

**UNIVERSIDADE FEDERAL DE MATO GROSSO
INSTITUTO DE FÍSICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL**

**EFEITOS DO USO DO SOLO SOBRE O BALANÇO DE
RADIÇÃO E ENERGIA EM CUIABÁ - MT**

PABLINNE CYNTHIA BATISTA ANGELINI

PROF.^a DR.^a NADJA GOMES MACHADO
Orientadora

PROF. DR. MARCELO SACARDI BIUDES
Coorientador

Cuiabá, MT
Dezembro de 2020

**UNIVERSIDADE FEDERAL DE MATO GROSSO
INSTITUTO DE FÍSICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL**

**EFEITOS DO USO DO SOLO SOBRE O BALANÇO DE
RADIAÇÃO E ENERGIA EM CUIABÁ - MT**

PABLINNE CYNTHIA BATISTA ANGELINI

*Tese apresentada ao Programa de
Pós-Graduação em Física Ambiental
da Universidade Federal de Mato
Grosso, como parte dos requisitos
para obtenção do título de Doutora
em Física Ambiental.*

PROF.^a DR.^a NADJA GOMES MACHADO
Orientadora

PROF. DR. MARCELO SACARDI BIUDES
Coorientador

**Cuiabá, MT
Dezembro de 2020**

Dados Internacionais de Catalogação na Fonte.

B333e Batista Angelini, Pablinne Cynthia.
EFEITOS DO USO DO SOLO SOBRE O BALANÇO DE RADIAÇÃO E
ENERGIA EM CUIABÁ - MT / Pablinne Cynthia Batista Angelini. -- 2020
113 f. : il. color. ; 30 cm.

Orientadora: Nadja Gomes Machado.
Co-orientador: Marcelo Sacardi Biudes.
Tese (doutorado) - Universidade Federal de Mato Grosso, Instituto de Física,
Programa de Pós-Graduação em Física Ambiental, Cuiabá, 2020.
Inclui bibliografia.

1. Urbanização. 2. Alterações antrópicas. 3. Classificação da cobertura do solo. 4.
Algoritmo SEBAL. I. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

Permitida a reprodução parcial ou total, desde que citada a fonte.



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE MATO GROSSO
PRÓ-REITORIA DE ENSINO DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL

FOLHA DE APROVAÇÃO

TÍTULO: EFEITOS DO USO DO SOLO SOBRE O BALANÇO DE RADIAÇÃO E ENERGIA EM CUIABÁ - MT

AUTORA: DOUTORANDA PABLINNE CYNTHIA BATISTA ANGELINI

Tese defendida e aprovada em 18 de dezembro de 2020.

COMPOSIÇÃO DA BANCA EXAMINADORA

1. Profa. Dra. Nadja Gomes Machado - Orientadora - Instituto Federal de Mato Grosso – IFMT
2. Prof. Dr. Marcelo Sacardi Biudes - Coorientador - Instituto de Física - UFMT
3. Prof. Dr. Leone Francisco Amorim Curado - Examinador Interno - Instituto de Física - UFMT
4. Prof. Dr. Victor Hugo de Moraes Danelichen - Examinador Externo - Universidade de Cuiabá - UNIC
5. Prof. Dr. Carlos Alexandre Santos Querino - Examinador Externo - Instituto de Educação, Agricultura e Ambiente (IEAA) – UFAM

Cuiabá-MT, 18/12/2020



Documento assinado eletronicamente por **SERGIO ROBERTO DE PAULO, Coordenador(a) de Programas de Pós-Graduação em Física Ambiental - IF/UFMT**, em 18/12/2020, às 15:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **LEONE FRANCISCO AMORIM CURADO, Docente da Universidade Federal de Mato Grosso**, em 18/12/2020, às 15:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **NADJA GOMES MACHADO, Usuário Externo**, em 18/12/2020, às 17:26, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **MARCELO SACARDI BIUDES, Docente da Universidade Federal de Mato Grosso**, em 18/12/2020, às 17:40, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Victor Hugo de Moraes Danelichen, Usuário Externo**, em 20/12/2020, às 23:30, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Carlos Alexandre Santos Querino, Usuário Externo**, em 21/12/2020, às 14:10, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufmt.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3106522** e o código CRC **85DFF58D**.

DEDICATÓRIA

A minha amada filha Isabela, razão de todo meu esforço e dedicação.

A minha amada mãe Genessi, pelo amor, carinho e paciência.

Ao meu amado marido Lucas, grande incentivador e fiel companheiro.

AGRADECIMENTOS

A Deus, pela dádiva da vida, pela bênção de cada dia e por me permitir realizar tantos sonhos.

A minha amada mãe, Genessi, minha melhor professora e incentivadora, que sempre esteve ao meu lado e acreditou em mim.

Ao meu marido Lucas, pela paciência, compreensão nos momentos de ausência, pelo carinho e amor. Agradeço por trilhar esse caminho comigo, que por muitas vezes foi exaustivo.

A Prof.^a Dr.^a Nadja Gomes Machado, pela orientação, apoio e confiança. A quem dedico toda minha admiração e respeito.

Ao Prof. Dr. Marcelo Sacardi Biudes pelas orientações que auxiliaram na realização desta Tese.

Ao Prof. Dr. José de Souza Nogueira, pelo apoio e grande empenho a frente do Programa de Pós-graduação em Física Ambiental.

A Prof.^a Dr.^a Marta Cristina de Jesus Albuquerque Nogueira, pelos conselhos, apoio e atenção.

A todos os professores do Programa de Pós-Graduação em Física Ambiental da Universidade Federal de Mato Grosso, que compartilharam seus conhecimentos.

Aos amigos do grupo de pesquisa, pelos momentos de alegria, em especial a Dalila Mützenber, Danielle Nassarden, Élio Júnior, Juliana Lotufo, Marcos Fausto e Vagner Pavão.

Aos amigos da Física Ambiental, em especial a Natallia Souza, Keylyane Alves, Diana de Paula, Larissa Pavão, Lucas Rothmund, Tonny Jader, pelos inúmeros momentos de alegrias vividos.

Aos meus familiares e amigos de convívio pessoal pelo carinho, apoio e incentivo.

A Soilce e Cesário pela colaboração nos serviços da secretaria que auxiliam o desenvolvimento dessa Tese;

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio e fornecimento da bolsa de doutorado.

SUMÁRIO

LISTA DE FIGURAS	viii
LISTA DE TABELAS	x
LISTA DE ABREVIACÕES E SÍMBOLOS.....	xii
RESUMO	xv
ABSTRACT	xvi
1 INTRODUÇÃO	1
1.1 PROBLEMÁTICA	1
1.2 JUSTIFICATIVA	2
1.3 HIPÓTESE	4
1.4 OBJETIVOS.....	4
1.4.1 Objetivo Geral.....	4
1.4.2 Objetivos Específicos	4
2 REVISÃO BIBLIOGRÁFICA	5
2.1 EXPANSÃO URBANA DE CUIABÁ – MT E SEUS EFEITOS MICROMETEOROLÓGICOS.....	5
2.2 IMAGENS ORBITAIS.....	7
2.3 ÍNDICES ESPECTRAIS DA SUPERFÍCIE.....	10
2.4 BALANÇO DE RADIAÇÃO E ENERGIA POR SENSORIAMENTO REMOTO	12
3 MATERIAL E MÉTODOS	15
3.1 ÁREA DE ESTUDO	15
3.2 AQUISIÇÃO E PROCESSAMENTO DAS IMAGENS	17
3.2.1 Dados Meteorológicos	18
3.3 ESTIMATIVA DOS ÍNDICES ESPECTRAIS.....	18
3.3.1 Índices de Vegetação.....	19
3.3.2 Índice de Área Construída.....	19
3.3.3 Índice de Umidade	19
3.3.4 Índice de Solo Exposto	20
3.4 CLASSIFICAÇÃO DA COBERTURA DO SOLO	20
3.4.1 Regras e Condições para gerar a classificação de cobertura do solo	21
3.5 AVALIAÇÃO DA CONFIABILIDADE DA CLASSIFICAÇÃO.....	22
3.6 MUDANÇA DE COBERTURA DO SOLO	24
3.7 CORREÇÃO DA TEMPERATURA DA SUPERFÍCIE	25

3.8 ESTIMATIVA DO BALANÇO DE RADIAÇÃO E ENERGIA PELO ALGORITMO SEBAL.....	27
3.8.1 Estimativa do Balanço de Radiação da superfície.....	27
3.8.2 Estimativa do Balanço de Energia pelo algoritmo SEBAL	29
3.9 ANÁLISE DOS DADOS.....	32
3.9.1 Extração dos dados espaciais	32
3.9.2 Análises do perfil.....	32
3.9.3 Análises estatísticas	33
4. RESULTADOS.....	34
4.1 VARIAÇÃO DA PRECIPITAÇÃO E DA TEMPERATURA	34
4.2 CLASSIFICAÇÃO DA COBERTURA DO SOLO	35
4.3 CONVERSÃO DA COBERTURA DO SOLO.....	39
4.4 DINÂMICA DOS PARÂMETROS DA SUPERFÍCIE.....	41
4.5 AVALIAÇÃO DA DINÂMICA DOS COMPONENTES DO BALANÇO DE ENERGIA	45
4.6 ANÁLISE ESPACIAL DOS PERFIS	51
4.6.1 Perfil nordeste-sudoeste (NE-SO)	51
4.6.2 Perfil noroeste-sudeste (NO-SE).....	57
4.7 CORRELOGRAMA E COEFICIENTE DE CORRELAÇÃO DAS VARIÁVEIS DOS PERFIS ESPACIAIS	63
5. DISCUSSÕES.....	65
5.1 VARIAÇÃO DA PRECIPITAÇÃO E DA TEMPERATURA	65
5.2 CLASSIFICAÇÃO DA COBERTURA DO SOLO	65
5.3 DINÂMICA DOS PARÂMETROS DA SUPERFÍCIE EM ÁREA URBANA.....	69
5.4 AVALIAÇÃO DA DINÂMICA DOS COMPONENTES DO BALANÇO DE ENERGIA EM ÁREA URBANA	71
5.5 ANÁLISE ESPACIAL DOS PERFIS	73
6. CONCLUSÃO	75
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	77

LISTA DE FIGURAS

Figura 1 - Evolução do perímetro urbano de Cuiabá-MT de acordo com as leis e atos municipais.	6
Figura 2 - Localização de Cuiabá, MT, Brasil e a distribuição das diferentes regiões no perímetro urbano de Cuiabá.	15
Figura 3 - Fluxograma ilustrando as etapas de processamento de classificação da cobertura do solo. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água).	21
Figura 4 - Matriz geral de tabulação cruzada para a comparação de dois mapas em momentos distintos, em que AVD é a classe de vegetação densa, AVA é a classe de vegetação arbustiva, AVR é a classe de vegetação rasteira e solo exposto, ACO é a classe de áreas construídas e ACA é a classe de corpos d'água.	25
Figura 5 - Normal climatológica (1981-2010) e médias mensais de precipitação de 1985 e 2017 (A); Normal climatológica (1981-2010) e médias de temperatura do ar 1985 e 2017 (B) para o município de Cuiabá - MT.....	34
Figura 6 - Distribuição espacial das classes de cobertura do solo para Cuiabá - MT em 1985 e 2017.	38
Figura 7 - Distribuição espacial somente das classes de áreas vegetadas (áreas de vegetação densa - AVD e áreas de vegetação arbustiva - AVA, em A) e construída (ACO, em B) para Cuiabá - MT em 1985 e 2017.	40
Figura 8 - Distribuição espacial do NDVI (índice de vegetação por diferença normalizada) em 1985 (A) e 2017 (B). Albedo da superfície em 1985 (C) e 2017 (D). T_s (temperatura de superfície) em 1985 (E) e 2017 (F) para o perímetro urbano de Cuiabá - MT.....	43
Figura 9 - Histograma do NDVI para Cuiabá - MT em 1985 e 2017. NDVI (Índice de vegetação por diferença normalizada).....	43
Figura 10 - Histograma do α_{sup} (albedo da superfície) para Cuiabá - MT em 1985 e 2017.....	44
Figura 11 - Histograma da T_s (temperatura da superfície) para Cuiabá - MT em 1985 e 2017.....	44
Figura 12 - Distribuição espacial do Rn_{inst} (saldo de radiação instantâneo) em W/m^2 de 1985 (A) e 2017 (B), G (fluxo de calor no solo; W/m^2) em 1985 (C) e 2017 (D), H (fluxo de calor sensível; W/m^2) de 1985 (E) e 2017 (F), LE (fluxo de calor latente; W/m^2) de 1985 (G) e 2017 (H) e ET_{24} (evapotranspiração diária; mm/dia) de 1985 (I) e 2017 (J) para o perímetro urbano de Cuiabá - MT.....	47
Figura 13 - Histograma do Rn_{inst} (saldo de radiação instantâneo; W/m^2) para Cuiabá - MT em 1985 e 2017.....	48
Figura 14 - Histograma do G (fluxo de calor no solo; W/m^2) para Cuiabá - MT em 1985 e 2017.....	48

Figura 15 - Histograma do H (fluxo de calor sensível; W/m ²) para Cuiabá – MT em 1985 e 2017.....	49
Figura 16 - Histograma do LE (fluxo de calor latente; W/m ²) para Cuiabá – MT em 1985 e 2017.....	50
Figura 17 - Histograma do ET ₂₄ (evapotranspiração diária; mm/dia) para Cuiabá – MT em 1985 e 2017.....	51
Figura 18 - Perfil NE-SO para as variáveis NDVI, α_{sup} e T _s para Cuiabá -MT com os dados de 1985 e 2017. Md.Mov. (média móvel), NDVI (Índice de vegetação por diferença normalizada), α_{sup} (albedo da superfície) e T _s (temperatura de superfície; °C) em °C.....	52
Figura 19 - Perfil NE-SO para as variáveis Rn _{inst} , H, Le e ET ₂₄ para Cuiabá -MT com os dados de 1985 e 2017. Md.Mov. (média móvel), Rn _{inst} (saldo de radiação instantâneo; W/m ²), G (fluxo de calor no solo; W/m ²), H (fluxo de calor sensível; W/m ²), Le (fluxo de calor latente; W/m ²) e ET ₂₄ (evapotranspiração diária; mm/dia).....	54
Figura 20 - Perfil NO-SE para as variáveis NDVI, α_{sup} e T _s para Cuiabá -MT com os dados de 1985 e 2017. Md.Mov. (média móvel), NDVI (Índice de vegetação por diferença normalizada), α_{sup} (albedo da superfície) e T _s (temperatura de superfície; °C).....	58
Figura 21 - Perfil NO-SO para as variáveis Rn _{inst} , H, Le e ET ₂₄ para Cuiabá -MT com os dados de 1985 e 2017. Md.Mov. (média móvel), Rn _{inst} (saldo de radiação instantâneo; W/m ²), G (fluxo de calor no solo; W/m ²), H (fluxo de calor sensível; W/m ²), Le (fluxo de calor latente; W/m ²) e ET ₂₄ (evapotranspiração diária; mm/dia).....	59
Figura 22 - Correlograma composto dos gráfico de dispersão, histogramas e coeficiente de correlação de Spearman para as variáveis: NDVI, α_{sup} , T _s , Rn _{inst} , G, H, LE e ET ₂₄ para Cuiabá -MT com os dados de 1985 e 2017. NDVI (Índice de vegetação por diferença normalizada); T _s (temperatura de superfície; °C); Rn _{inst} (saldo de radiação instantâneo; W/m ²), G (fluxo de calor no solo; W/m ²), H (fluxo de calor sensível; W/m ²), LE (fluxo de calor latente; W/m ²) e ET ₂₄ (evapotranspiração diária; mm/dia).....	64

LISTA DE TABELAS

Tabela 1 - Evolução dos limites dos perímetros urbanos de Cuiabá- MT.	5
Tabela 2 - Composição das bandas do satélite Landsat 5 TM e suas aplicações.	8
Tabela 3 - Composição das bandas do satélite Landsat 8 OLI/TIRS e suas aplicações.	9
Tabela 4 - Relação entre as regiões administrativas e bairros, localidades e distribuição populacional.	16
Tabela 5 - Dados meteorológicos utilizados para correção da temperatura de brilho e para estimativa do balanço de energia foram obtidos da Estação Meteorológica de Cuiabá do Instituto Nacional de Meteorologia (INMET).	18
Tabela 6 - Esquema geral da matriz de confusão.	22
Tabela 7 - Medidas de precisão da classificação de cobertura do solo derivada da matriz de confusão para a área urbana de Cuiabá-MT. Medidas de precisão para avaliar o desempenho preditivo da classificação. Onde a são os verdadeiros positivos, b os falsos positivos, c os falso-negativos, d os verdadeiros negativos, n são os pontos randômicos de uma classe e N é o número total de pontos randômicos.	23
Tabela 8 - Padrão de precisão e acurácia da classificação a partir da estimativa Kappa	24
Tabela 9 - Regras e condições definidas para gerar a classificação de cobertura do solo para Cuiabá – MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d’água); NDVI (índice de vegetação por diferença normalizada); NDBI (índice de construções por diferença normalizada); NDBAI (Índice de aridez por diferença normalizada); NDWI (índice de água por diferença normalizada); MNDWI (índice de água por diferença normalizada modificado)..	35
Tabela 10 - Estimativas de precisão da classificação da cobertura do solo para Cuiabá – MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d’água)..	36
Tabela 11 - Dimensionamento das áreas de cobertura do solo em hectares (ha) para Cuiabá – MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d’água); LCC (mudança de cobertura da superfície).	37
Tabela 12 - Dimensionamento das áreas de cobertura do solo em hectares (ha) por região para Cuiabá – MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d’água)	38
Tabela 13 - Conversão da cobertura do solo em hectares (ha) para Cuiabá – MT de 1985 a 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva);	

AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água)39

Tabela 14 - Permanência e alterações da cobertura do solo (perdas e ganhos) em hectares (ha) para Cuiabá – MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água)40

Tabela 15 - Perdas, ganhos, variação líquida, valor absoluto de troca e total de mudanças por cobertura do solo em hectares (ha) para Cuiabá – MT de 1985 a 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água)41

Tabela 16 - Médias (\pm 95% IC) dos parâmetros de NDVI, α_{sup} e T_s da cobertura do solo de Cuiabá - MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água). NDVI (índice de vegetação por diferença normalizada), α_{sup} (albedo da superfície) e T_s (temperatura da superfície; °C).....42

Tabela 17 - Médias (\pm 95% IC) do Rn_{inst} , G, H, LE e ET_{24} para a cobertura do solo de Cuiabá - MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água). Rn_{inst} (saldo de radiação instantâneo; W/m²), G (fluxo de calor no solo; W/m²), H (fluxo de calor sensível; W/m²), LE (fluxo de calor latente; W/m²) e ET_{24} (evapotranspiração diária; mm/dia).....46

LISTA DE ABREVIACOES E SMBOLOS

UFMT	Universidade Federal de Mato Grosso
Landsat	<i>Earth-observing satellite mission</i>
SR	Sensoriamento remoto
NASA	National aeronautics and space administration
TM	Thematic mapper
OLI	Operational land imager
TIRS	Thermal infrared sensor
INPE	Instituto nacional de pesquisas espaciais
SIG	Sistema de informao geogrfica
NDVI	Normalized difference vegetation index
SAVI	Soil adjusted vegetation index
MSAVI	Modified soil adjusted vegetation index
EVI	Enhanced vegetation Index
NDBI	Normalized difference built-up index
NDBaI	Normalized difference bareness index
NDWI	Normalized difference water index
MNDWI	Modified normalised difference water index
SMI	Soil moisture index
BOC	Balano de ondas curtas
BOL	Balano de ondas longas
R _g	Radiao global terrestre
METRIC	Mapping evapotranspiration with internalized calibration
SEBS	Surface energy balance system
S-SEBI	Simplified surface energy balance index
<i>H</i>	Fluxo de calor sensvel
<i>dt</i>	Gradiente de temperatura
ESPA	EROS science processing architecture
LEDAPS	Landsat ecosystem disturbance adaptive processing system
MODIS	Moderate resolution imaging spectroradiometer
NCEP	National centers for environmental prediction

NOAA	National oceanic and atmospheric administration
LaSRC	Land surface reflectance code
INMET	Instituto nacional de meteorologia
ρ_{NIR}	Banda do infravermelho próximo
ρ_{Red}	Banda do vermelho
ρ_{MIR}	Banda do infravermelho médio
ρ_{blue}	Banda azul
DN_{MIR}	Banda do infravermelho médio em número digital
$DN_{thermal}$	Banda termal em número digital
AVD	Áreas de vegetação densa
AVA	Áreas de vegetação arbustiva
AVR	Áreas de vegetação rasteira e/ou solo exposto
ACO	Áreas construídas
ACA	Áreas de corpos d'água
SC	Sigle-Channel
T_{SC}	Temperatura da Superfície utilizando o modelo sigle-channel
γ	Gama - Parâmetros da função de Planck
δ	Delta - Parâmetros da função de Planck
ψ	Psi - Parâmetros atmosféricos
ε_{sup}	Emissividade da superfície
L_{sen}	Radiância termal ao nível do sensor
T_{sen}	Temperatura de brilho em Kelvin
c_1	Constante de radiação de Planck
c_2	Constante de radiação de Planck
λ	Comprimento de onda da banda termal
w	Conteúdo de vapor d'água da atmosfera
t_0	Temperatura do ar próxima a superfície
UR	Umidade relativa
b_γ	Constante resultante da relação $\frac{c_2}{\lambda}$
FVC	Fração de cobertura vegetal
Rn	Saldo de radiação da superfície

$R_{s\downarrow}$	Radiação de onda curta incidente
α_{sup}	Albedo da superfície
$R_{L\downarrow}$	Radiação de onda longa emitida pela atmosfera
ε_{atm}	Emissividade da atmosfera
σ	Constante de Stefan-Boltzman
T_s	Temperatura da superfície
LE	Fluxo de calor latente
G	Fluxo de calor no solo
ρ_a	Massa específica do ar
c_p	Calor específico do ar
r_{ah}	Resistência aerodinâmica ao transporte de calor sensível
a	Coefficiente de referência
b	Coefficiente de referência
u_*	Velocidade de fricção
k	Constante de von Karman
z_{om}	Coefficiente de rugosidade ao transporte de momentum
u_{200}	Velocidade do vento na altura de 200 metros
z_{ome}	Coefficiente de rugosidade ao transporte de momentum próximo da estação
ET	Evapotranspiração diária
Rn_{24h}	Saldo de radiação diário
λ_v	Calor latente de vaporização
FE_i	Fração evaporativa
FE_{24h}	Fração evaporativa diária
$^{\circ}C$	Graus celsius
z	Altura
μm	Comprimento de onda
ρ	Refletância da superfície
PPT	Precipitação
NE-SO	Nordeste-Sudoeste
NO-SE	Noroeste-Sudeste

RESUMO

ANGELINI, P. C. B. **Efeitos do uso do solo sobre o balanço de radiação e energia em Cuiabá – MT**. 113 f. Tese (Doutorado em Física Ambiental) – Instituto de Física. Universidade Federal de Mato Grosso.

A intensificação do processo de urbanização mundial e a substituição de ambientes naturais por áreas construídas, trouxeram profundas mudanças sociambientais ao espaço urbano. Nos últimos anos, diante da complexidade da arquitetura urbana e do alto custo das estações meteorológicas, técnicas de sensoriamento remoto vêm sendo utilizadas como ferramentas alternativas e efetivas para o monitoramento espaço-temporal de áreas urbanas. O objetivo geral deste estudo foi avaliar os efeitos da urbanização de 1985 a 2017, no balanço de energia da superfície por sensoriamento remoto em Cuiabá - MT. A área de estudo foi o perímetro urbano do Município de Cuiabá – MT. O estudo foi realizado a partir de imagens dos sensores TM e OLI/TIRS a bordo dos satélites Landsat 5 e 8, obtidas da plataforma ESPA do USGS. A classificação da cobertura do solo de 1985 e 2017, foi realizada a partir de um algoritmo de decisão, baseado em índices espectrais. Os efeitos da urbanização foram avaliados a partir das estimativas do NDVI, albedo, temperatura da superfície e balanço de energia pelo método SEBAL. A classificação da cobertura do solo apresentou crescimento urbano de 1985 a 2017, resultado da substituição da vegetação arbustiva por áreas construídas. Houve diminuição do NDVI de 0,26 para 0,19 e aumento nos valores de albedo da superfície de 0,26 para 0,29 em áreas construídas. A temperatura da superfície apresentou aumento de até 4°C em áreas antropizadas entre 1985 e 2017. Houve diminuição no saldo de radiação, fluxo de calor latente e evapotranspiração em áreas antropizadas de 60 W m^{-2} , 72 W m^{-2} e $0,8 \text{ mm d}^{-1}$, respectivamente. Os fluxos de calor sensível e do solo aumentaram 21 W m^{-2} e 3 W m^{-2} em áreas antropizadas, respectivamente. Conclui-se que a expansão de áreas urbanizadas no município de Cuiabá – MT modificou o particionamento do balanço de energia. O estudo demonstrou-se adequado para áreas urbanas e pode fornecer informação que possibilitem a melhoria do planejamento urbano e da qualidade de vida da população.

Palavras-chave: Urbanização; Alterações antrópicas; Classificação da cobertura do solo; Algoritmo SEBAL.

ABSTRACT

ANGELINI, P. C. B. **Effect of urbanization on the surface energy balance by remote sensing in Cuiabá – MT.** 113 f. Thesis (Doctorate in Environmental Physics) - Institute of Physic. Federal University of Mato Grosso.

The intensification of the world urbanization process and the replacement of natural environments by built areas, brought profound socio-environmental changes to the urban space. In the last years, in the face of the complexity of urban architecture and the high cost of meteorological stations, remote sensing techniques have been used as alternative and effective tools for the space-time monitoring of urban areas. The general objective of this study was to evaluate the effects of urbanization from 1985 to 2017, on the surface energy balance by remote sensing in Cuiabá - MT. The study area was the urban perimeter of the Municipality of Cuiabá - MT. The study was made using images from the TM and OLI / TIRS sensors on the Landsat 5 and 8 satellites, obtained from the USGS ESPA platform. The classification of land cover in 1985 and 2017 was made using a decision algorithm, based on spectral indices. The effects of urbanization were assessed using the NDVI, albedo, surface temperature and energy balance estimates using the SEBAL method. The classification of land cover showed urban growth from 1985 to 2017, as a result of the replacement of shrub vegetation by built areas. There was a decrease in NDVI from 0.26 to 0.19 and an increase in surface albedo values from 0.26 to 0.29 in built-up areas. The surface temperature increased by up to 4 ° C in anthropized areas between 1985 and 2017. There was a decrease in the radiation balance, latent heat flow and evapotranspiration in anthropized areas of 60 W m⁻², 72 W m⁻² and 0.8 mm d⁻¹, respectively. Sensitive heat and soil flows increased by 21 W m⁻² and 3 W m⁻² in anthropized areas, respectively. Sensitive heat flux and soil heat flux increased by 21 W m⁻² and 3 W m⁻² in anthropized areas, respectively. It is concluded that the expansion of urbanized areas in the municipality of Cuiabá - MT changed the partitioning of the energy balance. The study showed to be appropriate for urban areas and can provide information that will enable the improvement of urban planning and the quality of life of the population.

Keywords: Urbanization; Anthropic changes; Land cover classification; SEBAL algorithm.

1 INTRODUÇÃO

1.1 PROBLEMÁTICA

Atualmente, estima-se que 55% da população mundial vive em áreas urbanas, uma proporção que deve aumentar para 68% até 2050. A expansão da urbanização mundial nos últimos anos, resultou da intensificação dos processos migratórios campo-cidade combinado ao crescimento da população mundial (UNITED NATIONS, 2018; MEKURIAW e GOKCEKUS, 2019). No Brasil, a urbanização ocorreu de forma tardia, motivada principalmente pela industrialização e trouxe como consequências profundas mudanças econômicas e sociais no espaço urbano (CARVALHO, 2019).

O estado de Mato Grosso, a partir da década de 70, passou por uma rápida expansão demográfica, resultado das políticas públicas que incentivaram o avanço das fronteiras agrícolas para a ocupação da Amazônia meridional. Sendo assim, o município de Cuiabá – MT torna-se um pólo de apoio ao intenso fluxo migratório para região, resultando em uma acelerada expansão urbana ao longo dos últimos anos (CUIABÁ, 2008). A expansão urbana traz benefícios econômicos e desenvolvimento urbano para as cidades, no entanto, altera drasticamente a atmosfera urbana, refletindo diretamente em uma série de impactos socioambientais (XIA et al., 2020).

A urbanização desencadeia a baixa dispersão de poluentes atmosféricos, a redução da biodiversidade, alterações no ciclo hidrológico e alterações no fluxo de energia (CALLEJAS et al., 2019). As áreas urbanas são caracterizadas pela redução da vegetação nativa e expansão de áreas edificadas que modifica as propriedades térmicas, radiativas, de rugosidade e umidade da superfície (OKE et al., 2017). Além disso, a substituição de ambientes naturais por áreas construídas altera o particionamento das variáveis do balanço de energia (DARAMOLA e BALOGUN, 2019).

Os materiais artificiais comumente encontrados em áreas urbanas, tais como: concreto, asfalto, pedra, tijolo, madeira, metal e vidro, entre outros, possuem maior capacidade de armazenamento de energia e aquecimento do ambiente urbano. Os “Cânions Urbanos” são responsáveis por múltiplas reflexões de radiação de onda longa, contribuindo para o maior aprisionamento de energia dentro do dossel urbano, dificultando sua dissipação para camadas atmosféricas superiores (CALLEJAS et al., 2016). As fontes antropogênicas de energia existente nas áreas urbanas contribuem

para os ganhos de energia dentro do dossel urbano e proporciona o aumento da temperatura superficial, criando variações do clima local e das trocas de energia (WANG et al., 2015).

A quantificação dos componentes do balanço de energia em áreas urbanas é um dos fatores-chave para o planejamento urbano e a modelagem da dinâmica urbana (CHEN e HU, 2017; MACHADO et al., 2020). O balanço de energia em áreas urbanas pode ser representado pelas densidades de fluxos de calor latente, sensível e do solo, sendo o calor latente responsável pela mudança do estado físico da água que será cedido para a atmosfera. O fluxo de calor sensível e do solo representa a quantidade de energia utilizada para o aquecimento do ar e do solo, respectivamente, que poderá ser intensificado pela expansão de áreas antropizadas (BIUDES et al., 2015; CHRYSOULAKIS et al., 2018; MACHADO et al., 2020).

Sendo assim, as alterações das propriedades naturais do solo causam impactos negativos as variáveis biofísicas e qualidade de vida urbana. A dinâmica dos arranjos urbanos, as propriedades de absorção e reflexão são complexos e modificam-se constantemente no espaço, dificultando o seu monitoramento. Portanto, conhecer as especificidades das áreas urbanas torna-se fundamental para os gestores da cidade, para que ações mitigadoras possam ser incentivadas para melhoria da qualidade de vida e ordenamento urbano.

1.2 JUSTIFICATIVA

As atividades antropogênicas vêm alterando drasticamente os ecossistemas urbanos. A urbanização que por um lado beneficia o bem-estar econômico da sociedade, por outro, provoca impactos socioambientais. As transformações da cobertura solo urbano são complexas e irreversíveis e são, portanto, um dos fenômenos mais estudados dos últimos anos.

As diferentes fontes de calor antropogênico, a impermeabilização da superfície, a formação dos cânions urbanos e a poluição do ar, contribuem para as alterações nas propriedades atmosféricas da cidade. As estruturas urbanas aumentam a emissão da radiação de onda longa, o fluxo de calor sensível, reduz o fluxo de calor latente e intensifica o armazenamento do calor superficial (OKE et al., 2017). A existência de diferentes coberturas do solo, exposições à radiação solar e características

aerodinâmica dentro da cidade, leva a uma complexa variação do fluxo de energia (FEIGENWINTER et al., 2018).

Sendo assim, diante da dificuldade no monitoramento urbano, associado aos altos custos das estações micrometeorológicas, técnicas de sensoriamento remoto têm sido utilizadas como ferramentas alternativas e efetivas para as análises espaciais e temporais de espaço urbanos (LIU et al., 2016; CHEVAL et al., 2020). A partir das tecnologias geoespaciais, tornou-se possível monitorar remotamente as variáveis biofísicas (NDVI, NDBI, NDBaI, NDWI e MNDWI), e analisar suas interações e as mudanças da cobertura do solo (BUYANTUYEV e WU, 2012). Além disso, a quantificação das variáveis do balanço de energia em áreas urbanas torna-se fundamental para o aprimoramento dos estudos urbanos.

