effects of green space spatial pattern on land surface temperature: Implications for sustainable urban planning and climate change adaptation. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 89, p. 59-66, 2014.

MENDELSON, Robert et al. Climate analysis with satellite versus weather station data. **Climatic Change**, v. 81, n. 1, p. 71-83, 2007.

MENEGAT, Rualdo et al. **Atlas Ambiental de Porto Alegre**. Ed. da UFRGS, 1999.

MOAZZAM, Muhammad Farhan Ul; DOH, Yang Hoi; LEE, Byung Gul. Impact of urbanization on land surface temperature and surface urban heat Island using optical remote sensing data: A case study of Jeju Island, Republic of Korea. **Building and Environment**, v. 222, p. 109368, 2022.

MUHAMMAD, Rizwan et al. 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**, v. 11, n. 3, p. 419, 2022.

MUSHORE, Terence Darlington et al. Prediction of future urban surface temperatures using medium resolution satellite data in Harare metropolitan city, Zimbabwe. **Building and Environment**, v. 122, p. 397-410, 2017.

NEOG, Rituraj. Evaluation of temporal dynamics of land use and land surface temperature (LST) in Agartala city of India. **Environment, Development and Sustainability**, v. 24, n. 3, p. 3419-3438, 2022.

NURWANDA, Atik; HONJO, Tsuyoshi. The prediction of city expansion and land surface temperature in Bogor City, Indonesia. **Sustainable Cities and Society**, v. 52, p. 101772, 2020.

PIRACHA, Awais; CHAUDHARY, Muhammad Tariq. Urban air pollution, urban heat island and human health: a review of the literature. **Sustainability**, v. 14, n. 15, p. 9234, 2022.

PRIYADARSINI, Rajagopalan. Urban heat island and its impact on building energy consumption. **Advances in building energy research**, v. 3, n. 1, p. 261-270, 2009.

RAHAMAN, Khan Rubayet; AHMED, M. Razu; HASSAN, Quazi K. Using satellite-borne remote sensing data in generating local warming maps with enhanced resolution. **ISPRS International Journal of Geo-Information**, v. 7, n. 10, p. 398, 2018.

SALAMA, Mhd et al. Decadal variations of land surface temperature anomalies observed over the Tibetan Plateau by the Special Sensor Microwave Imager (SSM/I) from 1987 to 2008. **Climatic Change**, v. 114, n. 3, p. 769-781, 2012.

SANTÉ, Inés et al. Cellular automata models for the simulation of real-world urban processes: A review and analysis. **Landscape and urban planning**, v. 96, n. 2, p. 108-122, 2010.

SAPUTRA, Muhammad Hadi; LEE, Han Soo. Prediction of land use and land cover changes for north sumatra, indonesia, using an artificial-neural-network-based cellular automaton. **Sustainability**, v. 11, n. 11, p. 3024, 2019.

SHATNAWI, Nawras; ABU QDAIS, Hani. Mapping urban land surface temperature using remote sensing techniques and artificial neural network modelling. **International Journal of Remote Sensing**, v. 40, n. 10, p. 3968-3983, 2019.

SIDDIQUE, Muhammad Amir et al. Assessment and simulation of land use and land cover change impacts on the land surface temperature of Chaoyang District in Beijing, China. **PeerJ**, v. 8, p. e9115, 2020.

SILVA, K. M. P. da. Análise da morfologia original do Arroio Dilúvio, município de Porto Alegre - RS. 2019. Mestrado em Geografia - Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2019.

SUERTEGARAY, Dirce Maria Antunes; MOURA, Nina Simone Vilaverde. Morfogênese do relevo do Estado do Rio Grande do Sul. **Rio Grande do Sul: paisagens e territórios em transformação. Porto Alegre: Editora da UFRGS, 2012. 2. ed. p. 11-26**, 2012.

TEIXEIRA, M. B. et al. **Levantamento de recursos naturais**. Rio de Janeiro: IBGE, 1986.

THAPA, Rajesh Bahadur; MURAYAMA, Yuji. Scenario based urban growth allocation in Kathmandu Valley, Nepal. **Landscape and Urban Planning**, v. 105, n. 1-2, p. 140-148, 2012.

TRAORE, Mamadou et al. Assessment of land use/land cover changes and their impacts on land surface temperature in Bangui (the capital of Central African Republic). **Environmental Challenges**, v. 4, p. 100114, 2021.

TRIANTAKONSTANTIS, Dimitrios; MOUNTRAKIS, Giorgos. Urban growth prediction: a review of computational models and human perceptions. 2012.

ULLAH, Siddique et al. Analysis and simulation of land cover changes and their impacts on land surface temperature in a lower Himalayan region. **Journal of environmental management**, v. 245, p. 348-357, 2019.

UN—United Nations, Department of Economic and Social Affairs, Population Division. 2022. World Population Prospects 2022, Online Edition. Disponível em: <https://population.un.org/wpp/>. Acesso em: 28 de outubro de 2022.

VAN GERVEN, Marcel; BOHTE, Sander. Artificial neural networks as models of neural information processing. **Frontiers in Computational Neuroscience**, v. 11, p. 114, 2017.

YUEN, Belinda; KONG, Leon. Climate change and urban planning in Southeast Asia. **SAPI EN. S. Surveys and Perspectives Integrating Environment and Society**, n. 2.3, 2009.

WENG, Qihao; LO, C. P. Spatial analysis of urban growth impacts on vegetative greenness with Landsat TM data. **Geocarto international**, v. 16, n. 4, p. 19-28, 2001.

ZHANG, Youshui et al. Analyzing the impacts of urbanization and seasonal variation on land surface temperature based on subpixel fractional covers using Landsat images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 4, p. 1344-1356, 2016.

ZENIL, Hector. Compression-based investigation of the dynamical properties of cellular automata and other systems. **arXiv preprint arXiv:0910.4042**, 2009.

ZHA, Yong; GAO, Jay; NI, Shaoxiang. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. **International journal of remote sensing**, v. 24, n. 3, p. 583-594, 2003.

ZHAO, Ziqi et al. Spatial variability and temporal heterogeneity of surface urban heat island patterns and the suitability of local climate zones for land surface temperature characterization. **Remote Sensing**, v. 13, n. 21, p. 4338, 2021.

4 CAPÍTULO IV. IMPACT ASSESSMENT OF URBAN GROWTH ON LAND SURFACE TEMPERATURE THROUGH CHANGES IN THE NORMALIZED DIFFERENCE VEGETATION INDEX USING LONG TERM LANDSAT SERIES DATA

Artigo submetido na revista *Journal of Applied Remote Sensing* (ISSN: 1931-3195) em 2023.

1 Impact assessment of urban growth on Land Surface Temperatures 2 using Normalized Difference Vegetation Index from Landsat imagery

3 Eduardo Andre Kaiser^{a,*}, Silvia Beatriz Alves Rolim^a, Atilio Efrain Bica Grondona^a,

4 Cristiano Lima Hackmann^a, Bijeesh Kozhikkodan Veettill^b

5 ^aFederal University of Rio Grande do Sul, State Center for Research in Remote Sensing and Meteorology, Porto
6 Alegre-RS, Brazil, 90040-060

7 ^bFaculty of Applied Technology, School of Engineering and Technology, Van Lang University, Ho Chi Minh City,
8 Vietnam, 700000

9 Abstract. This study was proposed to verify the impact of urban growth on Land Surface Temperatures (LST)
10 using variations in the Normalized Difference Vegetation Index (NDVI) over 30 years in Southern Brazil. A method
11 for evaluating the evolution of LST as a result of land use and land cover (LULC) changes (1989-2018) and time-
12 series NDVI classes of the study area was also proposed. The Landsat series (TM and OLI) were used for LULC
13 classification, calculating NDVI and LST retrieval. The k-means method was applied to create the NDVI classes (low,
14 moderate and high; k=3). Once the LST values were extracted from thermal data and NDVI, the relationship between
15 urbanization and LST variations was established. The urbanized area studied has shown an increase in LST from
16 1989-2018 as a result of areas with rapid urban growth and low NDVI. Nearly 89% of the vegetation in the study
17 area were removed between 1989 and 2018, causing an increase in low NDVI areas from 21% of the total urban area
18 to 43% during the same period, causing an increase of 1.12°C in the average LST during the same period. Spatial
19 analysis indicated priority areas for immediate attention by urban planners for mitigating the negative effects of urban
20 heat island formation, thereby affecting the population in terms of extreme microclimate events like temperature rise.

21 Keywords: NDVI clustering, LST, LULC, Urban planning, Urban Heat Islands.

22 *Eduardo Andre Kaiser, kaiser-eduardo@hotmail.com

23 1 Introduction

24 Climate change, associated with global warming and greenhouse gas emissions, is mainly caused
25 as a result of rapid urbanization process; approximately 97% of anthropogenic CO₂ emissions is
26 estimated as coming the urbanized areas which is only 2% of the total land area (estimated in
27 the 1990s).¹ This scenario becomes even more worrying when consider the increase in the urban
28 population, which in 1950 was 30%, 55% in 2018 and projected to be 68% in 2050.²

29 As a characteristic of urbanization, the replacement of vegetation cover by impermeable sur-
30 faces (e.g. roads, urban settlements) is responsible for affecting the degree of absorption of solar
31 radiation, albedo, evaporation rate, wind regime, and thereby modifying the atmospheric condi-
32 tions in urban areas drastically.³ In general, urban areas show higher temperatures compared to the

33 non-urbanized suburban areas and peripheries and this phenomenon is known as Urban Heat Island
34 (UHI) effect.^{4,5} The UHI phenomenon influences the quality of life in large cities due to health
35 implications, caused by thermal discomfort and respiratory problems derived from air pollution,
36 which can even lead to death.^{6,7} Heat wave events exacerbated by the occurrence of UHI have
37 become a public health issue in recent decades.^{8–10}

38 The installation of meteorological stations for the measurement of air temperatures is com-
39 monly used in metropolitan cities. However, due to the complexity of urban spatial arrangement
40 and the operational costs of maintaining meteorological stations, it is often difficult or even impos-
41 sible to cover large areas with required degree of detail. A feasible and cost-effective alternative
42 has been highlighted in the previously studies on the quantification of LST for both large and small
43 urban areas is the use of remote sensing (RS) applications. Satellite images can be used to retrieve
44 the LST and to map its spatial distribution;¹¹ LST is a variable which is directly related to the air
45 temperature.¹²

46 In addition to recovering the LST through the use of satellite images, it is possible to calcu-
47 late the Normalized Difference Vegetation Index (NDVI) and classify Land Use and Land Cover
48 (LULC), variables that directly influence the energy balance, the effect of surface cooling and
49 heating, and evapotranspiration in urban and rural areas.^{13,14} LULC changes affect LST due to
50 topographical and reflectance differences among surface cover types, which in turn causes differ-
51 ences in LST.¹⁵ Drastic changes in LULC arising from anthropogenic actions are one of the major
52 factors of climate change and also causes an increase in the concentration of greenhouse gases
53 in the atmosphere (Intergovernmental Panel on Climate Change -IPCC¹⁶). The presence and/or
54 absence of vegetation affects LST because of the variations in reflection and absorption of solar
55 radiation and regulating latent heat exchange.¹⁷ The NDVI is used directly in the determination of

56 surface emissivity, which in turn is an essential parameter for estimating the LST.^{18,19}

57 It is widely accepted that both mitigation measures and new methodologies are needed to di-
58 agnose and reduce the negative effects of the increase in LST resulting from rapid urbanization. In
59 recent decades, even though numerous works have been conducted on the subject, the research fo-
60 cus was mainly on large cities, such as São Paulo,²⁰ Tokyo,²¹ Bangkok,²² Inner Hanoi,²³ and Delhi
61 and Mumbai.²⁴ Thus, research on problems associated with heating aimed at small urban centres
62 can be used as pilot studies for the adoption of policies and specific solutions for this environmental
63 issues that affects the population. In light of rapid urban and population growth observed in recent
64 times, understanding the thermal behaviour of an urban area in the initial phase of development
65 (e.g. a small town) can prevent greater problems associated with vulnerability to temperature rise
66 in the future^{25,26}), particularly when the proportions and magnitudes of these can reach irreversible
67 impacts in terms of urban planning actions.

68 The LST values estimated using remote sensing are mainly dependent on the meteorological
69 conditions incident at a time and its proximity of date of passage of the satellite.²⁷⁻³⁰ In order to
70 establish the comparison and evolution of the LST values for different years, the present study used
71 the NDVI, since it presents less dependence on the conditions mentioned above when compared to
72 the greater correlation with the LST variable.³¹⁻³³ Thus, the analysis of the evolution of the LST
73 was conditioned to changes in LULC determined from the NDVI. The key objective of the present
74 study is to verify the impact of urban growth on LST through NDVI variations in an area that
75 has undergone intense LULC changes due to the implementation of social housing policies. Un-
76 derstanding the evolution and spatial distribution of LST, given its dependence on the presence/or
77 absence of vegetation, can help urban planners in adapting the thermal environment conditions of
78 cities to their inhabitants.

79 **2 Study site**

80 In this research, an urbanized land cover located in the city of Porto Alegre, in the state of Rio
81 Grande do Sul, Brazil, was considered as the study area (Figure 1). The criterion for defining the
82 study area was based on the availability of time-series satellite data from the mid-1980s, when the
83 area was predominantly occupied by vegetation (grasses or trees) and later changed to urbanized
84 areas recently. The study area ($51^{\circ}15'$ - $51^{\circ}20'$ W; $30^{\circ} 14'$ - $30^{\circ} 18'$ S) covers 534.61 hectares,
85 with population of approximately 120,000 inhabitants.³⁴ Currently, the study area partially occu-
86 pies the urban area of three districts (Aberta dos Morros, Hípica and Restinga) belonging to the
87 municipality of Porto Alegre, located from west to east.

