

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO DE FILOSOFIA E CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOCIÊNCIAS
CURSO DE GRADUAÇÃO EM GEOGRAFIA

Nayara Luisa Werner Moreira

A relação entre a expansão agrícola e os índices biofísicos: uma análise por meio do Google Earth Engine na Bacia Hidrográfica do Alto Parnaíba

Florianópolis

2022

Nayara Luisa Werner Moreira

A relação entre a expansão agrícola e os índices biofísicos: uma análise por meio do Google Earth Engine na Bacia Hidrográfica do Alto Parnaíba

Trabalho Conclusão do Curso de Graduação em Geografia do Centro de Filosofia e Ciências Humanas da Universidade Federal de Santa Catarina como requisito para a obtenção do Título de Bacharel em Geografia
Orientador: Prof. Carlos Antonio Oliveira Vieira, Dr.

Florianópolis

2022

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Moreira, Nayara Luisa Werner

A relação entre a expansão agrícola e os índices biofísicos
: uma análise por meio do Google Earth Engine na Bacia
Hidrográfica do Alto Parnaíba / Nayara Luisa Werner Moreira
; orientador, Carlos Antonio Oliveira Vieira, 2022.

92 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro de
Filosofia e Ciências Humanas, Graduação em Geografia,
Florianópolis, 2022.

Inclui referências.

1. Geografia. 2. alterações no ambiente. 3. fronteira
agrícola. 4. análise multi-temporal. 5. geotecnologias. I.
Vieira, Carlos Antonio Oliveira. II. Universidade Federal
de Santa Catarina. Graduação em Geografia. III. Título.

Nayara Luisa Werner Moreira

A relação entre a expansão agrícola e os índices biofísicos: uma análise por meio do Google Earth Engine na Bacia Hidrográfica do Alto Parnaíba

Este Trabalho Conclusão de Curso foi julgado adequado para obtenção do Título de Bacharel em Geografia e aprovado em sua forma final pelo Curso de Graduação em Geografia.

Florianópolis, 22 de março de 2022.



Documento assinado digitalmente
Lindberg Nascimento Junior
Data: 15/04/2022 17:18:53-0300
CPF: 049.596.139-63
Verifique as assinaturas em <https://v.ufsc.br>

Prof. Lindberg Nascimento Júnior, Dr.
Coordenador do Curso

Banca Examinadora:



Documento assinado digitalmente
Carlos Antonio Oliveira Vieira
Data: 14/04/2022 14:32:33-0300
CPF: 656.973.326-53
Verifique as assinaturas em <https://v.ufsc.br>

Prof. Carlos Antonio Oliveira Vieira, Dr.
Orientador

Universidade Federal de Santa Catarina



Documento assinado digitalmente
Everton da Silva
Data: 18/04/2022 15:21:31-0300
CPF: 686.388.259-00
Verifique as assinaturas em <https://v.ufsc.br>

Prof. Everton da Silva, Dr.
Universidade Federal de Santa Catarina



Documento assinado digitalmente
Francisco Henrique de Oliveira
Data: 18/04/2022 14:47:12-0300
CPF: 206.605.288-43
Verifique as assinaturas em <https://v.ufsc.br>

Prof. Francisco Henrique de Oliveira, Dr.
Universidade do Estado de Santa Catarina

AGRADECIMENTOS

Agradeço, primeiramente, à minha mãe, Maria Isabel, e meu pai, Sebastião, que sempre se dedicaram aos filhos, dando todo o suporte necessário para que realizemos nossos sonhos. Meu maior orgulho é ser filha de vocês.

Aos meus irmãos, Carlos e Ademir, por serem meus melhores e mais antigos parceiros.

Às amizades que fui desenvolvendo ao longo da vida e, apesar do tempo e da distância, se mantiveram presentes. Agradeço especialmente à Lídia, Fabiana, Débora, Júlia, Gabriella, Isabela, Andreza, Bárbara, Rodrigo, Pizetta, Laura, Vitor, Patrícia, Daniel e Júlio.

Ao Gabriel, por todo o carinho e companheirismo.

Ao meu orientador, Carlos Vieira, pela paciência e disponibilidade durante o processo de elaboração deste trabalho.

À Universidade Federal de Santa Catarina, que me acolheu durante anos e me fez geógrafa.

RESUMO

O Matopiba apresentou nos últimos anos um notável crescimento devido à expansão da atividade agropecuária na região. A alteração do uso e cobertura do solo tem estreita relação com o clima, que, por sua vez, é de grande importância para o plantio e a vida humana, sendo seu estudo e monitoramento necessário para a preservação e manutenção do ambiente. Considerando a extensão da área em análise, o Sensoriamento Remoto se configura como uma ferramenta essencial neste tipo de estudo. Dessa forma, levando em consideração a relevância deste território para o país, bem como o seu potencial em modificar o balanço energético e hídrico local, este trabalho tem como objetivo verificar, por meio da utilização do Google Earth Engine, se houve variações significativas nos índices biofísicos (Índice de Vegetação por Diferença Normalizada, temperatura da superfície e precipitação) da Bacia Hidrográfica do Alto Parnaíba devido ao aumento de áreas voltadas à agricultura e pastagem, bem como avaliar a utilização desta plataforma no processamento dos dados e suporte à análise. Os resultados obtidos revelam que, simultaneamente à conversão de áreas naturais para uso agrícola, houve elevação da temperatura da superfície e diminuição do índice de vegetação e da precipitação, implicando, possivelmente, na dinâmica da área analisada. Por fim, o GEE mostrou-se de grande eficiência, realizando os procedimentos de forma rápida e satisfatória.

Palavras-chave: análise multi-temporal; fronteira agrícola; alterações no ambiente; geotecnologias.

ABSTRACT

Matopiba has shown remarkable growth due to the expansion of agricultural activity in the region in recent years. Changes in land use is closely related to the climate, which is also very important for agriculture and human life, and its study and monitoring is necessary for the preservation and maintenance of the environment. Because of its huge land extension under analysis, Remote Sensing is taken as an essential tool for this kind of research. Thus, considering the relevance of this territory for Brazil, as well as, its potential to modify the local energy and water balance, this work aims to verify, by Google Earth Engine, if there were significant variations in the biophysical indices (Normalized Difference Vegetation Index, land surface temperature and precipitation) of Alto Parnaíba Watershed due to increases in areas used to agriculture and pasture. Furthermore, the GEE is evaluated for its use and performance in data processing and analysis support. The results obtained show that, simultaneously with the transformation of natural areas for agricultural use, there was an increase in land surface temperature and a decrease in vegetation index and precipitation, possibly implying in the dynamics of the analyzed area. Finally, the GEE proved to be highly efficient, performing the procedures quickly and satisfactorily.

Palavras-chave: multi-temporal analysis; agricultural frontier; changes in the environment; geotechnologies.

LISTA DE FIGURAS

Figura 1 – Localização da área de estudo	29
Figura 2 – Hidrografia da BH Parnaíba	30
Figura 3 – Vegetação da BH do Alto Parnaíba.....	31
Figura 4 – Clima na BH do Alto Parnaíba	32
Figura 5 – Unidades de Conservação na BH do Alto Parnaíba.....	33
Figura 6 – Fluxograma	35
Figura 7 – Uso e cobertura do solo em 2001	45
Figura 8 – Uso e cobertura do solo em 2019	46
Figura 9 – Áreas que sofreram alteração de uso e cobertura do solo entre 2001 e 2019	48
Figura 10 – Média de NDVI em 2001	51
Figura 11 – Média de NDVI em 2019	52
Figura 12 – Área amostral de vegetação densa, rala e uso agrícola	54
Figura 13 – Média da temperatura da superfície em 2001	58
Figura 14 – Média da temperatura da superfície em 2019.....	59
Figura 15 – Média da precipitação acumulada mensal em 2001	62
Figura 16 – Média da precipitação acumulada mensal em 2019	63

LISTA DE GRÁFICOS

Gráfico 1 – Série temporal da área ocupada por classe de uso e cobertura do solo entre 2001 e 2019	50
Gráfico 2 – Série temporal da média anual de NDVI.....	56
Gráfico 3 – Série temporal da média anual de temperatura da superfície	61
Gráfico 4 – Série temporal da média anual de precipitação acumulada mensal	65

LISTA DE QUADROS

Quadro 1 – Generalização e nome das classes do MapBiomas	37
Quadro 2 – Reclassificação dos <i>pixels</i> e os tipos de alteração de uso e cobertura do solo ocorridos entre 2001 e 2019	38

LISTA DE TABELAS

Tabela 1 – Intervalos utilizados para a reclassificação da imagem de NDVI	40
Tabela 2 – Intervalos utilizados para a reclassificação da imagem de temperatura da superfície.....	42
Tabela 3 – Intervalos utilizados para a reclassificação da imagem de precipitação acumulada.....	43
Tabela 4 – Quantificação das áreas ocupadas por uso e cobertura do solo em cada ano e a diferença obtida entre 2001 e 2019.....	47
Tabela 5 – Quantificação das áreas que sofreram alteração de uso e cobertura do solo entre 2001 e 2019.....	49
Tabela 6 – Quantificação das áreas ocupadas por intervalo de NDVI em cada ano e a diferença obtida entre 2001 e 2019.....	55
Tabela 7 – Quantificação das áreas ocupadas por intervalo de temperatura da superfície em cada ano e a diferença obtida entre 2001 e 2019.....	60
Tabela 8 – Quantificação das áreas ocupadas por intervalo de precipitação acumulada mensal em cada ano e a diferença obtida entre 2001 e 2019	64

LISTA DE SIGLAS

- A – Área agrícola
- ANA – Agência Nacional de Águas
- APA – Área de Proteção Ambiental
- API – *Application Programming Interface* (Interface de programação de aplicação)
- ATDB – *Algorithm Theoretical Basis Document* (Documento Base Teórico do Algoritmo)
- BA – Bahia
- BH – Bacia Hidrográfica
- CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
- CRU Ts – *Climatic Research Unit Time-Series* (Série Temporal da Unidade de Pesquisa Climática)
- D – Vegetação densa
- ESEC – Estação Ecológica
- EVI – *Enhanced Vegetation Index* (Índice de Vegetação Melhorado)
- GEE – *Google Earth Engine*
- IB – Índices Biofísicos
- IDE – *Integrated Development Environment* (Ambiente de Desenvolvimento Integrado)
- INPE – Instituto Nacional de Pesquisas Espaciais
- IV – Índice de Vegetação
- IVP – Infravermelho próximo
- JRA55 – Japanese 55-year Reanalysis (Reanálise japonesa de 55 anos)
- km² – Quilômetros quadrados
- MA – Maranhão
- METRIC – Mapping EvapoTranspiration at high Resolution with Internalized Calibration (Mapeamento da Evapotranspiração em alta Resolução com Calibração Internalizada)
- mm – Milímetros
- MODIS – *Moderate Resolution Imaging Spectroradiometer* (Espectrorradiômetro de Imageamento de Moderada Resolução)
- NASA – *National Aeronautics and Space Administration* (Administração Nacional da Aeronáutica e Espaço)

NDVI – *Normalized Difference Vegetation Index* (Índice de Vegetação por Diferença Normalizada)

OC – Observatório do Clima

PARNA – Parque Nacional

PI – Piauí

PIB – Produto Interno Bruto

Pr – Precipitação

QA – *Quality Assessment* (Avaliação de Qualidade)

R – Vegetação rala

REM – Radiação eletromagnética

SciELO – *Scientific Electronic Library Online* (Biblioteca Eletrônica Científica Online)

SDS – *Science Data Sets* (Conjuntos de Dados Científicos)

SEBAL – *Surface Energy Balance Algorithm for Land* (Algoritmo de Balanço de Energia da Superfície para Terra)

SEEG – Sistema de Estimativas de Emissões de Gases de Efeito Estufa

SIG – Sistema de Informação Geográfica

SR – Sensoriamento Remoto

TM – *Thematic Mapper* (Mapeador Temático)

TO – Tocantins

TS – Temperatura da superfície

T1 – Tempo 1 (2001)

T2 – Tempo 2 (2019)

UC – Unidade de Conservação

UCS – Uso e Cobertura do Solo

UFSC – Universidade Federal de Santa Catarina

V – Vermelho

°C – Grau Celsius

SUMÁRIO

1	INTRODUÇÃO	15
1.1	OBJETIVOS	16
1.1.1	Objetivo Geral	17
1.1.2	Objetivos Específicos	17
2	REFERENCIAL TEÓRICO	18
2.1	SENSORIAMENTO REMOTO	18
2.2	GOOGLE EARTH ENGINE (GEE)	20
2.2.1	MapBiomass	22
2.3	ANÁLISE DA DINÂMICA DE UMA ÁREA POR MEIO DO SR	23
2.3.1	Sensor MODIS	27
3	CARACTERIZAÇÃO DA ÁREA DE ESTUDO	28
4	PROCEDIMENTOS METODOLÓGICOS	34
4.1	PERÍODO ANALISADO.....	35
4.2	USO E COBERTURA DO SOLO (UCS).....	36
4.3	ÍNDICES BIOFÍSICOS (IB).....	39
4.3.1	Índice de Vegetação (IV)	39
4.3.2	Temperatura da Superfície (TS)	41
4.3.3	Precipitação (Pr)	42
5	RESULTADOS E DISCUSSÃO	44
5.1	QUANTO AO USO E COBERTURA DO SOLO	44
5.2	QUANTO AO ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA 50	
5.3	QUANTO À TEMPERATURA DA SUPERFÍCIE	57
5.4	QUANTO À PRECIPITAÇÃO	61
5.5	QUANTO AO GEE.....	65
5.6	LIMITAÇÕES DA PESQUISA.....	66
6	CONCLUSÃO	68

REFERÊNCIAS	70
Apêndice A – <i>Script</i> de uso e cobertura do solo	76
Apêndice B – <i>Script</i> de NDVI	78
Apêndice C – <i>Script</i> do gráfico de NDVI	81
Apêndice D – <i>Script</i> da temperatura da superfície	83
Apêndice E – <i>Script</i> do gráfico da temperatura da superfície	86
Apêndice F – <i>Script</i> da precipitação	88
Apêndice G – <i>Script</i> do gráfico de precipitação	91
Anexo A – Legenda da Coleção 5 do MapBiomias (2020)	92

1 INTRODUÇÃO

A área denominada Matopiba, composta por parte dos estados do Maranhão (MA), Tocantins (TO), Piauí (PI) e Bahia (BA), totalizando uma extensão de mais de 73 milhões de hectares, se configura como a nova fronteira agrícola do país. Desde o fim do século XX, a região apresenta um significativo crescimento devido à expansão da atividade agropecuária, sendo responsável por 11% do total de soja produzido no país na safra de 2017/2018 (EMBRAPA, 2018).

A ocupação do Matopiba é semelhante à ocorrida no Centro Oeste, segundo Bolfe *et al.* (2016), por apresentar características favoráveis à agricultura intensiva, como a disponibilidade de terras propícias para a mecanização e cultivos tecnificados desde o início, garantindo uma alta produtividade. Tais fatores, somados às políticas agrícolas convenientes, asseguraram o enriquecimento da região, indicado pelo aumento do Produto Interno Bruto (PIB).

A expansão se deu tanto sobre áreas de pastagem natural (vegetação campestre natural), vegetação florestal e mosaicos de agropecuária e remanescentes de vegetação florestal quanto sobre áreas que haviam previamente sofrido alterações antrópicas, sendo Maranhão e Piauí os dois estados da região que mais converteram áreas naturais em agricultura de larga escala nos últimos anos (BOLFE *et al.*, 2016). Encontra-se no sul maranhense e sudoeste piauiense, junto de um município de Tocantins, uma das duas zonas de alta produção de soja no Matopiba, entre 1990 e 2015, apontadas por Araújo (2018). Ela é abrangida em grande parte pela Bacia Hidrográfica (BH) do Parnaíba, mais especificamente pela sub-bacia do Alto Parnaíba. A outra zona é localizada no extremo oeste baiano e, por ser um mais antiga e centro de destaque na região, é objeto de estudo de pesquisadores que buscam compreender as características e dinâmicas deste local.

Diversos trabalhos indicam que o uso e cobertura do solo tem estreita relação com o balanço energético, influenciando nos índices biofísicos (IB), na circulação atmosférica e na dinâmica climática, no balanço hídrico, entre outros elementos (IDEIÃO, 2009; MARTINS *et al.*, 2015; CUNHA *et al.*, 2012). E, em contrapartida, tais aspectos em condições adequadas são de grande importância para, além do crescimento e desenvolvimento das plantas, a vida humana. Dessa forma, é fundamental estudar e monitorar os componentes do balanço de energia para poder compreender e diagnosticar a situação da área em análise, se tornando

um instrumento para a compreensão, preservação e manutenção desse espaço (IDEIÃO, 2009).

Em análises de grandes áreas, especialmente quando se trata de escala regional ou global, o Sensoriamento Remoto (SR) se configura como uma ferramenta essencial para esse tipo de estudo por ser, como especificam Meneses e Almeida (2012), “[...] *uma ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres*”. Assim, diversos parâmetros relacionados ao ambiente podem ser obtidos por meio do monitoramento via satélite, como a temperatura da superfície, o índice de vegetação, o albedo, entre outros.

Com o avanço da tecnologia, novos sensores foram sendo elaborados, softwares de Sistema de Informação Geográfica (SIG) atualizados e novas abordagens metodológicas de processamento digital de imagens estudadas. Um exemplo é o *Google Earth Engine* (GEE), uma plataforma gratuita com dados salvos em nuvem, que permite uma análise espaço-temporal em escala global (GORELICK *et al.*, 2017).

Levando em consideração a importância da região para o país, bem como o seu potencial em modificar a dinâmica da área, este trabalho visa verificar se houve mudanças significativas em alguns dos índices biofísicos na BH do Alto Parnaíba com a expansão da fronteira agrícola nos últimos anos. A metodologia consiste na análise dos índices biofísicos (índice de vegetação, temperatura da superfície e precipitação) e sua relação com a evolução do uso e cobertura do solo por meio das diferenças visualmente observadas nas imagens, conferindo, além disso, os valores estatísticos obtidos e a tendência dos dados ao longo do tempo representados em gráfico. Junto disso, será testada e avaliada a utilização do GEE para este tipo de estudo.

1.1 OBJETIVOS

Os objetivos desta pesquisa são subdivididos em um objetivo geral e quatro objetivos específicos.

1.1.1 Objetivo Geral

Avaliar a viabilidade de utilização da plataforma *Google Earth Engine* na análise da distribuição espaço-temporal de índices biofísicos na Bacia Hidrográfica do Alto Parnaíba e sua relação com o uso e cobertura do solo nos anos de 2001 e 2019.

1.1.2 Objetivos Específicos

- Detectar mudanças no uso e cobertura do solo na região nos anos de 2001 e 2019;
- Analisar o índice de vegetação, temperatura da superfície e os dados de precipitação na região em 2001 e 2019;
- Verificar a relação entre as modificações dos índices biofísicos e do uso e cobertura do solo.

2 REFERENCIAL TEÓRICO

Nesta seção, busca-se fundamentar a pesquisa com base nos trabalhos já existentes. Tais trabalhos foram obtidos ao procurar pelas palavras chave no Portal de Periódicos¹ e no Catálogo de Teses e Dissertações² da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), no Repositório Institucional da Universidade Federal de Santa Catarina (UFSC)³, no *Scientific Electronic Library Online* (SciELO)⁴, no Google Acadêmico⁵ e também livros físicos disponíveis na Biblioteca Universitária da UFSC.

2.1 SENSORIAMENTO REMOTO

Em Meneses e Almeida (2012), o sensoriamento remoto é definido sendo *“uma ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres”*. Desta forma, é frisada a especificidade desta Geotecnologia que, para sê-la, deve obter imagens a partir da detecção e medição da radiação eletromagnética (REM) que interage com os objetos. Logo, são considerados produtos do SR as imagens obtidas através de sensores terrestres, aéreos e orbitais, como as de satélite, radar e fotografia aérea, os quais produzem informação e possuem valor agregado após realização de análises temporais e espaciais dos fenômenos representados nas imagens que ocorrem na superfície do planeta Terra.

Jensen (2009) afirma que o advento do SR se deu a partir da compreensão do comportamento da REM, bem como do processo de captura e fixação da imagem de uma cena. O passo inicial para a ótica moderna e a origem da fotografia foi dado com a publicação da obra de Isaac Newton no final do século XVII, denominada *“Nova Teoria sobre Luz e Cores”*, no qual foi apresentado o conceito da composição da luz branca aceito até os dias atuais. Já para a captação da cena observada, há tempos era conhecida e manuseada a câmera escura. A fixação da imagem

1 Disponível em: <http://www.periodicos.capes.gov.br/>

2 Disponível em: <https://catalogodeteses.capes.gov.br/catalogo-teses/>

3 Disponível em: <https://repositorio.ufsc.br/>

4 Disponível em: <https://www.scielo.org/>

5 Disponível em: <https://scholar.google.com.br/>

observada, entretanto, só ocorreu no decorrer do século XIX, possibilitando, então, a sua aplicação na fotografia de seres, objetos e paisagens. No SR, especificamente, as imagens foram captadas inicialmente por meio de voos de balões ainda no século XIX, e, posteriormente, pipas, foguetes, pombos, planadores, veículos aéreos e satélites.

Desde seu surgimento, o SR vem evoluindo constantemente com o intuito de melhorar cada vez mais a qualidade de seus produtos. Nas guerras, o mapeamento da superfície terrestre por meio do levantamento aéreo teve grande importância para o reconhecimento fotográfico militar e, durante e após essa época, diversos avanços tecnológicos foram conquistados (JENSEN, 2009). A década de 1960, por exemplo, foi marcada por um grande desenvolvimento na área espacial, o que proporcionou a origem do SR a nível orbital. Este momento foi significativo pois, com isso, foi possível obter dados da superfície da Terra de forma sistemática em um curto período de tempo e em diferentes bandas espectrais simultaneamente (MENESES e ALMEIDA, 2012).

A informatização e a formulação das imagens em formato digital, por sua vez, garantiram um progresso expressivo às Geotecnologias de modo geral ao utilizar sistemas computadorizados como instrumento de manuseio, visualização, processamento e análise dos dados de forma rápida e eficiente. Surgem, então, o Geoprocessamento e o Sistema de Informações Geográficas. O primeiro é definido por Rocha (2007) como sendo uma ferramenta transdisciplinar de processamento de dados geográficos que, com o objetivo de solucionar problemas, “integra várias disciplinas, equipamentos, programas, processos, entidades, dados, metodologias e pessoas para coleta, tratamento, análise e apresentação de informações associadas a mapas digitais georreferenciados”. Já o SIG, de acordo com Rocha (2007), está inserido no Geoprocessamento, sendo capaz de adquirir, armazenar, processar, analisar e exibir as informações. Matias (2001) realça, entretanto, que este instrumento não se resume apenas a aspectos técnicos, mas também a produção de informação por meio da interpretação e análise dos dados realizada pelo analista, cabendo a este a noção de propósito de seu uso para a compreensão de fenômenos geográficos, sendo, portanto, um instrumento estratégico para interesses públicos e/ou privados, cujo potencial de aplicação é vasto e relevante.

Com a inovação tecnológica e a elaboração de plataformas orbitais, novos avanços e capacidades foram possibilitadas. Devido a característica dos satélites de

sistematicamente coletarem imagens periódicas de um mesmo local, o acompanhamento e monitoramento remoto de objetos foi facilitado, principalmente quando se trata de áreas extensas ou de difícil acesso. Este é, segundo Meneses e Almeida (2012), o fator principal que fez com que os seus produtos fossem os mais eficientes para utilização nas análises ambientais. Para além desta aplicação, Novo (2010) destaca diversas outras:

Urbanas (inferência demográfica, cadastro, planejamento urbano, suporte ao setor imobiliário). Agrícolas: condição das culturas, previsão de safras, erosão de solos. Geológicas: minerais, petróleo, gás natural. Ecológicas (regiões alagadas, solos, florestas, oceanos, águas continentais). Florestais (produção de madeira, controle de desflorestamento, estimativa de biomassa). Cartográficas (mapeamento topográfico, mapeamento temático, atualização de terra). Oceanográficas (produtividade primária, monitoramento de óleo, estudos costeiros, circulação oceânica etc.) Hidrológicas (mapeamento de áreas afetadas por inundações, avaliação de consumo de água por irrigação, modelagem hidrológica). Limnológicas (caracterização da vegetação aquática, identificação de tipos de água, avaliação do impacto do uso da terra em sistemas aquáticos). Militares, e muitas outras. (NOVO, 2010)

O progresso do SR nas últimas décadas não se restringiu apenas à melhoria da qualidade das imagens, mas também no desenvolvimento e aperfeiçoamento da capacidade de tratamento, armazenamento, processamento e produção dos dados, bem como de *hardwares*, *softwares* e de abordagens metodológicas (MATIAS, 2001; NOVO, 2010). Apesar do caráter positivo de tais avanços, Gorelick *et al.* (2017) destaca que essa ciência tem se tornado cada vez mais restrita devido à necessidade de conhecimento técnico e utensílios capazes de adquirir, armazenar, processar, etc., grande quantidade de dados, restringindo seu uso aos profissionais da área que detém computadores de alto desempenho.

2.2 GOOGLE EARTH ENGINE (GEE)

De acordo com Gorelick *et al.* (2017), o *Google Earth Engine*, com a proposta de agregar no desenvolvimento científico e tecnológico da humanidade, tem como objetivo principal possibilitar e facilitar, tanto aos cientistas do SR quanto às pessoas que não possuem técnica e/ou recursos instrumentais, análises em escala global, como o monitoramento, rastreamento e manejo do ambiente terrestre e de problemas que afetam a sociedade. Além disso, visa o compartilhamento de resultados entre os pesquisadores e público em geral, assim como aconteceu com o trabalho de Hansen *et al.* (2013 apud GORELICK *et al.*, 2017) sobre a modificação

da vegetação global que derivou muitas outras pesquisas utilizando a plataforma em diversas áreas, visto que:

Uma vez que um algoritmo é desenvolvido no Earth Engine, usuários podem produzir produtos de dados sistemáticos ou implantar aplicativos interativos apoiados pelos recursos do Earth Engine, sem necessitar ser um especialista em desenvolvimento de aplicativos, programação da Web ou HTML. (GORELICK *et al.*, 2017, tradução nossa)

O GEE trata-se de uma plataforma em nuvem, que consiste em um catálogo de dados continuamente atualizado, que armazena *datasets* geoespaciais de acesso público e um serviço computacional realizado pelos servidores do Google, no qual o processamento é realizado de forma paralela e distribuída. Os usuários conseguem acessar e analisar os dados por meio de uma interface de programação de aplicativos (*Application Programming Interface* - API) associada a um ambiente de desenvolvimento integrado (*Integrated Development Environment* - IDE) que permite a prototipagem e visualização dos resultados. Para a escrita dos algoritmos, as linguagens suportadas são *JavaScript* e *Python* (GORELICK *et al.*, 2017).

Dentre as aplicações deste sistema, Gorelick *et al.* (2017) cita pesquisas feitas sobre a detecção de mudança em recursos terrestres, estimativas de rendimento agrícola, mapeamento urbano e agrícola, bem como de inundações e outros fenômenos. Aponta também aplicativos de terceiros realizados com base no GEE, como o *Map of Life* (2016) que analisa a distribuição do habitat de variadas espécies, o *Climate Engine* (2016) que faz monitoramento do clima e, por fim, o *Collect Earth* (2016) para mudanças de uso e cobertura do solo. É importante acrescentar, além desses, o MapBiomass, projeto desenvolvido pelo Sistema de Estimativas de Emissões de Gases de Efeito Estufa (SEEG) do Observatório do Clima (OC) iniciado em 2015 para a classificação anual da cobertura e uso do solo do Brasil de forma rápida, confiável e com baixo custo (SEEG, 2019).

Desde o lançamento, diversos pesquisadores têm utilizado o GEE para desenvolver trabalhos e, paralelamente a isso, avaliar sua eficiência. Ferreira *et al.* (2017) utilizou esta tecnologia para análise sazonal das temperaturas superficiais no estado de Santa Catarina, concluindo que ela é “[...] inovadora para processamento de dados, que permite análises multitemporais e espaciais de uma forma rápida e eficiente”. Bourscheidt (2017) destaca seu caráter positivo ao aplicar regressão linear em uma grande quantidade de dados e obter os resultados rapidamente. Ganem (2017) caracteriza a plataforma como ágil ao realizar classificações de

cobertura do solo em um curto período. Sua eficiência é reforçada por Guerra, Schultz e Sanches (2017) ao informarem que em aproximadamente 2 horas foram processadas 1192 imagens do *Moderate Resolution Imaging Spectroradiometer* (MODIS), permitindo discriminar áreas de agricultura anual em 13 anos safra. Por fim, Taberner (2018) demonstra a utilidade do Earth Engine ao realizar um processamento para estimar variáveis biofísicas globais em 15 anos também com imagens do sensor MODIS. Além disso, defende que suas limitações relativas aos algoritmos que ainda não foram adicionados na plataforma serão superadas com o tempo, devido ao fato dos usuários também desenvolverem algoritmos que podem ser implementados, aumentando cada vez mais a abrangência de aplicações desta ferramenta.

2.2.1 MapBiomias

O Projeto de Mapeamento Anual do Uso e Cobertura da Terra no Brasil (MapBiomias) é uma iniciativa multi-institucional promovido pelo Sistema de Estimativas de Emissões e Remoções de Gases de Efeitos Estufa do Observatório do Clima. Iniciado em 2015, o projeto conta com seis coleções, sendo a Coleção 6, que cobre o período de 1985 a 2020, a mais recente, lançada em agosto de 2021.

Com o objetivo de contribuir no entendimento da dinâmica de uso e cobertura do solo (UCS) no Brasil, o MapBiomias utiliza dados dos satélites Landsat 5, 7 e 8 e a plataforma do Google Earth Engine na geração de uma série histórica de mapas anuais de UCS, garantindo o processamento de dados em larga escala a partir de um método barato, rápido, confiável e colaborativo (SOUZA *et al.*, 2020).