Desta maneira, diversos estudos vêm sendo realizado para estimar a expansão de áreas antropizadas em cidades e sua correlação com as alterações dos parâmetros biofísicos derivados de satélites (UDDIN et al., 2010; SHARMA et al., 2013; HE et al., 2017; CALLEJAS et al., 2019; MACHADO et al., 2020; LIN et al., 2020). O uso de técnicas de sensoriamento remoto na classificação e análise de alterações da cobertura do solo, baseados na radiação eletromagnética, vem demonstrando eficácia para a obtenção de um melhor entendimento da superfície terrestre (KHALAF e AL-JIBOURI, 2020).

A série do satélite Landsat vêm sendo amplamente utilizado para classificação da cobertura do solo (HU et al., 2017; PHIRI e MORGENROTH, 2017) e estimativas do balanço de energia (DA SILVA et al., 2017; NASCIMENTO et al., 2018), devido ao amplo acesso dos dados espectrais e suas respectivas séries temporais (ROY et al., 2014). O SEBAL (*Surface Energy Balance Algorithm for Land*; BASTIAANSEN et al., 1998), modelo utilizado para estimativa das variáveis do balanço de energia, foi inicialmente desenvolvido para aplicações hidrológicas e agrônomicas, no entanto, vêm demonstrado boa acurácia em ambientes urbanos (MIRANDA et al., 2018; FARIDATUL et al., 2019).

Portanto, estudos de áreas urbanas baseados em dados espaciais permitem avaliações espaço-temporais entre diferentes coberturas do solo, bem como analisar as alterações das variáveis dos componentes do balanço de energia (HU et al., 2016; MIRANDA et al., 2018). Esses dados podem auxiliar na compreensão da dinâmica e

os efeitos do processo de urbanização em diferentes escalas no ambiente urbano (HE et al., 2017). As informações obtidas a partir de estudos urbano, fornecem um diagnóstico temporal das ações antrópicas e podem auxiliar em ações futuras, sendo uma importante ferramenta de gestão urbana (COUTTS et al., 2016).

1.3 HIPÓTESE

A expansão de áreas construídas em Cuiabá – MT provoca diminuição nos valores de NDVI (*Normalized Difference Vegetation Index*), Rn_{inst} (saldo de radiação instantâneo), LE (fluxo de calor latente) e ET_{24} (evapotranspiração diária) e aumento nos valores de a_{sup} (albedo da superfície), T_s (temperatura de superfície), G (fluxo de calor no solo) e H (fluxo de calor sensível), resultante das alterações na rugosidade, cobertura da superfície e estrutura urbana que afetam as trocas de massa, energia e *momentum*.

1.4 OBJETIVOS

1.4.1 Objetivo Geral

Avaliar os efeitos da urbanização de Cuiabá-MT sobre o balanço de energia da superfície por sensoriamento remoto.

1.4.2 Objetivos Específicos

- Classificar a cobertura solo a partir de índices espectrais e avaliar a precisão da classificação para os anos de 1985 e 2017;
- Analisar as alterações na cobertura do solo para os anos de estudo;
- Avaliar os efeitos da mudança na cobertura do solo nos índices de vegetação, albedo e temperatura da superfície para os anos de 1985 e 2017;
- Analisar os efeitos das alterações da cobertura do solo nos componentes do balanço de energia.

2 REVISÃO BIBLIOGRÁFICA

2.1 EXPANSÃO URBANA DE CUIABÁ – MT E SEUS EFEITOS MICROMETEOROLÓGICOS

A cidade de Cuiabá foi fundada em 9 de abril de 1719 e passou por diferentes ciclos econômicos e de expansão urbana (SIQUEIRA e VILARINHO NETO, 2012). Nesse contexto, o desenvolvimento urbano acelerado que estrutura boa parte da malha urbana de Cuiabá ocorreu intensamente a partir da metade do século passado (MENEZES FILHO e AMARAL, 2014). A nova dinâmica urbana ocorreu devido a uma série de fatores, entre eles, os fluxos migratórios atraídos pela nova fronteira agroindustrial associadas a novas oportunidade de créditos rurais (BERNARDES, 2007).

Neste sentido, ao longo da história, o município de Cuiabá – MT passou por alguns períodos de expansão urbanas a partir de leis e atos municipais (Tabela 1- CUIABÁ 2007). O crescimento da área urbana entre as décadas de 1960 e 1990 foi expressivo, passando de uma área de 4,5 para 251 km². No sentido populacional, os maiores crescimentos também ocorreram entre as décadas de 1960 e 1990, como observado na tabela abaixo.

Tabela 1 - Evolução dos limites dos perímetros urbanos de Cuiabá- MT.

Mês/Ano	Lei nº	Área (Km ²)	Acréscimo (Km ²)	Variação (%)	População Urbana	Variação (%)
Jul/1938	176	2,59				
Jul/1960	534	4,50	1,91	73,75	45,87	
Mar/1974	1.346	48,45	43,95	976,67	122,28	166,56
Abr/1978	1.537	104,98	56,53	116,68	164,89	34,85
Nov/1982	2.023	153,06	48,8	45,80	222,30	34,81
Dez/1994	3.412	251,94	98,88	64,60	420,04	88,95
Dez/2003	4.485	256,31	4,37	1,73	517,19	23,13
Jul/2004	4.598	252,58	-3,73	-1,46	531,50	2,77
Dez/2004	4.719	254,57	1,99	0,79	531,50	0,00
Jan/2007	150	254,57	0,00	0,00	576,85	8,53

FONTE: Adaptado de CUIABÁ, 2007.

O efeito do rápido crescimento alterou a morfologia urbana com a construção de uma série de conjunto habitacionais, bairros e zonas industriais (ROMANCINI, 2011). Somando-se a esse crescimento residencial, durante o período 1960-1990, houve um grande desenvolvimento e reordenamento instituições públicas, como no caso da construção do centro político administrativo na região norte e a construção da

Universidade Federal de Mato Grosso na região leste (SIQUEIRA e VILARINHO NETO, 2012; MENEZES FILHO e AMARAL, 2014).

O reordenamento das instituições, a criação de abairramento nos extremos da cidade revela o interesse em descentralizar e expandir o perímetro urbano da capital (SIQUEIRA e VILARINHO NETO, 2012). Sendo assim, a evolução do perímetro urbano de Cuiabá - MT retrata de maneira muito clara como o processo de urbanização aumentou significativamente após a década de 1960, para diferentes eixos de ocupação (Figura 1).

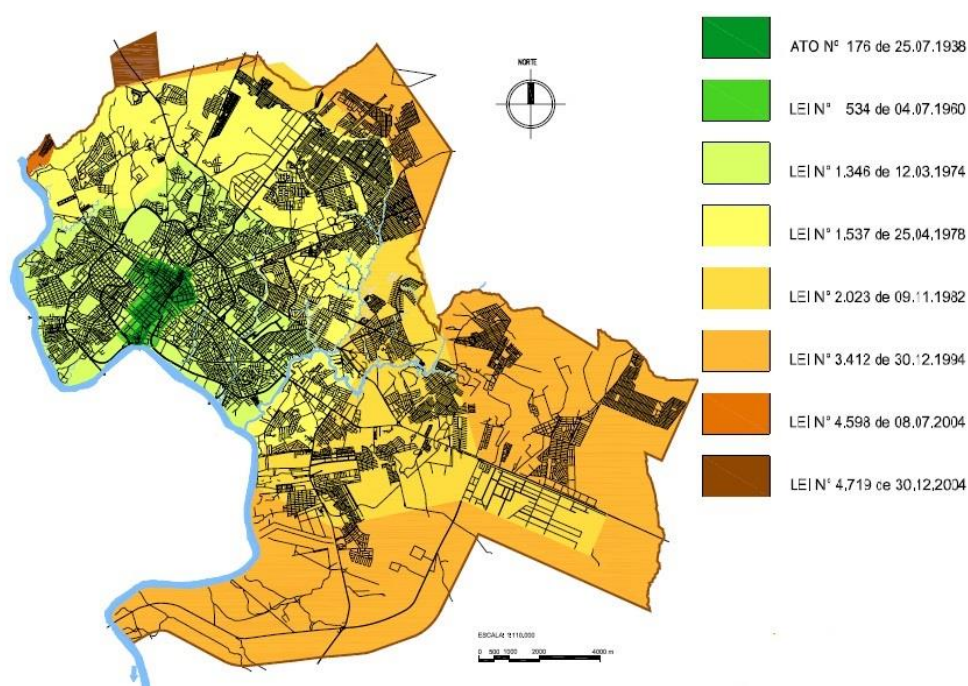


Figura 1 - Evolução do perímetro urbano de Cuiabá-MT de acordo com as. Leis e atos municipais.

FONTE: Adaptado de CUIABÁ (2007).

A expansão urbana, como demonstrado, teve como um dos principais efeitos ambientais a alta fragmentação dos espaços naturais e a rápida conversão de áreas vegetadas em construídas (VILANOVA & MAITELLI, 2009). A vegetação urbana é um importante elemento de conforto ambiental, minimização de poluição atmosférica, sonora e visual (KLINGBERG et al., 2017). No sentido biofísico, a vegetação é a principal cobertura do solo que atua para diminuição da temperatura do ar e aumento da umidade relativa, gerando o efeito de ilhas de frescor (DU et al., 2017). Sendo assim, esse efeito resulta da capacidade do tecido vegetal em absorver maior

quantidade de radiação solar e destinar esse aporte energético para mudança de estado de fase da água (DARAMOLA e BELOGUN, 2019).

A substituição das áreas vegetadas por superfícies artificiais, tais como concreto, asfalto e telhas, ocasionam uma mudança no padrão de absorção e reflexão da radiação (TAYYEBI et al., 2018). As superfícies urbanas, em especial, na região central-norte do Brasil, apresentam como características espectrais, maiores valores de albedo e menores valores de saldo de radiação da superfície quando comparado a vegetação nativa (DA SILVA et al., 2016; PAVÃO et al., 2017). Como consequência, estudos recentes demonstram que áreas urbanizadas apresentam maiores valores de temperatura do ar e menores umidade relativa, resultado da maior capacidade de condução térmica dos materiais urbanos (IGE et al., 2017; SHOJAEI, et al., 2017).

Atualmente, a área urbana de Cuiabá - MT conta com alguns parques que preservam a vegetação nativa, tais como, o Parque Dante de Oliveira, Parque Mãe Bonifácia, Morro da Luz, Parque Massairo Okamura, Parque Zé Bolo Flô. Ao longo dos anos houve um aumento na criação e melhoria de áreas destinadas a preservação e lazer, como o parque Tia Nair, Parque da Águas, Parque da Família e da Nascente Yone de Azevedo Campos. Esses espaços são importantes elementos para mitigar o efeito da urbanização no microclima urbano (DU et al., 2017).

2.2 IMAGENS ORBITAIS

O sensoriamento remoto (SR) consiste em uma das técnicas mais bem-sucedidas de coleta de dados da superfície terrestre. Cientificamente, o SR pode ser definido como técnicas que visam a obtenção de imagens e dados da superfície terrestre por meio da medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres (MENEZES, 2012).

As medições das interações da radiação eletromagnética com os materiais terrestres são realizadas por sensores imageadores acoplados em drones, aviões e em plataformas orbitais (GUO et al., 2017). Os sensores imageadores realizam a coleta de dados em forma de varredura linear do terreno, em diferentes faixas do espectro eletromagnéticos, também denominadas de bandas (MENEZES, 2012).

O processo de obtenção de imagens por plataforma orbitais (satélites artificiais) destaca-se como uma das metodologias mais utilizadas, com realização de coletas de

dados consistentes datadas no início da década de 1970 (ROY et al., 2014). Nesse contexto, a série de satélite Landsat da NASA (*National Aeronautics and Space Administration*) é uma das missões mais bem-sucedida, com início de suas atividades de coleta de dados a partir dos anos de 1972 (ROY et al., 2014; WULDER et al., 2016). Atualmente, a série Landsat encontra-se operante com duas plataformas o Landsat-7, lançado em 1999 e o Landsat-8, lançado em 2013.

A plataforma Landsat-5, lançada em 1984 e inativo desde final de 2011, foi o pioneiro na coleta de dados, operando por 27 anos (CLAVERIE et al., 2015; USGS, 2016; INPE, 2020). O satélite Landsat-5 era equipado com os sensores MSS até 1995 (*Multispectral Scanner System*) e o TM (*Thematic Mapper*) (USGS, 2016; INPE, 2020). Os pacotes de imagens eram constituídos por 7 bandas das quais as três primeiras são do visível (RGB), a quarta do infravermelho próximo, a quinta e a sétima do infravermelho, sendo a sexta a banda termal (Tabela 2).

Tabela 2 - Composição das bandas do satélite Landsat 5 TM e suas aplicações.

Banda	Detalhe espectral; Comprimento de onda (μm)	Resolução Espacial (m)	Aplicações
TM1	Azul (0,45–0,52)	30	Apresenta grande penetração em corpos de água, permitindo estudos batimétricos.
TM2	Verde (0,52–0,6)	30	Apresenta grande sensibilidade à presença de sedimentos em suspensão. Boa penetração em corpos de água
TM3	Vermelho (0,63–0,69)	30	Apresenta sensibilidade a vegetação permitindo contraste nos diversos usos do solo. Permite a visualização da mata galeria e cursos de rios. É a banda mais utilizada para delimitar a mancha urbana.
TM4	Infravermelho próximo (0,76–0,9)	30	Mapeamento de redes de drenagem, delineamento de corpos d'água e vegetação.
TM5	Infravermelho médio (1,55–1,75)	30	Por meio da umidade das plantas, permite a observação do estresse na vegetação, causado por desequilíbrio hídrico.
TM6	Infravermelho termal (10,40–12,5)	30	Observa os contrastes térmicos, detectando propriedades termais de rochas, solos, vegetação e água.
TM7	Infravermelho distante (2,08–2,35)	30	Apresenta sensibilidade à morfologia do terreno.

FONTE: Adaptado INPE, 2020; USGS, 2016.

Os sensores abordo do Landsat-5 forneciam imagens com uma resolução espacial de 30 m, com exceção da banda 6 (banda termal) com 120 m, resolução temporal de 16 dias e resolução radiométrica de 8 bits (USGS, 2016). O satélite Landsat-8 está equipado com dois sensores o *Operational Land Imager* (OLI) e o *Thermal Infrared Sensor* (TIRS) (VERMOTE et al., 2016; USGS, 2016). As imagens fornecidas por esses sensores estão distribuídas em 11 bandas, sendo a banda 1 focada para identificação de aerossol costal e 8 a pancromática (Tabela 3).

Tabela 3 - Composição das bandas do satélite Landsat 8 OLI/TIRS e suas aplicações.

Banda	Detalhe espectral; Comprimento de onda (μm)	Resolução Espacial (m)	Aplicações
OLI1	Aerossol Costal (0,43–0,45)	30	Detecção de aerossol e estudos costeiros e de coloração oceânica
OLI 2	Azul (0,45–0,51)	30	Apresenta grande penetração em corpos de água, permitindo estudos batimétricos.
OLI 3	Verde (0,53–0,59)	30	Apresenta grande sensibilidade à presença de sedimentos em suspensão. Boa penetração em corpos de água
OLI 4	Vermelho (0,64-0,67)	30	Apresenta sensibilidade a vegetação permitindo contraste nos diversos usos do solo. Permite a visualização da mata galeria e cursos de rios. É a banda mais utilizada para delimitar a mancha urbana.
OLI 5	Infravermelho próximo (0,85–0,88)	30	Mapeamento de redes de drenagem, delineamento de corpos d'água e vegetação.
OLI 6	Infravermelho médio (1,57–1,65)	30	Por meio da umidade das plantas, permite a observação do estresse na vegetação, causado por desequilíbrio hídrico.
OLI 7	Infravermelho distante (2,11–2,29)	30	Apresenta sensibilidade à morfologia do terreno.
OLI 8	Pancromática (0,50-0,68)	15	Apresenta maior contraste entre áreas vegetadas e terra sem cobertura vegetal.
OLI 9	Cirrus (1,36-1,38)	30	Detecção de nuvens finas compostas por cristais de gelo
TIRS 10	Banda termal 1 (10,60-11,19)	100	Observa os contrastes térmicos, detectando propriedades termais de rochas, solos, vegetação, água e áreas urbanas.
TIRS 11	Banda termal 2 (11,5-12,51)	100	Observa os contrastes térmicos, detectando propriedades termais de rochas, solos, vegetação, água e áreas urbanas.

FONTE: Adaptado INPE, 2020; USGS, 2016.

As bandas 2 a 7 e 10 a 11 correspondem as faixas do visível, infravermelho e termal. Os sensores abordo do Landsat-8 fornecem imagens com uma resolução espacial de 30 metros, com exceção da banda 10 e 11 (bandas termais) com 100 m, resolução temporal de 16 dias e resolução radiométrica de 16 bits (USGS, 2016).

O download das imagens da série Landsat pode ser realizado em diversas plataformas *onlines*, tais como a plataforma do INPE (Instituto Nacional de Pesquisas Espaciais) [<http://www.dgi.inpe.br/CDSR/>] e do Earth Explorer [<https://earthexplorer.usgs.gov/>] do serviço geológico americano (USGS). No caso da plataforma Earth Explorer é possível obter imagens em diferentes níveis de processamento e os produtos de refletância da superfície corrigida aos efeitos da atmosfera e índices espectrais. A plataforma do USGS permite ainda obter imagens reprojadas para o hemisfério sul e redimensionamento da resolução espacial.

As aplicações das imagens e produtos dos satélites Landsat são inúmeras, que vão desde acompanhamento de cobertura do solo (SHARMA et al., 2013), monitoramento de vegetação (ZHAO et al., 2018), estudo de dinâmica de urbanização (TAYYBI et al., 2018), estimativa de trocas de massa e energia na superfície (DARAMOLA e BELOGUN, 2019) entre outros. A ampla aplicação das imagens de satélites em estudos urbanos e ambientais se deve ao fato dessa metodologia prover informações confiáveis, sem custos de aquisição de imagens e de escalas temporais de até 40 anos (ROY et al., 2014).

Além disso, outros fatores contribuem para a ampla utilização das imagens de satélites ou de sensoriamento remoto são o uso de sensores multiespectrais, resolução espacial consistentes para avaliação de áreas menores e amplo acesso a softwares SIG (sistemas de informações geográfica). Os sensores multiespectrais permitem detecção da radiação em diferentes faixas do espectro eletromagnético, inclusive na faixa termal (10-13 μm) (USGS, 2016). No caso da resolução espacial, os 30 metros dos sensores TM e OLI fornecem dados suficientemente precisos para avaliações média e até mesmo municípios inteiros (USGS, 2016; TAYYBI et al., 2018).

2.3 ÍNDICES ESPECTRAIS DA SUPERFÍCIE

Os índices espectrais compreendem um conjunto de parâmetros com ampla utilização e finalidade no sensoriamento remoto. Historicamente, o uso dos índices

espectrais remonta ao final da década de 1960 e início da década de 1970, em que se percebeu que a razão normalizada entre as bandas é sensível às variações superficiais (KRIEGLER et al., 1969; ROUSE et al., 1974; JUSTICE et al., 1985). Desta maneira, índices espectrais tais como: NDVI (*Normalized Difference Vegetation Index*), NDBI (*Normalized Difference Built-up Index*), NDBaI (*Normalized Difference Bareness Index*), NDWI (*Normalized Difference Water Index*) e MNDWI (*Modified Normalised Difference Water Index*), vem sendo utilizados para classificação da cobertura do solo e análise da expansão de áreas urbanas (SHARMA et al., 2013).

Os índices espectrais fornecem dados numéricos e podem ser utilizados para classificação de diferentes coberturas do solo a partir da correlação dos parâmetros biofísicos. O NDVI obtido pela diferença normalizada entre as bandas correspondente ao vermelho e infravermelho próximo, é amplamente utilizado em áreas urbanas para identificação de áreas vegetadas (MARTIN et al., 2015). O NDVI foi proposto por ROUSE et al. (1974) e fornece informações espectrais muito precisas acerca da cobertura vegetal, o que permite avaliar espaço-temporalmente mudanças na cobertura do solo (FILIPPA et al., 2018; KARLSEN, et al., 2018; ZHAO et al., 2018).

O NDBI proposto por Zha et al. (2003), foi desenvolvido para identificação de áreas construídas e para estudos da correlação da urbanização com a formação de ilhas de calor (MOREIRA FILHO e TAVARES JUNIOR, 2016). A estimativa do NDBI tem como base a resposta espectral das áreas construídas entre as bandas do infravermelho próximo e o infravermelho médio (MOREIRA e AMORIM, 2016). Por outro lado, o NDBaI proposto por Chen et al. (2006), também foi criado para identificação de áreas antropizadas, pois suas características espectrais são altamente consistentes para identificação de áreas de solo exposto com baixo teor de umidade.

O NDBaI foi criado também para melhoria no mapeamento da cobertura do solo, pois suas características espectrais são altamente consistentes para identificação de áreas sem vegetação (CHEN et al., 2006). Sendo assim, NDBaI tem sido incluso em muitos estudos de mapeamento urbano, em consequência do aumento dessas áreas, fruto da intensificação da urbanização (AS-SYAKUR et al., 2012; PINHEIROS e LARANJEIRA, 2013; SHARMA et al., 2013).

Os índices espectrais podem também ser aplicados visando identificar corpos d'água, umidade da superfície e conteúdo de água no solo. Destacando-se o NDWI

proposto por Gao (1996) e o MNDWI proposto por Sharma et al. (2013). Nesses casos, suas aplicações são diversas, tanto para classificação do uso do solo, avaliação do efeito da urbanização, balanço de massa na superfície terrestre e conteúdo de água nas plantas (SHARMA et al., 2013; YUE et al., 2019).

2.4 BALANÇO DE RADIAÇÃO E ENERGIA POR SENSORIAMENTO REMOTO

O balanço de radiação da superfície pode ser definido como o saldo entre os fluxos radiativos de ondas longas e curtas na superfície terrestre (OLIVEIRA et al., 2016). O balanço de radiação por se tratar de um saldo, também é denominado como saldo de radiação da superfície terrestre. A energia líquida quantificada pelo saldo de radiação representa o total de energia disponível para os processos biofísicos e bioquímicos que ocorrem na superfície (MIRA et al., 2016).

No sentido prático, o saldo de radiação resulta da soma de dois componentes: i) o balanço de ondas curtas (BOC) e; o balanço de ondas longas (BOL). O balanço de ondas curtas é o componente maior peso e resulta do cômputo entre as frações da radiação direta e difusa que incidem e deixam a superfície terrestre (MIRA et al., 2016 HU et al., 2017; ZHAO et al., 2019). As frações de radiação solar diretas e difusas incidentes, nesse caso, são representadas pela radiação global terrestre (R_g). A fração de onda curta refletida é obtida a partir do coeficiente de reflexão da superfície, denominado de albedo da superfície (MIRA et al., 2016; HU et al., 2017; ZHAO et al., 2019).

O balanço de ondas longas, por outro lado, possui menor peso no saldo de radiação e resulta do cômputo das frações de ondas longas que incidem e deixam a superfície terrestre (WANG et al., 2015). A estimativa das frações de ondas longas no BOL, geralmente são obtidas aplicando-se a Lei de Stefan-Boltzmann que estabelece que a energia emitida por determinado corpo é proporcional a quarta potência de sua temperatura (ZHAO et al., 2019).

Atualmente, existe um volume considerável de estudos que estimaram e validaram o saldo de radiação através de técnicas de sensoriamento remoto (FAUSTO et al., 2014; CARMONA et al., 2015; OLIVEIRA, et al., 2016; MARQUES et al., 2017). As estimativas a partir dos sensores MODIS e dos sensores abordo dos satélites

Landsats ganham destaque pelo fácil acesso dos dados e continuidade temporal (OLIVEIRA, et al., 2016; MARQUES et al., 2017).

O saldo de radiação é uma das variáveis centrais para estudos da dinâmica energética na superfície terrestre (MIRA et al., 2016). A partir do seu valor é possível compreender como diferentes componentes terrestre (florestas, áreas urbanas, solos expostos) utilizam esse aporte energético em processos biofísicos (FAUSTO et al., 2014; MARQUES et al., 2017). A estimativa desse particionamento energético é denominada de balanço de energia da superfície e tem sido realizado por diferentes metodologias a partir do sensoriamento remoto (KALMA et al., 2008).

A estimativa do balanço de energia por sensoriamento remoto é realizada há algumas décadas, como no caso dos estudos de MORAN et al., (1989) e MENENTI et al., (1989) a partir de dados do sensor TM. Atualmente, as estimativas dos componentes do balanço de energia por dados dos satélites Landsats têm sido realizadas pelos algoritmos SEBAL (*Surface Energy Balance algorithm for Land* – BASTIAANSSEN et al., 1998), METRIC (*Mapping Evapotranspiration with Internalized Calibration* - ALLEN et al., 2007), SEBS (*Surface Energy Balance System* – SU et al., 2002) e S-SEBI (*Simplified Surface Energy Balance Index* – ROERINK et al., 2000), em que os dois primeiros modelos se destacam para estudos em ambientes urbanos.

O algoritmo SEBAL se destaca por sua robustez em estimar os componentes do balanço de energia, em especial a densidade de fluxo de calor sensível (H), obtida a partir da resolução da equação aerodinâmica (BASTIAANSSEN et al., 1998). No SEBAL a resolução do gradiente de temperatura (dt) é realizada a partir de uma relação linear baseada em dois pixels em condições extremas, denominados “âncoras” (BASTIAANSSEN et al., 1998; TANG et al., 2013).

O algoritmo SEBAL em sua proposição iniciais tinha como objetivo central a estimativa da evapotranspiração em escalas regionais (BASTIAANSSEN et al., 1998), contudo, inúmeros estudos demonstraram sua eficácia em ambientes urbanos ou modificados (NING et al., 2017; DARAMOLA e BELOGUN, 2019). Sendo assim, alguns estudos foram realizados no Brasil, utilizando o algoritmo do SEBAL para análises urbanas, como os estudos propostos por Pavão et al. (2016) para cidade de Humaitá – AM, Nascimento et al. (2017) para região metropolitana de Cariri – CE,

Silva et al. (2018) para a cidade de Salto de Lontra – PR, na região centro-oeste os estudos de Ribeiro et al. (2018) para e Goiânia – GO e Machado et al. (2020) para o perímetro urbano de Cuiabá – MT.

A heterogeneidade das áreas urbanas e as diferentes propriedades de absorção e reflexão de energia, torna seu monitoramento complexo, sendo o algoritmo SEBAL um alternativa para análise de sistemas urbanos. Os materiais que compõem o meio urbano apresentam maior admitância térmica, fazendo com que a energia armazenada dentro do dossel urbano seja maior do que nos ambientes rurais (CALLEJAS et al., 2016; GRIMMOND et al., 1991).

O principal efeito no balanço de energia a partir do processo de urbanização manifesta-se na diminuição da evapotranspiração e na intensificação do fluxo de calor sensível, que contribui para o aquecimento do ambiente urbano (CHRYSOULAKIS et al., 2018). Por outro lado, o fluxo de calor no solo exerce grande influência na formação das zonas quentes, baseando-se na premissa de maior condutividade térmica e capacidade de armazenamento de calor em materiais construtivos (MAITELLE, 2010). No entanto, existem poucos estudos que avaliam os impactos da conversão do cerrado em áreas urbanizadas nos componentes do balanço de energia.

O primeiro estudo de balanço de energia em Cuiabá – MT foi realizado por Maitelle (1994), que objetivou identificar os efeitos da urbanização na temperatura e umidade do ar. Outro trabalho relevante foi realizado por Callejas et al. (2019), que avaliou as trocas no fluxos de energia estimado pela razão de Bowen em áreas rurais e urbanas, bem como o calor armazenado dentro do dossel urbano. No entanto, foi o estudo propostos por Machado et al. (2020), o primeiro a analisar a influência das alterações antrópicas no componentes do balanço de energia a partir do algoritmo SEBAL.

Machado et al. (2020) identificou que a substituição da vegetação nativa por áreas construídas alterou completamente as características radiativas, térmicas e higrométrica da superfície. Os resultados apresentaram os maiores valores de a_{sup} e T_s em áreas antropizadas, que refletiu na redução do Rn_{inst} , aumento no G e H em áreas edificadas e de solo exposto. O balanço de energia estimado pelo algoritmo SEBAL mostrou-se eficaz para análise em áreas urbanas.

3 MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

A área de estudo localiza-se no perímetro urbano do município de Cuiabá, capital do Estado de Mato Grosso (Figura 1). O município possui uma população estimada de 612.547 habitantes (IBGE, 2019) e está localizado no Centro Geodésico da América do Sul, na região centro-oeste do país. O município possui uma área total de 3.495,4 km², com uma área urbana de 258,88 km² (MACHADO et al., 2017).

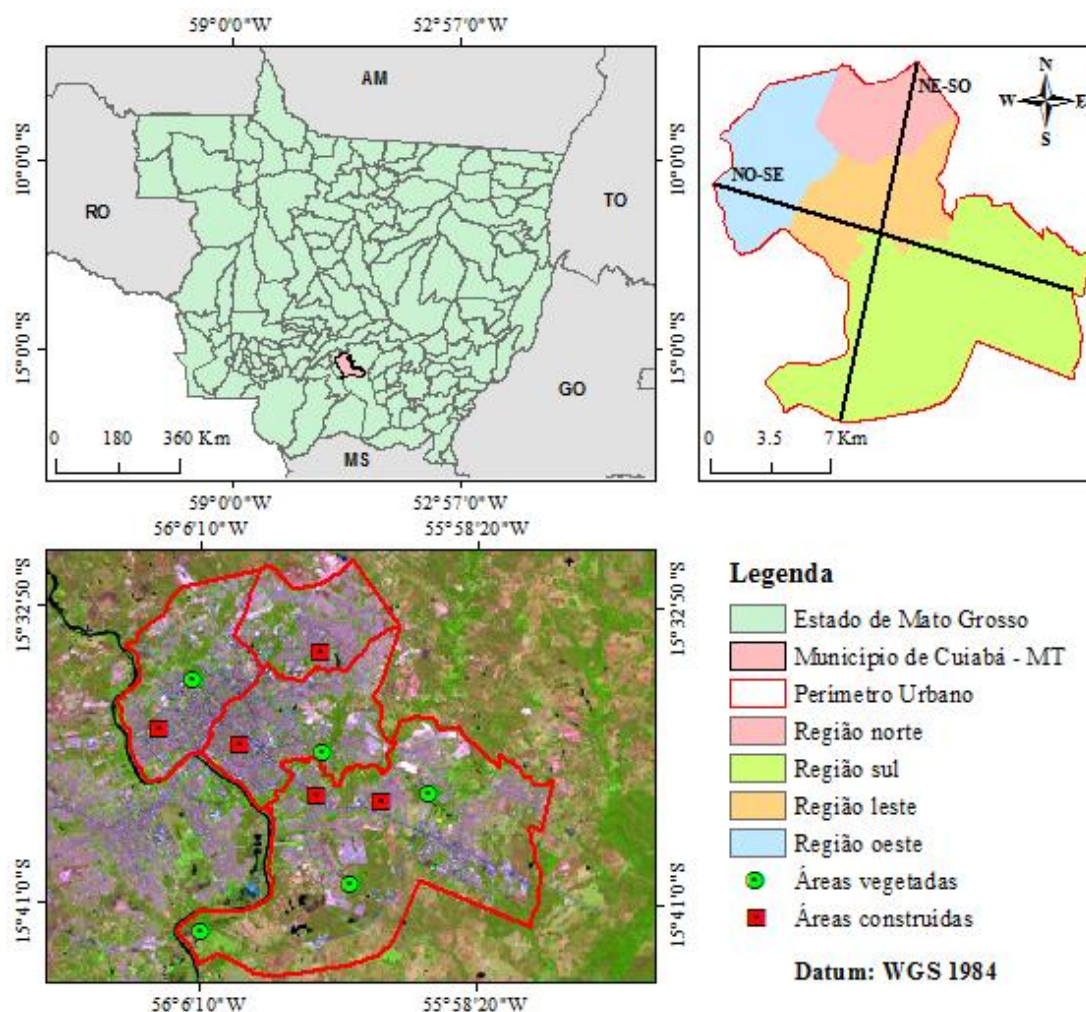


Figura 2 - Localização de Cuiabá, MT, Brasil e a distribuição das diferentes regiões no perímetro urbano de Cuiabá.