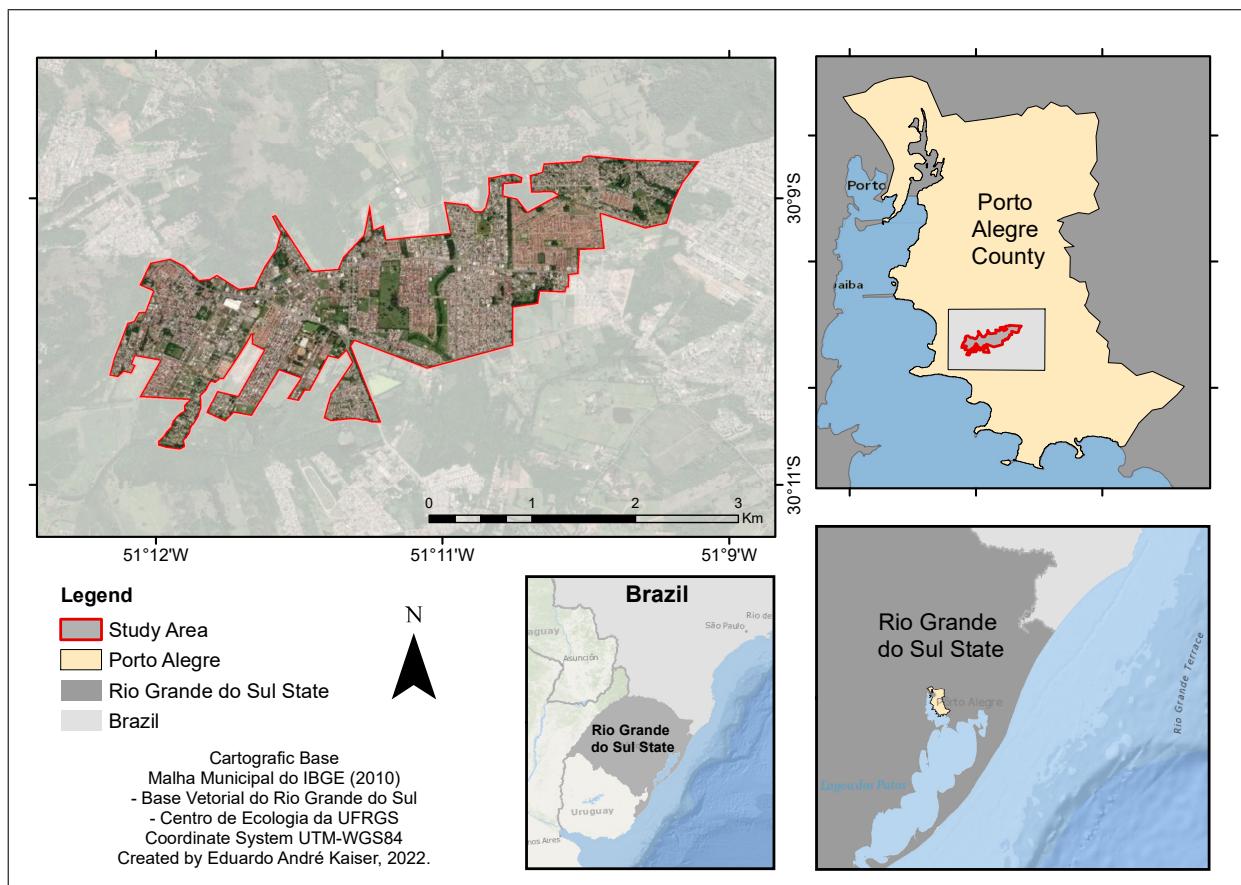


Fig 1 Location map of the study area in relation to the city of Porto Alegre, Rio Grande do Sul, Brazil.

88 The topography of Porto Alegre is characterized by a region of contact between the Uruguayan
89 Plateau of Rio Grande do Sul and the coastal plains and/or lowlands, in addition to sediments from
90 the Peripheral Depression.³⁵ In terms of elevation, the municipality of Porto Alegre has altitudes
91 ranging from 0.1m (Ilha das Flores) to 311.2 m (Morro Santana). The study area has altitudes
92 ranging from 14m in the Hípica (west end of the study area) to 21m in Restinga (east end of the
93 study area).

94 The climate of Porto Alegre is characterized as humid subtropical conditions due to its latitudi-
95 nal location (30°S) the distance of 100 km from the Atlantic Ocean. The key characteristics of this
96 type of climate is associated to the high variability of meteorological conditions throughout the
97 year. According to the Koeppen classification, it corresponds to the "cfa" subtype, whose average
98 annual temperature is nearly 19.5 °C and annual rainfall of 1,300 mm.³⁶

99 The LULC history of the 3 districts of the study area is associated with the appropriation of
100 space from the creation of small towns and industrial parks, where some constructions required a
101 certain standard. The Hípica district that covers most of the study area was officially created in
102 1991, the Restinga (eastern region of the study area) in 1990 and the Aberta dos Morros in 2016.
103 All of these study areas have two characteristics in common: accelerated urban growth and the
104 consequent loss of rural landscape with vegetation.³⁷

105 **3 Materials and Methods**

106 A seven-step methodological procedure has been followed in this study: 1). LULC classification
107 using Landsat-5 TM and Landsat-8/9 OLI images; 2). Extraction of the shapefile corresponding to
108 the urban area from each image; 3). Calculation of NDVI and LST estimation of urban areas; 4).
109 Analysis of the distribution of pixel by pixel NDVI in 1989 and 2018; 5). Grouping of data into 3

110 classes using the K-means method; 6). Extraction of the LST values of the samples corresponding
 111 to each of the groups and; 7). Comparative analysis between NDVI and LST groups, and quantifi-
 112 cation of spatiotemporal variation between variables. The flowchart given in Figure 2 shows the
 113 above-mentioned methodological steps applied in the present study..

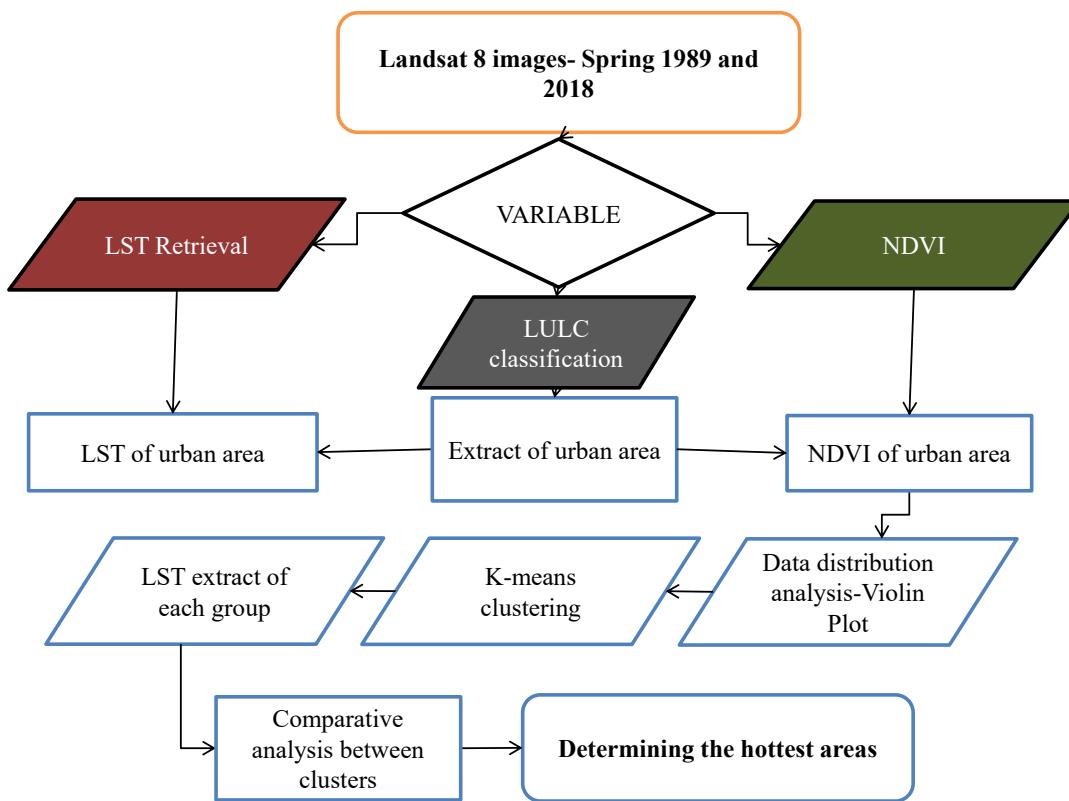


Fig 2 Flowchart of the methodological procedures used in the present study.

114 3.1 Land Use and Land Cover Classification

115 For LULC classification, the above-mentioned Landsat data during the spring season (09/29/1989
 116 – TM and 11/16/2018 – OLI/TIRS) were used. The criteria for defining the images were decadal
 117 intervals, absence of cloud cover and associated seasonality. A supervised Maximum Likelihood

¹¹⁸ Classification (MLC)³⁸ procedure was followed in the present study. MLC classifier has been used
¹¹⁹ in previous studies for the successful mapping of land cover changes and urban development.^{39,40}
¹²⁰ The LULC classes used comprised those (Forest, Urban Area, Grassland , and Exposed Soil)
¹²¹ visually verified on the study area.

¹²² *3.2 Land Surface Temperature Retrieval*

¹²³ The LSTs from the two previously mentioned images were obtained using the single-channel algo-
¹²⁴ rithm based on the method described in.⁴¹ using the single-channel Currently, different algorithms
¹²⁵ used to recover the LST from satellite data include mono window algorithm,⁴² single-channel al-
¹²⁶ gorithm,⁴³ radiation conduction equation⁴⁴ and split window algorithm.⁴⁵ The choice of the single-
¹²⁷ channel algorithm was due to the availability of a single band in the thermal infrared (band 6) for
¹²⁸ the Landsat5 TM, one of the sensors used in the present study. In addition, band 11 of the Infrared
¹²⁹ Thermal Sensor (TIRS) of the Landsat-8 satellite presents contamination (only band 10 was used
¹³⁰ in this study) by thermal energy outside the normal field of view (stray light effect) which is also
¹³¹ corroborated by the results of indirect calibration.⁴⁶

¹³² The surface emissivity was recovered from the NDVI (Equation 1)⁴⁷ for the two images ob-
¹³³ tained from the two sensors (TM, OLI/TIRS).

$$\text{NDVI} = \frac{\rho_{\text{nir}} - \rho_{\text{red}}}{\rho_{\text{nir}} + \rho_{\text{red}}} \quad (1)$$

¹³⁴ where NDVI is the Normalized Difference Vegetation Index, `nir` is the Near Infrared region, and
¹³⁵ `red` is the Red region.

¹³⁶ Once the NDVI values were calculated, the emissivity was estimated from the intervals shown
¹³⁷ in Table 1.

Table 1 Relation between Normalized Difference Vegetation Index (NDVI) and Emissivity proposed by.⁴⁷

NDVI	Land surface emissivity (ϵ_i)
NDVI < 0.185	0.995
0.185 ≤ NDVI < 0.157	0.970
0.157 ≤ NDVI ≤ 0.727	$1.009 - 4 + 0.047\ln(\text{NDVI})$
NDVI > 0.727	0.990

138 In addition to the effects of the atmosphere and the soil, the recovery of the LST from satellite
 139 data is complex as the terrestrial surface differs from a blackbody (a hypothetical body that emits
 140 electromagnetic radiation at all wavelengths) in view of its capacity for thermal emission (i.e., the
 141 emissivity of a material varies) as a result of temperature.^{48,49} Therefore, to recover the LST, in-
 142 version of the Radiative Transfer Equation (RTE) (Equation 2) is applied to a given sensor channel
 143 and wavelength range.

$$L(\text{sensor}, \lambda) = [\epsilon_\lambda B_\lambda(T_s) + (1 - \epsilon_\lambda)L_{atm,\lambda}^\downarrow]\tau_\lambda + L_{atm,\lambda}^\uparrow \quad (2)$$

144 where L_{sensor} is the radiance measured by the sensor in $W/m^{-2} m^{-1} sr^{-1}$, ϵ_λ is the land
 145 surface emissivity (LSE), $B_\lambda(T_s)$ is the Planck's function given by Equation 3, L^\downarrow is the descending
 146 atmospheric radiation in $W/m^{-2} m^{-1} sr^{-1}$, L^\uparrow is the ascending atmospheric radiation in W/m^{-2}
 147 $m^{-1} sr^{-1}$, and T is the atmospheric transmittance:

$$B_\lambda(T_s) = \frac{C1\lambda^{-5}}{(exp(C2/\lambda T) - 1)} \quad (3)$$

148 where $C1$ and $C2$ are Planck radiation constants, with values of (each type of sensor has a value).
 149 The atmospheric parameters (downwelling and upwelling atmospheric radiation and atmo-

150 spheric transmittance) used in Equation 2 were obtained from the National Aeronautics and Space
151 Administration (NASA) website (<http://atmcorr.gsfc.nasa.gov>, accessed on 15/08/2022).
152 To calculate these parameters, the following image information is inserted: time of passage of the
153 sensor, latitude, longitude, and season of the year. However, such parameters are available only
154 from the year 2000 onwards and, therefore, the values of L_{\downarrow} , L_{\uparrow} and T for the period between
155 1985 -1999 were generated using the Moderate Spectral Resolution Atmospheric Transmittance
156 Algorithm and Computer Model (MODTRAN) 4.0 v3r1 version 1.2.

157 *3.3 Spatiotemporal evolution of LST*

158 Once the LULC classification has been done using the satellite data, the class corresponding to the
159 urban areas was extracted and the pixel by pixel NDVI and LST values of these areas were esti-
160 mated simultaneously. Such procedures were performed using ArcGIS v.10.8 software package.

161 The NDVI values of the images referring to the spring of 1989 and 2018 were arranged in
162 a normal distribution using the violin and boxplot graphical layout. After analysing the density
163 (frequency) and dispersion of the data, the K-means grouping algorithm (Lloyd 1982) was applied.
164 The number of groups that the algorithm calculates was conditioned to the groupings verified in
165 the aforementioned graphic layout. The Student's t-test with a significance of 95% was applied in
166 order to verify whether the groups are statistically different. Since this test is dependent on equal
167 or different variances, the F statistics was previously calculated.

168 Since the relationship between vegetation areas and urban temperatures vary spatially,^{50,51} for
169 a comprehensive review of LST changes caused by urban growth, LST values were extracted
170 according to NDVI clusters, in pixel-by-pixel order. Thus, a comparative analysis was carried out
171 between the groups based on the mean, minimum and maximum values.

¹⁷² **4 Results and discussion**

¹⁷³ *4.1 Historical evolution of LULC and LST*

¹⁷⁴ The historical changes in LULC estimated for the study area showed that approximately 83% of
¹⁷⁵ the vegetation was removed in the period from 1989 to 2018. In addition, grassland and forest
¹⁷⁶ areas accounted 69% of the study area in 1989 (approximately 370 hectares) which has been
¹⁷⁷ changed to only 10% in 2018 (approximately 56 hectares), which is a reduction of 314 hectares
¹⁷⁸ of vegetation areas lost as a result of urbanization. It is worth mentioning the loss of areas covered
¹⁷⁹ specifically by forests, which in 1989 covered 77.2 hectares and in 2018 it was only 1.63 hectares.
¹⁸⁰ These changes can be observed from the LULC maps (1989 and 2018) and the graph, shown in
¹⁸¹ Figure 3.