Apesar de haver variadas fontes de dado de uso e cobertura do solo, este projeto merece destaque por diversos motivos, entre eles: todos os seus produtos estão gratuitamente disponibilizados; o processamento é feito em nuvem através da plataforma GEE; as imagens utilizadas possuem resolução espacial de 30 metros; e, por fim, é feita uma classificação para cada bioma ou tema transversal (pastagem, agricultura, zona costeira e área urbana) que posteriormente são integrados em um mapa único (SOUZA *et al.*, 2020). Este último fator citado é especialmente importante pois, visto que a resposta espectral de um mesmo objeto pode ser diferente em cada bioma, são consideradas as especificidades encontradas em cada um deles.

Cabe mencionar também o detalhamento dos produtos gerados, com a distinção das classes de UCS a partir de um sistema hierárquico. É explicitado no *Algorithm Theoretical Basis Document* (ATDB) da Coleção 5⁶, documento que detalha a elaboração dos mapas e algoritmos, que a classe de nível 1 “Floresta”, por exemplo, é subdividida no nível 2 em “Floresta Plantada” e em “Floresta natural” que, por sua vez, é composta por “Formação florestal”, “Formação savânica” e “Mangue” no nível 3. Já a classe “Agropecuária” (nível 1) se divide em “Pastagem”, “Agricultura” e “Mosaico de agricultura e pastagem” no nível 2. Destes, apenas a “Agricultura” possui divisão de nível 3, resultando em “Lavoura temporária” e “Lavoura perene”. Por fim, no nível 4, a “Lavoura temporária” é constituída por “Soja”, “Cana” e “Outras lavouras temporárias”. Há, além disso, as classes de UCS de nível 1 “Formação natural não florestal”, “Áreas não vegetadas”, “Corpos d’água” e “Não observado” que, nos níveis subsequentes, se separam em outras classes (MAPBIOMAS, 2020).

Outras iniciativas lideradas pela equipe do MapBiomas são o MapBiomas Amazônia, MapBiomas Chaco, MapBiomas Mata Atlântica, MapBiomas Pampa, MapBiomas Árida e MapBiomas Alerta⁷. Com exceção dos dois últimos, estes projetos têm como objetivo o mapeamento de uso e cobertura do solo anual referente aos territórios que os nomeiam, semelhante ao feito para o Brasil. Já o MapBiomas Alerta se refere à validação e ao refinamento de alertas emitidos de áreas desmatadas, degradadas ou regeneradas. Por fim, o MapBiomas Árida visa mitigar os processos da desertificação no nordeste brasileiro a partir do monitoramento pelas imagens de satélite.

2.3 ANÁLISE DA DINÂMICA DE UMA ÁREA POR MEIO DO SR

Desde sua origem, o ser humano mantém diferentes relações com o meio em que vive, modificando-o e extraindo riquezas para seu benefício. Algumas dessas ações, entretanto, ameaçam sua existência devido à interdependência dessa espécie com o meio ambiente. Na produção agrícola, por exemplo, a utilização dos recursos naturais é imprescindível. Mesmo assim, na sua forma intensiva, o solo e a água são constantemente prejudicados pela atividade, seja por causa da utilização

6 Legenda da coleção apresentada no Anexo A.

7 Descrição dos projetos e *link* de acesso disponível em: <https://mapbiomas.org/initiatives>

de insumos químicos ou da mudança do uso e cobertura do solo, acarretando alterações na dinâmica da área que podem ser prejudiciais ao ecossistema em diferentes escalas e, conseqüentemente, aos seres vivos (TRIGUEIRO *et al.*, 2003).

Tucci e Mendes (2006) e Santos *et al.* (2007) afirmam que o desflorestamento para dar origem a culturas anuais produz um grande impacto por sazonalmente retirar a proteção do solo (fase de plantio). As culturas consideradas permanentes, por sua vez, também geram conseqüências ao meio, principalmente durante o processo de transformação da cobertura do solo, provocando alterações em seu equilíbrio. Com o passar do tempo e o desenvolvimento do cultivo, a dinâmica da área tende a se estabelecer de uma nova forma devido à situação a qual foi submetida. Isso acontece pois, segundo os autores, a vegetação tem papel fundamental no balanço de energia. Sua supressão pode afetar o microclima de diferentes modos (IDEIÃO, 2009) além de promover, entre outros efeitos, alterações no ciclo hidrológico e seus fluxos envolvidos, aumento do escoamento superficial e aceleração considerável da erosão dos solos, o qual Santos *et al.* (2007) alega ser a causa principal responsável pela degradação de terras produtivas.

O balanço energético representa a energia que entra e sai de um sistema. No sistema terrestre, este balanço consiste, resumidamente, na diferença entre a radiação proveniente do Sol e a radiação refletida e emitida pela Terra de volta ao espaço, considerando os fluxos de energia que ocorrem no interior da atmosfera, a evapotranspiração e a transmissão. Os componentes necessários para o cálculo podem ser coletados em campo, mas o trabalho pode se tornar árduo e custoso quando se trata de áreas extensas (GOMES *et al.*, 2009).

Tendo em vista as desvantagens de se medir a energia eletromagnética na superfície, o SR surge como interessante alternativa e vem obtendo resultados satisfatórios. Liberato *et al.* (2011), por exemplo, estimou o saldo de radiação através do *Surface Energy Balance Algorithm for Land* (SEBAL) em uma imagem capturada pelo sensor *Thematic Mapper* (TM) do satélite Landsat 5 na qual é possível observar duas grandes áreas distintas: uma com cobertura vegetal e outra com pastagem. Posteriormente, comparou os dados obtidos com os da estação micrometeorológica e concluiu que são correspondentes. Giongo (2011) fez semelhante ao utilizar imagens do mesmo sensor para estimar o balanço de energia e a evaporação real diária por meio do algoritmo *Mapping EvapoTranspiration at high Resolution with Internalized Calibration* (METRIC) na Bacia Hidrográfica do Rio

Corumbataí, em São Paulo (SP), e compará-los com os dados obtidos em superfície na estação agrometeorológica, determinando equivalência entre ambos.

Outros pesquisadores atestaram a efetividade do SR em estudos relacionados ao balanço energético e seus componentes, visto que sua observação e monitoramento auxiliam na compreensão dos fluxos de energia e identificação da situação ambiental do local investigado, seja na Amazônia (OLIVEIRA, G., 2012; ANDRADE, 2014), em municípios com área urbana expressiva (IDEIÃO, 2009; OLIVEIRA, T., 2012), ou em Bacias Hidrográficas que tiveram grande alteração de uso e cobertura do solo (IDEIÃO, 2009; CONCEIÇÃO, 2018).

A verificação e estimativa de apenas alguns elementos constituintes do balanço de energia é também uma alternativa. Por meio disto, é possível inferir características de uma área que poderá contribuir no entendimento da sua dinâmica. A título de exemplo, Cunha *et al.* (2012) utilizou o SR para realizar uma análise multitemporal da cobertura vegetal na Bacia Hidrográfica de São João do Rio do Peixe, na Paraíba, e sua correlação com algumas variáveis biofísicas. Já Silva *et al.* (2011) analisou componentes do balanço de radiação por meio de imagens de satélite e concluiu que a presença de áreas irrigadas implica no clima localmente por meio da diminuição da temperatura da superfície e, conseqüentemente, do ar. Silva *et al.* (2015) indica, ao observar diferenças na distribuição espacial e temporal de estimativas de saldo de radiação e parâmetros biofísicos em áreas com cobertura de floresta amazônica natural, manejada, sistema silvipastoril e pastagem, que o desmatamento pode causar alterações climáticas por alterar a capacidade de retenção de energia pela superfície para utilização nos processos que integram o balanço energético. Tal ideia é corroborada por diferentes autores ao constatarem diminuição do Índice de Vegetação por Diferença Normalizada (NDVI), aumento do albedo e da temperatura da superfície e conseqüente modificação do saldo de radiação em áreas as quais a cobertura nativa foi substituída por cultivo agrícola ou solo exposto, afetando diversos processos cujo bom funcionamento é primordial para a atividade (MARTINS *et al.*, 2015; FAUSTO *et al.*, 2016).

Nota-se, a partir dos trabalhos citados, que é recorrente a utilização do índice de vegetação, temperatura da superfície e nível de precipitação para analisar a dinâmica de um sistema. Os dados levantados por eles se complementam e são capazes de indicar prováveis alterações no balanço energético, visto que são fatores que interferem na interação biosfera atmosfera.

O índice de vegetação (IV), por exemplo, auxilia no monitoramento da vegetação de uma área de interesse. São algoritmos que caracterizam a cobertura vegetal por meio do sensoriamento remoto, utilizando como base a reflectância nas faixas do espectro eletromagnético do visível e infravermelho próximo, visto que, de forma geral, as folhas absorvem a radiação nesta primeira faixa e refletem na segunda (LIU, 2007). Por meio das imagens de satélite é possível, além de identificar as áreas vegetadas, quantificá-las e verificar suas condições e distribuição, permitindo analisar os impactos das ações antrópicas e de causas naturais (HUETE *et al.*, 1999). Um dos principais IV é o Índice de Vegetação por Diferença Normalizada que, apesar de apresentar problemas de saturação em locais cujo Índice de Área Foliar é muito alto, tem se mostrado eficaz nos estudos da vegetação em escala global (JENSEN, 2009). Seu cálculo consiste na razão entre a diferença e a soma das bandas do infravermelho próximo (IVP) e do vermelho (V) e seu resultado pode variar de -1 a +1, no qual os valores negativos são referentes a nuvens e água, os valores próximos a zero são de solo exposto ou outras áreas não vegetadas e os valores positivos são referentes à presença de vegetação, sendo mais densa quanto mais próximo de 1.

Já a temperatura da superfície (TS), assim como define Wan (1999), resulta da interação entre a superfície e a atmosfera e, dessa forma, é um bom indicador do balanço de energia terrestre, além de ser necessário em estudos climáticos, hidrológicos, ecológicos e biogeoquímicos. Este parâmetro é estimado a partir de dados termais coletados através das bandas do infravermelho termal, mas seu cálculo é considerado complexo devido aos efeitos atmosféricos que interferem na obtenção da emissividade da superfície.

A precipitação (Pr), por fim, é um dos processos existentes no ciclo hidrológico que se configura como variável de entrada para a estimativa do balanço hídrico. É originada a partir da condensação do vapor d'água presente na atmosfera, devolvendo à superfície a água que foi evapotranspirada (AYOADE, 1996). Existe, portanto, uma relação de interdependência na qual as chuvas fornecem uma substância essencial para o desenvolvimento vegetal e as plantas retornam essa umidade ao ambiente, produzindo mais chuva. Observando as imagens orbitais, é possível notar que a vegetação é sensível à precipitação, conforme aponta Ideião (2009), se tornando mais viçosa em períodos chuvosos. Liu (2007), entretanto, alerta que há um atraso na correlação entre NDVI e precipitação, visto que é necessário

um tempo até a água precipitada ser “convertida” em crescimento da vegetação verificado através do NDVI.

Destes três componentes, dois (IV e TS) são disponibilizados como produtos do sensor MODIS, um dispositivo que muito contribui para os estudos da dinâmica terrestre.

2.3.1 Sensor MODIS

O *Moderate Resolution Imaging Spectroradiometer* (MODIS) é um instrumento de imageamento a bordo dos satélites Terra e Aqua lançados pela *National Aeronautics and Space Administration* (NASA) e que juntos percorrem todo o planeta num período de 1 a 2 dias. O sensor coleta dados em 36 faixas espectrais e em três resoluções espaciais diferentes, descrevendo feições do solo, oceanos, atmosfera e criosfera. Todos os seus dados são disponibilizados gratuitamente e constam na plataforma do *Google Earth Engine*.

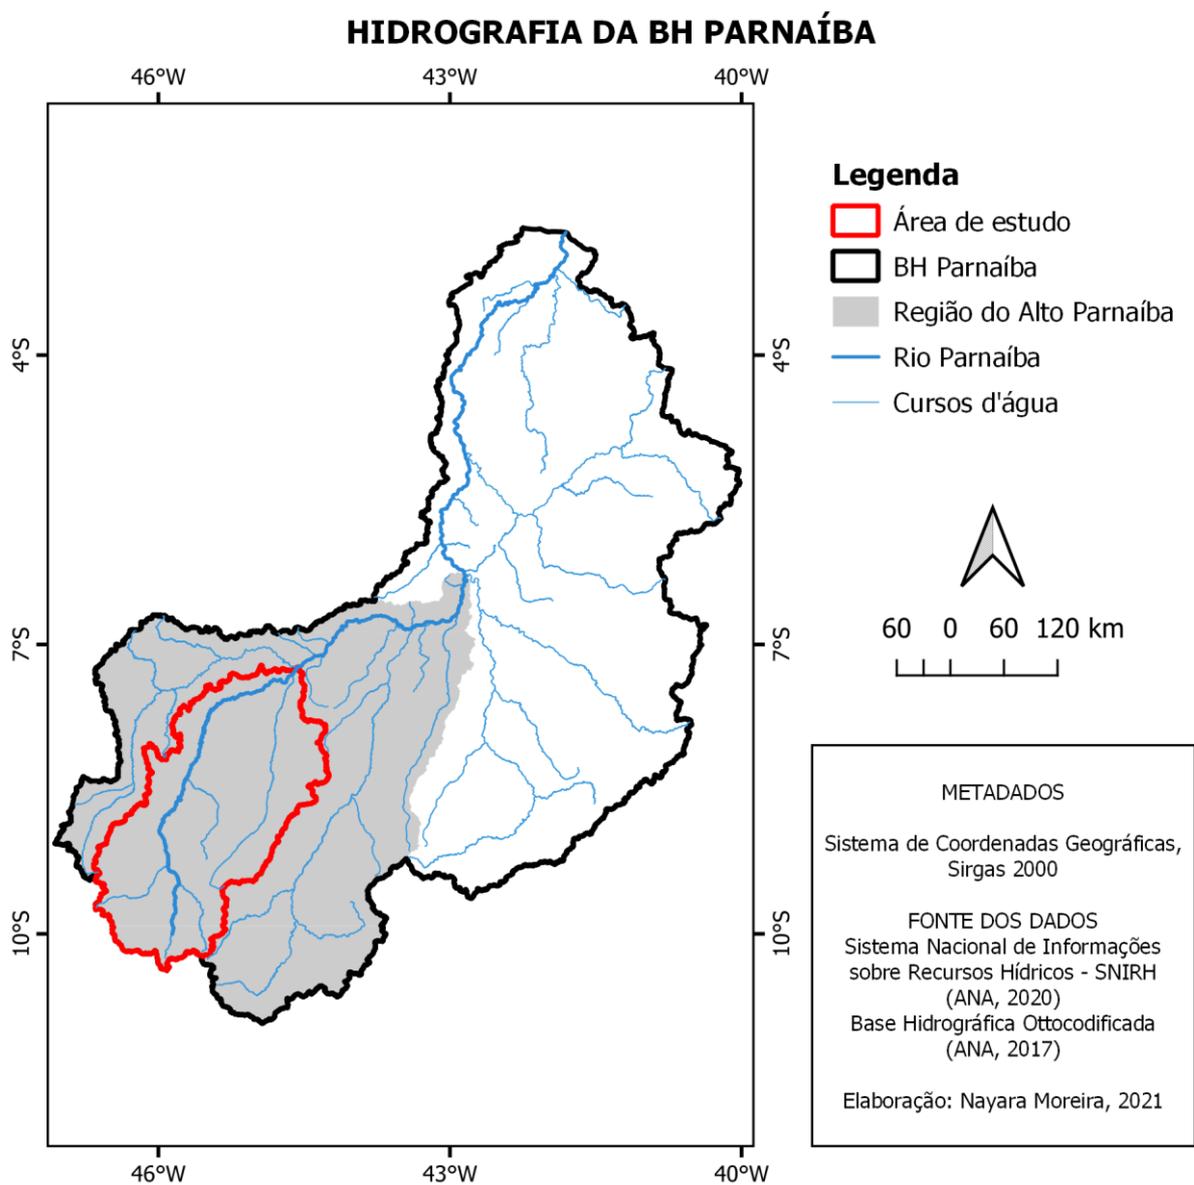
Entre os produtos oriundos do MODIS, pode-se citar os índices de vegetação, cobertura do solo, temperatura superficial do solo e dos oceanos, anomalias termais/fogo, evapotranspiração, albedo, cobertura de neve e gelo. Os dados oriundos deste sensor contam, além disso, com indicadores de qualidade por *pixel* (*Quality Assessment Science Data Sets – QA SDS*) em dígitos binários, sinalizando a confiabilidade do processo de geração do produto considerando as condições sob as quais cada unidade de imagem foi adquirida e/ou processada (HUETE et al., 1999; WAN, 1999). Para simplificar, há uma camada obrigatória em cada produto deste sensor que resume a qualidade do *pixel*, informando se o IV, por exemplo, foi gerado com boa qualidade e não é necessário consultar outro QA, se foi gerado mas é recomendado checar mais detalhadamente o QA, se há presença de nuvens ou se não foi gerado devido a outros motivos além de nuvem (DIDAN et al., 2015; WAN, 2013). Consultar estes *layers*, portanto, assegura a utilização de dados confiáveis resultando em uma análise mais precisa.

3 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área de estudo desta pesquisa foi definida utilizando como base a codificação de Bacias Hidrográficas pelo método de *Otto Pfafstetter*, oficialmente utilizada pela Agência Nacional de Águas (ANA). De código “749” e ocupando cerca de 52 mil quilômetros quadrados (km²), a delimitação selecionada é referente à área de drenagem da parte mais a montante do curso d’água principal da Bacia Hidrográfica do Parnaíba, que possui aproximadamente 334 mil km² e abrange os estados do Ceará, Piauí e Maranhão. A Figura 1 apresenta a área de estudo ilustrada pelo polígono com contorno vermelho, sobrepondo a BH do Parnaíba representada em hachura vermelha e, em verde, o Matopiba.

nesta pesquisa como “Região do Alto Parnaíba”, enquanto a extensão investigada é tratada como “BH do Alto Parnaíba” (ou apenas “Alto Parnaíba”), sub-bacia de nível 3 da BH do Parnaíba que abriga o início de seu rio homônimo. Na Figura 2 é possível observar estas duas delimitações, sendo a primeira apresentada em cinza e a segunda pelo contorno vermelho. Sobreposto a elas, as linhas azuis representam os principais trechos de drenagem da BH Parnaíba (contorno preto). O Rio Parnaíba, que dá nome à BH, está destacado com uma espessura maior.

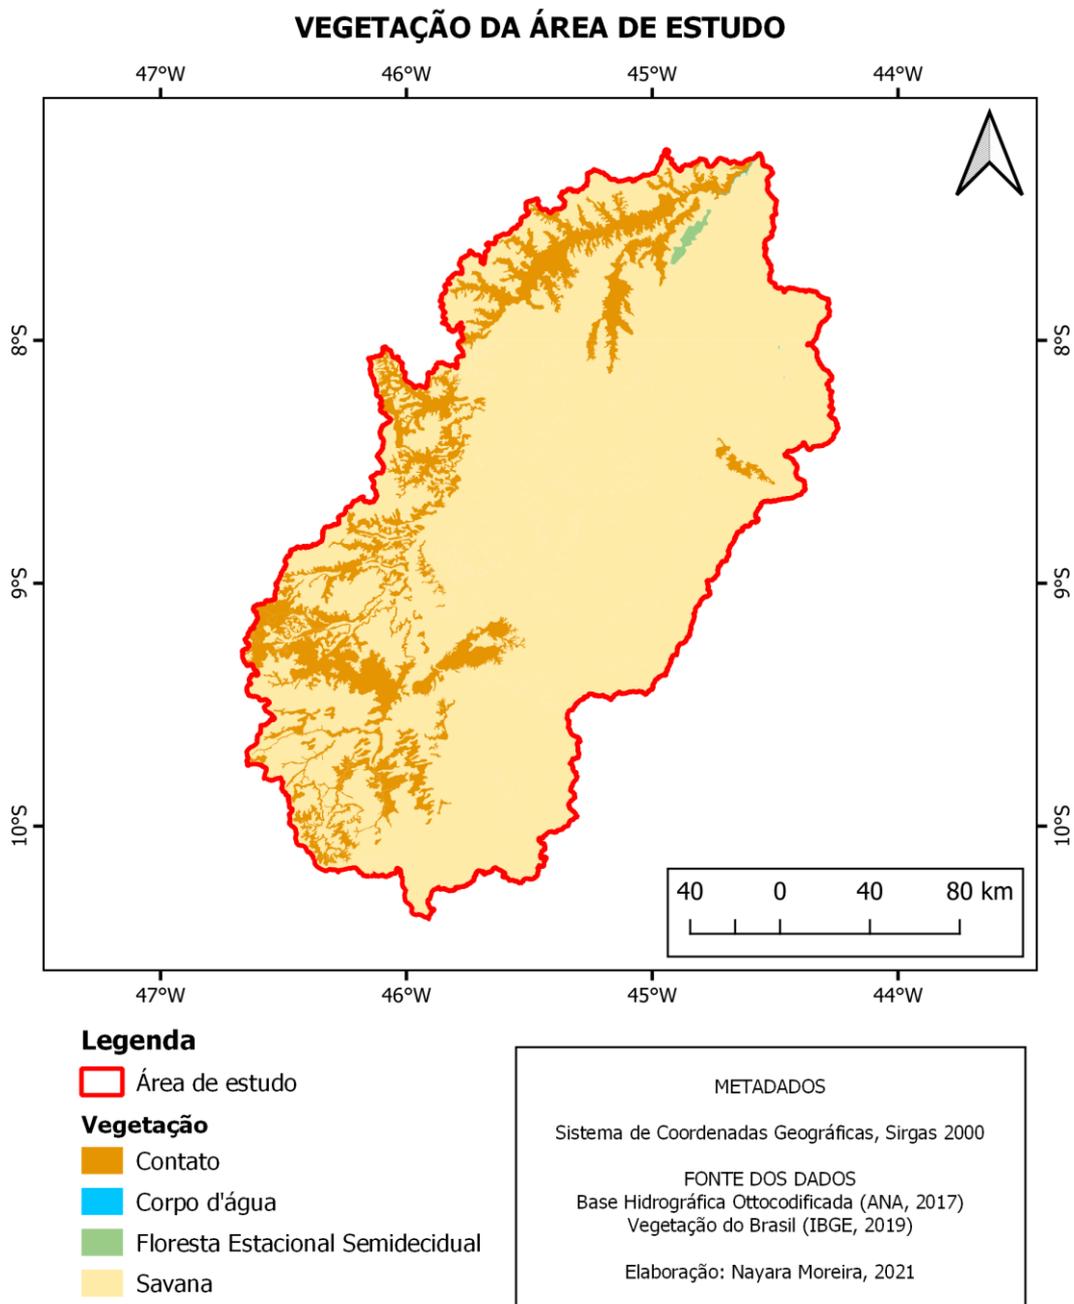
Figura 2 – Hidrografia da BH Parnaíba



Quanto ao bioma, a BH do Alto Parnaíba está integralmente contida no Cerrado cuja vegetação é predominantemente campestre, com “árvores e arbustos

esparços, sobre um tapete graminoso” (IBGE, 2019), embora exista também, mas de forma menos expressiva, formação florestal. De acordo com a Figura 3, observa-se que grande parte da bacia é coberta pela Savana, havendo também áreas de tensão ecológica (onde há o encontro de dois tipos de vegetação), identificadas na legenda do mapa por “Contato”, e um pequeno polígono de Floresta Estacional Semidecidual ao norte.

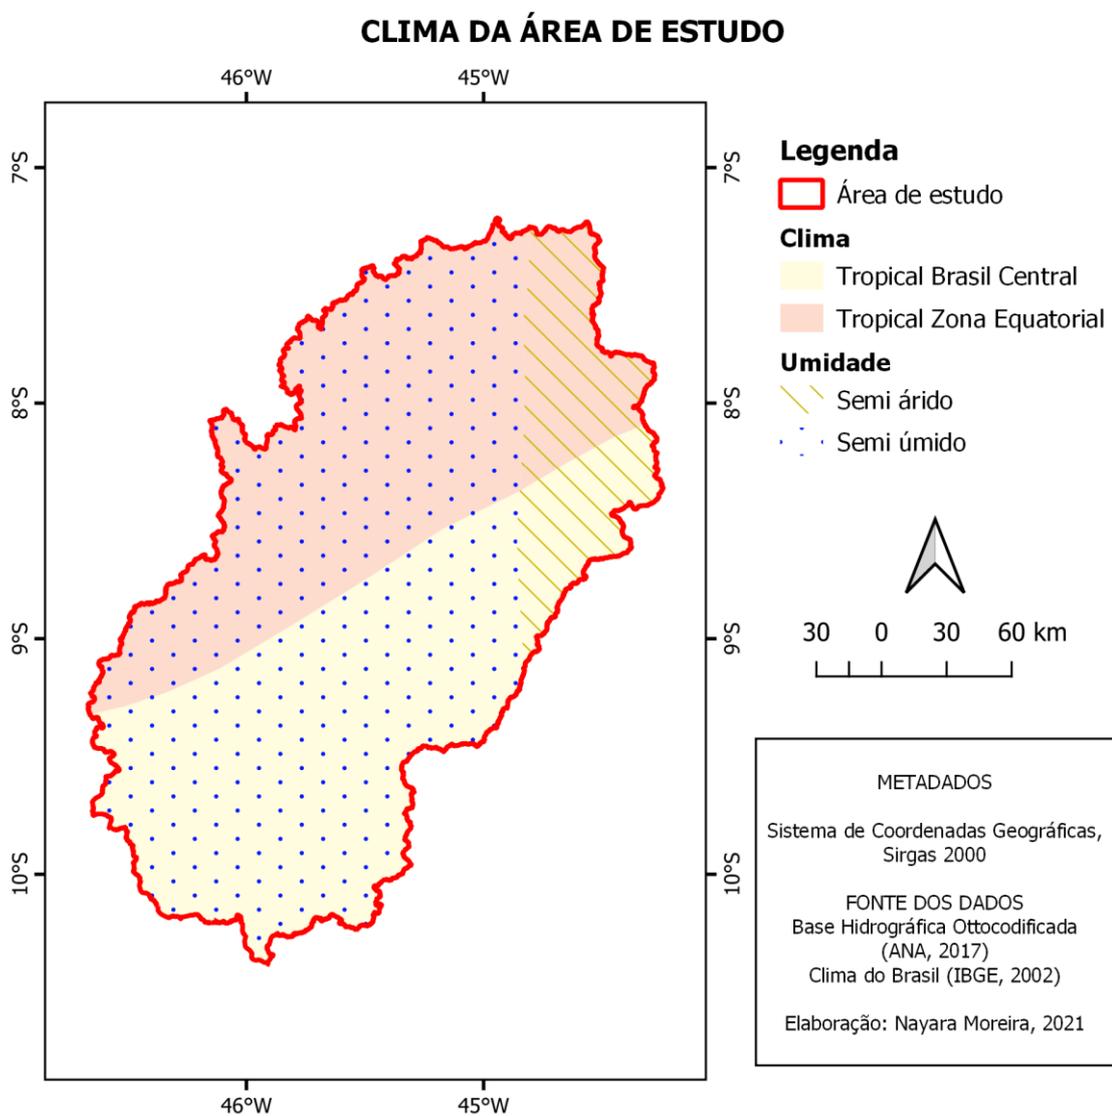
Figura 3 – Vegetação da BH do Alto Parnaíba



Fonte: Autora (2022)

Influenciando fortemente a condição da vegetação, o Alto Parnaíba se encontra dentro das zonas climáticas Tropical Brasil Central e Tropical Zona Equatorial com temperaturas médias maiores que 18°C durante todo o ano e secas de 6 meses na parte nordeste (semi árido) e de 4 a 5 meses na área semi úmida, assim como é retratado na Figura 4. É importante destacar que os efeitos dos fenômenos El Niño e La Niña abrangem a BH, afetando o clima e o volume de chuvas (MMA, 2006).

