



Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Classificação do Impacto de Variáveis Microclimáticas na Formação do Índice de Variância do Campo Termal Urbano em Ilhas de Calor Urbano em Cuiabá-Mato Grosso

Alberto Sales e Silva¹ Raphael Souza Rosa Gomes²

¹ Doutorando em Física Ambiental, Pós-Graduação em Física Ambiental, UFMT, Cuiabá, MT, e-mail: alberto.sales@ifmt.edu.br

² Doutor, Professor Titular, Departamento de Ciência da Computação, UFMT, Cuiabá, MT, e-mail: raphael@ic.ufmt.br

Artigo recebido em 14/09/2024 e aceito em 30/12/2024

RESUMO

Avaliar o impacto que as variáveis microclimáticas umidade relativa do ar, Índice de Vegetação por Diferença Normalizada (NDVI), direção dos ventos locais e velocidade dos ventos locais tem na ocorrência do Fenômeno de Ilha de Calor Urbano (UHI) pode nos auxiliar na compreensão da formação de ilhas de calor. Uma das formas de se avaliar é utilizar uma abordagem de classificação de dados através de Floresta Aleatória para analisar os cenários da influência do Índice de Variância do Campo Termal Urbano (UTFVI) nestas variáveis microclimáticas e, desta forma, compreender quais as tendências que podem ocorrer diante das mudanças comportamentais destas variáveis microclimáticas. Para alcançar estes objetivos, será realizado uma modelagem de dados com imagens e dados amostrais obtidos dos satélites Landsat 7, Landsat 8 e dados de reanálise ERA5. Com as imagens obtidas, será feito um procedimento de classificação da cobertura do solo e com dados de reanálise ERA5 a classificação do UTFVI. Quando da aplicação do algoritmo de Floresta Aleatória, o modelo foi gerado com uma amostra de dados reduzida a níveis de indicação do UTFVI para a determinação do acontecimento do Fenômeno UHI (forte, muito forte e extremo) e assim obter um modelo preditivo mais preciso. Além da investigação sobre o impacto das variáveis microclimáticas no UTFVI, buscou-se detectar tendências nas séries temporárias das variações das variáveis microclimáticas com relação ao UTFVI e a obtenção dos resultados demonstram a importância do aprendizado de máquina para melhorar a detecção dos fatores que levam a condições perigosas da existência do Fenômeno UHI.

Palavras-chave: UTFVI, dados de reanálise, floresta aleatória, ilhas de calor urbano.

Classification of the impact of microclimatic variables on the formation of the Urban Thermal Field Variance Index in Urban Heat Islands in Cuiabá-MT

ABSTRACT

Evaluating the impact that microclimatic variables relative air humidity, Normalized Digital Vegetation Index (NDVI), local wind direction and local wind speed have on the occurrence of the Urban Heat Island Phenomenon (UHI) can help us understand the formation of heat islands. One of the ways to evaluate is to use a data classification approach through Random Forest to analyze the scenarios of the influence of the Urban Thermal Field Variance Index (UTFVI) on these microclimatic variables and, in this way, understand which trends may occur due to behavioral changes in these microclimatic variables. To achieve these objectives, data modeling will be carried out with images and sample data obtained from Landsat 7, Landsat 8 satellites and ERA5 reanalysis data. With the images obtained, a soil cover classification procedure will be carried out and with ERA5 reanalysis data the UTFVI classification will be carried out. When applying the Random Forest algorithm, the model was generated with a data sample reduced to UTFVI indication levels to determine the occurrence of the UHI Phenomenon (strong, very strong and extreme) and thus obtain a more accurate predictive model. In addition to investigating the impact of microclimatic variables on the UTFVI, we sought to detect trends in the temporary series of variations in microclimatic variables in relation to the UTFVI and obtaining the results demonstrate the importance of machine learning to improve the detection of factors that lead to dangerous conditions for the existence of the UHI Phenomenon.

Keywords: UTFVI, Data reanalysis, Random Forest, urban heat island.

Introdução

A interferência humana no meio ambiente vem causando grandes e conflitantes impactos: de um lado essa interferência leva ao progresso onde a socialização é um fator bastante importante e de outro lado há impactos negativos como o aumento das temperaturas e o declínio da vegetação (Enteria et al., 2021; Ullah et al., 2023). Num esforço de compreender as consequências destes impactos negativos na ecologia, muitos estudos estão sendo realizados na tentativa de se analisar os efeitos danosos desta interferência (Cheval et al., 2024). Um dos aspectos destes impactos mais comumente estudado é a formação de ilhas de calor cujos fundamentos antropogênicos favorecem a concentração urbana implicando em óbvio declínio ecológico já que nesse processo de urbanização a vegetação é suprimida sendo substituída por edifícios, asfaltos e concretos causando mudanças na temperatura local (Costa, 2017).

Ilha de calor urbano (UHI) nada mais é do que a diferença da temperatura, da superfície do solo ou do ar, existente entre a área urbana e a área não urbana (o ambiente rural em torno da cidade) (Jabbar et al., 2023). A compreensão de todos os aspectos da formação de ilhas de calor é bastante complexa e uma forma minimizar esta complexidade é buscar compreender alguns aspectos de como variáveis microclimáticas como a umidade relativa do ar, direção e velocidade dos ventos, vegetação, temperatura da superfície do solo e temperatura do ar podem proporcionar uma investigação mais eficaz e menos complexa para revelar os efeitos nocivos derivados deste fenômeno (Teshamariam et al., 2023).

Uma das formas de se realizar esta investigação é com uso de análise de modelos que usam dados para estimar tendências através de séries espaço-temporais. Assim, implementar classificação destes dados para conhecer o comportamento microclimático de UHI pode ser bastante útil, uma vez que com ela é possível estimar quais as influências que as variáveis microclimáticas têm entre si ou uma sobre a outra.

A obtenção de dados climáticos por meio do uso de satélites proporciona facilidade e diminui custos operacionais com os equipamentos tradicionais de medição, muito embora estes equipamentos sejam dotados de alta precisão e de especificidade. O problema com o uso destes equipamentos surge quando há a necessidade de se captar dados de uma grande área, devido a possibilidade de se empregar uma grande quantidade destes maquinários. O que pode tornar inviável a realizar de pesquisas no contexto

climático por conta dos custos financeiros e mesmos logísticos.

Desta forma, fazer uso de dados e imagens de satélites é uma boa alternativa aos custos pelo uso repetitivo de equipamentos específicos. Através dos satélites, podemos obter dados amostrais por meio de conjunto de dados de reanálise ERA5 (Johannsen et al., 2024; Nogueira et al., 2022), que combina modelos climáticos com dados de satélites observacionais e sensores de solo, e de imagens (Landsat 7 e 8). Com imagens e dados de reanálise, será possível a realização, neste trabalho, de estudos das variáveis microclimáticas com análise espaço-temporal no contexto da formação de ilhas de calor urbano em Cuiabá-MT.

A cidade Cuiabá, por ser uma cidade bastante quente, sofre efeitos adversos da intensidade do calor antropogênico e estes efeitos são expressivamente negativos para a saúde da população, para a vegetação natural e ainda para a economia local. Além de ser muito quente, Cuiabá sofre muito com a baixa frequência de ventos o que pode intensificar os efeitos nocivos das altas temperaturas e consequentemente impactar diretamente na formação de ilhas de calor. Assim, Cuiabá se torna muito vulnerável às consequências das altas temperaturas, tais como o aumento dos casos de enfermidades e alta demanda de energia (De Paula et al., 2021).

A classificação de dados (Borodulin et al., 2024; Pandey; Muthuraman; Shrivastava, 2018) é uma técnica utilizada em algoritmos de aprendizado de máquina e pode ser empregada tanto na predição de eventos quanto em tomada de decisões e a Floresta Aleatória (Random Forest), que realiza classificação de dados, será utilizada neste trabalho para análise de cenários no contexto de formação de ilhas de calor sob a influência de variáveis microclimáticas.

Então, estudar a influência no direcionamento dos ventos, através da classificação de dados de variáveis microclimáticas, pode ser de grande valia no que diz respeito a implantação de mecanismos que acarretem o bom aproveitamento da ocorrência dos escassos ventos em Cuiabá ou mesmo em outras cidades com características similaridades e também de alguma forma de identificar a influência na formação do Fenômeno UHI. A avaliação do UTFVI, através da exploração da heterogeneidade espaço-temporal pode prover oportunidades nessa identificação, pois este índice quantifica a qualidade da saúde e ecologia urbana (Ullah et al., 2022; Waleed et al., 2023)

O Fenômeno UHI (Çevik e Çetin, 2023; Kusumawardani; Hidayati, 2022) pode ser

estudado na perspectiva do UTFVI, e este estudo visa, como objetivo geral, analisar e verificar como os padrões das temperaturas da superfície do solo e das temperaturas do ar associadas à umidade relativa do ar impactam nas direções e velocidades dos ventos locais e de que forma podem ter influência na formação do fenômeno de Ilha de Calor Urbano (UHI), na cidade de Cuiabá-MT. E como objetivos específicos serão realizados levantamento espaço-temporal dos dados acerca da área em estudo para obtenção dos índices espectrais (Ribeiro e Araujo, 2024; Zhang et al., 2023), NDBI (Índice por diferença normalizada de áreas construídas), (Luz et al., 2019) LST (Temperatura da Superfície do Solo) e UTFVI com o objetivo de avaliar a área urbana de Cuiabá a fim de compreender a relação vegetação (NDVI) com áreas construídas com o uso de classificação da cobertura do solo através de Floresta Aleatória, compreender como se comportam os ventos locais no que diz respeito à direção e velocidade quando há uma intensificação da temperatura do solo ou do ar; e por fim a análise de cenários com base nos resultados da predição dos dados classificados para compreender a influência das variáveis

geográficas 15°50' de latitude sul e 50°10' de longitude oeste, no centro-oeste brasileiro. A Figura 1 apresenta a localização da cidade de Cuiabá, a qual está inserida no estado de Mato Grosso e no Brasil.

De acordo com a classificação Köppen (Alvares et al., 2013; Beck et al., 2018; Lima et al., 2024), seu clima é do tipo AW, tropical semiúmido com temperaturas variando entre 30°C e 36°C, com estações bem definidas: (i) seca e quente (outono-inverno) abrangendo os meses de maio a setembro; e (ii) e chuvosa e quente (primavera-verão) que abrange os meses de outubro a abril.

Com um clima típico das cidades tropicais, Cuiabá é um centro urbano conhecido como um dos mais quentes do Brasil devido às suas características geográficas, pouca ventilação e baixa altitude. A pouca ventilação, em função da baixa frequência e velocidade dos ventos, faz com que a influência antropogênica na Temperatura do Ar seja mais perceptível (Chegury et al., 2022).

Obtenção dos dados

Os dados micrometeorológicos utilizados

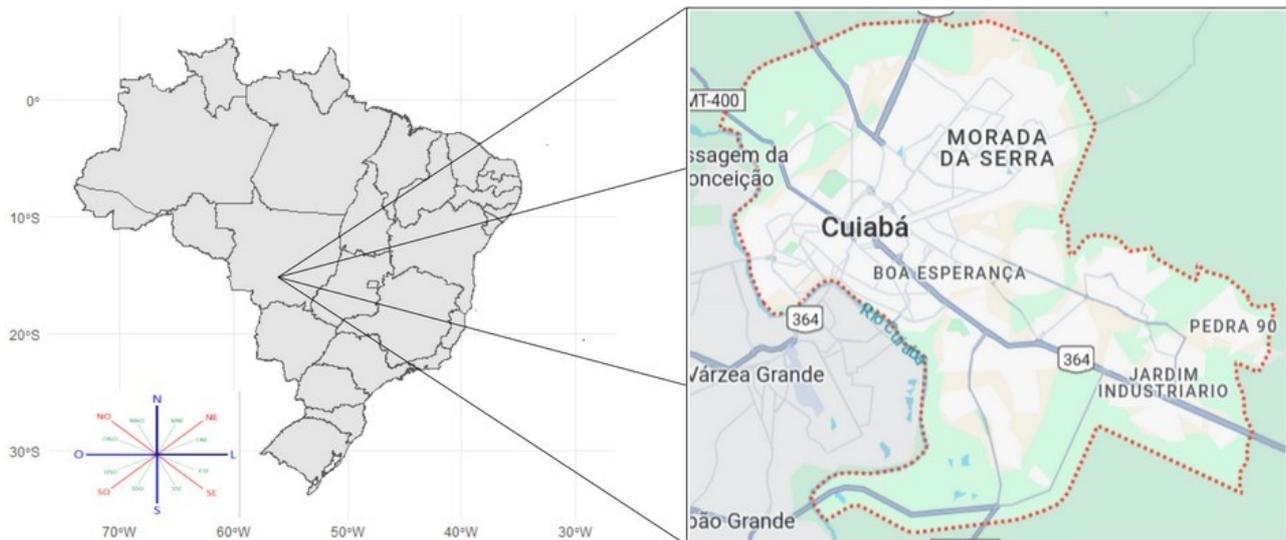


Figura 1: Localização da cidade de Cuiabá-MT (Brasil). Fonte: Google Earth Engine (acessado em 22/11/23) (Pereira e Gonçalves, 2019)

microclimáticas (NDVI, umidade relativa do ar, LST e velocidade dos ventos) direta e indiretamente no Índice de Variância do Campo Termal Urbano no sentido da formação do Fenômeno Ilhas de Calor Urbano.

Material e métodos

Área de estudo – cidade de Cuiabá-MT

A cidade de Cuiabá, capital do estado de Mato Grosso, está situada entre as coordenadas

neste trabalho foram obtidos de duas fontes, satélites e dados de reanálise. Sendo que as informações dos índices espectrais (LST e NDVI) foram obtidos através da captura de imagens dos satélites Landsat 7 e 8 e os dados de reanálise foram obtidos do produto ERA5 (Temperatura da Superfície, Temperatura do Ar, Umidade Relativa do Ar, Direção dos Ventos, Velocidade dos Ventos), além das coordenadas geográficas de latitude e longitude. A obtenção destas

informações foi através da plataforma Google Earth Engine (code.earthengine.google.com).

A Figura 2 apresenta um fluxograma das etapas que foram realizadas, as quais indicam uma preparação dos dados obtidos em relação a área de estudo para serem utilizados como informações de entrada no pré-processamento para análise posterior. As cores destacadas identificam as fases de cada etapa, onde o verde indica a origem das imagens e a etapa de cor marrom aborda os dados que foram utilizados para a derivação dos índices espectrais (NDVI, LST, UTFVI, NDBI). Já na fase de processamento (cor azul) foi aplicado aos dados o algoritmo de Floresta Aleatória para a realização da análise estatística e classificação dos dados. No procedimento de análise estatística foram utilizados o índice Kappa (Mchugh, 2012) e Matriz de Confusão (Düntsche e Gediga, 2019). O índice Kappa é um método estatístico para medir a concordância entre avaliadores ou observadores e a Matriz de Confusão fornece uma tabela que resume o desempenho de um modelo de

classificação, por exemplo Floresta Aleatória, comparando dados previstos com dados verdadeiros.

Cálculos dos índices

Índice de vegetação por diferença normalizada (NDVI)

O NDVI foi proposto por (Rouse et al., 1974) com o objetivo analisar as mudanças ocorridas na cobertura do solo em função da vegetação. O procedimento aplicado é uma separação da vegetação do brilho do solo através de dados obtidos de satélites, como Landsat e Modis. Como a cobertura do solo muda constantemente devido a sazonalidade do próprio desenvolvimento e ou atividade da vegetação, este índice permite comparações de dados temporais e espaciais das condições da vegetação (Nery et al., 2014).