¹⁸² Urban coverage has become more than double during the study period which is approximately
¹⁸³ 30 years. In 1989, urbanized area coverage comprised 165 hectares and in 2018 this figure has
¹⁸⁴ increased to 478 hectares, i.e. a 2.9-fold increase. In addition, urban growth took place not only in
¹⁸⁵ the periphery of urban areas (which in 1989 comprised approximately 51% of the study area and
¹⁸⁶ only 11% remained in 2018) but also in the forest areas, of which only 0.3% remained in 2018.

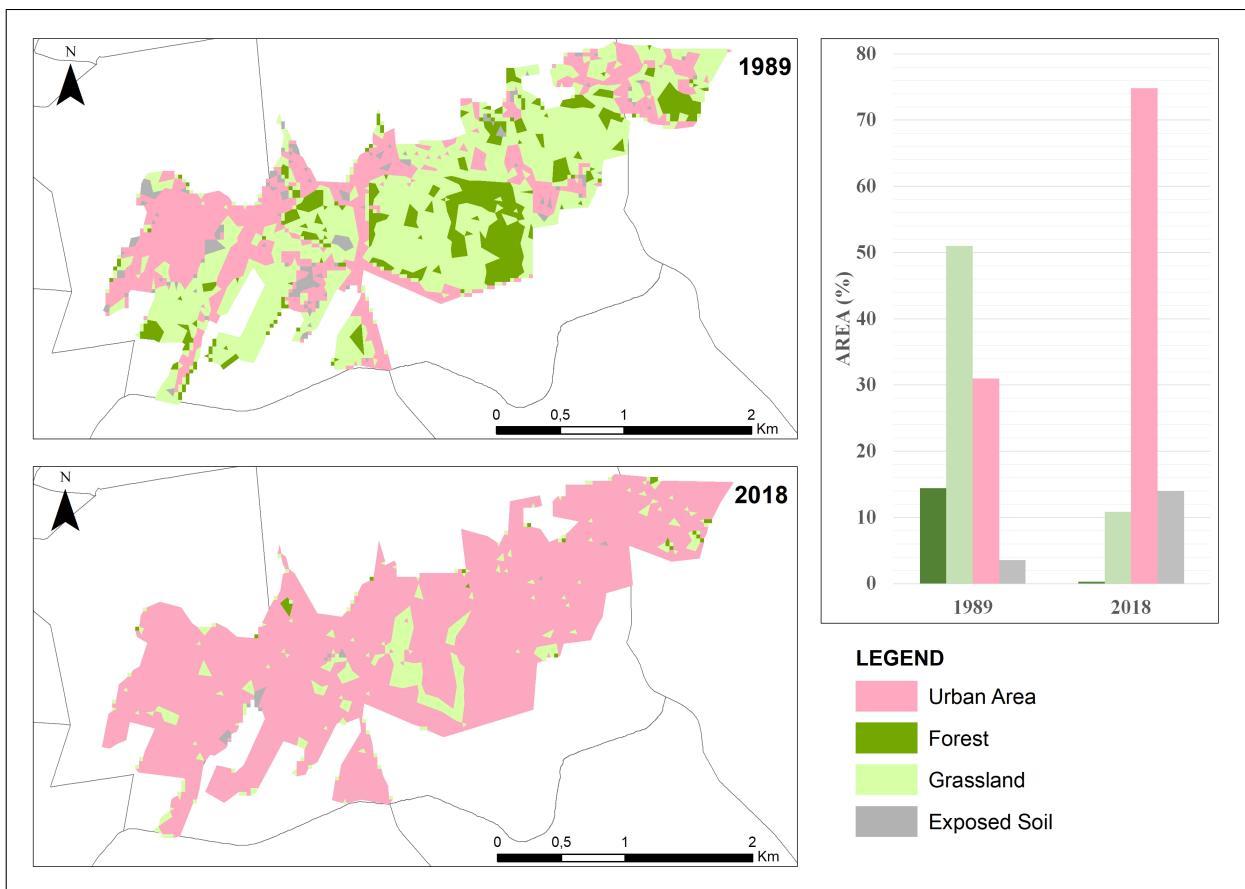


Fig 3 Maps and percentage areas of occupation of LULC classes in 1989 and 2018.

187 Another form of anthropic intervention on previously existing natural surfaces is through ex-
 188 posing the soil. From the maps in Figure 3, it is possible to observe the proximity of exposed soil
 189 areas and urban use, probably associated with soil preparation (clearing and grubbing) for the con-
 190 struction of urban structures that make up the urban growth. Compared to the other LULC classes,
 191 exposed soil areas showed the highest growth during the period studied, from approximately 19
 192 hectares in 1989 to 74.9 hectares in 2018, i.e., an increase of 3.9-fold increase in its area.

193 The removal of vegetation covers for anthropic activities led to a reduction in the average NDVI
 194 value of the study area. In 1989, NDVI average and its standard deviation accounted for 0.59 and
 195 0.15, respectively, which have been reduced to 0.40 and 0.18, respectively, in 2018. The negative

196 impacts of removing vegetation cover are widely addressed in previous studies in terms of a strong
197 negative correlation between NDVI and LST,⁵²⁻⁵⁴ where the reduction in NDVI caused by urban
198 occupation resulted in an increase in LST.

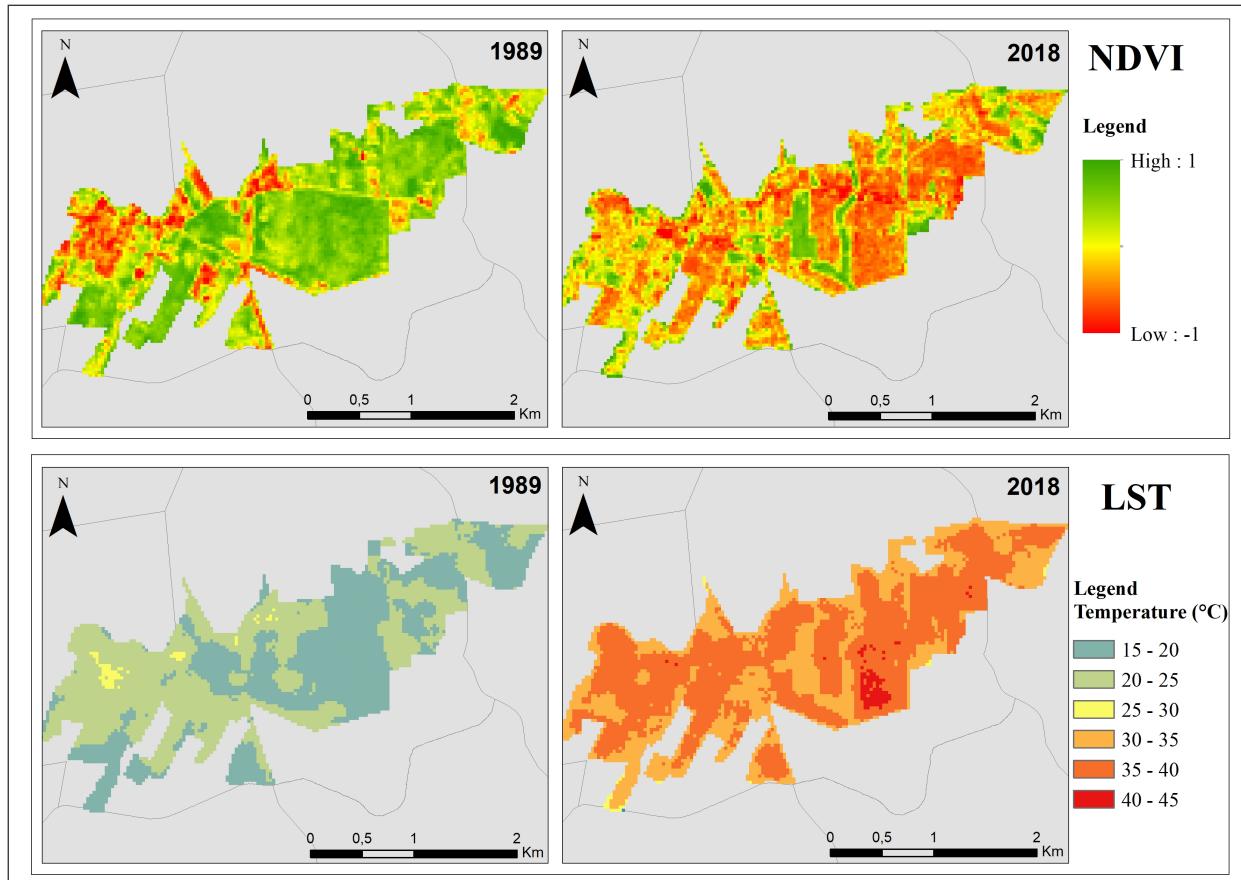


Fig 4 Vegetation Index by Normalized Difference and Land Surface Temperature maps for the years 1989 and 2018.

199 Except for the LST differences influenced by meteorological conditions in the 1989 and 2018
200 images (Figure 4), it is possible to observe that the highest LST values are located in the central
201 areas where the lowest NDVI values are concentrated. This characteristic of the vegetation index
202 is due to the urban occupation of the land surface which are precisely in the areas where the
203 temperature is higher in 1989 and 2018 (where the largest urban agglomerations are located).
204 Thus, it is important to point out that the urban area of the study site presented regions with varying

205 thermal behaviour. As the major reason, the urban growth experienced over the almost 30 years
206 caused changes in this behaviour, essentially in the contrast of the NDVI values, as shown in Figure
207 5.

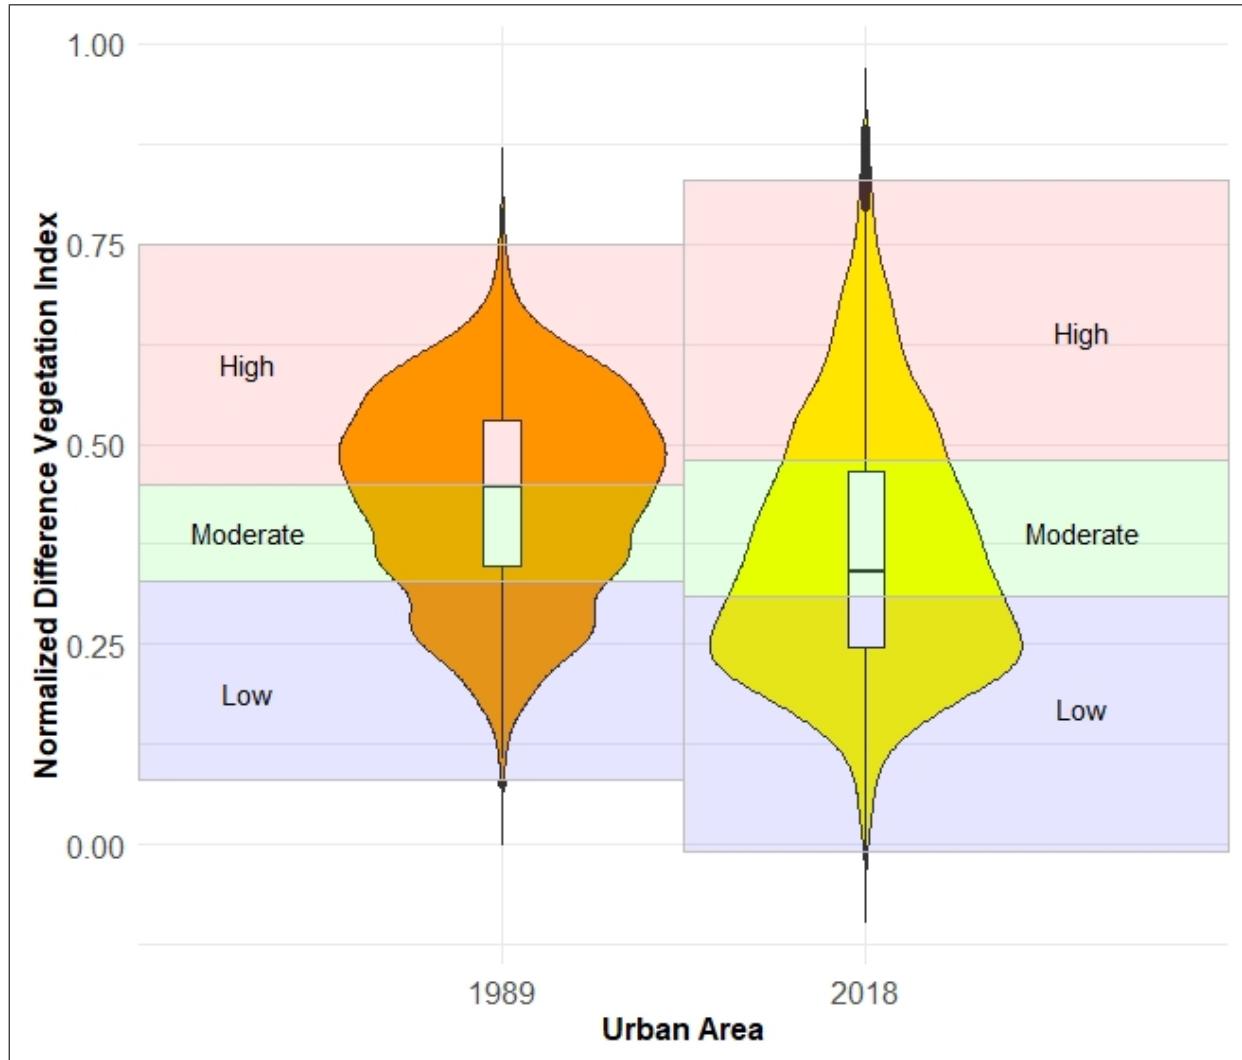


Fig 5 Violin graphs referring to the distribution of the values of Vegetation Index by Normalized Difference of the urban area in 1989 and 2018.

208 The violin plot corresponds to a method of representing numerical data through its distribu-
209 tion. Unlike the box plot that shows only the statistical summary (mean, median and interquartile
210 ranges), this form of representation is particularly useful for data that have a multimodal distri-
211 bution, i.e., those feature more than one frequency peak. Thus, in addition to the different peaks,

212 this method shows the density, position and relative amplitude of the data. Two violin plots were
213 generated (Figure 5) in the present study from the NDVI values of areas classified as urban in 1989
214 and 2018, respectively.