Figura 4 – Clima na BH do Alto Parnaíba

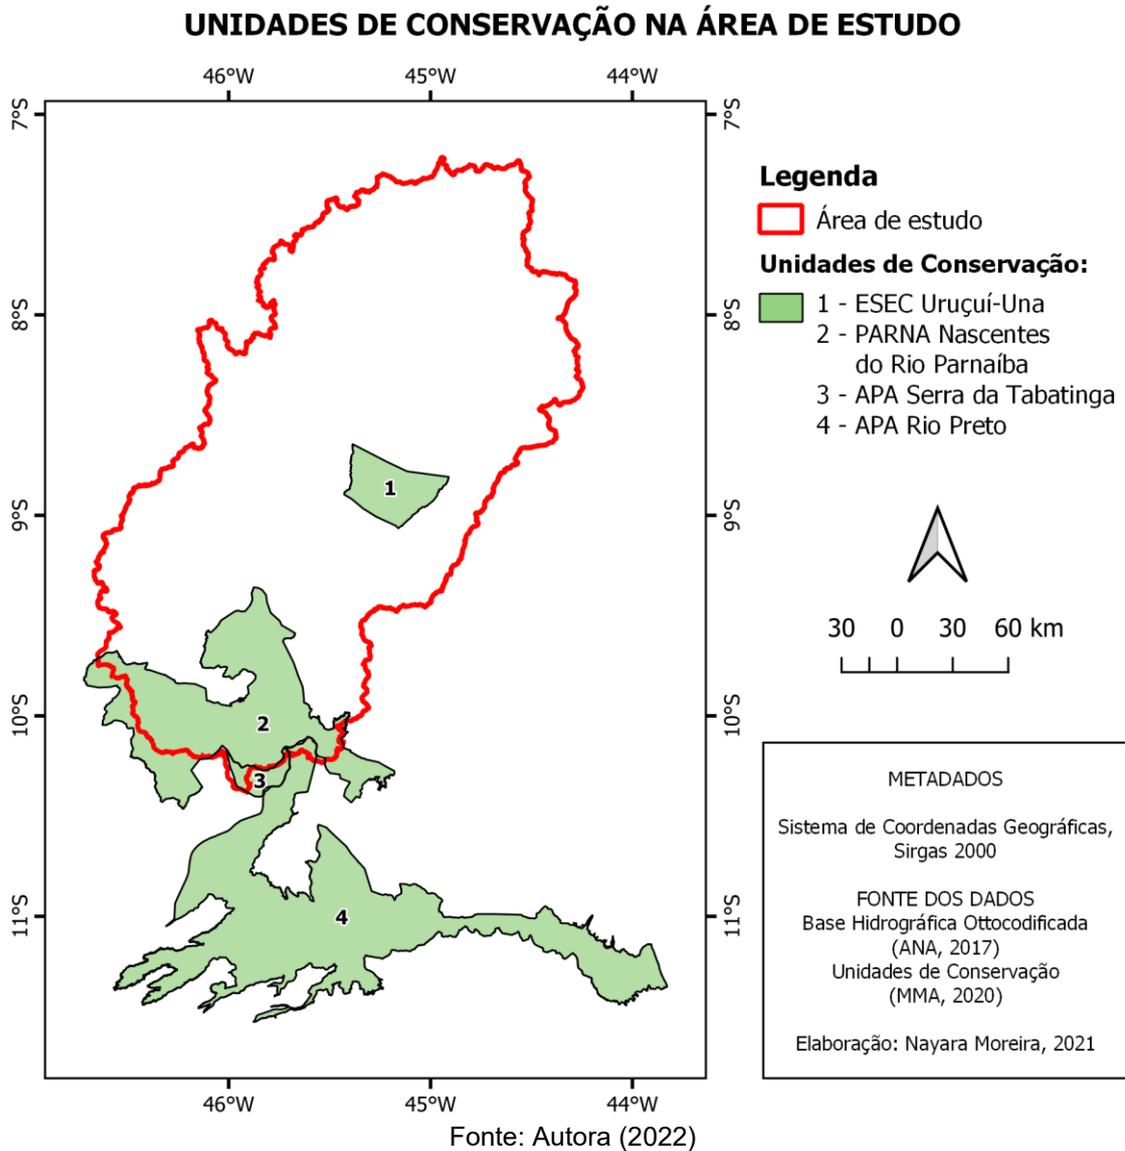


Fonte: Autora (2022)

Encontra-se na área de estudo quatro Unidades de Conservação (UC), cujo objetivo é preservar um local de relevância ecológica e beleza cênica. São elas: Estação Ecológica (ESEC) de Uruçuí-Una, Parque Nacional (PARNA) das Nascentes do Rio Parnaíba, Área de Proteção Ambiental (APA) da Serra da

Tabatinga e Área de Proteção Ambiental do Rio Preto. Destas, apenas a ESEC Uruçuí-Una está totalmente situada no interior do limite da BH do Alto Parnaíba, conforme exposto na Figura 5.

Figura 5 – Unidades de Conservação na BH do Alto Parnaíba



Em termos populacionais, por fim, toda a região do Alto Parnaíba conta com uma população de aproximadamente 583 mil habitantes, no qual cerca de 66% se encontram nos centros urbanos (IBGE, 2010 apud ANA, 2015). Dos municípios que fazem parte da BH em estudo, o mais populoso é Balsas (MA) com 83 mil habitantes, enquanto os outros possuem menos de 30 mil habitantes conforme Censo Demográfico do Brasil de 2010. Já em relação à economia, a atividade produtiva com mais destaque na região é a agricultura, sendo algodão, arroz, milho e soja os cultivos mais significativos (MMA, 2006).

4 PROCEDIMENTOS METODOLÓGICOS

No presente trabalho, foi utilizado o *Google Earth Engine* (GEE) para o processamento dos dados analisados. Encontram-se nele diversas coleções de imagens armazenadas em nuvem e *scripts* que facilitam e tornam mais rápida e prática a sua utilização. Ao final, buscou-se avaliar a plataforma considerando a facilidade e eficiência da mesma na realização dos procedimentos descritos nos subcapítulos 4.2 e 4.3, verificando o desempenho através da sua capacidade operacional e de processamento dos dados.

A escolha de quais índices biofísicos utilizar se deu com base na leitura de diferentes trabalhos de análise ambiental por meio de imagens multiespectrais, citados na seção 2.3 (análise da dinâmica de uma área por meio do SR). Sendo assim, optou-se por examinar nesta pesquisa o índice de vegetação, temperatura da superfície e precipitação. Para o NDVI e TS, optou-se por utilizar o sensor MODIS como base por ser uma fonte gratuita cujos produtos já constam no GEE. Além disso, os dados são previamente trabalhados e apresentados diretamente como índice de vegetação e temperatura da superfície, poupando algumas etapas de processamento.

As análises foram feitas a partir da observação dos índices e do uso e cobertura do solo nos períodos determinados. Além de obter as estatísticas e quantificar a área ocupada por classe, os dados foram exportados em imagem para subsidiar a análise a partir da visualização da situação da área nos períodos inicial e final compreendidos pela investigação. Também foram gerados gráficos para verificar o comportamento destes parâmetros durante os anos, permitindo identificar a presença ou ausência de uma tendência ao longo do tempo.

Após examinar as informações obtidas dos índices biofísicos, os resultados foram confrontados com a evolução do UCS para averiguar se há relação. Foram apontadas as diferenças dos IB visualmente observadas no intervalo de tempo selecionado, checando se houve também alteração de uso e cobertura do solo e, após, conferidos os valores estatísticos nos dois períodos de análise e, por fim, analisado o comportamento dos mesmos ao longo do tempo por meio dos gráficos.

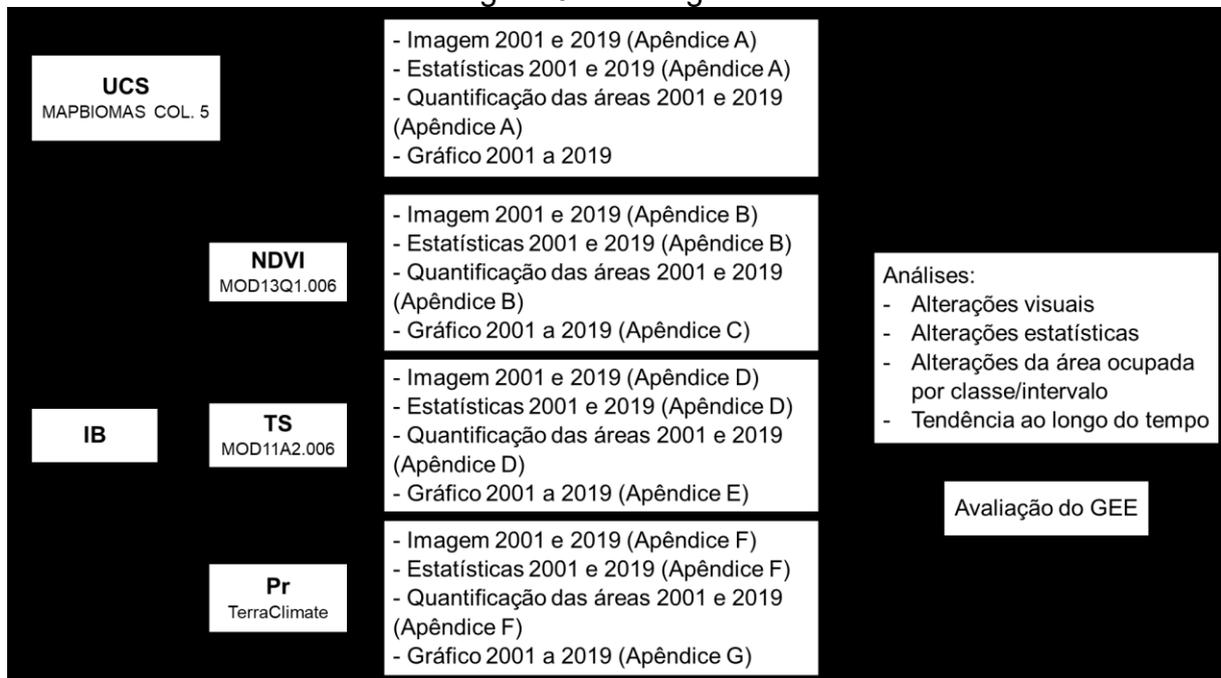
Ressalta-se que todos os *scripts* gerados neste trabalho constam nos apêndices, sendo 6 no total. São eles:

- Apêndice A – *Script* de uso e cobertura do solo em 2001 e 2019;

- Apêndice B – *Script* da média de NDVI em 2001 e 2019;
- Apêndice C – *Script* do gráfico da média anual de NDVI de 2001 a 2019;
- Apêndice D – *Script* da média da temperatura da superfície em 2001 e 2019;
- Apêndice E – *Script* do gráfico da média anual da temperatura da superfície de 2001 a 2019;
- Apêndice F – *Script* da média de precipitação acumulada mensal em 2001 e 2019;
- Apêndice G – *Script* do gráfico da média anual de precipitação acumulada mensal de 2001 a 2019.

O fluxograma ilustrado na Figura 6 indica os procedimentos metodológicos adotados para esta pesquisa. Nele, constam os dados utilizados, os produtos gerados (e seus respectivos *scripts* apresentados nos apêndices) e as análises realizadas.

Figura 6 – Fluxograma



Fonte: Autora (2022)

4.1 PERÍODO ANALISADO

Inicialmente, cabe destacar que as datas foram escolhidas levando em consideração, além da disponibilidade de imagens, as últimas ocorrências dos

fenômenos climáticos El Niño e La Niña, anomalias que ocorrem periodicamente no Oceano Pacífico e que modificam a interação entre o oceano e a atmosfera, trazendo consequências para todo o planeta. Seus efeitos afetam, inclusive, a área em estudo, alterando a dinâmica do sistema climático considerada como normal. Em períodos de El Niño, por exemplo, são notadas secas severas na região nordeste do Brasil, enquanto sob domínio de La Niña ocorre aumento de precipitação e vazões de rios (INPE, 2016).

Com o intuito de evitar a influência desses fenômenos nas paisagens analisadas, optou-se por escolher dois anos em que não foi registrada sua ocorrência no site do Instituto Nacional de Pesquisas Espaciais⁸ (INPE), sendo selecionados os anos de 2001 como tempo 1 (T1) e início da análise e 2019 como tempo 2 (T2) e ano final. O fato do período analisado abranger quase 20 anos possibilita uma boa noção em média escala de tempo acerca das mudanças que ocorreram na bacia hidrográfica estudada. Vale destacar que estas datas coincidem com intensas alterações de uso e cobertura do solo na área.

É importante mencionar que foram considerados todos os valores registrados ao longo do ano para a obtenção dos índices biofísicos com o intuito de buscar uma tendência central anual destes parâmetros e amenizar prováveis oscilações devido à natural estiagem que afeta a região em alguns meses e devido à produção agrícola. Dependendo do cultivo presente no local, a temperatura, bem como o índice de vegetação, pode variar no decorrer do ano, tendo períodos no ciclo da cultura com índices mais elevados e outros menos. Já nas áreas não vegetadas, como áreas urbanas e de solo exposto, essas variações são mínimas, sendo o índice de vegetação presumivelmente baixo e a temperatura superficial alta durante os doze meses. As áreas vegetadas, por sua vez, tendem a ter uma resposta termal inferior, sendo ela menor quanto mais densa a vegetação, configurando, assim, uma relação inversamente proporcional entre o IV e a TS.

4.2 USO E COBERTURA DO SOLO (UCS)

A distinção entre os diferentes usos e coberturas do solo, cujo código é informado no Apêndice A, se deu com base nos produtos da Coleção 5 do

8 Disponível em: <http://enos.cptec.inpe.br/#>

MapBiomas. Apesar desta não ser a versão atualizada, é a coleção que, no momento em que foram elaborados os *scripts* de UCS, era a mais recente.

Consta no Documento Base Teórico do Algoritmo (MAPBIOMAS, 2020) que a Coleção 5 conta com 4 níveis e 21 tipos de classes em sua legenda. Vale destacar, no entanto, que apenas 9 delas se encontram no interior da área de estudo de acordo com a classificação do ano de 2001 e 2019. Como este trabalho não necessita toda essa discretização, foi realizada uma generalização das 9 classes ali presentes para apenas 4, como apresenta o Quadro 1.

Quadro 1 – Generalização e nome das classes do MapBiomas

CLASSIFICAÇÃO MAPBIOMAS		NOVA CLASSIFICAÇÃO	
Valor do <i>pixel</i>	Nome da classe	Valor atribuído ao <i>pixel</i>	Nome da classe
3	Formação Florestal	1	Formação natural
4	Formação Savânica		
12	Formação Campestre		
15	Pastagem	3	Agropecuária
39	Soja		
41	Outros		
24	Infraestrutura Urbana	6	Área não vegetada
25	Outra Área não Vegetada		
33	Corpo d'água	10	Corpo d'água

Fonte: Dados obtidos do ATDB (MAPBIOMAS, 2020) adaptados pela autora (2022).

Notas: O quadro original é apresentado no Anexo A.

Para gerar os dados de transição, foi feita uma álgebra de mapas subtraindo o *raster* generalizado de 2001 do de 2019. As diferenças possíveis foram testadas para garantir que não houvesse ambiguidade entre as classes, certificando-se de que um mesmo número não representasse duas transformações da paisagem diferentes. Assim, assegura-se que cada valor de *pixel* é referente a uma transição de UCS específica.

Como resultado, foram obtidos *pixels* de valores -9, -7, -5, -4, -3, -2, 0, 2, 3, 4, 5, 7 e 9 e, para facilitar a interpretação, foi realizada uma reclassificação de acordo com o Quadro 2. Na parte esquerda do quadro estão expostos os dados resultantes da álgebra de mapas, contendo o valor dos *pixels* e os tipos de alteração

que cada um é referente. Já na parte direita estão indicados os novos valores atribuídos para cada *pixel* e o tipo de alteração relacionado.

Quadro 2 – Reclassificação dos *pixels* e os tipos de alteração de uso e cobertura do solo ocorridos entre 2001 e 2019

RESULTADO DA ÁLGEBRA DE MAPAS		NOVA CLASSIFICAÇÃO	
Valor do <i>pixel</i>	Tipo de alteração ocorrida entre 2001 e 2019	Valor atribuído ao <i>pixel</i>	Tipo de alteração ocorrida entre 2001 e 2019
0	Não houve alteração	0	Não houve alteração
5	De formação natural para área não vegetada	1	Supressão de vegetação natural
2	De formação natural para agropecuária	2	Expansão agropecuária sobre área natural
-7	De corpo d'água para agropecuária	3	Expansão agropecuária sobre outras áreas
-3	De área não vegetada para agropecuária		
-9	De corpo d'água para formação natural	4	Reflorestamento
-5	De área não vegetada para formação natural		
-2	De agropecuária para formação natural		
4	De área não vegetada para corpo d'água	5	Aparecimento de corpo d'água
7	De agropecuária para corpo d'água		
9	De formação natural para corpo d'água		
-4	De corpo d'água para área não vegetada	6	Outras áreas não vegetadas
3	De agropecuária para área não vegetada		

Fonte: Dados do MapBiomias (2020) adaptados pela autora (2022).

Para quantificar a área ocupada por classe de UCS e pelas transições ocorridas, foi necessário, primeiro, saber o tamanho do pixel e, então, multiplicá-lo pela quantidade de *pixels*.

Foi elaborado, então, um gráfico contendo a evolução temporal da área, no qual são apresentados dados de todos os anos entre 2001 e 2019 (totalizando 19 imagens). Semelhante aos procedimentos realizados anteriormente, foi feita a reclassificação indicada no Quadro 1 e calculada a área de cada classe por ano, possibilitando a geração do gráfico. Devido a limitações encontradas na utilização do GEE, este gráfico em si, no entanto, foi gerado no documento de planilhas LibreOffice Calc. Vale destacar que em alguns anos foram observados *pixels* de valor 23 representando áreas de praias e dunas. Assim como é indicado no ATDB da coleção 5 (MAPBIOMAS, 2020), esses *pixels* foram reclassificados como área não vegetada cujo valor atribuído na nova classificação (Quadro 2) é 6.

4.3 ÍNDICES BIOFÍSICOS (IB)

São descritos nos subitens 4.3.1, 4.3.2 e 4.3.3 os procedimentos realizados para geração dos IB.

4.3.1 Índice de Vegetação (IV)

As informações sobre o IV foram extraídas do *dataset* originado pelo produto MOD13Q1.006, obtido através do sensor MODIS, que, com resolução espacial de 250 m, seleciona o melhor pixel disponível num período de 16 dias para compor e gerar o Índice de Vegetação por Diferença Normalizada e Índice de Vegetação Melhorado (EVI) (DIDAN *et al.*, 2015).

Conforme exposto no Apêndice B, o qual apresenta a código elaborado para o NDVI, foi utilizado, primeiramente, os *layers* de indicadores de qualidade para mascarar os *pixels* de NDVI, mantendo apenas aqueles cujo índices de vegetação foram considerados gerados com boa qualidade. Então, foram filtrados os *rasters* para os dois períodos selecionados, totalizando 23 em cada ano, e normalizados os dados: os valores dos *pixels* foram divididos por 10.000 para corresponderem ao intervalo padrão de -1 a +1.

Para a visualização da imagem, optou-se por utilizar a média dos *pixels* em cada ano, e, para complementar a investigação, foi calculada a média total de NDVI na área de estudo em cada período. Antes de escolher esta medida de tendência central para examinar os dados, realizou-se uma comparação com o resultado caso fosse empregada a mediana e foram obtidos produtos muito semelhantes. No entanto, considerando que a mediana não sofre tanta influência dos valores extremamente altos ou baixos e que estes valores extremos podem corresponder aos diferentes estágios do ciclo de uma lavoura temporária (plantio, desenvolvimento, colheita) e, portanto, são relevantes para a análise, a utilização da média aritmética, neste caso, é mais adequada. Além disso, como foram mascarados os *pixels* de baixa qualidade, estes não interfeririam no cálculo. A presença de nuvens, dessa forma, não afetaria o resultado.

Posteriormente, para ser possível quantificar a área ocupada pelas classes do índice de vegetação utilizado, foi feita uma reclassificação dos valores dos *pixels* com base nos intervalos expostos na Tabela 1. Para não gerar sobreposição, os intervalos foram definidos a partir do valor maior ou igual ao limite inferior e menor que o limite superior. Então, assim como feito para o UCS, foi multiplicada a quantidade de *pixels* em cada intervalo pelo tamanho do *pixel* da imagem.

Tabela 1 – Intervalos utilizados para a reclassificação da imagem de NDVI

Intervalos (NDVI)	Valor atribuído ao <i>pixel</i>
[0 – 0,1[0
[0,1 – 0,2[1
[0,2 – 0,3[2
[0,3 – 0,4[3
[0,4 – 0,5[4
[0,5 – 0,6[5
[0,6 – 0,7[6
[0,7 – 0,8[7
[0,8 – 0,9[8
[0,9 – 1[9

Fonte: Autora (2022).

Foi elaborado também no *Google Earth Engine* um gráfico da média anual de NDVI de 2001 a 2019 e seu *script* consta no Apêndice C. Ele foi gerado a partir

de 437 *rasters* no total. Para isso, primeiramente foram mascarados os *pixels* não considerados de boa qualidade. Após, foi adicionada uma propriedade em cada imagem informando o ano a qual ela é referente para posteriormente unir os *rasters* pertencentes ao mesmo ano e, com isso, calcular a média anual de NDVI para compor o gráfico.

4.3.2 Temperatura da Superfície (TS)

Quanto à temperatura da superfície, os dados foram obtidos a partir do produto MOD11A2.006 do sensor MODIS. Ele é referente à média dos dados da TS de 8 dias com resolução espacial de 1000 m (WAN, 2015).

O código desenvolvido para este IB é apresentado no Apêndice D. Semelhante ao procedimento realizado para a obtenção do IV, foram mascarados os *pixels* não considerados de boa qualidade, filtrados os períodos desejados (obtendo 45 e 46 imagens em 2001 e 2019 respectivamente) e convertidos os valores de Kelvin para Grau Celsius (°C) levando em consideração o fator de escala informado⁹. Para a visualização da imagem, foi calculada a média de cada *pixel* em cada período e, junto disso, a média de toda a região, bem como o valor máximo e mínimo observados em cada período.

Já a reclassificação dos valores dos *pixels* para a quantificação das áreas se deu com base na Tabela 2, possibilitando multiplicar o tamanho do *pixel* pelo total de *pixels* contidos em cada intervalo definido.

9 O fator de escala, descrito nos metadados do produto utilizado, corresponde a 0,02.

Tabela 2 – Intervalos utilizados para a reclassificação da imagem de temperatura da superfície

Intervalos (°C)	Valor atribuído ao <i>pixel</i>
[28 – 30[1
[30 – 32[2
[32 – 34[3
[34 – 36[4
[36 – 38[5
[38 – 40[6
[40 – 42[7
[42 – 44[8

Fonte: Autora (2022).

A geração de um gráfico da média anual da TS de 2001 a 2019, cujo *script* é exibido no Apêndice E, se deu a partir do processamento de 873 imagens e seguiu a mesma ideia do gráfico de NDVI. Para isso, foi utilizada a função para mascarar os *pixels* mantendo os de boa qualidade, adicionada a data em cada *raster* e juntados aqueles que eram referentes ao mesmo ano e, antes de gerar o gráfico, foram convertidos os valores de temperatura obtidos de Kelvin para Grau Celsius.

4.3.3 Precipitação (Pr)

Para esta etapa foi utilizado o TerraClimate que gera dados mensais de clima em escala global por meio da combinação da base de dados climatológicos de alta resolução espacial do WorldClim com as do CRU Ts4.0¹⁰ e JRA55¹¹ que, apesar de possuírem menor resolução espacial, apresentam maior resolução temporal. É disponibilizado no *dataset* diversas variáveis que, conforme Abatzoglou *et al.* (2018), fornecem importante contribuição para estudos ecológicos e hidrológicos do planeta, entre elas a de precipitação acumulada mensal utilizada neste trabalho.

Então, similar ao realizado nos outros dois IB, elaborou-se um código (Apêndice F) no qual foram determinados os períodos para a filtragem (resultando em 12 *rasters* por ano, sendo um por mês), calculada a média dos *pixels* e as estatísticas (média, valor máximo e mínimo mensal) da região em T1 e T2 e, por fim,

10 Climatic Research Unit (CRU) Time-Series (Ts) version 4.0

11 Japanese 55-year Reanalysis

feita a reclassificação dos *pixels* para a estipulação da área ocupada por intervalo de precipitação acumulada (Tabela 3). Como a precipitação acumulada mínima observada na região é maior que 40 milímetros mensais (mm/mês), foram desconsiderados os intervalos inferiores a esse valor.

Tabela 3 – Intervalos utilizados para a reclassificação da imagem de precipitação acumulada

Intervalos (mm/mês)	Valor atribuído ao <i>pixel</i>
[40 – 50[1
[50 – 60[2
[60 – 70[3
[70 – 80[4
[80 – 90[5
[90 – 100[6
[100 – 110[7
[110 – 120[8
[120– 130[9
[130 – 140[10

Fonte: Autora (2022).

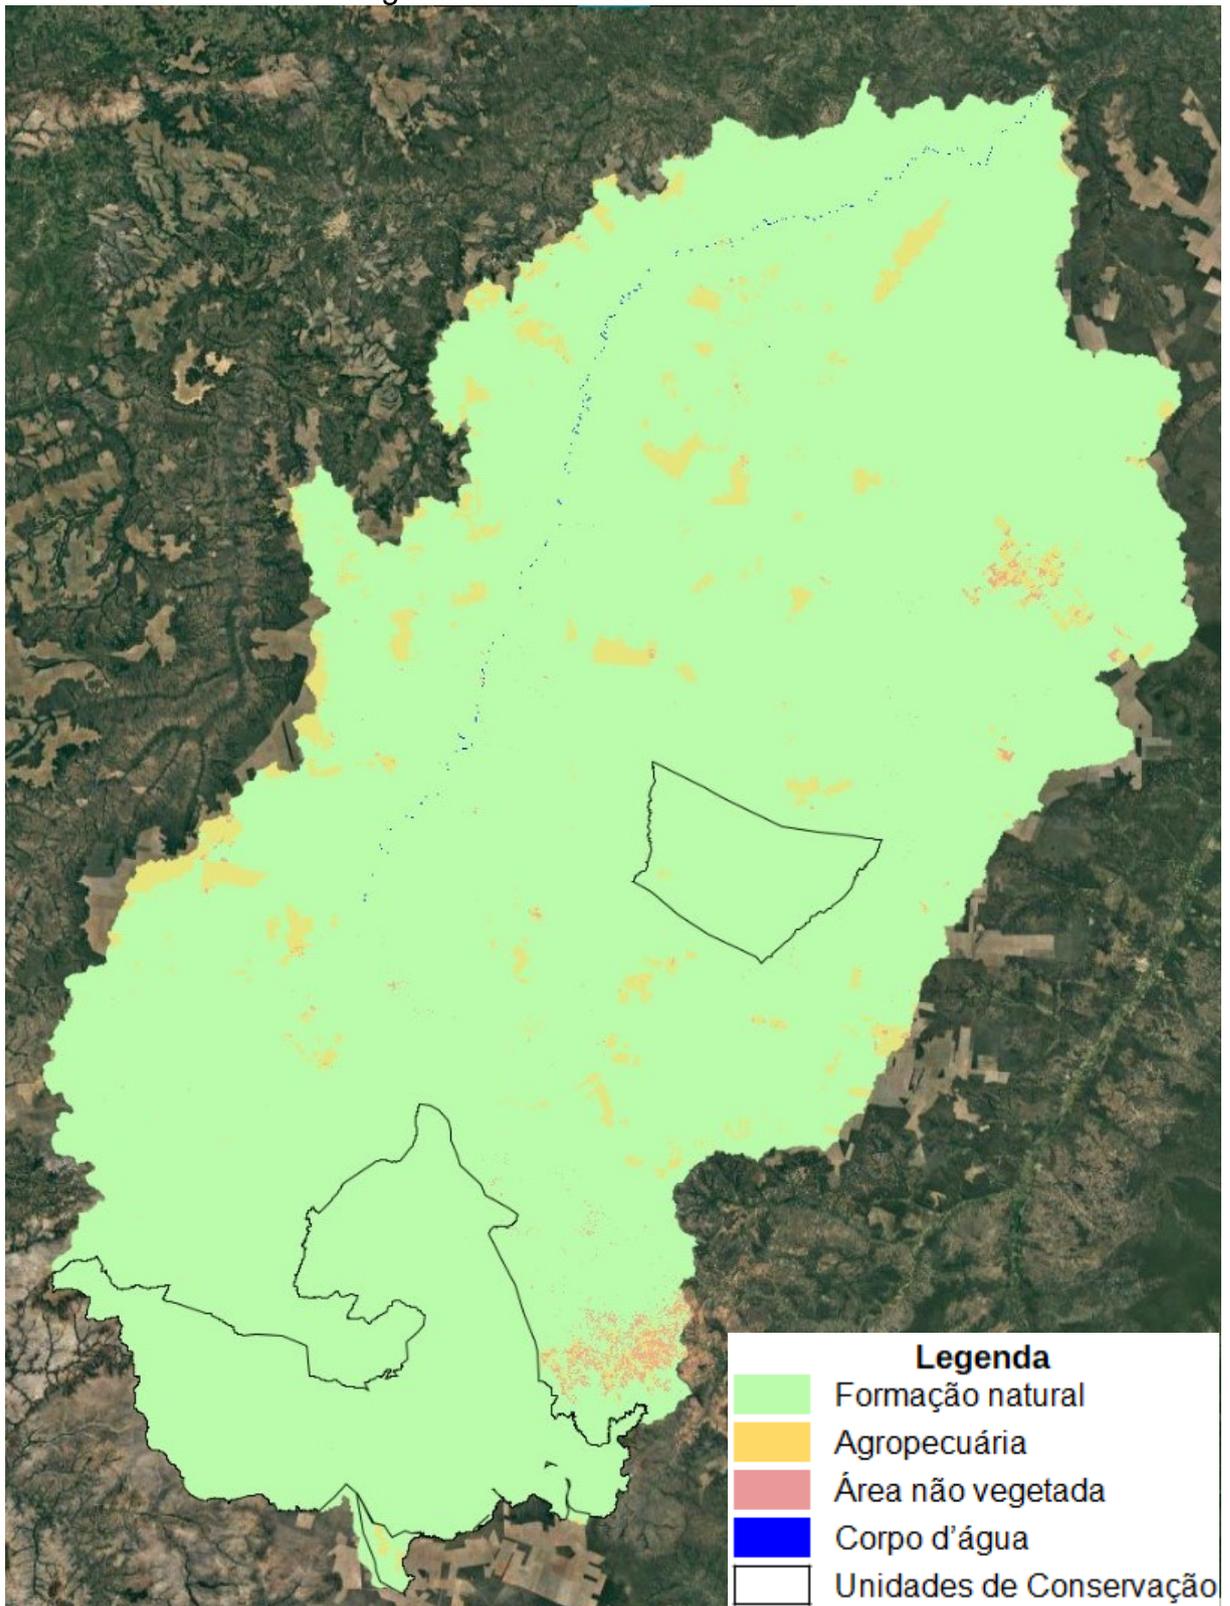
Por fim, foi produzido um gráfico da média anual de precipitação acumulada mensal de 2001 a 2019 seguindo a mesma lógica utilizada na geração dos gráficos anteriores. Portanto, foi inserida em cada uma das 228 imagens a informação de qual ano ela é referente e, a partir disto, calculada a média de precipitação acumulada por ano. Seu *script* é o último desenvolvido e é disponibilizado no Apêndice G.