Conforme proposto por (Rouse et al., 1974) a equação geral do NDVI é calculada pela diferença da reflectância e pela divisão da soma entre a faixa do infravermelho médio e a faixa do

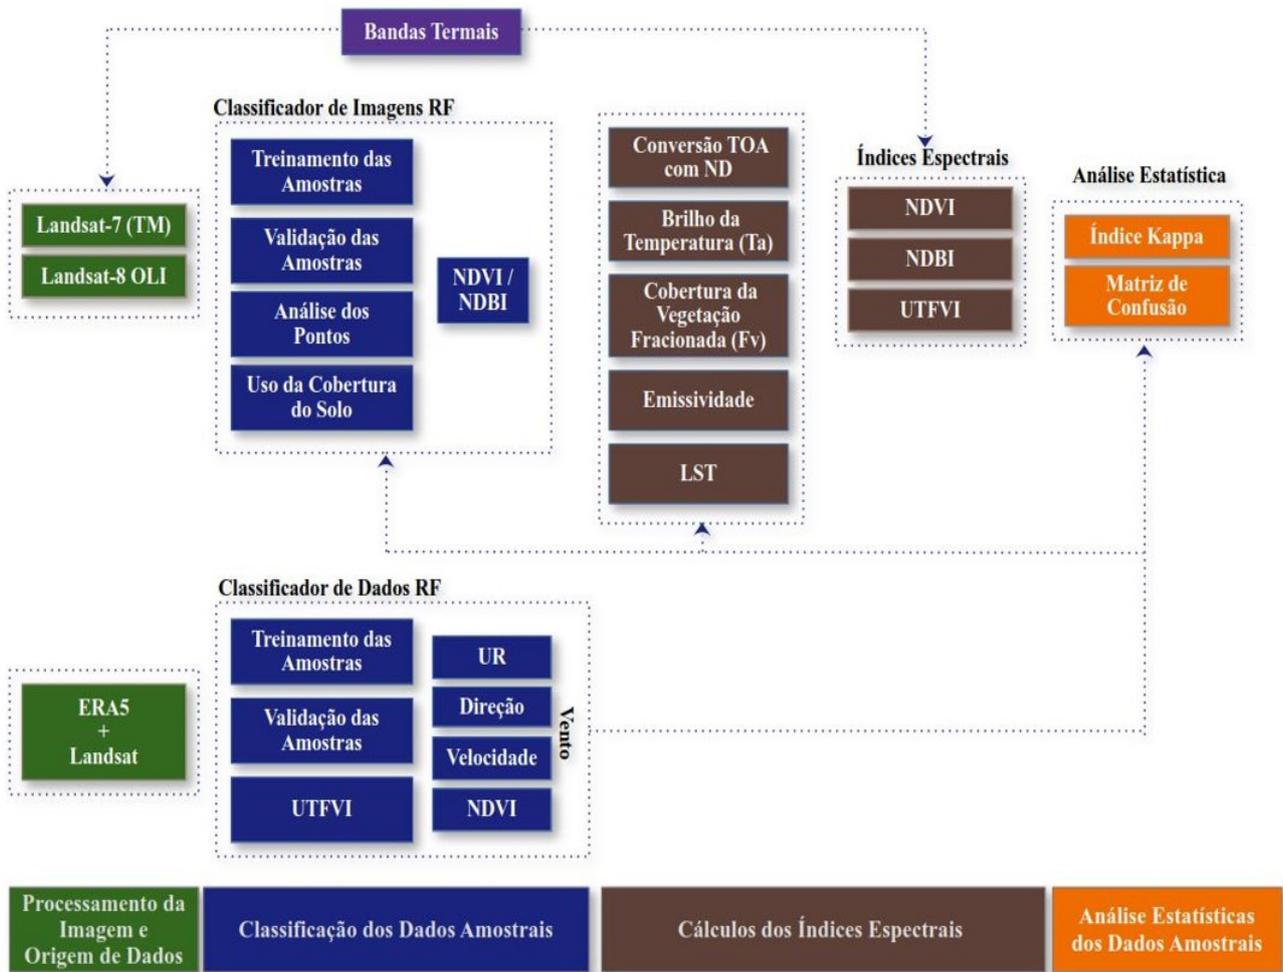


Figura 2: Fluxograma dos dados meteorológicos e pré-processamento dos dados. (Baseado em Ullah et al., 2022).

vermelho (Nery et al., 2014) e é estruturada da seguinte forma:

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

onde: **NIR** = comprimento de onda do infravermelho próximo e **RED** = comprimento de onda do vermelho.

O índice **NDVI** tem o seu espectro em um intervalo entre -1 e 1 e neste intervalo os valores que estiverem próximo a -1 representam corpos d'água e ou nuvens, os valores próximos a zero indicam que o solo está exposto, valores positivos entre 0,6 e 0,80 representam a presença de vegetação.

Temperatura da superfície do solo (LST)

Segundo (Moisa et al., 2022), LST é uma variável indicativa do balanço de energia de superfície líquido impulsionado pela emissão de superfície de radiação de onda longa. Os fluxos de calor latente e sensível são fortemente influenciados pela temperatura da superfície e a distribuição de energia entre eles é governada pelo teor de umidade, tipo de superfície, Velocidade dos Ventos e emissividade.

A extração dos dados relacionados à Temperatura da Superfície do Solo se dá através das medições do espectro do infravermelho termal (TIR) feitas por sensores terrestres, aéreos ou por sensores de satélites. A recuperação do LST a partir de banda termal Landsat 8 OLI (banda 10) pode ser feita pelo seguinte algoritmo (Guha et al., 2018):

$$L_{\lambda} = 0.0003342 * DN + 0.1 \quad (2)$$

onde L_{λ} é a radiância espectral em $Wm^{-2}sr^{-1}mm^{-1}$.

$$T_B = \frac{K_2}{\ln((K_1 L_{\lambda}) + 1)} \quad (3)$$

onde: T_B é a temperatura do brilho em Kelvin (K), onde L_{λ} é a radiância espectral em $Wm^{-2}sr^{-1}mm^{-1}$; K_2 e K_1 são constantes de calibração. Para Landsat 8 OLI, K_1 é 774,89 e K_2 é 1321,08.

De acordo com (Lehoczky et al., 2017; Moisa et al., 2022) a emissividade é calculada usando método dos limites do NDVI. (Carlson e Ripley, 1997) disponibilizaram a equação para o cálculo da cobertura da vegetação fracionada. Sendo ela:

$$F_v = \left(\frac{NDVI - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \right) \quad (4)$$

onde $NDVI_{min}$ é o valor mínimo do NDVI (0,2) onde os pixels são considerados como solo nu e $NDVI_{max}$ é o valor máximo do NDVI (0,5) onde os pixels são considerados vegetação saudável.

$d\epsilon$ é o efeito da distribuição geométrica das superfícies naturais e reflexões internas. Para superfícies heterogêneas e onduladas, o valor de $d\epsilon$ pode ser de 2%.

$$d\epsilon = (1 - \epsilon_s)(1 - F_v)F\epsilon_v \quad (5)$$

onde ϵ_v é a emissividade da vegetação, ϵ_s é a emissividade do solo, F_v a vegetação fracionada e F é um fator de forma cuja média é 0,55 (Sobrinho et al., 2004).

$$\epsilon = \epsilon_v F_v + \epsilon_s(1 - F_v) + d\epsilon \quad (6)$$

onde ϵ é a emissividade. A partir das equações (4) e (5), ϵ pode ser determinado pela seguinte equação:

$$\epsilon = 0.004 * F_v + 0.986 \quad (7)$$

E finalmente, de acordo com (Weng et al., 2004) o LST deriva da seguinte equação:

$$LST = \frac{T_B}{1 + (\lambda k T_B / (hc)) \ln \epsilon} \quad (8)$$

onde λ é o tamanho da onda efetiva (10,9 mm para a banda 10 nos dados Landsat 8), k é a constante de Boltzmann ($1,38 * 10^{-23} J/K$), h é a constante de Plank ($6,626 * 10^{-34} Js$), c é a velocidade da luz no vácuo ($2,998 * 10^8 m/s$) e ϵ é a emissividade.

Índice por diferença normalizada de áreas construídas (NDBI)

O Índice por Diferença Normalizada de Áreas Construídas 5 é um indicador que combina as bandas 3 (vermelho) com a banda 5 (infravermelho de ondas curtas) e a banda 1 (azul) com a banda 4 (infravermelho próximo), para revelar variações do solo para a região de interesse utilizando o satélite Landsat 7 e as bandas B6 e B4 combinadas e B5 e B2 também combinadas para se utilizar dados de imagens do satélite Landsat 8 (Albonwas e Al-Khakani, 2022). Este indicador é usado para capturar as variações do solo livre de vegetação, é pode ser calculado utilizando as seguintes equações as quais se referem ao satélite Landsat 7 (8) e Landsat 8 (9):

$$NDBI = \frac{(B5+B3)-(B4+B1)}{(B5+B3)+(B4+B1)} \quad (9)$$

$$NDBI = \frac{(B6+B4)-(B5+B2)}{(B6+B4)+(B5+B2)} \quad (10)$$

Umidade relativa do ar (UR)

A Umidade Relativa do AR (UR) é uma medida de quanto vapor de água existe em uma mistura de água e ar em comparação com a quantidade máxima possível. A UR é uma relação entre a relação de umidade de uma mistura particular de água e ar em comparação com a relação de umidade de saturação a uma determinada temperatura (Callahan et al., 2019; Kong e Singh, 2016) diz que a UR do ar é definida como a razão entre a pressão de vapor do ar e sua pressão de vapor de saturação. (Lawrence, 2005) diz que a Umidade Relativa do Ar e a Temperatura do Ponto de Orvalho são dois indicadores amplamente usados da quantidade de umidade no ar. De acordo com (Howell e Dusek, 1995), a seguinte equação deriva a Umidade Relativa do Ar.

$$UR = ((17,269 * Td) / (273.3 + Td)) - ((17.269 * Ta) / (237.3 + Ta)) \quad (11)$$

onde: T_a se refere a Temperatura do Ar e T_d se refere a temperatura do orvalho

Índice de calor urbano (UHI)

O termo Ilha de Calor Urbana (UHI) refere-se ao aumento das temperaturas urbanas nos últimos anos denotado pela alta carga térmica, problemas relacionados à ventilação urbana e ao aumento do uso de asfalto e concreto (Enteria et al., 2021). A contribuição do calor antropogênico varia consoante a localização e a estação: durante o verão tem uma contribuição insignificante enquanto durante o inverno pode ter uma contribuição significativa (Icaza et al., 2017; Nguyen, 2020). A intensidade do UHI é dada pela diferença entre a LST das áreas urbanas e da áreas não-urbanas usando as seguintes equações (Nguyen, 2020; Waleed et al., 2023):

$$LST > \mu + 0,5 * \delta \quad (12)$$

$$0 < LST \leq \mu + 0,5 * \delta \quad (13)$$

A equação (11) se refere à área urbana e a equação (12) à área não-urbana, onde μ e δ são a média e o desvio padrão da LST da área em estudo, respectivamente.

$$UHI_N = (T_s - T_M) / T_{Std} \quad (14)$$

onde: UHI_N é o UHI normalizado, T_s é a LST, T_M é a média de LST da área em estudo e T_{Std} é o desvio padrão da LST da área em estudo.

Índice de variância do campo termal urbano (UTFVI)

O efeito UHI é um fator importante em estudos ambientais e de saúde pública e dada a importância dos efeitos causados há alguns índices de conforto térmico disponíveis para a avaliação dos impactos do UHI na qualidade de vida urbana e neste caso o UTFVI foi usado nesta análise para medir o Fenômeno UHI conforme a equação abaixo (Icaza et al., 2017; Nguyen, 2020)

$$UTFVI = \frac{T_s - T_M}{T_s} \quad (15)$$

onde: T_s é a LST do local (°C ou °K) e T_m é a média da LST de toda área em estudo.

Tabela 1: Os limites dos Índices de Avaliação Ecológica e Fenômeno de Ilha de Calor

UTFVI	Fenômeno UHI	IAE
< 0,000	Nenhum	Excelente
0,000 – 0,005	Fraco	Bom
0,005 – 0,010	Médio	Normal
0,010 – 0,015	Forte	Ruim
0,015 – 0,020	Muito Forte	Pior
> 0,020	Extremo	Pior Caso

IAE: Índice de Avaliação Ecológica

A Tabela 1 apresenta os valores limites das respectivas categorias quanto ao Fenômeno de Ilha De Calor Urbana (UHI) e cada uma destas categorias com o seu correspondente Índice de Avaliação Ecológica correlacionados com UTFVI e Fenômeno UHI (Zhang et al., 2023).

Índice de construção por diferenças normalizadas (NDBI)

O NDBI permite mapear pontos de áreas construídas manufaturadas e juntamente com o NDVI é utilizado para examinar as variações espaciais e temporais da LST (Kuma e Shekhar, 2015; Ranagalage et al., 2017). Este índice é calculado com base na diferença entre as bandas de infravermelho ondas de curtas (SWIR) e o infravermelho próximo (NIR) e tem como limites valores entre -1 e +1. Valores negativos representam corpo d'água enquanto valores altos acima de 0,40 representam áreas construídas, valores baixos representam vegetação. Exemplificando a equação temos:

$$NDBI = \frac{SWIR - NIR}{SWIR + NIR} \quad (16)$$

Resultados

Caracterização do regime dos ventos em Cuiabá-MT

Segundo (Franco et al., 2013), Cuiabá tem um regime de vento onde a direção predominante é norte (N) e noroeste (NO) durante boa parte do ano e sul (S) durante o período quente e seco (inverno) e ainda cabe ressaltar que a velocidade do vento é reduzida, porém pode ocorrer rajadas de ventos de até 35,9 m/s. Neste trabalho será adotado que o direcionamento define de onde o vento se origina e para onde se destina.

A Tabela 2 apresenta as velocidades dos ventos durante a estação e quente (21 de junho a 21 de setembro) e estação quente e úmida (21 de dezembro a 21 de março), de acordo com os dados obtidos a partir do ERA5, para os anos de 2000-2020. Os dados referendados na Figura 3 apontam que os ventos ocorridos para os respectivos anos se originam do Sul em direção ao norte e têm uma predominância que varia de 23% a 32% para ambas as estações.

Tabela 2: Velocidades médias, em m/s, dos ventos em Cuiabá-MT durante as estações quente e seca e quente e úmida para os anos 2000-2020.

Ano	Estação Quente e Seca			Estação Quente e Úmida		
	Mín.	Máx.	Média	Mín.	Máx.	Média
2000	0,06	22,50	8,12	0,12	17,69	6,38
2005	0,02	22,80	8,47	0,01	21,19	6,85
2010	0,14	23,43	8,17	0,17	18,78	6,45
2015	0,07	20,73	7,44	0,07	20,73	7,44
2020	0,22	24,13	7,93	0,07	20,31	6,27

Comportamento dos ventos locais na estação quente e seca às 09hs

Analisando o comportamento da direção e velocidade dos ventos que ocorrem na estação da seca e quente (inverno) com suas respectivas temperaturas do ar em função do horário da coleta dos dados (9hs e 15hs) realizada diariamente nos anos de 2000-2020, é possível perceber claramente a mudança de direção dos ventos, onde há uma nítida concentração no horário das 09hs e uma percepção de espalhamento no horário das 15hs (Figura 4).

Pode-se observar na Figura 3 com dados referentes ao horário das 09hs da manhã, que há uma concentração da incidência dos ventos nos quadrantes 1 e 8.

Comportamento dos ventos locais na estação quente e seca às 15hs

A imagem retratada na Figura 4, que se refere ao período da estação seca e quente dos anos

2000-2020, demonstra que os ventos locais têm os seus comportamentos explicitando uma maior incidência nos quadrantes 1 e 8 com a grande maioria das ocorrências de ventos em direção ao norte. Importante frisar também que com o aumento gradual da temperatura em função dos horários (09 hs e 15hs) os ventos tendem a uma maior dispersão.

Caracterização do campo termal urbano em Cuiabá-MT

O fenômeno da Ilha de Calor Urbana pode ser explicado por meio da análise da formação do seu campo termal e o UTFVI é o mais amplamente utilizado e mais apropriado para descrever o efeito UHI com bastante precisão (Kafy et al., 2021; Naim e Kafy, 2021; Tomlinson et al., 2011).