215 According to the graphs in 1989 and 2018 shown in Figure 5, it is possible to observe that
216 the frequency density of the values occurs differently in the two years. Although in 2018 the
217 graph signals NDVI values greater than 0.75, the density of values between 0.50 and 0.75 is lower
218 compared to the same NDVI range in 1989. This indicates that, despite the maximum NDVI
219 values 2018 are higher compared to 1989, the coverage area of 2018 pixels is smaller compared
220 to the area occupied by pixels corresponding to low NDVI values in 1989. In turn, the peak and
221 higher density of values can be observed around median (NDVI=0.44) in 1989 and close to the first
222 quartile mark in 2018. Thus, there was a reduction in the values corresponding to the peaks from
223 1989 to 2018, which can be justified by a series of factors such as reduction in the presence and
224 quality of vegetation during urban expansion, verticalization of the built-up area and the thermal
225 effect of the surrounding areas.

226 In general, the urban growth occurred in the study area and the consequent removal of vege-
227 tation cover caused the contraversion of the violin graph in Figure 5, when comparing the years
228 1989 and 2018. This result is associated with a higher frequency of NDVI values greater than
229 approximately 0.33 (1415 occurrences) in 1989 and less than 0.33 (2534 occurrences) in 2018,
230 in relation to all samples of each grouping and respective year. Thus, when comparing the urban
231 areas of each year, it is possible to state that there were a greater number of areas with the presence
232 of vegetation in 1989 which can be justified by the observed frequency peaks around 0.50 (which
233 in 2018 showed a reduction in intensity for the region around 0.25).

234 Since it is possible to observe the occurrence of three frequency peaks both in 1989 and in 2018

235 from Figure 5 , three groups were calculated using the K-means method (K=3). After calculating
236 these groups, the maximum, minimum, mean and standard deviation values were defined for each
237 group, named as low, moderate and high NDVI. It should be noted that the Student's t-test hypoth-
238 esis with a 95% confidence interval was applied, thus confirming the statistical difference between
239 the groups. The intervals of each grouping and other statistical calculations are shown in Table 2.

Table 2 Maximum, minimum, mean, standard deviation and number of samples (N) values of the urban area low, moderate and high NDVI groups in 1989 and 2018.

NDVI Urban Area						
	1989			2018		
	Low	Moderate	High	Low	Moderate	High
Max	0.33	0.45	0.75	0.31	0.48	0.83
Min	0.08	0.33	0.45	-0.01	0.31	0.48
Mean	0.26	0.39	0.52	0.24	0.39	0.58
DP	0.05	0.04	0.05	0.05	0.05	0.08
N	386	554	893	2310	1816	1195
Area (ha)	34.74	49.86	80.37	207.9	163.44	107.55

240 From 1989 to 2018, the values grouped as low NDVI showed a reduction on average (Table
241 2), from 0.26 to 0.24, while those grouped as high NDVI showed an increase, from 0.45 to 0.48,
242 respectively. The group classified as moderate did not change the mean value in the two images,
243 remaining at 0.39. The highlight is the change in the average value and area of the group classi-
244 fied as high NDVI, whose increase is probably linked to the greater urban concentration in 2018
245 compared to 1989, which favours the occupation of mainly arboreal vegetation used in green parks
246 and roadsides and which performs higher values of NDVI . An adverse situation could probably
247 be verified in 1989 when the urban area was in the initial phase of development and a greater vari-
248 ety of vegetation cover, such as grasses and shrubs, caused a decrease in the average value of the
249 NDVI.

250 Once the low, moderate and high NDVI groups were obtained, the LST values corresponding

251 to the pixels of each group were extracted. Thus, after calculating the maximum, minimum, mean
252 and standard deviation of LST for each group (Table 3), some differences were found between the
253 two dates, mainly linked to the amplitude and contrast of the groups. In 1989, the amplitude of each
254 group accounted for 7.48°C, 8.91°C and 8.16°C for low, moderate and high NDVI, respectively,
255 while in 2018 these values have been increased to 8.87°C, 10.63°C and 9.48°C, respectively. This
256 increase corroborates that accounted for in the grouped NDVI values, which in 1989 were 0.25,
257 0.12, 0.30 and in 2018 increased to 0.32, 0.17 and 0.35 (Table 2). That is, the urban growth that
258 occurred led to a greater range of NDVI values for each of the groups, which resulted in a greater
259 range of LST values.

Table 3 Maximum, minimum, mean, and standard deviation LST values of the low, moderate, and high NDVI groups in 1989 and 2018.

LST (°C)							
NDVI	1989			2018			DP
	Low	Moderate	High	Low	Moderate	High	
Max	27.90	26.46	25.83	42.22	41.63	39.41	
Min	20.42	17.55	17.67	33.35	31.00	29.93	
Mean	24.39	23.29	21.67	38.38	36.60	34.55	
DP	01.46	01.55	01.54	01.55	01.42	01.42	

260 The observed increase in the urban area over a period of approximately 30 years has led to an
261 increase in the difference between the means between the three groups on both dates, as shown in
262 Table 3 . In 1989, the difference in the mean LST value between the low and high NDVI groups
263 was 2.71°C, while in 2018 the value increased to 3.83°C, i.e., an increase of 1.12°C. This result is
264 associated with the growth of areas classified as low NDVI, which resulted in the highest values
265 of LST, which in 1989 comprised 21.06% of the urban area and in 2018 became 43.41%, as well
266 as the reduction of areas classified as high NDVI (lowest LST values), from 48.72% to 22.46%
267 respectively, as can be seen in Table 4.

Table 4 Coverage areas in hectares and percentage in relation to urban area and study area calculated for low, moderate and high NDVI groups in 1989 and 2018.

NDVI Groups	1989			2018		
	Urban area		Study area	Urban area		Study area
	Ha	%	%	Ha	%	%
Low	34.74	21.06	06.50	207.09	43.41	38.74
Moderate	49.86	30.22	09.33	163.44	34.13	30.57
High	80.37	48.72	15.04	107.55	22.46	20.12

268 Once Figure 6 is observed with regard to the spatial distribution of the NDVI groups in 1989, it
 269 is possible to affirm the influence of the peripheral areas, which form a boundary between the urban
 270 space and other areas (mostly occupied by vegetation), on the reduction of temperature values. In
 271 that year , when approximately 80% of the urban area was classified as high and moderate NDVI,
 272 the highest temperature values basically predominated in the centre of the areas corresponding to
 273 the largest urban agglomerations, in the northwest portion of the study area. Although the group
 274 classified as low NDVI occurred in the southern portion of the urban area, the moderate and high
 275 NDVI areas tend to reduce LST at the local level, since they were predominant in these areas.

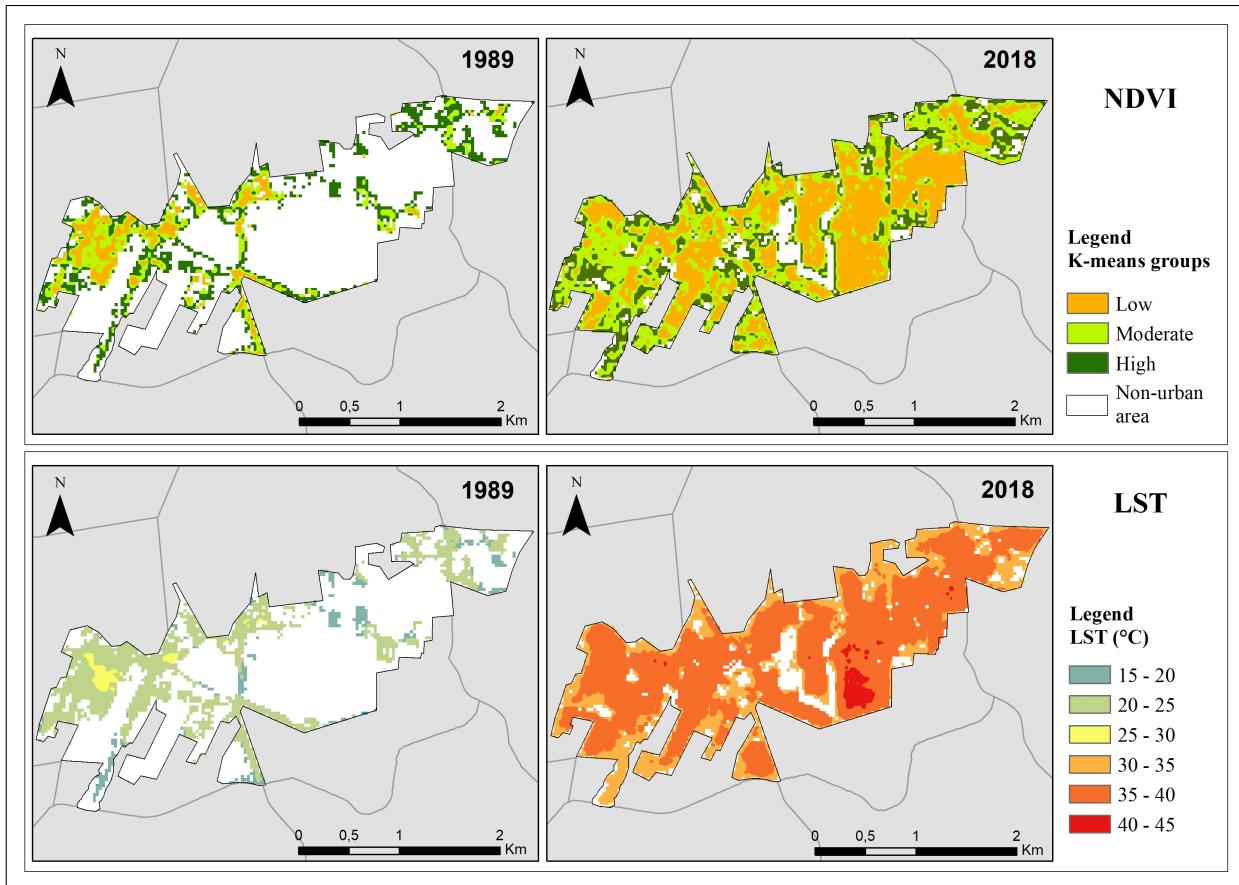


Fig 6 Groups classified as low, moderate and high NDVI and spatial representation of LST the urban area of the study area in the years 1989 and 2018.

276 The urban growth that occurred in the study area has led not only to the formation of new

277 low NDVI areas but also to their change to moderate and even high vegetation levels during the

278 evaluated period (Figure 6). The areas where the lowest NDVI values were concentrated in 1989,

279 and consequently the highest LST values (mainly west of the urban area), characterized an opposite

280 scenario in 2018, with the highest concentration of moderate and high NDVI and lowest LST

281 values. The main factor associated to this result is due to the absence of adequate urban planning,

282 during the implementation of the housing complex (the popular housing scheme known as "Minha

283 Casa, Minha Vida" in Brazil), which occurred on a larger scale in the eastern half of the study area,

284 which is responsible for causing an increase in LST in the area. This shows that the construction

285 standard often adopted in Brazil is characterized by small lots with high levels of impermeability
286 and scarcity of vegetation inside and on sidewalks as observed and verified by.⁵⁵

287 In terms of the formation of Urban Heat Islands (UHIs), the present study gives alerts to the
288 urban area studies where low NDVI values between 0.08 and 0.33 are grouped as low (Table 2).
289 These areas averaged 2.71°C warmer compared to those with high NDVI in 1989 and 3.83°C in
290 2018 within the same urban space. Considering the similar vegetation index averages in the two
291 years covered for the low NDVI group (0.26 in 1989 and 0.24 in 2018, Table 2) and the spatial
292 changes of this group, it is possible to state that there was spatial variation of the NDVI of the
293 urban area over the 30 years, that is, a displacement of the UHI has occurred.

294 The results of the present study corroborate those observed by,⁵⁵ where the multivariate k-
295 means grouping methodology of NDVI, Normalized Difference Built-Up Index (NDBI) and LST,
296 as used by the authors alerted to the fourth group of lower mean NDVI and higher mean LST, as
297 an indicator of UHI formation. In a study on the changes in NDVI, NDBI and LST from 1992 to
298 2016 in an area located in north-eastern Brazil, the authors (⁵⁵) identified that 6% of the study area
299 covered both the largest increase in built-up area (the difference in NDBI between 1992 and 2016
300 was of 0.34) and in temperature (mean LST difference = 11.2°C) was associated with low NDVI
301 values (between -0.38 and -0.13). In the present study, the low NDVI group (between -0.01 and
302 0.31) corresponded to 43.4% of the urban area in 2018 and, compared to the low NDVI group of
303 1989, the difference reaches 14°C. Comparing the studies, the increase in the areas of low NDVI
304 (6% in⁵⁵ and approximately 44% in the present study) constituted an indicator for the increase in
305 the average LST in relation to the other groups and, therefore, the formation of UHIs.

306 **5 Conclusions**

307 The main conclusions of the present study were: (1) Grouping the NDVI values and obtaining the
308 LST statistical variables of each group has made it possible to quantify not only the increase in
309 LST but also to spatially qualify the areas that need more attention from urban planners in terms of
310 sustainable development. Despite being a small urban area with a horizontal pattern of settlements
311 installed as a part of social housing program mentioned above, the absence of sustainable urban
312 planning and formation of UHIs are related to the reduction in the energy efficiency of impervious
313 surfaces (e.g. buildings), increase in refrigeration and changes in the thermal comfort of the local
314 population. (2) By integrating and spatializing the changes in the urban landscape, the method-
315 ological procedures of the present study made it possible to verify the impacts of rapid urban
316 growth, more specifically the high area of impervious surfaces with low occupation of vegetation
317 cover. (3) The increase in thermal amplitude (the difference in mean LST of areas with low and
318 high NDVI in 1989 and 2018) between urban areas with greater and less occurrence of vegetation
319 from 1989 to 2018 shows an increase in temperature at a regional scale as result of the rapid urban
320 growth estimated in the study area. (4) Given the inverse relationship between LST and NDVI, not
321 only the study area but also the urban space warmed up, justified by the reduction in the average
322 value of the vegetation index of urban areas with little vegetation which were predominant in 2018
323 (compared to 1989). Thus, the removal of 89% of the vegetation in the study area for urban occu-
324 pation, together with the increase from approximately 21% to 43% of areas classified as having
325 low vegetation index, resulted in an increase in the thermal amplitude of 1.12°C.

326 The comparison model between remote sensing images from different dates used in the present
327 study was adopted due to the meteorological effects that occurred in previous days and on the date

328 of acquisition of the images. Although the images are from the same season of the year (spring),
329 the southern region of Brazil, where the temperate subtropical climate prevails, presents a large
330 seasonal variation in the air temperature which varies from -10°C to 40°C. Thus, especially the
331 relationship between AT and LST mentioned above, it can be dissimilar in different years and
332 the comparison between images of LST can be redundant. Such interference does not change the
333 comparison carried out in the present study, since the thermal amplitudes between areas with a
334 higher and lower vegetation index were considered for the urban areas in both 1989 and 2018.