O clima regional é Aw de acordo com a classificação de Köppen, que representa um clima tropical semi-úmido, com duas estações bem definidas (BRASIL, 1997; MACHADO et al., 2015). A precipitação média anual é de 1335 mm, com dois regimes de chuvas distintos, sendo uma estação seca de maio a setembro (outono-

inverno) e uma estação chuvosa de outubro a abril (primavera-verão). As temperaturas médias anuais oscilam entre 24 °C e 26 °C (MACHADO et al., 2015).

A vegetação típica da região é constituída por remanescentes de Cerrado, Cerradão, Matas Ciliares e por vegetação introduzida cultivadas em quintais e praças (GUARIM NETO, 1991; MACHADO et al., 2017). O relevo da região urbana é suavemente ondulado com altitude média de 165 metros. A área urbana do município é drenada pelo rio Coxipó e inúmeros córregos tais como: córrego da Prainha, Ribeirão da Ponte, Manoel Pinto, Moinho, Barbados, Gambá e São Gonçalo (MAITELLI, 2010).

A macrozona urbana de Cuiabá – MT é dividida em quatro grandes regiões administrativas: Região Norte, Região Sul, Região Leste e Região Oeste, criadas pela Lei 3.262 de 1994 (Tabela - 4; CUIABÁ, 2010). A região urbana é composta ainda por ocupações denominadas de localidades constituídas por loteamentos regulares, irregulares, clandestinos, fechados, desmembrados, assentamentos informais, conjuntos habitacionais, condomínios verticais e horizontais (CUIABÁ, 2010).

Tabela 4 - Relação entre as regiões administrativas e bairros, localidades e distribuição populacional.

Regiões Administrativas	Bairros	Localidades	Distribuição Populacional
Norte	10	72	8,47%
Sul	33	104	29,67%
Leste	49	115	41,52%
Oeste	24	106	20,34%

FONTE: Adaptado de CUIABÁ, 2010.

A região norte teve sua expansão urbana acelerada após a década de 1970 com a construção do Centro Político Administrativo (CPA). Atualmente, o bairro Morada da Serra, mais conhecido como CPA, apresenta-se como uma nova centralidade em relação a cidade (VASCONCELOS & ZAMPARONI, 2011). Em adição, o bairro Morada da Serra representa a maior densidade de habitação da região.

A região sul apresenta a maior extensão territorial da área urbana, destacando-se os bairros Pedra 90 e Tijucal. A região sul possui como uma das características muitos espaços não urbanizados destinadas a expansão urbana (CUIABÁ, 2010), o que lhe confere a menor densidade populacional entre as regiões, em torno de 3,2 mil hab/km² (CUIABÁ, 2009).

A região leste apresenta a maior concentração populacional de Cuiabá – MT, com densidade populacional acima de 6,6 mil hab/km². Nesta região estão localizados o centro histórico e os bairros mais antigos, por ser a região onde se iniciou o processo de ocupação da cidade (CUIABÁ, 2009). Nessa região destaca-se os bairros Dom Aquino, Jardim Itália e a Universidade Federal de Mato Grosso (CUIABÁ,2010).

A região oeste é uma região de expansão populacional tardia em relação as demais. Foi a partir da instalação do Shopping Goiabeiras, no final de 1980 e da implementação do Parque Mãe Bonifácia no final de 1990, que houve um expressivo aumento populacional nessa região, em consequência do aumento das especulações imobiliárias (ROMANCINI, 2011).

3.2 AQUISIÇÃO E PROCESSAMENTO DAS IMAGENS

Neste estudo foram utilizadas imagens dos sensores TM e OLI/TIRS abordo dos satélites Landsat 5 e 8 para os dias 03/07/1985 e 11/07/2017, respectivamente. As imagens foram obtidas na plataforma ESPA (*EROS Science Processing Architecture*) [<https://espa.cr.usgs.gov>] do serviço geológico americano (USGS). A plataforma ESPA permite o download de produtos de refletância da superfície, refletância no topo da atmosfera e temperatura de brilho dos sensores TM e OLI/TIRS que foram utilizados para classificação da cobertura do solo e estimativa do balanço de energia superficial.

O produto de refletância da superfície do sensor TM fornecido pela ESPA foi gerado pelo algoritmo LEDAPS (*Landsat Ecosystem Disturbance Adaptive Processing System*). O algoritmo aplica rotinas de correções atmosféricas utilizando dados internos do sensor e dados externos do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), dados meteorológicos do NCEP (*National Centers for Environmental Prediction*), NOAA (*National Oceanic and Atmospheric Administration*) e NASA (*National Aeronautics and Space Administration*) para obter a refletância da superfície corrigida a partir da refletância do topo da atmosfera (SCHMIDT et al., 2013; USGS 2019a). O LEDAPS utiliza o código transferência radiativa 6s (*Second Simulation of a Satellite Signal in the Solar Spectrum*; VERMOTE et al., 1997) e ainda o modelo digital de elevação para corrigir o erro de paralaxe devido ao relevo topográfico local, bem como, correção geométrica

sistemática e correção de precisão usando chips de controle na superfície (SCHMIDT et al., 2013; CLAVERIE et al., 2015; VERMOTE et al., 2016).

O produto de refletância da superfície do sensor OLI foi gerado pelo algoritmo LaSRC (*Land Surface Reflectance Code*) que utiliza bandas de aerossol, dados climáticos auxiliares (temperatura do ar, profundidade ótica e ozônio) de produtos MODIS. Os dados de pressão atmosférica são obtidos internamente a partir da elevação. O LaSRC usa um modelo de transferência radiativa exclusivo (VERMOTE et al., 2016; USGS 2019b).

3.2.1 Dados Meteorológicos

Os dados meteorológicos utilizados nos algoritmos de correção da temperatura de brilho e para estimativa do balanço de energia foram obtidos da Estação Meteorológica de Cuiabá do Instituto Nacional de Meteorologia (INMET), código 83361. Os dados utilizados foram de temperatura do ar, umidade relativa do ar, pressão atmosférica, velocidade do vento e insolação dos dias 03/07/1985 e 11/07/2017 (Tabela 5).

Tabela 5 - Dados meteorológicos utilizados para correção da temperatura de brilho e para estimativa do balanço de energia foram obtidos da Estação Meteorológica de Cuiabá do Instituto Nacional de Meteorologia (INMET).

Data	Temperatura do ar (°C)	Umidade Relativa do ar (%)	Pressão Atmosférica (kPa)	Velocidade do vento (m s ⁻¹)	Insolação (horas)
03/07/1985	24,6	77,0	99,9	1,5	9,4
11/07/2017	26,0	57,7	101,2	1,8	8,6

3.3 ESTIMATIVA DOS ÍNDICES ESPECTRAIS

Os índices espectrais são parâmetros estimados a partir da razão entre bandas dos sensores TM e OLI/TIRS dos satélites Landsat 5 e 8. Esses índices são fundamentais para estudos de cobertura do solo a partir condições para caracterização de classes, pois representam muito bem as assinaturas espectrais de diferentes componentes da superfície (SHARMA et al., 2013). Os índices espectrais também desempenham um papel importante na estimativa de parâmetros no balanço de energia como emissividade da superfície, coeficiente de rugosidade da superfície e também na estimativa do fluxo de calor no solo. Nesse sentido, podemos dividir os índices

espectrais em índices de vegetação, índice de área construída, índices de umidade e índice de solo exposto.

3.3.1 Índices de Vegetação

O índice de vegetação por diferença normalizada (*Normalized Difference Vegetation Index* - NDVI) é a razão das diferenças de refletividade para a banda do infravermelho próximo (ρ_{NIR}) e a banda do vermelho (ρ_{Red}) por sua soma (ROUSE et al., 1974).

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}} \quad \text{Eq. 1}$$

O índice de vegetação ajustado aos efeitos do solo (*soil adjusted Vegetation Index* - SAVI) proposto por Huerte (1988) consiste em uma adaptação do NDVI aos efeitos do solo:

$$SAVI = \frac{(1 + L)\rho_{NIR} - \rho_{Red}}{L + \rho_{NIR} + \rho_{Red}} \quad \text{Eq. 2}$$

em que L é a constante de ajuste ao solo cujo valor usado no estudo foi 0,1 (FAUSTO et al., 2016).

3.3.2 Índice de Área Construída

O índice de área construída por diferença normalizada (*Normalised Difference Built-up Index* - NDBI) é a razão das diferenças de refletividade para a banda do infravermelho médio (ρ_{MIR}) e a banda do infravermelho próximo (ρ_{NIR}) por sua soma (ZHA et. al., 2003):

$$NDBI = \frac{\rho_{MIR} - \rho_{NIR}}{\rho_{MIR} + \rho_{NIR}} \quad \text{Eq. 3}$$

3.3.3 Índice de Umidade

O índice de umidade por diferença normalizada (*Normalised Difference Water Index* - NDWI) é a razão das diferenças de refletividade para a banda do infravermelho próximo (ρ_{NIR}) e a banda do infravermelho médio (ρ_{MIR}) por sua soma (GAO, 1996).

$$NDWI = \frac{\rho_{NIR} - \rho_{MIR}}{\rho_{NIR} + \rho_{MIR}} \quad \text{Eq. 4}$$

O índice de umidade modificado (*Modified Normalised Water Index* - MNDWI) propõe a substituição da banda ρ_{NIR} pela banda azul (ρ_{blue}) sendo obtido pela seguinte equação (SHARMA et al., 2013):

$$MNDWI = \frac{\rho_{blue} - \rho_{MIR}}{\rho_{blue} + \rho_{MIR}} \quad \text{Eq. 5}$$

3.3.4 Índice de Solo Exposto

O índice de solo exposto por diferença normalizada (*Normalised Difference Bareness Index* - NDBaI) é a razão das diferenças da banda do infravermelho médio em número digital (DN_{MIR}) e banda termal também em número digital (DN_{termal} ; CHEN et al., 2006):

$$NDBaI = \frac{DN_{MIR} - DN_{termal}}{DN_{MIR} + DN_{termal}} \quad \text{Eq. 6}$$

em que DN representa os valores de número digital para cada pixel.

3.4 CLASSIFICAÇÃO DA COBERTURA DO SOLO

A classificação da cobertura do solo foi realizada a partir do estabelecimento de cinco categorias identificadas por interpretação visual das imagens. As classes identificadas foram: (1) Áreas de vegetação densa (AVD), que inclui parques urbanos, mata ciliar e de galeria; (2) Áreas de vegetação arbustiva (AVA), que são formadas por uma composição mista de gramíneas e árvores de pequeno porte, sendo essas tipicamente encontradas em regiões de cerrado e em meio a áreas urbanas; (3) Áreas de vegetação rasteira e/ou solo exposto (AVR), que são as áreas de solo totalmente exposto ou com alguma presença de gramíneas; (4) Áreas construídas (ACO), sendo composta por características urbanas e estruturas impermeáveis como asfalto e concreto; e (5) Áreas de corpos d'água (ACA), sendo formadas por rios e armazenamento de água de pequeno porte.

A classificação da cobertura do solo nas classes descritas foi realizada a partir de um algoritmo de decisão hierárquico, baseando-se em inúmeros testes, para estabelecer regras e condições para o processamento e obtenção de uma classificação mais próxima ao real. Nesse sentido, a partir dos índices espectrais descritos

anteriormente foi estabelecida uma condição para cada classe, onde cada condição foi inferida e processadas para geração de imagens de classificação.

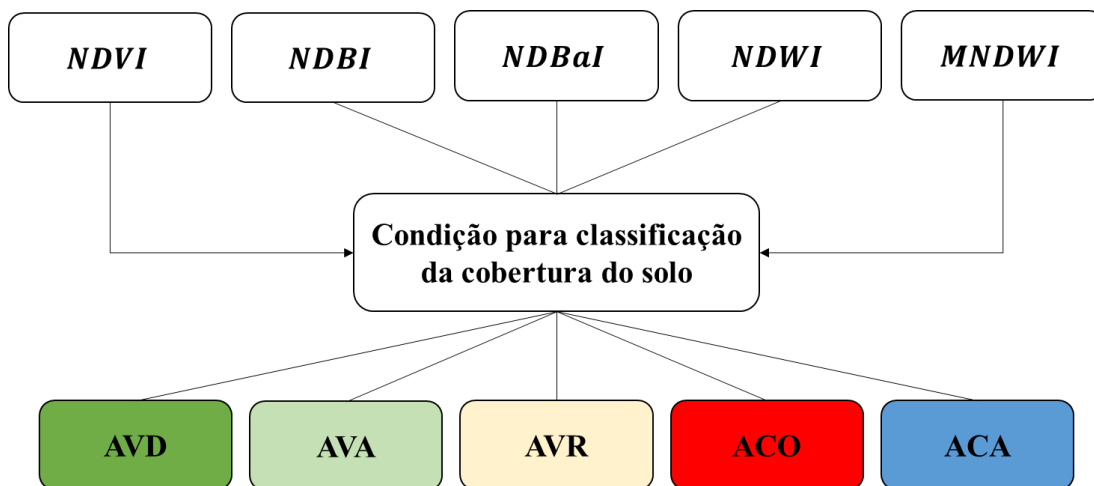


Figura 3 - Fluxograma ilustrando as etapas de processamento de classificação da cobertura do solo. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água).

3.4.1 REGRAS E CONDIÇÕES PARA GERAR A CLASSIFICAÇÃO DE COBERTURA DO SOLO

A construção da condição para classificação de cobertura do solo foi realizada a partir de amostragens de áreas que se enquadravam nas regras de classe de cobertura do solo. A classe AVD representou áreas de vegetação densa, AVA representou áreas de vegetação esparsa de médio e pequeno porte, associadas a gramíneas, AVR representou áreas de gramíneas associadas a solo exposto, ACO representou áreas de construções, asfalto e concreto, ACA representou áreas de corpos d'água.

A partir da interpretação visual das imagens do Google Earth, foram identificadas áreas de controle que atendiam as regras de cada classe descrita. Posteriormente, essas áreas de controle foram delimitadas e os valores dos índices espectrais utilizados na classificação foram extraídos. Dessa maneira, foi possível obter os intervalos dos índices para cada classe.

3.5 AVALIAÇÃO DA CONFIABILIDADE DA CLASSIFICAÇÃO

A avaliação da acurácia do modelo de classificação foi realizada a partir da construção de uma matriz quadrada ou também chamada matriz de confusão de números definidos em linhas e colunas. A matriz de confusão permite avaliar a qualidade obtida de uma classificação a partir da comparação com dados de referências (FIELDING & BELL, 1997). A construção foi realizada a partir de uma tabulação cruzada simples, onde as colunas representaram os dados de referência (Real), enquanto as linhas representaram a classificação gerada a partir dos dados de sensoriamento remoto (Estimado) (FOODY, 2002) (TABELA 6).

Tabela 6 - Esquema geral da matriz de confusão.

Estimado	Real	
	1	0
1	a	b
0	c	d

O preenchimento da matriz de confusão foi realizado em três etapas: i) Separação das classes identificadas (*clip*) e posterior conversão dos valores dos pixels em 0 e 1, onde 1 representa os pixels da classe em análise e 0 representa os pixels que estavam fora da classe em análise; ii) Geração de 25 pontos aleatórios para cada classe devidamente distribuídos por toda área de estudo, obedecendo uma distância mínima de 120 m para cada ponto e; iii) Conferência e análise da precisão de cada ponto gerado aleatoriamente em cada classe através da sobreposição das imagens classificadas com o Google Earth, onde foi possível verificar os acertos e os erros na aplicação do método.

Dessa maneira, os valores de “a” foram definidos como os verdadeiros positivos, isto é, foram os pixels classificados com valor 1 que em comparação ao real são verdadeiramente 1. Os valores de “b” foram definidos como os falsos positivos, onde os pixels classificados com valor 1 não são verdadeiramente 1 em comparação ao real. Os valores de “c” foram definidos como os falsos negativos, onde os pixels classificados com valor 0 equivale ao valor 1 em comparação com o real e os valores de “d” foram definidos como os verdadeiros negativos, isto é, foram os pixels classificados como 0 que são verdadeiramente 0 em comparação com o real.

A partir do preenchimento da matriz de confusão foi calculado uma variedade de medidas de erro e de precisão para a avaliação da confiabilidade da classificação

estabelecida (Tabela 7). Os valores desses índices variam de 0 a 1, sendo que quando mais próximo de 1, melhor a acurácia da classificação.

Tabela 7 - Medidas de precisão da classificação de cobertura do solo derivada da matriz de confusão para a área urbana de Cuiabá-MT. Medidas de precisão para avaliar o desempenho preditivo da classificação. Onde **a** são os verdadeiros positivos, **b** os falsos positivos, **c** os falso-negativos, **d** os verdadeiros negativos, **n** são os pontos randômicos de uma classe e **N** é o número total de pontos randômicos.

Estimativas	Cálculo
Classificação correta	$(a + d)/N$
Classificação incorreta	$(b + c)/N$
Erro de omissão	$c/(a + b)$
Erro de comissão	b/n
Acurácia do produtor	$1 - \text{erro de omissão}$
Acurácia do usuário	$1 - \text{erro de comissão}$
Kappa	$[(a + d) - (((a + b) + (b + d)(c + d))/N)]/[N - (((a + c)(a + b) + (b + d)(c + d))/N)]$

A classificação correta informa a proporção dos verdadeiros positivos e negativos (diagonal principal) em relação ao total de pontos avaliados. A classificação incorreta avalia a proporção dos erros das classificações em relação ao total de pontos avaliados (CONGALTON & GREEN, 1999)

O erro de omissão representa a porcentagem de pixels pertencentes à classe x nos dados de referência, que não foram classificados como tais, ou seja, omitidos (BOSCHETTI et al., 2004). O erro de comissão representa a porcentagem de pixels classificados como classe x que não pertencem a essa classe de acordo com os dados de referência (BOSCHETTI et al., 2004).

A acurácia do produtor avalia o quão bem uma determinada área foi classificada a partir do erro de omissão, ou seja, a partir da proporção de características observadas no terreno que não são classificadas no mapa. A acurácia do usuário informa ao usuário o quão bem o mapa representa o que realmente está no terreno a partir do erro de comissão (BANKO, 1998; FISHER et al., 2018).

O coeficiente Kappa é a estimativa mais utilizadas em análises de confiabilidade de classificações, pois o seu cálculo incorpora a informação mal classificados e não apenas o bem classificado como a taxa de classificação correta

(CONGALTON & GREEN, 1999). Os resultados obtidos pelas estimativas do Kappa variam de 0 a 1, sendo que quando mais próximo de 1, melhor a acurácia da classificação (Tabela 8).

Tabela 8 - Padrão de precisão e acurácia da classificação a partir da estimativa Kappa.

Estimativa Kappa	Desempenho
<0	Péssimo
$0,0 < \text{Kappa} \leq 0,2$	Ruim
$0,2 < \text{Kappa} \leq 0,4$	Razoável
$0,4 < \text{Kappa} \leq 0,6$	Bom
$0,6 < \text{Kappa} \leq 0,8$	Muito Bom
$0,8 < \text{Kappa} \leq 1,0$	Excelente

3.6 MUDANÇA DE COBERTURA DO SOLO

As alterações gerais da cobertura do solo foram estimas pelas seguintes equações:

$$LCC(\text{ha}) = LC2011 - LC1986 \quad \text{Eq. 7}$$

$$LCC(\%) = LCC(\text{ha}) / LC1986 \times 100 \quad \text{Eq. 8}$$

em que $LCC(\text{ha})$ corresponde à mudança de cobertura de superfície em hectares; $LCC(\%)$ é a mudança de cobertura de superfície em porcentagem; $LC1985$ e $LC2017$ são a área total do tipo de cobertura do solo em hectares no ano de 1985 e 2017.

A avaliação da mudança da cobertura do solo entre os anos de 1985 e 2017 também foi realizada mediante a construção da matriz geral (Figura 4) de tabulação cruzada ou matriz transição (PONTIUS Jr, et al, 2004; ALVES et al., 2018).

Classe 1985	Classificação 2017					Total 1985	Perdas
	AVD	AVA	AVR	ACO	ACA		
AVD	C ₁₁	C ₁₂	C ₁₃	C ₁₄	C ₁₅	$\sum_{i=1}^{i=5} C_{1x}$	$\sum_{i=1}^{i=5} C_{1x} - C_{11}$
AVA	C ₂₁	C ₂₂	C ₂₃	C ₂₄	C ₂₅	$\sum_{i=1}^{i=5} C_{2x}$	$\sum_{i=1}^{i=5} C_{2x} - C_{22}$
AVR	C ₃₁	C ₃₂	C ₃₃	C ₃₄	C ₃₅	$\sum_{i=1}^{i=5} C_{3x}$	$\sum_{i=1}^{i=5} C_{3x} - C_{33}$
ACO	C ₄₁	C ₄₂	C ₄₃	C ₄₄	C ₄₅	$\sum_{i=1}^{i=5} C_{4x}$	$\sum_{i=1}^{i=5} C_{4x} - C_{44}$
ACA	C ₅₁	C ₅₂	C ₅₃	C ₅₄	C ₅₅	$\sum_{i=1}^{i=5} C_{5x}$	$\sum_{i=1}^{i=5} C_{5x} - C_{55}$
Total 2017	$\sum_{i=1}^{i=5} C_{x1}$	$\sum_{i=1}^{i=5} C_{x2}$	$\sum_{i=1}^{i=5} C_{x3}$	$\sum_{i=1}^{i=5} C_{x4}$	$\sum_{i=1}^{i=5} C_{x5}$	$\sum_{i=1}^{i=5} C_{nx}$	$\sum_{i=1}^{i=5} perdas$
Ganhos	$\sum_{i=1}^{i=5} C_{x1} - C_{11}$	$\sum_{i=1}^{i=5} C_{x2} - C_{22}$	$\sum_{i=1}^{i=5} C_{x3} - C_{33}$	$\sum_{i=1}^{i=5} C_{x4} - C_{44}$	$\sum_{i=1}^{i=5} C_{x5} - C_{55}$	$\sum_{i=1}^{i=5} ganhos$	$\sum_{i=1}^{i=5} C_{nx} - perdas$

FONTE: Adaptado de Pontius Jr. et al. (2004).

Figura 4 - Matriz geral de tabulação cruzada para a comparação de dois mapas em momentos distintos, em que AVD é a classe de vegetação densa, AVA é a classe de vegetação arbustiva, AVR é a classe de vegetação rasteira e solo exposto, ACO é a classe de áreas construídas e ACA é a classe de corpos d'água.

A matriz de transição permite uma avaliação mais detalhada sobre a mudança da cobertura do solo através dos cruzamentos de dois mapas de classificação da cobertura do solo em momentos diferentes (ALVES et al., 2018). Através da matriz de transição podemos observar as áreas que persistiram entre os anos analisados (diagonal sombreada) e as áreas que se modificaram em outras coberturas através das perdas e ganhos em hectares (ALVES et al., 2018).

3.7 CORREÇÃO DA TEMPERATURA DA SUPERFÍCIE

A correção da temperatura de brilho em temperatura da superfície foi realizada utilizando o modelo *sigle-channel* (SC) proposto por Jiménez-Muñoz e Sobrino (2003) e adaptado para as bandas termais dos sensores TM e TIRS por Sobrino et al. (2004) e Jiménez-Muñoz et al. (2014), respectivamente. O modelo SC (Equação 9) recupera a radiação termal atenuada pelos constituintes atmosféricos através de funções atmosféricas obtidas por simulações de diferentes perfis atmosféricos (JIMÉNEZ-MUÑOZ E SOBRINO, 2003).

$$T_{SSC} = \gamma \left[\frac{1}{\varepsilon_{sup}} (\psi_1 L_{sen} + \psi_2) + \psi_3 \right] + \delta \quad \text{Eq. (9)}$$

em que γ e δ são parâmetros de aproximação da função de Planck, ψ_1, ψ_2 e ψ_3 são parâmetros atmosféricos obtidos a partir do conteúdo de vapor d'água na atmosfera (w g/cm³). Para a banda termal do sensor TM (TM6) abordo do satélite Landsat-5 $\gamma, \delta, \psi_1, \psi_2$ e ψ_3 podem ser obtidos pelas seguintes equações.

$$\gamma \approx \left\{ \frac{c_2 L_{sen}}{T_{sen}^2} \left[\frac{\lambda^4 L_{sen}}{c_1} + \frac{1}{\lambda} \right] \right\}^{-1} \quad \text{Eq. (10)}$$

$$\delta \approx -\gamma L_{sen} + T_{sen} \quad \text{Eq. (11)}$$

$$\psi_1 = 0,14714 w^2 - 0,15583 w + 1,1234 \quad \text{Eq. (12)}$$

$$\psi_2 = -1,1835 w^2 - 0,37607 w - 0,52894 \quad \text{Eq. (13)}$$

$$\psi_3 = 0,04554 w^2 + 1,8719 w - 0,39071 \quad \text{Eq. (14)}$$

em que L_{sen} é a radiância termal ao nível do sensor ($\text{W m}^{-2} \text{sr}^{-1} \mu\text{m}^{-1}$), T_{sen} é a temperatura de brilho (K), $c_1 (1,19104 \times 10^8 \text{ W } \mu\text{m}^4 \text{ m}^{-2} \text{sr}^{-1})$ e $c_2 (1,4387 \times 10^4 \mu\text{m K})$ são constantes de radiação de Planck, λ é o comprimento de onda efetivo da banda termal ($11,457 \mu\text{m}$ para banda termal do TM). w é o conteúdo de vapor d'água da atmosfera (g/cm^3) obtido pela equação 15 (YANG e QIU, 1996).

$$w = 0,0981 \times \left\{ 10 \times 0,6108 \times \exp \left[\frac{17,27 \times (t_0 - 273,15)}{237,3 + (t_0 - 273,15)} \right] \times UR \right\} + 0,1697 \quad \text{Eq. (15)}$$

em que t_0 é a temperatura do ar próxima a superfície (K), UR é a umidade relativa (%). Para a banda termal 1 do sensor TIRS (TIRS-1) abordo do satélite Landsat-8 $\gamma, \delta, \psi_1, \psi_2$ e ψ_3 podem ser obtidos pelas seguintes equações:

$$\gamma \approx \frac{T_{sen}^2}{b_\gamma L_{sen}} \quad \text{Eq. (16)}$$

$$\delta \approx T_{sen} - \frac{T_{sen}^2}{b_\gamma} \quad \text{Eq. (17)}$$

$$\psi_1 = 0,04019 w^2 + 0,02916 w + 1,01523 \quad \text{Eq. (18)}$$

$$\psi_2 = -0,38333 w^2 - 1,50294 w + 0,20324 \quad \text{Eq. (19)}$$

$$\psi_3 = 0,0918 w^2 + 1,36072 w - 0,27514 \quad \text{Eq. (20)}$$

em que b_γ é uma constante resultante da relação $\frac{c_2}{\lambda} = 1324$ para TIRS-1 abordo do Landsat-8.

A emissividade da superfície ε_{sup} foi estimada a partir da fração de cobertura vegetal (FVC) e das emissividades típicas de solos exposto e de vegetação para os sensores TM e TIRS-1 (SKOKOVIC et al., 2014).

$$\varepsilon_{sup} = \varepsilon_s (1 - FVC) + \varepsilon_v FVC \quad \text{Eq. (21)}$$

em que ε_s é a emissividade típica de solo exposto com valores de 0,960 para o TM e 0,971 para o TIRS-1, ε_v é a emissividade típica da vegetação com valores de 0,985 para o TM e 0,987 para o TIRS-1 (VALOR e CASELLES, 1996; SKOKOVIC et al., 2014) e FVC é a fração de cobertura vegetal obtida pela seguinte equação:

$$FVC = \left(\frac{NDVI - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \right)^2 \quad \text{Eq. (22)}$$

em que NDVI é o índice de vegetação por diferença normalizada, $NDVI_{min}$ é o NDVI mínimo e $NDVI_{max}$ é o NDVI máximo. Os valores mínimos e máximos foram extraídos dos histogramas das imagens de NDVI na área de estudo.

3.8 ESTIMATIVA DO BALANÇO DE RADIAÇÃO E ENERGIA PELO ALGORITMO SEBAL

3.8.1 Estimativa do Balanço de Radiação da superfície

O balanço de radiação da superfície também conhecido como saldo de radiação da superfície (R_n ; $W m^{-2}$) foi obtido através da relação dos balanços de ondas curtas e de longas na superfície terrestre.

$$R_n = R_{s\downarrow} (1 - \alpha_{sup}) + R_{L\downarrow} - R_{L\uparrow} - (1 - \varepsilon_{sup}) R_{L\downarrow} \quad \text{Eq. (23)}$$

em que $R_{s\downarrow}$ é a radiação de onda curta incidente medida ($W m^{-2}$), α_{sup} é o albedo da superfície de cada pixel, $R_{L\downarrow}$ é a radiação de onda longa emitida pela atmosfera na direção de cada pixel ($W m^{-2}$), $R_{L\uparrow}$ é a radiação de onda longa emitida por cada pixel ($W m^{-2}$) e ε_{sup} é a emissividade de cada pixel obtido anteriormente.

Os cálculos das $R_{L\uparrow}$ e $R_{L\downarrow}$ foram realizados utilizando a equação de Stefan-Boltzman (ALLEN et al., 2002).

$$R_{L\uparrow} = \varepsilon_{sup} \cdot \sigma \cdot T_s^4 \quad \text{Eq. (24)}$$

$$R_{L\downarrow} = \varepsilon_{atm} \cdot \sigma \cdot T_0^4 \quad \text{Eq. (25)}$$

$$\varepsilon_{atm} = 0,625 \left(\frac{1000 e_a}{273.15 + T_0} \right)^{0,131} \quad \text{Eq. (26)}$$

em que ε_{sup} e ε_{atm} são as emissividades da superfície e da atmosfera, σ é a constante de Stefan-Boltzman ($\sigma = 5,67 \cdot 10^{-8} \text{Wm}^{-2}\text{K}^{-4}$), T_s é a temperatura da superfície (K) e T_0 é a temperatura aproximada da atmosfera (K).

Os albedos da superfície (α_{sup}) utilizados para resolução da equação 23 foram obtidos a partir do modelo convencional (ZHONG e LI, 1988; SILVA et al., 2016).

$$\alpha_{sup} = \frac{(\alpha_{toa} - \alpha_{atm})}{\tau_{oc}^2} \quad \text{Eq. (27)}$$

em que α_{atm} é o albedo da atmosfera que pode ser obtido através de modelos de transferência radiativo, em que usualmente utilizam-se constantes entre 0,025 a 0,040 (ALLEN et al., 2013 SILVA et al., 2016), nesse estudo, foi adotado o valor de 0,03. O α_{toa} é o albedo no topo da atmosfera e τ_{oc} é a transmitância atmosférica para radiação de ondas curtas (Equação 31; ALLEN et al., 2007). Para o sensor TM e OLI α_{toa} pode ser obtida a partir das seguintes equações, respectivamente:

$$\alpha_{toa \text{ lt05}} = 0,293\rho_{1toa} + 0,274\rho_{2toa} + 0,233\rho_{3toa} + 0,157\rho_{4toa} + 0,033\rho_{6toa} + 0,011\rho_{7toa} \quad \text{Eq. (28)}$$

$$\alpha_{toa \text{ lt08}} = 0,300\rho_{2toa} + 0,277\rho_{3toa} + 0,233\rho_{4toa} + 0,143\rho_{5toa} + 0,036\rho_{6toa} + 0,012\rho_{7toa} \quad \text{Eq. (29)}$$

em que $\rho_{1toa} \dots \rho_{7toa}$ são as refletâncias do topo da atmosfera das bandas dos sensores TM e OLI, respectivamente. Os pesos das Equações 28 e 29 foram definidos por Allen et al., (2002) e Silva et al., (2016) e podem ser obtidos pela razão entre a constante solar de uma banda i e a soma de todos os valores de constante solar das bandas usados no cálculo do albedo.

$$\tau_{oc} = 0,35 + 0,627 \exp \left[- \frac{0,00146P_o}{K_t \cos Z} - 0,75 \left(\frac{W}{\cos Z} \right)^{0,4} \right] \quad \text{Eq. (30)}$$

$$W = 0,14 e_a P_o + 2.1 \quad \text{Eq. (31)}$$

em que P_o é a pressão atmosfera local (kPa), K_t é o coeficiente de turbidez da atmosfera = 0,65 para céu limpo ($K_t = 1$ para céu totalmente limpo e $K_t = 0,5$ para céu parcialmente nublado) e W é a água precipitável (mm) obtida pela pressão atual de vapor d'água (e_a ; kPa).