Tabela 3: Proporção das áreas afetadas pela condição do UTFVI em 2000-2020

Ano	Áreas afetadas pela UTFVI em km ²				Total
	Limites				
	0,005 – 0,010 (médio)	0,010 – 0,015 (forte)	0,015 – 0,020 (muito forte)	> 0,020 (extrema)	
2000	44,51	2,77	0,003	-	47,28
2005	41,28	1,19	0,92	0,02	43,41
2010	50,41	30,13	2,53	0,02	83,09
2015	44,59	20,53	1,62	0,01	66,75
2020	39,48	2,47	0,13	-	42,08

Devido aos padrões da formação ilha de calor ter uma relação direta com a cobertura do solo sabe-se que as áreas urbanas têm uma maior concentração de UTFVI em relação às áreas rurais circundantes (Teshfamariam et al., 2023).

Os efeitos nocivos causados pelo UTFVI incluem impactos adversos nos padrões dos ventos locais, diminuição da umidade, prejudicando a qualidade do ar, redução no conforto, aumento da taxa de mortalidade e influência em prejuízos mesmos que indiretos na economia, problemas ambientais, dentre outros fatores (Sejati et al., 2019; Teshfamariam et al., 2023). A prevenção dos efeitos indesejados do UTFVI e a sua identificação podem levar ao conhecimento de possíveis zonas de ondas de calor, o que pode auxiliar em políticas públicas para mitigação da formação de ilhas de calor (Najafzadeh et al., 2021).

A Figura 5 apresenta o resultado da identificação do Fenômeno UHI em Cuiabá para os períodos dos anos 2000, 2005, 2010, 2015 e 2020. Nos aspectos do índice de avaliação ecológica Fenômeno UHI, a cidade é fortemente impactada pelo campo termal e experimenta três níveis de conforto térmico: áreas de extrema condição de

considerada muito forte ($0,015 < UTFVI < 0,020$), áreas com condição nos limites entre 0,010 e 0,015, considerada forte na escala UTFVI. É possível observar, nesta figura, que em 2005 houve uma maior concentração do UTFVI na região central e nordeste da cidade de Cuiabá, na medida que cidade foi se expandindo, no decorrer dos anos, o calor ($UTFVI > 0,02$), áreas com condição considerada muito forte ($0,015 < UTFVI < 0,020$),

áreas com condição nos limites entre 0,010 e 0,015, considerada forte na escala UTFVI. É possível observar, nesta figura, que em 2005 houve uma maior concentração do UTFVI na região central e nordeste da cidade de Cuiabá, na medida que cidade foi se expandindo, no decorrer dos anos, o Fenômeno UHI começou a impactar as regiões mais ao sul e sudeste.

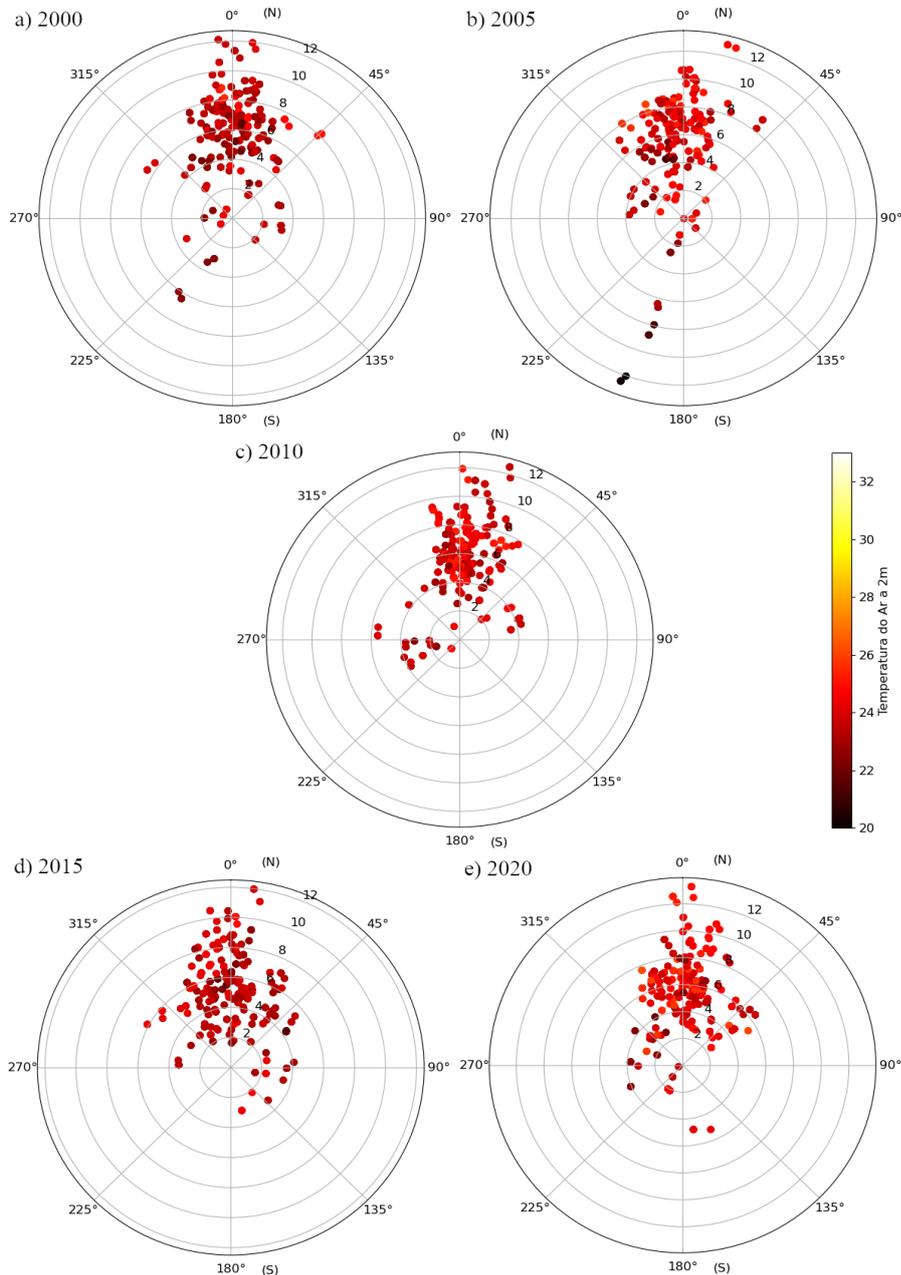


Figura 3: Rosa dos ventos apresentando a direção e velocidade dos ventos a 10 m com as respectivas temperaturas do ar para a estação quente e seca para os períodos de 2000-2020 no horário das 9 hs

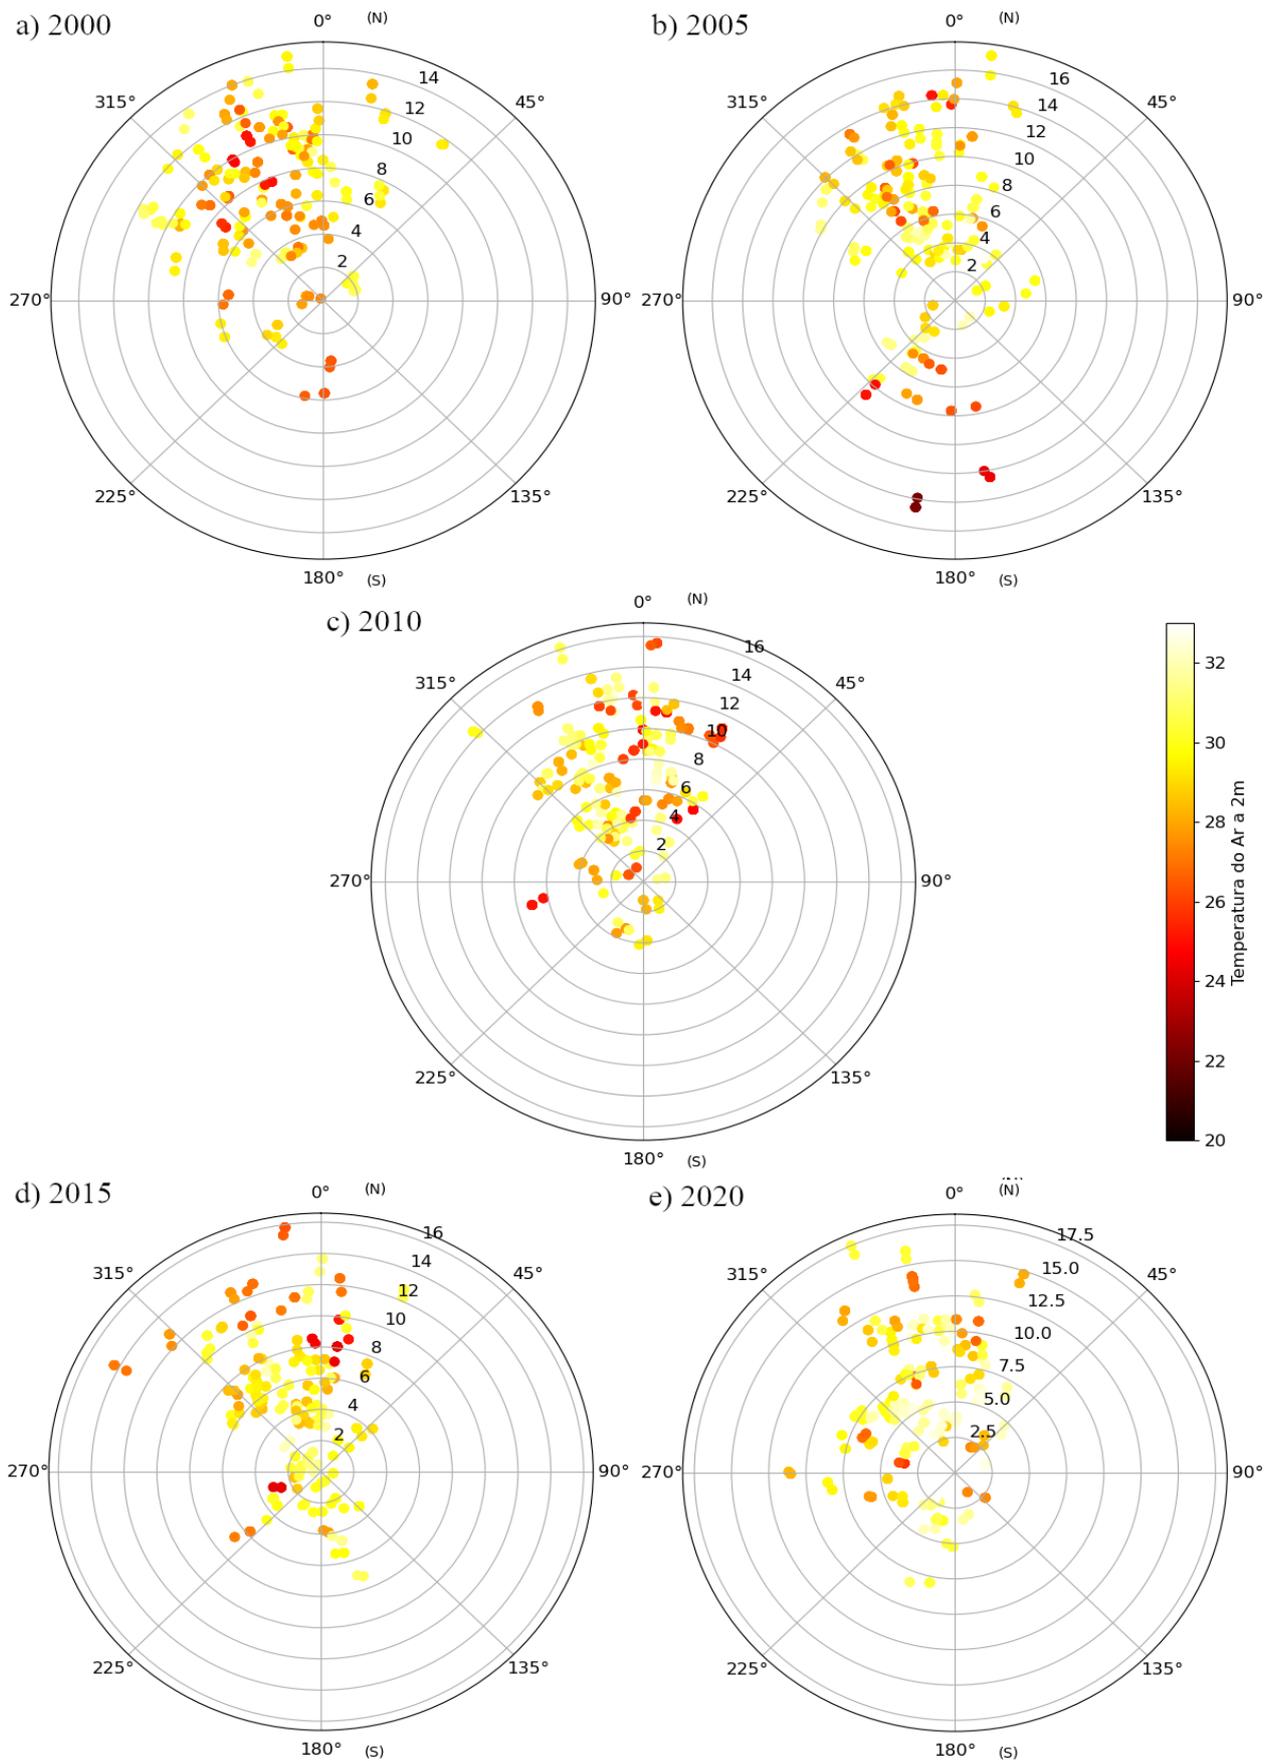


Figura 4: Rosa dos ventos apresentando a direção e velocidade dos ventos a 10 m com as respectivas temperaturas do ar para a estação quente e seca para os períodos de 2000-2020 no horário das 15 hs.

Em 2000, os registros demonstram que 43,56% dos dias (159 dias) tiveram um campo termal no grau forte quanto ao Fenômeno UHI, ou com índice de avaliação ecológica ruim, 5,75% dos dias (21) a cidade experimentou um grau muito forte e para a condição extrema foram dois dias, 10/05/2000 e 18/07/2000. Em 2005, foi constatado que em 62,46% dos dias (228) houve uma incidência do grau forte do Fenômeno de UHI, 27,67% dos dias foram afetados pela condição muito forte e 9,04% dos dias deste ano foi influenciado pelo grau extremo.

com grau muito forte e 7,12% dos dias com grau extremo na referida escala UTFVI.

No geral, a maior parte de Cuiabá tem boas condições ecológicas, neste caso, as áreas com vegetação e as áreas circundantes (rurais). No entanto, as áreas afetadas por condições muito fortes e extremas (UTFVI > 0,01) são bem significativas e estão relacionadas com a área central, as áreas residenciais e as áreas de solo descoberto.

