



**Universidade do Estado do Rio de Janeiro**

**Universidade de Montpellier AgroParisTech**

Patrick Calvano Kuchler

**Utilização do sensoriamento remoto para o mapeamento dos sistemas integrados de produção agrícola: contribuição ao monitoramento da agricultura de baixa emissão de carbono no estado do Mato Grosso, Brasil**

Montpellier (França)

2021

Patrick Calvano Kuchler

**Utilização do sensoriamento remoto para o mapeamento dos sistemas integrados de produção agrícola: contribuição ao monitoramento da agricultura de baixa emissão de carbono no estado do Mato Grosso, Brasil**

Tese apresentada, como requisito parcial para obtenção do título de Doutor, ao Programa de Pós-Graduação em Meio Ambiente, da Universidade do Estado do Rio de Janeiro, em regime de cotutela internacional com a Escola Doutoral GAIA, da Universidade de Montpellier AgroParisTech. Área de concentração: Conservação do Meio Ambiente.

Orientadoras: Prof.<sup>a</sup> Dra. Margareth Simões

Dra. Agnès Bégué

Montpellier (França)

2021

**CATALOGAÇÃO NA FONTE**  
**UERJ / REDE SIRIUS / BIBLIOTECA CTC-A**

K95

Kuchler, Patrick Calvano

Utilização do sensoriamento remoto para o mapeamento dos sistemas integrados de produção agrícola: contribuição ao monitoramento da agricultura de baixa emissão de carbono no estado do Mato Grosso, Brasil/ Patrick Calvano Kuchler. – 2021.

204 f. : il.

Orientadoras: Margareth Simões, Agnès Bégué.

Tese (Doutorado em Meio Ambiente) - Universidade do Estado do Rio de Janeiro.

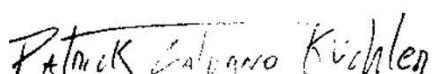
Convênio realizado em cotutela entre a Universidade do Estado do Rio de Janeiro e a Universidade de Montpellier AgroParisTech.

1. Sensoriamento remoto - Mato Grosso - Teses. 2. Agricultura - Mato Grosso - Teses. 3. Carbono – Teses. 4. Desenvolvimento sustentável – Teses. I. Simões, Margareth. II. Bégué, Agnès. III. Universidade do Estado do Rio de Janeiro. IV. Universidade de Montpellier AgroParisTech. V. Título.

CDU 504

Patricia Bello Meijinhos CRB-7/ 5217- Bibliotecária responsável pela elaboração da ficha catalográfica

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta tese, desde que citada a fonte.



Assinatura

29/09/2021

Data

Patrick Calvano Kuchler

**Utilização do sensoriamento remoto para o mapeamento dos sistemas integrados de produção agrícola: contribuição ao monitoramento da agricultura de baixa emissão de carbono no estado do Mato Grosso, Brasil**

Tese apresentada, como requisito parcial para obtenção do título de Doutor, ao Programa de Pós-Graduação em Meio Ambiente, da Universidade do Estado do Rio de Janeiro, em regime de cotutela internacional com a Escola Doutoral GAIA, da Universidade de Montpellier AgroParisTech. Área de concentração: Conservação do Meio Ambiente.

Aprovada em 30 de março de 2021.

Banca Examinadora:

---

Prof.<sup>a</sup> Dra. Margareth Simões (Orientadora)  
Departamento de Engenharia de sistemas e computação - UERJ

---

Prof.<sup>a</sup> Dra. Agnès Bégué (Orientadora francesa)  
CIRAD – França

---

Prof. Dr. Laerte Ferreira  
Universidade Federal de Goiás

---

Prof. Dr. Vincent Dubreuil  
Universidade de Rennes 2 – França

---

Dr. Rodrigo Ferraz  
EMBRAPA SOLOS

Rio de Janeiro

2021

## **DEDICATÓRIA**

Dedico este estudo à minha família, acima de tudo às minhas filhas Alice e Mel. Mesmo sem ainda entenderem todo o significado desta etapa da nossa vida, nasceram, aprenderam a ler, cresceram e compartilharam esse momento de forma intensa com muita troca. Cada figura desta tese foi fonte de perguntas e até sugestões por parte delas. À minha companheira, parceira e Amor Sofia, com quem durante estes quatro anos compartilhamos lutas e vitórias das maiores da nossa vida. À minha irmã Erika, minha mãe Helena e meu pai Joaquim, pelo apoio, incentivo e ouvidos. Os três sempre me foram fonte de inspiração e sempre me motivaram a alcançar novos horizontes. A todos que de alguma forma me incentivaram a chegar até aqui.