3.8.2 Estimativa do Balanço de Energia pelo algoritmo SEBAL

O Balanço de energia representa o particionamento da energia líquida disponível na superfície (R_n) em processos de aquecimentos do ar, do solo e na mudança de estado da água (ALLEN et al., 2002). Nesse sentido, o SEBAL faz o particionamento do R_n a partir das estimativas das densidades de fluxos de calor sensível (H) e do solo (G), resultando como residual a densidade de fluxo de calor latente (LE):

$$LE = Rn - H - G \quad \text{Eq. (32)}$$

em que LE é o fluxo de calor latente (W m^{-2}), Rn é o saldo de radiação (W m^{-2}), H é o fluxo de calor sensível (W m^{-2}) e G é o fluxo de calor no solo (W m^{-2}). A estimativa do G foi realizada a partir do modelo proposto por Bastiaanse, (2000):

$$G = \left[\frac{T_s}{\alpha_{sup}} (0,0038 \alpha_{sup} + 0,0074 \alpha_{sup}^2) (1 - 0,98 NDVI^4) \right] Rn \quad \text{Eq. (33)}$$

em que T_s é temperatura de superfície (K) α_{sup} é albedo de superfície, NDVI é índice de vegetação por diferença normalizada e Rn é o saldo de radiação (W m^{-2}).

A estimativa do H representa o ponto central dentro do algoritmo SEBAL. A obtenção desse parâmetro foi realizada a partir de uma adaptação da equação aerodinâmica, onde a resolução do Δ Temperatura é obtida a partir de uma relação linear entre T_s e dois coeficientes:

$$H = \rho_a c_p \frac{(a + bT_s)}{r_{ah}} \quad \text{Eq. (34)}$$

em que ρ_a é a massa específica do ar (kg m^{-3}), c_p é o calor específico do ar a pressão constante ($1004 \text{ J kg}^{-1} \text{ K}^{-1}$), $a + bT_s$ representa a diferença de temperatura próximo a superfície (K), r_{ah} é a resistência aerodinâmica ao transporte de calor sensível (s m^{-1}) entre duas alturas ($z_1 = 0,1 \text{ m}$ e $z_2 = 2,0 \text{ m}$).

A determinação dos coeficientes a e b foi realizada através da escolha de dois pixels de referência denominado de pixels “âncoras” (BASTIAANSEEN 1998; ALLEN et al., 2002). Os pixels “âncoras” representam áreas ou usos do solo em condições de extremos no balanço de energia. Nesse sentido, denomina-se de “pixels frios” superfícies com H baixos, como por exemplo, corpos d’água, uma cultura bem irrigada ou uma área de vegetação densa. Os “pixels quentes” representam superfícies com LE baixos, como por exemplo, uma superfície onde a restrição de água é severa, como solos expostos (BASTIAANSEEN et al., 1998; ALLEN et al., 2002).

Dessa maneira, podemos reescrever a equação 34 para os pixels “âncoras” da seguinte maneira:

$$Rn_{quente} - G_{quente} = \rho_a c_p \frac{(a + bT_{s_{quente}})}{r_{ah}} \quad \text{Eq. (35)}$$

$$Rn_{frio} - G_{frio} = \rho_a c_p \frac{(a + bT_{s_{frio}})}{r_{ah}} \quad \text{Eq. (36)}$$

Dessa maneira, temos um sistema de equações onde é possível obter os coeficientes a e b através de uma reestruturação algébrica. A r_{ah} foi obtida em função da velocidade de fricção e sua aplicação é realizada após um processo iterativo de correção baseado funções atmosféricas de estabilidade (BASTIAANSEN et al. 1998). Inicialmente a r_{ah} é obtida pela equação (34):

$$r_{ah} = \frac{\ln\left(\frac{z_2}{z_1}\right)}{u_* \cdot k} \quad \text{Eq. (37)}$$

em que u_* é a velocidade de fricção (s m^{-1}), k é a constante de von Karman (0,41). Para se calcular a u_* é necessário definir o coeficiente de rugosidade ao transporte de momentum (z_{om}) dado em função do SAVI (*Soil Adjusted Vegetation Index*) segunda a equação (35) de Bastiaanssen (2000).

$$z_{om} = \exp(-5,809 + 5,62\text{SAVI}) \quad \text{Eq. (38)}$$

em que SAVI é o índice de vegetação ajustado aos efeitos do solo que tenta reduzir os efeitos de fundo no solo. A u_* foi calculada utilizando um perfil logaritmo do vento com a atmosfera em condição neutralidade:

$$u_* = \frac{ku_{200}}{\ln\left(\frac{200}{z_{om}}\right)} \quad \text{Eq. (39)}$$

em que u_{200} é a velocidade do vento na altura de 200 metros (m s^{-1}), onde o efeito da rugosidade da superfície não influencia a velocidade do vento, z_{0m} é o coeficiente de rugosidade estimado na etapa anterior. Nesse sentido, u_{200} foi calculado utilizando a seguinte equação:

$$u_{200} = u^* \frac{\ln\left(\frac{200}{z_{0m_e}}\right)}{k} \quad \text{Eq. (40)}$$

em que u^* é a velocidade de fricção próximo a superfície (s m^{-1}) obtida na equação (38), z_{0m_e} é o coeficiente de rugosidade ao transporte de momentum próximo da estação ($z_{0m_e} = 0,12h$, onde h é a altura da vegetação).

$$u^* = \frac{k u}{\ln\left(\frac{10}{z_{0m_e}}\right)} \quad \text{Eq. (41)}$$

em que u é a velocidade do vento medida na estação micrometeorológica (m s^{-1}).

O fluxo de calor sensível (H) calculado para cada pixel usando as equações anteriormente descritas foram obtidos considerando a condição atmosférica neutra. Como consequência, as estimativas de u_* e r_{ah} inicialmente calculadas podem não estar adequadas devido as condições atmosféricas (ALLEN et al., 2002). Nesse sentido, u_* e r_{ah} foram recalculados através de um processo iterativo utilizando funções atmosféricas (BASTIAANSEN et al., 1998; ALLEN et al., 2002):

$$u_* = \frac{u_{200}k}{\ln\left(\frac{200}{z_{0m}}\right) - \psi_{m(200m)}} \quad \text{Eq. (42)}$$

$$r_{ah} = \frac{\ln\left(\frac{z_2}{z_1}\right) - \psi_{h(z_2)} + \psi_{h(z_1)}}{u_* k} \quad \text{Eq. (43)}$$

em que $\psi_{m(200m)}$ é a função de correções de estabilidade para o momento a 200 metros. $\psi_{h(z)}$ são as funções para correções de estabilidade para o transporte de calor sensível nas alturas z . As funções atmosféricas são obtidas a partir do comprimento de Monin-Obukhov que em um processo iterativo recalcula os parâmetros u_* e r_{ah} até estabilidade para posterior aplicação na estimativa de H final (ALLEN et al., 2002; BASTIAANSEN et al., 2005).

A estimativa do H final possibilita a resolução da equação 29 e o computo do LE , o que permite o cálculo da evapotranspiração diária (ET) através da fração evaporativa instantânea (FE_i) e do Rn diário (Rn_{24h}) (BASTIAANSEN, 2005):

$$ET = \frac{(86400 \times FE_i \times Rn_{24h})}{\lambda_v} \quad \text{Eq. (44)}$$

em que λ_v é a calor latente de vaporização (J kg^{-1}), FE_i é evaporativa instantânea e Rn_{24h} é o saldo de radiação diário (W m^{-2}). A FE_i foi obtida a partir dos componentes do balanço de energia. Dessa maneira, assumindo-se que a FE_i é similar a fração evaporativa diária, logo:

$$FE_i = \left(\frac{LE}{Rn - G} \right) = FE_{24h} = \frac{LE_{24h}}{Rn_{24h}} \quad \text{Eq. (45)}$$

em que FE_{24h} é a fração evaporativa diária, a qual foi igualada à FE_i , LE_{24h} é a densidade de fluxo de calor latente diário (W m^{-2}) e Rn_{24h} é o saldo de radiação diário (W m^{-2}) obtida pela seguinte equação (PAVÃO et al., 2018):

$$Rn_{24h} = Rs_{24h}(1 - a_{sup}) - 63,4\tau_{24h} \quad \text{Eq. (46)}$$

em que Rs_{24h} é a radiação solar média de incidência diária (W m^{-2}) e τ_{24h} é a transmissividade diária da atmosfera para onde curta (ALLEN et al., 2002).

3.9 ANÁLISE DOS DADOS

3.9.1 Extração dos dados espaciais

A extração dos dados para análises estatísticas e construção das tabelas foi realizada a partir de pixels de áreas de referências. Essas áreas correspondem a locais em que a classificação da cobertura do solo foi bem-sucedida após a conferência manual dos pixels. Foram analisadas 50 áreas por uso do solo para cada ano, totalizando 250 pixels por ano.

3.9.2 Análises do perfil

A análise espacial dos índices espectrais e dos componentes do balanço de energia, foram avaliados através de dois perfis traçados nos sentidos Nordeste-Sudoeste (NE-SO) e Noroeste-Sudeste (NO-SE) para os anos de 1985 e 2017 (Figura 1). Os sentidos dos perfis foram escolhidos objetivando-se abranger os extremos do

perímetro urbano do Município. A partir dos dados correspondentes as áreas dos perfis foram calculadas as médias aritméticas e móveis dos parâmetros do NDVI, albedo e temperatura da superfície, saldo de radiação instantâneo, fluxos de calor sensível, latente, do solo e evapotranspiração diária.

3.9.3 Análises estatísticas

As médias e os intervalos de confiança ($\pm 95\%$) do NDVI, α_{sup} , T_s e dos componentes do balanço de energia foram calculadas pelo processo de reamostragem aleatória utilizando *bootstrapping* de 1000 iterações no Software R, a partir da extração de todos os valores dos pixels por cobertura do solo (EFRON e TIBSHIRANI, 1993). O intervalo de confiança é uma alternativa ao teste de hipóteses, por que ele fornece informações sobre a probabilidade do efeito do sinal (BERRY, 1986; GARDNER & ALTMAN, 1986; BRANDSTÄTTER & LINS, 1999).

O estabelecimento das classes e intervalos para construção dos mapas dos parâmetros avaliados foram estabelecidas utilizando a regra de Sturges (VIEIRA, 1991):

$$K = 1 + 3,322\log(n) \quad \text{Eq. (47)}$$

em que K corresponde ao número das classes e n a quantidade de dados.

4. RESULTADOS

4.1 VARIAÇÃO DA PRECIPITAÇÃO E DA TEMPERATURA

A precipitação anual acumulada de 1985, foi de 1202 mm, 17% menor que a normal climatológica de 1980 a 2010. A precipitação anual acumulada para 2017, foi de 1642 mm, 13% maior que a normal pluviométrica para Cuiabá – MT. Os valores apresentados indicam um volume maior de precipitação em 2017 em comparação a 1985 (Figura 5).

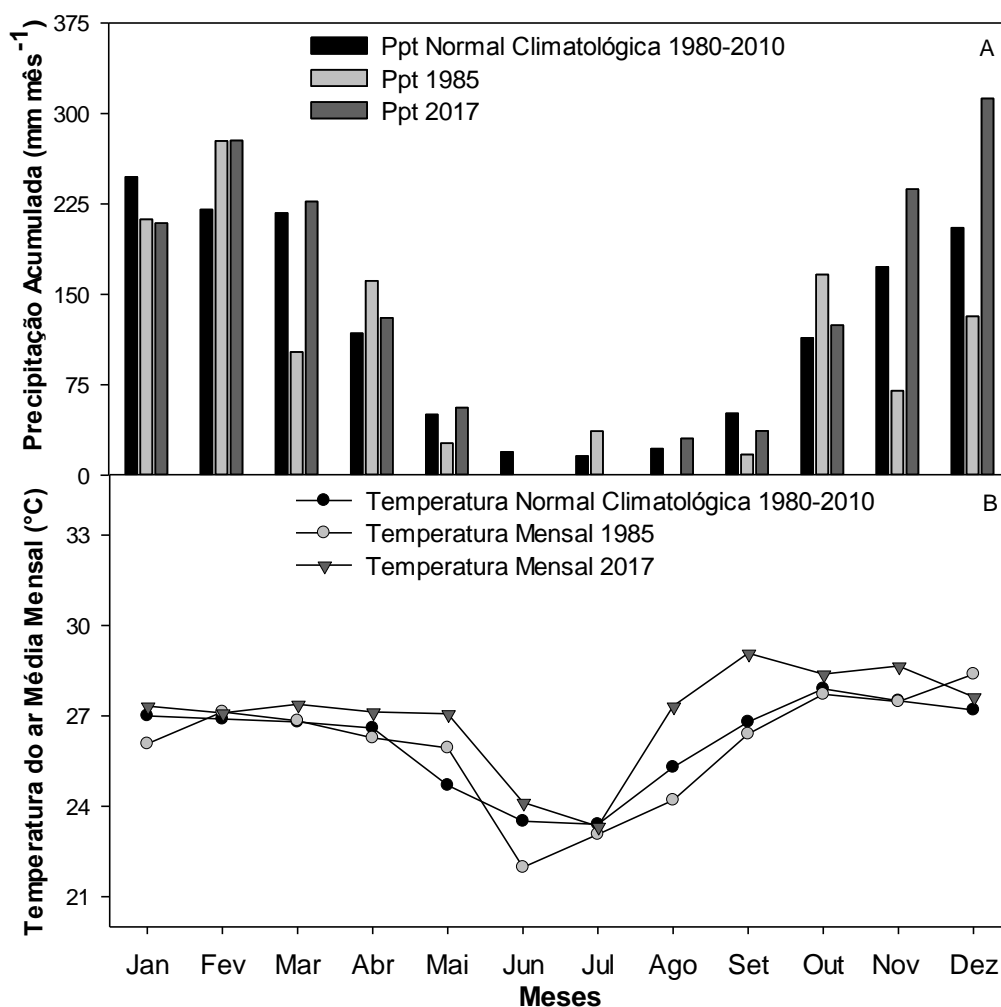


Figura 5 – Normal climatológica (1981-2010) e médias mensais de precipitação de 1985 e 2017 (A). Normal climatológica (1981-2010) e médias mensais de temperatura do ar de 1985 e 2017 (B) para o município de Cuiabá – MT.

Os meses que antecederam as datas das imagens, de janeiro a junho, dos anos de 1985 e 2017, apresentaram, respectivamente, um acúmulo de 780 mm e 900 mm de precipitação. Os meses de junho, julho e agosto apresentaram os menores valores de precipitação, corroborando com o padrão sazonal da região.

A temperatura do ar para os anos de estudo, apresentou um padrão semelhante ao da normal climatológica. A média anual da temperatura do ar em 2017, foi de 27,04°C, 4% maior que a média anual de 1985. Os menores valores de temperatura do ar ocorreram nos meses de junho e julho em 1985 e 2017. Os meses de agosto e setembro apresentaram em 1985, valores abaixo da normal climatológica e em 2017 valores acima da normal.

4.2 CLASSIFICAÇÃO DA COBERTURA DO SOLO

As regras e condições geradas a partir da interpretação visual das imagens permitiram definir cinco classes de cobertura do solo para Cuiabá – MT. São elas: áreas de vegetação densa (AVD), que apresentaram os maiores valores de NDVI, presentes em áreas remanescente, próximo a cursos d'água e parques urbanos; áreas de vegetação arbustiva (AVA), caracterizada como um vegetação esparsa de médio e pequeno porte presente na área urbana; áreas de vegetação rasteira e/ou solo exposto (AVR), composta por gramíneas associadas a solo exposto; áreas construídas (ACO), composta por áreas edificadas e estruturas impermeáveis; áreas cobertas com corpos d'água (ACA), que podem ser naturais ou artificiais (Tabela 9).

Tabela 9 - Regras e condições definidas para gerar a classificação de cobertura do solo para Cuiabá – MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água); NDVI (índice de vegetação por diferença normalizada); NDBI (índice de construções por diferença normalizada); NDBAI (Índice de aridez por diferença normalizada); NDWI (índice de água por diferença normalizada); MNDWI (índice de água por diferença normalizada modificado).

Classes	Regras	Condições
AVD	Vegetação densa em parques e matas ciliares	$NDVI \geq 0.5$; $0.197 \geq NDWI \geq -0.0$; $-0.3 \geq NDBaI \geq -0.48$; $-0.07 \geq NDBI \geq -0.19$
AVA	Vegetação esparsa de médio e pequeno porte, associadas a gramíneas	$0.49 \geq NDVI \geq 0.45$
AVR	Gramíneas associadas a solo exposto	$0.35 \geq NDVI \geq 0.05$; $MNDWI \leq -0.5$; $NDBaI \geq -0.3$
ACO	Construções, asfalto e concreto.	$0.32 \geq NDVI \geq 0.05$; $0.30 \geq NDBI \geq -0.25$; $-0.146 \geq NDBaI \geq -0.2$; $MNDWI \leq -0.05$
ACA	Corpos d'água: lagos e tanques de piscicultura	$MNDWI \geq -0.27$

As estimativas de precisão obtidas pelo processo de amostragem aleatória, apresentaram valores diferenciados para a classificação da cobertura do solo para os anos analisados. As estimativas de taxa de classificação correta apresentaram valores de confiabilidade acima de 0,91 para todas as classes, sugerindo excelente desempenho para classificação multiespectral proposta neste estudo. As classes AVR e ACO apresentaram os maiores valores para taxa de classificação incorreta, oscilando de 0,03 a 0,09 em comparação as outras classes (Tabela 10).

As estimativas de erro de omissão apresentaram os maiores valores para a classe AVR para os anos de estudo, chegando a 44% em 1985. Os maiores valores de erro de comissão foram apresentados em ACO, sendo os maiores erros apresentados em 1985. A acurácia do produtor apresentou valores satisfatórios, acima de 0,96, para as classes de AVD, AVA, ACO e ACA para os anos de estudo. Os menores valores foram identificados para AVR, apresentando 56% de acurácia para a classificação de 1985.

Tabela 10 - Estimativas de precisão da classificação da cobertura do solo para Cuiabá – MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água).

Estimativas	Classificação 1985					Classificação 2017				
	AVD	AVA	AVR	ACO	ACA	AVD	AVA	AVR	ACO	ACA
Classificação correta	1,00	1,00	0,91	0,91	1,00	1,00	0,99	0,96	0,97	0,98
Classificação incorreta	0,00	0,00	0,09	0,09	0,00	0,00	0,01	0,04	0,03	0,02
Erro de omissão	0,00	0,00	0,44	0,00	0,00	0,00	0,04	0,16	0,04	0,00
Erro de comissão	0,00	0,00	0,00	0,44	0,00	0,00	0,00	0,04	0,12	0,08
Acurácia do produtor	1,00	1,00	0,56	1,00	1,00	1,00	0,96	0,84	0,96	1,00
Acurácia do usuário	1,00	1,00	1,00	0,56	1,00	1,00	1,00	0,96	0,88	0,92
Kappa	1,00	1,00	0,76	0,67	1,00	1,00	0,98	0,88	0,90	0,95

A acurácia do usuário apresentou valores acima de 90% para AVD, AVA, AVR e ACA, indicando uma boa confiabilidade para classificação. Os menores valores de acurácia do usuário foram identificados em ACO, apresentando um percentual de 56% para a classificação de 1985. O coeficiente Kappa apresentou desempenho muito bom a excelente para classificação da cobertura do solo, com valores acima de 0,76, sendo que o menor valor foi identificado em ACO para classificação de 1985.

A classificação da cobertura do solo para 1985, apresentou 35% de AVD, 27% de AVA, 6% de AVR, 32% de ACO e 0,23% de ACA. De acordo com a classificação de 1985, 62% da área total da cidade era ocupado por áreas vegetadas. Por outro lado, a classificação para 2017 apresentou uma redução das áreas vegetadas, ocupando 55% da cidade.

A classificação para 2017, apresentou 34% de AVD, 21% de AVA, 1% de AVR, 44% de ACO e 0,34% de ACA. Sendo assim, observou-se que as áreas construídas (ACO) apresentaram um aumento em comparação a 1985, demonstrando a intensificação do processo de urbanização vivenciada nos últimos anos. As ACA apesar de representar um valor inexpressivo de cobertura em comparação as outras áreas, também apresentou um aumento de suas áreas em 2017.

As mudanças na cobertura do solo indicaram que as áreas de vegetação densa (AVD) e vegetação arbustiva (AVA) apresentaram uma redução de 27% de sua cobertura original de 1985 a 2017. A classe de AVR apresentou um redução significativa (83%) em relação as valores identificados em 1985, resultado da substituição da cobertura do solo original por outras classes em 2017. A classe de ACO apresentou um aumento de 39%, indicando um expressivo aumento de áreas urbanizadas de 1985 a 2017 para Cuiabá - MT. A classe de ACA apresentou um aumento de sua área em 49% de 1985 a 2017 (Tabela 11).

Tabela 11 - Dimensionamento das áreas de cobertura do solo em hectares (ha) para Cuiabá – MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água); LCC (mudança de cobertura da superfície).

Classes	1985 (ha)	2017 (ha)	LCC (ha)	LCC (%)
AVD	9088.0	8676.4	-411.7	-4.5
AVA	7052.0	5487.8	-1564.3	-22.2
AVR	1508.8	262.1	-1246.7	-82.6
ACO	8161.5	11354.9	3193.4	39.1
ACA	59.4	88.7	29.3	49.2

A distribuição espacial e os dados por região da cobertura do solo, demonstraram que 70% da região sul está coberta por áreas vegetadas, identificadas principalmente em áreas remanescentes e próximo a corpos d'água. A região oeste também apresentou expressiva concentração de áreas vegetadas em relação a sua área total, variando de 52% em 1985 a 47% em 2017. As regiões norte, leste e oeste apresentaram o maior percentual de ACO em relação a sua área total e o maior

crescimento urbano de 1985 a 2017, indicando a maior concentração urbana nessas regiões (Tabela 12 e Figura 6).

Tabela 12 - Dimensionamento das áreas de cobertura do solo em hectares (ha) por região para Cuiabá – MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água).

Classes	Classificação 1985 (ha)				Classificação 2017 (ha)			
	Região Norte	Região Sul	Região Leste	Região Oeste	Região Norte	Região Sul	Região Leste	Região Oeste
AVD	615,96	6018,57	1387,08	1035	679,23	5616,72	1031,85	1316,07
AVA	824,49	3744,72	1060,29	1412,01	468,54	3313,8	801,18	896,58
AVR	152,55	655,02	326,34	375,48	10,53	211,41	17,19	22,86
ACO	1503,09	3026,34	1841,76	1809,63	1944,99	4267,89	2764,8	2395,62
ACA	17,01	35,64	3,69	3,78	9,81	70,47	4,14	4,77
Área Total (ha)	3113,1	13480,29	4619,16	4635,9	3113,1	13480,29	4619,16	4635,9

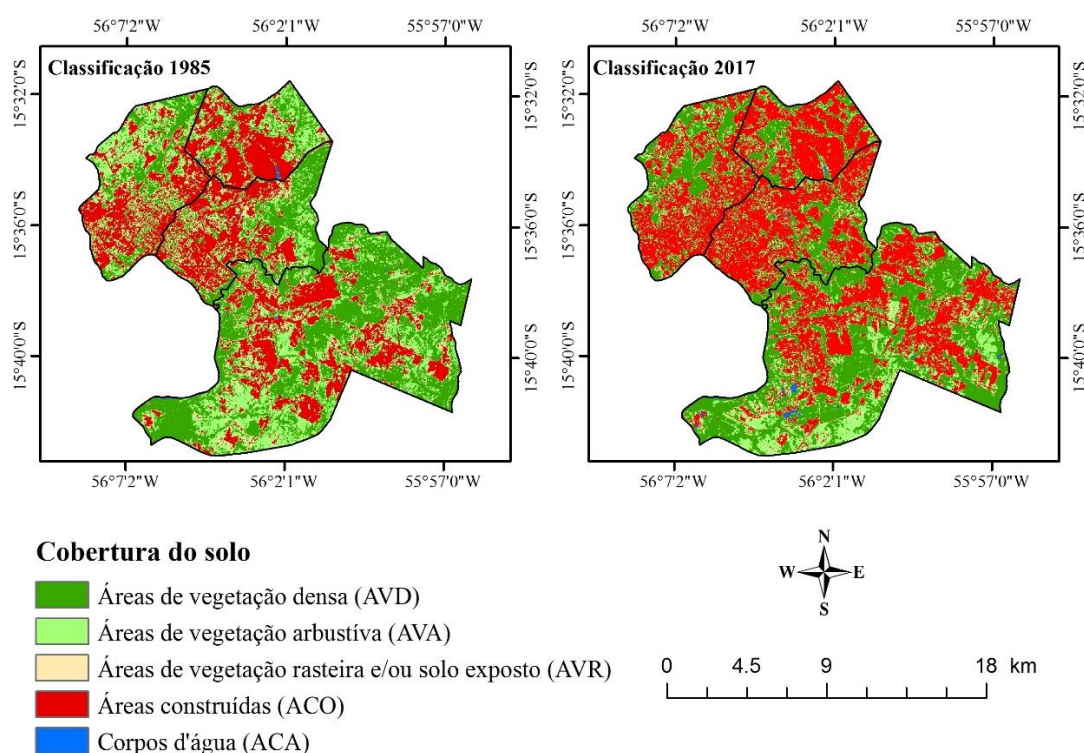


Figura 6 - Distribuição espacial das classes de cobertura do solo para Cuiabá - MT em 1985 e 2017.

As regiões norte e leste apresentaram as maiores concentrações de AVR em 1985, indicando a subtração de áreas vegetadas. No entanto, em 2017 a região sul apresentou maior concentração de AVR, sendo essas identificadas próximo as áreas

de expansão urbana. A maior concentração de ACA foi identificada na região sul para os anos de estudo, no entanto, foi a classe que apresentou menor expressão em comparação as outras classes.

4.3 CONVERSÃO DA COBERTURA DO SOLO

As áreas de vegetação densa (AVD) apresentaram uma redução de 45% de sua cobertura original de 1985 a 2017, sendo 18% convertido em áreas arbustivas (AVA), 1% em áreas de vegetação rasteira e/ou solo exposto (AVR) e 25% em áreas construídas (ACO) (Tabela 13). As áreas de vegetação arbustiva (AVA) apresentaram uma redução de 74% de sua cobertura original, sendo que 32% foram convertidas em AVD, 2% convertido em AVR e 40% em ACO.

Tabela 13 - Conversão da cobertura do solo em hectares (ha) para Cuiabá – MT de 1985 a 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água).

Classificação 1985	Classificação 2017					Total 1985 (ha)
	AVD	AVA	AVR	ACO	ACA	
AVD	5027,0	1635,9	82,4	2316,2	26,4	9088,0
AVA	2271,0	1858,0	96,0	2804,5	22,6	7052,0
AVR	305,4	398,2	21,2	781,7	2,3	1508,8
ACO	1054,2	1592,7	62,4	5443,7	8,5	8161,5
ACA	18,8	3,0	0	8,64	29,0	59,4
Total 2017 (ha)	8676,4	5487,8	262,1	11354,9	88,7	25869,7

As AVR apresentaram uma redução de 99% de sua cobertura original de 1985 a 2017, sendo que 20% foram convertidas em AVD, 26% em AVA e 52% em ACO. As ACO apresentaram uma redução de 33% de 1985 a 2017, sendo que 13% foram convertidas em AVD, 20% em AVA e 1% em AVR. As ACA apresentaram uma redução de 51% de 1985 a 2017, sendo 32% dessas áreas convertidas em AVD, 5% em AVA e 15% em ACO.

A distribuição espacial e os dados de alteração da cobertura do solo, indicaram que 62% da área total de Cuiabá – MT em 1985, era composta por áreas vegetadas (AVD e AVA) (Figura 7 e Tabela 14). Por outro lado, em 2017, houve uma redução de 36% dessas áreas, resultado dos maiores valores de perdas em relação ao número de ganhos de 1985 a 2017. As áreas vegetadas, apresentaram 26% de permanência no

arranjo da cidade para os anos de estudo, podendo ser identificadas em parques urbanos, nas proximidades de cursos d'água, em áreas remanescentes e de vegetação permanente.

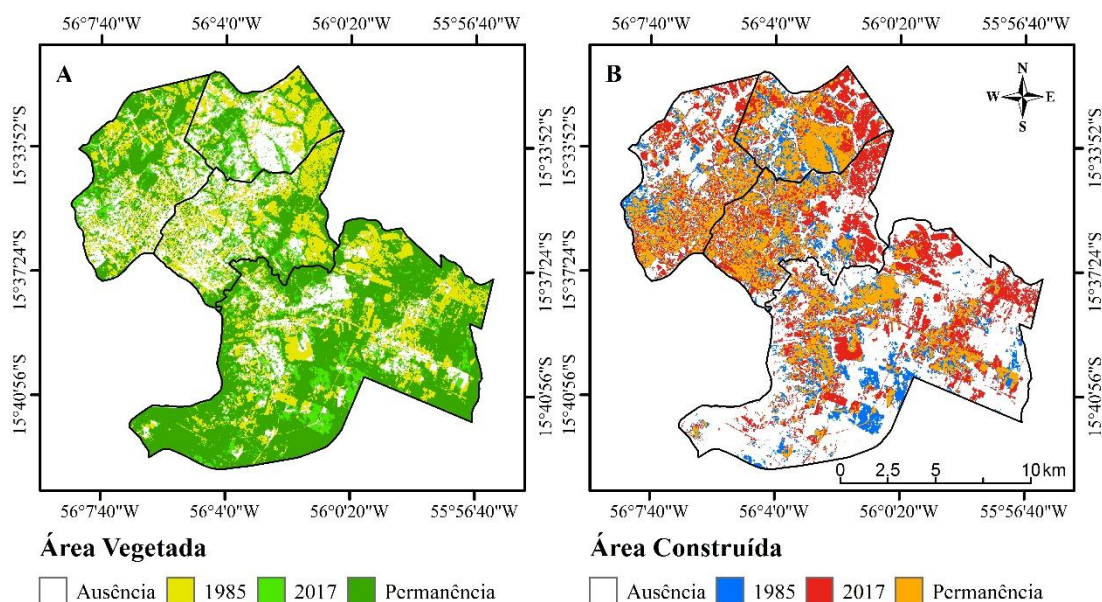


Figura 7 - Distribuição espacial somente das classes de áreas vegetadas (áreas de vegetação densa - AVD e áreas de vegetação arbustiva - AVA, em A) e construída (ACO, em B) para Cuiabá - MT em 1985 e 2017.

Tabela 14 - Permanência e alterações da cobertura do solo (perdas e ganhos) em hectares (ha) para Cuiabá – MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água).

Classes	Área total 1985	Área Total 2017	Permanência	Perda	Ganho
AVD	9088,0	8676,4	5027,0	4061,0	3649,3
AVA	7052,0	5487,8	1858,0	5194,1	3629,8
AVR	1508,8	262,1	21,2	1487,5	240,8
ACO	8161,5	11354,9	5443,7	2717,7	5911,1
ACA	59,4	88,7	29,0	30,4	59,7
Área Total (ha) = 25869,7					

As áreas construídas, apresentaram uma área total de 32% em 1985 e 44% em 2017 (Figura b e tabela). As áreas construídas apresentaram 23% de ganhos ao longo dos anos de estudo e 21% de permanência. Sendo assim, os resultados indicaram um expressivo avanço de áreas urbanizadas em Cuiabá – MT de 1985 a 2017.

A variação líquida do total de perdas e ganhos da cobertura do solo para Cuiabá – MT foi negativa para as áreas vegetadas, apresentado um saldo de -2% para áreas de

vegetação densa (AVD) e -6% para áreas de vegetação arbustiva (AVA). As áreas de vegetação rasteira e/ou solo exposto (AVR) também apresentaram um saldo negativo de -5% em relação a área total da cidade. Em contrapartida, áreas construídas (ACO) e de corpos d'água (ACA) apresentaram um saldo positivo, de 12% e 0,1%, respectivamente, de 1985 a 2017 (Tabela 15).

Tabela 15 - Perdas, ganhos, variação líquida, valor absoluto de troca e total de mudanças por cobertura do solo em hectares (ha) para Cuiabá – MT de 1985 a 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água).