Proporcionalmente à variação espacial de NDVI e LST, tipos de uso do solo e UHI, as áreas

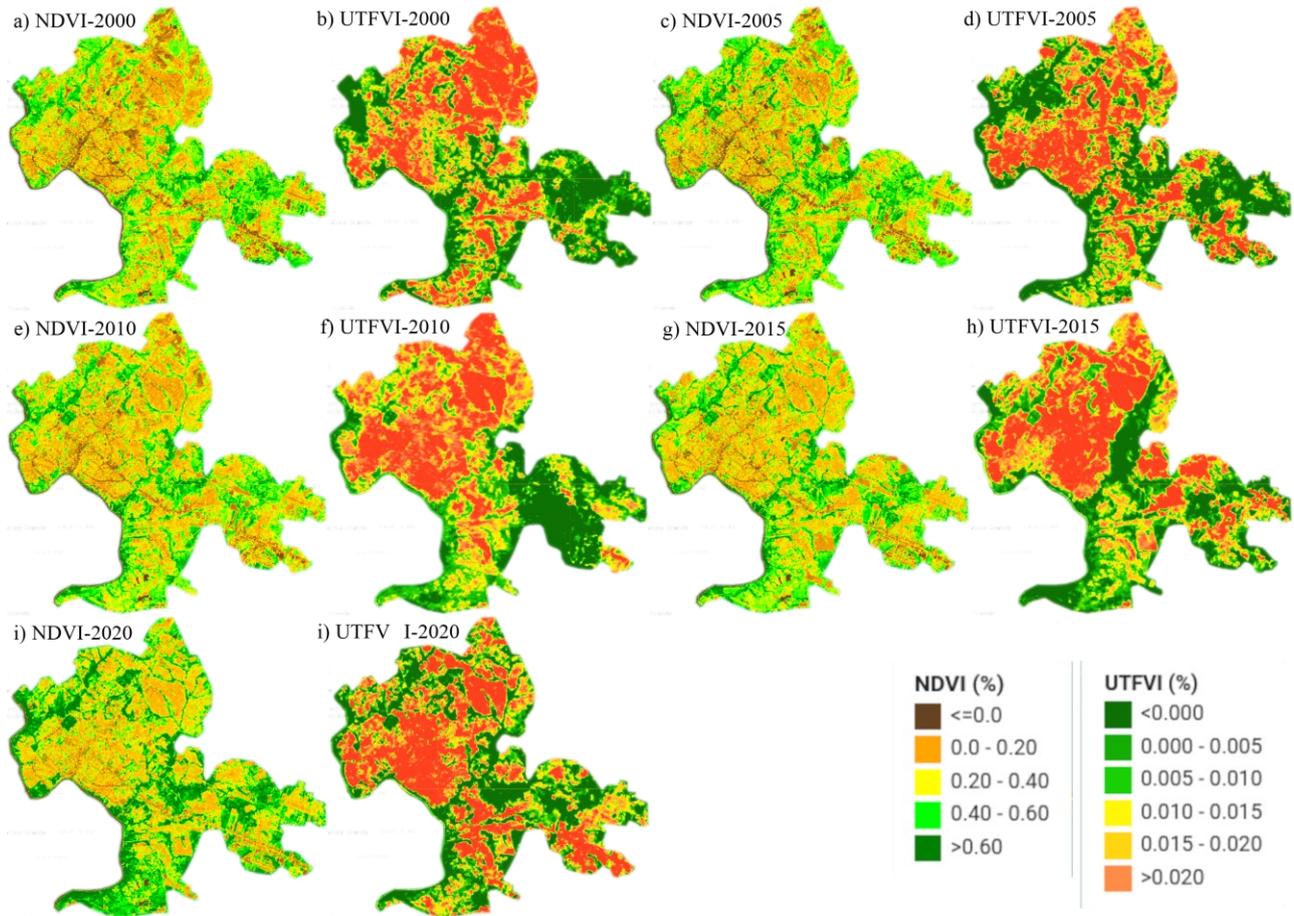


Figura 5: Mapas do UTFVI's e respectivos NDVI's de Cuiabá para o período de 2000-2020

Para o ano 2010, houve uma redução nos dias com condição forte em relação ao ano de 2005 e foi constatado 41,36% dos dias nesta faixa. 7,94% dos dias tiveram a condição estabelecida como muito forte e em apenas 3,5% dos dias a cidade experimentou a condição de grau extremo.

31,50% dos dias do ano de 2015 registram uma condição forte na escala do UTFVI, 6,02% para uma condição muito forte e em 4 dias do ano tiveram um grau extremo do UTFVI, estes dias foram 20/04/2015, 21/04/2015, 02/10/2014 e 15/12/2015. Já os graus UTFVI para o ano 2020 tiveram um aumento em relação ao ano de 2015 e atingiram 56,43% dos dias com grau forte, 16,43%

mais impactadas pela pior condição de calor em 2015 evoluíram significativamente nas regiões norte e sudeste.

A cidade de Cuiabá por estar em uma região com um clima considerado tropical é bastante impactada pela Temperatura da Superfície do Solo e como se pode observar na Tabela 3 o campo termal formado pelas condições média, forte, muito forte e extrema atinge cerca de 18% do tamanho da área urbana da cidade que tem aproximadamente 232 km².

Quando se observa a condição forte, é possível perceber que em 2010 e 2015 houve uma elevação drástica no tamanho da área do campo

termal, atingindo 30,13 km² e 20,53 km². O que pode vir a causar danos ecológicos, na saúde e até mesmo na economia local.

Análise e classificação do impacto do índice de variância do campo termal urbano (fenômeno UHI)

Sabe-se que o Índice de Variância do Campo Termal Urbano (UTFVI) é amplamente utilizado para determinar os efeitos colaterais de uma Ilha de Calor Urbana (Tomlinson et al., 2011). Um desses efeitos é o possível impacto causado nos padrões dos ventos locais, então realizar a classificação e análise, utilizando Florestas Randômicas, da influência que o UTFVI tem nos padrões dos ventos pode colaborar para a compreensão do comportamento dos ventos em uma área urbanizada. Outro aspecto a ser estudado é o quão importante pode ser o impacto dos ventos na diminuição dos efeitos negativos da formação do campo termal.

Ao utilizar o algoritmo RF é importante a preparação e adequação do conjunto de dados a ser analisado e classificado, pois a RF são algoritmos de aprendizado de máquina e nesse sentido se faz necessário realizar um treinamento do algoritmo. Para atender a esta necessidade, foi feita uma divisão no conjunto de dados em amostra de treinamento com 70% dos dados e amostra para teste (validação) com 30% dos dados, para a realização da classificação e posterior análise dos valores resultantes.

A partir de dados obtidos do sistema ERA5, foi estabelecido o uso das variáveis microclimáticas Temperatura da Superfície do Solo, Temperatura do Ar (2m), Umidade Relativa do Ar, NDVI, Direção dos Ventos, Velocidade dos Ventos e a derivação da variável Índice de Variância do Campo Termal Urbano (UTFVI).

Considerando a preparação dos dados levantados para a utilização da classificação das variáveis foram realizados ajustes na base de dados a fim de manter apenas os níveis de UTFVI significativos que são categorizados no aspecto de formação do Fenômeno UHI como (Forte, Muito Forte e Extremo) e no aspecto de índice de avaliação ecológica como ruim, pior e pior caso. Para as constituições das análises, as variáveis dependentes serão definidas de acordo com os objetivos das observações que neste caso são: (i) avaliar a influência ou impacto que o campo termal, medido pelo UTFVI, tem sobre as variáveis microclimáticas Umidade Relativa do Ar, Direção e Velocidade dos Ventos; (ii) observar como o vento (direção e velocidade) se comporta de acordo com os níveis do UTFVI, NDVI, Umidade Relativa do Ar e Temperatura da Superfície do Solo.

Serão feitas também análise com relação à formação do campo termal em função da Temperatura do Ar a dois metros aplicados aos mesmos contextos citados, ou seja, analisar qual a influência que o UTFVI a dois metros tem sobre as variáveis microclimáticas NDVI, Umidade Relativa do Ar, Direção e Velocidade dos Ventos, será feita também uma análise de qual o impacto que a Direção e Velocidade dos Ventos tem sobre as variáveis microclimáticas UTFVI a dois metros, NDVI, Umidade Relativa do Ar e Temperatura do Ar a dois metros de altura.

Análise do impacto do índice de variância do campo termal urbano nos padrões dos ventos locais em função do NDVI

Tabela 4: Matriz de Confusão e estatísticas da variável Fenômeno UHI para os dados amostrais do ano 2000.

	Treino		
	Extremo	Forte	Muito Forte
Extremo	26	2	0
Forte	2	1274	7
Muito Forte	0	2	129
Acurácia:	0,9924		
Kappa:	0,9621		
	Teste		
	Extremo	Forte	Muito Forte
Extremo	10	0	0
Forte	1	543	7
Muito Forte	0	3	51
Acurácia:	0,9821		
Kappa:	0,9088		

Com o objetivo de compreender qual a influência do NDVI em relação ao UTFVI aplicado aos padrões dos ventos locais em conjunto com a demais variáveis microclimáticas Umidade Relativa do AR, Velocidade dos Ventos e Direção dos Ventos, esta seção apresenta os resultados da classificação dos dados amostrais com o uso do algoritmo de Floresta Randômica no contexto do Fenômeno UHI na superfície do solo em relação ao NDVI.

De acordo com (Ullah et al., 2022) onde é definido, por meio da correlação de Pearson, que o NDVI tem uma relação negativa e insignificante com o Índice de Temperatura da Superfície do Solo. Portanto, analisar a relação do NDVI com o UTFVI pode ser um bom indicador no desenvolvimento urbano sustentável, pois este índice tem uma relação direta com o respectivo índice LST.

A matriz de confusão apresentada na Tabela 4 demonstra os resultados em relação à

variável Fenômeno UHI em função das variáveis microclimáticas Direção dos Ventos, Velocidade dos Ventos, Umidade Relativa do Ar e o NDVI para os dados amostrais do ano 2000. De acordo com os resultados desta Tabela, o treinamento determina uma acurácia de 99,24% nas classificações e quando aplicadas à validação dos dados (Teste) e obtido uma taxa de classificações corretas de 98,21%. Os índices Kappa aplicados aos dados amostrais para treinamento e validação

Tabela 5: Estatísticas da variável Fenômeno UHI para os dados amostrais de treinamento e teste para o Fenômeno UHI na superfície do solo dos anos de 2000-2020.

Treinamento		
	Acurácia	Kappa
2000	0,9924	0,9621
2005	0,9737	0,9351
2010	0,9926	0,9783
2015	0,9887	0,9469
2020	0,9816	0,9578
Teste		
	Acurácia	Kappa
2000	0,9821	0,9088
2005	0,8995	0,7416
2010	0,9828	0,9482
2015	0,9796	0,9011
2020	0,9176	0,8031

sugerem um alto grau de concordância nas avaliações, entre 82% e 100%, neste caso, 90,88% e 96,21%.

A matriz de confusão, apresentada na Tabela 4, demonstram que no momento do treinamento os resultados para o Fenômeno UHI Extremo indicam 26 registros classificados como verdadeiros positivos, ou seja, o valor real e o valor previsto são iguais. Dos 28 registros para o Fenômeno UHI Extremo 2 são apontados ou como falsos positivos (referindo-se a uma amostra pertencente à classe negativa, mas sendo classificada erroneamente como pertencente à classe positiva) ou falsos negativos (neste caso, referindo-se a uma amostra pertencente à classe positiva, mas sendo classificada erroneamente como pertencente à classe negativa).

Quanto ao Fenômeno UHI Forte, que contém um total de 1276 registros, há 9 registros considerados falsos negativos e 4 considerados falsos positivos. Após o treinamento do algoritmo da Floresta Aleatória, com um tamanho de 500 árvores e profundidade de nível 5, foi realizado a validação que nada mais é o uso de hiper parâmetros adequados e assim poder gerar resultados substanciais através da escolha da

Silva, A. S.; Gomes, R. S. R.

melhor variável para compor o nó raiz. Como pode-se observar na seção Teste da Tabela 4 que com apenas 30% dos dados amostrais o desempenho foi bastante similar aos resultados do treinamento, com 98,21% de acertos e uma confiança substancial de 90,88%.

Na Tabela 5, a qual se refere aos dados amostrais para ocorrência do Fenômeno UHI na superfície do solo de todos os períodos, o grau de concordância obtido pelo índice Kappa é considerado substancial (acima de 80%) para a confiabilidade da informação, de acordo com os níveis de concordância apresentados por (Mchugh, 2012) com exceção para o ano de 2015 que é considerado moderado, e segundo o índice Kappa e conforme os dados de 35% a 65% dos dados são confiáveis.

Indicadores de robustez do modelo para o fenômeno UHI na superfície do solo em função do NDVI e demais variáveis microclimáticas

Os indicadores de robustez dos modelos analisados e apresentados na Tabela 6, revelam que as estatísticas das amostras de teste do modelo são suficientes para a sensibilidade, o que expressa uma acerto na identificação das variáveis que correspondem aos Fenômenos UHI Forte com valores médios acima de 96% e Muito Forte com média acima de 73% de acerto e para os dados amostrais do ano 2015 e 2020 temos uma exceção em relação ao Fenômeno UHI Extremo que demonstrou uma precisão explicando que entre 62% e 64% são verdadeiros positivos classificados corretamente.

A árvore, com recorte parcial, relacionada aos dados amostrais, Figura 6, estruturada com uma quantidade de 500 árvores e profundidade de

Tabela 6: Indicadores preditivos referentes aos dados amostrais do período 2000-2020.

Indicadores do Teste					
Extremo	2000	2005	2010	2015	2020
Sensibilidade	0,9090	0,6250	0,9375	0,9285	0,6406
Especificidade	1,0000	0,9947	1,0000	1,0000	0,9871
Precisão	1,0000	0,8490	1,0000	0,9285	0,8118
F1	0,9523	0,7200	0,9677	1,0000	0,7161
Acurácia	0,9545	0,8098	0,9687	0,9642	0,8138
Forte	2000	2005	2010	2015	2020
Sensibilidade	0,9945	0,9673	0,9986	0,9931	0,9790
Especificidade	0,8841	0,7436	0,9206	0,8814	0,7978
Precisão	0,9855	0,9109	0,9801	0,9839	0,9232
F1	0,9900	0,9383	0,9893	0,9885	0,9503
Acurácia	0,9393	0,8555	0,9596	0,9372	0,8884
Muito Forte	2000	2005	2010	2015	2020
Sensibilidade	0,8793	0,7339	0,9120	0,9286	0,8133
Especificidade	0,9946	0,9660	0,9988	0,9931	0,9843
Precisão	0,9444	0,8618	0,9913	0,9455	0,9310
F1	0,9107	0,7927	0,9500	0,9369	0,8682
Acurácia	0,9369	0,8499	0,9554	0,9608	0,8988

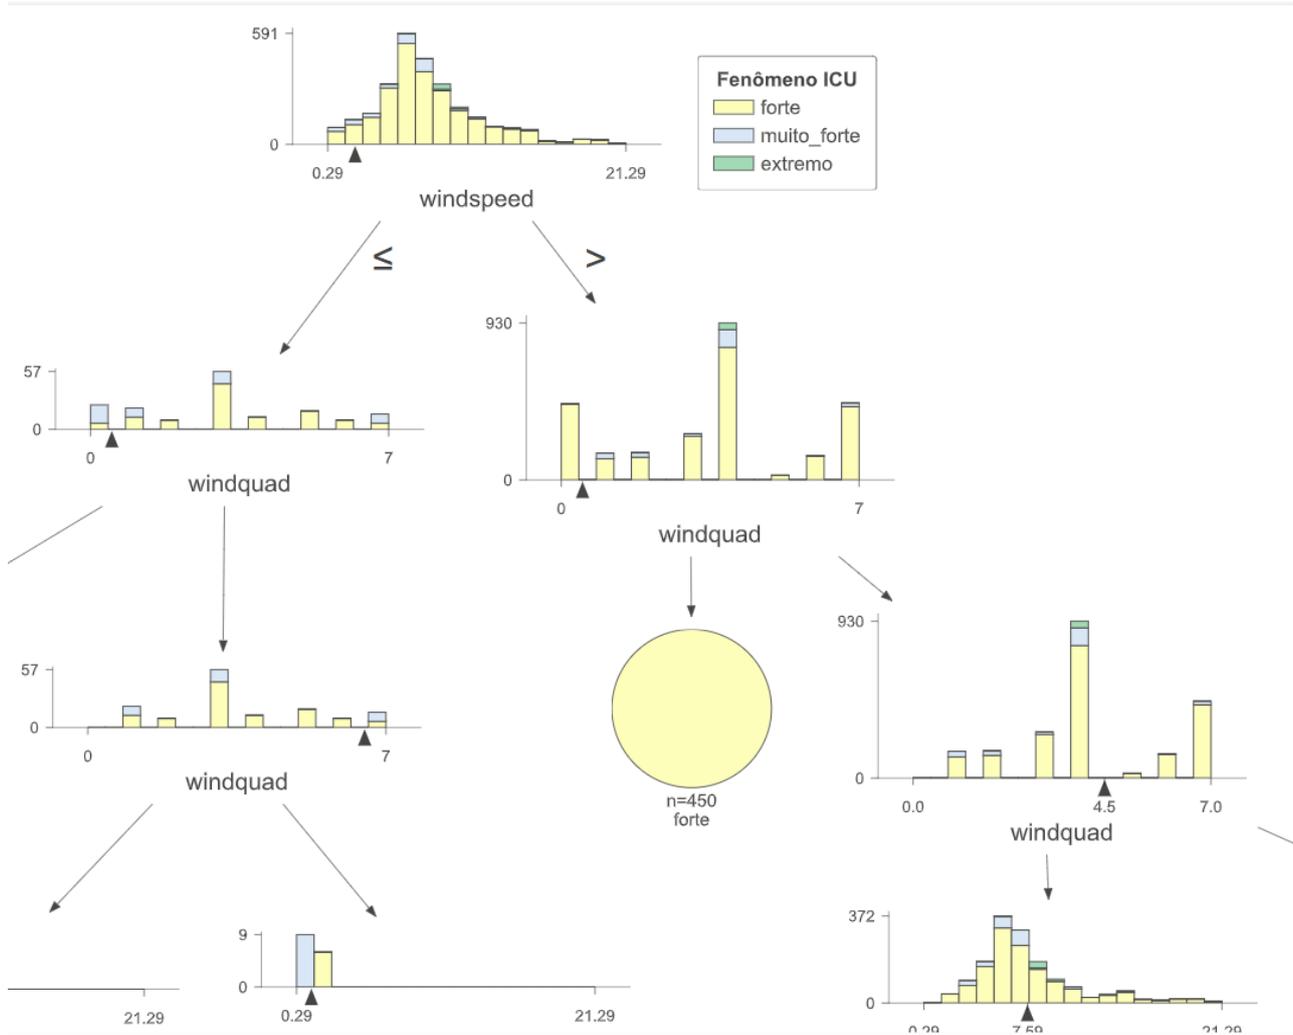


Figura 6: Floresta Randômica, com suas árvores de decisão, resultante para amostra do treinamento dos dados do ano 2000 com profundidade 6. As folhas (círculos) resultantes demonstram a classificação do Fenômeno UHI (Forte, Muito Forte e Extremo) em função das variáveis microclimáticas Umidade Relativa do Ar, NDVI, Velocidade e Direção dos Ventos Locais para UTFVI em relação à superfície do solo

5 níveis, apresenta os seus respectivos nós terminais em uma classificação dos dados utilizando a variável dependente UTFVI, derivada da Temperatura da Superfície do Solo, sendo redefinida como uma variável discreta e categórica e as variáveis independentes Umidade Relativa do Ar, Velocidade e Direção dos Ventos Locais e NDVI.