## AGRADECIMENTOS

Gostaria de registrar aqui os meus agradecimentos a todos e todas que tornaram possível a realização deste trabalho. Em especial, gostaria de agradecer:

Às minhas filhas Alice e Mel que doaram parte do tempo delas com o pai para que esta tese se tornasse realidade.

À minha esposa e companheira Sofia, que inevitavelmente renunciou a questões pessoais e profissionais para construirmos juntos uma parte de nossas histórias na França, momento em que fez nossa família crescer com a gestação e nascimento da Mel. Agradeço também toda a paciência, incentivo e apoio incondicional.

À minha irmã Erika, que com toda sua experiência, muito me ouviu e me apoiou a mergulhar na área acadêmica, não somente em formas de palavras e conselhos, mas também de forma prática, que tanto me deram segurança para continuar.

Aos meus pais, Joaquim e Helena, pelo irredutível apoio e confiança em todos as situações, por terem me dado todo amor, ensinamento e coragem para trilhar meu caminho

À minha orientadora Margareth Simões, por me permitir fazer parte do seu grupo e da sua rede de trabalho e por ter sido a primeira pessoa a incentivar meu redirecionamento profissional e acadêmico. Graças ao seu apoio e confiança, me possibilitou buscar novos horizontes, conquistar novos continentes que tanto engrandeceram a minha história profissional e pessoal. Muito obrigado pela sua paciência e resiliência e por todas as oportunidades de crescimento! Obrigado Maggie, minha amiga, por me orientar com a cabeça e com o coração tão grande que vocês têm! Por seu ombro e seu ouvido que tanto necessitei para seguir em frente superando as dores e receios e claro pelas vitórias compartilhadas.

À minha orientadora francesa Agnès Bégué, por me receber tão bem na *Maison de la télédétection*, aceitar me orientar em cotutela e nunca medir esforços para prover os recursos necessários para o bom andamento da pesquisa, do meu aprendizado e do meu bem estar no laboratório e na França. Muito obrigado pela sua disponibilidade, sua torcida, tão importante para mim nos momentos mais difíceis, e nas comemorações das vitórias. Obrigado a você e ao Laurent pela amizade, *dîners, verres à vin et rires*, fundamentais para quem está longe do seu país. *Merci beaucoup!!* Me sinto privilegiado por começar o doutorado com uma orientadora e terminar com duas amigas orientadoras. Vocês são modelos de pesquisadoras!!!

Ao Pesquisador Rodrigo Ferraz, por todo ensinamento, amizade, e disponibilidade durante todo este tempo de elaboração da tese. Obrigado pelas sábias palavras nas horas certas. Esta tese não seria possível sem a sua participação.

Aos pesquisadores da Embrapa, principalmente em nome do Pedro Machado e João Veloso pelos ensinamentos, ajudas, sempre dispostos e disponíveis para ajudar. Meu primeiro mergulho conceitual na área agrícola foi orientado pelo Pedro, que com sua calma, profundo conhecimento e amizade muito me ajudaram no início da tese. O João pelas discussões calorosas e por ajudar a viabilizar o trabalho de campo.

Ao Damien Arvor pelos conselhos, debates e ensinamentos.

Aos pesquisadores da UMR-TETIS pelo acolhimento, pela troca de experiências científicas e de vida, principalmente em nome de Raffaelli Gaetano, Dino e Roberto, *Grazie mille*. Christian Barrón, Valentine Lebourgeois *Merci!*

À equipe da Embrapa Sinop, principalmente em nome da Laurimar e Flavio Wruck, que sem suas disponibilidades, este trabalho não teria ocorrido.

Ao corpo docente do PPGMA, principalmente em nome da professora Elza, do professor Mário, do professor Fernandez e da professora Rosane pelo comprometimento com o programa e pelos ricos debates.

Às secretárias do PPGMA, Dani e Jennifer e do CIRAD Annie, pela disponibilidade e disposição de me ajudarem a encarar as burocracias brasileiras e francesas.