Classes	Perda (ha)	Ganho (ha)	Variação líquida (ha)	Troca (ha)	Total de mudança (ha)
AVD	4061,0	3649,3	-411,7	7298,6	7710,3
AVA	5194,1	3629,8	-1564,3	7259,6	8823,9
AVR	1487,5	240,8	-1246,7	481,7	1728,4
ACO	2717,7	5911,1	3193,4	5435,5	8628,8
ACA	30,42	59,7	29,3	60,8	90,1
Área Total (ha) = 25869,7					

As áreas vegetadas apresentaram as maiores alterações da cobertura do solo em relação as outras classes de 1985 a 2017. As AVD e AVA apresentaram 56% no total de trocas e 64% no total de mudanças absolutas, representado pela soma das perdas e ganhos em relação a área total da cidade. No entanto, as AVA foram as que apresentaram o maior percentual de alterações, com a redução de 20% de sua cobertura original de 1985 a 2017.

As áreas construídas também indicaram elevado percentual de alteração da cobertura do solo, apresentando 21% no total de trocas e 33% no valor absoluto de mudanças. As AVR e ACA foram as classes que apresentaram o menor percentual de alterações da cobertura do solo, resultando em valores inexpressivos em relação as mudanças ocorridas nas outras classes.

4.4 DINÂMICA DOS PARÂMETROS DA SUPERFÍCIE

O NDVI se diferiu estatisticamente para todas as classes de cobertura do solo e apresentou uma redução dos valores nas áreas de referência analisadas em 1985 e 2017. As áreas vegetadas (AVD e AVA) apresentaram os maiores valores de NDVI para os anos de estudo e se diferiu estatisticamente de outras classes. Os menores

valores do NDVI foram identificados nas porções cobertas por água (naturais ou artificiais), seguido por AVR e ACO em 1985 e 2017 (Tabela 16).

Tabela 16 - Médias (\pm 95% IC) dos parâmetros de NDVI, α_{sup} e T_s da cobertura do solo de Cuiabá - MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água). NDVI (índice de vegetação por diferença normalizada), α_{sup} (albedo da superfície) e T_s (temperatura de superfície; °C).

		NDVI	α_{sup}	T_s (°C)
Classes 1985	AVD	0.60 \pm 0.0	0.18 \pm 0.0	26.1 \pm 0.8
	AVA	0.41 \pm 0.0	0.20 \pm 0.0	28.3 \pm 0.7
	AVR	0.34 \pm 0.0	0.23 \pm 0.0	29.3 \pm 1.0
	ACO	0.26 \pm 0.0	0.26 \pm 0.0	29.2 \pm 0.8
	ACA	-0.10 \pm 0.1	0.13 \pm 0.0	26.4 \pm 0.2
Classes 2017	AVD	0.59 \pm 0.1	0.21 \pm 0.0	31.4 \pm 0.9
	AVA	0.39 \pm 0.0	0.24 \pm 0.0	33.2 \pm 0.9
	AVR	0.33 \pm 0.0	0.30 \pm 0.0	33.6 \pm 0.8
	ACO	0.19 \pm 0.0	0.29 \pm 0.0	33.8 \pm 0.6
	ACA	-0.29 \pm 0.2	0.09 \pm 0.0	28.4 \pm 0.2

As classes de áreas vegetadas (AVD e AVA) e áreas antropizadas (AVR e ACO), apresentaram aumento nos valores de α_{sup} de 1985 a 2017, variando de 12% a 30%. As áreas cobertas por água (ACA) e as áreas vegetadas, apresentaram os menores valores de α_{sup} para os anos de estudo. Por outro lado, as áreas antropizadas apresentaram os maiores valores. No entanto, as AVR apresentaram o maior aumento (30%) do α_{sup} de 1985 a 2017 em comparação as outras classes.

A T_s apresentou aumento de seus valores em todas as classes analisadas de 1985 a 2017, variando de 8% a 20%. A média de T_s apresentou os menores valores em áreas vegetadas (AVD e AVA) e cobertas por água (ACA). Os maiores valores de T_s foram identificados em áreas antropizadas, ou seja, áreas cobertas por vegetação rasteira e/ou solo exposto (AVR) e áreas construídas (ACO) para os anos de estudo.

A distribuição espacial do NDVI a partir da classificação de Sturges apresentou a maior concentração de pixel (79%) entre 0,13 a 0,56 para os anos de estudo (Figura 8 e 9). Os maiores valores de NDVI (>0,47) foram observados em áreas vegetadas, tais como: parques urbanos, matas ciliares e remanescentes, identificada na classificação da cobertura do solo como AVD e AVA (Figura 6). Por outro lado, os menores valores de NDVI são identificados em áreas urbanizadas e em áreas cobertas por água.

A distribuição espacial do α_{sup} apresentou maior concentração de pixels (91%) entre 0,13 e 0,32 para os anos de estudo (Figura 10). Os maiores valores de α_{sup} são observados em áreas densamente urbanizadas, identificadas principalmente nas regiões norte e leste da cidade. Por outro lado, os menores valores são identificados em áreas vegetadas.

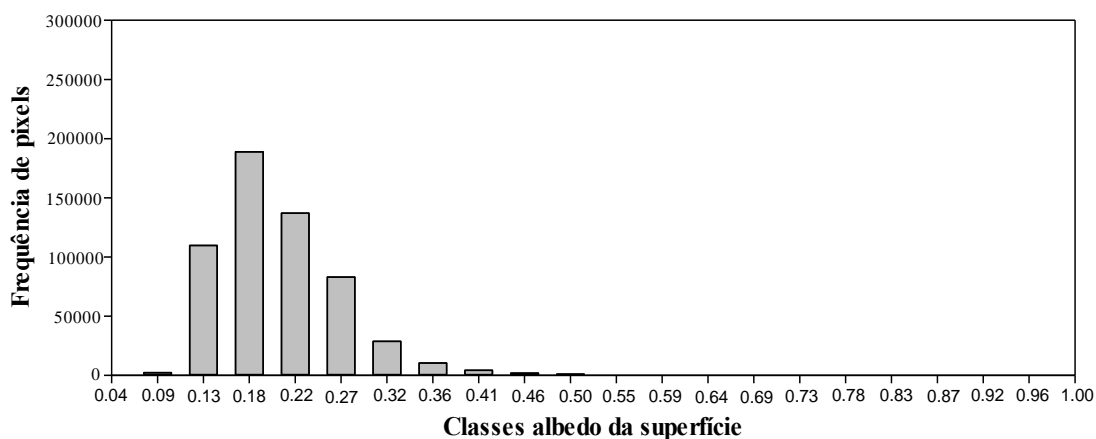


Figura 10 – Histograma do α_{sup} (albedo da superfície) para Cuiabá – MT em 1985 e 2017.

A distribuição espacial da T_s apresentou maior concentração de pixels (89%) entre 26,5°C e 34,8°C para os anos de estudo (Figura 11). Os maiores valores de T_s (> 31,3°C) foram identificados em áreas urbanizadas e em áreas cobertas por vegetação rasteira e/ou solo exposto (AVR), presentes principalmente nas regiões norte e leste da cidade em 1985 e 2017.




Figura 11 – Histograma da T_s (temperatura da superfície; °C) para Cuiabá – MT em 1985 e 2017.

Os menores valores de T_s ($< 27^\circ\text{C}$) foram identificados em áreas vegetadas, no entanto, pelo efeito da urbanização, essas áreas se tornaram inexpressivas em 2017. A distribuição espacial de 1985 e 2017, apresentou pontos da cidade com T_s acima de 35°C , identificados em áreas densamente urbanizadas e de vegetação rasteiras e/ou solo exposto (AVR). Em 2017, observa-se a expansão de áreas com T_s mais elevadas para todas as regiões da cidade.

4.5 AVALIAÇÃO DA DINÂMICA DOS COMPONENTES DO BALANÇO DE ENERGIA

O saldo de radiação instantâneo (Rn_{inst}) apresentou os maiores valores em áreas cobertas por água (ACA), seguido por áreas de vegetação densa (AVD) e áreas de vegetação arbustiva (AVA). Os menores valores do Rn_{inst} foram identificados em áreas de vegetação rasteira e/ou solo exposto (AVR) e em áreas construídas (ACO) em 1985 e 2017. Os resultados apresentaram uma redução nos valores do Rn_{inst} de 1985 a 2017, para as classes de AVD, AVA, AVR e ACO (Tabela 17).

As áreas vegetadas (AVD e AVA) apresentaram redução de 11% a 15% e as áreas antropizadas (AVR e ACO) apresentaram redução de 14% a 19% nos valores do Rn_{inst} de 1985 a 2017. Por outro lado, as áreas cobertas por água (ACA) foram as únicas que apresentaram aumento nos valores do Rn_{inst} (3%) para os anos analisados neste estudo.

O fluxo de calor no solo (G) apresentou aumento nas classes de AVD, AVA, AVR e ACO para os anos de estudo. Os maiores valores foram identificados em áreas antropizadas (AVR e ACO). As ACO apresentaram 4% de aumento do G quando comparado os anos de estudo. Em contrapartida, os menores valores foram identificados em áreas vegetadas (AVD e AVA) e de corpos d'água em 1985 e 2017.

O fluxo de calor sensível (H) apresentou aumento em AVD, AVA, AVR e ACO para os anos de estudo. Os maiores valores foram identificados em áreas antropizadas (AVR e ACO), sendo que as ACO apresentaram um acréscimo de 11% de 1985 a 2017. Por outro lado, os menores valores do H foram identificados em ACA, seguido de áreas vegetadas (AVD e AVA) para os anos analisados neste estudo.

O fluxo de calor latente (LE) apresentou redução em AVD, AVA, AVR e ACO para os anos de estudo. Os maiores valores foram identificados em áreas vegetadas

(AVD e AVA) e áreas cobertas por água (ACA). Os menores valores foram identificados em áreas antropizadas (AVR e ACO), sendo que as AVR e ACO apresentaram redução de 46% e 41%, respectivamente, de 1985 a 2017.

Tabela 17 - Médias ($\pm 95\%$ IC) do Rn_{inst} , G , H , LE e ET_{24} para a cobertura do solo de Cuiabá - MT em 1985 e 2017. AVD (área de vegetação densa); AVA (área de vegetação arbustiva); AVR (área de vegetação rasteira e/ou solo exposto); ACO (áreas construídas); ACA (áreas de corpos d'água). Rn_{inst} (saldo de radiação instantâneo; W/m^2), G (fluxo de calor no solo; W/m^2), H (fluxo de calor sensível; W/m^2), LE (fluxo de calor latente; W/m^2) e ET_{24} (evapotranspiração diária; mm/dia).

		Rn_{inst}	G	H	LE	Rn_{inst}
Classes 1985	AVD	366.8 ± 8.5	44.2 ± 2.1	81.0 ± 11.79	241.6 ± 19.5	3.0 ± 0.2
	AVA	348.8 ± 6.6	50.4 ± 0.7	102.3 ± 12.4	196.1 ± 15.4	2.6 ± 0.2
	AVR	328.1 ± 8.9	51.6 ± 1.1	121.0 ± 17.0	155.4 ± 22.8	2.1 ± 0.3
	ACO	310.2 ± 10.5	51.2 ± 0.9	118.0 ± 14.8	141.0 ± 19.2	1.9 ± 0.2
	ACA	401.1 ± 2.1	49.8 ± 0.3	69.2 ± 3.9	282.2 ± 5.8	3.5 ± 0.1
Classes 2017	AVD	327.1 ± 13.8	47.0 ± 3.3	104.9 ± 8.9	196.8 ± 0.5	2.4 ± 0.3
	AVA	296.7 ± 11.7	53.0 ± 0.7	124.9 ± 10.0	118.6 ± 20.0	1.8 ± 0.3
	AVR	265.0 ± 11.1	52.1 ± 1.0	129.2 ± 10.3	83.8 ± 16.8	1.3 ± 0.2
	ACO	267.2 ± 10.8	53.2 ± 1.0	131.4 ± 7.5	82.8 ± 13.3	1.2 ± 0.2
	ACA	411.5 ± 2.9	49.0 ± 2.7	68.7 ± 2.2	293.8 ± 7.0	3.8 ± 0.1

A evapotranspiração diária (ET_{24}) apresentou redução em AVD, AVA, AVR e ACO para os anos de estudo. Os maiores valores foram identificados em áreas vegetadas e áreas cobertas por água em 1985 e 2017. Por outro lado, os menores valores foram identificados em áreas antropizadas. As AVR apresentaram uma redução de 38% e as ACO de 37% nos valores de ET_{24} quando comparado os anos de estudo.

A distribuição espacial do Rn_{inst} a partir da classificação de Sturges apresentou a maior concentração de pixel (77%) entre $275,4 W m^{-2}$ e $371,8 W m^{-2}$ para os anos de estudo (Figura 12 e 13). Os maiores valores do Rn_{inst} ($>339,7 W m^{-2}$) foram observados em áreas próximo aos cursos d'água e em áreas vegetadas, identificadas, principalmente, nas regiões sul e oeste da cidade. Por outro lado, a distribuição espacial do Rn_{inst} apresentou os menores valores em áreas densamente urbanizadas, sendo identificados pontos da cidade com valores abaixo de $211,1 W m^{-2}$.

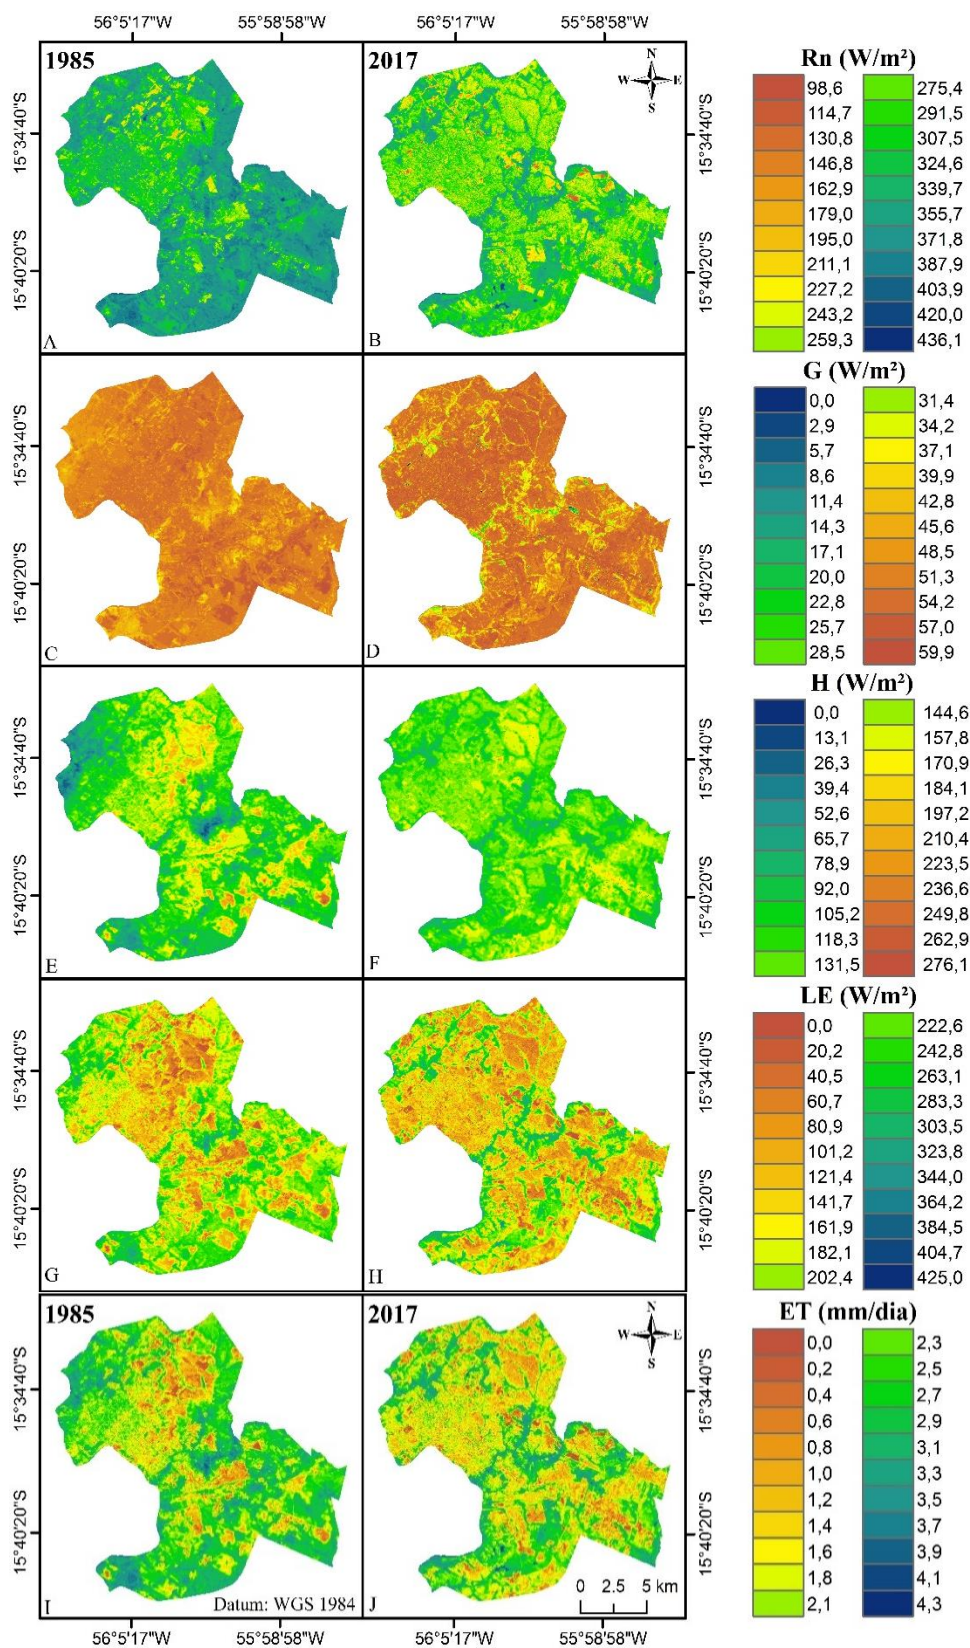


Figura 12 - Distribuição espacial do Rn_{inst} (saldo de radiação instantâneo) em W/m^2 de 1985 (A) e 2017 (B), G (fluxo de calor no solo; W/m^2) em 1985 (C) e 2017 (D), H (fluxo de calor sensível; W/m^2) de 1985 (E) e 2017 (F), LE (fluxo de calor latente;

W/m^2) de 1985 (G) e 2017 (H) e ET_{24} (evapotranspiração diária; mm/dia) de 1985 (I) e 2017 (J) para o perímetro urbano de Cuiabá – MT.




Figura 13 - Histograma do Rn_{inst} (saldo de radiação instantâneo; W/m^2) para Cuiabá – MT de 1985 e 2017.

O Rn_{inst} apresentou os menores valores em áreas de vegetação rasteira e/ou solo exposto (AVR), identificadas em áreas periféricas e de expansão urbana a partir da classificação da cobertura do solo para os anos de estudo. As áreas densamente urbanizadas, também apresentaram os menores valores de Rn_{inst} , identificadas principalmente nas regiões norte e leste da cidade em 1985 e 2017.

A distribuição espacial do G apresentou a maior concentração de pixel (85%) entre $45,6 W m^{-2}$ e $54,2 W m^{-2}$ para os anos de estudo (Figura 14). Os maiores valores do G foram observados em áreas antropizadas. A partir das imagens, foi possível observar que a expansão urbana identificada em 2017, influenciou diretamente no aumento de áreas com valores acima de $51,3 W m^{-2}$ para todas as regiões da cidade.

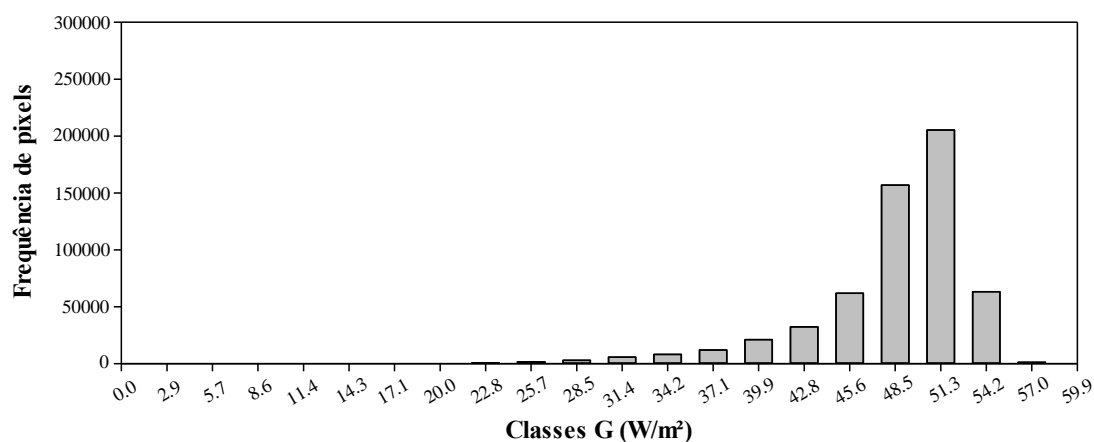


Figura 14 - Histograma do G (fluxo de calor no solo; W/m^2) para Cuiabá – MT de 1985 e 2017.

O G apresentou os menores valores próximo a cursos d'água e em áreas de vegetação remanescente, identificadas em áreas periféricas e de expansão urbana a partir da classificação da cobertura do solo realizada neste estudo. As regiões oeste e sul foram as apresentaram as áreas com os menores valores de G em comparação as outras regiões da cidade.

O fluxo de calor sensível (H) apresentou 85% da concentração de pixels entre $78,9 \text{ W m}^{-2}$ e $144,6 \text{ W m}^{-2}$ para os anos de estudo (Figura 15). A distribuição espacial do H apresentou valores mais elevados em 2017, distribuídos por todas as regiões da cidade em comparação a 1985. Os menores valores do $H (< 92,0 \text{ W m}^{-2})$ foram identificados em áreas próximo aos cursos d'água e em áreas de vegetação remanescentes, cobertura dominante nas regiões sul e oeste da cidade de acordo com a classificação da cobertura do solo.




Figura 1 - Histograma do H (fluxo de calor sensível; W/m^2) para Cuiabá – MT de 1985 e 2017.

O H apresentou os maiores valores em AVR, identificadas em áreas periféricas e de alterações antrópica para os anos de estudo. As áreas densamente urbanizadas e de circulação intensa de veículos, apresentaram os maiores valores de H em relação as outras classes, identificadas principalmente nas regiões norte e leste da cidade, com alguns pontos extremos na região sul com pouca ou nenhuma vegetação em 1985 e 2017.

O fluxo de calor latente (LE) apresentou 75% da concentração de pixels entre $60,7 \text{ W m}^{-2}$ e $222,6 \text{ W m}^{-2}$ de 1985 a 2017, demonstrando maior variabilidade dos dados em comparação as outras variáveis do balanço de energia (Figura 16). A distribuição espacial dos valores do LE de 2017, apresentou menores valores em todas

as regiões da cidade em comparação a 1985. Sendo assim, a expansão urbana identificada em 2017 a partir da classificação da cobertura do solo, afetou diretamente a distribuição espacial de LE em comparação a 1985.




Figura 16 - Histograma do LE (fluxo de calor latente; W/m^2) para Cuiabá – MT de 1985 e 2017.

Os maiores valores de LE ($>222,6 W m^{-2}$) foram identificados em áreas próximas aos cursos d'água e em áreas vegetadas, presentes principalmente nas regiões sul e oeste da cidade de acordo com a classificação da cobertura do solo apresentada neste estudo. O LE apresentou os menores valores em AVR, identificadas em áreas periféricas e de expansão urbana, presentes principalmente na região sul e em pontos isolados da cidade. As áreas densamente urbanizadas, também apresentaram os menores valores de LE identificadas principalmente nas regiões norte e leste, com alguns pontos extremos na região sul em 1985 e 2017.

A evapotranspiração diária (ET_{24}) apresentou 75% da concentração de pixels entre $1,2 W m^{-2}$ e $3,1 mm dia^{-1}$, demonstrando assim como LE maior variabilidade dos dados para os anos de estudo (Figura 17). As estimativas do ET_{24} em 2017, apresentaram menores valores em todas as regiões da cidade em comparação a 1985. A expansão urbana identificada em 2017, afetou diretamente a distribuição espacial de ET_{24} em comparação a 1985.




Figura 17 - Histograma do ET_{24} (evapotranspiração diária; mm/dia) para Cuiabá – MT de 1985 e 2017.

Os maiores valores de ET_{24} foram identificados em áreas próximo aos cursos d'água e em áreas vegetadas, cobertura dominante nas regiões sul e oeste da cidade, de acordo com a classificação da cobertura do solo em 1985 e 2017. O ET_{24} apresentou os menores valores em AVR, identificadas em áreas periféricas e alterações antrópicas, presentes principalmente na região sul e em pontos isolados da cidade. As áreas densamente urbanizadas, também apresentaram os menores valores de ET_{24} identificadas principalmente nas regiões norte e leste, com alguns pontos extremos na região sul da cidade com pouca ou nenhuma vegetação em 1985 e 2017.

4.6 ANÁLISE ESPACIAL DOS PERFIS

4.6.1 Perfil nordeste-sudoeste (NE-SO)

O perfil NE-SO passou por diferentes coberturas do solo em 1985 e 2017. O perfil do NDVI, apresentou 51% dos valores acima da média (0,38) em 1985, 47% dos valores acima da média (0,41) em 2017 e um aumento da média de 8% de 1985 a 2017 (Figura 18).




Figura 18 - Perfil NE-SO para as variáveis NDVI, α_{sup} e T_s para Cuiabá -MT com os dados de 1985 e 2017. Md.Mov. (média móvel), NDVI (Índice de vegetação por diferença normalizada), α_{sup} (albedo da superfície) e T_s (temperatura de superfície; °C).

As áreas de construídas e de expansão urbana, apresentaram os menores valores de NDVI em comparação ao mesmo trecho em 1985. As áreas de permanência

e expansão de vegetação nativa em 2017, tais como: áreas remanescentes e mata ciliares; apresentaram os maiores valores de NDVI em comparação a 1985.

O perfil do α_{sup} , apresentou 37% dos valores acima da média (0,22) em 1985, 51% dos valores acima da média (0,24) em 2017 e um aumento da média de 9% de 1985 a 2017. As áreas de expansão urbana, apresentaram os maiores valores de α_{sup} em comparação ao mesmo trecho em 1985. As áreas de permanência e expansão da vegetação nativa em 2017, apresentaram uma diminuição nos valores de α_{sup} em comparação a 1985.

O perfil da T_s , apresentou 41% dos valores acima da média (29.9°C) em 1985, 48% dos valores acima da média (33.1°C) em 2017 e um aumento da média de 11% de 1985 a 2017. As áreas de expansão urbana em 2017, apresentaram os maiores valores de T_s em comparação ao mesmo trecho em 1985. As áreas de permanência e de expansão de áreas vegetadas em 2017, apresentaram os menores valores de T_s .


O perfil NE-SO do saldo de radiação instantâneo (Rn_{inst}), apresentou 63% dos valores acima da média (327,4) em 1985, 48% dos valores acima a da média (297,5) em 2017 e uma redução da média de 9% de 1985 a 2017 (Figura 19). O perfil do Rn_{inst} apresentou os menores valores em áreas construídas e de vegetação rasteira e/ou solo exposto, sendo que os maiores valores foram identificados em áreas vegetadas para os anos de estudo.

O perfil do fluxo de calor no solo (G), apresentou 56% dos valores acima da média (51,0) em 1985, 68% dos valores acima a da média (50,3) em 2017 e uma redução da média de 1,4% de 1985 a 2017. O perfil do G apresentou os maiores valores em áreas construídas e de vegetação rasteira e/ou solo exposto, sendo que os menores valores foram identificados em áreas vegetadas para os anos de estudo.

O perfil do fluxo de calor sensível (H), apresentou 44% dos valores acima da média (131,2) em 1985, 47% dos valores acima a da média (123,8) em 2017 e uma redução da média de 6% de 1985 a 2017. O perfil do H apresentou os maiores valores em áreas construídas e de vegetação rasteira e/ou solo exposto, sendo que os menores valores foram identificados em áreas vegetadas para os anos de estudo.

O perfil do fluxo de calor latente (LE), apresentou 55% dos valores acima da média (162,4) em 1985, 50% dos valores acima a da média (129,2) em 2017 e uma redução da média de 20% de 1985 a 2017. O perfil do LE apresentou os menores

valores em áreas antropizadas (AVR e ACO), sendo que os maiores valores foram identificados em áreas vegetadas em 1985 e 2017.






Figura 19 - Perfil NE-SO para as variáveis Rn_{inst} , H , Le e ET_{24} para Cuiabá -MT com os dados de 1985 e 2017. Md.Mov. (média móvel), Rn_{inst} (saldo de radiação instantâneo; W/m^2), G (fluxo de calor no solo; W/m^2), H (fluxo de calor sensível; W/m^2), Le (fluxo de calor latente; W/m^2) e ET_{24} (evapotranspiração diária; mm/dia).

O perfil evapotranspiração diária (ET_{24}), apresentou 57% dos valores acima da média (2,17) em 1985, 53% dos valores acima a da média (1,84) em 2017 e uma redução da média de 15% de 1985 a 2017. O perfil da ET_{24} apresentou os menores valores em áreas construídas e de vegetação rasteira e/ou solo exposto, sendo que os maiores valores foram identificados em áreas vegetadas para os anos de estudo.

O perfil do NDVI para região norte, apresentou 65% dos valores acima da média (0,37) em 1985 e 15% dos valores acima da média (0,41) em 2017. O perfil do α_{sup} , apresentou 27% dos valores acima da média (0,22) em 1985 e 70% dos valores acima da média (0,24) em 2017. O perfil da T_s , apresentou 78% dos valores acima da média (29,9°C) em 1985 e 84% dos valores acima da média (33,1°C) em 2017.

O perfil NE-SO do Rn_{inst} para a região norte, apresentou 69% dos valores acima da média (327,4) em 1985 e 23% dos valores acima da média (297,5). O perfil

do G , apresentou 75% dos valores acima da média (51,0) em 1985 e 92% dos valores acima da média (50,3) em 2017.

O perfil do H , apresentou 72% dos valores acima da média (131,2) em 1985 e 83% dos valores acima da média (123,8) em 2017. O perfil do LE , apresentou 55% dos valores acima da média (145,9) em 1985 e 18% dos valores acima a da média (123,5) em 2017. O perfil da ET_{24} , apresentou 60% dos valores acima da média (1,97) em 1985 e 18% dos valores acima a da média (1,8) em 2017, indicando também a expansão de áreas urbanas neste recorte da cidade de 1985 a 2017.

O perfil do NDVI para região leste, apresentou 16% dos valores acima da média (0,37) em 1985 e 29% dos valores acima da média (0,41) em 2017. O perfil do α_{sup} , apresentou 69% dos valores acima da média (0,22) em 1985 e 68% dos valores acima da média (0,24) em 2017. O perfil da T_s , apresentou 89% dos valores acima da média (29,9°C) em 1985 e 76% dos valores acima da média (33,1°C) em 2017, indicando uma relação direta com os com os resultados do NDVI e uma ligeira expansão de áreas vegetadas neste recorte.

O perfil NE-SO do Rn_{inst} para a região leste, apresentou 27% dos valores acima da média (327,4) em 1985 e 27% dos valores acima da média (297,5). O perfil do G , apresentou 78% dos valores acima da média (51,0) em 1985 e 76% dos valores acima da média (50,3) em 2017.

O perfil do H , apresentou 89% dos valores acima da média (131,2) em 1985 e 74% dos valores acima da média (123,8) em 2017. O perfil do LE , apresentou 14% dos valores acima da média (145,9) em 1985 e 25% dos valores acima a da média (123,5) em 2017. O perfil da ET_{24} , apresentou 17% dos valores acima da média (1,97) em 1985 e 26% dos valores acima a da média (1,8) em 2017, indicando a predominância de áreas vegetadas neste recorte da cidade de 1985 a 2017.

O perfil do NDVI para região sul, apresentou 66% dos valores acima da média (0,37) em 1985 e 61% dos valores acima da média (0,41) em 2017. O perfil do α_{sup} , apresentou 32% dos valores acima da média (0,22) em 1985 e 41% dos valores acima da média (0,24) em 2017. O perfil da T_s , apresentou 26% dos valores acima da média (29,9°C) em 1985 e 31% dos valores acima da média (33,1°C) em 2017.

O perfil NE-SO do Rn_{inst} para a região sul, apresentou 71% dos valores acima da média (327,4) em 1985 e 61% dos valores acima da média (297,5). O perfil do G ,

apresentou 45% dos valores acima da média (51,0) em 1985 e 60% dos valores acima da média (50,3) em 2017.