5 RESULTADOS E DISCUSSÃO

5.1 QUANTO AO USO E COBERTURA DO SOLO

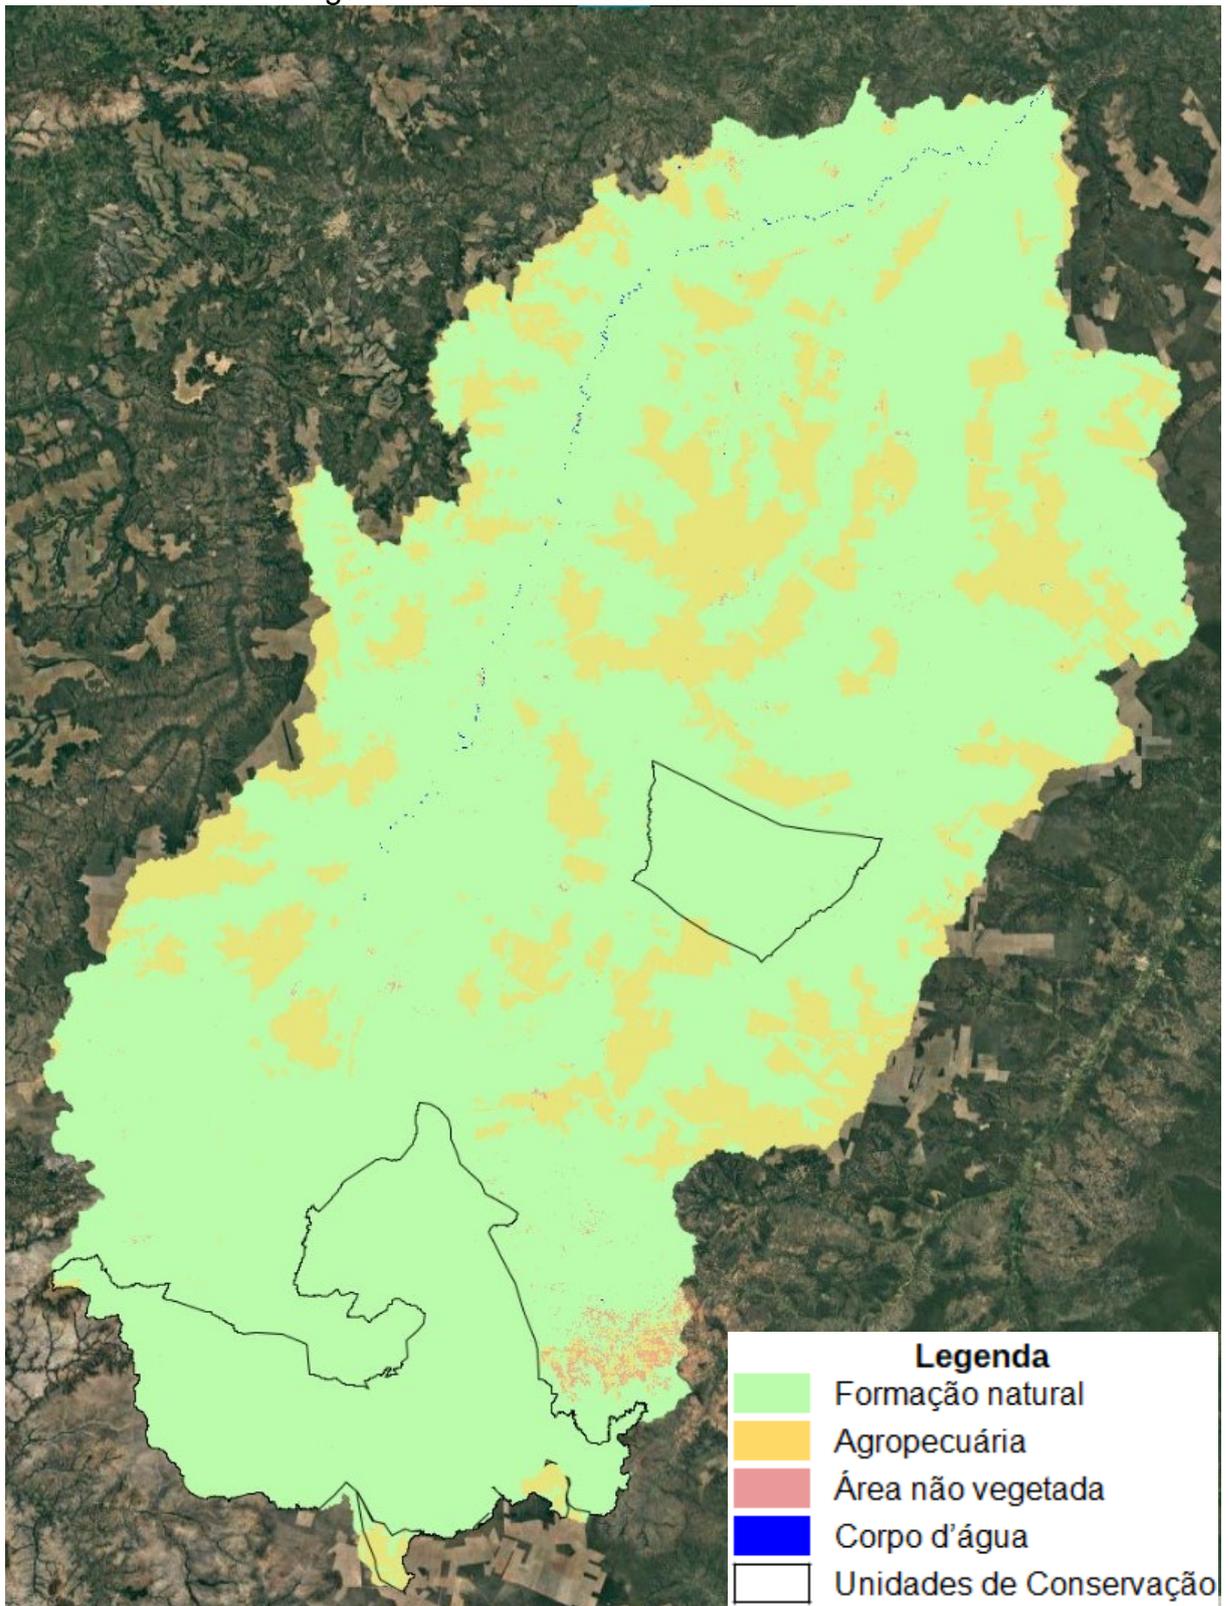
Para dimensionar a expansão agrícola na área selecionada para o estudo, foi feita a distinção entre os diferentes usos e coberturas do solo, com base nos produtos do MapBiomas. Após a primeira reclassificação dos *pixels*, foram obtidas as imagens apresentadas na Figura 7 para o ano de 2001 e, na Figura 8, 2019. É evidenciado em verde as áreas de “Formação Natural”, composta pelas formações Florestal, Savânica e Campestre. Em amarelo são distinguidas as áreas destinadas ao uso agropecuário, que combina as classes “Pastagem”, “Soja” e “Outras”, sendo este último referente a outras culturas temporárias. Em tons em rosa avermelhado e azul estão representadas, respectivamente, “Área não vegetada” (constituída por “Infraestrutura Urbana” e “Outra Área Não Vegetada”) e “Corpo d’água”. Por fim, os polígonos com contorno preto são as Unidades de Conservação presentes na BH.

Figura 7 – Uso e cobertura do solo em 2001



Fonte: Dados do MapBiomias (2020) adaptados pela autora (2022). Imagem orbital TerraMetrics (Google, 2021).

Figura 8 – Uso e cobertura do solo em 2019



Fonte: Dados do MapBiomias (2020) adaptados pela autora (2022). Imagem orbital TerraMetrics (Google, 2021).

É visível que houve um avanço expressivo da classe denominada “Agropecuária” sobre a “Formação Natural”. Esta, conforme mostra a Tabela 4,

abrangia uma área de aproximadamente 49.370,16 km² no ano de 2001, equivalente a mais de 95% da área total, e foi reduzida a 41.383,34 km² em 2019, 80% da área total, configurando uma diminuição de 7.986,82 km² (15,44%). A classe “Agropecuária”, por sua vez, expandiu de 2.006,76 km² para 9.994,94 km² neste período, um aumento de 7.988,18 km². Por fim, as outras duas classes, “Área não vegetada” e “Corpo d’água”, não apresentaram relevantes alterações.

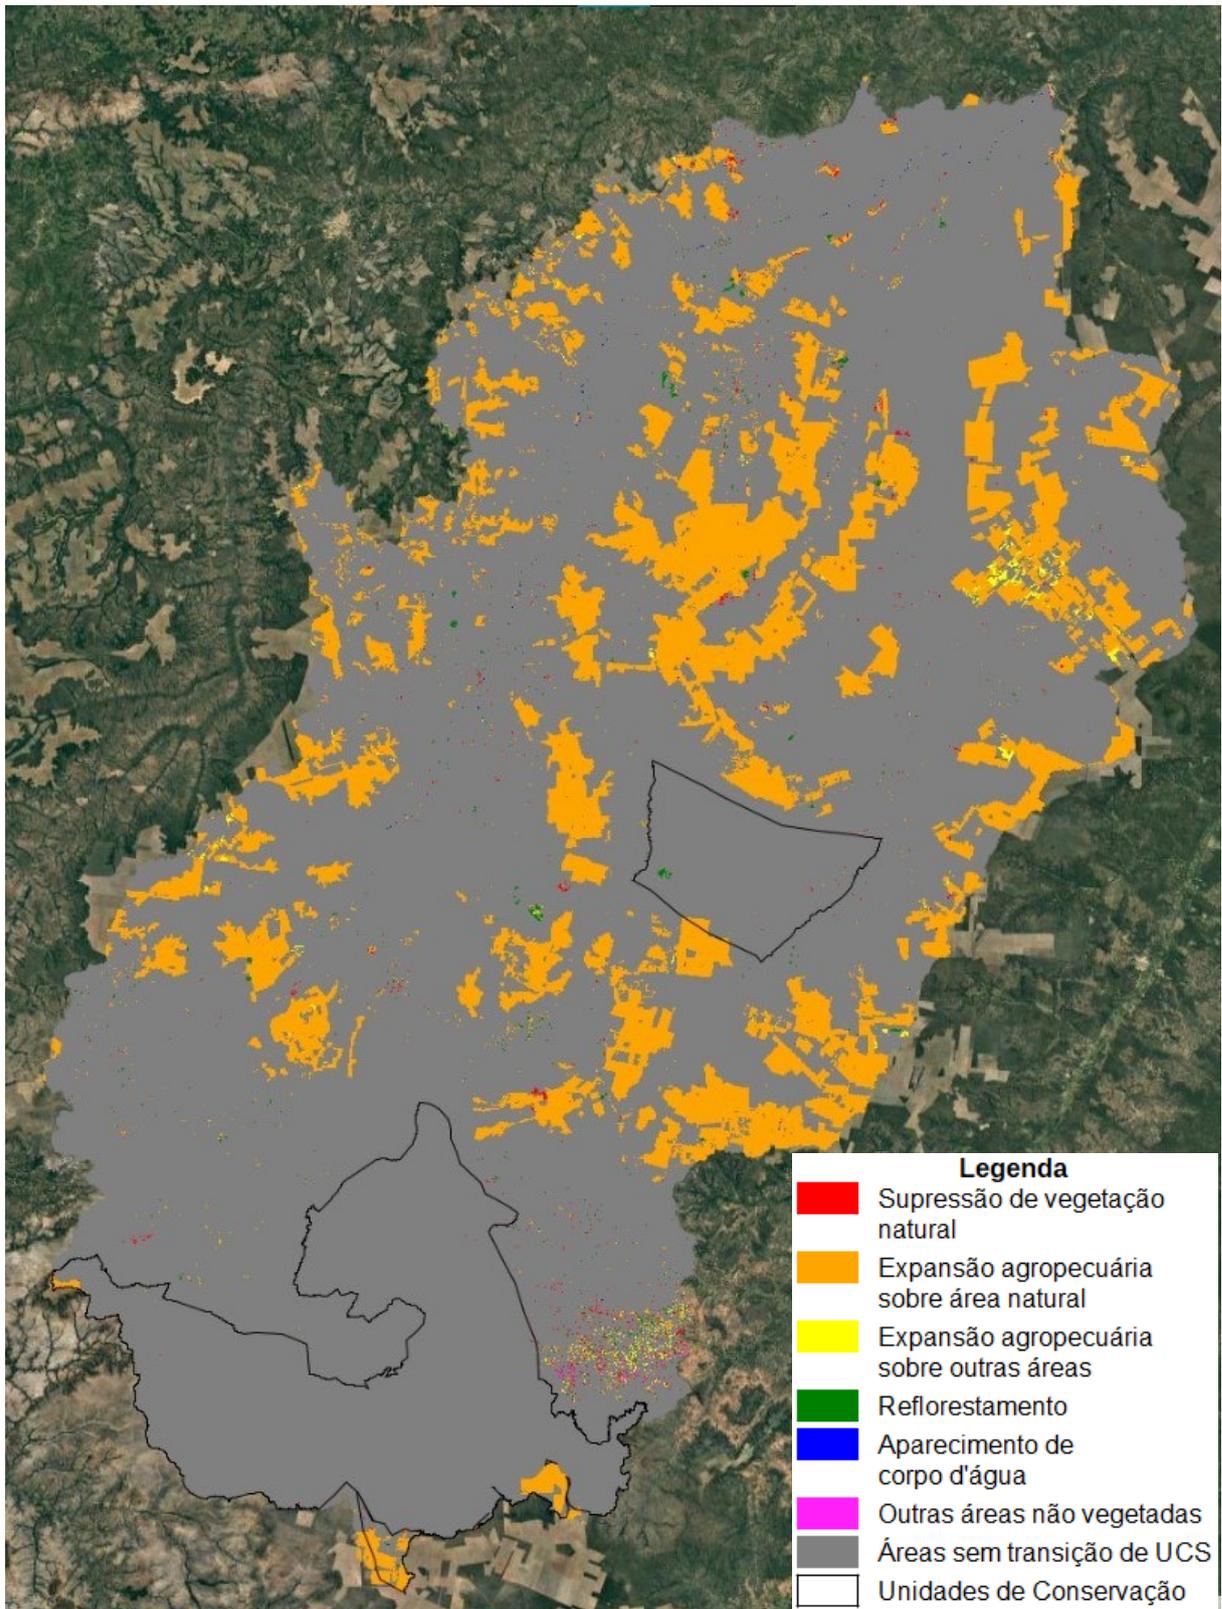
Tabela 4 – Quantificação das áreas ocupadas por uso e cobertura do solo em cada ano e a diferença obtida entre 2001 e 2019

UCS	2001		2019		Diferença	
	km ²	%	km ²	%	km ²	%
Formação Natural	49.370,16	95,44	41.383,34	80,00	-7.986,82	-15,44
Agropecuária	2.006,76	3,88	9.994,94	19,32	7.988,18	15,44
Área não vegetada	325,42	0,63	324,29	0,63	-1,13	0,00
Corpo d’água	27,20	0,05	26,97	0,05	-0,23	0,00

Fonte: Dados do MapBiomas (2020) adaptados pela autora (2022).

Analisando as Figuras 7 e 8 juntamente dos dados contidos na Tabela 4, é possível inferir que as áreas de “Formação Natural”, suprimidas neste período foram convertidas para “Agropecuária”. Confirmando esta hipótese, a Figura 9 ressalta, em laranja, as áreas as quais de fato passaram por esta modificação de UCS. De forma mais tímida, nota-se em vermelho, amarelo, verde, azul e rosa os *pixels* correspondentes a “Supressão de vegetação natural”, “Expansão agropecuária sobre área natural”, “Expansão agropecuária sobre outras áreas”, “Reflorestamento”, “Aparecimento de corpo d’água” e “Outras áreas não vegetadas” respectivamente. Ocupando grande parte da imagem, a cor cinza é referente à superfície onde não ocorreu transição, ou seja, é identificada a mesma classe em 2001 e em 2019, e, em contorno preto, as Unidades de Conservação.

Figura 9 – Áreas que sofreram alteração de uso e cobertura do solo entre 2001 e 2019



Fonte: Dados do MapBiomias (2020) adaptados pela autora (2022). Imagem orbital TerraMetrics (Google, 2021).

Complementando a Figura 9, a quantificação da área ocupada pelas classes que representam algum tipo de alteração entre os dois anos é indicada na Tabela 5. Destaca-se que entre os 8.364,86 km² que sofreram mudanças, 95,28% é relativo a “Expansão agropecuária sobre área natural”. Além disso, outros 135,19 km² de vegetação natural foram suprimidos devido a motivos distintos e foram abertos 119,41 km² de áreas voltadas para a agropecuária sobre locais que não são cobertos por vegetação natural.

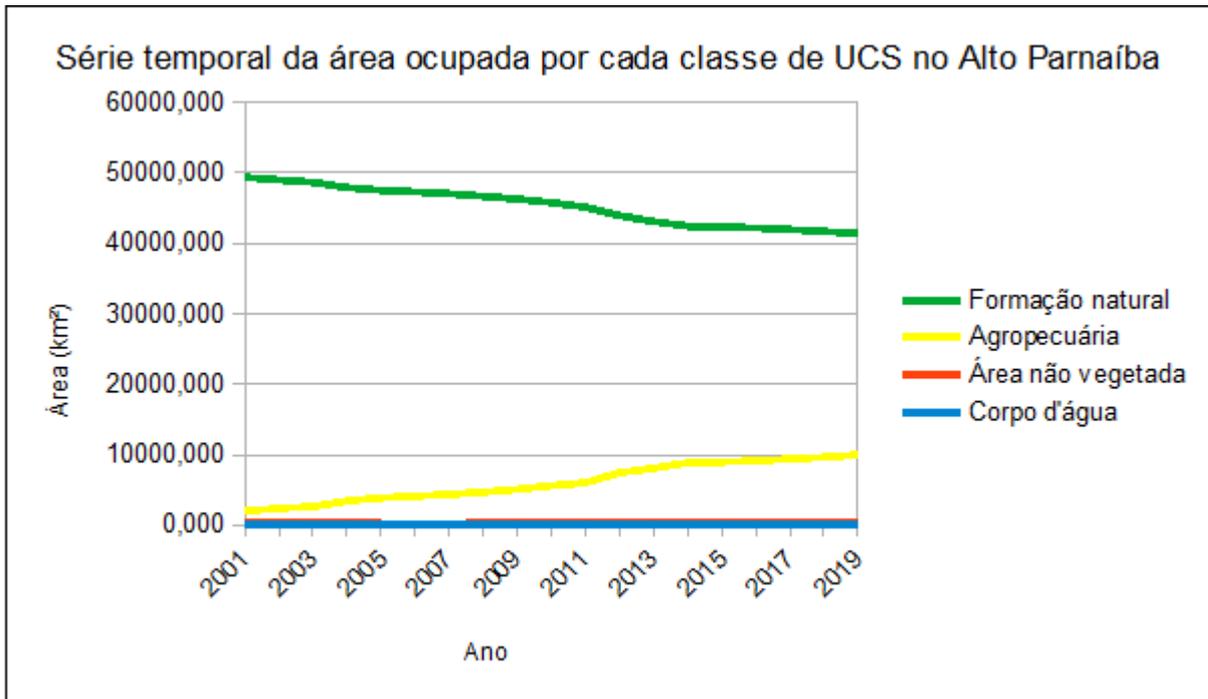
Tabela 5 – Quantificação das áreas que sofreram alteração de uso e cobertura do solo entre 2001 e 2019

Transição	Área (km²)	%
Supressão de vegetação natural	135,19	1,62
Expansão agropecuária sobre área natural	7.970,43	95,28
Expansão agropecuária sobre outras áreas	119,41	1,43
Reflorestamento	120,75	1,44
Aparecimento de corpo d'água	2,01	0,02
Outras áreas não vegetadas	17,07	0,20
Total	8364,86	-

Fonte: Dados do MapBiomas (2020) e adaptados pela autora (2022).

Apesar do aumento considerável de áreas voltadas para o cultivo agrícola ou para a pecuária no Matopiba ter início no final do século XX, este evento continua sendo observado nos dias atuais, assim como apresenta o Gráfico 1.

Gráfico 1 – Série temporal da área ocupada por classe de uso e cobertura do solo entre 2001 e 2019



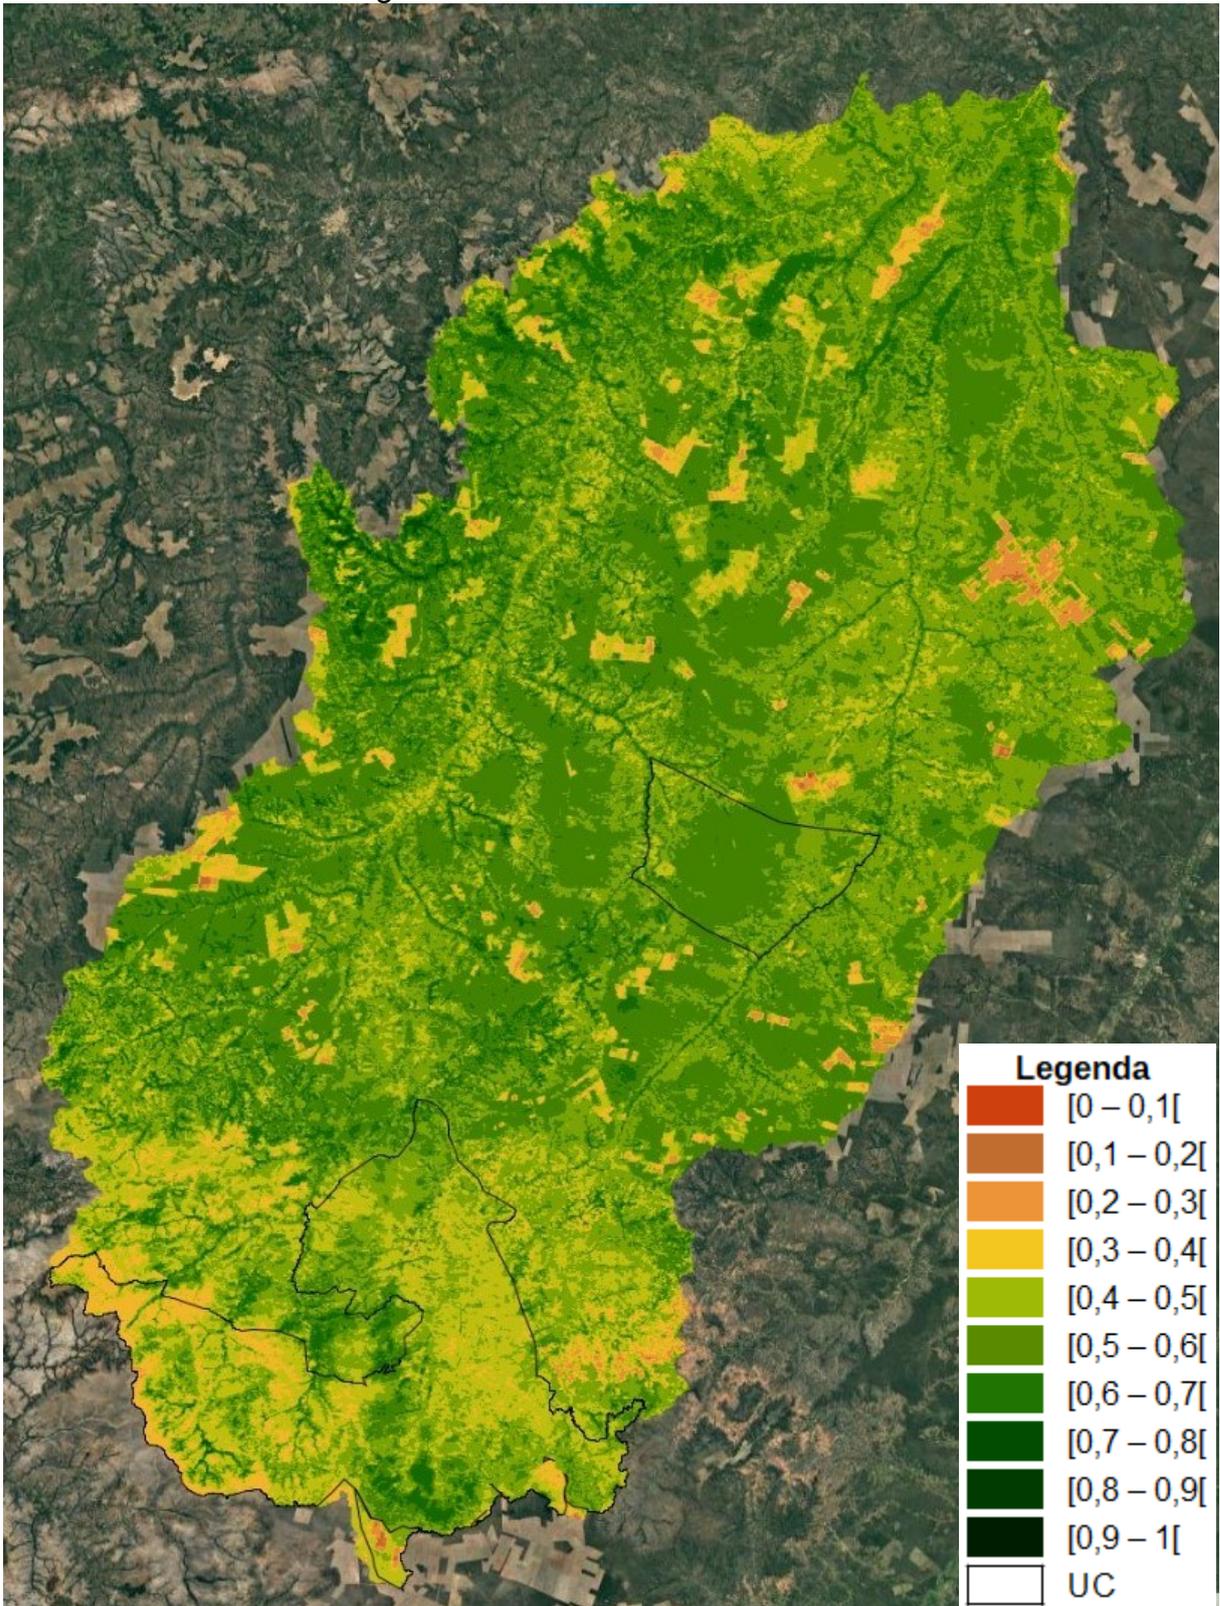
Fonte: Dados do MapBiomias (2020) e adaptados pela autora (2022).

De 2001 até 2019, nota-se uma tendência linear de crescimento da classe “Agropecuária”, representada pela cor amarela no Gráfico 1, enquanto a “Formação natural”, em verde, apresentou um declínio em proporção semelhante. Dados divulgados pela Agrosatélite (2020) reforçam esta análise ao indicar que ocorreu no Matopiba significativo aumento do desmatamento associado ao cultivo de soja entre os anos 2000 e 2014. No período seguinte, até 2019, contudo, houve uma diminuição expressiva deste quadro.