Ao Grupo Bom Futuro pelo apoio à pesquisa

Ao pesquisador e coordenador técnico do Mapbiomas, Marcos Rosa, pelos ensinamentos na plataforma GEE e pela solicitude e motivação em ajudar na pesquisa.

À CAPES-COFECUBE pelo incentivo à pesquisa e financiamento desta tese.

## RESUMO

KUCHLER, Patrick Calvano. *Utilização do sensoriamento remoto para o mapeamento dos sistemas integrados de produção agrícola: contribuição ao monitoramento da agricultura de baixa emissão de carbono no estado do Mato Grosso, Brasil.* 2021. 204 f. Tese (Doutorado em Meio Ambiente) - Universidade do Estado do Rio de Janeiro, Rio de Janeiro; Universidade de Montpellier AgroParisTech, Montpellier, 2021.

Para cumprir seus compromissos internacionais de redução das emissões de gases de efeito estufa, o Brasil criou o plano ABC (Agricultura de Baixo Carbono). A implementação de sistemas integrados de produção está entre as principais estratégias do referido plano. Mais de dez anos se passaram do lançamento do plano e ainda não há mecanismos para monitorar a adoção dessas práticas. O objetivo geral da tese é desenvolver uma metodologia de mapeamento anual em escala regional dos sistemas integrados de produção lavoura-pecuária (iLP), a partir de séries temporais de imagens do satélite MODIS, a fim de contribuir com o estabelecimento de um protocolo de monitoramento da agricultura de baixa emissão de carbono. O trabalho é dividido em três etapas: desenvolvimento da estratégia de classificação dos sistemas iLP; aplicação à escala regional e a análise temática dos mapas resultantes. A área de estudo é o estado de Mato Grosso, maior produtor nacional de soja, com uma grande variedade de ambientes possibilitando avaliar a robustez da metodologia. A etapa-1 foi desenvolvida em uma área no norte do estado. Os resultados mostram que o pré-processamento, como a suavização da série-temporal e o cálculo de indicadores fenométricos, deterioram a acurácia, e que a utilização de Índices de Vegetação 'originais' fornecem bons resultados (Acurácia Global AG=0,96). Constatou-se que o algoritmo *Random Forest* tem um desempenho ligeiramente melhor que o SVM (*Support Vector Machine*). A estratégia foi, em seguida aplicada a todo Mato Grosso, sete anos de campanha agrícola (2012-2019), 6 regiões climáticas, em 4 níveis hierárquicos (Nível 1 - Soja, advinda do Mapbiomas). Os resultados mostram que o uso de uma base de aprendizagem única (vários anos/regiões) para classificar cada região e ano individualmente proporciona acurácia semelhante ao uso de bases particularizadas para cada ano/região. O grande número de amostras de uma base integrada, compensa em grande parte a variabilidade espaço-temporal das classes. O mapa dos sistemas de cultivo Nível-2 (monoculturas SC e culturas sequenciais DC) tem uma AG média de 0,89 no período estudado e boa estabilidade interanual. No Nível-3 a AG = 0,84 e os DCs são divididos em 3 classes (soja-algodão, soja-cereal e o iLP soja-brachiaria). No Nível 4 tem AG= 0,77, a classe iLP é separada em iLP1 (soja-brachiaria) e iLP2 (soja-brachiaria consorciado com milho). Os valores *f-score* do sistema de cultura DC, iLP e iLP1 são próximos (0,89, 0,85 e 0,84) e a classe iLP2 (0,63). A análise dos mapas anuais dos sistemas de cultivo (2012-13 à 2018-19) mostra um aumento de 66% na área de cultivo sequencial, incluindo iLP, e uma redução de 19% na monocultura. Esses resultados refletem uma intensificação agrícola em curso no estado. A intensificação sustentável baseada em sistemas integrados mais que dobrou no mesmo período, de 18,6% (1,1Mha) para 28,9% (2,6Mha) das áreas cultivadas. Concluindo, o método desenvolvido permitiu-nos enfrentar quatro grandes desafios: mapear sistemas complexos (evoluir de cobertura para o uso da terra); em escala regional (diversidade de condições intranuais); de forma retrospectiva e processar um grande volume de dados através de ferramentas do *Big Data*. Planeja-se testar essa abordagem em todo o corredor da soja, a fim de se operacionalizar o monitoramento territorial e análise da adoção de práticas de intensificação sustentável.