335 There are some notable limitations of the methodology applied in the present study and future
336 recommendations. Firstly, data from meteorological stations (e.g. humidity, TA) can be used as ad-
337 ditional input for the interpretation and discussion of the results, since these variables are related to
338 LST. Secondly, the comparison between LULC, NDVI and LST in different years was carried out
339 using the images acquired in the spring season only due to the low availability of images because
340 of unfavourable meteorological conditions in other seasons and the interval between image acqui-
341 sition dates is approximately 30 years. Since the NDVI represents seasonal variation, verifying the
342 comparison made in the present study in other seasons of the year can contribute to understanding
343 the thermal behaviour of the urban area both throughout the year during the study period. For this
344 purpose, future research can make use of complementary data, such as the Advanced Spaceborne
345 Thermal Emission and Reflection Radiometer (ASTER).

346 Remote sensing and image processing techniques have shown to be highly useful for urban
347 planning in terms of quantification and qualification of spatial patterns of settlements and imper-
348 vious surfaces and their thermal response. Urban growth as a consequence of population growth
349 can be monitored, evaluated and predicted cost-effectively using satellite imagery and geographic
350 information systems for mitigating the effects of future rise in urban temperature, particularly the

351 formation of UHIs.

352 *Acknowledgments*

353 This research received support from Coordenação de Aperfeiçoamento de Pessoal de Nível Supe-

354 rior—Brazil (CAPES).

355 *References*

- 356 1 A. Svirejeva-Hopkins, H. J. Schellnhuber, and V. L. Pomaz, “Urbanised territories as a spe-
- 357 cific component of the global carbon cycle,” *Ecological Modelling* **173**(2), 295–312 (2004).
- 358 [doi: 10.1016/j.ecolmodel.2003.09.022].
- 359 2 U. N. D. of Economic and S. Affairs, “2018 revision of world urbanization prospects,” (2018).
- 360 3 J. Mallick, Y. Kant, and B. Bharath, “Estimation of land surface temperature over delhi using
- 361 landsat-7 etm+,” *J. Ind. Geophys. Union* **12**(3), 131–140 (2008).
- 362 4 L. Howard, *The climate of London: deduced from meteorological observations made in the*
363 *metropolis and at various places around it*, vol. 3, Harvey and Darton, J. and A. Arch, Long-
- 364 man, Hatchard, S. Highley [and] R. Hunter (1833).
- 365 5 T. R. Oke, “The energetic basis of the urban heat island,” *Quarterly Journal of the Royal*
366 *Meteorological Society* **108**(455), 1–24 (1982).
- 367 6 A. Favretto, “Urban heat island analysis with remote sensing and gis methods: an application
- 368 in the trieste area (north-east of italy),” *Bollettino Della Società Geografica Italiana Serie*
369 **1**(1), 215–229 (2018).
- 370 7 L. de Faria Peres, A. J. de Lucena, O. C. Rotunno Filho, *et al.*, “The urban heat island
- 371 in rio de janeiro, brazil, in the last 30 years using remote sensing data,” *International*

- 372 *Journal of Applied Earth Observation and Geoinformation* **64**, 104–116 (2018). [doi:
373 10.1016/j.jag.2017.08.012].
- 374 8 K. Katsouyanni, D. Trichopoulos, X. Zavitsanos, *et al.*, “The 1987 athens heatwave,” *The
375 Lancet* **2**, 573 (1988).
- 376 9 J. C. Semenza, C. H. Rubin, K. H. Falter, *et al.*, “Heat-related deaths during the july 1995
377 heat wave in chicago,” *New England Journal of Medicine* **335**(2), 84–90 (1996). [doi:
378 10.1056/NEJM199607113350203].
- 379 10 J.-M. Robine, S. L. K. Cheung, S. Le Roy, *et al.*, “Death toll exceeded 70,000 in europe
380 during the summer of 2003,” *Comptes Rendus Biologies* **331**(2), 171–178 (2008). [doi:
381 10.1016/j.crvi.2007.12.001].
- 382 11 J. Voogt and T. Oke, “Thermal remote sensing of urban climates,” *Remote Sensing of Envi-
383 ronment* **86**(3), 370–384 (2003). [doi: 10.1016/S0034-4257(03)00079-8].
- 384 12 S. Khandelwal, R. Goyal, N. Kaul, *et al.*, “Assessment of land surface temperature variation
385 due to change in elevation of area surrounding jaipur, india,” *The Egyptian Journal of Remote
386 Sensing and Space Science* **21**(1), 87–94 (2018). [doi: 10.1016/j.ejrs.2017.01.005].
- 387 13 C. Wang, Z.-H. Wang, C. Wang, *et al.*, “Environmental cooling provided by urban trees
388 under extreme heat and cold waves in u.s. cities,” *Remote Sensing of Environment* **227**, 28–43
389 (2019). [doi: 10.1016/j.rse.2019.03.024].
- 390 14 Z. Yu, G. Yang, S. Zuo, *et al.*, “Critical review on the cooling effect of urban blue-green
391 space: A threshold-size perspective,” *Urban Forestry Urban Greening* **49**, 126630 (2020).
392 [doi: 10.1016/j.ufug.2020.126630].
- 393 15 R. Wang, H. Hou, Y. Murayama, *et al.*, “Spatiotemporal analysis of land use/cover patterns

- 394 and their relationship with land surface temperature in nanjing, china,” *Remote Sensing* **12**(3)
395 (2020). [doi: 10.3390/rs12030440].
- 396 16 T. F. Stocker, D. Qin, G.-K. Plattner, *et al.*, “Technical summary,” in *Climate change 2013:*
397 *the physical science basis. Contribution of Working Group I to the Fifth Assessment Report*
398 *of the Intergovernmental Panel on Climate Change*, 33–115, Cambridge University Press
399 (2013). [doi: 10.1017/CBO9781107415324].
- 400 17 X. Yuan, W. Wang, J. Cui, *et al.*, “Vegetation changes and land surface feedbacks drive
401 shifts in local temperatures over central asia,” *Scientific Reports* **7**(1), 1–8 (2017). [doi:
402 10.1038/s41598-017-03432-2].
- 403 18 T. Carlson and D. Ripley, “On the relation between ndvi, fractional vegetation cover, and
404 leaf area index,” *Remote sensing of environment*. **62**, 241—252 (1997). [doi: 10.1016/s0034-
405 4257(97)00104-1].
- 406 19 J. A. Sobrino, J. C. Jiménez-Muñoz, and L. Paolini, “Land surface temperature re-
407 trieval from landsat tm 5,” *Remote Sensing of Environment* **90**(4), 434–440 (2004). [doi:
408 10.1016/j.rse.2004.02.003].
- 409 20 M. A. Lombardo, *Ilha de calor nas metrópoles: o exemplo de São Paulo*, Editora Hucitec
410 com apoio de Lalekla SA Comércio e Indústria (1985).
- 411 21 S. Kawashima, “Relation between vegetation, surface temperature, and surface composition
412 in the tokyo region during winter,” *Remote Sensing of Environment* **50**(1), 52–60 (1994). [doi:
413 10.1016/0034-4257(94)90094-9].
- 414 22 E. J. Gago and S. E. Berrizbeitia, “Chapter 6 - effects of land use composition and pattern on
415 land surface temperature: an urban heat island study in the megacities of scotland, uk, using

- 416 time series of landsat tm/etm+data,” 109–129 (2022). [doi: 10.1016/B978-0-323-85539-
- 417 6.00006-8].
- 418 23 N. Thanh Hoan, Y.-A. Liou, K.-A. Nguyen, *et al.*, “Assessing the effects of land-use types in
- 419 surface urban heat islands for developing comfortable living in hanoi city,” *Remote Sensing*
- 420 **10**(12) (2018). [doi: 10.3390/rs10121965].
- 421 24 S. Talukdar, M. Rihan, H. T. Hang, *et al.*, “Modelling urban heat island (uhi) and thermal field
- 422 variation and their relationship with land use indices over delhi and mumbai metro cities,” *En-*
- 423 *vironment, Development and Sustainability* **24**(3), 3762–3790 (2022). [doi: 10.1007/s10668-
- 424 021-01587-7].
- 425 25 J. Song, S. Du, X. Feng, *et al.*, “The relationships between landscape composi-
- 426 tions and land surface temperature: Quantifying their resolution sensitivity with spa-
- 427 tial regression models,” *Landscape and Urban Planning* **123**, 145–157 (2014). [doi:
- 428 10.1016/j.landurbplan.2013.11.014].
- 429 26 G. D. Jenerette, S. L. Harlan, A. Buyantuev, *et al.*, “Micro-scale urban surface temperatures
- 430 are related to land-cover features and residential heat related health impacts in phoenix, az
- 431 usa,” *Landscape ecology* **31**(4), 745–760 (2016). [doi: 10.1007/s10980-015-0284-3].
- 432 27 F. Marzban, S. Sodoudi, and R. Preusker, “The influence of land-cover type on the relation-
- 433 ship between ndvi-lst and lst-t air,” *International Journal of Remote Sensing* **39**(5), 1377–
- 434 1398 (2018). [doi: 10.1080/01431161.2017.1402386].
- 435 28 J. Cao, W. Zhou, Z. Zheng, *et al.*, “Within-city spatial and temporal heterogeneity of air tem-
- 436 perature and its relationship with land surface temperature,” *Landscape and Urban Planning*
- 437 **206**, 103979 (2021). [doi: 10.1016/j.landurbplan.2020.103979].

- 438 29 H. Imran, A. Hossain, A. Islam, *et al.*, “Impact of land cover changes on land surface tem-
- 439 perature and human thermal comfort in dhaka city of bangladesh,” *Earth Systems and Envi-*
- 440 *ronment* **5**(3), 667–693 (2021). [doi: 10.1007/s41748-021-00243-4].
- 441 30 F. Taripanah and A. Ranjbar, “Quantitative analysis of spatial distribution of land surface
- 442 temperature (lst) in relation ecohydrological, terrain and socio- economic factors based on
- 443 landsat data in mountainous area,” *Advances in Space Research* **68**(9), 3622–3640 (2021).
- 444 [doi: 10.1016/j.asr.2021.07.008].
- 445 31 Y. Deng, S. Wang, X. Bai, *et al.*, “Relationship among land surface temperature and lucc,
- 446 ndvi in typical karst area,” *Scientific reports* **8**(1), 1–12 (2018). [doi: 10.1038/s41598-017-
- 447 19088-x].
- 448 32 M. Sharma, P. Bangotra, A. S. Gautam, *et al.*, “Sensitivity of normalized difference vege-
- 449 tation index (ndvi) to land surface temperature, soil moisture and precipitation over district
- 450 gautam buddh nagar, up, india,” *Stochastic Environmental Research and Risk Assessment*
- 451 **36**(6), 1779–1789 (2022). [doi: 10.1007/s00477-021-02066-1].
- 452 33 R. Prăvălie, I. Sîrodoev, I.-A. Nita, *et al.*, “Ndvi-based ecological dynamics of forest vegeta-
- 453 tion and its relationship to climate change in romania during 1987–2018,” *Ecological Indica-*
- 454 *tors* **136**, 108629 (2022). [doi: 10.1016/j.ecolind.2022.108629].
- 455 34 C. D. IBGE, “Censo demográfico 2010: Características da população e dos domicílios: re-
- 456 sultados do universo,” (2011). <https://biblioteca.ibge.gov.br/visualizacao/periodicos/93/>.
- 457 35 D. M. A. Suertegaray and N. S. V. Moura, “Morfogênese do relevo do estado do rio grande
- 458 do sul,” *Rio Grande do Sul: paisagens e territórios em transformação*. **2**, 11–26 (2012).

- 459 36 L. M. W. Ferraro and H. Hasenack, *Carvão e meio ambiente*, Ed. Universidade UFRGS
460 (2000).
- 37 S. M. de Planejamento, “Historia dos bairros de porto alegre,” (2022).
http://lproweb.procempa.com.br/pmpa/prefpoa/observatorio/usu_doc/.
- 461 38 T. Lillesand, R. W. Kiefer, and J. Chipman, *Remote sensing and image interpretation*, John
462 Wiley & Sons (2015).
- 463 39 B. Rimal, L. Zhang, D. Fu, *et al.*, “Monitoring urban growth and the nepal earth-
464 quake 2015 for sustainability of kathmandu valley, nepal,” *Land* **6**(2) (2017). [doi:
465 10.3390/land6020042].
- 466 40 S. Rijal, B. Rimal, and S. Sloan, “Flood hazard mapping of a rapidly urbanizing city in the
467 foothills (birendranagar, surkhet) of nepal,” *Land* **7**(2) (2018). [doi: 10.3390/land7020060].
- 468 41 L. Liu and Y. Zhang, “Urban heat island analysis using the landsat tm data and aster
469 data: A case study in hong kong,” *Remote Sensing* **3**(7), 1535–1552 (2011). [doi:
470 10.3390/rs3071535].
- 471 42 Z. Qin, A. Karnieli, and P. Berliner, “A mono-window algorithm for retrieving land surface
472 temperature from landsat tm data and its application to the israel-egypt border region,” *Inter-
473 national journal of remote sensing* **22**(18), 3719–3746 (2001). [doi: 10.11821/xb200104009].
- 474 43 J. C. Jiménez-Muñoz and J. A. Sobrino, “A generalized single-channel method for retriev-
475 ing land surface temperature from remote sensing data,” *Journal of geophysical research: atmospheres* **108**(D22) (2003). [doi: 10.1029/2003jd003480].
- 476 44 H. Luo, J. Shao, and X. Zhang, “Retrieving land surface temperature based on the radioactive
477

- 478 transfer equation in the middle reaches of the three gorges reservoir area,” *Resources Science*
479 **34**, 256–264 (2012).
- 480 45 O. Rozenstein, Z. Qin, Y. Derimian, *et al.*, “Derivation of land surface temperature for
481 landsat-8 tirs using a split window algorithm,” *Sensors* **14**(4), 5768–5780 (2014). [doi:
482 10.3390/s140405768].
- 483 46 J. A. Barsi, J. R. Schott, S. J. Hook, *et al.*, “Landsat-8 thermal infrared sensor (tirs)
484 vicarious radiometric calibration,” *Remote Sensing* **6**(11), 11607–11626 (2014). [doi:
485 10.3390/rs61111607].
- 486 47 Z. Yong, Y. Tao, G. Xingfa, *et al.*, “Land surface temperature retrieval from cbers-02 irmss
487 thermal infrared data and its applications in quantitative analysis of urban heat island effect,”
488 *Journal of remote sensing* (2006).
- 489 48 Z.-L. Li, B.-H. Tang, H. Wu, *et al.*, “Satellite-derived land surface temperature: Cur-
490 rent status and perspectives,” *Remote sensing of environment* **131**, 14–37 (2013). [doi:
491 10.1016/j.rse.2012.12.008].
- 492 49 C. Wang, S. W. Myint, Z. Wang, *et al.*, “Spatio-temporal modeling of the urban heat island
493 in the phoenix metropolitan area: Land use change implications,” *Remote Sensing* **8**(3), 185
494 (2016). [doi: 10.3390/rs8030185].
- 495 50 K. Deilami and M. Kamruzzaman, “Modelling the urban heat island effect of smart
496 growth policy scenarios in brisbane,” *Land Use Policy* **64**, 38–55 (2017). [doi:
497 10.1016/j.landusepol.2017.02.027].
- 498 51 J. Yang, J. Sun, Q. Ge, *et al.*, “Assessing the impacts of urbanization-associated green space