Há nesta árvore a apresentação do primeiro nó identificado como a variável microclimática RH (Umidade Relativa do Ar), definido em uma escolha, da melhor variável, aleatória por meio de *bootstrap*, de onde se origina os demais nós, os quais são derivados a partir do corte que delimita a umidade relativa o valor abaixo de 0,5022 e acima deste valor, um cálculo de votação que ocorre pela média da árvore de decisão.

Nesta árvore, podemos observar que a maior incidência dos valores do Fenômeno UHI Forte relacionados à variável dependente.

Aproximadamente 91% da frequência se refere ao Fenômeno UHI Forte e o restante são atribuídos aos Fenômeno UHI Extremo e Muito Forte.

Frisa-se o resultado onde se demonstra o nó terminal para o Fenômeno Extremo que determina que para esta classificação aconteça deve haver uma Umidade Relativa do Ar entre 50% e 51% e Velocidade dos Ventos entre 7,82 km/h e 9,21 km/h, independente das demais variáveis microclimáticas.

Caracterizando a importância das variáveis climáticas na floresta aleatória

Muitos estudos descrevem que o NDVI é preponderante na atenuação da formação de ilhas de calor, neste estudo a classificação do Fenômeno UHI demonstra que, conforme a Figura 7, o Índice por Diferença Normalizada da Vegetação não contribui para a formação do mesmo, o que contribui para afirmar que o NDVI tem influência

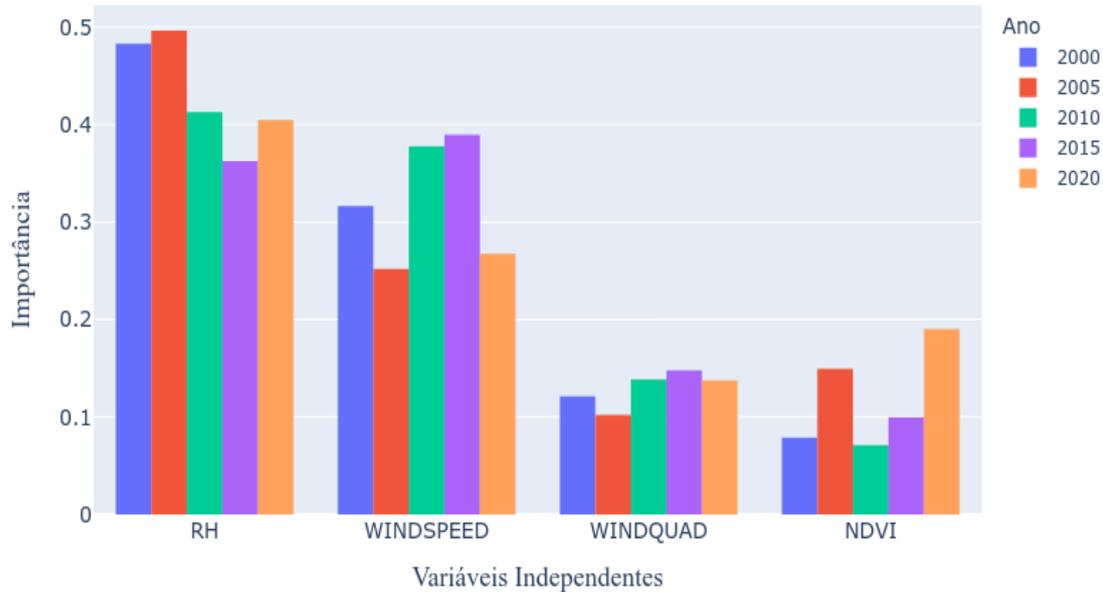


Figura 7: Classificação da importância das variáveis independentes para UTFVI em relação à superfície do solo referentes aos dados amostrais do período de 2000-2020.

negativa com relação a formação do Fenômeno UHI. Nesta Figura, a Umidade do Relativa do Ar e a Velocidade dos Ventos são de maior importância, em especial a Umidade do Ar.

A distribuição indica que a Umidade do Ar tem uma importância acima dos 35% formação dos Fenômeno UHI Forte, Muito Forte e Extremo. O

NDVI forem retiradas do modelo causarão imprecisão do mesmo.

Quanto a medida da importância baseada na impureza, a Figura 9 revela a contribuição de cada variável para homogeneidade dos nós e folhas na Floresta Aleatória resultante (Figura 6). É demonstrado na Figura 9 que a variável NDVI não

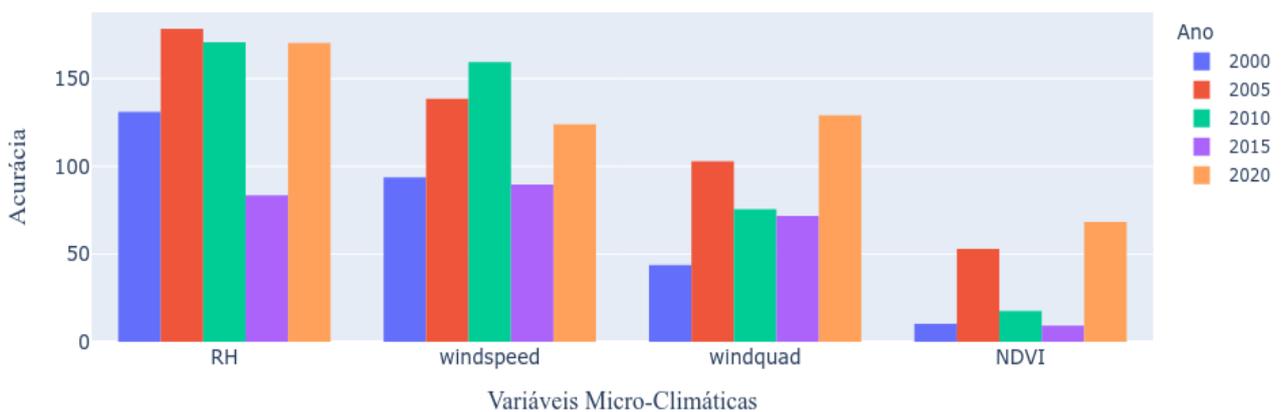


Figura 8: Médias do decréscimo da acurácia referentes ao período 2000-2020 para UTFVI a 2 metros de altura.

NDVI contribui com uma média de apenas 11% e a Direção dos Ventos com média de 12%, se equivalendo na pouca influência no Índice de Variação do Campo Termal Urbano.

Para verificar a precisão do modelo a Figura 8 externa a ordem da importância das variáveis e explicita que se as variáveis RH (Umidade Relativa do Ar), windspeed (Velocidade dos Ventos), windquad (Direção dos Ventos) e

causará grande impacto na homogeneidade do modelo caso seja removida, o mesmo acontecerá para a variável windquad (Direção dos Ventos) em especial para os dados amostrais dos anos 2000 e 2015.

Análise do impacto do índice de variância do campo termal urbano a 2 metros de altura nos padrões dos ventos locais em função do NDVI.

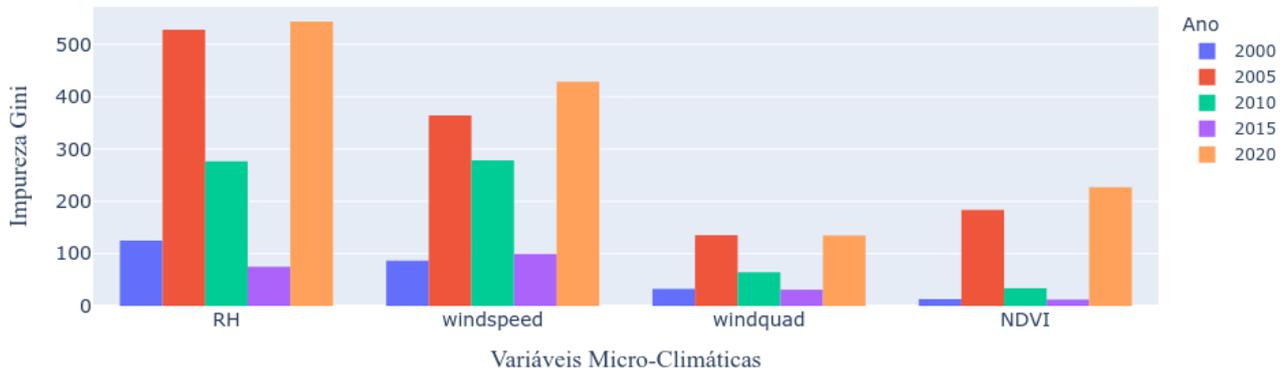


Figura 9: Médias dos decréscimos Gini referentes ao período 2000-2020 para UTFVI em relação à Temperatura da Superfície do Solo.

Na seção anterior foram estudados os efeitos do NDVI e demais variáveis no UTFVI derivado da Temperatura da Superfície do Solo e nesta serão estudados a repercussão do NDVI e demais variáveis na formação dos Fenômenos UHI Forte, Muito Forte e Extremo e sua influência no comportamento dos ventos locais. A Tabela 7 expressa os resultados da matriz de confusão em função da variável Fenômeno UHI a 2 metros (UTFVI2m) e respectivas variáveis microclimáticas Direção e Velocidade dos ventos locais, Umidade Relativa do Ar e o índice espectral NDVI.

A matriz de confusão delimita uma acurácia de 99,44% para o treinamento e 96% para a validação dos dados amostrais pela Floresta Aleatória, o que remete à uma taxa de acerto da predição com uma performance bastante alta e uma forte concordância nas avaliações dos dados amostrais.

Percebe-se que há 1 registro detectado no momento do treinamento como falso-negativo, ou seja, este registro foi classificado erroneamente como pertencente à classe negativa (Fenômeno UHI Muito Forte) e que há 3 registros nesta mesma categoria classificado como falsos negativos.

Os índices estatísticos visualizados na Tabela 8 indicam uma alta precisão da predição dos dados e uma confiança, no geral, substancial.

Indicadores de robustez do modelo para o fenômeno UHI a 2 metros de altura em função do NDVI e demais variáveis microclimáticas

A robustez dos indicadores preditivos para os modelos identificados na Tabela 9, expõe que as estatísticas das amostras de afirmação do treinamento dos dados são suficientes para todos os indicadores estatísticos, determinando assim uma correteza na identificação das variáveis que

correspondem aos Fenômenos UHI Extremo e Forte.

No que tange a Sensibilidade (taxa de valores reais previstos e relação ao número total de valores reais) para o Fenômeno UHI Muito Forte, os dados do ano 2000 explicita uma baixa correspondência na suficiência, porém no decorrer dos demais períodos os valores se reafirmaram, sendo suficientes.

Caracterizando a importância das variáveis climáticas na floresta aleatória

A importância das variáveis microclimáticas, no tocante à classificação do Fenômeno UHI a 2 metros é visualizada na Figura 10 a qual demonstra que a variável Velocidade dos Ventos (windspeed) tem uma importância definida entre aproximadamente 40% e 56%. A direção dos Ventos e NDVI não tem importância quando se trata de predição do Fenômeno UHI em Ilha de Calor Urbana.

É nítido que a manutenção da precisão do modelo recai sobre variável microclimática Velocidade dos Ventos (windspeed) no contexto do Fenômeno UHI em função do NDVI e demais variáveis. Nota-se também que a variável NDVI não influencia na formação do UTFVI a 2 metros de altura, dada a baixa Média do Decréscimo da Acurácia, conforme é apresentado na Figura 11.

A média do Decréscimo da Acurácia para a variável NDVI ficou estabelecida entre aproximados -3 e 15, conforme a Figura 11. Quanto à Média do Decréscimo Gini, que mensura a homogeneidade dos dados, a Figura 12 a externa a importância das variáveis microclimáticas Velocidade dos Ventos e a Umidade Relativa do Ar.

Discussão

A aplicação, neste estudo, da técnica de classificação de dados utilizando Floresta Aleatória proporcionou resultados analíticos que permitiu

observar como se deu a evolução da expansão do fenômeno de ilhas de calor na cidade de Cuiabá.

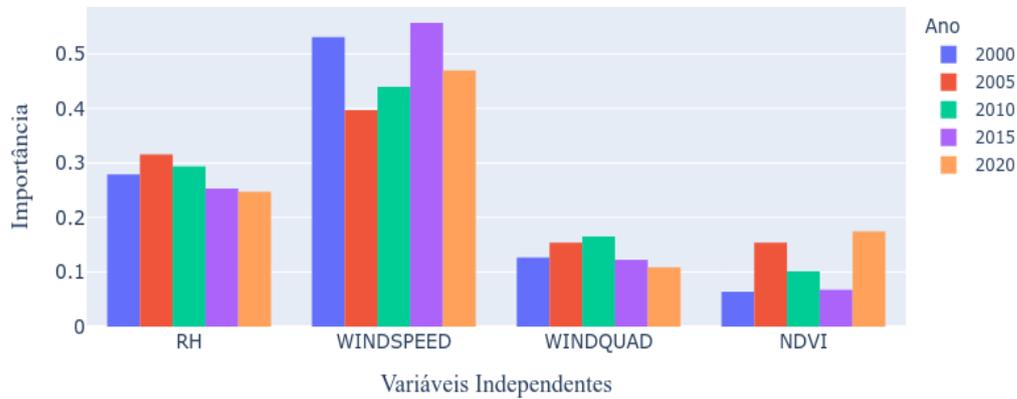


Figura 10: Classificação da importância das variáveis independentes para UTFVI a 2 metros de altura resultantes da classificação dos dados amostrais do período de 2000-2020.

Segundo (Abir et al., 2021; Fung et al., 2022) o uso de Floresta Aleatória na classificação de zonas climáticas locais por meio de estudo da incorporação de estruturas impermeáveis e identificou o impacto destas zonas na formação de Ilhas de Calor Urbano.

Em outro estudo, (Abir et al., 2021) realizou pesquisa sobre a aplicação de aprendizado de máquina para caracterizar a superfície do Fenômeno da Ilha de Calor Urbano e desta forma estimar a formação do UTFVI e a analisar a sua distribuição espaço-temporal.

Expansão da ilha de calor em Cuiabá

Tabela 7: Matriz de Confusão e estatísticas da variável Fenômeno UHI a 2 metros de altura para os dados amostrais do 2000.