Palavras-chave: Desenvolvimento Sustentável. Integração Lavoura-Pecuária. Aprendizado de Máquina. Séries temporais. MODIS. *Big data*

## RESUMÉ

KUCHLER, Patrick Calvano. *Utilisation de la télédétection pour la cartographie des systèmes intégrés de production agricole : une contribution à la surveillance de l'agriculture à faibles émissions de carbone dans l'état du Mato Grosso.* 2021. 204 f. Tese (Doutorado em Meio Ambiente) - Universidade do Estado do Rio de Janeiro, Rio de Janeiro; Universidade de Montpellier AgroParisTech, Montpellier, 2021.

Pour atteindre ses engagements internationaux de réduction des émissions de gaz à effet de serre, le Brésil a un projet appelé Plan ABC (*Agriculture Bas Carbone*). Parmi les stratégies d'intensification durable de l'agriculture, l'Etat incite l'adoption de systèmes intégrés agriculture-élevage-forêt. Toutefois, il est nécessaire de créer des mécanismes de suivi de l'adoption de ces nouvelles pratiques. L'objectif général de la thèse est de développer une méthodologie de cartographie annuelle à l'échelle régionale des systèmes intégrés de type agriculture-élevage (iLP) à partir de séries temporelles d'images satellite MODIS, afin de contribuer à l'établissement d'un protocole de suivi de l'agriculture à faibles émissions de carbone. Le travail est divisé en trois étapes : la mise au point de la stratégie de classification des systèmes intégrés, l'application à l'échelle régionale et l'analyse thématique des cartes obtenues. La zone d'étude est l'État du Mato Grosso, le plus grand producteur national de soja, et qui offre une grande diversité de milieux naturels permettant d'évaluer les méthodes dans des contextes et années climatiques différents. La stratégie de classification a été mise au point dans une zone au nord de l'État. Les résultats montrent que les pré-traitements de type lissage du signal temporel ou calcul d'indices phénométriques détériorent la précision des classifications des systèmes de culture, que l'utilisation de séries temporelles d'indices de végétation permettent d'obtenir de bons scores de classification (précision globale : OA = 0.96) et enfin que l'algorithme Random Forest est légèrement plus performant que SVM (Support Vector Machine). La stratégie a été ensuite appliquée au Mato Grosso, à 7 campagnes agricoles (2012-2019) et 6 régions climatiques, selon une approche hiérarchique en 4 niveaux. Les résultats montrent que l'utilisation d'une base de données d'apprentissage unique (échantillons de différentes années et régions) pour classer chaque région et années individuellement permet d'obtenir des précisions proches que l'utilisation d'une base de données acquise dans chaque région et pour chaque année. Le nombre élevé d'échantillons dus au regroupement compense en grande partie la variabilité spatio-temporelle des classes. La carte des systèmes de culture du niveau 2 (monocultures SC et cultures séquentielles DC) a OA moyenne de 0.89 sur la période étudiée et présente une bonne stabilité interannuelle: OA entre 0.86 et 0.96 ; au niveau 3: OA = 0.84, les DC sont séparées en 3 classes (soja-coton, soja-céréale et le système intégré iLP soja-brachiaria) ; au niveau 4 (OA=0.77), la classe iLP est séparée en iLP1 (soja- brachiaria) et iLP2 (soja-brachiaria en association avec du maïs). Les F-score des classes de systèmes de culture DC, iLP et iLP1 ont une précision proche (0.89, 0.85 et 0.84) et la classe iLP2 (0.63). L'analyse des cartes annuelles des systèmes de culture des campagnes agricoles de 2012-13 à 2018-19 montre une augmentation de 66% de la superficie en cultures séquentielles, y compris les iLP, et une réduction de 19% de la monoculture. Ces résultats témoignent de l'intensification agricole en cours dans l'État. L'intensification durable basée sur les systèmes intégrés à plus que doublé pendant la même période passant de 18.6% (1.1 Mha) à 28.9% (2.6 Mha). En conclusion, la méthode développée nous a permis de relever quatre défis majeurs: cartographier des systèmes complexes (passer de l'occupation des sols à l'utilisation des sols), à l'échelle régionale, de façon rétrospective et traiter un grand volume de données grâce aux outils du *Big Data*. Alors, il est prévu de tester cette approche sur l'ensemble du corridor du soja, pour aboutir à terme à un outil opérationnel de suivi territorial et d'analyse de l'adoption des pratiques d'intensification durable.