5.2 QUANTO AO ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA

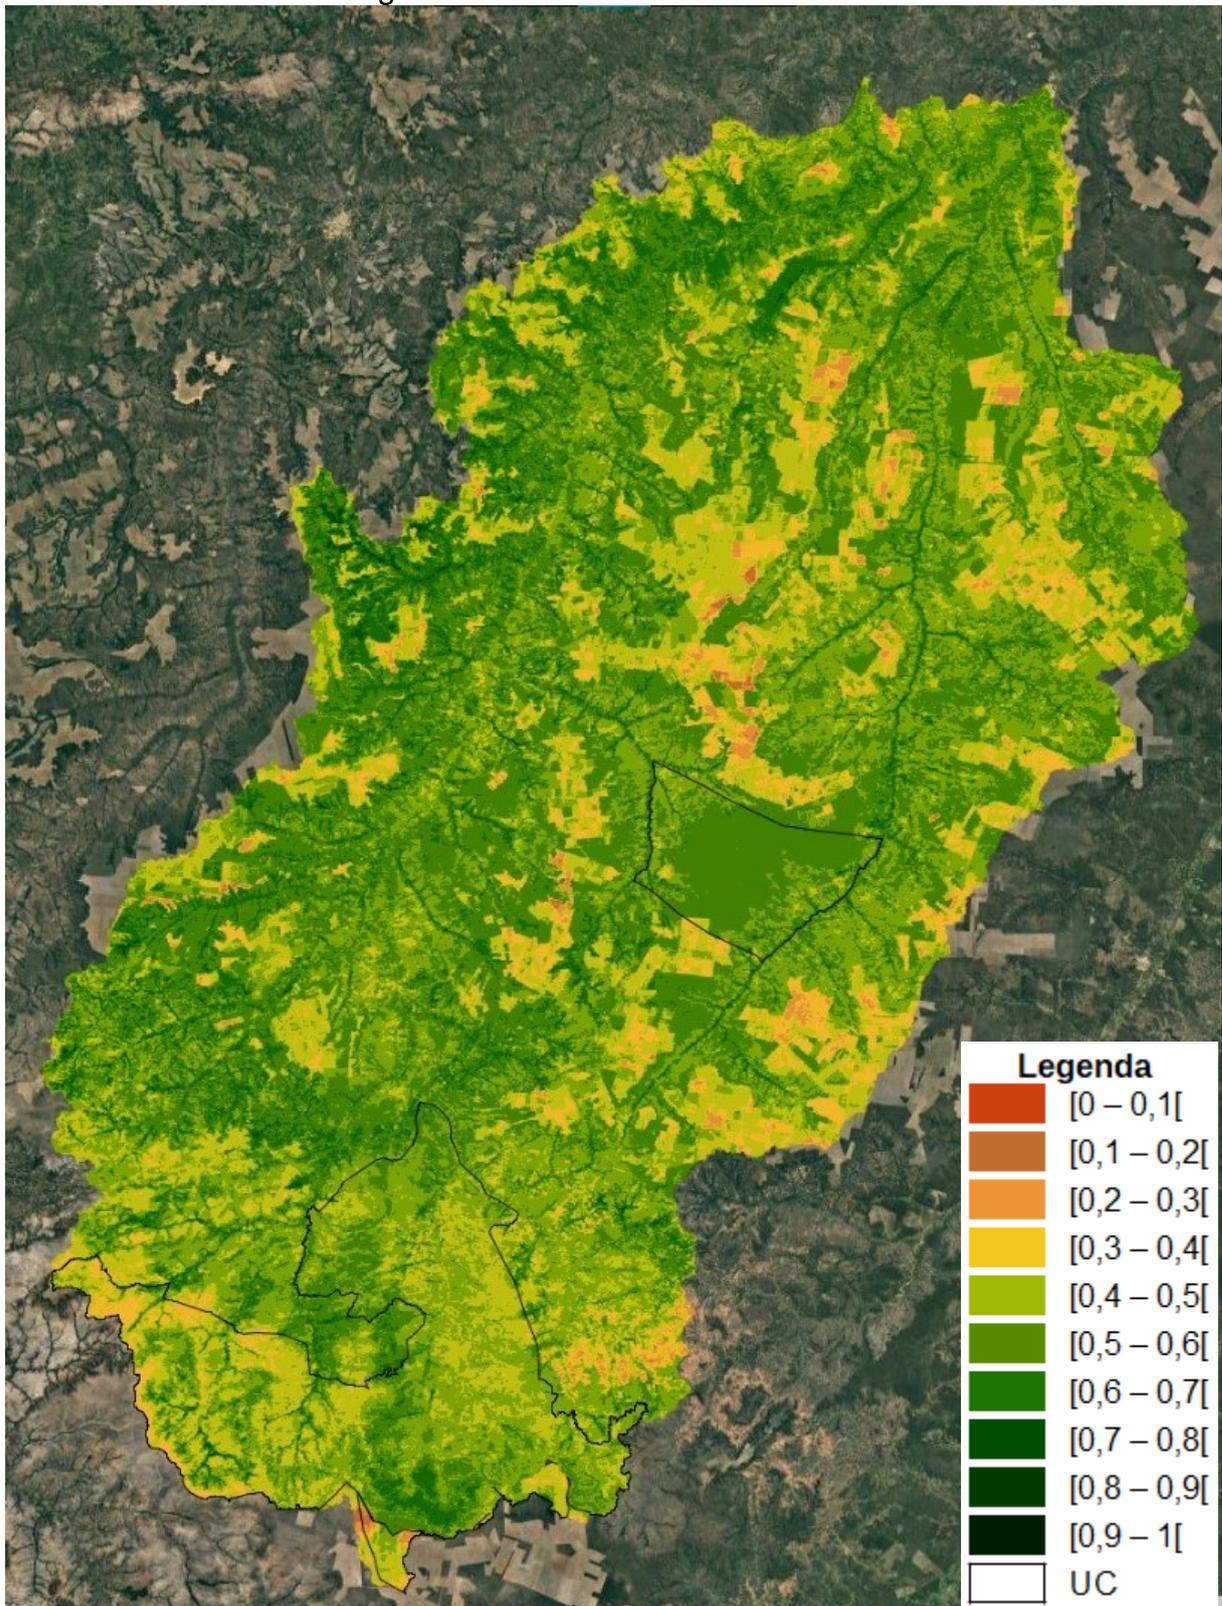
Em relação ao NDVI, observa-se nas Figuras 10 e 11 as médias reclassificadas de 2001 e 2019 respectivamente, sendo os tons marrons referentes aos valores inferiores, amarelo e verde-claro aos valores médios e as variações de verde-escuro aos valores altos. O contorno preto ilustra as UC presentes na área em estudo.

Figura 10 – Média de NDVI em 2001



Fonte: Dados do sensor MODIS adaptados pela autora (2022). Imagem orbital TerraMetrics (Google, 2021).

Figura 11 – Média de NDVI em 2019



Fonte: Dados do sensor MODIS adaptados pela autora (2022). Imagem orbital TerraMetrics (Google, 2021).

As mudanças que mais se destacam ocorreram em grandes áreas na porção centro-norte da BH que em 2001 são apresentadas na cor verde e em 2019 estão

com uma coloração mais amarelada, indicando uma evidente diminuição no índice de vegetação.

É interessante notar que, no sul da região, feições com NDVI médio mais baixo também são observadas e que, no entanto, não se tratam de áreas de transição de UCS de acordo com a Figura 9. Este comportamento é constatado tanto em 2001 quanto em 2019, não sendo verificadas significativas alterações entre os dois anos. Vale destacar que esta paisagem é legalmente protegida por se tratar de uma Unidade de Conservação Federal, o Parque Nacional das Nascentes do Rio Parnaíba, sendo seu objetivo contribuir para a manutenção de um ecossistema ambientalmente relevante.

Anterior à análise da distribuição da vegetação, foi necessário conferir a resposta espectral das áreas vegetadas em alguns pontos amostrais para ser utilizado como base. Sendo assim, foram coletados pontos no sul da área de estudo, todos em áreas de proteção ambiental (PARNA Nascentes do Rio Parnaíba e APA Serra da Tabatinga), referentes à vegetação densa, vegetação rala e áreas de uso agropecuário, identificados a partir de imagem orbital de alta resolução disponível no Google Earth Pro e confirmados pelos dados de UCS do MapBiomas (2020). A Figura 12 apresenta a área amostral, no qual o ponto sinalizado pela letra “D” é referente à vegetação densa¹², “R” para rala¹³ e “A” para agrícola¹⁴. O valor aproximado de NDVI registrado nestes locais em 2001 e 2019 respectivamente foi de 0,19 e 0,37 para A, 0,41 e 0,4 para R e, para D, 0,76 nos dois anos. No entanto, em outros locais da BH, também foram verificadas amostras de vegetação esparsa com NDVI em torno de 0,5 e, em áreas de uso agrícola, 0,4. Quanto à vegetação densa, foram conferidos valores que atingiam 0,65 na ESEC Urucuí-Una, área protegida localizada no centro da área de estudo, havendo ali poucos casos de NDVI acima de 0,7. Portanto, IV maior que 0,5 provavelmente é referente à vegetação natural, sendo mais viçosa quanto mais próximo de 1, enquanto índices entre 0,4 e 0,5 podem ser, além de áreas de vegetação não tão densas, talhões agrícolas.

12 Coordenada lat/long em grau decimal do ponto amostral D: -10.219770°, -45.840310°

13 Coordenada lat/long em grau decimal do ponto amostral R: -10.152470°, -46.002340°

14 Coordenada lat/long em grau decimal do ponto amostral A: -10.295130°, -45.922150°

Figura 12 – Área amostral de vegetação densa, rala e uso agrícola



Fonte: Imagem orbital Landsat/Copernicus (Google Earth Pro, 2022).

Assim como é apresentado na Tabela 6, os intervalos nos quais houve retração de área são os com NDVI de 0,5 a 0,6 e 0,6 a 0,7. Em 2001, foi conferido valores do índice nestes intervalos em cerca de 75% do Alto Parnaíba e, em 2019, este número caiu para aproximadamente 67%. Em contrapartida, no T1, 13,62% da área de estudo apresentava NDVI entre 0,4 a 0,5 e no T2 esta taxa aumentou para 17,57%.

Tabela 6 – Quantificação das áreas ocupadas por intervalo de NDVI em cada ano e a diferença obtida entre 2001 e 2019

Intervalos de NDVI	2001		2019		Diferença	
	km ²	%	km ²	%	km ²	%
[0 – 0,1[0,00	0,00	0,00	0,00	0,00	0,00
[0,1 – 0,2[29,50	0,06	48,67	0,09	19,17	0,04
[0,2 – 0,3[450,03	0,87	452,25	0,87	2,22	0,00
[0,3 – 0,4[2074,87	4,01	2913,92	5,63	839,05	1,62
[0,4 – 0,5[7047,60	13,62	9089,65	17,57	2042,05	3,95
[0,5 – 0,6[18556,51	35,87	16839,58	32,55	-1716,93	-3,32
[0,6 – 0,7[20281,27	39,21	18166,31	35,12	-2114,96	-4,09
[0,7 – 0,8[3159,39	6,11	4046,28	7,82	886,88	1,71
[0,8 – 0,9[129,03	0,25	172,40	0,33	43,38	0,08
[0,9 – 1[0,00	0,00	0,18	0,00	0,18	0,00
Sem dado	1,04	0,00	0,00	0,00	-1,04	0,00

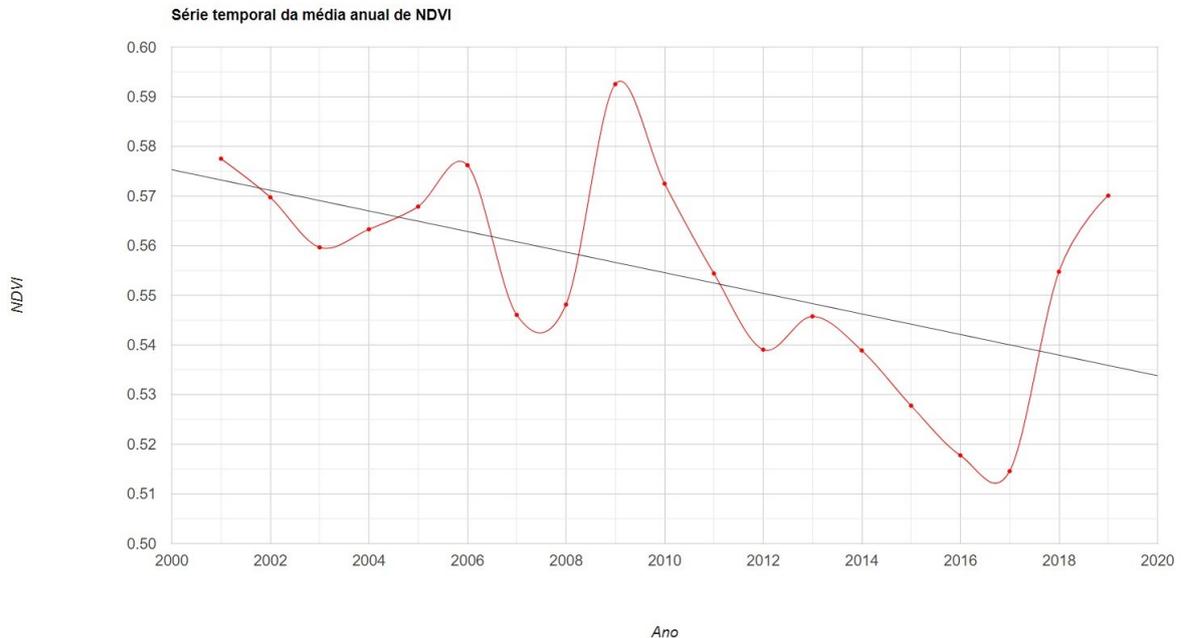
Fonte: Dados do sensor MODIS adaptados pela autora (2022).

De forma menos expressiva, os intervalos de 0,3 a 0,4 e 0,7 a 0,8 também expandiram, nesta ordem, de 4,01% e 6,11% para 5,63% e 7,82%. O aumento de aproximadamente 886,88 km² neste último caso é curioso pois, conforme visto nos dados de transição de UCS, a única classe que caracterizaria a ampliação de área vegetada seria a de “Reflorestamento”. A superfície reflorestada neste período, no entanto, é irrisória, contando com cerca de 120,75 km² apenas. Assim, a expansão desta faixa de NDVI pode não estar relacionada “quantitativamente” à vegetação, mas “qualitativamente”: neste caso, locais onde já contavam com uma cobertura vegetal em 2001, responderam com um índice mais alto em 2019. Ressalta-se que há, dentro do limite escolhido para este estudo, quatro Unidades de Conservação e que, por serem áreas protegidas, propiciam o desenvolvimento da flora, fazendo com que este fenômeno seja plausível.

Ainda assim, é possível afirmar que o NDVI da BH, de modo geral, diminuiu. Em 2001, sua média total foi de 0,58 e, em 2019, caiu para 0,57. Apesar de ser pequena a diferença, a série temporal apresentada no Gráfico 2 mostra que há

nesta região uma tendência linear de queda no índice de vegetação, representada pela reta preta.

Gráfico 2 – Série temporal da média anual de NDVI



Fonte: Dados do sensor MODIS adaptados pela autora (2022).

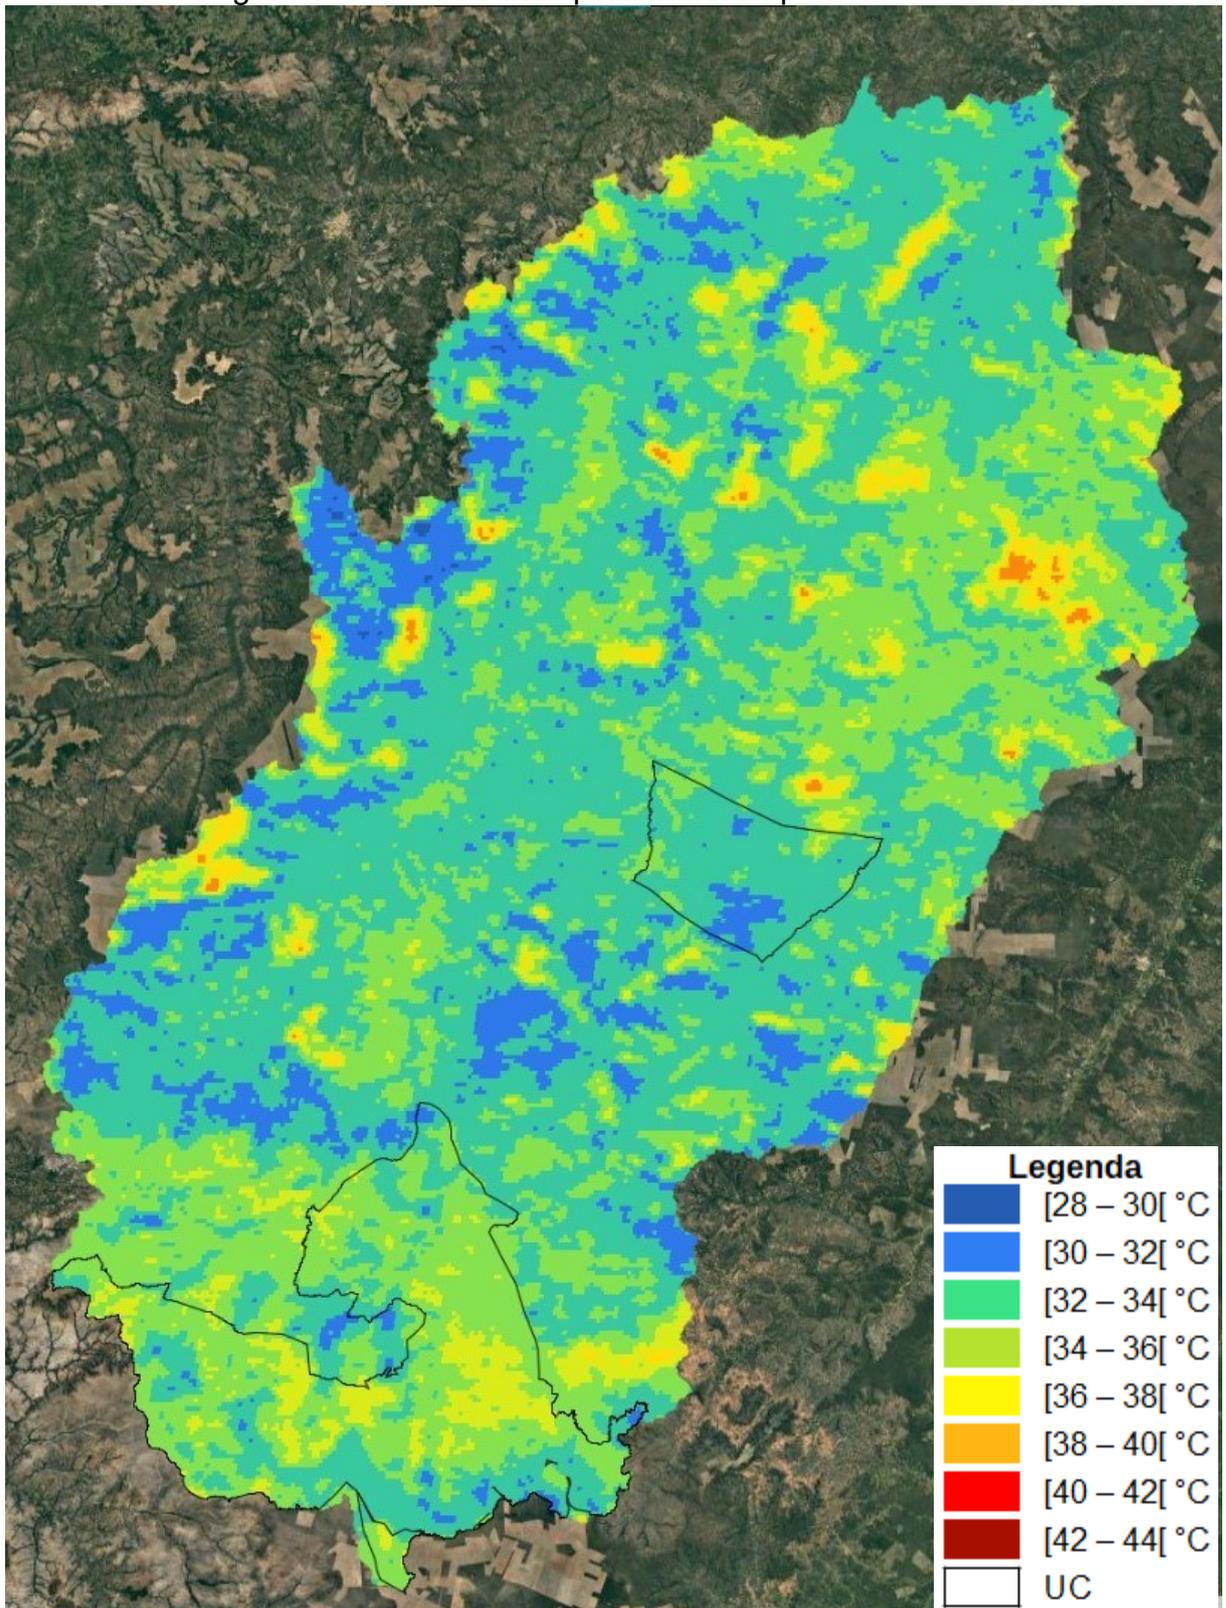
Considerando algumas condições anormais efêmeras que podem afetar a região (como os impactos dos fenômenos atmosférico-oceânico *La Niña* e *El Niño*), é presumível que sejam observados valores discrepantes nas médias anuais dos índices biofísicos ao longo do tempo, ilustrados pela linha vermelha no Gráfico 2. Isto ocorre, por exemplo, em 2009 e 2019, quando é conferido um alto índice de vegetação que diverge do esperado comportamento de declínio.

Por não apontarem onde ocorreram as mudanças, os dados em números, apesar de essenciais para a análise, possuem uma limitação. Este obstáculo, no entanto, pode ser superado ao recorrer ao material do qual os dados quantitativos foram inicialmente extraídos: as imagens. Ao confrontar as imagens de NDVI com as de UCS, verifica-se uma relação espacial entre elas devido à sobreposição de áreas de vegetação em 2001 que foram convertidas para uso agropecuário com as feições no centro-norte da bacia hidrográfica as quais houve perceptível diminuição no IV.

5.3 QUANTO À TEMPERATURA DA SUPERFÍCIE

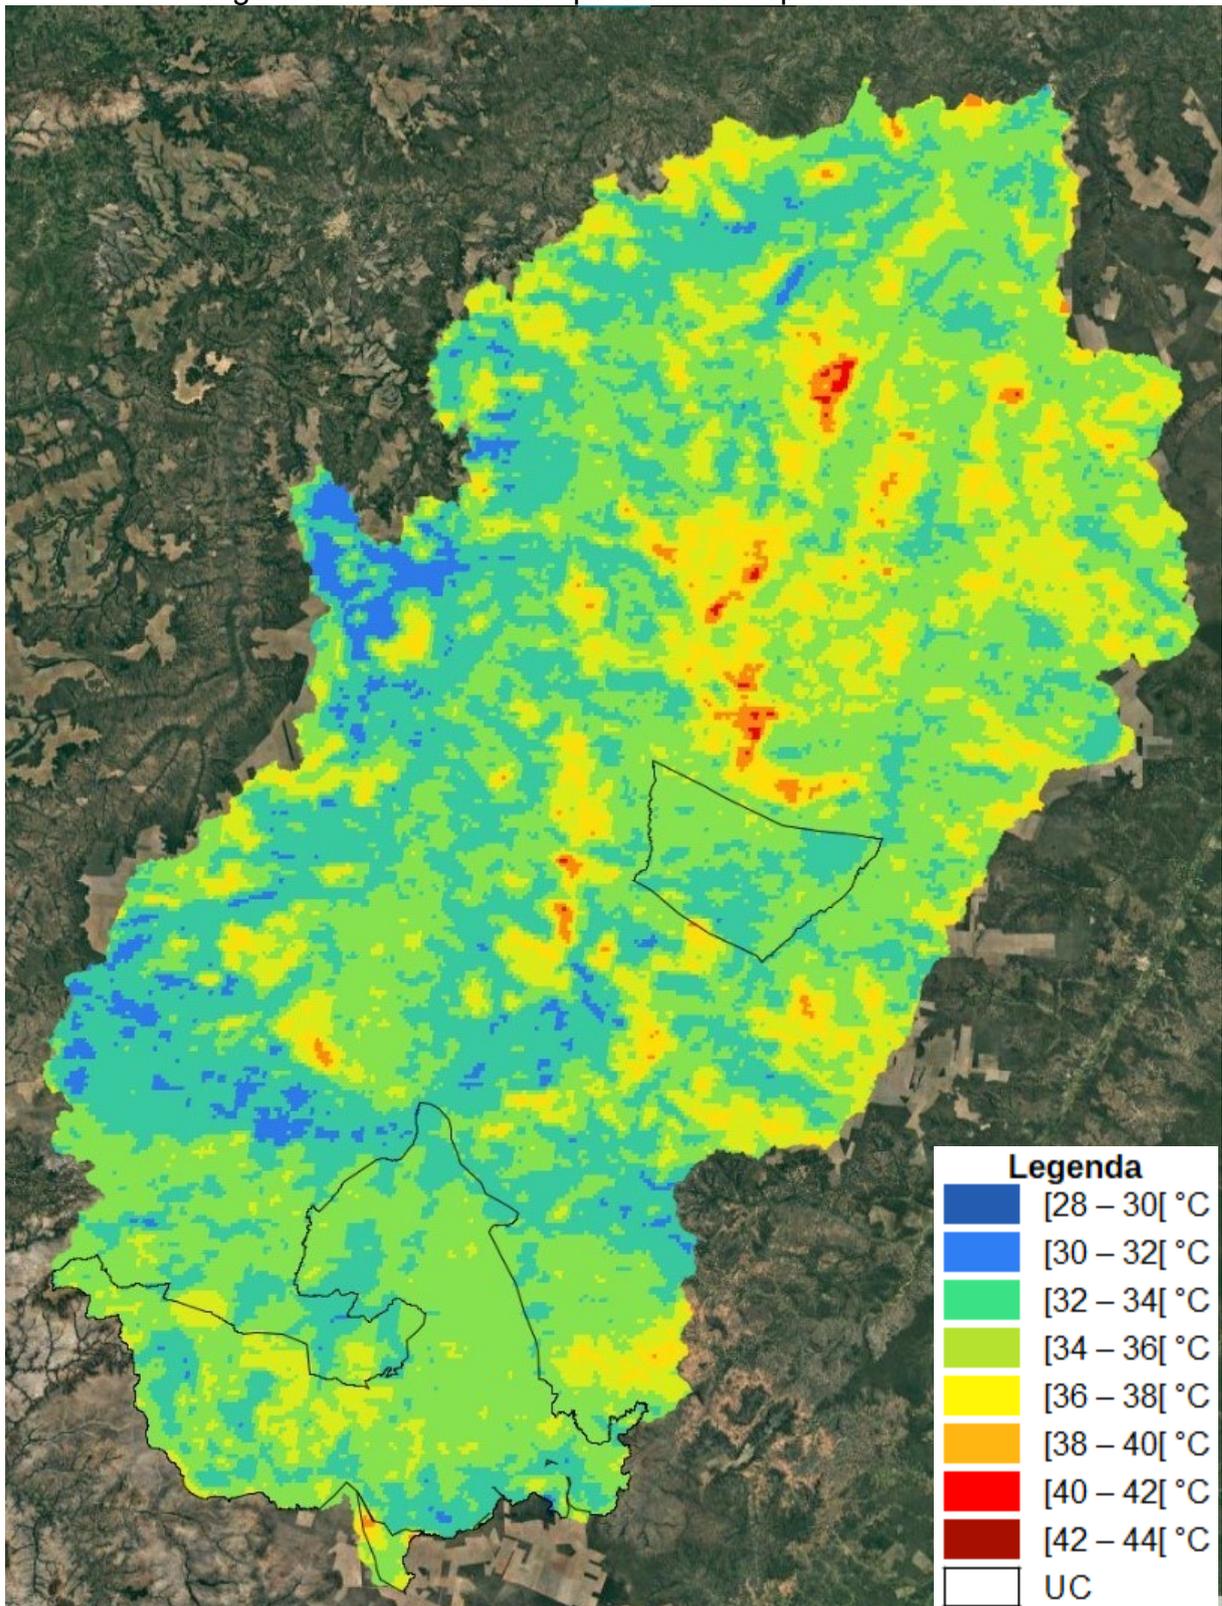
Diretamente relacionado com o índice de vegetação, a temperatura da superfície no Alto Parnaíba em 2001 e 2019 é exposta nas Figuras 13 e 14. Do intervalo de menor temperatura (28 a 30 °C) para o mais elevado (42 a 44 °C), os dados estão ilustrados em azul, verde, amarelo, laranja, vermelho e, por último, bordô, nesta ordem. Já o contorno preto é referente às UC.

Figura 13 – Média da temperatura da superfície em 2001



Fonte: Dados do MODIS adaptados pela autora (2022). Imagem orbital TerraMetrics (Google, 2021)

Figura 14 – Média da temperatura da superfície em 2019



Fonte: Dados do sensor MODIS adaptados pela autora (2022). Imagem orbital TerraMetrics (Google, 2021).

As Figuras 13 e 14 revelam um visível aumento de TS na área em análise, especialmente na parte centro-norte, onde algumas regiões com temperaturas

próximas a 36 °C em 2019, representadas pelas cores quentes, antes apresentavam uma temperatura mais baixa. Em sua maioria, estas feições correspondem também aos locais anteriormente citados de expansão agrícola que tiveram seu índice de vegetação reduzido. Portanto, mesmo com um tamanho de *pixel* diferente, observa-se uma semelhança nas imagens deste indicador com as de NDVI e UCS.

Complementando os dados, na Tabela 7 estão quantificadas as áreas de cada faixa de temperatura observada nas Figuras 13 e 14. Verifica-se que em 2001 59,3% da BH mensurava uma temperatura média abaixo de 34 °C e, em 2019, este valor foi conferido em apenas 32,3% da área em estudo. Por outro lado, 40,7% do Alto Parnaíba apresentou em 2001 temperatura acima de 34 °C e, em 2019, esta porcentagem aumentou para 67,7%.

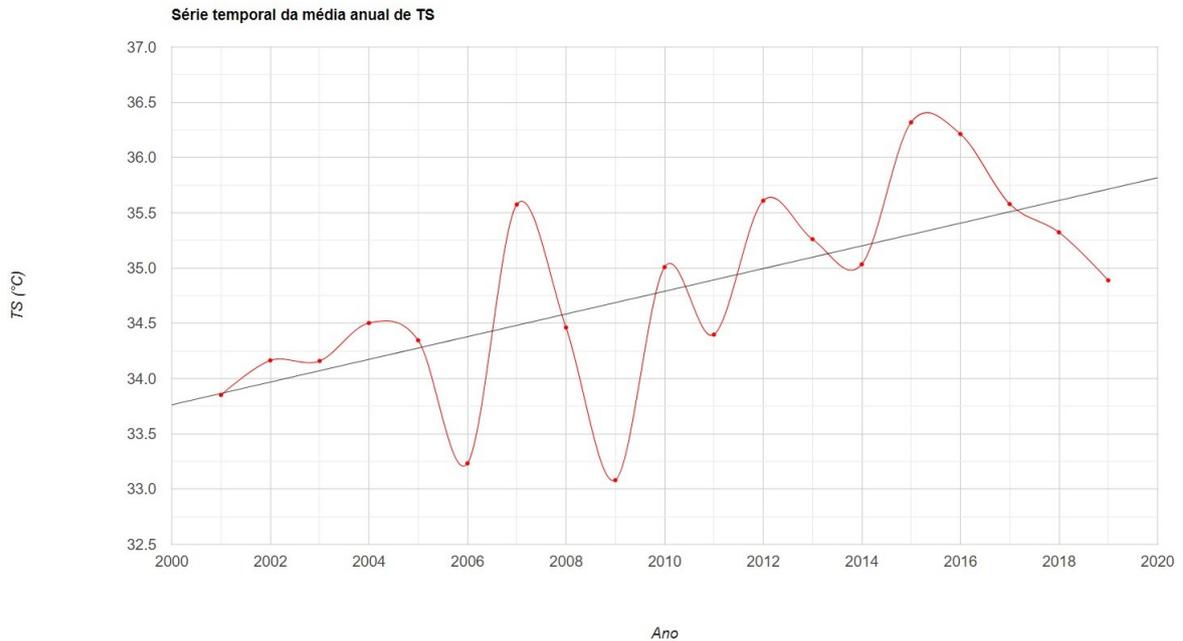
Tabela 7 – Quantificação das áreas ocupadas por intervalo de temperatura da superfície em cada ano e a diferença obtida entre 2001 e 2019

Intervalos de TS (°C)	2001		2019		Diferença	
	km ²	%	km ²	%	km ²	%
[28 – 30[29,51	0,06	0,00	0,00	-29,51	-0,06
[30 – 32[4318,21	8,35	1265,16	2,45	-3053,05	-5,90
[32 – 34[26317,26	50,88	15434,27	29,84	-10882,99	-21,04
[34 – 36[16570,44	32,03	23396,70	45,23	6826,26	13,20
[36 – 38[3615,81	6,99	8557,72	16,54	4941,91	9,55
[38 – 40[768,64	1,49	2612,51	5,05	1843,88	3,56
[40 – 42[108,37	0,21	406,78	0,79	298,41	0,58
[42 – 44[0,00	0,00	55,08	0,11	55,08	0,11

Fonte: Dados do sensor MODIS adaptados pela autora (2022).