	Treino		
	Extremo	Forte	Muito Forte
Extremo	15	0	1
Forte	0	140	0
Muito Forte	0	0	22
Acurácia:	0,9944		
Kappa:	0,9843		
	Teste		
	Extremo	Forte	Muito Forte
Extremo	6	0	3
Forte	0	60	0
Muito Forte	0	0	6
Acurácia:	0,9600		
Kappa:	0,8826		

Inicialmente, com o uso da ferramenta *Google Earth Engine*, foram obtidas imagens que demonstraram os níveis atingidos pela Temperatura da Superfície do Solo, o índice de vegetação por diferença normalizada (NDVI) e também o índice de área construída por diferença normalizada (NDBI) e dessa forma pôde-se obter uma análise visual da expansão das áreas construídas e a consequente ocupação desordenada do solo, como pode ser observado na Figura 13.

Na Figura, é possível observar que, proporcionalmente, a área de vegetação diminui na medida que se aumenta a área construída, isto não necessariamente implica em construções, mas pode ter ocorrido a diminuição da área vegetada, por meios de desmatamentos e queimadas.

Tabela 8: Estatísticas da variável Fenômeno UHI a 2 metros de altura para os dados amostrais de treinamento e teste dos anos de 2000-2020.

	Treinamento	
	Acurácia	Kappa
2000	0,9944	0,9843
2005	0,9654	0,9078
2010	0,9802	0,9624
2015	1,0000	1,0000
2020	0,9873	0,9734
	Teste	
	Acurácia	Kappa
2000	0,9600	0,8826
2005	0,9104	0,7469
2010	0,9813	0,9543
2015	1,0000	1,0000
2020	0,9704	0,9346

Mas, de modo geral, nesta Figura houve apenas representação dos índices espectrais LST, NDVI e NDBI que são obtidos através de cálculos que analisa o espectro da vegetação, albedo dos materiais e do solo.

Considerando apenas os limites dos índices espectrais já foi possível visualizar a dimensão das áreas de vegetação e das áreas construídas e na finalidade de confirmar e até complementar os resultados destes índices aplicou-se o algoritmo de classificação de Floresta Aleatória (*smileRandomForest*) que demonstrou uma clara e evidente diferença na distinção de áreas vegetadas das áreas construídas, inclusive corpos d'água e solo nu, e na variação, mesmo que indireta, do UTFVI sobre diferentes classes de coberturas de solo e sua sazonalidade em função das estações do ano. Assim como demonstrado nos estudos de (Kafy et al., 2021) que apontam para uma similaridade entre os períodos mais frios e mais quentes. Em outro estudo, onde foi implementado análise de correlação entre os índices NDBI, NDVI, LST e o UTFVI, os autores (Kikon et al, 2023) apontaram para uma forte correlação entre os índices NDBI e UTFVI e uma baixa correlação entre o NDVI e UTFVI, o que corrobora com este estudo na afirmação de que o UTFVI tem alto impacto em áreas com influências antropogênicas.

Na imagem da Figura 14 observou-se uma nítida diferença quando da aplicação do algoritmo de classificação resultando em uma acurácia de 86,47%, o que a caracteriza como satisfatória na classificação da cobertura do solo para a imagem

Tabela 9: Indicadores preditivos referentes à validação (Teste) dos dados amostrais para o período 2000-2020.

Extremo	2000	2005	2010	2015	2020
Sensibilidade	1,0000	1,0000	1,0000	1,0000	1,0000
Especificidade	0,9565	1,0000	1,0000	1,0000	1,0000
Precisão	0,6667	1,0000	1,0000	1,0000	1,0000
F1	0,8000	1,0000	1,0000	1,0000	1,0000
Acurácia	0,9783	1,0000	1,0000	1,0000	1,0000
Forte	2000	2005	2010	2015	2020
Sensibilidade	1,0000	0,9515	1,0000	1,0000	1,0000
Especificidade	1,0000	0,7742	0,9298	1,0000	0,9024
Precisão	1,0000	0,9333	0,9752	1,0000	0,9592
F1	1,0000	0,9423	0,9874	1,0000	0,9792
Acurácia	1,0000	0,8629	0,9649	1,0000	0,9512
Muito Forte	2000	2005	2010	2015	2020
Sensibilidade	0,6667	0,7586	0,7777	1,0000	0,8261
Especificidade	1,0000	0,9524	1,0000	1,0000	1,0000
Precisão	1,0000	0,8148	1,0000	1,0000	1,0000
F1	0,8000	0,7857	0,8750	1,0000	0,9048
Acurácia	0,8334	0,8555	0,8889	1,0000	0,9131

do ano 2000 onde foi utilizada o satélite Landsat 7. Percebe-se na imagem uma tímida representação da cobertura de solo nu, em contraste a área vegetada e a área urbana estão bem caracterizadas. Por outro lado, com o uso das imagens do satélite Landsat 8 já foi possível haver uma melhor classificação, através do algoritmo, onde notou-se uma evolução na apresentação da imagem relacionado ao ano 2020, com resultado da acurácia ficando em torno de 95%, o que é bem representativo.

Em resumo, quando obtidos bons dados e imagens de satélites e quando bem treinado o algoritmo de Floresta Aleatória apresenta respostas quase perfeitas na classificação da cobertura do solo.

Análise estatística da classificação do Fenômeno UHI

Na Tabela 10 são exibidos a avaliação estatística onde é demonstrado o desempenho obtido na classificação dos dados em relação ao UTFVI na Superfície do Solo. Nesta tabela, o coeficiente de determinação (R^2) revela que 97% da variável categorizada derivada de UTFVI é explicada pelas variáveis independentes (RH, windspeed e windquad) para o treinamento e 96% para a validação dos dados amostrais na classificação das variáveis referentes ao ano 2000.

Em 2005, o coeficiente de determinação foi estabelecido em 86% para o treinamento dos dados e 82% para a testagem dos dados. Para 2010, R^2 foi de 92% para o treinamento e 94% como resultado da classificação na validação dos dados. 2015 os resultados obtidos evidenciam que os coeficientes da classificação para treinamento e teste dos dados ficaram em 97%.

Na Tabela 10 são exibidos ainda, para a classificação dos dados do período de 2000-2020, os resultados do coeficiente de determinação em 86% para o treinamento e 85% quando da testagem dos dados, indicando o quanto a variação observada pode ser explicada pelos dados do modelo. Apesar da avaliação estatística revelar que o desempenho do coeficiente de determinação para a classificação dos dados dos anos 2005 e 2020 ficarem abaixo em relação aos demais períodos avaliados, no geral os resultados acima 80% do R^2 indicam que mais variabilidade é explicada pelo modelo.

Quanto a análise da diferença absoluta entre os valores previstos pelo modelo e os valores observados expressada pelo erro médio absoluto (MAE), têm-se que o acerto das predições são mais acentuados para o ano 2000 e 2015, para os demais

anos o MAE indica um certo afastamento das previsões do modelo real, em média.

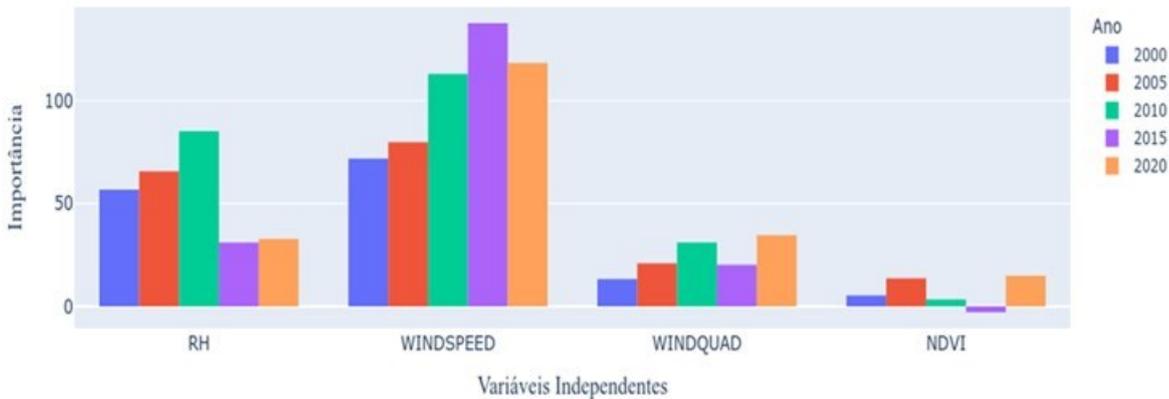


Figura 11: Médias dos decréscimos da acurácia referentes ao período 2000-2020 para UTFVI a 2 metros de altura.

Para os modelos relacionados à UTFVI a 2 metros de altura, percebe-se, conforme a Tabela 10, que apenas para o ano 2000 houve uma predição para a validação dos dados amostrais que se aproxima muito da realidade do modelo onde o Erro Médio Absoluto está em 0,02. Nos demais anos os erros médios absolutos tendem a erros na previsão e demonstram um certo distanciamento das previsões dos modelos reais.

Ao avaliar o modelo com a inclusão do índice espectral NDVI na classificação do

treinamento dos dados amostrais em relação ao UTFVI na superfície do solo temos os resultados indicando que a maioria das variáveis explicativas (RH, windspeed, windquad e NDVI) são estatisticamente significativas, com o coeficiente de determinação (R^2) acima de 0,80 tanto para o treinamento quanto para a avaliação dos dados amostrais, o que implica em dizer que a relação entre as variáveis é considerada forte, conforme podemos observar na Tabela 11.

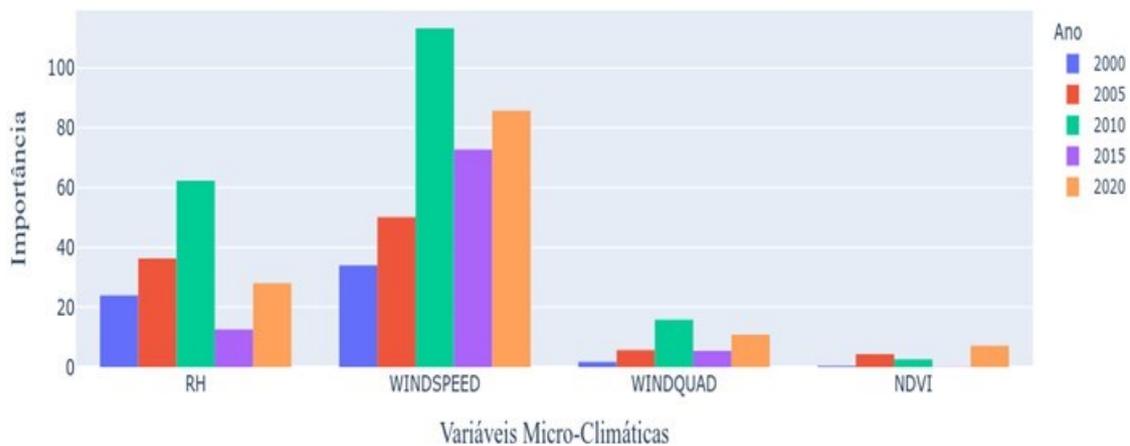


Figura 12: Médias dos decréscimos da acurácia e índice Gini referentes aos anos 2000-2020 para UTFVI em relação da Temperatura do Ar (2 metros).

De forma equiparada, o modelo que utiliza o NDVI na classificação tem um desempenho semelhante ao modelo classificado sem o NDVI como se pode observar nos valores dos seus respectivos Erros Médios Absolutos. A predição para a validação dos dados amostrais para ambos os modelos, nos períodos de 2000 e 2015, se aproximam muito da veracidade do modelo, com o MAE abaixo de 0,03.

A sumarização da avaliação estatística apresentada na Tabela 12 expressa a magnitude absoluta média (Erro Médio Absoluto) entre os valores reais e os valores previstos pelo modelo de classificação do treinamento dos dados amostrais como sendo perfeito, pois o mesmo é zero. Os resultados para R^2 dizem que a proporção da informação dos dados explicada pelo modelo é de 100% para o treinamento dos dados.

Tabela 10: Avaliação estatística sumarizada da classificação dos dados para os anos 2000-2020 em relação à UTFVI a 2 metros de altura.

Treino					
Indicador	2000	2005	2010	2015	2020
MAE	0,17	0,19	0,28	0,28	0,24
MSE	0,18	0,33	0,41	0,48	0,40
RMSE	0,42	0,57	0,64	0,69	0,63
R ²	0,84	0,89	0,78	0,81	0,84
Teste					
Indicador	2000	2005	2010	2015	2020
MAE	0,02	0,23	0,33	0,31	0,32
MSE	0,03	0,42	0,47	0,54	0,54
RMSE	0,18	0,65	0,69	0,73	0,74
R ²	0,78	0,87	0,75	0,81	0,79

Na validação dos dados (Teste), os valores para R² são bem próximos dos obtidos no treinamento. Muito embora, para os anos 2005 e 2020, na aplicação do algoritmo Floresta Aleatória para validação dos dados os Erros Médios Absolutos tendem a não se aproximar da realidade do modelo, ou seja, a eficácia da predição do modelo não se confirma.

De modo geral, o Erro Quadrático Médio (MSE) para os modelos classificados com base no UTFVI em relação à superfície do solo e a 2 metros de altura, sem a influência do NDVI, não é impactante. Quando o modelo é submetido à influência do NDVI, no contexto do UTFVI na superfície do solo, a avaliação da diferença quadrática média entre os valores observados e previstos torna-se importante. E quando se trata da avaliação do modelo segundo o UTFVI a 2 metros de altura, sob a influência do NDVI, no geral é insignificante. Neste caso, o modelo não apresenta erros.

Análise dos resultados da classificação do Fenômeno UHI

UTFVI na superfície do solo e o NDVI

Na classificação dos dados amostrais do ano 2000 e sob o aspecto do NDVI, quando esta variável é incluída como variável dependente na Floresta Aleatória, haverá a ocorrência de 1% de frequência do Fenômeno UHI Forte sob a condição de que a Umidade Relativa do Ar tenha de estar em 45% e o NDVI acima de 0,21. O NDVI influencia diretamente na Direção dos Ventos, para nordeste, quando esta variável estiver com o índice com valor maior ou igual a 0,22, Velocidade dos Ventos maior ou igual a 6,37 km/h e Umidade Relativa do Ar menor que 43%. Já quando o NDVI estiver menor que 0,22, a Velocidade dos Ventos maior ou igual a 6,37 km/h com a Umidade Relativa do Ar menor que 43%, a Direção dos Ventos ocorrerá no sentido sudoeste. A inclusão da variável NDVI causa influência indireta de modo que o Fenômeno

UHI Forte ocorrerá em 32% dos casos quando a Umidade Relativa do Ar estiver entre 52% e 54% e a Velocidade dos Ventos for maior que 1,7 km/h. Diferentemente do que ocorre quando não há a inclusão da variável NDVI, a incidência do Fenômeno UHI Extremo ocorrerá em 2% dos casos quando a Umidade Relativa do Ar estiver em 51% com a Velocidade dos Ventos maior ou igual a 7,8 km/h e a Direção dos Ventos for sul com tendência direcional para o noroeste.

Tabela 11: Avaliação estatística sumarizada da classificação dos dados para os anos 2000-2020 em relação à UTFVI a 2 metros de altura em função do NDVI e demais variáveis microclimáticas.

Treino					
Indicador	2000	2005	2010	2015	2020
MAE	0,03	0,26	0,10	0,00	0,19
MSE	0,39	0,48	0,16	0,00	0,31
RMSE	0,62	0,70	0,41	0,03	0,55
R ²	0,99	0,85	0,93	1,00	0,86
Teste					
Indicador	2000	2005	2010	2015	2020
MAE	0,02	0,36	0,11	0,02	0,20
MSE	0,02	0,67	0,17	0,03	0,32
RMSE	0,13	0,82	0,41	0,17	0,56
R ²	0,98	0,80	0,92	0,98	0,86

Tabela 12: Avaliação estatística sumarizada da classificação dos dados para os anos 2000-2020 em relação à UTFVI na Superfície do Solo em função do NDVI e demais variáveis microclimáticas.