Mot clé: Développement durable. Intégration agriculture-élevage. Apprentissage automatique. Séries temporelles. MODIS. Big Data

## ABSTRACT

KUCHLER, Patrick Calvano. *Use of remote sensing for mapping integrated cropping systems: contribution to low-carbon agriculture monitoring in Mato Grosso state, Brazil.* 2021. 204 f. Tese (Doutorado em Meio Ambiente) - Universidade do Estado do Rio de Janeiro, Rio de Janeiro; Universidade de Montpellier AgroParisTech, Montpellier, 2021.

In order to accomplish the international commitments to reduce greenhouse gas emissions, Brazil has a project named ABC Plan (Low Carbon Agriculture Plan). Among strategies for increasing a sustainable intensification of agriculture, Brazil is promoting the adoption of integrated crop-livestock-forest systems. However, it is necessary to create mechanisms to monitor the adoption of those new practices. The overall objective of this thesis is to develop a methodology for annual mapping of integrated crop-livestock systems (iLP) at regional level, from MODIS satellite images timeseries, to contribute to the establishment of a protocol for monitoring low-carbon agriculture. The work is divided into three stages: the development of the integrated system classification strategy, application at regional scale and thematic analysis of the maps obtained. The study area is the state of Mato Grosso, the largest national producer of soybean, which offers a wide variety of natural environments for evaluating methods in different climatic contexts and years. The classification strategy was developed in an area in the north of the state. The results show: that pre-treatments such as temporal signal smoothing or phenometric index calculations deteriorate the accuracy of crop system classifications; that the use of Raw time series of vegetation indices provides good classification scores (global accuracy: OA - 0.96) and that the Random Forest algorithm performs slightly better than SVM (Support Vector Machine). The strategy was then applied to Mato Grosso, 7 agricultural campaigns (2012-2019) and 6 climatic regions, using a hierarchical approach in 4 levels (Level 1 - Soybean, Mapbiomas product). The results show that the use of a single training database (pooling samples from different years and regions) to classify each region and year individually provides similar classification accuracies in comparison to those based on the use of a database acquired in each region and for each year. The high number of samples due to grouping largely compensates for the spatial-temporal variability of the classes. The map of Level 2 cropping systems (SC single crop and DC double crops) has an Overall Accuarcy, OA of 0.89 over the period studied and has good interannual stability: OA between 0.86 and 0.96; at Level 3: OA-0.84, DC are divided into 3 classes (soy-cotton, soy-cereal and the integrated system iLP soy-brachiaria); at level 4 (OA-0.77), the iLP class is separated into iLP1 (soy-bracharia) and iLP2 (soy-bracharia mixed with maize). The F-scores for DC, iLP and iLP1 classes of cropping systems have close accuracy (0.89, 0.85 and 0.84) and the iLP2 class (0.63). Analysis of annual cropping systems maps from 2012-13 to 2018-19 shows a 66% increase in the area under double cropping systems, including iLP, and a 19% reduction in single cropping. These results reflect the ongoing agricultural intensification in the state. Sustainable intensification based on integrated systems has more than doubled during the same period from 18.6% (1.1 Mha) to 28.9% (2.6 Mha) of the cultivated area. In conclusion, the method developed has enabled us to address four major challenges: mapping complex systems (moving from land cover to land use), at the regional level (diversity of environmental conditions), retrospectively (in the absence of corresponding in situ data) and processing a large volume of data using Big Data tools. Therefore, it is planned to test this approach across the entire Brazilian soybean corridor, eventually leading to an operational tool for monitoring and analysis of the adoption of sustainable intensification practices.