Durante este período, portanto, 27% da área total da BH sofreu aumento na temperatura da superfície. No T1, a máxima registrada foi de 41,6 °C e a mínima de 29,3 °C, enquanto no T2 os valores conferidos foram, nesta ordem, 2 °C e 0,7 °C mais altos: 43,6 °C e 30 °C. A média geral, por sua vez, variou em 1 °C, passando de aproximadamente 33,9 °C em 2001 para 34,9 °C em 2019, como aponta o Gráfico 3.

Gráfico 3 – Série temporal da média anual de temperatura da superfície



Fonte: Dados do sensor MODIS adaptados pela autora (2022).

Apesar da série temporal mostrada no Gráfico 3, juntamente dos dados contidos na Tabela 7, revelarem que a área em estudo vem aquecendo ao longo do tempo, é verificada em 2006, 2009 e 2019 uma temperatura média que muito difere do comportamento desenhado pela linha de tendência e, ao confrontar com o NDVI (Gráfico 2), nota-se uma relação inversamente proporcional entre as oscilações de ambos gráficos. Na maior parte dos casos, um alto índice de vegetação está acompanhado de uma baixa temperatura da superfície, como ocorreu nestes anos.

5.4 QUANTO À PRECIPITAÇÃO

Por fim, a precipitação acumulada mensal, último fator a ser examinado nesta pesquisa, se distingue quando comparada aos outros dados devido à sua resolução espacial, sendo o tamanho do *pixel* nas Figuras 15 e 16 maior e, portanto, com um nível de detalhamento menor. Porém, por se tratar de uma variável cuja dimensão não é local, esta característica não prejudica a análise. As 10 classes de precipitação, da menor para a maior, são ilustradas nas imagens em tons de vermelho, laranja, amarelo, verde, azul e roxo. Em contorno preto, estão representadas as UC.

Figura 15 – Média da precipitação acumulada mensal em 2001

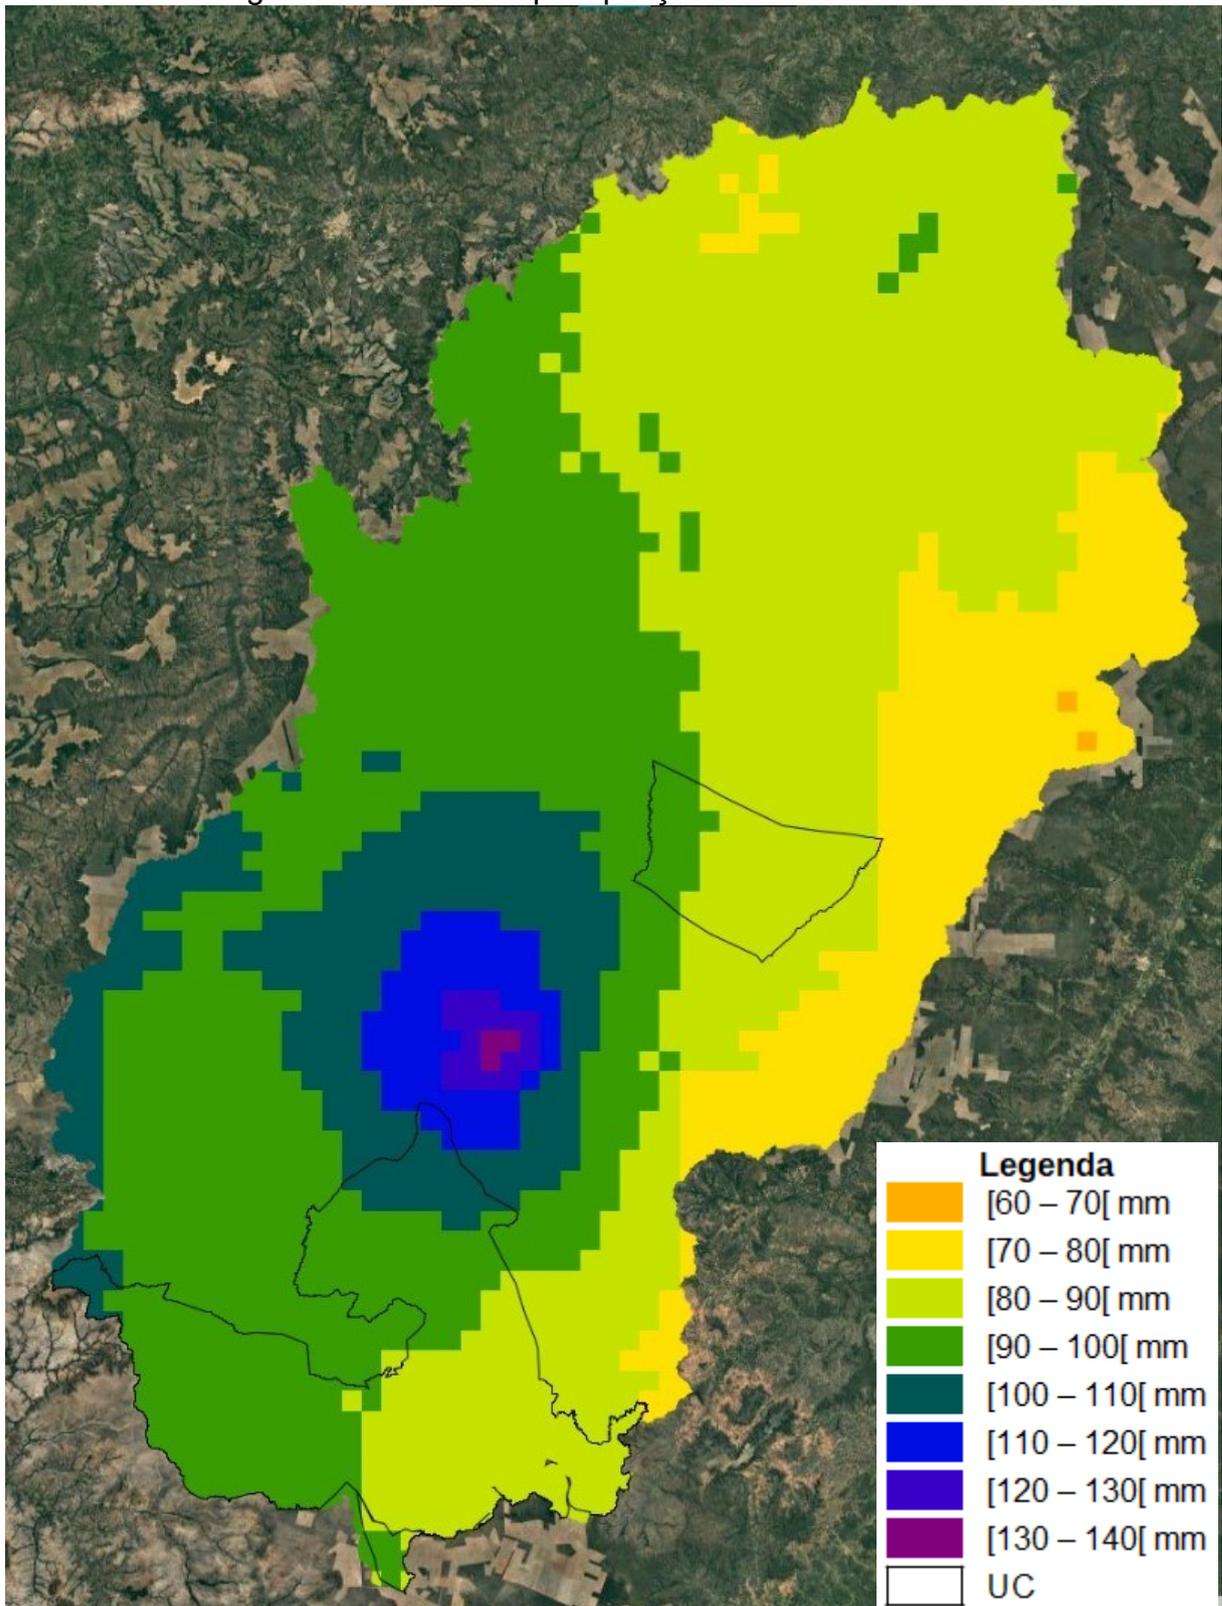
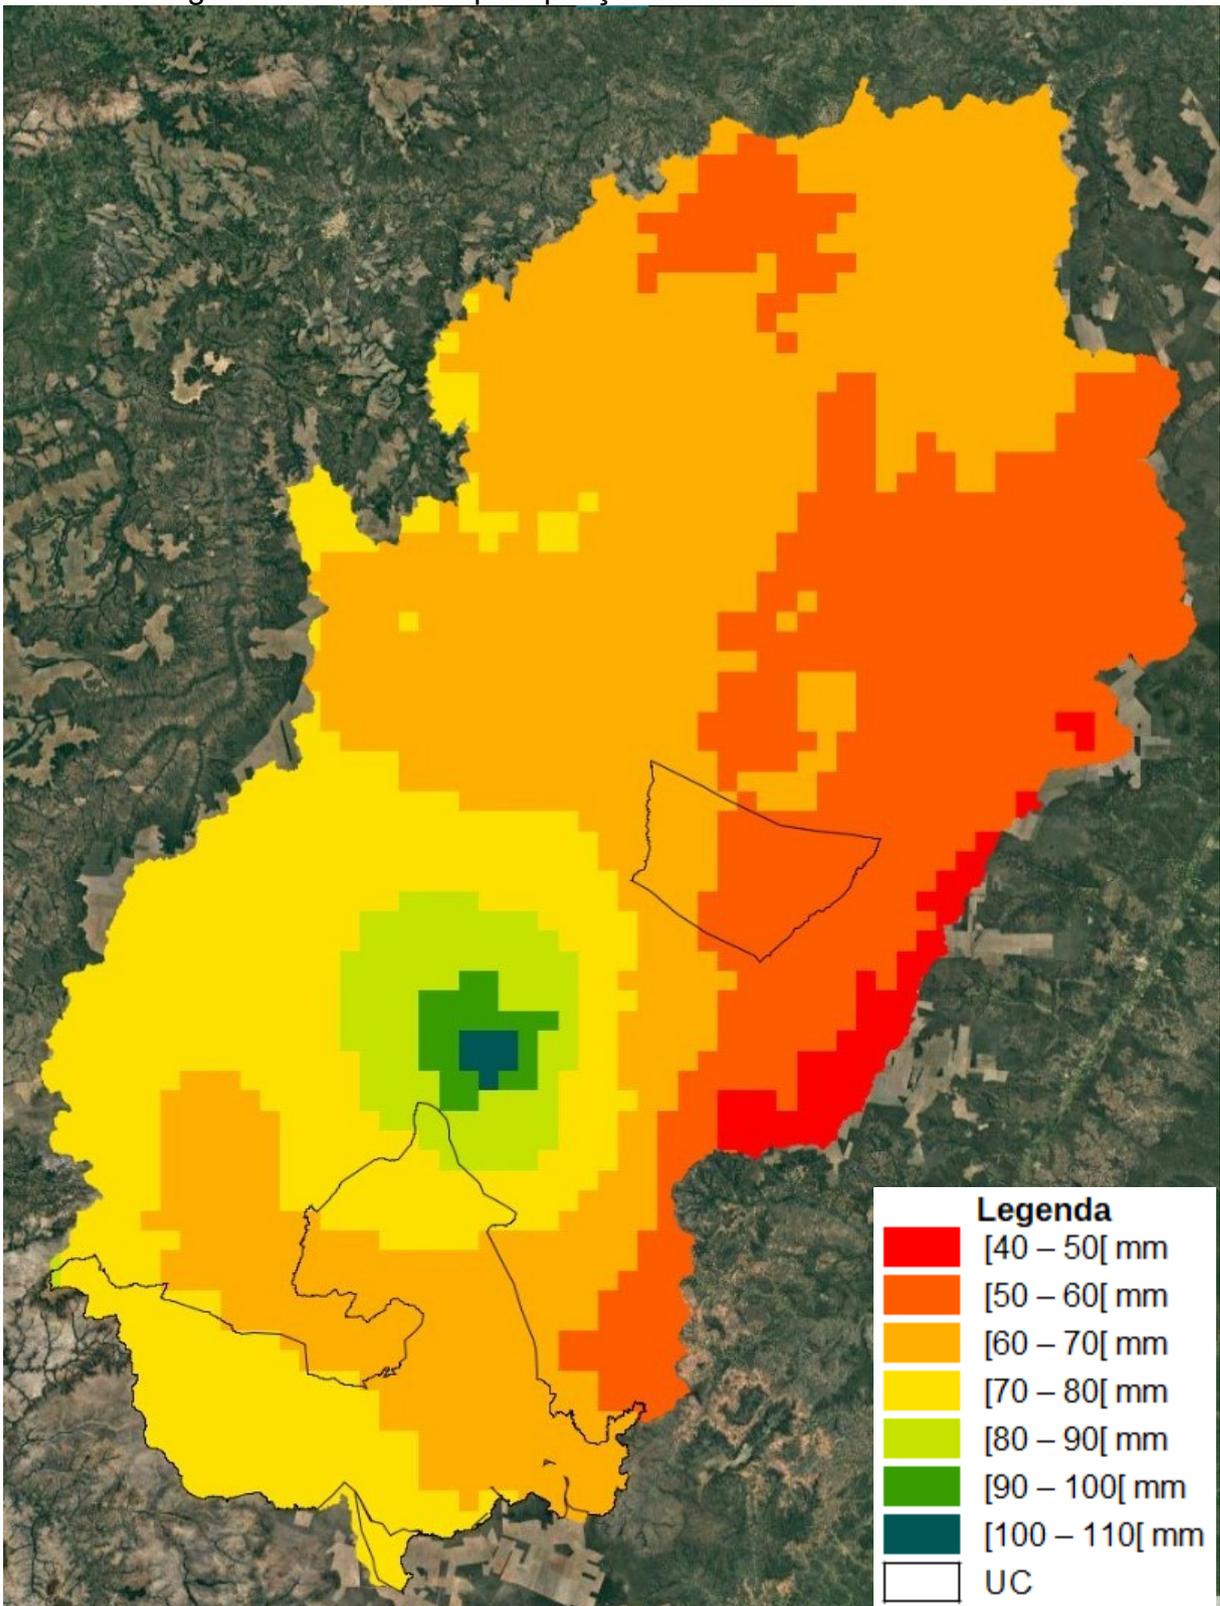


Figura 16 – Média da precipitação acumulada mensal em 2019



Fonte: Dados do TerraClimate adaptados pela autora (2022). Imagem orbital TerraMetrics (Google, 2021).

É evidenciada uma redução na precipitação por toda a região durante o período em análise. Em 2001, o menor valor registrado foi de 60 a 70 mm mensais,

enquanto o maior é de 130 a 140 mm mensais. Já em 2019, constata-se uma mínima de 40 a 50 mm e máxima de 100 a 110 mm mensais.

A distribuição deste indicador desperta atenção pois manteve, em ambos os anos, um mesmo padrão espacial: maior nível pluviométrico no centro-sul da BH e menor na porção nordeste. É importante destacar que se situa nesta parte nordeste significativa parcela das extensões de terra convertidas para o uso agropecuário e, além disso, assim como exposto na caracterização da área em estudo, é onde está localizado um clima cuja particularidade é um menor volume de chuvas.

A quantificação das classes de precipitação, presente na Tabela 8, reforça a informação de diminuição da pluviosidade no Alto Parnaíba, visto que houve uma retração de áreas com volumes maiores que 80 mm acumulados por mês e um aumento de áreas com volumes menores que esse valor. A média total, por sua vez, equivale a 90,51 mm mensais em 2001 e 65,95 mm mensais em 2019, resultando em uma diferença negativa de aproximadamente 25 mm/mês.

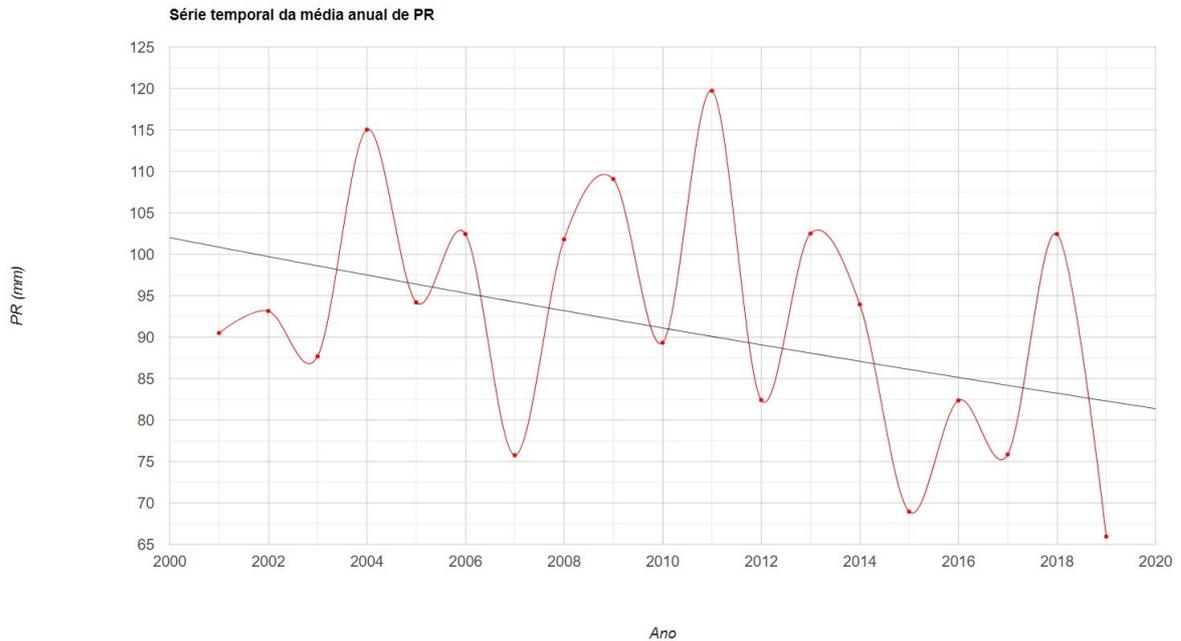
Tabela 8 – Quantificação das áreas ocupadas por intervalo de precipitação acumulada mensal em cada ano e a diferença obtida entre 2001 e 2019

Intervalos de Pr (mm/mês)	2001		2019		Diferença	
	km ²	%	km ²	%	km ²	%
[40 – 50[0,00	0,00	1144,41	2,21	1144,41	2,21
[50 – 60[0,00	0,00	12652,42	24,46	12652,42	24,46
[60 – 70[44,21	0,09	22839,53	44,15	22795,32	44,07
[70 – 80[6300,28	12,18	12222,44	23,63	5922,16	11,45
[80 – 90[20182,90	39,02	2179,93	4,21	-18002,97	-34,80
[90 – 100[17682,75	34,18	541,40	1,05	-17141,34	-33,14
[100 – 110[5633,87	10,89	148,09	0,29	-5485,78	-10,61
[110 – 120[1444,83	2,79	0,00	0,00	-1444,83	-2,79
[120 – 130[375,64	0,73	0,00	0,00	-375,64	-0,73
[130 – 140[63,75	0,12	0,00	0,00	-63,75	-0,12

Fonte: Dados do TerraClimate adaptados pela autora (2022).

O gráfico de Pr (Gráfico 4), diferentemente dos de NDVI e TS, apresenta uma maior quantidade de oscilações desde 2001, o que dificulta a visualização de um padrão dos dados no decorrer dos anos.

Gráfico 4 – Série temporal da média anual de precipitação acumulada mensal



Fonte: Dados do TerraClimate adaptados pela autora (2022).

No entanto, mesmo observando no Gráfico 4 anos com registro de média de chuva mensal mais alto que as médias de 2001 e 2019, a linha de tendência constata uma queda gradual deste índice.

5.5 QUANTO AO GEE

O GEE realizou os processamentos de forma rápida e satisfatória, considerando todas as etapas e procedimentos requeridos. Vale destacar que, para a geração de cada produto, foi utilizada uma enorme quantidade de *rasters*, chegando a 873 para elaborar apenas o gráfico de TS. Tal fator poderia ser configurado como um obstáculo caso não se optasse por utilizar a plataforma, visto que seria necessário realizar o *download* destas imagens e seu tratamento seria presumivelmente custoso.

Além disso, por ser incentivado o compartilhamento de conhecimentos e produtos elaborados utilizando o *Google Earth Engine*, encontram-se diversos materiais disponíveis para consulta e alguns usuários dispostos a auxiliar. Isto facilita, por exemplo, a utilização desta ferramenta por novos cientistas ou por pessoas que não possuem técnica geralmente necessária em tais trabalhos.

5.6 LIMITAÇÕES DA PESQUISA

Durante o processo de elaboração deste trabalho, foram encontradas algumas limitações. Em relação à utilização do *Google Earth Engine*, merecem destaque dois pontos de dificuldade encontrados durante o manuseio da ferramenta, mas que não interferiram negativamente no resultado final desta pesquisa.

O primeiro é referente ao conhecimento sobre programação: apesar de a plataforma simplificar os procedimentos e, dessa forma, possibilitar que mesmo os usuários leigos no assunto consigam utilizá-la, ser familiar a este conhecimento se torna um diferencial, permitindo gerar códigos elaborados e, assim, realizar diversas análises que requerem um melhor domínio desta linguagem. No caso deste trabalho, não foi possível gerar e exportar o gráfico de uso e cobertura do solo pelo GEE, visto que, para isto, seria necessário primeiramente converter os dados contidos em imagem para um arranjo (*array*) organizado por classe e data. Como não foi obtido o resultado esperado após algumas tentativas, optou-se por formular um *array* por ano contendo a área de cada classe e, no *LibreOffice Calc*, elaborar o gráfico.

A segunda limitação está relacionada à exportação para o *Google Drive* das imagens produzidas no *Google Earth Engine*. Por se tratar de uma área relativamente extensa, os arquivos cobrindo toda a BH se tornam pesados, dificultando a ação. Deste modo, foi necessário tirar uma captura de tela, inviabilizando a inserção dos elementos essenciais na construção de um mapa, como o título, grade de coordenadas, norte geográfico, metadados, etc. A escala, exclusivamente, é exibida pela própria plataforma e por isso consta nas capturas. As imagens contendo as legendas, por sua vez, foram montadas separadamente por serem fundamentais para o entendimento e interpretação dos dados.

Por fim, é importante apontar que a resolução espacial dos dados utilizados como base são diferentes. Apesar de idealmente ser utilizada a mesma resolução espacial em todos os elementos para compor uma análise, optou-se por aproveitar *datasets* já disponibilizados no GEE do MODIS e TerraClimate. Esta limitação, portanto, apesar de afetar o diferente detalhamento em cada componente analisado, não impacta negativamente a pesquisa em si, visto que os dados foram tratados separadamente e as áreas foram calculadas de acordo com o tamanho de *pixel* respectivo de cada fonte. Além disso, mesmo com essa adversidade, foi possível

notar correlações espaciais entre os IB e o UCS e realizar reflexões acerca da dinâmica da área ao longo do tempo.

6 CONCLUSÃO

Este trabalho teve como propósito analisar, por meio do *Google Earth Engine*, o comportamento de três índices biofísicos (Índice de Vegetação por Diferença Normalizada, temperatura da superfície e precipitação) frente às mudanças de uso e cobertura do solo em 2001 e 2019 na Bacia Hidrográfica do Alto Parnaíba. Tendo em vista os resultados obtidos, é possível afirmar que os objetivos propostos foram alcançados.

Considerando o que foi exposto, é sinalizada uma mudança na dinâmica da região apontada a partir das alterações dos índices. O estudo revela que, simultaneamente à expansão agrícola, houve elevação da temperatura da superfície e diminuição do índice de vegetação e da precipitação, implicando, possivelmente, no balanço energético e hídrico da área analisada.

Cerca de 30,88% da área total (8.364,86 km²) teve o UCS modificado, e, deste valor, 95,28% (7.970,43 km²) configura-se como expansão agropecuária sobre área natural, consolidando, ao longo do tempo, uma tendência de aumento das áreas de uso agrícola e pecuário e diminuição das de formação natural. No mesmo período, foi observada variação significativa nos índices selecionados para compor a análise. Enquanto o NDVI apresentou uma tendência de queda com a média total caindo de 0,58 para 0,57, indicando a redução de áreas com vegetação mais densa devido à conversão de UCS, a média da TS aumentou de 33,9 °C para 34,9 °C. É possível constatar, além disso, uma correlação espacial entre estes três elementos, sobretudo na região centro-norte do Alto Parnaíba: as áreas naturais que em 2019 revelam-se suprimidas coincidem com as regiões onde se verifica, no mesmo ano, um baixo índice de vegetação e alta temperatura superficial. A Pr também sofreu decaimento entre o T1 e T2, cuja média passou de 90,51 para 65,95 mm mensais, mas manteve um padrão de distribuição semelhante nos dois anos analisados, com um menor volume de chuvas no nordeste, porção parcialmente abrangida por um clima de baixa umidade, o semi árido, e médias de precipitação acumulada mensal mais altas no centro-sul.

O resultado de que a conversão de áreas de vegetação natural para uso agropecuário tem potencial de provocar desequilíbrio em um local com importância ambiental, por fim, vai ao encontro do que vem sendo discutido por diversos pesquisadores (IDEIÃO, 2009; MARTINS *et al.*, 2015; CUNHA *et al.*, 2012). São

expressivas as transformações observadas no Alto Parnaíba e a correlação espacial que elas possuem com o uso e cobertura do solo, gerando potenciais ameaças à própria manutenção da atividade agrícola. Considerando a importância ecológica dessa área que abriga a cabeceira do Rio Parnaíba, é, portanto, imprescindível seu monitoramento para que sejam garantidas condições adequadas ao meio ambiente, à vida humana e à produção.

Quanto ao processamento dos dados, o GEE mostrou-se de grande eficiência, realizando os procedimentos de forma rápida e satisfatória considerando a quantidade de *rasters* utilizados. Houve, no entanto, duas limitações relacionadas à exportação: dos dados de UCS em gráfico e das imagens geradas. Embora não seja um requisito dominar programação para operar a plataforma, seu conhecimento é importante para auxiliar no êxito de ações mais complexas.

Apesar disso, esta ferramenta merece reconhecimento por ser gratuito e facilitar de algumas maneiras o trabalho. A não necessidade de se utilizar uma máquina de qualidade superior, o que seria desejável caso o processamento não fosse realizado em nuvem, a pré-disponibilização de conjuntos de dados na própria plataforma e o incentivo pelo compartilhamento de conhecimento entre os usuários faz com que o trabalho seja mais ágil e menos custoso, fazendo com que o *Google Earth Engine* se destaque como uma opção eficiente e de custo praticamente zero.

Para trabalhos futuros, sugere-se que seja estimado o balanço energético da BH e feita a correlação entre as variáveis. Dessa forma, será possível avaliar e mensurar, de fato, os impactos no sistema. A sequência da análise para os anos posteriores a 2019, além disso, pode gerar dados interessantes, possibilitando a continuação do acompanhamento da dinâmica dessa bacia hidrográfica e suas tendências, fundamentado, assim, tomadas de decisão que busquem equilibrar a interação entre o homem e a natureza. Outro fator a ser aprofundado é referente à mudança da dinâmica em outras áreas de rápida expansão agropecuária, estudando e deixando um alerta sobre o impacto das ações antrópicas no meio ambiente e no clima.

REFERÊNCIAS

- ABATZOGLOU, J. T. *et al.* TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. **Scientific Data**, [S.L.], v. 5, n. 1, 9 jan. 2018. Disponível em: <https://www.nature.com/articles/sdata2017191>. Acesso em: 13 jan. 2021.
- AGROSATÉLITE. **Análise Geoespacial da Soja no Bioma Cerrado: dinâmica da expansão | aptidão agrícola da soja | sistema de avaliação para compensação financeira: 2001 a 2019**. Florianópolis, 2020. 60 p. Disponível em: https://agrosatelite.com.br/wp-content/uploads/2020/06/relatorio_ccm_Agrosatelite_pt.pdf. Acesso em: 10 fev. 2022.
- ANA. **Região Hidrográfica Parnaíba**. In: MMA. **Conjuntura dos recursos hídricos no Brasil: regiões hidrográficas brasileiras**. Brasília: ANA, 2015. p. 110-123. Disponível em: <https://arquivos.ana.gov.br/institucional/sge/CEDOC/Catalogo/2015/ConjunturaDosRecursosHidricosNoBrasil2015.pdf>. Acesso em: 25 nov. 2021.
- ANDRADE, S. C. de P. **Sensoriamento remoto aplicado ao estudo do balanço de energia em áreas de floresta e pastagem em Rondônia no Brasil**. 2014. 95 f. Dissertação (Mestrado em Meteorologia) - Universidade Federal de Campina Grande, Campina Grande, 2014. Disponível em: <http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/3845>. Acesso em: 4 maio 2020.
- ARAÚJO, M. L. S. de. **Dinâmica espaço-temporal da cultura de soja na região do Matopiba, Brasil (1990-2015)**. 2018. 68 f. Dissertação (Mestrado em Geociências Aplicadas e Geodinâmica) - Instituto de Geociências, Universidade de Brasília, Brasília, 2018. Disponível em: http://repositorio.unb.br/bitstream/10482/32871/1/2018_MayaraLucyAnneSantosdeAraujo.pdf. Acesso em: 21 mar. 2019.
- AYOADE, J. O. Umidade atmosférica / Precipitação. In: AYOADE, J. O. **Introdução à climatologia para os trópicos**. 4. ed. Rio de Janeiro: Bertrand Brasil, 1996. p. 128-179. Trad. Maria Juraci Zani dos Santos; rev. Suely Bastos; coord. Antonio Christofolletti. Disponível em: https://www2.ifmg.edu.br/governadorvaladares/pesquisa/laboratorio-de-climatologia/livros/ayoade-j-o-_introducao_a_climatologia_para_os_tropicos.pdf. Acesso em: 21 jan. 2022.
- BOLFE, E. L. *et al.* Matopiba em crescimento agrícola: aspectos territoriais e socioeconômicos. **Revista de Política Agrícola**, [S. l.], v. 25, n. 4, p. 38-62, out./dez. 2016. Disponível em: <https://seer.sede.embrapa.br/index.php/RPA/article/view/1202/1025>. Acesso em: 13 mar. 2020.
- BOURSCHEIDT, V. Análise da tendência da temperatura de superfície a partir de imagens Landsat 5: contribuições da plataforma Google Earth Engine. In: SIMPÓSIO

BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2017, Santos. **Anais [...]**. Santos: Instituto Nacional de Pesquisas Espaciais, 2019, p. 7401-7407. Disponível em: <http://marte2.sid.inpe.br/rep/sid.inpe.br/marte2/2017/10.27.16.21.18>. Acesso em: 09 out. 2019.