Treino					
Indicador	2000	2005	2010	2015	2020
MAE	0,00	0,00	0,00	0,00	0,00
MSE	0,00	0,00	0,00	0,00	0,00
RMSE	0,00	0,00	0,00	0,00	0,06
R ²	1,00	1,00	1,00	1,00	1,00
Teste					
Indicador	2000	2005	2010	2015	2020
MAE	0,05	0,12	0,00	0,00	0,04
MSE	0,05	0,24	0,00	0,00	0,04
RMSE	0,23	0,49	0,07	0,00	0,21
R ²	0,95	0,94	1,00	1,00	0,96

Quando realizada a classificação dos dados amostrais referentes ao ano 2005, observou-se que 10% dos casos do Fenômeno UHI Muito Forte ocorreram quando o nível do NDVI ficou maior ou igual a 0,24, a Umidade Relativa do Ar ficou entre 41% e 45% e a Velocidade dos Ventos maior ou igual a 7,1 km/h. Em 1% dos casos ocorreu o Fenômeno UHI Forte quando a Umidade Relativa do Ar ficou entre 41% e 45%, com uma Velocidade dos Ventos em 7,1 km/h e o NDVI menor que 0,24. Para os anos 2010 e 2015 não houve ocorrências dos Fenômenos UHI que sofreram influência direta do NDVI. Com relação ao ano 2020 2% dos casos do Fenômeno UHI Forte ocorreram quando a Umidade Relativa do Ar ficou abaixo de 40% e o NDVI abaixo de 0,33, houve uma ocorrência de 3% dos casos para o Fenômeno UHI Muito Forte quando a Umidade Relativa do Ar ficou menor que 40% e o NDVI maior ou igual a 0,33.

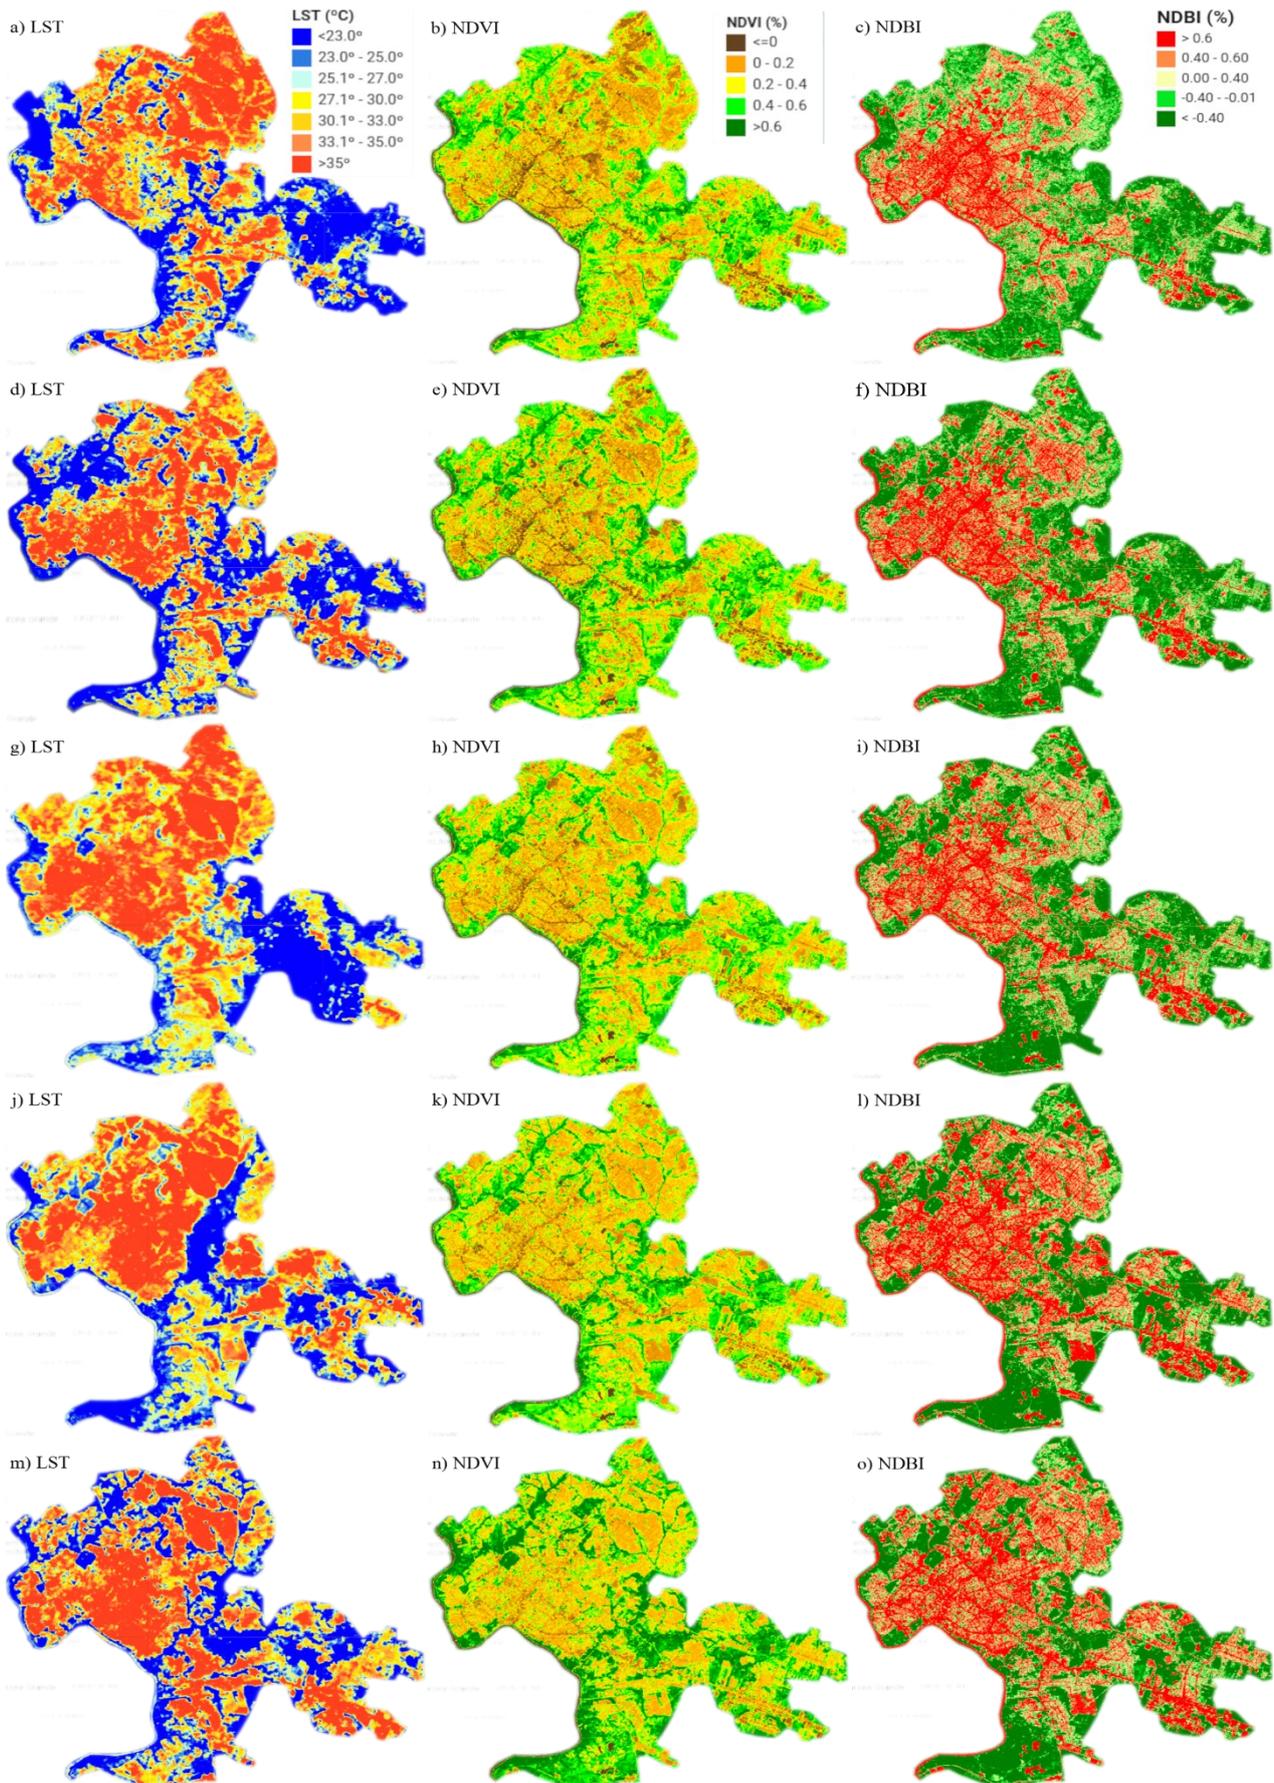


Figura 13: Os valores LST, NDVI e NDBI com variação espaço-temporal em Cuiabá-MT para o período de 2000 (a-c), 2005 (d-f), 2010 (g-i), 2015 (j-i) e 2020 (m-o).

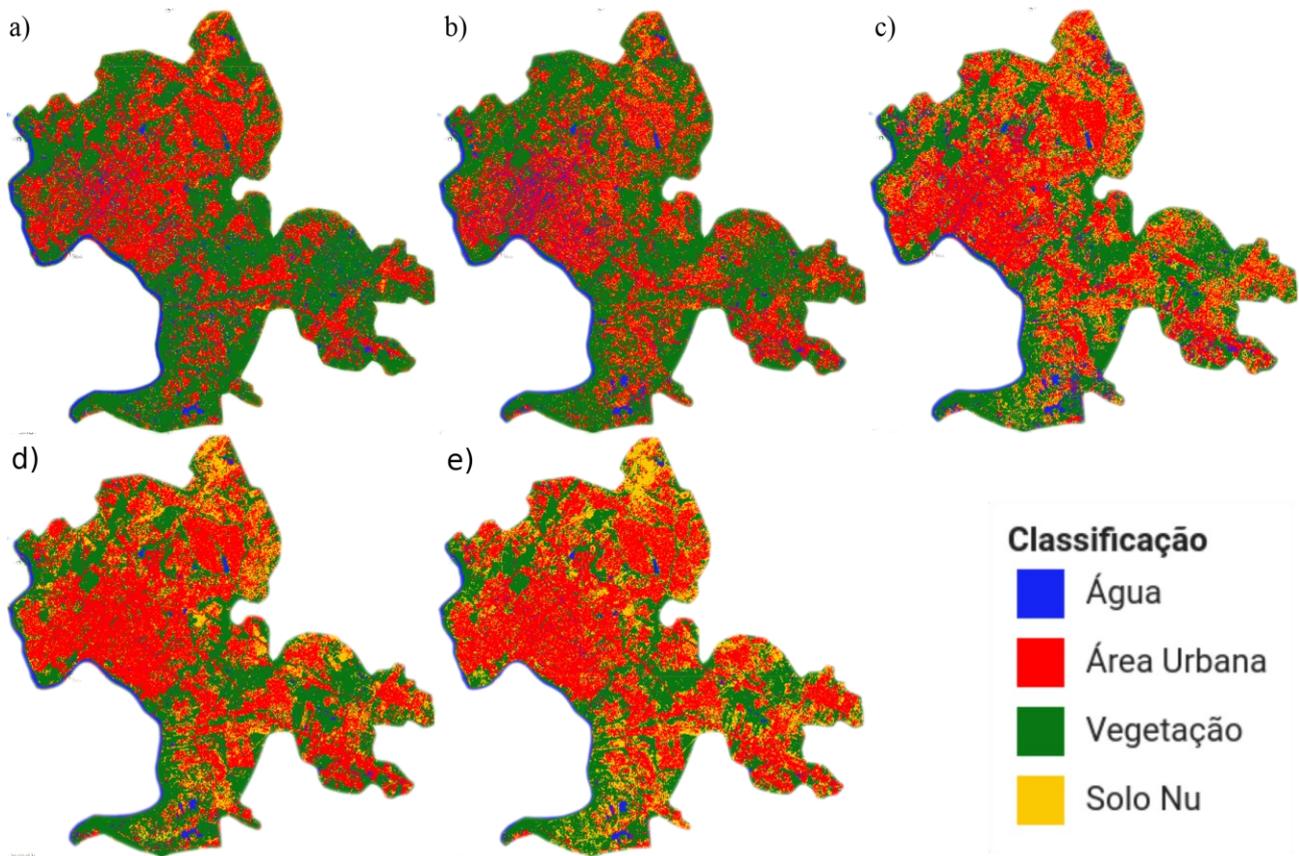


Figura 14: Imagens de Cuiabá classificadas com algoritmo smileRandomForest utilizando imagens Landsat 7 [a) 2000, b) 2005 e c) 2010] e Landsat 8 [d) 2015 e e) 2020]

UTFVI a 2 metros de altura e o NDVI

A investigação dos resultados da análise da classificação do Fenômeno UHI a 2 metros de altura demonstram não ocorrer influência do NDVI em sua formação para o período de 2000, e que existe apenas influência quando se trata de avaliar a Direção dos Ventos que se direciona à nordeste quando a Umidade Relativa do Ar está em 51%, o NDVI maior ou igual 0,37 e Velocidade dos Ventos em 4,5 km/h. Quando o NDVI é menor que 0,37 e mantendo as mesmas características para a Velocidade dos Ventos e Umidade Relativa do Ar a Direção dos Ventos passa ser sudeste. Ressalta-se que 2005, 2010 e 2015 tiveram um comportamento similar ao período de 2000 onde foi constatado influência indireta. No período de 2020, o NDVI passou a ter impacto na formação dos Fenômenos UHI Forte e Muito Forte. Em 10% dos casos o NDVI contribui para a formação do Fenômeno UHI Forte, sendo que em 6% dos casos este fenômeno ocorreu nas condições em que o NDVI foi maior ou igual a 0,25 com a Direção dos Ventos ficando a sudeste e nordeste e ainda a Velocidade dos Ventos em 8,0 km/h. Em 5% dos

Silva, A. S.; Gomes, R. S. R.

NDVI foi maior ou igual a 0,25 com a Direção dos Ventos ficando a sudeste e nordeste e ainda a Velocidade dos Ventos em 8,0 km/h. Em 5% dos casos, o NDVI em conjunto com as variáveis Umidade Relativa do Ar, Direção dos Ventos e Velocidade dos Ventos ocasionou o Fenômeno UHI Muito Forte.

Conclusões

O propósito deste trabalho foi analisar como os padrões de temperaturas da superfície do solo e da Temperatura do Ar das áreas urbanas, através do uso do Índice de Variância do Campo Termal Urbano, podem impactar nos comportamentos dos ventos locais e assim favorecer indiretamente para a formação de ilhas de calor. As ilhas de calor têm por si só um arranjo espacial que é intrinsecamente relacionado com a classificação termal em função do uso e cobertura do solo, assim foi feito, inicialmente, uma análise da ocupação do solo onde se verificou que houve uma crescente variação das temperaturas, tanto da superfície do solo como do ar, muito em função da expansão das áreas construídas.

O comportamento dos ventos locais na cidade de Cuiabá-MT, segundo os dados de

reanálise do ERA5, tem como característica uma combinação das direções nor-nordeste e norte, com ocorrências em torno de 30% e com velocidade máxima média de aproximadamente de 22 km/h para a estação quente e seca. Muito embora acontecesse esta predominância na direção norte, houve também ocorrências de ventos na direção sul. Para a estação quente e úmida houve uma predominância no sentido nor-nordeste com cerca de 60% das ocorrências e com a velocidade dos ventos em torno de 20 km/h.

Importa ressaltar que de acordo com o aumento da temperatura do ar, consoante as Figuras 3 e 4 houve um espalhamento dos ventos locais, o que indica a influência da mesma no comportamento dos ventos locais. Assim, investir na mitigação da formação de ilha de calor pode colaborar para um maior equilíbrio do fluxo dos ventos locais, o que pode levar a melhorias de fatores como saúde, economia etc.