- 499 on urban land surface temperature: A case study of dalian, china," *Urban Forestry & Urban*
500 *Greening* **22**, 1–10 (2017). [doi: 10.1016/j.ufug.2017.01.002].
- 501 52 Y. Jamei, P. Rajagopalan, and Q. C. Sun, "Spatial structure of surface urban heat island and
502 its relationship with vegetation and built-up areas in melbourne, australia," *Science of The*
503 *Total Environment* **659**, 1335–1351 (2019). [doi: 10.1016/j.scitotenv.2018.12.308].
- 504 53 A. S. Alademomi, C. J. Okolie, O. E. Daramola, *et al.*, "Assessing the relationship of lst, ndvi
505 and evi with land cover changes in the lagos lagoon environment," *Quaestiones Geographicae*
506 **39**(3), 87–109 (2020). [doi: 10.2478/quageo-2020-0025].
- 507 54 S. Guha and H. Govil, "Seasonal variability of lst-ndvi correlation on different land use/land
508 cover using landsat satellite sensor: a case study of raipur city, india," *Environment, Develop-*
509 *opment and Sustainability* **24**(6), 8823–8839 (2022). [doi: 10.1007/s10668-021-01811-4].
- 510 55 A. G. Silva and M. C. Torres, "Proposing an effective and inexpensive tool to detect urban
511 surface temperature changes associated with urbanization processes in small cities," *Building*
512 *and Environment* **192**, 107634 (2021). [doi:10.1016/j.buildenv.2021.107634].

513 **Eduardo Andre Kaiser** is a PhD student in Remote Sensing at the Federal University of Rio
514 Grande do Sul. He received his BS and MS degrees in geography from the Federal University
515 of Santa Maria in 2016 and 2018, respectively. His current research interests include urban heat
516 islands, land surface temperature, land use indices and limnology.

517 Biographies and photographs of the other authors are not available.

518 **List of Figures**

- 519 1 Location map of the study area in relation to the city of Porto Alegre, Rio Grande
520 do Sul, Brazil.
- 521 2 Flowchart of the methodological procedures used in the present study.
- 522 3 Maps and percentage areas of occupation of LULC classes in 1989 and 2018.
- 523 4 Vegetation Index by Normalized Difference and Land Surface Temperature maps
524 for the years 1989 and 2018.
- 525 5 Violin graphs referring to the distribution of the values of Vegetation Index by
526 Normalized Difference of the urban area in 1989 and 2018.
- 527 6 Groups classified as low, moderate and high NDVI and spatial representation of
528 LST the urban area of the study area in the years 1989 and 2018.

529 **List of Tables**

- 530 1 Relation between Normalized Difference Vegetation Index (NDVI) and Emissivity
531 proposed by.⁴⁷
- 532 2 Maximum, minimum, mean, standard deviation and number of samples (N) values
533 of the urban area low, moderate and high NDVI groups in 1989 and 2018.
- 534 3 Maximum, minimum, mean, and standard deviation LST values of the low, mod-
535 erate, and high NDVI groups in 1989 and 2018.
- 536 4 Coverage areas in hectares and percentage in relation to urban area and study area
537 calculated for low, moderate and high NDVI groups in 1989 and 2018.

5 CAPÍTULO V. CONSIDERAÇÕES GERAIS

O objetivo da tese foi o estudo da dinâmica de crescimento urbano no município de Porto Alegre- RS, a partir da recuperação da LST e técnicas de redução de dados de sensoriamento remoto proximal a orbital. O uso de aproximadamente 120 imagens de sensoriamento orbital e dados de bibliotecas espectrais (sensoriamento remoto proximal), ao longo de 33 anos, possibilitou caracterizar o comportamento térmico temporal das áreas urbanas e rurais do município. Simultaneamente, bandas do visível, infravermelho próximo e infravermelho termal foram utilizadas para a classificação do uso e cobertura da terra e cálculo dos seus índices (NDVI, NDBI e UI). Bibliotecas espectrais e parâmetros atmosféricos calibrados por perfis atmosféricos foram empregados no cálculo da emissividade e recuperação da LST, respectivamente. Os resultados mostraram a capacidade do estudo no levantamento de informações acerca do crescimento urbano e os impactos na distribuição espacial e temporal da vegetação como principal determinante da LST. Além disso, a redução e classificação de dados de SR permitiu criar um método alternativo para comparar a LST em anos diferentes e realizar a previsão desta associada a variações do LULC e seus índices e fatores físicos da superfície.

Inicialmente, na análise realizada sobre a área urbana de três bairros do município de Porto Alegre constatou-se o aumento da LST média de 4,18°C quando comparadas à primeira e última década da série histórica de ~33 anos (1985-2018) nas quatro estações. Conclui-se, portanto, que esse aumento pode estar relacionado as mudanças de LULC verificadas principalmente na ocupação urbana que era de ~31% da área de estudo em 1989 passando a abranger ~91% em 2018. A LST associada a sazonalidade indicou o aumento médio desta em todas as estações do ano, entretanto o teste de análise de tendência apontou o aumento da temperatura apenas no outono e primavera, cuja diferença entre a primeira e última década resultou em 6,36°C e 4,4°C, respectivamente. Assim o estudo alerta para o aumento da LST média atrelado ao crescimento urbano, principalmente no outono, cujo o aumento supera o intervalo de 2,6 a 4,8 °C previsto pelo Painel Intergovernamental de Mudanças Climáticas (IPCC) até o final do século.

O cálculo da regressão linear entre produtos de diferentes bandas dos sensores TM-Landsat 5 e OLI/TIRS-Landsat 8 permitiu estabeleceu a relação entre NDVI e LST

e a dependência desta em relação ao crescimento urbano. Durante o aumento das superfícies urbanizadas (de ~31% da área de estudo em 1989 para ~91% em 2018), conforme exposto anteriormente, o coeficiente de correlação entre as variáveis NDVI e LST também apresentou crescimento, de 0,55 em 1989 para 0,76 em 2018. A partir deste resultado ressaltamos o impacto do uso urbano da superfície para o meio ambiente uma vez que seu crescimento ocasionou a homogeneidade da superfície (menor mistura espectral, menores variações meteorológicas e efeito reduzido das áreas vizinhas), aumentando o contraste entre ausência de vegetação e aumento da temperatura.

A análise histórica espacial do LULC e LST permitiu inferir cenários negativos e positivos em termos de conforto térmico no município de Porto Alegre. Segundo a classificação das imagens TM-Landsat 5 e OLI-Landsat 8, a área urbana do município apresentou crescimento de 10,16% e em contrapartida as áreas cobertas por vegetação, seja de campo ou floresta, reduziram 10,01% no período de 1995-2017. Entretanto, a espacialização da LST recuperada pelas imagens TM e TIRS dos satélites citados, respectivamente, possibilitou verificar o aumento de 2,03% (aproximadamente 1000 hectares) das áreas com LST entre 35 e 40°C e aumento de 1,13% das áreas com LST menores que 30°C. Esse resultado alerta para o aumento das áreas de LST elevadas verificadas unicamente sobre as superfícies urbanizadas visto que o aumento das áreas de baixo LST se deu em maior escala de abrangência sobre o espaço rural do município. O ponto positivo que cabe ressaltar se dá na ocorrência das áreas de LST menores que 30°C (que indicaram aumento em sua área ao longo do período) nos grandes centros urbanos do município, atuando como pequenos núcleos de resfriamento, visto os entornos urbanizados destas áreas com LST próximas dos 30°C. Recomenda-se em pesquisas futuras o estudo da evolução espaço-temporal destas áreas que atuam no resfriamento urbano, principalmente em relação a qualidade e distribuição da vegetação utilizada na cobertura.

A estimativa do uso e cobertura da terra e da temperatura de superfície, a partir de dados históricos e modelo CA-ANN, apresentou desempenho satisfatório quando comparadas as categorias reais e simuladas destas. A utilização das variáveis determinantes representadas por mapas de declividade, distância das estradas e distância da área construída para prever as classes de LULC e de NDVI, NDBI, UI e LULC para prever as classes de LST permitiram alcançar a porcentagem de precisão

de 77,6% e 74,67% no processo de validação, respectivamente. No intuito de melhorar a capacidade da estimativa, pesquisas futuras podem relacionar o crescimento populacional, poder aquisitivo, valor das propriedades, crescimento urbano vertical por exemplo, por distritos e uma vez especializados, inserir como uma das variáveis determinantes das previsões.

Uma vez validado o modelo, mapas das variáveis físicas do terreno e índices de LULC da série histórica Landsat 5 e 8 foram utilizados no prognóstico do LULC e LST para 2028 e 2039. Assim a previsão indicou crescimento urbano de 1,41% (~685 ha) até 2028 e 2,33% (~1131 ha) até 2039 e crescimento das áreas de LST entre 35 e 40°C, de 2,39% e 2,64%, respectivamente para os mesmos anos. Cabe ressaltar esse aumento percentual da LST previsto até 2028 (10 anos) já sendo superior aos 20 anos (aumento de 2,03%) analisados anteriormente. Ademais, a redução no percentual de crescimento urbano verificado na previsão e comparado a série histórica, provavelmente está associado dois fatores principais: aumento do crescimento vertical das cidades e demanda de dados socioeconômicos da população como variável determinante no modelo de previsão, conforme citado anteriormente. Esses fatores devem ser melhor explorados na sequência da presente pesquisa, onde pretendemos melhorar o desempenho do modelo de previsão.

Um método alternativo criado para avaliar a LST recuperada em diferentes anos foi desenvolvido no intuito de atenuar os efeitos meteorológicos ocorridos em dias anteriores e na data de aquisição das imagens. Para isso, utilizou-se o NDVI e sua distribuição espacial e temporal em uma área urbana em crescimento para então avaliar as variações de LST, partindo de duas premissas: 1. o índice apresenta maior dependência sazonal do clima e vegetação e menor dependência das condições meteorológicas momentâneas e; 2. a relação inversa entre NDVI e LST, ou seja, maior concentração de vegetação saudável reflete em valores menores de LST. Deste modo, o agrupamento dos valores de NDVI da área urbana de três bairros em 1989 e 2018, a partir da técnica k-médias =3, e extração dos valores de LST de cada grupo, possibilitou quantificar o aumento da amplitude térmica (diferença de LST média das áreas de baixo e alto NDVI em 1989 e 2018) durante o período. A diferença de LST entre áreas de baixo e alto NDVI que era de 2,72°C em 1989 passou a ser 3,83°C em 2018, ou seja, um acréscimo de 1,12°C. Assim, agrupar os valores de NDVI e obter as variáveis estatísticas de LST de cada grupo possibilitou quantificar não só o

aumento da temperatura como também qualificar espacialmente as áreas que necessitam maior atenção por parte dos planejadores urbanos. Apesar de ser uma área urbana de pequeno porte e com um padrão horizontal de moradias, a ausência de planejamento urbano sustentável e formação das ICUS está relacionada com a redução da eficiência energética dos edifícios, aumento dos custos de refrigeração e alterações no conforto térmico da população local.

Finalmente o método desenvolvido supracitado deverá ser aplicado para toda área urbana do município de Porto Alegre e em conjunto com os fatores socioeconômicos e análise do crescimento vertical, compor a sequência desta pesquisa. Estudar a LST a partir das variações de NDVI ao longo da evolução de áreas urbanas poderá fornecer melhor acurácia do modelo de previsão e assim fornecer informações espaciais acuradas acerca do comportamento térmico do município.

Como a previsão aponta uma tendência de aumento nas áreas de LST elevadas, algumas estratégias e soluções de planejamento urbano devem ser definidas. Primeiro, é de fundamental importância a manutenção e preservação dos parques verdes e da arborização viária localizados na área urbana, afim de manter o efeito de resfriamento que pode ser observado no presente estudo em termos de microclima. Segundo, a descentralização urbana pode ser uma solução para atenuar os efeitos da formação das Ilhas de Calor, visto que as áreas onde houveram maior concentração de superfícies impermeáveis, principalmente nos centros urbanos, apresentaram os valores superiores de LST em relação aos entornos menos urbanizados. Deste modo o crescimento urbano esperado deve continuar sendo monitorado, e os produtos de sensoriamento remoto se mostraram de grande valia para avaliar e prever alterações na superfície bem como no comportamento térmico.

FINANCIAMENTO

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de doutorado concedida ao doutorando Eduardo André Kaiser.

REFERÊNCIAS

ABURAS, Maher Milad; AHAMAD, Mohd Sanusi S.; OMAR, Najat Qader. Spatio-temporal simulation and prediction of land-use change using conventional and machine learning models: a review. **Environmental monitoring and assessment**, v. 191, n. 4, p. 1-28, 2019.

AFLAKI, A. et al. Urban heat island mitigation strategies: A state-of-the-art review on Kuala Lumpur, Singapore and Hong Kong. **Cities**, v. 62, p. 131–145, fev. 2017.

AKBARI, H. et al. Local climate change and urban heat island mitigation techniques – The state of the art. **Journal of civil engineering and management**, v. 22, n. 1, p. 1–16, dez. 2015.

AKHAND, K. et al. An Artificial Neural Network-based model for predicting Boro rice yield in Bangladesh using AVHRR-based satellite data. **International Journal of Agriculture and Forestry**, v. 8, n. 1, p. 16-25, 2018.

ALBERTI, Marina; WEEKS, Robin; COE, Stefan. Urban land-cover change analysis in central Puget Sound. **Photogrammetric Engineering & Remote Sensing**, v. 70, n. 9, p. 1043-1052, 2004.

ALSHARIF, Abubakr AA; PRADHAN, Biswajeet. Urban sprawl analysis of Tripoli Metropolitan city (Libya) using remote sensing data and multivariate logistic regression model. **Journal of the Indian Society of Remote Sensing**, v. 42, n. 1, p. 149-163, 2014.