CONCEIÇÃO, A. F. **Balço de energia da superfície nas bacias hidrográficas dos rios Cachoeira e Atibainha do Sistema Cantareira por meio de sensoriamento remoto**. 2018. 167 f. Dissertação (Mestrado em Geografia) - Instituto de Geociências, Universidade Estadual de Campinas, Campinas, 2018. Disponível em: <http://repositorio.unicamp.br/jspui/handle/REPOSIP/333382>. Acesso em: 4 maio 2020.

CUNHA, J. E. de B. L. *et al.* Dinâmica da cobertura vegetal para a Bacia de São João do Rio do Peixe, PB, utilizando-se sensoriamento remoto. **Rev. bras. eng. agríc. ambient.**, Campina Grande, v. 16, n. 5, p. 539-548, 2012. DOI 10.1590/S1415-43662012000500010. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662012000500010&lng=en&nrm=iso. Acesso em: 23 jan. 2019.

DIDAN, K. *et al.* **MODIS Vegetation Index: User's Guide** (v. 3, collection 6). 2015. Disponível em: https://landweb.modaps.eosdis.nasa.gov/QA_WWW/forPage/user_guide/MODISC6V1Userguide.pdf. Acesso em: 15 dez. 2020.

EMBRAPA. **Soja produzida no Matopiba representa 11% da produção nacional**. Brasil, 2018. Disponível em: <https://www.embrapa.br/busca-de-noticias/-/noticia/33775633/soja-produzida-no-matopiba-representa-11-da-producao-nacional>. Acesso em: 20 jan. 2019.

FAUSTO, M. A. *et al.* Impacto da alteração do uso do solo no saldo de radiação no Cerrado do sul de Mato Grosso. **Ambiente & Água**, Taubaté, v. 11, n. 2, p. 350-361, abr./jun. 2016. Disponível em: <http://www.ambi-agua.net/seer/index.php/ambi-agua/article/view/1843>. Acesso em: 7 maio 2020.

FERREIRA *et al.* Análise sazonal das temperaturas superficiais do Estado de Santa Catarina entre os anos de 2000 e 2010. In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, 27.; EXPOCARTTA, 26., 2017, Rio de Janeiro. **Anais [...]**. Rio de Janeiro: Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto, 2017, p. 933-937. Disponível em: <http://www.cartografia.org.br/cbc/2017/trabalhos/4/718.html>. Acesso em: 23 jan. 2019.

GANEM, K. A. **Classificação da cobertura do solo na Caatinga a partir de imagens do Landsat-8 e da ferramenta Google Earth Engine: uma comparação entre dados com e sem correção atmosférica**. 2017. 202 f. Dissertação (Mestrado em Geociências Aplicadas) - Instituto de Geociências, Universidade de Brasília, Brasília, 2017. Disponível em: <http://repositorio.unb.br/handle/10482/23501>. Acesso em: 15 fev. 2019.

GIONGO, P. R. **Mapeamento do balanço de energia e evapotranspiração diária por meio de técnicas de sensoriamento remoto**. 2011. 122 f. Tese (Doutorado em Irrigação e Drenagem) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2011. Disponível em: <https://teses.usp.br/teses/disponiveis/11/11143/tde-13092011-092028/pt-br.php>. Acesso em: 4 maio 2020.

GOMES, H. B. *et al.* Balanço de radiação em diferentes biomas no estado de São Paulo mediante imagens Landsat 5. **Geociências**, São Paulo, v. 28, n. 2, p. 153-164, abr./maio 2009. Disponível em: <https://www.periodicos.rc.biblioteca.unesp.br/index.php/geociencias/article/view/3383>. Acesso em: 4 maio 2020.

GORELICK, N. *et al.* Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, [S.l.], v. 202, p. 18-27, dez. 2017. DOI 10.1016/j.rse.2017.06.031 Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425717302900?via%3Dihub>. Acesso em: 15 jan. 2019.

GUERRA, J. B.; SCHULTZ, B.; SANCHES, I. D. A. Mapeamento automático da expansão da agricultura anual no MATOPIBA entre 2002 e 2015 utilizando a plataforma Google Earth Engine. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2017, Santos. **Anais [...]**. Santos: Instituto Nacional de Pesquisas Espaciais, 2019, p. 6850-6857. Disponível em: <http://marte2.sid.inpe.br/rep/sid.inpe.br/marte2/2017/10.27.15.57>. Acesso em: 02 jan. 2019.

HUETE, A. *et al.* **MODIS Vegetation Index (MOD13): Algorithm Theoretical Basis Document (v. 3)**. 1999. Disponível em: https://modis.gsfc.nasa.gov/data/atbd/atbd_mod13.pdf. Acesso em: 15 dez. 2020.

IBGE. **Biomass e sistema costeiro-marinho do Brasil: compatível com a escala 1:250 000**. Rio de Janeiro: IBGE, 2019. 168 p. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101676.pdf>. Acesso em: 1 dez. 2021.

IDEIÃO, S. M. A. **Imagens multiespectrais e aplicações em recursos hídricos: temperatura da superfície e balanços de radiação e energia**. 2009. 156 f. Dissertação (Mestrado em Engenharia Civil e Ambiental) - Centro de Tecnologia e Recursos Naturais, Universidade Federal de Campina Grande, Campina Grande, 2009. Disponível em: <http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/4062>. Acesso em: 23 jan. 2019.

INPE. **El Niño/La Niña: efeitos globais**. 2016. Disponível em: <http://enos.cptec.inpe.br/#>. Acesso em: 03 nov. 2020.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução de J. C. N. Epiphanyo (coord.). 2en ed. São José dos Campos: Parêntese, 2009.

LIBERATO, A. M. *et al.* Uso de técnicas de sensoriamento remoto na estimativa do saldo de radiação em Rondônia. **Pesquisa & Criação**, [Porto Velho], v. 10, n. 2, p. 153-164, jul./dez. 2011. Disponível em: <https://periodicos.unir.br/index.php/propesq/article/view/421>. Acesso em: 4 maio 2020.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. Campo Grande: UNIDERP, 2007.

MAPBIOMAS. **Algorithm Theoretical Basis Document**: Coleção 5 (v. 1) da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil. 2020. 48 p. Disponível em: https://mapbiomas-br-site.s3.amazonaws.com/ATBD_Collection_5_v1.pdf. Acesso em: 10 nov. 2020.

MARTINS, A. L. *et al.* Mudanças em Índices Biofísicos devido à Alteração da Cobertura do Solo em Área Nativa de Cerrado em Mato Grosso. **Ciência e Natura**, [S.l.], v. 37, n. 3, p. 152-159, set. 2015. DOI 10.5902/2179460X16145. Disponível em: <https://periodicos.ufsm.br/cienciaenatura/article/view/16145>. Acesso em: 23 jan. 2019.

MATIAS, L. F. **Sistema de Informações Geográficas (SIG)**: teoria e método para representação do espaço geográfico. 2001. Tese (Doutorado em Geografia Humana) - Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 2001. Disponível em: <https://bdpi.usp.br/item/001169780>. Acesso em: 10 abr. 2019.

MENESES, P. R.; ALMEIDA, T. de. **Introdução ao processamento de imagens de Sensoriamento Remoto**. Universidade de Brasília – UNB. Brasília. 2012. Disponível em <http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>. Acesso em: 09 nov. 2018.

MMA. **Caderno da Região Hidrográfica do Parnaíba**. Brasília: MMA, 2006. 184 p.

NOVO, E. M. L. de M. **Sensoriamento remoto**: princípios e aplicações. 4 ed. São Paulo: Blucher, 2010.

OLIVEIRA, G. de. **Modelagem do balanço de energia e evapotranspiração na Amazônia brasileira e com uso de imagens MODIS e ASTER**. 2012. 227 f. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012. Disponível em: <http://mtc-m16d.sid.inpe.br/col/sid.inpe.br/mtc-m19/2012/05.10.18.32/doc/publicacao.pdf>. Acesso em: 4 maio 2020.

OLIVEIRA, T. H. de. **Mudança espaço temporal do uso e cobertura do solo e estimativa do balanço de energia e evapotranspiração diária no município do Recife-PE**. 2012. 154 f. Dissertação (Mestrado em Geografia) - Universidade Federal de Pernambuco, Recife, 2012. Disponível em: https://more.ufsc.br/tese_dissert/inserir_tese_dissert. Acesso em: 4 maio 2020.

ROCHA, C. H. B. **Geoprocessamento**: tecnologia transdisciplinar. 3 ed. Juiz de Fora: Ed. Do Autor, 2007.

SANTOS, R. F. dos *et al* (org.). **Vulnerabilidade Ambiental**: desastres naturais ou fenômenos induzidos?. 2. ed. Brasília: Ministério do Meio Ambiente, 2007. 192 p. Disponível em: <https://www.terrabrasil.org.br/ecotecadigital/pdf/vulnerabilidade-ambiental-desastres-naturais-ou-fenomenos-induzidos.pdf>. Acesso em: 22 abr. 2020.

SEEG. **Projeto de Mapeamento Anual da Cobertura e Uso do Solo no Brasil**. Brasil, 2019. Disponível em: <https://mapbiomas.org>. Acesso em: 18 set. 2019.

SILVA, B. B. da *et al*. Balanço de radiação no perímetro irrigado São Gonçalo - PB mediante imagens orbitais. **Caatinga**, Mossoró, v. 24, n. 3, p. 145-152, jul./set. 2011. Disponível em: <https://periodicos.ufersa.edu.br/index.php/caatinga/article/view/2282>. Acesso em: 6 maio 2020.

SILVA, L. C. *et al*. Estimativa do balanço de radiação por sensoriamento remoto de diferentes usos de solo no sudoeste da Amazônia brasileira. **Sociedade & Natureza**, Uberlândia, v. 27, n. 2, p. 341-356, maio/ago. 2015. Disponível em: <https://www.scielo.br/j/sn/a/Dc5zbPTXsFHjRVfFxR5TxGQ/?lang=pt>. Acesso em: 6 maio 2020.

SOUZA, C. M. *et al*. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, [S.l.], v. 12, n. 17, p. 1-27, 25 ago. 2020. Disponível em: <https://www.mdpi.com/2072-4292/12/17/2735>. Acesso em: 10 nov. 2020.

TABERNER, M. C. *et al*. Global estimation of biophysical variables from Google Earth Engine platform. **Remote Sens.**, [S.l.], v. 10, n. 8, p. 1-17, jul. 2018. DOI 10.3390/rs10081167. Disponível em: <https://www.mdpi.com/2072-4292/10/8/1167>. Acesso em: 15 fev. 2019.

TRIGUEIRO, A. *et al* (org.). **Meio ambiente no século 21**: 21 especialistas falam da questão ambiental nas suas áreas de conhecimento. Rio de Janeiro: Sextante, 2003. 367 p.

TUCCI, C. E. M.; MENDES, C. A. **Avaliação ambiental integrada de bacia hidrográfica**. 2. ed. Brasília: Ministério do Meio Ambiente, 2006. 302 p. Disponível em: <http://projects.mcrit.com/ceara/attachments/article/189/Avali%C3%A7%C3%A3o%20ambiental%20de%20bacias%20hidrogr%C3%A1ficas.pdf>. Acesso em: 22 abr. 2020.

WAN, Z. **MODIS Land-Surface Temperature**: Algorithm Theoretical Basis Document (v. 3.3). 1999. Disponível em: https://modis.gsfc.nasa.gov/data/atbd/atbd_mod11.pdf. Acesso em: 15 dez. 2020.

WAN, Z. **MODIS Land Surface Temperature Products**: User's Guide (collection 6). 2013. Disponível em:

https://lpdaac.usgs.gov/documents/118/MOD11_User_Guide_V6.pdf. Acesso em: 15 dez. 2020.

Apêndice A – Script de uso e cobertura do solo

```

1 //Importação de dados do MapBiomas e da área em análise
2 var mapbiomas =
  ee.Image("projects/mapbiomas-workspace/public/collection5/mapbiomas_collection50_integ
    ration_v1"),
3   AREA =
  ee.FeatureCollection("users/nayarawm/UnidadeHidrografica_AltoParnaiba_749"),
4   uc = ee.FeatureCollection("users/nayarawm/UCs_recortado");
5
6 //Preparar os dados do MapBiomas
7 //Cortar e filtrar para as imagens de UCS em 2001 e 2019
8 var ucs2001 = mapbiomas.select('classification_2001').clip(AREA);
9 var ucs2019 = mapbiomas.select('classification_2019').clip(AREA);
10
11 //Reclassificar as imagens de 2001 e 2019, generalizando em apenas 4 classes
12 var ucs2001_remap = ucs2001.remap(
13   [3,4,12,15,24,25,33,39,41] ,
14   [1,1,1,3,6,6,10,3,3]
15 );
16 var ucs2019_remap = ucs2019.remap(
17   [3,4,12,15,24,25,33,39,41] ,
18   [1,1,1,3,6,6,10,3,3]
19 );
20
21 //Configuração da paleta de cores para cada classe de UCS
22 var palette = [
23   '#bbfcac', // Formação natural (1)
24   '#ffd966', // Agropecuária (3)
25   '#ea9999', // Área não vegetada (6)
26   '#0000ff', // Corpo d'água (10)
27 ];
28
29 //Adicionar as imagens reclassificadas para visualizar e centralizar na área desejada
30 Map.addLayer(ucs2001_remap, {'min': 1, 'max': 10, 'palette': palette},
  'ucs2001 generalizado');
31 Map.addLayer(ucs2019_remap, {'min': 1, 'max': 10, 'palette': palette},
  'ucs2019 generalizado');
32 Map.centerObject(AREA, 8.8);
33
34 //Calcular área ocupada por cada classe
35 var ucs2001_pixelarea_m2 = ee.Image.pixelArea().addBands(ucs2001_remap);
36 var ucs2001_area_m2 = ucs2001_pixelarea_m2.reduceRegion({
37   reducer: ee.Reducer.sum().group({
38     groupField: 1,
39     groupName: 'ucs_class_value',
40   }),
41   geometry: AREA,
42   scale: 30,
43   bestEffort: true,
44 });
45 var ucs2019_pixelarea_m2 = ee.Image.pixelArea().addBands(ucs2019_remap);
46 var ucs2019_area_m2 = ucs2019_pixelarea_m2.reduceRegion({
47   reducer: ee.Reducer.sum().group({
48     groupField: 1,
49     groupName: 'ucs_class_value',
50   }),
51   geometry: AREA,
52   scale: 30,
53   bestEffort: true,
54 });
55
56 //Imprimir o cálculo de área das classes
57 print('ucs2001 area m2', ucs2001_area_m2,
58 'ucs2019_area_m2', ucs2019_area_m2);
59
60 //Gerar imagem de transição
61 var transicao = ucs2019_remap.subtract(ucs2001_remap);
62
63 //Adicionar imagem de transição para visualizar
64 Map.addLayer(transicao,
65   {min: -9, max: 9, palette: ['gray']},
66   'transicao');
67
68 //Calcular área ocupada por cada classe de transição

```

```

69 var transicao_pixelarea_m2 = ee.Image.pixelArea().addBands(transicao);
70 var transicao_area_m2 = transicao_pixelarea_m2.reduceRegion({
71   reducer: ee.Reducer.sum().group({
72     groupField: 1,
73     groupName: 'ucs_class_value',
74   }),
75   geometry: AREA,
76   scale: 30,
77   bestEffort: true,
78 });
79
80 //Imprimir o cálculo de área das classes de transição
81 print('transicao_area_m2', transicao_area_m2);
82
83 //Reclassificar as imagens de transição, generalizando em apenas 6 classes
84 var transicao_remap = transicao.remap(
85   [-9,-7,-5,-4,-3,-2,0,2,3,4,5,7,9] ,
86   [4,3,4,6,3,4,0,2,6,5,1,5,5]
87 );
88
89 //Configuração da paleta de cores para cada classe de transição
90 var palette_transicao = [
91   'red', // Supressão de vegetação natural (1)
92   'orange', // Expansão agropecuária sobre área natural (2)
93   'yellow', // Expansão agropecuária sobre outras áreas (3)
94   'green', // Reflorestamento (4)
95   'blue', // Aparecimento de corpo d'água (5)
96   "#ff21f8", // Outras áreas não vegetadas (6) = de corpo d'água para área não
97   vegetada; de agropecuária para área não vegetada
98 ];
99
100 //Adicionar imagem de transição reclassificada para visualizar, mascarando os
101 //valores iguais a 0 (onde não houve alteração de UCS)
102 Map.addLayer(transicao_remap.selfMask(), {min: 1, max: 6, 'palette':
103   palette_transicao}, 'transicao_remap');
104
105 //Adicionar camada de UC
106 var ucVis = uc.style({
107   color: 'black',
108   width: 1,
109   fillColor: '00000000',
110   lineType: 'solid'
111 });
112 Map.addLayer(ucVis, null, 'UC');
113
114 //Calcular área ocupada por cada classe da imagem de transição reclassificada
115 var transicao_remap_pixelarea_m2 = ee.Image.pixelArea().addBands(transicao_remap);
116 var transicao_remap_area_m2 = transicao_remap_pixelarea_m2.reduceRegion({
117   reducer: ee.Reducer.sum().group({
118     groupField: 1,
119     groupName: 'ucs_class_value',
120   }),
121   geometry: AREA,
122   scale: 30,
123   bestEffort: true,
124 });
125
126 //Imprimir o cálculo de área das classes da imagem de transição reclassificada
127 print('transicao_remap_area_m2', transicao_remap_area_m2);

```

Apêndice B – Script de NDVI

```

1 //Importação de dados do MODIS, da área em análise, das Unidades de Conservação e de
  parâmetros de visualização para o NDVI
2 var MODIS = ee.ImageCollection("MODIS/006/MOD13Q1"),
3   imageVisParam =
4     {"opacity":1,"bands":["NDVI"],"min":0,"max":1,"palette":["ffffff","ce7e45","df923d",
5     "f1b555","fcd163","99b718","74a901","66a000","529400","3e8601","207401","056201",
6     "004c00","023b01","012e01","011d01","011301"]},
7   area =
8     ee.FeatureCollection("users/nayarawm/UnidadeHidrografica_AltoParnaiba_749"),
9     uc = ee.FeatureCollection("users/nayarawm/UCs_recortado");
10
11 //Configuração do recorte para a área
12 var clip = function(img){
13   return img.clip(area);};
14
15 //Filtrar pixels de acordo com a banda QA
16 var getQABits = function(image, start, end, newName) {
17   //Cálculo dos bits a serem extraídos.
18   var pattern = 0;
19   for (var i = start; i <= end; i++) {
20     pattern += Math.pow(2, i);
21   }
22   //Retorno de uma imagem de banda única dos bits de QA extraídos
23   return image.select([0], [newName])
24     .bitwiseAnd(pattern)
25     .rightShift(start);
26 };
27
28 //Mascarar a qualidade do IV de acordo com a banda QA (bits 0-1)
29 var mask1 = function(image) {
30   //Selecionar a banda QA
31   var QA = image.select('DetailedQA');
32   //Obter o bit de indicador de qualidade para o IV
33   var VI_quality = getQABits(QA, 0, 1, 'MODLAND QA');
34   //Retorno de uma imagem mascarada.
35   return image.updateMask(VI_quality.eq(0));
36 };
37
38 //Preparar os dados do sensor MODIS
39 //Mascarar, cortar, selecionar a banda de NDVI, multiplicar pelo fator de escala e
  adicionar propriedades
40 var modis = MODIS.map(mask1).map(clip);
41 var ndvi = modis.select('NDVI');
42 var ndvi = modis.map(function(img){return
  img.select('NDVI').multiply(0.0001).copyProperties(img,['system:time_start','system:ti
  me_end']);});
43
44 //Definir os períodos desejados (T1 e T2)
45 var ano2001 = ee.DateRange('2001-01-01', '2002-01-01'),
46   ano2019 = ee.DateRange('2019-01-01', '2020-01-01');
47
48 //Filtrar os valores de NDVI para cada período e calcular a média por pixel
49 var ndvi2001 = ndvi.filterDate(ano2001).mean(),
50   ndvi2019 = ndvi.filterDate(ano2019).mean();
51
52 //Imprimir a quantidade de imagens utilizadas em cada período
53 print('size2001', ndvi.filterDate(ano2001).size(), 'size2019',
  ndvi.filterDate(ano2019).size());
54
55 //Adicionar as camadas para visualizar e centralizar na área desejada
56 Map.addLayer(ndvi2001, imageVisParam, 'NDVI_2001_mean');
57 Map.addLayer(ndvi2019, imageVisParam, 'NDVI_2019_mean');
58 Map.centerObject(area, 8.8);
59
60 //Configurar redutores para as estatísticas
61 var reducers_sum_mean = ee.Reducer.sum().combine({
62   reducer2: ee.Reducer.mean(),
63   sharedInputs: true
64 });
65 var reducers_stdDev_variance = ee.Reducer.stdDev().combine({
66   reducer2: ee.Reducer.variance(),
67   sharedInputs: true
68 });

```

```

65 var reducers_max_min = ee.Reducer.max().combine({
66   reducer2: ee.Reducer.min(),
67   sharedInputs: true
68 });
69
70 //Gerar estatísticas para 2001 e 2019
71 var stats2001_sum_mean = ndvi2001.reduceRegion({
72   reducer: reducers_sum_mean,
73   geometry: area,
74   scale: 250,
75   maxPixels: 1e9,
76 });
77 var stats2001_max_min = ndvi2001.reduceRegion({
78   reducer: reducers_max_min,
79   geometry: area,
80   scale: 250,
81   maxPixels: 1e9,
82 });
83 var stats2001_median = ndvi2001.reduceRegion({
84   reducer: ee.Reducer.median(),
85   geometry: area,
86   scale: 250,
87   maxPixels: 1e9
88 });
89 var stats2001_stdDev_variance = ndvi2001.reduceRegion({
90   reducer: reducers_stdDev_variance,
91   geometry: area,
92   scale: 250,
93   maxPixels: 1e9,
94 });
95
96 var stats2019_sum_mean = ndvi2019.reduceRegion({
97   reducer: reducers_sum_mean,
98   geometry: area,
99   scale: 250,
100  maxPixels: 1e9,
101 });
102 var stats2019_max_min = ndvi2019.reduceRegion({
103   reducer: reducers_max_min,
104   geometry: area,
105   scale: 250,
106   maxPixels: 1e9,
107 });
108 var stats2019_median = ndvi2019.reduceRegion({
109   reducer: ee.Reducer.median(),
110   geometry: area,
111   scale: 250,
112   maxPixels: 1e9
113 });
114 var stats2019_stdDev_variance = ndvi2019.reduceRegion({
115   reducer: reducers_stdDev_variance,
116   geometry: area,
117   scale: 250,
118   maxPixels: 1e9,
119 });
120
121 //Imprimir estatísticas
122 print('stats2001', stats2001_sum_mean, stats2001_stdDev_variance, stats2001_max_min,
stats2001_median,
123   'stats2019', stats2019_sum_mean, stats2019_stdDev_variance, stats2019_max_min,
stats2019_median);
124
125 //Reclassificar as imagens de 2001 e 2019
126 var ndvi2001_mean_remap = ee.Image(0)
127   .where(ndvi2001.gte(0.0).and(ndvi2001.lt(0.1)), 0.0)
128   .where(ndvi2001.gte(0.1).and(ndvi2001.lt(0.2)), 0.1)
129   .where(ndvi2001.gte(0.2).and(ndvi2001.lt(0.3)), 0.2)
130   .where(ndvi2001.gte(0.3).and(ndvi2001.lt(0.4)), 0.3)
131   .where(ndvi2001.gte(0.4).and(ndvi2001.lt(0.5)), 0.4)
132   .where(ndvi2001.gte(0.5).and(ndvi2001.lt(0.6)), 0.5)
133   .where(ndvi2001.gte(0.6).and(ndvi2001.lt(0.7)), 0.6)
134   .where(ndvi2001.gte(0.7).and(ndvi2001.lt(0.8)), 0.7)
135   .where(ndvi2001.gte(0.8).and(ndvi2001.lt(0.9)), 0.8)

```

```

136         .where(ndvi2001.gte(0.9), 0.9);
137
138     var ndvi2019_mean_remap = ee.Image(0)
139     .where(ndvi2019.gte(0.0).and(ndvi2019.lt(0.1)), 0.0)
140     .where(ndvi2019.gte(0.1).and(ndvi2019.lt(0.2)), 0.1)
141     .where(ndvi2019.gte(0.2).and(ndvi2019.lt(0.3)), 0.2)
142     .where(ndvi2019.gte(0.3).and(ndvi2019.lt(0.4)), 0.3)
143     .where(ndvi2019.gte(0.4).and(ndvi2019.lt(0.5)), 0.4)
144     .where(ndvi2019.gte(0.5).and(ndvi2019.lt(0.6)), 0.5)
145     .where(ndvi2019.gte(0.6).and(ndvi2019.lt(0.7)), 0.6)
146     .where(ndvi2019.gte(0.7).and(ndvi2019.lt(0.8)), 0.7)
147     .where(ndvi2019.gte(0.8).and(ndvi2019.lt(0.9)), 0.8)
148     .where(ndvi2019.gte(0.9), 0.9);
149
150     //Adicionar as camadas para visualizar
151     Map.addLayer(ndvi2001_mean_remap.clip(area),
152     {"opacity":1,"min":0,"max":1,
153     "palette": ["#ce420d",
154     "c26d30","ed9439","f3c620","9eba06","588b00","207401","004c00","023b01","011d01"]},
155     'NDVI_2001_mean_remap');
156     Map.addLayer(ndvi2019_mean_remap.clip(area),
157     {"opacity":1,"min":0,"max":1,
158     "palette": ["#ce420d",
159     "c26d30","ed9439","f3c620","9eba06","588b00","207401","004c00","023b01","011d01"]},
160     'NDVI_2019_mean_remap');
161
162     //Adicionar camada de UC
163     var ucVis = uc.style({
164     color: 'black',
165     width: 1,
166     fillColor: '00000000',
167     lineType: 'solid'
168     });
169     Map.addLayer(ucVis, null, 'UC');
170
171     //Calcular área ocupada por cada classe
172     var ndvi2001_mean_remap_pixelarea_m2 =
173     ee.Image.pixelArea().addBands(ndvi2001_mean_remap);
174     var ndvi2001_mean_remap_area_m2 = ndvi2001_mean_remap_pixelarea_m2.reduceRegion({
175     reducer: ee.Reducer.sum().group({
176     groupField: 1,
177     groupName: 'ndvi_class_value',
178     }),
179     geometry: area,
180     scale: 250,
181     bestEffort: true,
182     });
183     var ndvi2019_mean_remap_pixelarea_m2 =
184     ee.Image.pixelArea().addBands(ndvi2019_mean_remap);
185     var ndvi2019_mean_remap_area_m2 = ndvi2019_mean_remap_pixelarea_m2.reduceRegion({
186     reducer: ee.Reducer.sum().group({
187     groupField: 1,
188     groupName: 'ndvi_class_value',
189     }),
190     geometry: area,
191     scale: 250,
192     bestEffort: true,
193     });
194
195     //Imprimir o cálculo de área das classes
196     print('ndvi2001_mean_remap_area_m2', ndvi2001_mean_remap_area_m2,
197     'ndvi2019_mean_remap_area_m2', ndvi2019_mean_remap_area_m2);