O perfil do H , apresentou 24% dos valores acima da média (131,2) em 1985 e 29% dos valores acima da média (123,8) em 2017. O perfil do LE , apresentou 68% dos valores acima da média (145,9) em 1985 e 62% dos valores acima da média (123,5) em 2017. O perfil da ET_{24} , apresentou 62% dos valores acima da média (1,97) em 1985 e 70% dos valores acima da média (1,8) em 2017, indicando que mesmo com o avanço de áreas urbanizadas, ainda há a predominância de áreas vegetadas neste recorte da cidade.

4.6.2 Perfil noroeste-sudeste (NO-SE)

O perfil NO-SE perpassou por diferentes coberturas do solo em 1985 e 2017. O perfil do NDVI, apresentou 47% dos valores acima da média (0,37) em 1985, 43% dos valores acima da média (0,44) em 2017 e um aumento da média de 19% de 1985 a 2017 (Figura 20). As áreas de construídas e de expansão urbana, apresentaram os menores valores de NDVI em comparação ao mesmo trecho em 1985. As áreas de permanência e expansão de vegetação nativa em 2017, tais como: áreas remanescentes e mata ciliares; apresentaram os maiores valores de NDVI em comparação a 1985.

O perfil do α_{sup} , apresentou 45% dos valores acima da média (0,24) em 1985, 54% dos valores acima da média (0,23) em 2017 e uma redução da média de 4% de 1985 a 2017. As áreas de expansão urbana, apresentaram os maiores valores de α_{sup} em comparação ao mesmo trecho em 1985. As áreas de permanência e expansão da vegetação nativa em 2017, apresentaram uma diminuição nos valores de α_{sup} em comparação a 1985.

O perfil da T_s , apresentou 44% dos valores acima da média (28,5°C) em 1985, 44% dos valores acima da média (32,4°C) em 2017 e um aumento da média de 14% de 1985 a 2017. As áreas de expansão urbana em 2017, apresentaram os maiores valores de T_s em comparação ao mesmo trecho em 1985. As áreas de permanência e de expansão de áreas vegetadas em 2017, apresentaram os menores valores de T_s .





Figura 20 - Perfil NO-SE para as variáveis NDVI, α_{sup} e T_s para Cuiabá -MT com os dados de 1985 e 2017. Md.Mov. (média móvel), NDVI (Índice de vegetação por diferença normalizada), α_{sup} (albedo da superfície) e T_s (temperatura de superfície; °C).

O perfil NO-SE do saldo de radiação instantâneo (Rn_{inst}), apresentou 34% dos valores acima da média (326,5) em 1985, 37% dos valores acima a da média (304,9)

em 2017 e uma redução da média de 7% de 1985 a 2017 (Figura 21). O perfil do Rn_{inst} apresentou os menores valores em áreas construídas e de vegetação rasteira e/ou solo exposto, sendo que os maiores valores foram identificados em áreas vegetadas para os anos de estudo.






Figura 21 - Perfil NO-SO para as variáveis Rn_{inst} , H , Le e ET_{24} para Cuiabá -MT com os dados de 1985 e 2017. Md.Mov. (média móvel), Rn_{inst} (saldo de radiação instantâneo; W/m^2), G (fluxo de calor no solo; W/m^2) em W/m^2 , H (fluxo de calor sensível; W/m^2), Le (fluxo de calor latente; W/m^2) e ET_{24} (evapotranspiração diária; mm/dia).

O perfil do fluxo de calor sensível (G), apresentou 58% dos valores acima da média (49,4) em 1985, 66% dos valores acima a da média (48,7) em 2017 e uma redução da média de 1,4% de 1985 a 2017. O perfil do G apresentou os maiores valores em áreas construídas e de vegetação rasteira e/ou solo exposto, sendo que os menores valores foram identificados em áreas vegetadas para os anos de estudo.

O perfil do fluxo de calor sensível (H), apresentou 54% dos valores acima da média (107,9) em 1985, 58% dos valores acima a da média (116,1) em 2017 e um aumento da média de 8% de 1985 a 2017. O perfil do H apresentou os maiores valores em áreas construídas e de vegetação rasteira e/ou solo exposto, sendo que os menores valores foram identificados em áreas vegetadas para os anos de estudo.

O perfil do fluxo de calor latente (LE), apresentou 50% dos valores acima da média (171,6) em 1985, 41% dos valores acima a da média (141,2) em 2017 e uma redução da média de 18% de 1985 a 2017. O perfil do LE apresentou os menores valores em áreas antropizadas (AVR e ACO), sendo que os maiores valores foram identificados em áreas vegetadas em 1985 e 2017.

O perfil evapotranspiração diária (ET_{24}), apresentou 50% dos valores acima da média (2,3) em 1985, 36% dos valores acima a da média (2,0) em 2017 e uma redução da média de 13% de 1985 a 2017. O perfil da ET_{24} apresentou os menores valores em áreas construídas e de vegetação rasteira e/ou solo exposto, sendo que os maiores valores foram identificados em áreas vegetadas para os anos de estudo.

O perfil do NDVI para região oeste, apresentou 17% dos valores acima da média (0,37) em 1985 e 37% dos valores acima da média (0,42) em 2017. O perfil do α_{sup} , apresentou 80% dos valores acima da média (0,24) em 1985 e 62% dos valores acima da média (0,23) em 2017, indicando uma relação direta com os com os resultados do NDVI e uma ligeira expansão de áreas vegetadas neste recorte. O perfil da T_s , apresentou 35% dos valores acima da média (28,5°C) em 1985 e 64% dos valores acima da média (32,4°C) em 2017.

O perfil NO-SE do Rn_{inst} para a região oeste, apresentou 37% dos valores acima da média (326,5) em 1985 e 40% dos valores acima da média (304,9). O perfil do G , apresentou 51% dos valores acima da média (49,4) em 1985 e 77% dos valores acima da média (48,7) em 2017.

O perfil do H , apresentou 29% dos valores acima da média (107,9) em 1985 e 63% dos valores acima da média (116,1) em 2017. O perfil do LE , apresentou 53% dos valores acima da média (171,6) em 1985 e 37% dos valores acima a da média (141,2) em 2017. O perfil da ET_{24} , apresentou 50% dos valores acima da média (2,3) em 1985 e 40% dos valores acima a da média (2,0) em 2017, indicando também a expansão de áreas urbanas neste recorte da cidade de 1985 a 2017.

O perfil do NDVI para região leste, apresentou 22% dos valores acima da média (0,37) em 1985 e 7% dos valores acima da média (0,44) em 2017. O perfil do α_{sup} , apresentou 59% dos valores acima da média (0,24) em 1985 e 73% dos valores acima da média (0,23) em 2017, indicando uma relação direta com os com os resultados do NDVI e uma ligeira expansão de áreas vegetadas neste recorte. O perfil

da T_s , apresentou 100% dos valores acima da média (28,5°C) em 1985 e 95% dos valores acima da média (32,4°C) em 2017, indicando a relação do avanço de áreas urbanizadas nos valores da T_s .

O perfil NO-SE do Rn_{inst} para a região leste, apresentou 23% dos valores acima da média (326,5) em 1985 e 14% dos valores acima da média (304,9). O perfil do G , apresentou 88% dos valores acima da média (49,4) em 1985 e 90% dos valores acima da média (48,7) em 2017.

O perfil do H , apresentou 100% dos valores acima da média (107,9) em 1985 e 94% dos valores acima da média (116,1) em 2017. O perfil do LE , apresentou 5% dos valores acima da média (171,6) em 1985 e 6% dos valores acima da média (141,2) em 2017. O perfil da ET_{24} , apresentou 6% dos valores acima da média (2,3) em 1985 e 8% dos valores acima da média (2,0) em 2017, indicando poucas alterações na cobertura do solo neste recorte da cidade.

O perfil do NDVI para região sul, apresentou 67% dos valores acima da média (0,37) em 1985 e 58% dos valores acima da média (0,44) em 2017. O perfil do α_{sup} , apresentou 25% dos valores acima da média (0,24) em 1985 e 43% dos valores acima da média (0,23) em 2017, indicando uma relação direta com os resultados do NDVI e uma expansão de áreas urbanizadas neste recorte. O perfil da T_s , apresentou 48% dos valores acima da média (28,5°C) em 1985 e 49% dos valores acima da média (32,4°C) em 2017.

O perfil NO-SE do Rn_{inst} para a região sul, apresentou 58% dos valores acima da média (326,5) em 1985 e 46% dos valores acima da média (304,9). O perfil do G , apresentou 51% dos valores acima da média (49,4) em 1985 e 54% dos valores acima da média (48,7) em 2017.

O perfil do H , apresentou 46% dos valores acima da média (107,9) em 1985 e 49% dos valores acima da média (116,1) em 2017. O perfil do LE , apresentou 65% dos valores acima da média (171,6) em 1985 e 52% dos valores acima da média (141,2) em 2017. O perfil da ET_{24} , apresentou 66% dos valores acima da média (2,3) em 1985 e 54% dos valores acima da média (2,0) em 2017, demonstrando que mesmo com o avanço de áreas urbanizadas, ainda há a predominância de áreas vegetadas neste recorte da cidade.

4.7 CORRELOGRAMA E COEFICIENTE DE CORRELAÇÃO DAS VARIÁVEIS DOS PERFIS ESPACIAIS

O NDVI apresentou correlação negativa com o α_{sup} e a T_s . O α_{sup} apresentou forte correlação com o NDVI e a moderada com a T_s . O Rn_{inst} foi positivamente correlacionado com o NDVI e negativamente com o α_{sup} , no entanto, apresentou forte correlação entre as variáveis (Figura 22).

O G foi negativamente correlacionado com NDVI e Rn_{inst} e positivamente com α_{sup} e T_s , apresentando moderada correlação entre as variáveis. O H foi negativamente correlacionado com NDVI e Rn_{inst} e positivamente correlacionado com α_{sup} , T_s e G , apresentando correlação moderada a alta entre as variáveis. O LE e ET_{24} foram positivamente correlacionados com NDVI e Rn_{inst} , no entanto, apresentando correlação negativa com α_{sup} , T_s , G e H .

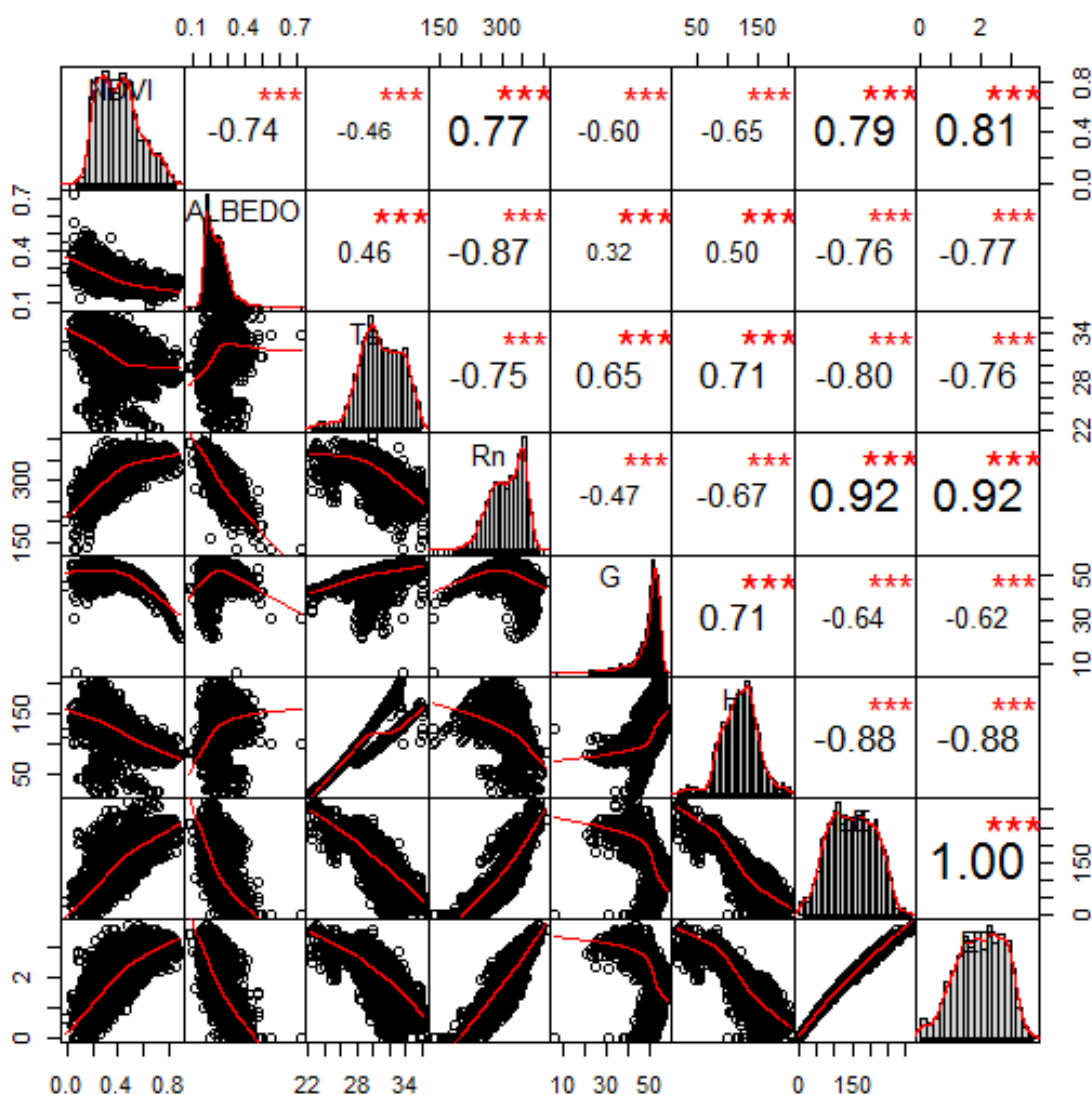


Figura 22 - Correlograma composto dos gráfico de dispersão, histogramas e coeficiente de correlação de Spearman para as variáveis: NDVI, α_{sup} , T_s , Rn_{inst} , G , H , LE e ET_{24} para Cuiabá -MT com os dados de 1985 e 2017. NDVI (Índice de vegetação por diferença normalizada); T_s (temperatura de superfície; °C); Rn_{inst} (saldo de radiação instantâneo; W/m²), G (fluxo de calor no solo; W/m²), H (fluxo de calor sensível; W/m²), LE (fluxo de calor latente; W/m²) e ET_{24} (evapotranspiração diária; mm/dia).

O LE indicou forte correlação com todas as variáveis analisadas. A ET_{24} apresentou o maior valor de correlação em relação as outras variáveis, sendo identificado 100% de correlação positiva entre a ET_{24} e o LE para os anos de estudo. O LE e a ET_{24} apresentou forte correlação com todas as variáveis analisadas neste estudo, sendo o menor valor identificado na relação com G .

5. DISCUSSÕES

5.1 VARIAÇÃO DA PRECIPITAÇÃO E DA TEMPERATURA

Os dados pluviométricos de Cuiabá – MT indicaram uma tendência sazonal típica, com verões chuvosos e invernos secos, para os anos de estudo (BIUDES et al., 2015; MACHADO et al., 2017). A variação anual da precipitação identificados neste estudo corrobora com os estudos de Machado et al. (2015) e Callejas et al. (2019) para mesma região. No entanto, a precipitação em 2017 apresentou, em média, valores acima da normal climatológica para a cidade de Cuiabá – MT.

Os maiores valores de temperatura do ar apresentados em 2017 em comparação a 1985, podem ser justificado pelo acelerado processo de urbanização ocorrido em Cuiabá – MT nos anos de estudo. As alterações térmicas ocorridas em áreas densamente urbanizadas são reflexo das propriedades físicas dos tecidos urbanos e da substituição de ambientes naturais por áreas construídas. Áreas antropizadas apresentam uma complexa troca de energia e maior capacidade de retenção de calor (CALLEJAS et al., 2019), resultando nos maiores valores de temperatura, que podem influenciar nas médias térmicas da cidade (WANG et al., 2015).

5.2 CLASSIFICAÇÃO DA COBERTURA DO SOLO

As estimativas gerais de confiabilidade da classificação da cobertura do solo em 1985 e 2017 para Cuiabá - MT, apresentaram excelentes resultados a partir do Kappa, indicando eficácia para utilização de imagens de satélite para classificação da cobertura do solo (LANDIS e KOCH, 1977; RAWANGA e NDAMBUKI, 2017). A metodologia de classificação da cobertura do solo utilizada neste estudo, apresentou resultados satisfatórios quando comparado as metodologias de classificação proposta por FU e WENG (2016), DA SILVA et al. (2019), ZHANG et al. (2020). Os resultados de precisão, apresentaram elevada confiabilidade para áreas vegetadas (AVD e AVA) e áreas cobertas por água, podendo ser justificado pela homogeneidade e continuidade espacial apresentada nestas superfícies em comparação as outras classes.

As ACO e AVR apresentaram a menor confiabilidade para a classificação da cobertura do solo, diante da complexidade dos arranjos que a compõe e de difícil detecção por sensores de média resolução espectral. As áreas antropizadas apresentam misturas e semelhanças espectrais, refletindo diretamente no algoritmo de decisão, que

resulta na sobreposição de classes e redução da confiabilidade da classificação (HU et al., 2016). Os menores valores de acurácia identificado em 1985, para AVR e ACO, pode ser justificado pela mistura de áreas edificadas com ruas não asfaltadas, terrenos com solo exposto e quintais com presença de vegetação dificultando a análise de decisão do algoritmo.

Além disso, o NDBaI, índice utilizado para identificação de áreas de solo exposto, foi criado por Chen et al. (2006) para identificação de áreas sem vegetação, claras e com baixo teor de umidade. No entanto, observa-se que a região sul da cidade apresentou áreas com maior teor de umidade e solos com coloração mais escura em comparação as áreas centrais. Sendo assim, a umidade do solo, bem como sua textura e coloração, podem ter influenciado nos erros de classificação.

Resultados semelhantes foram encontrados nos estudos de Sharma et al. (2013), Fu e Weng (2016), Rawanga e Ndambuki (2017), Da Silva et al. (2019), para classificação da cobertura do solo com sensores de média resolução espectral, onde os menores valores de acurácia são identificados em áreas antropizadas. De acordo com os estudos de Schultz et al. (2017), as classes de ACO e AVR, frequentemente confusas, que apresentam os maiores erros de omissão e comissão, poderiam ser agregadas para aumentar a precisão do mapa. A utilização de imagens de alta resolução, modelos baseados na lógica *fuzzy* (GOPAL et al., 2016; AMATO et al., 2018) e análise de misturas espectrais (HALABISKY et al., 2016; LIU et al., 2016) também se mostraram eficazes para minimização dos erros em métodos de classificação da cobertura do solo.

O dimensionamento das áreas vegetadas (AVD e AVA) a partir da classificação da cobertura do solo, apresentou redução de 1985 a 2017, o que pode ser explicado pela expansão das áreas construídas ocorrida nas últimas décadas. O estado de Mato Grosso de 1960 a 1990, passou por uma rápida expansão demográfica impulsionada pelos programas de desenvolvimento do agronegócio (ROMANCINI, 2011). O município de Cuiabá – MT torna-se um pólo de apoio aos intensos fluxos migratórios, resultando na expansão de loteamento periféricos, construção de novas áreas residenciais, comerciais e industriais ao longo da cidade (CUIABÁ, 2007; 2009).

A expansão urbana de Cuiabá – MT, ocorreu sem planejamento, a partir de aglomerações centrais, ocupações irregulares de áreas remanescentes e periféricas,

ignorando a Lei Orgânica Municipal de 1990 e o Plano Diretor de Desenvolvimento Urbano (CUIABÁ, 2009; SILVA e ROMERO, 2013). Sendo assim, diante da preocupação com a expansão urbana vivenciada nos últimos anos, diversos estudos vem sendo realizados na capital correlacionando os impactos socioambientais e as alterações no fluxo de energia com a substituição de áreas vegetadas por áreas impermeáveis e densamente urbanizadas (SILVA e ROMERO, 2008; MAITELLI, 2010; ZEILHOFER et al., 2010; CALLEJAS et al., 2011; SANTOS et al., 2013; SILVA e TARIFA, 2017; CALLEJAS et al., 2019).

A maior cobertura de áreas de vegetação rasteira e/ou solo exposto foi identificada em 1985, resultado da criação dos loteamentos habitacionais a partir da década de 1980 para atender o crescimento demográfico (CUIABÁ, 2008). A expansão fragmentada da cidade e o desmatamento indiscriminado de áreas vegetadas, começou a ocorrer sem que houvesse regras urbanísticas que orientasse o surgimento desses assentamentos e incorporação de áreas vazias de fins especulativos ao longo da cidade (SIQUEIRA e VILARINHO NETO, 2012; OLIVEIRA et al., 2018). As AVR apresentaram uma redução em 2017, resultante da substituição por ACO para atender as necessidades urbanas identificadas nos anos de estudo (SILVA e ROMERO, 2013).

A expansão de áreas cobertas por água de 1985 a 2017, pode ser justificado pelo crescimento da piscicultura no estado de Mato Grosso, sendo o terceiro maior produtor nacional e o maior produtor da região Centro-Oeste (IMEA, 2014). A partir da Lei Estadual n° 8.684, o Governo Estadual oferece incentivos fiscais e isenção de imposto sobre a Circulação de Mercadorias e Serviços, estimulando a criação, industrialização e o comércio de pescado (DIÁRIO OFICIAL, 2007; BARROS et al., 2011). A Lei tem como principal objetivo estimular o comércio local e a geração de empregos, bem como preservar a herança cultural da população ribeirinha.

O dimensionamento das áreas por região apresentou maior predominância de áreas vegetadas na região oeste e sul, identificadas em áreas remanescente, próximo a cursos d'água e em parques urbanos. A região sul apresentou a maior extensão de áreas vegetadas, resultado da presença de áreas de conservação, como o parque Zé Bolo-Flor e o Horto Florestal as margens do rio Coxipó, e também ao menor desenvolvimento urbano e econômico da região (CUIABÁ, 2009). A região oeste também se destaca pela presença de áreas verdes, resultado da expansão populacional

tardia, maior porcentagem de áreas arborizadas e pela presença da presença do Parque Mãe Bonifácia (ROMANCINI, 2011).

A maior expansão de áreas construídas foi apresentada nas regiões leste e norte da cidade, corroborando com os estudos de Romancini (2011) e Vasconcelos e Zamparoni (2011) realizados em Cuiabá – MT. A região leste se destaca por ser a região pioneira no povoamento da cidade até a década de 60 e pelo contínuo crescimento urbano, resultante do fortalecimento da capital como polo de apoio a ocupação da Amazônia meridional.

A expansão de áreas construídas na região norte, pode ser justificado pela criação do Centro Político e Administrativo (CPA) e o bairro Morada da Serra nas décadas de 70 e 80, povoado inicialmente pela classe de baixa renda. Na região, foi se estabelecendo áreas residenciais, comerciais, de lazer, saúde, transporte e educação, atraindo um acelerado contingente populacional de diferentes classes sociais nos anos de estudo. Atualmente, a região se apresenta em constante crescimento diante da valorização imobiliária da região, tornando-se uma nova centralidade da cidade, com elevada concentração populacional e, conseqüentemente, expansão de áreas antropizadas (VILANOVA e MAITELLI, 2009; VASCONCELOS e ZAMPARONI, 2011).

A partir da década de 70, novos eixos de crescimento foram sendo criados, bem como novos conjuntos habitacionais e loteamentos emergenciais sem infraestruturas, objetivando a descentralização da cidade. A expansão urbana do município também está atrelada a valorização do capital imobiliário, em torno de áreas consideradas “nobres”, próximas a atrativos comerciais ou áreas que ofereçam qualidade de vida, infraestrutura e boa localização (SIQUEIRA e VILARINHO NETO, 2012; SILVA, 2016). A expansão do crescimento urbano para as regiões oeste e sul da cidade, pode ser justificado pela criação de *Shoppings Center*, parques urbanos e pela valorização da Avenida Fernando Corrêa a partir da década de 80 (ROMANCINI, 2011).

Por outro lado, a permanência e a expansão, de áreas de vegetação remanescentes 1985 a 2017 nas diferentes regiões da cidade, pode ser resultado da Lei Orgânica Municipal criada em 1990 e pela Lei Complementar nº 231 de 2011. A Lei Orgânica Municipal de Cuiabá, estabelece criar e manter áreas verdes, na proporção mínima de 10 m² por habitante, exigindo o reflorestamento de áreas permanentes e

recuperação da vegetação urbana segundo os critérios definidos em lei (CUIABÁ, 1990). A Lei Complementar nº 231 de 2011, estabelece regras para uso e ocupação do solo, onde 25% da área total do terreno deve ser permeável, coberto por vegetação arbórea ou paisagística (CUIABÁ, 2011).

Desta maneira, nota-se que nos últimos anos, a Prefeitura Municipal de Cuiabá, através da Secretária Municipal de Desenvolvimento Urbano (SMDU), vem criando leis relevantes para regulação e o ordenamento da expansão urbana da cidade. A falta de cumprimento da lei e a fiscalização efetiva, resulta ainda em maior percentual de perdas de áreas vegetadas em detrimento do avanço de áreas construídas. Sendo assim, a substituição de ambientes naturais por áreas construídas nos anos de estudo tem contribuído para intensificação de degradação ambiental, que resulta em sérios problemas urbanos, tais como: alterações nos valores de α_{sup} , T_s e no balanço de energia.

5.3 DINÂMICA DOS PARÂMETROS DA SUPERFÍCIE EM ÁREA URBANA

As áreas urbanas apresentam diferentes valores de NDVI, α_{sup} e T_s resultante do complexo arranjo urbano, formado por áreas antropizadas e vegetadas em diferentes densidades que refletem diretamente na resposta espectral da superfície (HU et al., 2017). Os maiores valores de NDVI identificados em áreas vegetadas (parques urbanos, mata ciliar e remanescente), classificado como AVD e AVA neste estudo, está relacionado aos pigmentos fotossintetizantes e a umidade, refletindo na resposta espectral. As áreas vegetadas apresentam maior refletância na faixa do infravermelho próximo e menor na faixa do vermelho, pois essa energia é utilizada nos processos fotossintéticos das células foliares (GANDHI et al., 2015).

Os menores valores de NDVI identificados em áreas cobertas por água e áreas antropizadas (AVR e ACO) é resultado da maior absorção da radiação na faixa do infravermelho, que reflete diretamente na redução dos valores do NDVI. Resultados semelhantes foram identificados nos estudos de Xiong et al. (2012), Sharma et al. (2013), Li e Chen (2018), realizados em áreas densamente urbanizada e diretamente associada com a substituição de ambientes naturais por áreas construídas.

Os valores do α_{sup} variam de acordo com as características da superfície e os materiais que a compõe, influenciando diretamente na variação do fluxo do calor latente e sensível da superfície (KRÜGER e GONZALEZ, 2016). Os menores valores

do a_{sup} em áreas vegetadas e cobertas por água, pode ser justificado pelo maior potencial das superfícies em absorver a radiação solar, utilizadas em seus processos biofísicos e influenciando na diminuição da T_s (BIUDES et al., 2015; PAVÃO et al., 2017). Os maiores valores do a_{sup} são identificados em AVR e ACO, resultante do tipo de solo, ao aumento de áreas impermeáveis e ao tipo de material construtivo utilizado, tais como: tijolos e telhas de cimento que apresentam valores de a_{sup} mais elevados (GIRIDHARAN et al., 2004; OLIVEIRA et al., 2020).

Por outro lado, os maiores erros de classificação da cobertura do solo em AVR e ACO podem ter influenciado nos maiores valores de NDVI e na redução dos valores do a_{sup} em alguns pontos da cidade em 2017. Os erros apresentados, podem ser justificados pela complexidade dos arranjos urbanos de difícil detecção por sensores de média resolução espectral (HU et al., 2016). Os arranjos urbanos são formados por áreas fragmentadas, composta por áreas densamente urbanizadas e fragmentos de vegetação, permeados por espaços vazios.

As áreas vegetadas e de corpos d'água são consideradas ilhas de frescor, diante dos menores valores da T_s presentes nas cidades e se diferiram estatisticamente de outras classes (ESTOQUE et al., 2017). Os menores valores em áreas vegetadas podem ser justificados pelo bloqueio da radiação solar direta, maior quantidade de energia destinada à evapotranspiração, combinados com a menor inércia térmica em comparação a superfícies antropizadas (HAMADA e OHTA, 2010; ZHOU et al., 2011; LI et al., 2012). As áreas vegetadas apresentam-se como importante regulador da T_s e aumento da umidade relativa do ar, melhorando o conforto térmico na cidade (OLIVEIRA, et al., 2011; LAI et al., 2019).

Os maiores valores da T_s estão associados a substituição de ambientes naturais por áreas construídas e de solo exposto que possuem a maior capacidade armazenamento de calor na superfície (CAI e XU, 2017). A expansão de áreas impermeáveis e construídas, a intensa circulação de veículos e a poluição atmosférica em áreas urbanas, influenciam no aumento da temperatura do ar e da superfície, resultando na formação de anomalias térmicas (FEIZIZADECH e BLASCHKE, 2013). As diferentes temperaturas ao longo da cidade são influenciadas pelas alterações na troca de energia e aerodinâmicas da superfície, resultante da morfologia

e estrutura da superfície urbana (WONG et al., 2011; RADHI et. al., 2013; CAI e XU, 2017).

A expansão urbana do município de Cuiabá de 1985 a 2017, influenciou diretamente na dinâmica dos parâmetros analisados neste estudo. Os dados espaciais indicaram maior expansão urbana nas regiões leste e norte, refletindo nos menores valores de NDVI e maiores valores de a_{sup} e T_s , pois quando menor a concentração vegetal, maior a disponibilidade da energia para aquecimento do ar (BIUDES et al., 2015). As regiões oeste e sul apresentou a maior concentração de áreas vegetadas influenciando diretamente nos maiores valores de NDVI e menores valores de a_{sup} e T_s , pois quanto maior a biomassa, maior o efeito termorregulador da superfície (PAVÃO et al., 2017).

5.4 AVALIAÇÃO DA DINÂMICA DOS COMPONENTES DO BALANÇO DE ENERGIA EM ÁREA URBANA

Os maiores valores do Rn_{inst} identificados em 1985 nas diferentes coberturas do solo pode ser justificado pela maior concentração de áreas vegetadas no arranjo da cidade. A cidade de Cuiabá - MT, ficou conhecida durante séculos como “Cidade Verde”, resultado dos seus extensos fragmentos de cerrado presentes em toda área urbana (MACHADO et al., 2013; NETTO e UGEDA JÚNIOR, 2019). Sendo assim, as características da superfície urbana e a presença de fragmentos vegetais influenciam diretamente na interceptação, refletância e absorção da radiação solar, resultando em alterações nos componentes do balanço de energia.

O G em áreas vegetadas aumenta com a diminuição da cobertura vegetal, no entanto, em áreas urbanizadas a variação do G está relacionado as propriedades térmicas dos tecidos urbanos (MACHADO et al., 2020; OKE et al., 2017; RIGO e PARLOW, 2007). O armazenamento de calor no solo que está diretamente relacionado com G é de 2-6 vezes maior em áreas urbanas em comparação as áreas vegetadas. O valores mais elevados são identificados no período diurno e em áreas densamente antropizadas (CHRYSOULAKIS et al., 2018).

Os maiores valores de G em áreas antropizadas ocorreram devido a propriedade dos materiais utilizados na área urbana de Cuiabá, onde predominam o concreto, asfalto e solo exposto. Contudo, notou-se que não houve diferenças

significativas entre as classes AVA, AVR e ACO, o que evidencia um possível efeito da resolução espacial dos sensores TM e OLI que aliada a alta heterogeneidade da superfície urbana geram valores semelhantes de G . Esse comportamento demonstra a dificuldade do modelo utilizado em distinguir superfícies heterogêneas (PAUL et al., 2014), o que sugere a necessidade de ajustes a partir do uso do solo no modelo (KATO e YAMAGUCHI, 2005; FARIDATUL et al., 2019).

O estudo do G em áreas urbanas é de suma importância, pois esse parâmetro basicamente se relaciona a energia estocada no tecido urbano (RIGO e PARLOW, 2007; LINDBERG et al., 2020). A energia estocada, pode representar de maneira mais adequada o efeito da urbanização nos fluxos energéticos superficiais (FEIGENWINTER et al., 2018). Em outras palavras, a energia estocada no tecido urbano pode ser determinante para compreensão dos fenômenos de ilha de calor urbano e aumento da temperatura no ar após o ocaso solar (CRAWFORD et al., 2017; CHRYSOULAKIS et al., 2018).