AMORIM, Margarete; DUBREUIL, Vincent; CARDOSO, Renatta. Modelagem espacial da ilha de calor urbana em Presidente Prudente (SP), Brasil. **Revista Brasileira de Climatologia**, v. 16, p. 29-45, 2015.

ARNFIELD, A. John. Two decades of urban climate research: a review of turbulence, exchanges of energy and water, and the urban heat island. **International Journal of Climatology: a Journal of the Royal Meteorological Society**, v. 23, n. 1, p. 1-26, 2003.

ASHWINI, Kumar; SIL, Briti Sundar. Impacts of Land Use and Land Cover Changes on Land Surface Temperature over Cachar Region, Northeast India—A Case Study. **Sustainability**, v. 14, n. 21, p. 14087, 2022.

AYOADE, J. O. Introdução à climatologia para os trópicos: 1-332. **Bertrand Brasil, Rio de Janeiro**, 1998.

BAEZA, Santiago; PARUELO, José M. Land use/land cover change (2000–2014) in the Rio de la Plata grasslands: an analysis based on MODIS NDVI time series. **Remote sensing**, v. 12, n. 3, p. 381, 2020.

BARSI, Julia A. et al. Landsat-8 thermal infrared sensor (TIRS) vicarious radiometric calibration. **Remote Sensing**, v. 6, n. 11, p. 11607-11626, 2014.

BARROS, Hugo Rogério de. **A relação entre ilha de calor urbana, o uso e cobertura do solo e o balanço de energia no município de São Paulo:** avaliação do campo térmico nos parques públicos de lazer. 2016. Tese de Doutorado. Universidade de São Paulo.

BECKER, François; LI, Zhao-Liang. Towards a local split window method over land surfaces. **Remote Sensing**, v. 11, n. 3, p. 369-393, 1990.

BUYANTUYEV, Alexander; WU, Jianguo. Urban heat islands and landscape heterogeneity: linking spatiotemporal variations in surface temperatures to land-cover and socioeconomic patterns. **Landscape ecology**, v. 25, n. 1, p. 17-33, 2010.

CARVALHO , André Carlos Ponce; DE PADUA BRAGA, Antonio; LUDERMIR, Teresa B. **Fundamentos de redes neurais artificiais**. DCC/IME, COPPE/UFRJ, NCE-UFRJ, 1998.

CHEN, Yun; HIEN, Wong Nyuk. Thermal benefits of city parks. **Energy and buildings**, v. 38, n. 2, p. 105-120, 2006.

COLL, César; CASELLES, Vicente. A split-window algorithm for land surface temperature from advanced very high resolution radiometer data: validation and algorithm comparison. **Journal of Geophysical Research: Atmospheres**, v. 102, n. D14, p. 16697-16713, 1997.

DAN, Shangming et al. Comparison and analysis of research methods for urban heat island effect based on Landsat TM6. In: **2010 Second IITA International Conference on Geoscience and Remote Sensing**. IEEE, 2010. p. 161-164.

DASH, Prasanjit et al. Land surface temperature and emissivity estimation from passive sensor data: Theory and practice-current trends. **International Journal of remote sensing**, v. 23, n. 13, p. 2563-2594, 2002.

DE LUCENA, Andrews José et al. Estimation of the urban heat island in the Metropolitan Area of Rio de Janeiro-Brazil. In: **2015 Joint Urban Remote Sensing Event (JURSE)**. IEEE, 2015. p. 1-4.

DE MORAIS, Heliene Ferreira.et al. Identificação do fenômeno de ilhas de calor urbano em Belo Horizonte – MG. In **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR** (pp. 0936–0943), 2013. Foz do Iguaçu - Pr: INPE. Diponível em: <<http://marte2.sid.inpe.br/col/dpi.inpe.br/marte2/2013/05.29.00.00.40/doc/p0813.pdf>>. Acesso em: 16 de dezembro de 2019.

DE SOUZA, Diego Oliveira; DOS SANTOS ALVALÁ, Regina Célia. Observational evidence of the urban heat island of Manaus City, Brazil. **Meteorological Applications**, v. 21, n. 2, p. 186-193, 2014.

DEILAMI, Kaveh; KAMRUZZAMAN, Md; LIU, Yan. Urban heat island effect: A systematic review of spatio-temporal factors, data, methods, and mitigation measures. **International journal of applied earth observation and geoinformation**, v. 67, p. 30-42, 2018.

DENG, Yuanhong et al. Relationship among land surface temperature and LUCC, NDVI in typical karst area. **Scientific reports**, v. 8, n. 1, p. 1-12, 2018.

DORIGON, Larissa Piffer; DOS SANTOS CARDOSO, Renata. ANÁLISE DO FLUXO DE VENTO E SEU PAPEL NA DISPERSÃO DE POLUENTES EM PRESIDENTE PRUDENTE-SP. **Boletim de Geografia**, v. 33, n. 1, p. 95-108, 2015.

ECF, 2014: Climate Change: Implications for cities. European Climate Foundation (ECF). Disponível em: <http://www.iclei.org/fileadmin/PUBLICATIONS/Brochures/IPCC_AR5_Cities_Summary_FINAL_Web.pdf> Acesso em: 15 de novembro de 2019.

EPIPHANIO, José Carlos Neves et al. Índices de vegetação no sensoriamento remoto da cultura do feijão. **Pesquisa agropecuária brasileira**, v. 31, n. 6, p. 445-454, 1996.

ESTOQUE, Ronald C.; MURAYAMA, Yuji; MYINT, Soe W. Effects of landscape composition and pattern on land surface temperature: An urban heat island study in the megacities of Southeast Asia. **Science of the Total Environment**, v. 577, p. 349-359, 2017.

FAVRETTI, Andrea. Urban Heat Island analysis with Remote Sensing and GIS methods: an application in the Trieste area (North-East of Italy). **Bollettino Della Società Geografica Italiana Serie**, v. 1, n. 1, p. 215-229, 2018.

FEYISA, Gudina Legese; DONS, Klaus; MEILBY, Henrik. Efficiency of parks in mitigating urban heat island effect: An example from Addis Ababa. **Landscape and urban planning**, v. 123, p. 87-95, 2014.

FILHO, D. J. C. et al. Identificação de ilhas de calor na cidade de Patos de Minas - MG com dados de temperatura superficial e Índice de Vegetação Normalizada (NDVI) por meio de sensoriamento remoto. **Anais XII SIMPÓSIO BRASILEIRO DE CLIMATOLOGIA GEOGRÁFICA - VARIABILIDADE E SUSCETIBILIDADE CLIMÁTICA: IMPLICAÇÕES ECOSSISTÊMICAS E SOCIAIS**. Goiânia (GO): Universidade Federal de Goiás. pp. 1477–1486, 2016. Disponível em: <[http://www.abclima.ggf.br/sbcg2016/anais/arquivos/eixo_3/trabalho_\(57\).pdf](http://www.abclima.ggf.br/sbcg2016/anais/arquivos/eixo_3/trabalho_(57).pdf)>. Acesso em: 26 de outubro de 2019.

FLECK, Leandro et al. Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47-57, 2016.

FOUNDA, Dimitra; SANTAMOURIS, Mattheos. Synergies between Urban Heat Island and Heat Waves in Athens (Greece), during an extremely hot summer (2012). **Scientific reports**, v. 7, n. 1, p. 1-11, 2017.

GALLO, K. P. et al. The use of a vegetation index for assessment of the urban heat island effect. **Remote Sensing**, v. 14, n. 11, p. 2223-2230, 1993.

GARCÍA, Felipe. Manual de climatología aplicada. Clima, medio ambiente y planificación. **Madrid: Editorial síntesis, SA**, 1996.

GARTLAND, Lisa. **Ilhas de calor: como mitigar zonas de calor em áreas urbanas.** Oficina de textos, 2011.

GILLESPIE, Alan et al. A temperature and emissivity separation algorithm for Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) images. **IEEE transactions on geoscience and remote sensing**, v. 36, n. 4, p. 1113-1126, 1998.

GILLESPIE, Alan R. et al. Temperature/emissivity separation algorithm theoretical basis document, version 2.4. **ATBD contract NAS5-31372, NASA**, 1999.

GOBAKIS, K. et al. Development of a model for urban heat island prediction using neural network techniques. **Sustainable Cities and Society**, v. 1, n. 2, p. 104-115, 2011.

GOMES, Washington Paulo; AMORIM, Margarete Cristiane de Costa Trindade; DUBREUIL, Vincent. Modelagem da Ilha de Calor Urbana Aplicada ao Ambiente Litorâneo-Ubatuba/Brasil. **Revista do Departamento de Geografia**, v. 34, p. 82-94, 2017.

GRONDONA, Atilio; ROLIM, Silvia Beatriz Alves. Separation of Temperature and Emissivity from Thermal Infrared Images: Analysis of their Application/Restriction. **Boletim de Ciências Geodésicas**, v. 22, p. 16-34, 2016.

GRONDONA, Atilio Efrain Bica; VEETTIL, Bijeesh Kozhikkodan; ROLIM, Silvia Beatriz Alves. Urban Heat Island development during the last two decades in Porto Alegre, Brazil and its monitoring. In: **Joint Urban Remote Sensing Event 2013**. IEEE, 2013. p. 061-064.

I. B. G. E, Brasil. Instituto Brasileiro de geografia e Estatística. **Censo demográfico**, v. 2010, p. 11, 2010.

IPCC. *Summary for policymakers, IPCC working Group II report, Climate Change 2022: Impacts, adaptation and vulnerability*. IPCC, 2022.

ISLAM, Tanvir et al. A physics-based algorithm for the simultaneous retrieval of land surface temperature and emissivity from VIIRS thermal infrared data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 55, n. 1, p. 563-576, 2016.

HAASHEMI, Sirous et al. Seasonal variations of the surface urban heat island in a semi-arid city. **Remote Sensing**, v. 8, n. 4, p. 352, 2016.

HALDER, Bijay; BANDYOPADHYAY, Jatisankar; BANIK, Papiya. 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**, v. 74, p. 103186, 2021.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Bookman Editora, 2001.

HAYKIN, S., **Neural networks: A comprehensive foundation**. New York: Macmillan, 1999.

HARTMANN, D. L. The ocean general circulation and climate. **Global Physical Climatology**, p. 171-203, 1994.

HILKER, Thomas et al. On the measurability of change in Amazon vegetation from MODIS. **Remote Sensing of Environment**, v. 166, p. 233-242, 2015.

HO, Hung Chak et al. Mapping maximum urban air temperature on hot summer days. **Remote Sensing of Environment**, v. 154, p. 38-45, 2014.

HOOK, Simon J. et al. A comparison of techniques for extracting emissivity information from thermal infrared data for geologic studies. **Remote sensing of Environment**, v. 42, n. 2, p. 123-135, 1992.

HOU, G. L. et al. Retrieval and spatial distribution of land surface temperature in the middle part of Jilin province based on MODIS data. **Scientia Geographica Sinica**, v. 30, n. 3, p. 421-427, 2010.

JENSEN, John R.; EPIPHANIO, José Carlos Neves. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese Editora, 2009.

JIMÉNEZ-MUÑOZ, Juan C.; SOBRINO, José A. A generalized single-channel method for retrieving land surface temperature from remote sensing data. **Journal of geophysical research: atmospheres**, v. 108, n. D22, 2003.

JULIEN, Yves; SOBRINO, José A.; VERHOEF, Wout. Changes in land surface temperatures and NDVI values over Europe between 1982 and 1999. **Remote sensing of environment**, v. 103, n. 1, p. 43-55, 2006.

KAFY, Abdulla-Al et al. Modeling the relationship between land use/land cover and land surface temperature in Dhaka, Bangladesh using CA-ANN algorithm. **Environmental Challenges**, v. 4, p. 100190, 2021.

KAISER, Eduardo Andre et al. Spatiotemporal Influences of LULC Changes on Land Surface Temperature in Rapid Urbanization Area by Using Landsat-TM and TIRS Images. **Atmosphere**, v. 13, n. 3, p. 460, 2022.

KEALY, Peter S.; HOOK, Simon J. Separating temperature and emissivity in thermal infrared multispectral scanner data: Implications for recovering land surface temperatures. **IEEE Transactions on Geoscience and Remote Sensing**, v. 31, n. 6, p. 1155-1164, 1993.

KHANDELWAL, Sumit et al. Assessment of land surface temperature variation due to change in elevation of area surrounding Jaipur, India. **The Egyptian Journal of Remote Sensing and Space Science**, v. 21, n. 1, p. 87-94, 2018.

KAWASHIMA, Shigeto. Relation between vegetation, surface temperature, and surface composition in the Tokyo region during winter. **Remote Sensing of Environment**, v. 50, n. 1, p. 52-60, 1994.

KOLOKOTRONI, Maria; ZHANG, Y.; GIRIDHARAN, Renganathan. Heating and cooling degree day prediction within the London urban heat island area. **Building Services Engineering Research and Technology**, v. 30, n. 3, p. 183-202, 2009.

MENDONÇA, F. O estudo do SCU-Sistema do Clima Urbano-no Brasil: Aplicações e avanços. **A construção da climatologia geográfica no Brasil**. 1ed. Campinas: Alínea Editora, p. 155-166, 2015.

MONTEIRO, C. A. F. **Teoria e Clima Urbano**. 1976. Tese (Livre Docência em Geografia) – Universidade de São Paulo, São Paulo, 1976.

LANDSBERG, Helmut E. **The urban climate**. Academic press, 1981.

LEITE, M. R. **Sensoriamento remoto aplicado na análise temporal da relação uso da terra/temperatura e albedo de superfície na bacia do Rio Vieira no norte de Minas Gerais**. Uberlândia, MG. 2011. Tese de Doutorado. Tese (Doutorado em Geografia)–Universidade de Uberlândia, Minas Gerais, 114 p. 2011.

LEITE, P. F.; KLEIN, R. M. Vegetação. In: **Geografia do Brasil: região sul**. Rio de Janeiro: IBGE, v. 2, p. 113-150, 1990.

LI, Dan et al. Contrasting responses of urban and rural surface energy budgets to heat waves explain synergies between urban heat islands and heat waves. **Environmental Research Letters**, v. 10, n. 5, p. 054009, 2015.

LI, Juan-juan et al. Remote sensing evaluation of urban heat island and its spatial pattern of the Shanghai metropolitan area, China. **Ecological Complexity**, v. 6, n. 4, p. 413-420, 2009.

LI, Xiaoxiao et al. Remote sensing of the surface urban heat island and land architecture in Phoenix, Arizona: Combined effects of land composition and configuration and cadastral-demographic-economic factors. **Remote Sensing of Environment**, v. 174, p. 233-243, 2016.