Keywords: Sustainable development. Crop-livestock integration. Machine learning. Time series. MODIS. Big Data

## LISTA DE FIGURAS

Figura 1 -	Estrutura Metodológica e etapas de pesquisa .....	25
Figura 2 -	Diferentes componentes e arranjos de integração, iLP, ILF, IPF e ILPF.....	35
Figura 3 -	(a) Proporção entre as modalidades de SI (ILP, ILF, IPF e ILPF); (b) mapa com as áreas em ha de ILPF dos principais estados da federação, para a safra 2015/2016.....	36
Figura 4 -	Diferentes estratégias de implementação dos sistemas integrados lavoura-pecuária na modalidade “Boi safrinha” praticados no Cerrado	38
Figura 5 -	Evolução das emissões de GEE por fonte emissora em toneladas de carbono equivalente .....	41
Figura 6 -	Proporção das emissões de GEE por fonte emissora .....	41
Figura 7 -	Hierarquia dos sistemas agrícolas e níveis de organização .....	42
Figura 8 -	Exemplo de séries temporais de imagens de satélite .....	54
Figura 9 -	Resposta espectral da vegetação .....	64
Figura 10 -	Exemplo de filtragem e suavização por SG .....	67
Figura 11 -	Métricas extraídas pelo TIMESAT. Adaptado de Jönsson e Eklundh (2004) e Htitiou et al (2019) .....	68
Figura 12 -	Os 3 Vs que compões o Big Data.....	70
Figura 13 -	Cubo de Dados .....	72
Figura 14 -	Esquema representativo de floresta aleatória.....	75
Figura 15 -	Mapa das principais bacias Hidrográficas.....	79
Figura 16 -	Mapa Geomorfológico .....	80
Figura 17 -	Perfis topográficos dos sistemas deplainamento .....	81
Figura 18 -	Potencial agroclimático e das áreas de agricultura com referência ao ano de 2017 do Estado do Mato Grosso .....	83
Figura 19 -	Esquema da lógica espacial dos sistemas de cultivo baseada na morfologia .....	84
Figura 20 -	Abertura de áreas para início da colonização. 1976; (d) Alta Floresta década de 70 .....	87
Figura 21 -	Contato entre colonos e povos indígenas em Porto dos Gaúchos .....	87
Figura 22 -	Fotos de campo apresentando a transição entre biomas .....	91

Figura 23 -	Localização das fazendas visitadas em campo .....	91
Figura 24 -	Sistemas integrados fotografados em campo.....	92
Figura 25 -	Comportamento espectral das amostras de classe de cobertura e uso ...	93
Figura 26 -	Sobreposição das curvas de STIS das classes levantadas em campo ...	94
Figura 27 -	Localização da área de estudos da etapa 1 e a visualização a escala da fazenda .....	95
Figura 28 -	a) Séries temporais anuais do R-NDVI MODIS.....	99
Figura 29 -	Métricas fenológicas calculadas pelo TIMESAT.....	99
Figura 30 -	Acurárias Globais em função do número de variáveis, das classificações .....	101
Figura 31 -	Distribuição do nível de importância de cada descritor em cada conjunto de dados.....	101
Figura 32 -	Fluxograma metodológico .....	105
Figura 33 -	Diagrama da estrutura hierárquica de classificação dos sistemas de cultivo.....	106
Figura 34 -	Composição dos três conjuntos de dados de treinamento testados.....	110
Figura 35 -	Distribuição espaço-temporal das amostras de ILP1 e ILP2 no estado do Mato Grosso .....	112
Figura 36 -	Séries temporais da média dos valores de NDVI da classe iLP 1 .....	114
Figura 37 -	Acurácia global e fscore da classe iLP obtida para cada ano .....	115
Figura 38 -	Regiões pluviométricas .....	116
Figura 39 -	Variabilidade espacial das amostras de iLP .....	117
Figura 40 -	Acurácia global e fscore da classe iLP .....	118
Figura 41 -	(a) Áreas de iLP detectadas no nível 2; (b) Mapa pós processado das áreas de iLP.....	119
Figura 42 -	Evolução anual da acurácia global nos 3 níveis .....	121
Figura 43 -	Evolução anual do fscore das classes de sistema de cultivo do Nível 01..	122
Figura 44 -	Comparações entre as áreas cultivadas anuais do Mato Grosso fornecidas pelo IBGE-PAM e aquelas obtidas pela classificação Random Forest .....	124
Figura 45 -	Variação anual na distribuição das classes obtidas pelo método Random Forest, e valores das áreas cultivadas da classe iLP. ....	125
Figura 46-	Mapas que mostram a evolução dos sistemas de cultivo do Nível 2) ....	127