A maior concentração de áreas vegetadas em 1985, também influenciou no predomínio do LE sobre o H associado a maior quantidade de energia destinado a evapotranspiração. Por outro lado, os maiores valores de H e os menores valores de LE em 2017, pode ser justificado pela expansão de áreas edificadas, pavimentadas com asfalto e intensificação da circulação de veículos que modificam as trocas de energia da superfície (SANTOS et al., 2013; GARUMA et al., 2018). As superfícies urbanas, juntamente com o aumento da rugosidade e intensificação dos poluentes atmosféricos, possuem maior capacidade de armazenamento de energia que será dissipada na forma de calor sensível (KHALIL et al., 2018; ZHENG et al., 2018)

As áreas urbanas apresentam diferentes valores de Rn_{inst} , H , LE e ET_{24} , resultado da arquitetura heterogênea dos espaços urbanos. Os maiores valores de Rn_{inst} , LE e ET_{24} identificados em áreas vegetadas (AVD e AVA) e ACA, resulta da maior absorção da energia disponível, utilizada majoritariamente no processo de evapotranspiração associados a fotossíntese (PAVÃO et al., 2017; CONG et al., 2017). As superfícies com vegetação densa apresentam coloração mais escura o que permite que a radiação entre no dossel e não retorne para a atmosfera (QUERINO et al., 2016, 2017).

Os dados espaciais evidenciam a influência da geometria urbana e as propriedades da superfície no particionamento do balanço de energia, refletindo diretamente nas condições térmicas do ambiente (CHAKRABORTY et al., 2013).

Os menores valores de Rn_{inst} e maiores valores H identificados em áreas antropizadas (AVR e ACO), resulta da diminuição da cobertura vegetal que modifica a absorção e distribuição de energia, que será convertida em calor sensível (FARIDATUL et al., 2019). A expansão de áreas construídas, diminuição da cobertura vegetal e a menor disponibilidade de água no solo caracteriza-se pela redução do fluxo evaporativo e o aumento da radiação de ondas longas emitidas pela superfície (DARAMOLA e BALOGUN, 2019). A expansão urbana de Cuiabá – MT apresentada nos últimos anos, refletiu diretamente nos componentes do balanço de energia, principalmente em regiões densamente urbanizadas ou associadas a presença de solo exposto (CALLEJAS et al., 2019).

5.5 ANÁLISE ESPACIAL DOS PERFIS

Os resultados dos perfis apresentaram, majoritariamente, maiores valores de NDVI em 2017 em comparação a 1985 e menores valores de a_{sup} . Os fatores determinantes da variabilidade do NDVI e do a_{sup} são complexos, podendo estar relacionados aos elementos meteorológicos (precipitação, temperatura e umidade do solo), aos diferentes tipos de cobertura vegetal e as atividades antrópicas (HOU et al., 2015; LIU e MENZEL, 2016; LIU et al., 2019). Os maiores valores de NDVI em 2017, pode estar relacionado aos maiores valores de precipitação naquele ano, em comparação a normal climatológica da cidade.

A variabilidade pluviométrica afeta os processos ecofisiológico da vegetação, podendo estimular a fotossíntese e a respiração do ecossistema (INGLIMA et al., 2009; WU et al., 2011; CONTE et al., 2019). De acordo com os estudos de Biudes et al. (2015) e Machado et al. (2020) para a mesma região, a sazonalidade das chuvas e a disponibilidade de água no solo influenciam na quantidade de folhas em áreas de cerrado. Por outro lado, o aumento nos valores do NDVI em diferentes pontos da cidade, pode estar atrelado a Lei Complementar n° 231 de 2011, que estabelece uma porcentagem mínima de área permeável nos terrenos residenciais, que pode ser coberto com vegetação arbórea ou paisagística (CUIABÁ, 2011).

Os menores valores do α_{sup} em 2017 em comparação a 1985, em alguns trechos do perfil, pode estar relacionado a maior disponibilidade de água na superfície e maiores valores de NDVI já apresentado acima neste estudo (ZHENG et al., 2019). Sendo assim, a correlação entre a vegetação e o α_{sup} varia de acordo com o tipo e a densidade da vegetação, estrutura do dossel, estágio de desenvolvimento da planta (LUKĚS et al., 2014).

A mudança na cobertura vegetal pode alterar significativamente o α_{sup} e consequentemente o balanço de energia (SABZIPARVAR et al., 2020), o que pode justificar a correlação alta do NDVI com o α_{sup} e os componentes do balanço de energia. Além disso, a expansão da pavimentação asfáltica e a alteração do material construtivo, como o concreto, que possuem maior capacidade de absorção da radiação solar podem justificar os resultados encontrado neste estudo (GARUMA et al., 2018).

As alterações dos materiais construtivos e de pavimentação, juntamente com a expansão urbana, influenciou diretamente no aumento da T_s e redução do Rn_{inst} , observado nos resultados dos perfis e na conversão do uso do solo. O incremento nos valores de T_s a partir da expansão de áreas antropizadas, resultou no aumento da fração de onda longa influenciando negativamente o Rn_{inst} (ANDRADE et al., 2014; PAVÃO et al., 2017), evidenciado no correlograma de Spearman.

A substituição de ecossistemas naturais por áreas antropizadas resultou na redução do fluxo evaporativo e no aumento da radiação de onda longa, influenciando negativamente na dinâmica do G , H , LE e ET_{24} apresentado nos perfis. As alterações na dinâmica dos componentes do balanço de radiação em função da expansão urbana já foi tema de diferentes estudos em Cuiabá – MT, diante da preocupação com as alterações antrópicas (MAITELLI, 2010; CALLEJAS et al., 2016; e CALLEJAS et al., 2019). Em geral, os resultados demonstraram a importância do planejamento urbano e a necessidade da expansão de áreas verdes dentro da cidade, a fim de otimizar a qualidade socioambiental dos ecossistemas urbanos.

6. CONCLUSÃO

Os resultados apresentados demonstraram que o município de Cuiabá – MT passou por uma acelerada expansão urbana nos últimos anos. A região leste e norte da cidade foi pioneira nesta ocupação, que se expandiu para as outras regiões da cidade a partir da década de 1980. A expansão das áreas urbanas verificadas neste estudo esteve atrelada a substituição da vegetação nativa por áreas construídas, afetando diretamente os valores da temperatura da superfície e os componentes do balanço de energia.

A classificação a partir de índices espectrais mostrou-se adequado e eficiente para avaliação espaço-temporal da cobertura do solo. As áreas de vegetação rasteira e/ou solo exposto e as áreas construídas, apresentaram o maior erro de precisão, comissão e omissão em 1985, resultante da mistura espectral do complexo arranjo urbano. No entanto, a classificação da cobertura do solo a partir de dados orbitais, para sensores de média resolução, demonstrou alta confiabilidade e precisão.

O aumento da precipitação em 2017, em comparação a normal climatológica, influenciou nos maiores valores de NDVI em alguns pontos da cidade. No entanto, as alterações antrópicas observadas ao longo dos anos de estudo resultaram no aumento dos valores do albedo e temperatura da superfície principalmente em áreas impermeáveis e com baixa disponibilidade de vegetação. A expansão de áreas edificadas e de solo exposto influenciou no aumento de energia armazenada dentro do dossel urbano.

As alterações na cobertura do solo resultaram no aumento dos valores do G e H e diminuição do Rn_{inst} , LE e ET_{24} de 1985 a 2017. Os resultados demonstraram que a maior parte da energia disponível foram utilizadas para o aquecimento da superfície. A expansão das áreas antropizadas refletiram negativamente no particionamento das variáveis do balanço de energia, pois a maior parte da energia disponível foi dissipada na forma de calor sensível e armazenada nas superfícies artificiais.

O aumento do G e H em áreas densamente urbanizadas, influenciam na intensificação do aquecimento do ar e do solo, o que pode contribuir para a formação de ilhas de calor e refletir na qualidade de vida urbana. Sendo assim, este estudo foi adequado para avaliar os efeitos da urbanização nas variáveis biofísicas e componentes do balanço de energia. Portanto, os resultados encontrados nesta tese constitui um

importante subsídio para o planejamento e gestão da cidade, podendo auxiliar na tomada de decisão e desenvolvimento de projetos futuros que visão a melhoria da qualidade de vida da população.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ALLEN, R. G.; BASTIAANSEN, W.; WATERS, R.; TASUMI, M.; TREZZA, R. Surface energy balance algorithms for land (SEBAL), **Idaho implementation – Advanced training and users manual**, version 1.0, 2002.

ALLEN, R.G.; TASUMI, M.; TREZZA, R. Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC)-Model. **Journal of Irrigation and Drainage Engineering**, v 133, p. 380-394, 2007.

ALVES, W. S. MARTINS, A. P.; SCOPEL, I. Uso da Terra e Cobertura Vegetal na Bacia do Ribeirão das Abóboras, em Rio Verde (GO), Entre os anos de 1985 e 2015. **Revista Caminhos de Geografia**, v. 19, n. 65, p. 125-145, 2018.

AMATO, F.; TONINI, M.; MURGANTE, B.; KANEVSKI, M. Fuzzy definition of Rural Urban Interface: An application based on land use change scenarios in Portugal. **Environmental Modelling & Software**, v. 104, p. 171–187, 2018.

ANDRADE, A.M.D.; MOURA, M.A.L.; SANTOS, A.B. dos S.; CARNEIRO, R.G.; JUNIOR, R.S. da S. Radiação fotossinteticamente ativa incidente e refletida acima e abaixo do dossel de Floresta de Mata Atlântica em Coruripe, Alagoas. **Revista Brasileira de Meteorologia**, v. 29, n. 1, p. 68 - 79, 2014.

AS-SYAKUR, A. R.; ADNYANA, I. W. S.; ARTHANA, I. W.; NUARSA, I. W. Enhanced Built-Up and Bareness Index (EBBI) for Mapping Built-Up and Bare Land in an Urban Area. **Remote Sensing**, v. 4, n. 10, p. 2957–2970, 2012.

BALZAROLO, M.; PEÑUELAS, J.; VEROUSTRAETE, F. Influence of Landscape Heterogeneity and Spatial Resolution in Multi-Temporal In Situ and MODIS NDVI Data Proxies for Seasonal GPP Dynamics. **Remote Sensing**, v. 11, n. 1656, 2019.

BANKO, G. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data and of Methods Including Remote Sensing Data in Forest Inventory. **International Institute for Applied Systems Analysis Interim Report**, 1998.

BARET, F.; GUYOT, G. MAJOR, D. J. TSAVI: A Vegetation Index Which Minimizes Soil Brightness Effects On LAI And APAR Estimation. 12th **Canadian Symposium on Remote Sensing and IGARSSX30**, 1989.

BARROS, A. F.; MARTINS, M. I. E. G.; SOUZA, O. M. Caracterização da piscicultura na microrregião da Baixada Cuiabana, Mato Grosso, Brasil. **Boletim do Instituto de Pesca**, São Paulo, v. 37, p. 261-273, 2011.

BARROS, M. P.; MUSIS, C. R. Uma abordagem sistêmica sobre as implicações entre a fragmentação das áreas verdes e o ambiente térmico do espaço urbano. **Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental**, v. 9, p. 1999-2017, 2013.

BASTIAANSEEN, W.G.; MENENTI, M.; FEDDES, R.A.; HOLTSLAG, A. A. M. A Remote Sensing Surface Energy Balance Algorithm for Land (SEBAL) 1. Formulation. **Journal of Hydrology**, v. 212-213, p 198-212, 1998.

BASTIAANSEN, W. G. M.; NOORDMAN, E. J. M.; PELGRUM, H.; DAVIDS, G.; THORESON, B. P.; ALLEN, R. G. SEBAL Model with Remotely Sensed Data to Improve Water-Resources Management under Actual Field Conditions, **Journal of Irrigation and Drainage Engineering**, v. 131, n. 1, p. 85-93, 2005.

BASTIAANSEN, W.G. SEBAL-based sensible and latent heat fluxes in the irrigated Gediz Basin, Turkey. **Journal of Hydrology**, v. 229, p. 87-100, 2000.

BERNARDES, J. A. Dimensões da ação e novas territorialidades no cerrado brasileiro: pistas para uma análise teórica. **Revista Nera**, n. 10, p. 1-10, 2007.

BERRY, G. Statistical significance and confidence intervals. **The Medical Journal of Australia**, v. 144, p. 618-619, 1986.

BIUDES, M. S.; VOULITIS, G. L.; MACHADO, N. G.; DE ARRUDA, P. H. Z.; NEVES, G. A. R.; LOBO, F. A.; NEALE, C. M. U.; NOGUEIRA, J. S. Patterns of Energy Exchange for Tropical Ecosystems across a climate gradient in Mato Grosso, Brazil. **Agricultural and Forest Meteorology**, v. 202, p. 112-124, 2015.

BOENING, C.; WILLIS, J. K.; LANDERER, F. W.; NEREM, R. S.; FASULLO, J. BOSCHETTI, L.; FLASSE, S. P.; BRIVIO, P. A. Analysis of the conflict between omission and commission in low spatial resolution dichotomic thematic products: The Pareto Boundary. **Remote Sensing of Environment**, V. 91, p. 280-292, 2004.

BRANDSTÄTTER, E.; LINZ, J. K. U. Confidence Intervals as an Alternative to Significance Testing. **Methods of Psychological Research Online**, v. 4. n. 2, p. 33-46, 1999.

BRASIL. Ministério do Meio Ambiente, dos Recursos Hídricos e da Amazônia Legal. **Plano de conservação da Bacia do Alto Paraguai: diagnóstico dos meios físicos e biótico**. Brasília, Ministério do Meio Ambiente, dos Recursos Hídricos e da Amazônia Legal, Programa Nacional do Meio Ambiente, 2, 334p, 1997.

BUYANTUYEV, A., WU, J. Urbanization diversifies land surface phenology in arid environments: interactions among vegetation, climatic variation, and land use pattern in the Phoenix metropolitan region, USA. **Landscape and Urban Planning**, 105, 149–159, 2012.

CAI, H.; XU, X. Impacts of built-up area expansion in 2D and 3D on regional surface temperature. **Sustainability**, v. 9, n. 1862, p. 1-16, 2017.

CALLEJAS, I. J. A., OLIVEIRA, A. S. O., SANTOS, F. M. M., DURANTE, L. C., NOGUEIRA, M. C. J. A., ZEILLHOFER, P. Relationship between land use/cover and

surface temperatures in the urban agglomeration of Cuiabá-Várzea Grande, Central Brazil, **Journal of Applied Remote Sensing**, v. 5, 53569: 1-15, 2011.

CALLEJAS, I. J. A.; BIUDES, M. S.; MACHADO, N. G.; DURANTE, L. C.; LOBO, F. A. Patterns of Energy Exchange for Tropical Urban and Rural Ecosystems Located in Brazil Central. **Journal of Urban and Environmental Engineering**, v. 13, n. 1, p. 69-79, 2019.

CALLEJAS, I. J. A.; NOGUEIRA, M. C. J. A.; BIUDES, M. S.; DURANTE, L. C. Variação sazonal do balanço de energia em cidade localizada na região central do Brasil. **Mercator**, v. 15, n. 3, p. 85-106, 2016.

CARMONA, F.; RIVAS, R.; CASELLES, V. Development of a general model to estimate the instantaneous, daily, and daytime net radiation with satellite data on clear sky days. **Remote Sensing of Environment**, v. 171, p. 1-13, 2015.

CARVALHO, R. C. As migrações e a urbanização no Brasil a partir da década de 1950: um breve histórico e uma reflexão à luz das teorias de migração. **Revista Espinhaço**, v. 8, p. 24-33, 2019.

CHAKRABORTY, S. D., KANT, Y., MITRA, D. Assessment of land surface temperature and heat fluxes over Delhi using remote sensing data. **Journal of Environmental Management**, v. 148, p. 143–152, 2015.

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 Sensing of Environment**, v. 104, p. 133–146, 2006.

CHEN, S.; HU, D. Parameterizing anthropogenic heat flux with an energy-consumption inventory and multi-source remote sensing data. **Remote Sensing of Environment**. 9 (11), 1165, 2017.

CHEVAL, S.; MICU, D.; DUMITRESCU, A.; IRIMESCU, A.; FRIGHENCIU, M.; IOJĂ, N. C.; TUDOSE, N. C.; DAVIDESCU, S.; ANTONESCU, B. Meteorological and Ancillary Data Resources for Climate Research in Urban Areas. **Climate**, v. 8, n. 37, 2020.

CHIARANDA, R., RIZZI, N. E., COLPINI, C., SOARES, T. S., SILVA, V. S. M. Análise da precipitação e da vazão da bacia do Rio Cuiabá. **Revista Brasileira de Ciências Agrárias**, v. 7, p. 117-122, 2012.

CHRYSOULAKIS, N., GRIMMOND, S., FEIGENWINTER, C., LINDBERG, F., GASTELLU-ETCHEGORRY, J-P., MARCONCINI, M., MITRAKA, Z., STAGAKIS, S., CRAWFORD, B., OLOFSON, F., LANDIER, L., MORRISON, W., PARLOW, E. Urban energy exchanges monitoring from space. **Scientific Reports**, v.8, 2018.

CLAVERIE, M., VERMOTe, E.F., FRANCH, B., MASEK, J. G. Evaluation of The Landsat-5 TM and Landsat-7 ETM + Surface Reflectance Products. **Remote Sensing of Environment** v.169, p. 390-403, 2015.

CONG, Z., SHEN, Q., ZHOU, L., SUN, T., LIU, J. Evapotranspiration estimation considering anthropogenic heat based on remote sensing in urban area. **Science China Earth Sciences**, v. 60, p. 659–671, 2017.

CONGALTON, R.G., K. GREEN. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices, **Lewis Publishers**, Boca Raton, Florida, 137 p., 1999.

CONTE, A.; FARES, S.; SALVATI, L.; SAVI, F.; MATTEUCCI, G.; MARRENGA, F.; SPANO, D.; SIRCA, C.; MARRAS, S.; GALVAGNO, M.; CREMONESE, E.; MONTAGNANI, L. Ecophysiological responses to rainfall variability in grassland and forest along a latitudinal gradient in Italy. **Forest responses to rainfall variability**, v. 2, p. 1-12, 2019.

COUTTS, A. M.; HARRIS, R. J.; PHAN, T.; LIVESLEY, S. J.; WILLIAMS, N. S. G.; TAPPER, N. J. Thermal infrared remote sensing of urban heat: Hotspots, vegetation, and an assessment of techniques for use in urban planning. **Remote Sensing of Environment**, v, 186, p. 637–651, 2016.

CRAWFORD, B., GRIMMOND, C. S. B., WARD, H. C, MORRISON, W., KOTTHAUS, S. Spatial and temporal patterns of surface–atmosphere energy exchange in a dense urban environment using scintillometry. **Quarterly Journal of the Royal Meteorological Society**, v. 143, n. 703, p. 817-833, 2016.

CUIABÁ. **Lei Orgânica do Município de Cuiabá – MT**, de 05 de abril de 1990. Estado de Mato Grosso, Câmara Municipal de Cuiabá, 1990.

CUIABÁ. Prefeitura Municipal de Cuiabá / **Evolução Urbana de Cuiabá**. IPDU Instituto de Planejamento e Desenvolvimento Urbano. Cuiabá, 2010.

CUIABÁ. Prefeitura Municipal de Cuiabá / **Perfil Socioeconômico de Cuiabá – Volume IV**. IPDU-Instituto de Planejamento e Desenvolvimento Urbano. Cuiabá, 2009.

CUIABÁ. Prefeitura Municipal de Cuiabá. **Evolução do Perímetro Urbano de Cuiabá – 1938 a 2007**. IPDU - Instituto de Planejamento e Desenvolvimento Urbano. Cuiabá, 2007.

CUIABÁ. Prefeitura Municipal de Cuiabá. **Plano Diretor de Desenvolvimento Estratégico de Cuiabá**. IPDU-Instituto de Planejamento e Desenvolvimento Urbano. Cuiabá, 2008.

CUIABÁ. Prefeitura Municipal de Cuiabá. **Perfil Socioeconômico de Cuiabá – Volume IV**. IPDU-Instituto de Planejamento e Desenvolvimento Urbano. Cuiabá, 2009.

CUIABÁ. Prefeitura Municipal de Cuiabá. **Uso, Ocupação e Urbanização do Solo**. SMDU – Secretaria Municipal de Desenvolvimento Urbano. Cuiabá, 2011.

CUIABÁ. Prefeitura Municipal. Instituto de Planejamento e Desenvolvimento Urbano: **Plano Diretor de Desenvolvimento Estratégico de Cuiabá**. Cuiabá, MT. 147 p. 2007.

DA SILVA, B. B.; BRAGA, A. C.; BRAGA, C. C. L.; OLIVEIRA, M. M.; MONTENEGRO S. M. G. L.; BARBOSA JUNIOR, B. 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.

DA SILVA, B. B.; MERCANTE, E.; VILAS BOAS, M. A.; WRUBLACK, S. C.; OLDONI, L. V. Satellite-based ET estimation using Landsat 8 images and SEBAL model. **Revista Ciência Agronômica**, v. 49, n. 2, p. 221-227, 2018.

DA SILVA, V. S.; SALAMI, G.; DA SILVA, M. I. O.; Silva, Araújo, E.; Monteiro Junior, J. J.; ALBA, E. Methodological evaluation of vegetation indexes in land use and land cover (LULC) classification, **Geology, Ecology, and Landscapes**, 2019.

DA SILVA, V. S.; SALAMI, G.; DA SILVA, M. I. O.; SILVA, E. A.; JUNIOR MONTEIRO, J. J.; ALBA, E. Methodological evaluation of vegetation indexes in land use and land cover (LULC) classification. **Geology, Ecology and Landscapes**, p. 1-11, 2019.

DARAMOLA, M.; BALOGUN, I. A. Analysis of the urban surface thermal condition based on sky-view factor and vegetation cover. **Remote Sensing Applications: Society and Environment**, v. 15, 2019.

DIÁRIO OFICIAL. Superintendência da Imprensa Oficial do Estado de Mato Grosso. **Decreto-Lei Estadual nº 8.684 de 20 de Julho de 2007**. Diário Oficial, Cuiabá, n. 24.638, p.1, 2007.

DU, H.; CAI, W.; XU, Y.; WANG, Z.; WANG, Y. e CAI, Y. Quantifying the cool island effects of urban green spaces using remote sensing Data. **Urban Forestry & Urban Greening**, v. 27, p. 24–31, 2017.

DUO, A.; ZHAO, W.; QU, X.; JING, R.; XIONG, K. Spatiotemporal variation of vegetation coverage and its response to climate change in North China plain in the last 33 years. **International Journal of Applied Earth Observation and Geoinformation**, v. 53, p. 103–117, 2016.

EFRON, B.; TIBSHIRANI, R.J. An introduction to the bootstrap. **Chapman & Hall, New York**. p. 443, 1993.

ESTOQUE, R. C.; MURAYAMA, Y.; MYINT, S. W. Effects of landscape composition and pattern on land surface temperature: Na urban heat island. Study in the megacities of southeast Asia. **Science of the total environment**, v. 577, p. 349-359, 2017.

FARIDATUL, M. I., WU, B., ZHU, X., & WANG, S. Improving Remote Sensing based Evapotranspiration Modelling in a Heterogeneous Urban Environment. **Journal of Hydrology**, v. 581, 2020.

FARIDATUL, M. I.; WU, B.; ZHU, X.; WANG, S. Improving remote sensing based evapotranspiration modelling in a heterogeneous urban environment. **Journal of hydrology**, v. 581, 124405, 2020.

FARIDATUL, M.I., WU, B., ZHU, X., WANG, S., Improving Remote Sensing based Evapotranspiration Modelling in a Heterogeneous Urban Environment, **Journal of Hydrology**, v. 581, 2019.

FAUSTO, M. A.; MACHADO, N. G.; NOGUEIRA, J. S.; BIUDES, M. S. Net radiation estimated by remote sensing in Cerrado areas in the Upper Paraguay River Basin. **Journal of Applied Remote Sensing**, v. 8, p. 083541-1 - 083541-17, 2014.

FEIGENWINTER, C., VOGT, R., PARLOW, E., LINDBERG, F., MARCONCINI, M., FRATE, F., CHRYSOULAKIS, N. Spatial Distribution of Sensible and Latent Heat Flux in the City of Basel (Switzerland). **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 8, 2018.

FEIZIZADEH, B.; BLASCHKE, T. Examining urban heat island. Relations to land use and air pollution: multiple endmember spectral mixture analysis for thermal remote sensing. **IEEE Journal of selected topics in applied earth observations and remote sensing**, v. 6, n. 3, 2013.

FIELDING, A. H., BELL, J. F. A review of methods for the assessment of prediction errors in conservation presence/absence models. **Environmental Conservation**, v. 24, p. 38-49, 1997.

FILHO, F. C. M. M., AMARAL, D. B. Histórico da expansão urbana e ocorrência de inundações na cidade de Cuiabá-MT. **Sociedade e Natureza**, v. 26, p. 159-170, 2014.

FILIPPA, G., CREMONESE, E., MIGLIAVACCA, M., GALVAGNO, M., SONNENTAG, O., HUMPHREYS, E. HUFKENS, K. RYO, Y.; VERFAILLIE, J.; DI CELLA, U. M.; RICHARDSON, A. D. NDVI derived from near-infrared-enabled digital cameras: Applicability across different plant functional types. **Agricultural and Forest Meteorology**, v. 249, p. 275–285, 2018.

FISHER, J. R. B.; ACOSTA, E. A.; DENNEDY-FRANK, P. J.; KROEGER, T.; BOUCHER, T. M. Impact of satellite imagery spatial resolution on land use

classification accuracy and modeled water quality. **Remote Sensing in Ecology and Conservation**, v. 4, n.2, p.137–149, 2018.

FOODY, G. M. Status of land cover classification accuracy assessment, **Remote Sensing of Environment**, v. 80, p. 185 – 201, 2002.

FU, P.; WENG, Q. A time series analysis of urbanization induced land use and land cover change and its impacts on land surface temperature with Landsat imagery. **Remote Sensing of Environment**, v. 175, p. 205-2014, 2016.

FU, P.; WENG, Q. A time series analysis of urbanization induced land use and land cover change and its impact on land surface temperature with Landsat imagery. **Remote Sensing of Environment**, n. 175, p. 205-214, 2016.

GANDHI, G. M.; PARTHIBAN, S.; THUMMALU, N.; CHRISTY, A. Ndvi: Vegetation Change Detection Using Remote Sensing and Gis – A Case Study of Vellore District. **Procedia Computer Science**, n. 57, p. 1199–1210, 2015.

GAO, B. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, 58, 257–266, 1996.

GARDNER, M. J.; ALTMAN, D. G. Confidence intervals rather than P values: estimation rather than hypothesis testing. **British Medical Journal**, v. 292, p. 746-750, 1986.

GARUMA, G. F.; BLANCHET, J. –P.; GIRARD, E.; LEDUC, M. Urban surface effects on current and future climate. **Urban Climate**, v. 24, p. 121-138, 2018.

GASHAW, T.; TULU, T.; ARGAW, M.; WORQLUL, A. W. Modeling the hydrological impacts of land use/land cover changes in the Andassa watershed, Blue Nile Basin, Ethiopia. **Science of The Total Environment**, v. 619-620, p.1394–1408, 2018.

GEORGANOS, S.; GRIPPA, T.; VANHUYSSSE, S.; LENNERT, M.; SHIMONI, M.; WOLFF, E. Very High Resolution Object-Based Land Use–Land Cover Urban Classification Using Extreme Gradient Boosting. **IEEE Geoscience and Remote Sensing Letters**, v. 15, n.4, p. 607–611, 2018.

GIRIDHARAN, R.; GANESAN, S.; LAU, S. S. Y. Daytime urban heat island. Effect in high-rise and high-density residential developments in Hong Kong. **Energy and Buildings**, v. 36, p. 525-543, 2004.

GRIMMOND, C.S.B.; CLEUGH, H.A. and OKE, T.R. An objective urban heat storage model and its comparison with other schemes. **Atmospheric Environment, Urban Atmosphere**, v.25, n.3, p.311-326, 1991.

GONG, B., IM, J; MOUNTRAKIS, G. An artificial immune network approach to multi-sensor land use/land cover classification. **Remote Sensing of Environment**, v. 115 n. 2, p. 600–614, 2011.

GOPAL, S.; TANG, X.; PHILLIPS, N.; NOMACK, M.; PASQUARELLA, V.; PITTS, J. Characterizing urban landscapes using fuzzy sets. **Computers, Environment and Urban Systems**, v. 57, p. 212-223, 2016.

GUARIM NETO, G. PLANTAS DO BRASIL – Angiospermas do estado de Mato Grosso – Pantanal. **Acta botanica brasílica**, v. 5, 1991.

GUO, M. LI, J. SHENG, C. XU, J. WU, L. A Review of Wetland Remote Sensing, **Sensors**, v. 17, n. 777, 2017.

HALABISKY, M.; MOSKAL, L. M.; GILLESPIE, A.; HANNAM, M. Reconstructing semi-arid wetland surface water dynamics through spectral mixture analysis of a time series of Landsat satellite images (1984–2011). **Remote Sensing of Environment**, v. 177, p. 171–183, 2016.

HAMADA, S.; OHTA, T. Seasonal variations in the cooling effect of urban green areas on surrounding urban areas. **Urban For Urban Green**, v. 9, p. 15–24, 2010.

HE, C.; GAO, B.; HUANG, Q.; MA, Q.; DOU, Y. Environmental degradation in the urban areas of China: Evidence from multi-source remote sensing data. **Remote Sensing of Environment**, v. 193, p. 65–75, 2017.

HE, C.; GAO, B.; HUANG, Q.; MA, Q.; DOU, Y. Environmental degradation in the urban areas of China: Evidence from multi-source remote sensing data. **Remote Sensing of Environment**, v. 193, p. 65–75, 2017.

HEUNG, B.; HO, H. C.; ZHANG, J.; KNUDBY, A.; BULMER, C. E.; SCHMIDT, M. G. An overview and comparison of machine-learning techniques for classification purposes in digital soil mapping. **Geoderma**, v. 265, p. 62-77, 2016.

HOU, W.; GAO, J.; WU, S.; DAI, E. Interannual variations in growing-season ndvi and its correlation with climate variables in the southwestern Karst region of China. **Remote Sensing**, v. 7, p. 11105–11124, 2015.

HU, D.; CAO, S.; CHEN, S.; DENG, L. FENG, N. Monitoring spatial patterns and changes of surface net radiation in urban and suburban areas using satellite remote-sensing data. **International Journal of Remote Sensing**, v. 38, n. 4, p. 1043-1061, 2017.

HU, T.; YANG, J.; LI, X.; GONG, P. Mapping urban land use by using landsat images and open social data. **Remote Sensing**, v. 8, n. 151, p. 1-18, 2016.

HUETE, A. R. Adjusting vegetation indices for soil influences. **International Agrophysics**, v. 3, p. 367-376, 1988.

HUETE, A. R. DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X. FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195–213, 2002.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Cidades**. Disponível em: <https://cidades.ibge.gov.br/brasil/mt/cuiaba/panorama>, acessado em 02/03/2020.

IGE, S. O.; AJAYI, V. O.; ADEYERI, O. E.; OYEKAN, K. S. A. Assessing remotely sensed temperature humidity index as human comfort indicator relative to landuse landcover change in Abuja, Nigeria. **Spatial Information Research**, v. 25, n. 4, p. 523–533, 2017.

IMEA – Instituto Mato-Grossense de Economia Agropecuária. **Diagnóstico da Piscicultura em Mato Grosso**, FAMATO – Federação da Agricultura e Pecuária do Estado de Mato Grosso, 2014.

INGLIMA, I.; ALBERTI, G.; BERTOLINI, T.; VACCARI, F. P.; GIOLI, B.; MIGLIETTA, F.; COTRUFO, M. F.; PERESSOTTI, A. Precipitation pulses enhance respiration of Mediterranean ecosystems: the balance between organic and inorganic components of increased soil CO₂ efflux. **Global Change Biology**, v. 15, p. 1289–1301, 2009.

INPE - Instituto Nacional de Pesquisas Espaciais. Disponível em: <http://www.dgi.inpe.br/documentacao/satelites/landsat>, acessado em 02/03/2020.

JAAFAR, H. H.; AHMAD, F. A. Time series trends of Landsat-based ET using automated calibration in METRIC and SEBAL: The Bekaa Valley, Lebanon. **Remote Sensing of Environment**, v. 238, 2020.