LI, Zhao-Liang et al. Satellite-derived land surface temperature: Current status and perspectives. **Remote sensing of environment**, v. 131, p. 14-37, 2013.

LILLESAND, Thomas; KIEFER, Ralph W.; CHIPMAN, Jonathan. **Remote sensing and image interpretation**. John Wiley & Sons, 2015.

LIMA ALVES, Elis Dener; LOPES, António. The urban heat island effect and the role of vegetation to address the negative impacts of local climate changes in a small Brazilian City. **Atmosphere**, v. 8, n. 2, p. 18, 2017.

LIU, Lin; ZHANG, Yuanzhi. Urban heat island analysis using the Landsat TM data and ASTER data: A case study in Hong Kong. **Remote sensing**, v. 3, n. 7, p. 1535-1552, 2011.

LIU, Yang et al. Spatial and temporal relationships among NDVI, climate factors, and land cover changes in Northeast Asia from 1982 to 2009. **GIScience & Remote Sensing**, v. 48, n. 3, p. 371-393, 2011.

LOMBARDO, Magda Adelaide. **Ilha de calor nas metrópoles:** o exemplo de São Paulo. Editora Hucitec com apoio de Lalekla SA Comércio e Indústria, 1985.

LU, Qing et al. Using the NDVI to analyze trends and stability of grassland vegetation cover in Inner Mongolia. **Theoretical and Applied Climatology**, v. 135, n. 3, p. 1629-1640, 2019.

MADUAKO, I. D.; YUN, Z.; PATRICK, B. Simulation and prediction of land surface temperature (LST) dynamics within Ikom City in Nigeria using artificial neural network (ANN). **Journal of Remote Sensing & GIS**, v. 5, n. 1, p. 1-7, 2016.

MARSTON, Christopher G. et al. Scrubbing up: multi-scale investigation of woody encroachment in a Southern African Savannah. **Remote Sensing**, v. 9, n. 5, p. 419, 2017.

MATSUSHITA, Bunkei et al. Sensitivity of the enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI) to topographic effects: a case study in high-density cypress forest. **Sensors**, v. 7, n. 11, p. 2636-2651, 2007.

MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115-133, 1943.

MINSKY, Marvin; PAPERT, Seymour. An introduction to computational geometry. **Cambridge tress., HIT**, v. 479, p. 480, 1969.

MIRZAEI, Parham A. Recent challenges in modeling of urban heat island. **Sustainable cities and society**, v. 19, p. 200-206, 2015.

MUSHORE, Terence Darlington et al. Prediction of future urban surface temperatures using medium resolution satellite data in Harare metropolitan city, Zimbabwe. **Building and Environment**, v. 122, p. 397-410, 2017.

NETZBAND, Maik; JÜRGENS, Carsten. Urban and suburban areas as a research topic for remote sensing. In: **Remote sensing of urban and suburban areas**. Springer, Dordrecht, 2010. p. 1-9.

NIGUSSIE, Demeke; ZURITA-MILLA, R.; CLEVERS, J. G. P. W. Possibilities and limitations of artificial neural networks for subpixel mapping of land cover. **International journal of remote sensing**, v. 32, n. 22, p. 7203-7226, 2011.

OKE, Timothy R. The energetic basis of the urban heat island. **Quarterly Journal of the Royal Meteorological Society**, v. 108, n. 455, p. 1-24, 1982.

OKE, T. R. **Boundary Layer Climates**. 2 nd ed. London: Ethuen & CO, 372p. 1978.

OLIVEIRA, R. M. **Nova metodologia para análise e síntese de sistemas de aterramento complexos utilizando o método LN-FDTD, computação paralela automática e redes neurais artificiais**. Tese de Doutorado disponível em : <http://repositorio.ufpa.br:8080/jspui/handle/2011/1990>. 2008. Acesso em 15/01/2020.

UNITED NATIONS ORGANIZATION (UNO). World Urbanization Prospects.

Organização das Nações Unidas (ONU), 2014. Disponível em: <<https://esa.un.org/unpd/wup/Publications/Files/WUP2014-Report.pdf>> . Acesso em: Out. 2019.

PATINO, Jorge E.; DUQUE, Juan C. A review of regional science applications of satellite remote sensing in urban settings. **Computers, Environment and Urban Systems**, v. 37, p. 1-17, 2013.

_____. **PAINEL BRASILEIRO DE MUDANÇAS CLIMÁTICAS** (PBMC). Mudanças Climáticas e Cidades. Relatório Especial do Painel Brasileiro de Mudanças Climáticas [Ribeiro, S.K., Santos, A.S. (Eds.)]. PBMC, COPPE – UFRJ. Rio de Janeiro, Brasil. 116p, 2016.

PENG, Shushi et al. Surface urban heat island across 419 global big cities. **Environmental science & technology**, v. 46, n. 2, p. 696-703, 2012.

PERES, Leonardo et al. The urban heat island in Rio de Janeiro, Brazil, in the last 30 years using remote sensing data. **International journal of applied earth observation and geoinformation**, v. 64, p. 104-116, 2018.

PICHIERRI, Manuele; BONAFONI, Stefania; BIONDI, Riccardo. Satellite air temperature estimation for monitoring the canopy layer heat island of Milan. **Remote Sensing of Environment**, v. 127, p. 130-138, 2012.

PLANCK, Max. The theory of heat radiation. **Search** (2nd ed.). P. Blakiston's Son & Co. OL 7154661M, 1914.

PONZONI, F. J; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. 2010. ed. São José dos Campos: Parêntese, 128 p. 2010.

QIN, Zhihao; KARNIELI, Arnon; BERLINER, Pedro. A mono-window algorithm for retrieving land surface temperature from Landsat TM data and its application to the Israel-Egypt border region. **International journal of remote sensing**, v. 22, n. 18, p. 3719-3746, 2001.

RAMOS, Alexandre Webber Perlandim; DA SILVA NEVES, Sandra Mara Alves; SILVA, Géssica de Jesus Oliveira. Análise, a partir de imagem LANDSAT 8, de ilhas de calor na cidade brasileira de Cáceres/MT. **Os Desafios da Geografia Física na Fronteira do Conhecimento**, v. 1, p. 2715-2720, 2017.

RAO, Krishna. Remote sensing of urban “heat islands” from an environmental satellite. **Bull. Am. Meteorol. Soc.** 53, 647–648, 1972.

RASUL, Azad et al. A review on remote sensing of urban heat and cool islands. **Land**, v. 6, n. 2, p. 38, 2017.

RIBEIRO, Antonio Giacomini. As escalas do clima. **Boletim de Geografia Teórica**, v. 23, n. 45-46, p. 288-294, 1993.

ROKNI, Komeil; MUSA, Tajul Ariffin. Normalized difference vegetation change index: A technique for detecting vegetation changes using Landsat imagery. **Catena**, v. 178, p. 59-63, 2019.

ROLIM, Silvia Beatriz Alves et al. A review of temperature and emissivity retrieval methods: applications and restrictions. **Am. J. Environ. Eng.**, v. 6, p. 119-128, 2016.

ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386, 1958.

ROSENZWEIG, C. et al. **ARC3. 2 Summary for City Leaders Climate Change and Cities: Second Assessment Report of the Urban Climate Change Research Network**. 2015.

ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. **Proceedings 3rd ERTS symposium** (pp. 309–317). Washington DC: U.S. Government Printing Office (ed. SP-351), 1973.

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. **Learning internal representations by error propagation**. California Univ San Diego La Jolla Inst for Cognitive Science, 1985.

SANT'ANNA NETO , João Lima. O clima urbano como construção social: da vulnerabilidade polissêmica das cidades enfermas ao sofisma utópico das cidades saudáveis. **Revista Brasileira de Climatologia**, v. 8, 2011.

SCHWARZ, Nina; LAUTENBACH, Sven; SEPPELT, Ralf. Exploring indicators for quantifying surface urban heat islands of European cities with MODIS land surface temperatures. **Remote Sensing of Environment**, v. 115, n. 12, p. 3175-3186, 2011.

SHATNAWI, Nawras; ABU QDAIS, Hani. Mapping urban land surface temperature using remote sensing techniques and artificial neural network modelling. **International Journal of Remote Sensing**, v. 40, n. 10, p. 3968-3983, 2019.

SHEN, Huanfeng et al. Long-term and fine-scale satellite monitoring of the urban heat island effect by the fusion of multi-temporal and multi-sensor remote sensed data: A 26-year case study of the city of Wuhan in China. **Remote Sensing of Environment**, v. 172, p. 109-125, 2016.

SILVA, Bernardo B. da et al. Procedures for calculation of the albedo with OLI-Landsat 8 images: Application to the Brazilian semi-arid. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 20, p. 3-8, 2016.

SILVA, Edelci Nunes; RIBEIRO, Helena; SANTANA, Paula. Clima e saúde em contextos urbanos: uma revisão da literatura. **Biblio 3W. Revista Bibliográfica de Geografía y Ciencias Sociales**, Barcelona: Universidad de Barcelona, v. 19, n. 1092, 2014.

SILVA, H. R. et al. Identificação de ilhas de calor em municípios de pequeno porte: estudo da área urbana de Ilha Solteira (SP). **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR** ,pp. 5065–5070, 2015. João Pessoa-PB, Brazil: INPE. <http://www.dsr.inpe.br/sbsr2015/files/p0993.pdf>

SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas - Fundamentos Teóricos e Aspectos Práticos**. 2a.. ed. , 431p, 2016.

SILVA, Mara Rubia; RIBEIRO, Marcelo Guimarães; CENTENO, Jorge Antonio Silva. Monitoramento de estiagens com imagens MODIS. **Anais XIII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, v. 13, p. 6229-6236, 2007.

SMALL, Christopher. Multitemporal analysis of urban reflectance. **Remote Sensing of Environment**, v. 81, n. 2-3, p. 427-442, 2002.

SMITH, R. C. G.; CHOUDHURY, Bhaskar J. On the correlation of indices of vegetation and surface temperature over south-eastern Australia. **International Journal of Remote Sensing**, v. 11, n. 11, p. 2113-2120, 1990.

SOBRINO, José A.; JIMÉNEZ-MUÑOZ, Juan C.; PAOLINI, Leonardo. Land surface temperature retrieval from LANDSAT TM 5. **Remote Sensing of environment**, v. 90, n. 4, p. 434-440, 2004.

SOBRINO, J. A.; RAISOUNI, N. Toward remote sensing methods for land cover dynamic monitoring: Application to Morocco. **International journal of remote sensing**, v. 21, n. 2, p. 353-366, 2000.

SORRE, M. *Traité de climatologie biologique et médicale*. Paris: Piery Masson et Cie Éditeurs, 1934.

SOUZA, Amaury et al. Modelo de Thom para o zoneamento bioclimático de Mato Grosso do Sul. **Revista de Geografia Norte Grande**, n. 46, p. 137-147, 2010.

STEWART, I. D. **Redefining the urban heat island**. Tese de Doutorado. (Doctor of Philosophy). The Faculty of Graduate Studies, The University of British Columbia. Vancouver, p. 368, 2011.

SUERTEGARAY, Dirce Maria Antunes; MOURA, Nina Simone Vilaverde. Morfogênese do relevo do Estado do Rio Grande do Sul. **Rio Grande do Sul: paisagens e territórios em transformação**. Porto Alegre: Editora da UFRGS, 2012. 2. ed. p. 11-26, 2012.

TANG, Huajun; LI, Zhao-Liang. **Quantitative remote sensing in thermal infrared: theory and applications**. Springer Science & Business Media, 2013.

TEIXEIRA, M. B. et al. **Levantamento de recursos naturais**. Rio de Janeiro: IBGE, 1986.

THANH HOAN, Nguyen et al. Assessing the effects of land-use types in surface urban heat islands for developing comfortable living in Hanoi City. **Remote Sensing**, v. 10, n. 12, p. 1965, 2018.

UGEDA JÚNIOR, J.C. **Clima urbano e planejamento na cidade de Jales-SP**. 2011. xxvi, 373 f. Tese (doutorado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia, 2011.

USGS. **Landsat 8 (L8) Data Users Handbook**. Department of the Interior, U.S. Geological Survey (USGS), LSDS-1574, Ver. 1.0, 106p., 2015.

VAN DE GRIEND, A. A.; OWE, Manfred. On the relationship between thermal

emissivity and the normalized difference vegetation index for natural surfaces. **International Journal of remote sensing**, v. 14, n. 6, p. 1119-1131, 1993.

VOOGT, James A.; OKE, Tim R. Thermal remote sensing of urban climates. **Remote sensing of environment**, v. 86, n. 3, p. 370-384, 2003.

WANG, Chuyuan et al. Spatio-temporal modeling of the urban heat island in the Phoenix metropolitan area: Land use change implications. **Remote Sensing**, v. 8, n. 3, p. 185, 2016.

WARD, Kathrin et al. Heat waves and urban heat islands in Europe: A review of relevant drivers. **Science of the Total Environment**, v. 569, p. 527-539, 2016.

WEN, Zhaofei et al. NDVI indicated long-term interannual changes in vegetation activities and their responses to climatic and anthropogenic factors in the Three Gorges Reservoir Region, China. **Science of the Total Environment**, v. 574, p. 947-959, 2017.

WENG, Qihao. Thermal infrared remote sensing for urban climate and environmental studies: Methods, applications, and trends. **ISPRS Journal of photogrammetry and remote sensing**, v. 64, n. 4, p. 335-344, 2009.

WERBOS, Paul J. Backpropagation through time: what it does and how to do it. **Proceedings of the IEEE**, v. 78, n. 10, p. 1550-1560, 1990.

WIDROW, Bernard; HOFF, Marcian E. **Adaptive switching circuits**. Stanford Univ Ca Stanford Electronics Labs, 1960.

YUAN, Wei. et al. NDVI-based assessment of climate change impact on vegetation growth in the humid-arid transition zone in northern China during 1982-2013. **International Journal of Climatology**, 6172, 2019.

YUAN, Xiuliang et al. Vegetation changes and land surface feedbacks drive shifts in local temperatures over Central Asia. **Scientific Reports**, v. 7, n. 1, p. 1-8, 2017.

ZHANG, Jinqu; WANG, Yunpeng; LI, Yan. A C++ program for retrieving land surface temperature from the data of Landsat TM/ETM+ band6. **Computers & geosciences**, v. 32, n. 10, p. 1796-1805, 2006.

ZHAO, Anzhou et al. Assessing the effects of drought and “Grain for Green” Program on vegetation dynamics in China's Loess Plateau from 2000 to 2014. **Catena**, v. 175, p. 446-455, 2019.

ZURADA, Jacek M. Analog implementation of neural networks. **IEEE Circuits and Devices Magazine**, v. 8, n. 5, p. 36-41, 1992.