Ainda nesse mesmo sentido, as Figuras 13 e 14 demonstram a relação proporcional da cobertura do solo com a Temperatura da Superfície do Solo. Nestas figuras, é possível se ater na evolução das áreas construídas que se expandiram para a região norte e sudeste com consequente diminuição da área verde. Numa classificação específica da cobertura do solo percebe-se uma nítida característica da formação de uma ilha de calor, aumento de áreas impermeáveis (áreas construídas e solo nu) e a diminuição da área vegetada. É importante ressaltar que apesar da variável microclimática Temperatura da Superfície do Solo ser importante na formação das ilhas de calor urbano (Ahmad; Najar; Ahmad, 2024; Cetin Et Al., 2024), esta por si só nem sempre é um bom indicador de UHI, uma vez que as temperaturas da superfície são afetadas pelas condições meteorológicas (Vergara et al., 2023).

Como consequência da correlação positiva entre os índices de áreas construídas e as temperaturas da superfície do solo e do ar, procurou-se avaliar os fatores que mais contribuem na formação dos fenômenos UHI em Cuiabá, o que resultou na identificação de três níveis ou graus que podem impactar negativamente no desenvolvimento da vegetação, natural ou não, no cotidiano das pessoas quanto aos aspectos econômicos e de saúde, dentre outros impactos negativos. Cuiabá apresenta, conforme a Figura 5, áreas com piores condições térmicas com UTFVI > 0,010, categorizados neste trabalho como Fenômeno UHI Forte, Muito Forte e Extremo.

Na Figura 5, houve uma demonstração da dinâmica do UTFVI onde no ano 2000 a variância do campo termal, com piores condições, se concentrou na região norte e no ano de 2020 houve

uma maior distribuição da variância do campo termal, se expandido para região sul e sudeste, o que se expressa um aumento da área de ilha de calor na região da cidade de Cuiabá-MT.

Como forma de avaliar quais os impactos causados por estas condições, foi então realizado uma classificação dos níveis do UTFVI em função da Velocidade e Direção dos Ventos e Umidade Relativa do Ar. Como resultado direto desta classificação, notou-se que ao nível da superfície do solo a Umidade Relativa do Ar tem mais importância, ou seja, esta variável contribui efetivamente para a formação do UTFVI em relação à superfície do solo.

E quando se trata da classificação do UTFVI a 2 metros de altura a variável Velocidade dos Ventos tem mais importância. Assim, para classificação do UTFVI ao nível da superfície do solo a Floresta Aleatória determinou que se deve utilizar a Umidade Relativa do Ar como fator de definição do Fenômeno UHI resultante. Já para a classificação do UTFVI a 2 metros a Floresta Aleatória resultante determinou que a Velocidade dos Ventos é o fator principal na definição do Fenômeno UHI resultante.

Quando adicionada na classificação, a variável NDVI se mostrou, de fato, ser fator de atenuação da formação de ilha de calor, consoante a baixa importância, retratadas nas Figuras 7, 8 e 9, a partir dos resultados da classificação da Floresta Aleatória quando avaliada na perspectiva da UTFVI em relação à superfície do solo. Ainda de acordo com os resultados desta classificação, o NDVI não repercute no desempenho e nem na homogeneidade da formação dos Fenômenos UHI Forte, Muito Forte e Extremo. Ao avaliar na perspectiva do UTFVI a 2 metros de altura, o mesmo se repetiu, o Índice de Vegetação por Diferença Normalizada se revelou não impactar na formação dos Fenômenos UHI Forte, Muito Forte e Extremo. Presume-se, a partir destes resultados, que o NDVI é um fator de grande importância na mitigação na formação de ilha de calor.

Um aspecto a salientar é que a chance de ocorrências do Fenômeno UHI Extremo aumenta consideravelmente quando se compara a variável Índice de Variância do Campo Termal Urbano a 2 metros de altura com esta mesma variável em relação à superfície do solo, o que nos leva a considerar que as variações entre a temperatura da superfície do solo do ponto geográfico e a temperatura média da superfície solo de toda área em estudo (Cuiabá-MT) é menor quando comparadas com as variações temperatura a 2 metros de altura do ponto geográfico em relação a toda área em estudo.

Finalmente, o uso do algoritmo de aprendizado de máquina supervisionado Floresta Aleatória se mostrou bastante versátil na classificação tanto na cobertura do solo, com análise de imagens, onde demonstrou a sua capacidade de detecção com grande acurácia de pontos (pixels) distintos como água, vegetação e solo nu, Figura 13, quanto na classificação de dados amostrais realizando previsões com acurácia dentro das expectativas, como pode ser visualizado nas árvores de decisões, tal como a Figura 6.

Portanto, a Floresta Aleatória demonstrou bom desempenho na estimativa do impacto que as Temperaturas do Solo e do Ar têm em relação aos ventos locais (direção e velocidade) e consequentemente influência na formação de Ilhas de Calor Urbanas a partir de dados microclimáticos, podendo ser um recurso a ser explorado no planejamento das cidades em relação à mitigação dos impactos relacionados ao UTFVI.

Agradecimentos

Ao programa de Pós-Graduação em Física Ambiente e a Universidade Federal de Mato Grosso por proporcionar a oportunidade ímpar de poder realizar esta pesquisa

Referências

Abir, F. A. Et al. (2021) Thermal and ecological assessment based on land surface temperature and quantifying multivariate controlling factors in Bogura, Bangladesh. *Heliyon*, 7, 9, E08012.

Ahmad, B., Najar, M. B., (2024) Ahmad, S. Analysis of LST, NDVI, and UHI patterns for urban climate using Landsat-9 satellite data in Delhi. *Journal of Atmospheric and Solar-Terrestrial Physics*, 265, 106359.

Allbonwas, R. K.; Al-Khakani, E. T. (2022). Using the multiple regression model to predict the land surface temperature in Al Najaf province, Iraq. *International Journal of Special Education*, 37(3), 9970–9981.

Alvares, C. A. Et al. (2013). Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, 22.

Beck, H. E. Et al. (2018), Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Scientific Data*, 5(1), 180214.

Borodulin, A. Et al. (2024). Using machine learning algorithms to solve data classification
Silva, A. S.; Gomes, R. S. R.

problems using multi-attribute dataset. *BIO Web of Conferences*, 84, 02001.

Callahan, C. W.; Elansari, A. M.; Fenton, D. L. Chapter 8 - Psychometrics. Em: YAHIA, E. M. (Ed.). *Postharvest Technology of Perishable Horticultural Commodities*. [s.l.] Woodhead Publishing. 271–310.

Carlson, T. N.; Ripley, D. A. (1997). On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sensing of Environment*, 62(3), 241–252.

Cetin, M. Et al. (2024). Determination of land surface temperature and urban heat island effects with remote sensing capabilities: the case of Kayseri, Türkiye. *Natural Hazards*, 120(6), 5509–5536.

Çevik Değerli, B.; Çetin, M. (2023). Evaluation of UTFVI index effect on climate change in terms of urbanization. *Environmental Science and Pollution Research*, 30.

Chegury, J. Q. B. De M., Justi, A. C. A., (2022) Nogueira, M. C. De J. A. Avaliação microclimática, termo higrométrica e das ilhas de calor na cidade de Cuiabá-MT/Brasil. *Revista Brasileira de Climatologia*, 30, 69–91.

Cheval, S. Et al. (2024). A systematic review of urban heat island and heat waves research (1991–2022). *Climate Risk Management*, 44, 100603.

Costa, R. L. (2017). Use of remote sensing in the identification of Urban Heat Islands and in the evaluation of Human Thermal Comfort. *Journal of Hyperspectral Remote Sensing*, 7(7), 408–422.

De Paula, D. C. J. Et al. (2021). Estimativa da temperatura do ar microclimática em Cuiabá/MT utilizando redes neurais. *Revista Brasileira de Climatologia*, (28), 184–200.

Düntsche, I.; Gediga, G. (2019). Confusion Matrices and Rough Set Data Analysis. *Journal of Physics: Conference Series*, 1229(1), 012055.

- Enteria, N.; Santamouris, M.; Eicker, U. Urban heat island (uhi) mitigation hot and humid regions: hot and humid regions. [s.l.: s.n.].
- Franco, F. M. Et Al. (2013). Traçado urbano e sua influência no microclima: um estudo de caso em centro histórico. *Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental*, 1916–1931.
- Fung, K. Y.; Yang, Z.-L.; Niyogi, D. (2022). Improving the local climate zone classification with building height, imperviousness, and machine learning for urban models. *Computational Urban Science*, 2(1), 16.
- Guha, S. Et al. (2018) Analytical study of land surface temperature with NDVI and NDBI using Landsat 8 OLI and TIRS data in Florence and Naples city, Italy. *European Journal of Remote Sensing*, 51(1), 667–678.
- Howell, T.; Dusek, D. (1995). Comparison of Vapor-Pressure-Deficit Calculation Methods—Southern High Plains. *Journal of Irrigation and Drainage Engineering*, 121(1).
- Icaza, L. E. Et al. (2017). Impacts, strategies and tools to mitigate UHI. *A+BE | Architecture and the Built Environment*, 20, 67–102.
- Jabbar, H.; Hamoodi, M.; Al-Hameedawi, A. (2023). Urban heat islands: a review of contributing factors, effects and data. *IOP Conference Series: Earth and Environmental Science*, 1129, 012038.
- Johannsen, F.; Soares, P. M. M. (2024). Langendijk, G. S. On the deep learning approach for improving the representation of urban climate: The Paris urban heat island and temperature extremes. *Urban Climate*, 56, 102039.
- Kafy, A.-A. Et al. (2021). Prediction of seasonal urban thermal field variance index using machine learning algorithms in Cumilla, Bangladesh. *Sustainable Cities and Society*, 64, 102542.
- Kikon, N.; Kumar, D.; Ahmed, S. A. (2023). Quantitative assessment of land surface temperature and vegetation indices on a kilometer grid scale. *Environmental Science and Pollution Research*, 30, 49, 107236–107258.
- Kong, F.; Singh, R. P. (2016). Chemical deterioration and physical instability of foods and Beverages. Em: SUBRAMANIAM, P. (Ed.). *The Stability and Shelf Life of Food (Second Edition)*. Woodhead Publishing Series in Food Science, Technology and Nutrition. [s.l.] Woodhead Publishing. 43–76.
- Kumar, D.; Shekhar, S. (2015). Statistical analysis of land surface temperature–vegetation indexes relationship through thermal remote sensing. *Ecotoxicology and Environmental Safety, Green Technologies for Environmental Pollution Control and Prevention (Part 1)*. 121, 39–44.
- Kusumawardani, K. P., Hidayati, I. N. (2022) Analysis of urban heat island and urban ecological quality based on remote sensing imagery transformation in semarang city. *IOP Conference Series: Earth and Environmental Science*, 1089(1), 012037.
- Lawrence, M. G. (2005). The Relationship between Relative Humidity and the Dewpoint Temperature in Moist Air: A Simple Conversion and Applications. *Bulletin of the American Meteorological Society*, 86(2), p. 225–234.
- Lehoczky, A. Et al. (2017), The Urban Heat Island Effect in the City of Valencia: A Case Study for Hot Summer Days. *Urban Science*, 1(1), p. 9.
- Lima, R. F. de et al. (2024). Climate change assessment in Brazi: utilizing the Köppen-Geiger (1936) climate classification. *Revista Brasileira de Meteorologia*, 38, E38230001.
- Luz, L. Et al. (2019). Utilização do NDVI e NDBI para avaliação da expansão urbana no município do Rio das Ostras - RJ, utilizando a plataforma Google Earth Engine. *Anais Do XIX Simpósio Brasileiro De Sensoriamento Remoto*.
- Mchugh, M. L. (2012). Interrater reliability: the kappa statistic. *Biochemia Medica*, 22(3), 276–282.

- Moisa, M. B. Et al. (2022). Analysis of land surface temperature using geospatial technologies in Gida Kiremu, Limu, and Amuru District, Western Ethiopia. *Artificial Intelligence in Agriculture*, 6, 90–99.
- Naim, Md. N. H.; Kafy, A.-A. (2021). Assessment of urban thermal field variance index and defining the relationship between land cover and surface temperature in Chattogram city: A remote sensing and statistical approach. *Environmental Challenges*, 4, 100107.
- Najafzadeh, F. Et al. (2021). Spatial and temporal analysis of surface urban heat island and thermal comfort using landsat satellite images between 1989 and 2019: a case study in Tehran. *Remote Sensing*, 13(21), 4469.
- Nery, C. V. M., Moreira, A. A., Fernandes, F. H. S. (2014). Análise do comportamento espectral da floresta estacional decidual no parque estadual Lapa Grande (behavior analysis of spectral deciduous forest in Lapa Grande state park). *Revista Brasileira de Geografia Física*, 7(2), 417–433.
- Nguyen, T. T. (2020). Landsat time-series images-based urban heat island analysis: the effects of changes in vegetation and built-up land on land surface temperature in summer in the hanoi metropolitan area, Vietnam. *Environment and Natural Resources Journal*, 18(2).
- Nogueira, M. Et al. (2022). Assessment of the Paris urban heat island in ERA5 and offline SURFEX-TEB (v8.1) simulations using the METEOSAT land surface temperature product. *Geoscientific Model Development*, 15(14), 5949–5965.
- Pandey, S.; Muthuraman, S.; Shrivastava, A. Data classification using machine learning approach. [s.l: s.n.]. 122.
- Ranagalage, M.; Estoque, R.; Murayama, Y. (2017). An urban heat island study of the Colombo Metropolitan area, Sri Lanka, based on Landsat data (1997–2017). *International Journal of Geo-Information*, 6, 17.
- Ribeiro, A. J. A.; Araujo, R. De S. (2024), Análise temporal do índice de cobertura vegetal NDVI da floresta nacional do Araripe - Apodi. *Revista Brasileira de Geografia Física*, 17(5), 3223–3239.
- Rouse, J. W. Et Al. (1974). Monitoring vegetation systems in the Great Plains with ERTS. Disponível em: <<https://ntrs.nasa.gov/citations/19740022614>>. Acesso em: 6 jun. 2023
- Sejati, A. W.; Buchori, I.; Rudiarto, I. (2019). The spatio-temporal trends of urban growth and surface urban heat islands over two decades in the Semarang Metropolitan Region. *Sustainable Cities and Society*, 46, 101432.
- Sobrino, J.; Jimenez, J.-C.; Paolini, L. (2004). Land surface temperature retrieval from LANDSAT TM 5. *Remote Sensing of Environment*, 90, 434–440.
- Tesfamariam, S.; Govindu, V.; Uncha, A. (2023). Spatio-temporal analysis of urban heat island (UHI) and its effect on urban ecology: The case of Mekelle city, Northern Ethiopia. *Heliyon*, 9(2), E13098.
- Tomlinson, C. J. Et al. (2011). Including the urban heat island in spatial heat health risk assessment strategies: a case study for Birmingham, UK. *International Journal of Health Geographics*, 10(1), 42.
- Ullah, N. Et al. (2022). Spatiotemporal impact of urbanization on urban heat island and urban thermal field variance index of Tianjin City, China. *Buildings*, 12(4), 399.
- Ullah, N. Et al. (2023). The Impact of Urbanization on Urban Heat Island: Predictive Approach Using Google Earth Engine and CA-Markov Modelling (2005–2050) of Tianjin City, China. *International Journal of Environmental Research and Public Health*, 20(3), 2642.
- Vergara, D. C. D. M. Et al. (2023). Assessing and modelling urban heat island in Baguio City using landsat imagery and machine learning. *The International Archives of the*

Photogrammetry, Remote Sensing and Spatial Information Sciences, 68(4), 457–464.

Waleed, M. Et al. Towards Sustainable and Livable Cities: Leveraging Remote Sensing, Machine Learning, and Geo-Information Modelling to Explore and Predict Thermal Field Variance in Response to Urban Growth. Sustainability, 15(2), 1416.

Weng, Q., Lu, D., Schubring, J. (2004). Estimation of land surface temperature–vegetation

abundance relationship for urban heat island studies. Remote Sensing of Environment, 89(4), 467–483.

Zhang, Z., Fan, Y., Jiao, Z. (2023) Wetland ecological index and assessment of spatial-temporal changes of wetland ecological integrity. Science of The Total Environment, 862, 160741.