```

Apêndice C – Script do gráfico de NDVI

```

1 //Importação de dados do MODIS e da área em análise
2 var MODIS = ee.ImageCollection("MODIS/006/MOD13Q1"),
3     area =
4     ee.FeatureCollection("users/nayarawm/UnidadeHidrografica_AltoParnaiba_749");
5
6 //Configuração do recorte para a área
7 var clip = function(img){
8     return img.clip(area)};
9
10 //Filtrar pixels de acordo com a banda QA
11 var getQABits = function(image, start, end, newName) {
12     //Cálculo dos bits a serem extraídos.
13     var pattern = 0;
14     for (var i = start; i <= end; i++) {
15         pattern += Math.pow(2, i);
16     }
17     //Retorno de uma imagem de banda única dos bits de QA extraídos
18     return image.select([0], [newName])
19         .bitwiseAnd(pattern)
20         .rightShift(start);
21 };
22
23 //Mascarar a qualidade do IV de acordo com a banda QA (bits 0-1)
24 var mask1 = function(image) {
25     //Selecionar a banda QA
26     var QA = image.select('DetailedQA');
27     //Obter o bit de indicador de qualidade para o IV
28     var VI_quality = getQABits(QA, 0, 1, 'MODLAND QA');
29     //Retorno de uma imagem mascarada.
30     return image.updateMask(VI_quality.eq(0));
31 };
32
33 //Preparar os dados do sensor MODIS: mascarar e cortar
34 var modis = MODIS.map(mask1).map(clip);
35
36 //Filtrar as imagens MODIS no período desejado (de 2001 a 2019)
37 //Adicionar ano de observação como uma propriedade de imagem
38 var modis = modis.filter(ee.Filter.calendarRange(2001, 2019, 'year'))
39     .map(function(img) {
40         return img.set('year', img.date().get('year'));
41     });
42
43 //Imprimir a quantidade de imagens utilizadas
44 print('size', modis.size());
45
46 //Gerar listas das imagens de cada ano
47 var modisrAnnualJoin = ee.Join.saveAll('same_year').apply({
48     primary: modis.distinct('year'),
49     secondary: modis,
50     condition: ee.Filter.equals({leftField: 'year', rightField: 'year'})
51 });
52
53 //Calcular a média anual de NDVI das imagens de mesmo ano.
54 //É retornada uma imagem com duas bandas, sendo a banda 1 referente ao ano e a banda
55 //2 ao NDVI médio
56 var Stats = ee.ImageCollection(modisrAnnualJoin.map(function(img) {
57     var year = img.get('year');
58     var yearCol = ee.ImageCollection.fromImages(img.get('same_year'));
59     var mean = yearCol.select('NDVI').mean();
60     var yr = ee.Image.constant(ee.Number(year)).toShort();
61     return ee.Image.cat(yr, mean).rename(['year', 'mean']).set('year', year);
62 }));
63
64 //Preparar os dados
65 //Selecionar o campo de NDVI médio, multiplicar pelo fator de escala e adicionar
66 //propriedades
67 var Stats = Stats.map(function(img){return
68     img.select('mean').multiply(0.0001).copyProperties(img,['NDVI','mean','year']);});
69
70 //Gerar gráfico dos dados médios de NDVI por ano e sua linha de tendência
71 print(ui.Chart.image
72     .seriesByRegion({
73         imageCollection: Stats,

```

```
70     regions: area,
71     reducer: ee.Reducer.mean(),
72     band: 'mean',
73     scale: 250,
74     xProperty: 'year',
75     seriesProperty: 'area'
76   })
77   .setChartType('ScatterChart')
78   .setOptions({
79     title: 'Série temporal da média anual de NDVI',
80     curveType: 'function',
81     vAxis: {title: 'NDVI'},
82     hAxis: {title: 'Ano', format: '####'},
83     legend: 'none',
84     colors: ['red'],
85     lineWidth: 1,
86     pointSize: 3,
87     trendlines: {
88       0: {type: 'linear', color: 'black', opacity: 0.7}
89     }
90   });
```

Apêndice D – Script da temperatura da superfície

```

1 //Importação de dados do MODIS, da área em análise e de parâmetros de visualização
  para a TS
2 var MODIS = ee.ImageCollection("MODIS/006/MOD11A2"),
3   area =
  ee.FeatureCollection("users/nayarawm/UnidadeHidrografica_AltoParnaiba_749"),
4   landSurfaceTemperatureVis =
  {"min":25,"max":45,"palette":["040274","040281","0502a3","0502b8","0502ce","0502e6",
  "0602ff","235cb1","307ef3","269db1","30c8e2","32d3ef","3be285","3ff38f","86e26f",
  "3ae237","b5e22e","d6e21f","fff705","ffd611","ffb613","ff8b13","ff6e08","ff500d",
  "ff0000","de0101","c21301","a71001","911003"]},
5   uc = ee.FeatureCollection("users/nayarawm/UCs_recortado");
6
7 //Configuração do recorte para a área
8 var clip = function(img){
9   return img.clip(area);};
10
11 //Filtrar pixels de acordo com a banda QA
12 var getQABits = function(image, start, end, newName) {
13   //Cálculo dos bits a serem extraídos.
14   var pattern = 0;
15   for (var i = start; i <= end; i++) {
16     pattern += Math.pow(2, i);
17   }
18   //Retorno de uma imagem de banda única dos bits de QA extraídos
19   return image.select([0], [newName])
20     .bitwiseAnd(pattern)
21     .rightShift(start);
22 };
23
24 //Mascarar a qualidade da TS de acordo com a banda QA (bits 0-1)
25 var mask1 = function(image) {
26   //Selecionar a banda QA
27   var QA = image.select('QC_Day');
28   //Obter o bit de indicador de qualidade para a TS
29   var LST_quality = getQABits(QA, 0, 1, 'Mandatory QA');
30   //Retorno de uma imagem mascarada.
31   return image.updateMask(LST_quality.eq(0));
32 };
33
34 //Mascarar a qualidade da TS de acordo com a banda QA (bits 2-3)
35 var mask2= function(image) {
36   //Selecionar a banda QA
37   var QA = image.select('QC_Day');
38   //Obter o bit de indicador de qualidade para a TS
39   var data_quality = getQABits(QA, 2, 3, 'Data quality');
40   //Retorno de uma imagem mascarada.
41   return image.updateMask(data_quality.eq(0));
42 };
43
44 //Preparar os dados do sensor MODIS
45 //Mascarar, cortar, selecionar a banda de TS, multiplicar pelo fator de escala e
  adicionar propriedades
46 var modis = MODIS.map(mask1).map(mask2).map(clip);
47 var ts = modis.select('LST_Day_1km');
48 var ts = modis.map(function(img){return
  img.select('LST_Day_1km').multiply(0.02).subtract(273.15).copyProperties(img,['system:
  time_start','system:time_end']);});
49
50 //Definir os períodos desejados (T1 e T2)
51 var ano2001 = ee.DateRange('2001-01-01', '2002-01-01'),
52   ano2019 = ee.DateRange('2019-01-01', '2020-01-01');
53
54 //Filtrar os valores de TS para cada período e calcular a média por pixel
55 var ts2001 = ts.filterDate(ano2001).mean(),
56   ts2019 = ts.filterDate(ano2019).mean();
57
58 //Imprimir a quantidade de imagens utilizadas em cada período
59 print('size2001', ts.filterDate(ano2001).size(), 'size2019',
  ts.filterDate(ano2019).size());
60
61 //Adicionar as camadas para visualizar e centralizar na área desejada
62 Map.addLayer(ts2001, landSurfaceTemperatureVis, 'TS_2001_mean');
63 Map.addLayer(ts2019, landSurfaceTemperatureVis, 'TS_2019_mean');

```

```

64 Map.centerObject(area, 8.8);
65
66 //Configurar redutores para as estatísticas
67 var reducers_sum_mean = ee.Reducer.sum().combine({
68   reducer2: ee.Reducer.mean(),
69   sharedInputs: true
70 });
71 var reducers_stdDev_variance = ee.Reducer.stdDev().combine({
72   reducer2: ee.Reducer.variance(),
73   sharedInputs: true
74 });
75 var reducers_max_min = ee.Reducer.max().combine({
76   reducer2: ee.Reducer.min(),
77   sharedInputs: true
78 });
79
80 //Gerar estatísticas para 2001 e 2019
81 var stats2001_sum_mean = ts2001.reduceRegion({
82   reducer: reducers_sum_mean,
83   geometry: area,
84   scale: 1000,
85   maxPixels: 1e9,
86 });
87 var stats2001_median = ts2001.reduceRegion({
88   reducer: ee.Reducer.median(),
89   geometry: area,
90   scale: 1000,
91   maxPixels: 1e9
92 });
93 var stats2001_stdDev_variance = ts2001.reduceRegion({
94   reducer: reducers_stdDev_variance,
95   geometry: area,
96   scale: 1000,
97   maxPixels: 1e9,
98 });
99 var stats2001_max_min = ts2001.reduceRegion({
100   reducer: reducers_max_min,
101   geometry: area,
102   scale: 1000,
103   maxPixels: 1e9,
104 });
105
106 var stats2019_sum_mean = ts2019.reduceRegion({
107   reducer: reducers_sum_mean,
108   geometry: area,
109   scale: 1000,
110   maxPixels: 1e9,
111 });
112 var stats2019_median = ts2019.reduceRegion({
113   reducer: ee.Reducer.median(),
114   geometry: area,
115   scale: 1000,
116   maxPixels: 1e9
117 });
118 var stats2019_stdDev_variance = ts2019.reduceRegion({
119   reducer: reducers_stdDev_variance,
120   geometry: area,
121   scale: 1000,
122   maxPixels: 1e9,
123 });
124 var stats2019_max_min = ts2019.reduceRegion({
125   reducer: reducers_max_min,
126   geometry: area,
127   scale: 1000,
128   maxPixels: 1e9,
129 });
130
131 //Imprimir estatísticas
132 print('stats2001', stats2001_sum_mean, stats2001_stdDev_variance, stats2001_max_min,
stats2001_median,
133   'stats2019', stats2019_sum_mean, stats2019_stdDev_variance, stats2019_max_min,
stats2019_median);
134

```

```

135 //Reclassificar as imagens de 2001 e 2019
136 var ts2001_mean_remap = ee.Image(0)
137   .where(ts2001.gte(28).and(ts2001.lt(30)), 1)
138   .where(ts2001.gte(30).and(ts2001.lt(32)), 2)
139   .where(ts2001.gte(32).and(ts2001.lt(34)), 3)
140   .where(ts2001.gte(34).and(ts2001.lt(36)), 4)
141   .where(ts2001.gte(36).and(ts2001.lt(38)), 5)
142   .where(ts2001.gte(38).and(ts2001.lt(40)), 6)
143   .where(ts2001.gte(40).and(ts2001.lt(42)), 7)
144   .where(ts2001.gte(42).and(ts2001.lt(44)), 8);
145
146 var ts2019_mean_remap = ee.Image(0)
147   .where(ts2019.gte(28).and(ts2019.lt(30)), 1)
148   .where(ts2019.gte(30).and(ts2019.lt(32)), 2)
149   .where(ts2019.gte(32).and(ts2019.lt(34)), 3)
150   .where(ts2019.gte(34).and(ts2019.lt(36)), 4)
151   .where(ts2019.gte(36).and(ts2019.lt(38)), 5)
152   .where(ts2019.gte(38).and(ts2019.lt(40)), 6)
153   .where(ts2019.gte(40).and(ts2019.lt(42)), 7)
154   .where(ts2019.gte(42).and(ts2019.lt(44)), 8);
155
156 //Adicionar as camadas para visualizar
157 Map.addLayer(ts2001_mean_remap.clip(area),
158 {"opacity":1,"min":1,"max":9,"palette":["235cb1", '307ef3', '3be285', 'b5e22e',
159 'fff705', 'ffb613', 'ff0000', 'a71001']},
160 'TS_2001_mean_remap');
161 Map.addLayer(ts2019_mean_remap.clip(area),
162 {"opacity":1,"min":1,"max":9,"palette":["235cb1", '307ef3', '3be285', 'b5e22e',
163 'fff705', 'ffb613', 'ff0000', 'a71001']},
164 'TS_2019_mean_remap');
165
166 //Adicionar camada de UC
167 var ucVis = uc.style({
168   color: 'black',
169   width: 1,
170   fillColor: '00000000',
171   lineType: 'solid'
172 });
173 Map.addLayer(ucVis, null, 'UC');
174
175 //Calcular área ocupada por cada classe
176 var ts2001_mean_remap_pixelarea_m2 = ee.Image.pixelArea().addBands(ts2001_mean_remap);
177 var ts2001_mean_remap_area_m2 = ts2001_mean_remap_pixelarea_m2.reduceRegion({
178   reducer: ee.Reducer.sum().group({
179     groupField: 1,
180     groupName: 'ts_class_value',
181   }),
182   geometry: area,
183   scale: 1000,
184   bestEffort: true,
185 });
186 var ts2019_mean_remap_pixelarea_m2 = ee.Image.pixelArea().addBands(ts2019_mean_remap);
187 var ts2019_mean_remap_area_m2 = ts2019_mean_remap_pixelarea_m2.reduceRegion({
188   reducer: ee.Reducer.sum().group({
189     groupField: 1,
190     groupName: 'ts_class_value',
191   }),
192   geometry: area,
193   scale: 1000,
194   bestEffort: true,
195 });
196
197 //Imprimir o cálculo de área das classes
198 print('ts2001_mean_remap_area_m2', ts2001_mean_remap_area_m2,
199 'ts2019_mean_remap_area_m2', ts2019_mean_remap_area_m2);

```

Apêndice E – Script do gráfico da temperatura da superfície

```

1 //Importação de dados do MODIS e da área em análise
2 var MODIS = ee.ImageCollection("MODIS/006/MOD11A2"),
3     area =
4     ee.FeatureCollection("users/nayarawm/UnidadeHidrografica_AltoParnaiba_749");
5
6 //Configuração do recorte para a área
7 var clip = function(img){
8     return img.clip(area);};
9
10 //Filtrar pixels de acordo com a banda QA
11 var getQABits = function(image, start, end, newName) {
12     //Cálculo dos bits a serem extraídos.
13     var pattern = 0;
14     for (var i = start; i <= end; i++) {
15         pattern += Math.pow(2, i);
16     }
17     //Retorno de uma imagem de banda única dos bits de QA extraídos
18     return image.select([0], [newName])
19         .bitwiseAnd(pattern)
20         .rightShift(start);
21 };
22
23 //Mascarar a qualidade do IV de acordo com a banda QA (bits 0-1)
24 var mask1 = function(image) {
25     //Selecionar a banda QA
26     var QA = image.select('QC_Day');
27     //Obter o bit de indicador de qualidade para a TS
28     var LST_quality = getQABits(QA, 0, 1, 'Mandatory QA');
29     //Retorno de uma imagem mascarada.
30     return image.updateMask(LST_quality.eq(0));
31 };
32
33 //Mascarar a qualidade da TS de acordo com a banda QA (bits 2-3)
34 var mask2= function(image) {
35     //Selecionar a banda QA
36     var QA = image.select('QC_Day');
37     //Obter o bit de indicador de qualidade para a TS
38     var data_quality = getQABits(QA, 2, 3, 'Data quality');
39     //Retorno de uma imagem mascarada.
40     return image.updateMask(data_quality.eq(0));
41 };
42
43 //Preparar os dados do sensor MODIS: mascarar e cortar
44 var modis = MODIS.map(mask1).map(mask2).map(clip);
45
46 //Filtrar as imagens MODIS no período desejado (de 2001 a 2019)
47 //Adicionar ano de observação como uma propriedade de imagem
48 var modis = modis.filter(ee.Filter.calendarRange(2001, 2019, 'year'))
49     .map(function(img) {
50         return img.set('year', img.date().get('year'));
51     });
52
53 //Imprimir a quantidade de imagens utilizadas
54 print('size', modis.size());
55
56 //Gerar listas das imagens de cada ano
57 var modisrAnnualJoin = ee.Join.saveAll('same_year').apply({
58     primary: modis.distinct('year'),
59     secondary: modis,
60     condition: ee.Filter.equals({leftField: 'year', rightField: 'year'})
61 });
62
63 //Calcular a média anual de TS das imagens de mesmo ano.
64 //É retornada uma imagem com duas bandas, sendo a banda 1 referente ao ano e a banda
65 //2 à TS média
66 var Stats = ee.ImageCollection(modisrAnnualJoin.map(function(img) {
67     var year = img.get('year');
68     var yearCol = ee.ImageCollection.fromImages(img.get('same_year'));
69     var mean = yearCol.select('LST Day 1km').mean();
70     var yr = ee.Image.constant(ee.Number(year)).toShort();
71     return ee.Image.cat(yr, mean).rename(['year', 'mean']).set('year', year);
72 }));

```

```
72 //Preparar os dados
73 //Selecionar o campo de TS média, multiplicar pelo fator de escala e adicionar
    propriedades
74 var Stats = Stats.map(function(img) {return
    img.select('mean').multiply(0.02).subtract(273.15).copyProperties(img,['LST_Day_1km',
    'mean', 'year']);});
75
76 //Gerar gráfico dos dados médios de TS por ano e sua linha de tendência
77 print(ui.Chart.image
78     .seriesByRegion({
79         imageCollection: Stats,
80         regions: area,
81         reducer: ee.Reducer.mean(),
82         band: 'mean',
83         scale: 250,
84         xProperty: 'year',
85         seriesProperty: 'area'
86     })
87     .setChartType('ScatterChart')
88     .setOptions({
89         title: 'Série temporal da média anual de TS',
90         curveType: 'function',
91         vAxis: {title: 'TS (°C)'},
92         hAxis: {title: 'Ano', format: '####'},
93         legend: 'none',
94         colors: ['red'],
95         lineWidth: 1,
96         pointSize: 3,
97         trendlines: {
98             0: {type: 'linear', color: 'black', opacity: 0.7}}
99     })
100     ));
```

Apêndice F – Script da precipitação

```

1 //Importação de dados de de precipitação, da área em análise e de parâmetros de
  visualização para a TS
2 var terra_climate = ee.ImageCollection("IDAHO EPSCOR/TERRACLIMATE"),
3   area =
4     ee.FeatureCollection("users/nayarawm/UnidadeHidrografica_AltoParnaiba_749"),
5     prVis =
6       {"min":20,"max":120,"palette":["#ff0000","#ff5c00","#ffaf00","#fee100","#c6e300",
7         "#399c01","#005655","#000ee3","#3900c7","#81007e"]},
8     uc = ee.FeatureCollection("users/nayarawm/UCs_recortado");
9
10 //Configuração do recorte para a área
11 var clip = function(img){
12   return img.clip(area);};
13
14 //Preparar os dados: selecionar a banda de Pr e cortar
15 var pr = terra_climate.select('pr').map(clip);
16
17 //Definir os períodos desejados (T1 e T2)
18 var ano2001 = ee.DateRange('2001-01-01', '2002-01-01'),
19     ano2019 = ee.DateRange('2019-01-01', '2020-01-01');
20
21 //Filtrar os valores de TS para cada período e calcular a média por pixel
22 var pr2001 = pr.filterDate(ano2001).mean(),
23     pr2019 = pr.filterDate(ano2019).mean();
24
25 //Imprimir a quantidade de imagens utilizadas em cada período
26 print('size2001', pr.filterDate(ano2001).size(), 'size2019',
27     pr.filterDate(ano2019).size());
28
29 //Adicionar as camadas para visualizar e centralizar na área desejada
30 Map.addLayer(pr2001, prVis, 'pr_2001_mean');
31 Map.addLayer(pr2019, prVis, 'pr_2019_mean');
32 Map.centerObject(area, 8.8);
33
34 //Configurar redutores para as estatísticas
35 var reducers_sum_mean = ee.Reducer.sum().combine({
36   reducer2: ee.Reducer.mean(),
37   sharedInputs: true
38 });
39 var reducers_stdDev_variance = ee.Reducer.stdDev().combine({
40   reducer2: ee.Reducer.variance(),
41   sharedInputs: true
42 });
43 var reducers_max_min = ee.Reducer.max().combine({
44   reducer2: ee.Reducer.min(),
45   sharedInputs: true
46 });
47
48 //Gerar estatísticas para 2001 e 2019
49 var stats2001_sum_mean = pr2001.reduceRegion({
50   reducer: reducers_sum_mean,
51   geometry: area,
52   scale: 1000,
53   maxPixels: 1e9,
54 });
55 var stats2001_median = pr2001.reduceRegion({
56   reducer: ee.Reducer.median(),
57   geometry: area,
58   scale: 1000,
59   maxPixels: 1e9
60 });
61 var stats2001_stdDev_variance = pr2001.reduceRegion({
62   reducer: reducers_stdDev_variance,
63   geometry: area,
64   scale: 1000,
65   maxPixels: 1e9,
66 });
67 var stats2001_max_min = pr2001.reduceRegion({
68   reducer: reducers_max_min,
69   geometry: area,
70   scale: 1000,
71   maxPixels: 1e9,
72 });

```

```

69
70 var stats2019_sum_mean = pr2019.reduceRegion({
71   reducer: reducers_sum_mean,
72   geometry: area,
73   scale: 1000,
74   maxPixels: 1e9,
75 });
76 var stats2019_median = pr2019.reduceRegion({
77   reducer: ee.Reducer.median(),
78   geometry: area,
79   scale: 1000,
80   maxPixels: 1e9
81 });
82 var stats2019_stdDev_variance = pr2019.reduceRegion({
83   reducer: reducers_stdDev_variance,
84   geometry: area,
85   scale: 1000,
86   maxPixels: 1e9,
87 });
88 var stats2019_max_min = pr2019.reduceRegion({
89   reducer: reducers_max_min,
90   geometry: area,
91   scale: 1000,
92   maxPixels: 1e9,
93 });
94
95 //Imprimir estatísticas
96 print('stats2001', stats2001_sum_mean, stats2001_stdDev_variance, stats2001_max_min,
97       stats2001_median,
98       'stats2019', stats2019_sum_mean, stats2019_stdDev_variance, stats2019_max_min,
99       stats2019_median);
100
101 //Reclassificar as imagens de 2001 e 2019
102 var pr2001_mean_remap = ee.Image(0)
103   .where(pr2001.gte(40).and(pr2001.lt(50)), 1)
104   .where(pr2001.gte(50).and(pr2001.lt(60)), 2)
105   .where(pr2001.gte(60).and(pr2001.lt(70)), 3)
106   .where(pr2001.gte(70).and(pr2001.lt(80)), 4)
107   .where(pr2001.gte(80).and(pr2001.lt(90)), 5)
108   .where(pr2001.gte(90).and(pr2001.lt(100)), 6)
109   .where(pr2001.gte(100).and(pr2001.lt(110)), 7)
110   .where(pr2001.gte(110).and(pr2001.lt(120)), 8)
111   .where(pr2001.gte(120).and(pr2001.lt(130)), 9)
112   .where(pr2001.gte(130).and(pr2001.lt(140)), 10);
113
114 var pr2019_mean_remap = ee.Image(0)
115   .where(pr2019.gte(40).and(pr2019.lt(50)), 1)
116   .where(pr2019.gte(50).and(pr2019.lt(60)), 2)
117   .where(pr2019.gte(60).and(pr2019.lt(70)), 3)
118   .where(pr2019.gte(70).and(pr2019.lt(80)), 4)
119   .where(pr2019.gte(80).and(pr2019.lt(90)), 5)
120   .where(pr2019.gte(90).and(pr2019.lt(100)), 6)
121   .where(pr2019.gte(100).and(pr2019.lt(110)), 7)
122   .where(pr2019.gte(110).and(pr2019.lt(120)), 8)
123   .where(pr2019.gte(120).and(pr2019.lt(130)), 9)
124   .where(pr2019.gte(130).and(pr2019.lt(140)), 10);
125
126 //Adicionar as camadas para visualizar
127 Map.addLayer(pr2001_mean_remap.clip(area),
128   {"opacity":1,"min":1,"max":10,"palette":["#ff0000", "#ff5c00", "#ffaf00", "#fee100",
129     "#c6e300", "#399c01", "#005655", "#000ee3", "#3900c7", "#81007e"]},
130   'pr_2001_mean_remap');
131 Map.addLayer(pr2019_mean_remap.clip(area),
132   {"opacity":1,"min":1,"max":10,"palette":["#ff0000", "#ff5c00", "#ffaf00", "#fee100",
133     "#c6e300", "#399c01", "#005655", "#000ee3", "#3900c7", "#81007e"]},
134   'pr_2019_mean_remap');
135
136 //Adicionar camada de UC
137 var ucVis = uc.style({
138   color: 'black',
139   width: 1,
140   fillColor: '00000000',
141   lineType: 'solid'

```

```
138 });
139 Map.addLayer(ucVis, null, 'UC');
140
141 //Calcular área ocupada por cada classe
142 var pr2001_mean_remap_pixelarea_m2 = ee.Image.pixelArea().addBands(pr2001_mean_remap);
143 var pr2001_mean_remap_area_m2 = pr2001_mean_remap_pixelarea_m2.reduceRegion({
144   reducer: ee.Reducer.sum().group({
145     groupField: 1,
146     groupName: 'pr_class_value',
147   }),
148   geometry: area,
149   scale: 1000,
150   bestEffort: true,
151 });
152 var pr2019_mean_remap_pixelarea_m2 = ee.Image.pixelArea().addBands(pr2019_mean_remap);
153 var pr2019_mean_remap_area_m2 = pr2019_mean_remap_pixelarea_m2.reduceRegion({
154   reducer: ee.Reducer.sum().group({
155     groupField: 1,
156     groupName: 'ts_class_value',
157   }),
158   geometry: area,
159   scale: 1000,
160   bestEffort: true,
161 });
162
163 //Imprimir o cálculo de área das classes
164 print('pr2001 mean remap area m2', pr2001_mean_remap_area_m2,
165 'pr2019_mean_remap_area_m2', pr2019_mean_remap_area_m2);
```

Apêndice G – Script do gráfico de precipitação

```

1 //Importação de dados do MODIS e da área em análise
2 var terra_climate = ee.ImageCollection("IDAHO_EPSCOR/TERRACLIMATE"),
3   area =
4   ee.FeatureCollection("users/nayarawm/UnidadeHidrografica_AltoParnaiba_749");
5
6 //Recorte para a área
7 var clip = function(img){
8   return img.clip(area);};
9 var terra_climate = terra_climate.map(clip);
10
11 //Filtrar as imagens de Pr no período desejado (de 2001 a 2019)
12 //Adicionar ano de observação como uma propriedade de imagem
13 var terra_climate = terra_climate.filter(ee.Filter.calendarRange(2001, 2019, 'year'))
14   .map(function(img) {
15     return img.set('year', img.date().get('year'));
16   });
17
18 //Imprimir a quantidade de imagens utilizadas
19 print('size', terra_climate.size());
20
21 //Gerar listas das imagens de cada ano
22 var terra_climateAnnualJoin = ee.Join.saveAll('same_year').apply({
23   primary: terra_climate.distinct('year'),
24   secondary: terra_climate,
25   condition: ee.Filter.equals({leftField: 'year', rightField: 'year'})
26 });
27
28 //Calcular a média anual de Pr mensal das imagens de mesmo ano.
29 //É retornada uma imagem com duas bandas, sendo a banda 1 referente ao ano e a banda
30 //2 à Pr média
31 var Stats = ee.ImageCollection(terra_climateAnnualJoin.map(function(img) {
32   var year = img.get('year');
33   var yearCol = ee.ImageCollection.fromImages(img.get('same_year'));
34   var mean = yearCol.select('pr').mean();
35   var yr = ee.Number(year).toShort();
36   return ee.Image.cat(yr, mean).rename(['year', 'mean']).set('year', year);
37 }););
38
39 //Gerar gráfico dos dados anuais de Pr média mensal e sua linha de tendência
40 print(ui.Chart.image
41   .seriesByRegion({
42     imageCollection: Stats,
43     regions: area,
44     reducer: ee.Reducer.mean(),
45     band: 'mean',
46     scale: 250,
47     xProperty: 'year',
48     seriesProperty: 'area'
49   })
50   .setChartType('ScatterChart')
51   .setOptions({
52     title: 'Série temporal da média anual de PR',
53     curveType: 'function',
54     vAxis: {title: 'PR (mm)'},
55     hAxis: {title: 'Ano', format: '####'},
56     legend: 'none',
57     colors: ['red'],
58     lineWidth: 1,
59     pointSize: 3,
60     trendlines: {
61       0: {type: 'exponential', color: 'black', opacity: 0.7}
62     }
63   }));

```

Anexo A – Legenda da Coleção 5 do MapBiomas (2020)

ID	COLLECTION 5 CLASSES	NATURAL/ ANTHROPIC	LAND COVER/ LAND USER	BIOMES/ THEMES
1	1. Forest	NATURAL/ ANTHROPIC	COVER/USE	-
2	1.1. Natural Forest	NATURAL	COVER	-
3	1.1.1. Forest Formation	NATURAL	COVER	BIOMES
4	1.1.2. Savanna Formation	NATURAL	COVER	BIOMES
5	1.1.3. Mangrove	NATURAL	COVER	THEMES
9	1.2. Forest Plantation	ANTHROPIC	USE	THEMES
10	2. Non Forest Natural Formation	NATURAL	COVER	-
11	2.1. Wetland	NATURAL	COVER	BIOMES
12	2.2. Grassland Formation	NATURAL	COVER	BIOMES
32	2.3. Salt Flat	NATURAL	COVER	THEMES
29	2.4. Rocky Outcrop	NATURAL	COVER	BIOMES
13	2.5. Other non Forest Formations	NATURAL	COVER	BIOMES
14	3. Farming	ANTHROPIC	USE	-
15	3.1. Pasture	ANTHROPIC	USE	THEMES
18	3.2. Agriculture	ANTHROPIC	USE	THEMES
19	3.2.1. Temporary Crop	ANTHROPIC	USE	THEMES
39	3.2.1.1. Soybean	ANTHROPIC	USE	THEMES
20	3.2.1.2. Sugar cane	ANTHROPIC	USE	THEMES
41	3.2.1.3. Other Temporary Crops	ANTHROPIC	USE	THEMES
36	3.2.2. Perennial Crop	ANTHROPIC	USE	THEMES
21	3.3. Mosaic of Agriculture and Pasture	ANTHROPIC	USE	BIOMES
22	4. Non Vegetated Area	NATURAL/ ANTHROPIC	COVER/USE	-
23	4.1. Beach and Dune	NATURAL	COVER	THEMES
24	4.2. Urban Infrastructure	ANTHROPIC	USE	THEMES
30	4.3. Mining	ANTHROPIC	USE	THEMES
25	4.4. Other Non Vegetated Areas	NATURAL/ ANTHROPIC	COVER/USE	BIOMES
26	5. Water	NATURAL/ ANTHROPIC	COVER/USE	-
33	5.1. River, Lake and Ocean	NATURAL	COVER	BIOMES
31	5.2. Aquaculture	ANTHROPIC	USE	THEMES
27	6. Non Observed	NONE	NONE	NONE