JEEVALAKSHMI, D. REDDY, S. N.; MANIKIAM, B. Land Surface Temperature Retrieval from LANDSAT data using Emissivity Estimation. **International Journal of Applied Engineering Research**, v.12, n. 20, p. 9679-9687, 2017.

JIANG, Z.; HUETE, A.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, V. 112, n.10, p. 3833–3845, 2008.

JIMÉNEZ-MUÑOZ, J. C.; SOBRINO, J. A. A generalized single-channel method for retrieving land surface temperature from remote sensing data. **Journal of Geophysical Research**, v. 108, n. D22, 2003.

JIMÉNEZ-MUÑOZ, J. C.; SOBRINO, J. A.; SKOKOVIC, D. MATTAR, C. CRISTÓBAL, J. Land Surface Temperature Retrieval Methods From Landsat-8 Thermal Infrared Sensor Data. *IEEE Geoscience and Remote Sensing Letters*, v. 11, n. 10, p. 1840-1843, 2014.

JUSTICE, C. O. TOWNSHEND, J. R. G.; HOLBEN, B. N.; TUCKER, C. J. Analysis of the phenology of global vegetation using meteorological satellite data, **International Journal of Remote Sensing**, v. 6 n.8, p. 1271-1318, 1985.

KALMA, J. D.; MCVICAR, T. R.; MCCABE, M. F. Estimating Land Surface Evaporation: A Review of Methods Using Remotely Sensed Surface Temperature Data. **Surveys in Geophysics**, v. 29, p. 421-469, 2008.

KARLEN, S. R.; ANDERSON, H. B.; VAN DER WAL, R.; HANSEN, B. B. new NDVI measure that overcomes data sparsity in cloud-covered regions predicts annual variation in ground-based estimates of high arctic plant productivity. **Environmental Research Letters** v.13, 2018.

KATO, S., YAMAGUCHI, Y. Analysis of urban heat-island effect using ASTER and ETM+ Data: Separation of anthropogenic heat discharge and natural heat radiation from sensible heat flux. **Remote Sensing of Environment**, v. 99, p. 44 – 54, 2005.

KHALIL, H. A. E. E.; IBRAHIM, A.; ELGENDY, N.; MAKHLOUF, N. Could/should improving the urban climate in informal areas of fast-growing cities be an integral part of upgrading processes? Cairo case. **Urban Climate**, v. 24. p. 63-79, 2018.

KHALAF, A. B.; AL-JIBOURI, A. I. J. Detection land cover changes of the Baquba city for the period 2014-2019 using spectral indices. **Iraqi Journal of Agricultural Sciences**, v. 51, n. 3, p.805-815, 2020.

KLINGBERG, J.; BROBERG, M.; STRANDBERG, B.; THORSSON, P.; PLEIJEL, H. Influence of urban vegetation on air pollution and noise exposure – A case study in Gothenburg, Sweden. **Science of The Total Environment**, v. 599-600, p. 1728–1739, 2017.

KRIEGLER, F. J., MALILA, W. A., NALEPKA, R. F., RICHARDSON, W., Preprocessing transformations and their effects on multispectral recognition. **Proceedings of the Sixth International Symposium on Remote Sensing of the Environment**, Ann Arbor, Michigan, p.97, 1969.

LAI, D.; LIU, W.; GAN, T.; LIU, K.; CHEN. A review of mitigating strategies to improve the thermal environment and thermal comfort in urban outdoor spaces. **Science of the total environment**. v. 661, p. 337-353, 2019.

LANDIS, J.R. KOCH, G. G. A medição da concordância do observador para dados categóricos. **Biometria**. v. 33, p. 159-174, 1977.

LEE, Y.; KIM, S. The Modified SEBAL for Mapping Daily Spatial Evapotranspiration of South Korea Using Three Flux Towers and Terra MODIS Data. **Remote Sensing**, v. 8, 2016.

LI, G.; ZHANG, X.; MIRZAEI, P. A.; ZHANG, J.; ZHAO, Z. Urban heat island effect of a typical valley city in China: Responds to the global warming and rapid urbanization. **Sustainable Cities and Society**, v. 38, n. 736–745, 2018.

LI, K.; CHEN, Y. A genetic algorithm-based urban cluster automatic threshold method by combining VIIRS DNB, NDVI, and NDBI to monitor urbanization. **Remote Sensing**, v. 10, n. 277, p. 1-21, 2018.

LI, M.; ZANG, S.; ZHANG, B.; LI, S. WU, C. A Review of Remote Sensing Image Classification Techniques: the Role of Spatio-contextual Information. **European Journal of Remote Sensing**, v. 47, n. 1, p. 389-411, 2014.

LI, X.; ZHOU, W.; OUYANG, Z.; XU, W.; ZHENG, H. Spatial pattern of greenspace affects land surface temperature: evidence from the heavily urbanized Beijing metropolitan area, China. **Landscape Ecology**, v. 27, p. 887-898, 2012.

LIANG, S. Narrowband to broadband conversions of land surface albedo I Algorithms. **Remote Sensing of Environment**, v. 76, p. 213-238, 2000.

LINDBERG, F. OLOFSON, K. F. G.; SUN, T.; GRIMMOND, C. S.B.; FEIGENWINTER, C. Urban storage heat flux variability explored using satellite, meteorological and geodata. **Theoretical and Applied Climatology**, v. 141 p. 271–284, 2020.

LIN, L.; HAO, Z.; POST, C. J.; MIKHAILOVA, E. A.; YU, K.; YANG, L.; LIU, J. Monitoring land cover change on a rapidly urbanizing island. Using google Earth engine. **Applied Sciences**, v. 10, n. 7336, p. 1-16, 2020.

LIU, J.; FENG, Q.; GONG, J.; ZHOU, J.; LI, Y. Landcover classification of the Yellow River Delta wetland based on multiple end-member spectral mixture analysis and a Random Forest classifier. **International Journal of Remote Sensing**, 37:8, 1845-1867, 2016.

LIU, S.; HUANG, S.; XIE, Y.; WANG, H.; HUANG, Q.; LENG, G.; LI, P. WANG, L. Spatial-temporal changes in vegetation cover in a typical semi-humid and semi-arid region in China: Changing patterns, causes and implications. **Ecological Indicators**, v. 98, p. 462-475, 2019.

LIU, Z.; MENZEL, L. Identifying long-term variations in vegetation and climatic variables and their scale-dependent relationships: A case study in Southwest Germany. **Global and Planetary Change**, v. 147, p. 54–66, 2016.

LUKEŠ, P.; RAUTIAINEN, M.; MANNINEN, T.; STENBERG, P.; MÖTTUS, M. Geographical gradients in boreal forest albedo and structure in Finland. **Remote Sensing of Environment**, v. 152, p. 526-535, 2014.

MA, L.; FU, T.; BLASCHKE, T.; LI, M.; TIEDE, D. ZHOU, Z. MA, X.; CHEN, D. Evaluation of Feature Selection Methods for Object-Based Land Cover Mapping of Unmanned Aerial Vehicle Imagery Using Random Forest and Support Vector

Machine Classifiers. **ISPRS International Journal of Geo-Information**, v. 6, n. 51, 2017. (B)

MA, L.; LI, M.; MA, X.; CHENG, L.; DU, P.; LIU, Y. A review of supervised object-based land-cover image classification, **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 277–293, 2017. (A)

MACHADO, N. G.; BIUDES, M. S.; QUERINO, C. A. S.; DANELICHEN, V. H. M.; SOUZA, M. C. Seasonal and interannual pattern of meteorological variables in Cuiabá, Mato Grosso state, Brazil. **Revista Brasileira de Geofísica**, v. 33, p. 1-12, 2015.

MACHADO, N. G.; FRIEDLANDER, V. A.; SANCHES, L.; BIUDES, M.S. Temperatura e umidade relativa do ar na estação seca em diferentes usos do solo no campus Cuiabá - Bela Vista do IFMT. **Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental**. v. 9, n. 9, p. 2018-2025, 2013.

MACHADO, N.G.; ROCHA, L.A.; SILVA, N. D; DA SILVA, D. F. N.; FLORÊNCIO, F. P.; FERNANDES, T. B. S. Biodiversity in urban green space: a case study in the neotropics. **Nativa**, Sinop, v. 5, n. 5, p. 320-329, 2017.

MACHADO, N. G; BIUDES, M. S.; ANGELINI, L. P.; QUERINO, C. A. S.; ANGELINI, P. C. B. S. Impact of changes in surface cover on energy balance in a tropical city by remote sensing: A study case in Brazil. **Remote Sensing Applications: Society and Environment**, v. 20, n. 100372, 2020.

MAITELLI, G. T. **Uma abordagem tridimensional de clima urbano em área tropical continental: o exemplo de Cuiabá-MT**. 1994. 220f. Tese (Doutorado em Geografia) - Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 1994.

MAITELLI, G.T. Balanço de Energia Estimado Para a Cidade de Cuiabá: Uma Abordagem de Balanço de Energia pelo Método de Bowen. **Ambiente Construído e Patrimônio Sustentável**, v.4, n.1, p. 2010.

MARQUES, H. O.; BIUDES, M. S.; PAVÃO, V. M.; MACHADO, N. G.; QUERINO, C. A. S.; DANELICHEN, V. H. M. Estimated net radiation in an Amazon-Cerrado transition forest by Land 5 TM. **Journal of Applied Remote Sensing**, v 11, n. 4, p. 046020, 2017.

MARTIN, P.; BAUDOUIN, Y.; GACHON, P. An alternative method to characterize the surface urban heat island. **Int J Biometeorol**. v. 59, p. 849–861, 2015.

MAYES, M.T.; MUSTARD, J.F.; MELILLO, J.M. Forest cover change in Miombo Woodlands: Modeling land cover of African dry tropical forests with linear spectral mixture analysis. **Remote Sensing. Environmental**. v. 165, p. 203–215, 2015.

MEKURIAW, T.; GOKCEKUS, H. The impact of expansion on physical environment in Debre Markos Town, Ethiopia. **Civil and Environmental Research**, v. 11, n. 5, 2019.

MENENTI, M.; BASTIAANSEN, W.; VAN EICK, D.; ABD EL KARIM, M. A. Linear Relationships Between Surface Reflectance And Temperature And Their Application To Map Actual Evaporation Of Groundwater. **Advances in Space Research**, v. 9, n. 1, p. 165-176, 1989.

MENESES P.R.; ALMEIDA T. (org.) Introdução ao Processamento de Imagens de Sensoriamento Remoto. Brasília: **UnB/CNPq**, 2012.

MIRA, M.; OLIOSO, A; GALLEGO-ELVIRA, B.; COURAULT, D.; GARRIGUES, S.; MARLOIE, O.; HAGOLLE, O.; GUILLEVIC, P.; BOULET, G. Uncertainty assessment of surface net radiation derived from Landsat images. **Remote Sensing of Environment**, v. 175, p. 251-270, 2016.

MIRANDA, V. F. V. V. PERES, L. F.; FILHO, E. P. M. FRANÇA, J. R. A. Validation of the Surface Energy Balance Retrieved From Remote Sensing Data For the Metropolitan Area Of Rio De Janeiro (MARJ). **Geoscience and Remote Sensing (IGARSS), IEEE International Symposium**, 2018.

MOON, M.; LI, D.; LIAO, W.; RIGDEN, A. J.; FRIEDL, M. A. Modification of surface energy balance during springtime: The relative importance of biophysical and meteorological changes. **Agricultural and Forest Meteorology**, v. 284, 2020.

MORAN, M. S.; JACKSON, R. D.; RAYMOND, L. H.; GAY, L. W.; SLATER, P. N. Mapping Surface Energy Balance Components by Combining Landsat Thematic Mapper and Ground-Based Meteorological Data. **Remote Sensing of Environment**, v. 30, p. 30-77, 1989.

MOREIRA, J. L; AMORIM, M. C. C. T. O clima urbano de Penápolis-SP através da temperatura da superfície e de índices radiométricos. **Geosaberes**, v. 3, p. 190-202, 2016.

MOREIRA FILHO, J. C. C.; TAVARES JUNIOR, J. R. (2016). Avaliação da precisão temática de composições de NDBI, NDVI, NDWI. **Revista Brasileira de Geomática**, v. 4, n. 1, p. 3-14, 2016.

MULLER, C. L. CHAPMAN, L. GRIMMOND, C.S.B. YOUNG, D. T. CAI, X. Review Sensors and the city: a review of urban meteorological networks. **International journal of climatology**, v. 33 n. 7 p. 1585–1600, 2013.

NASCIMENTO, M. T. B.; DA SILVA, J. A. S.; OLIVEIRA, C. W.; MEIRELE, A. C. M.; FERREIRA, L. F. Application of the SEBAL model for determining the net radiation in the Cariri Cearense region. **Journal of Hyperspectral Remote Sensing** v.7, n.5, p.299-305, 2017.

NING, J.; GAO, Z.; XU, X. Effects of land cover change on evapotranspiration in the Yellow River Delta analyzed with the SEBAL model. **Journal of Applied Remote Sensing**, v. 11, n. 1, 2017.

OKE, T.R.; MILLS, G.; CHRISTEN, A.; VOOGT, J.A. Urban Climate. Cambridge University Press, 2017.

OLIOSO, A., BRIOTTET, X., FABRE, S., JACOB, F., MICHEL, A., NATIVEL, S., RIVALLAND, V.; ROUJEAN, J.-L. Relations Between Landsat Spectral Reflectances and Land Surface Emissivity Over Bare Soils. **IEEE International Geoscience and Remote Sensing Symposium**, 2019.

OLIVEIRA, A. L. G; BOAVENTURA, D. R.; MOYSES, A.; AMORIM, D. C. A.; RODRIGUES, R. L. Produção e planejamento do espaço urbano da metrópole matogrossense: análise sobre o acesso as terras urbanizáveis na cidade ilegal segundo os planos diretores. **Revista Baru**, v. 4, n. 1, p. 3-20, 2018.

OLIVEIRA, G. BRUNSELL, N. A.; MORAES, E. C.; BERTANI, G. SANTOS, T. V.; SHIMABUKURO, Y. E.; ARAGÃO, L. E. O. C. Use of MODIS Sensor Images Combined with Reanalysis Products to Retrieve Net Radiation in Amazonia. **Sensors** v.16, 2016.

OLIVEIRA, M. L.; RUFINO, I. A. A.; CUNHA, J. E. B. L.; VANCONCELOS, R. S.; BRITO, H. C. Urban growth dynamics based on surface albedo changes in Petrolina, Brazil. **Acta Scientiarum**, v. 42, p. 1-11, 2020.

OLIVEIRA, S.; ANDRADE, H.; VAZ, T. The cooling effect of green spaces as a contribution to the mitigation of urban heat: A case study in Lisbon. **Building and Environment**, v. 46, p. 2186–2194, 2011.

PANDEY, P. C.; KOUTSIAS, N.; PETROPOULOS, G. P. SRIVASTAVA, P. K.; DOR, E. B. Land use/land cover in view of earth observation: data sources, input dimensions, and classifiers—a review of the state of the art. **Geocarto International**, 2019.

PAVÃO, V. M.; BIUDES, M. S.; MACHADO, N. G.; QUERINO, C. A. S. Effects of solar radiation and correction of surface temperature by net radiation estimates in northern Pantanal. **Journal of Applied Remote Sensing**, v. 12, N. 4, 2018.

PAVÃO, V. M.; NASSARDEN, D. C. S.; PAVÃO, L. L.; MACHADO, N. G.; BIUDES, M. B. Impacto da Conversão da Cobertura Natural em Pastagem e Área Urbana sobre Variáveis Biofísicas no Sul do Amazonas. **Revista Brasileira de Meteorologia**, v. 32, n. 3, p. 343-351, 2017.

PERALBA, O. C.; RIVERA, J. A. Precipitation response to El Niño/La Niña events in Southern South America – emphasis in regional drought occurrences. **Advances in Geosciences**, v. 42, p. 1-14, 2016.

PINHEIRO, C.; LARANJEIRA, M. Análise do ambiente térmico e das condições de ventilação para a definição das funções climáticas na área urbana de Guimarães. **Revista de Geografia e Ordenamento do Território (GOT)**, n.º 4, Centro de Estudos de Geografia e Ordenamento do Território, p. 249-272, 2013.

PHIRI, D.; MORGENROTH, J. Developments in Landsat Land Cover Classification Methods: A Review. **Remote Sensing**, v. 9, n. 967, 2017.

PÔÇAS, I.; PAÇO, T. A.; CUNHA, M.; ANDRADE, J. A.; SILVESTRE, J.; SOUSA, A.; SANTOS, F. L.; PEREIRA, L. S.; ALLEN, R. G. Satellite-based evapotranspiration of a super-intensive olive orchard: Application of METRIC algorithms. **Biosystems Engineering**, v. 128, p. 69-81, 2014.

PONTIUS Jr, R. G.; SHUSAS, E.; MCEACHERN, M. Detecting important categorical land changes while accounting for persistence. **Agriculture, Ecosystems and Environment**, v.101, p. 251-268, 2004.

QI, J. CHEHBOUNI, A.; HUETE, A. R.; KERR, Y. H.; SOROOSHIAN, S. A Modified Soil Adjusted Vegetation Index. **Remote Sensing Environmental**, v. 45, p. 119-126, 1994.

RADHI, H.; FIKRY, F.; SHARPLES, S. Impacts of urbanisation on the thermal behaviour of new built up environments: A scoping study of the urban heat island in Bahrain. **Landscape and Urban Planning**, v. 113, p. 47-61, 2013.

RIBEIRO, H. J.; OLIVEIRA, W. N.; SIQUEIRA, R. V.; DE OLIVEIRA, A. W. N.; DE OLIVEIRA, V. T.; KM, R. G. S. N. Estimativa da evapotranspiração diária para diferentes usos do solo utilizando imagens do satélite Landsat 5. **7º Simpósio de Geotecnologias no Pantanal Jardim/MS**. Embrapa Informática Agropecuária/INPE, p. 513-522, 2018.

RIGO, G., PARLOW, E. Modelling the ground heat flux of an urban area using remote sensing data. **Theoretical and Applied Climatology**, v.90, p.185-199, 2007.

RODRIGUES, L. O.; SOUZA, W. M.; COSTA, V. S. O.; PEREIRA, M. L. T. Influência dos eventos de El Niño e La Niña no regime de precipitação do Agreste de Pernambuco. **Revista Brasileira de Geografia Física**, v. 10, n. 6, p. 1995-2009, 2017.

ROERINK, G. J.; SU, Z.; MENENTI, M. S-SEBI: A Simple Remote Sensing Algorithm to Estimate the Surface Energy Balance. **Physics and Chemistry of the Earth**, v. 25, n. 2. P. 147-157, 2000.

ROMANCINI, S. R. Novas formas de habitat urbano em Cuiabá (MT): os condomínios fechados. **ACTA Geográfica**, Ed. Esp, p. 135-149, 2011.

ROUSE, J.W, HAAS, R.H., SCHEEL, J.A., AND DEERING, D.W. Monitoring Vegetation Systems in the Great Plains with ERTS. **Proceedings, 3rd Earth Resource Technology Satellite (ERTS) Symposium**, vol. 1, p. 48-62, 1974.

ROY, D. P.; WULDER, M. A.; LOVELAND, T. R.; WOODCOCK, C.E.; ALLEN, R. G.; ANDERSON, M. C.; HELDER, D.; IRONS, J. R.; JOHNSON, D. M.; KENNEDY, R.; SCAMBOS, T. A.; SCHOTT, C. B.; SHENG, Y.; VERMOTE, E. F.; BELWARD, A. S.; BLINDSCHADLER, R.; COHEN, W. B.; GAO, F.; HIPPLE, J. D.; HOSTERT, P.; HUNTINGTON, J.; JUSTICE, C. O.; KILIC, A.; KOVALSKYY, V. LEE, Z. P.; LYMBURNER, L.; MASEK, J. G.; MCCORKEL, J.; SHUAI, Y.; TREZZA, R. VOGELMANN, J. Landsat-8: Science and product vision for terrestrial globalchange research. **Remote Sensing of Environment**, v.145, p. 154–172, 2014.

RWANGA, S. S.; NDAMBUKI, J. M. Accuracy assessment of land use/land cover classification using remote sensing and GIS. **International Journal of Geosciences**, v. 8, p. 611-622, 2017.

SABZIPARVAR, A. A.; GHAFHAROKHI, S. M. M.; KHORASANI, H. T. Long-term changes of surface albedo and vegetation indices in north of Iran. **Arabian Journal of Geosciences**, 13:117, p. 1-11, 2020.

SADEGHI, M., JONES, S. B.; PHILPOT, W. D. A linear physically-based model for remote sensing of soil moisture using short wave infrared bands. **Remote Sensing of Environment**, v. 164, p. 66–76, 2015.

SANTOS, F. M. M. S., MUSIS, C. R., NOGUEIRA.J.S., PINTO JUNIOR, O. B., NOGUEIRA, M. C. J. A. Análise da variação higrótérmica ocasionada pela influência da ocupação do solo na cidade de Cuiabá-MT, **Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental**, v. 9, p. 1932-1945, 2013.

SCHMIDT, G.L.; JENKERSON, C.B.; MASEK, J.; VERMOTE, E.; GAO, F. Landsat ecosystem disturbance adaptive processing system (LEDAPS) algorithm description: **U.S. Geological Survey Open-File Report** 2013.

SCHULTZ, M.; VOSS, J.; AUER, M.; CARTER, S.; ZIPF, A. Open land cover from Openstreetmap and remote sensing. **Int J Appl Earth Obs Geoinformation**, v. 63, p. 206-213, 2017.

SHARMA, R., GHOSH, A., JOSHI, P. K. Spatio-temporal footprints of urbanisation in Surat, the Diamond City of India (1990–2009). **Springer Science**, v.185, p. 3313-3325, 2013.

SHOJAEI, P.; GHEYSARI, M.; MYERS, B.; ESLAMIAN, S.; SHAFIEIYOUN, E.; ESMAEILI, H. EFFECT of different land cover/use types on canopy layer air temperature in an urban area with a dry climate. **Building and Environment**, v. 125, p. 451–463, 2017.

SILVA, G. J. A.; ROMERO, M. A. B. Cidades sustentáveis: uma nova condição urbana a partir de estudos aplicados a Cuiabá, capital do estado de Mato Grosso, Brasil. **Ambiente Construído**, v. 13, n. 3, p. 253-266, 2013.

SILVA, G. J. A.; ROMERO, M. A. B. Estudo histórico – ambiental dos processos de produção e reprodução do espaço urbano em Cuiabá – MT. **Caderno de Arquitetura e Urbanismo**, v. 15, n. 17, p. 111-135, 2008.

SILVA, M. P.; TARIFA, J. R. Ritmo da temperatura no clima local da cidade de Cuiabá – Várzea Grande (MT): Uma análise secular (1912 a 2012). **Biodiversidade**, v. 16, n. 2, p. 2-20, 2017.

SILVA, V. A produção da exclusividade: empreendimentos de alto padrão - Cuiabá-MT. **Geosaberes**, v. 6, número especial (3), p. 427 – 438, 2016.

SIQUEIRA, F. M. B.; VILARINHO NETO, C. S. O capital imobiliário e a cidade – uma análise do espaço urbano de Cuiabá como resultado da preparação para a copa do mundo de 2014. **ACTA Geográfica**, v. 6, n. 13, 2012.

SKOKOVIC, D.; SOBRINO, J.A.; JIMENEZ-MUÑOZ, J.C.; SORIA, G.; JULIEN, Y.; MATTAR, C.; CRISTOBAL, J. Calibration and Validation of Land Surface Temperature for Landsat 8—TIRS Sensor. **In Proceedings of the Land product Validation and Evolution**, Frascati, Italy, 28–30 January 2014.

SOBRINO, J. A.; JIMÉNEZ-MUÑOZ, J. C.; PAOLINI, L. Land surface temperature retrieval from LANDSAT TM 5. **Remote Sensing of Environment**, v. 90, p. 434-440, 2004.

SU, Z. The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes. **Hydrology and Earth System Sciences**, v. 6, n. 1, p. 85-99, 2002.

TANG, R.; LI, Z.-L.; CHEN, K.-S.; JIA, Y.; LI, C.; SUN, X. Spatial-scale effect on the SEBAL model for evapotranspiration estimation using remote sensing data. **Agricultural and Forest Meteorology**, v. 174, p. 28–42, 2013.

TANG, R.; LI, Z.-L.; CHEN, K.-S.; JIA, Y.; LI, C.; SUN, X. Spatial-scale effect on the SEBAL model for evapotranspiration estimation using remote sensing data. **Agricultural and Forest Meteorology** v. 174– 175, p. 28– 42, 2013.

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**, v. 71, p. 459-469, 2018.

The 2011 La Niña: So strong, the oceans fell. **Geophysical Research Letters**, v. 39, n. 19, 2012.

UDDIN, S.; AL GHADBAN, A. N.; AL DOUSARI, A.; AL MURAD, M.; AL SHAMROUKH, D. A remote sensing classification for landcover changes and micro-climate in Kuwait. **International Journal of Sustainable Development and Planning**, v. 5, p.367–377, 2010.

U.S. Geological Survey Landsat Surface Reflectance products courtesy of the U.S. Geological Survey **Earth Resources Observation and Science Center**. Versão 2.0, 2019.

U.S. Geological Survey **Landsat—Earth observation satellites U.S. Geological Survey Fact Sheet** 2015–3081. Versão 1.1, 2016.

United Nations – UN. **World urbanization prospects 2018**. Available from: <https://esa.un.org/unpd/wup/>. Acessado em: 05/03/2020.

VALOR, E.; CASELLES, V. Mapping land surface emissivity from NDVI: Application to European, African, and South American areas. **Remote Sensing of Environment**, v. 57, p. 167-184, 1996.

VASCONCELOS, L. C. S. & ZAMPARONI, C. A. G. P. Os efeitos da urbanização no microclima no bairro morada da serra, Cuiabá – MT. **Revista Raega**, v. 23, p. 573-599, 2011.

VASCONCELOS, L. C. S. & ZAMPARONI, C. A. G. P. Os efeitos da urbanização no microclima no bairro morada da serra, Cuiabá – MT. **Revista Raega**, v. 23, p. 573-599, 2011.

VERMOTE, E. F.; JUSTICE, C. CLAVERIE, M; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46-56, 2016.

VERMOTE, E. F.; TANRÉ, D.; DEUZÉ, J. L.; HERMAN, M.; MORCRETTE, J. Second Simulation of the Satellite Signal in the Solar Spectrum, 6S: An Overview. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n 3, p. 675-686, 1997.

VIEIRA, S. Introdução à Bioestatística. 2.ed. Rio de Janeiro: Campus, 1991.

VILANOVA, S. R. F., MAITELLI, G. T. A importância da conservação de áreas verdes remanescentes no centro político administrativo de Cuiabá-MT. **Uniciências**, v. 13, p. 55-71, 2009.

WANG, D.; LIANG, S.; HE, T.; SHI, Q. Estimation of Daily Surface Shortwave Net Radiation From the Combined MODIS Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n 10, p. 5519-5529, 2015.

WANG, L.; GAO, Z.; MIAO, S.; GUO, X.; SUN, T.; LIU, M.; LI, D. Contrasting characteristics of the surface energy balance between the urban and rural areas of Beijing. **Advances in Atmospheric Sciences**, v. 32, p. 505-514, 2015.

WHALLEY, W. R.; LEEDS-HARRISON, P. B.; BOWMAN, G. E. Estimation Of Soil Moisture Status Using Near Infrared Reflectance. **Hydrological Processes**, V. 5, p.321-327, 1991.

WONG, N.H.; JUSUF, S.K.; SYAFII, N.I.; CHEN, Y.X.; HAJADI, N.; SATHYANARAYANAN, H.; MANICKAVASAGAM, Y.V. Evaluation of the impact of the surrounding urban morphology on building energy consumption. **Solar Energy**, v. 85, p. 57–71, 2011.

WU, Z.; DIJKSTRA, P.; KOCH, G. W.; PEÑUELAS, J.; HUNGATE, B. A. Responses of terrestrial ecosystems to temperature and precipitation change: a meta analysis of experimental manipulation. **Global Change Biology**, v. 17, p. 927–942, 2011.

WULDER, M.; WHITE, J. C.; LOVELAND, T. R.; WOODCOCK, C. E.; BELWARD, A. S.; COHEN, W. B.; FOSNIGHT, E. A.; SHAW, J.; MASEK, J. G.; ROY, D. P. The global Landsat archive: Status, consolidation, and direction. **Remote Sensing of environment**, v. 185, p. 271-283, 2016.

XIA, C.; YEH, A. G.-O., ZHANG, A. Analyzing spatial relationships between urban land use intensity and urban vitality at street block level: A case study of five Chinese megacities. **Landscape and Urban Planning**, v. 193, 103669, 2020.

XIONG, Y.; HUANG, S.; CHEN, F.; YE, H.; WANG, C.; ZHU, C. The impacts of rapid urbanization on the thermal environment: A remote sensing study of Guangzhou, South China. **Remote Sensing**, v. 4, p. 2033-2056, 2012.

YANG, J.; QIU, J. The empirical expressions of the relation between precipitable water and ground water vapor pressure for some areas in China. **Scientia Atmospherica Sinica**, v. 20, p. 620-626, 1996.

YANG, L.; JIA, K.; LIANG, S.; WEI, X.; YAO, Y.; ZHANG, X. A Robust Algorithm for Estimating Surface Fractional Vegetation Cover from Landsat Data. **Remote Sensing**, v. 9, n. 857, 2017.

YUAN, W.; WU, S.; HOU, S.; XU, Z.; LU, H. Normalized difference vegetation index-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**, v. 39, p.1-16, 2019.

YUE, J.; TIAN, Q. XU, K.; XU, N. Development of soil moisture indices from differences in water absorption between shortwave-infrared bands. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 154, p. 216–230, 2019.

ZAIATZ, A. P. S. R.; ZOLIN, C. A.; VENDRUSCULO, L. G.; LOPES, T. R.; PAULINO, J. Agricultural land use and cover change in the Cerrado/ Amazon ecotone: A case study of the upper Teles Pires River basin. **Acta Amazonica**, v.48, p. 168-177, 2018.

ZEILHOFER, P.; LIMA, E. B. N. R.; LIMA, G. A. R. Land use effects on water quality in the urban agglomeration of Cuiabá and Várzea Grande, Mato Grosso State, central Brazil. **Urban Water Journal**, v. 7, n. 3, p. 173-186, 2010.

ZHA, Y.; GAO, J.; NI, S. Use of normalised difference built-up index in automatically mapping urban areas from TM imagery. **International journal of remote sensing**, v. 24, p. 583–594, 2003.

ZHANG, C.; HARRISON, P. A.; PAN, X.; LI, H.; SARGENT, I.; ATKINSON, P. M. Scale sequence joint deep learning (SS-JDL) for land use and land cover classification. **Remote Sensing of Environment**, v. 237, p. 1-16, 2020.

ZHAO, F.; HUANG, C.; GOWARD, S. N.; SCHLEEWEIS, K.; RISHMAWI, K.; LINDSEY, M. A.; DENNING, E.; KEDDEL, L.; COHEN, W. B.; YANG, Z.; DUNGAN, L.; MICHAELIS, A. Development of Landsat-based annual US forest disturbance history maps (1986–2010) in support of the North American Carbon Program (NACP). **Remote Sensing of Environment**, v. 209, p. 312–326. 2018.

ZHAO, L.; SHEN, Z.; LI, C.; GUO, M.; SUN, Y.; GAO, L. Evaluating the Estimation of Net Radiation Based on MODIS Data and CoLM: A Case Study in the Tibetan Plateau. **IEEE Journal Of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 12, n. 2, 2019.

ZHENG, L.; ZHAO, G.; DONG, J.; GE, Q.; TAO, J.; ZHANG, X.; QI, Y.; DOUGHTY, R. B.; XIAO, X. Spatial, temporal, and spectral variations in albedo due to vegetation changes in China's grasslands. **ISPRS Journal of photogrammetry and remote sensing**, v. 152, p. 1-12, 2019.

ZHENG, Z.; REN, G.; WANG, H.; DOU, J.; GAO, Z.; DUAN, C.; LI, Y.; NGARUKIYIMANA, J. P.; ZHAO, C.; CAO, C.; JIANG, M.; YANG, Y. Relationship between fine-particle pollution and the urban heat island in Beijing, China: Observational Evidence. **Boundary-Layer Meteorology**, v. 169, p. 93-113, 2018.

ZHOU, W., HUANG, G., CADENASSO, M. L. Does spatial configuration matter? Understanding the effects of land cover pattern on land surface temperature in urban landscapes. **Landscape and urban planning**, v. 102, p. 54–63, 2011.