Figura 47 -	Mapas de densidade (índices Kernel) das áreas estabelecidas de iLP ....	129
Figura 48 -	Mapa da quantidade de hectares de ILP implementados por município.	130
Figura 49 -	Correspondência entre as localizações prioritárias e as localizações reais das ILPs.....	131

## **LISTA DE TABELAS**

Tabela 1 - Acurárias obtidas para os diferentes classificadores.....	100
Tabela 2 - Fonte das amostras de campo e sua proporcionalidade.....	108
Tabela 3 - Métricas dos resultados de acurácia dos conjuntos balanceados e não balanceados.....	111
Tabela 4 - Valores anuais da acurácia global do mapeamento dos sistemas de cultivo obtidos no nível estadual do Mato Grosso, para os diferentes níveis.....	120

## LISTA DE ABREVIATURAS E SIGLAS

ABC	Agricultura de Baixo Carbono
API	Interface de programação de aplicativos
AWiFS	<i>Advanced Wide Field Sensor</i>
BEOD	<i>Big Earth Observation Data</i>
COP-17	17º Conferência das Partes
Embrapa	Empresa de Pesquisa Agropecuária Brasileira Corporação
ENOS	<i>El Niño Oscilação Sul</i>
EVI	Índice de Vegetação Aprimorado
FAO	Organização para a Alimentação e Agricultura
FGV-GVAGRO	Centro Agroalimentar da Fundação Getúlio Vargas
Fundo do Clima	Fundo Nacional de Mudanças do Clima
GEE	Gases de Efeito Estufa
IBAMA	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis
iLP	Integração, Lavouva e Pecuária
ILPF	Integração, Lavouva, Pecuária e Floresta
INPE	Instituto Nacional de Pesquisas Espaciais
IPCC	<i>Intergovernmental Panel on Climate Change</i>
MDA	Mean Decrease Accuracy
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>

NDVI	Índice de Vegetação por Diferença Normalizada
ONG	Organizações não governamentais
ONU	Organização das Nações Unidas
OTB	<i>Orfeo ToolBox</i>
PAM	Pesquisa Agrícola Municipal
Plano ABC	Plano de Agricultura de Baixa Emissão de Carbono
PRODES	Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite
RF	<i>Random Forests</i>
SEEG	Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa
SIs	Sistemas Integrados
STIS	Séries Temporais de Imagem de Satélite
SVM	<i>Support Vector Machine</i>
TI	Tecnologia da Informação
UNFCC	Convenção-Quadro das Nações Unidas sobre Mudanças Climáticas
URTs	Unidades de Transferência Tecnológica

## SUMÁRIO

	<b>INTRODUÇÃO .....</b>	17
1	<b>FUNDAMENTAÇÃO TEÓRICA .....</b>	27
1.1	<b>Intensificação da agricultura no Brasil .....</b>	27
1.2	<b>Sistemas Integrados de produção agropecuária.....</b>	31
1.3	<b>Agricultura de baixa emissão de carbono.....</b>	40
1.4	<b>Monitoramento de uso e cobertura da terra por sensoriamento remoto</b> 44	
1.4.1	<u>Monitoramento do uso agrícola em larga escala .....</u>	48
1.4.1.1	Principais iniciativas e Programas Internacionais .....	48
1.4.2	<u>Monitoramento dos sistemas de produção agrícola em larga escala .....</u>	51
1.4.2.1	Dados MODIS ( <i>MODerate resolution Imaging Spectroradiometer</i> ) .....	59
1.4.2.2	Séries temporais de dados de sensoriamento remoto .....	60
1.4.2.2.1	Índices de vegetação .....	62
1.4.2.2.2	Filtragem e suavização de séries temporais.....	65
1.4.2.2.3	Métricas fenológicas.....	67
1.5	<b>Big data e observação da Terra, uma estratégia.....</b>	69
1.5.1	<u>Big Earth Observation Data.....</u>	69
1.5.2	<u>Mineração de dados espaciais e aprendizado de máquina.....</u>	73
1.5.2.1	Classificador <i>Random Forest</i> .....	74
1.5.2.2	Avaliação da acurácia.....	76
1.6	<b>Considerações sobre o Capítulo.....</b>	77
2	<b>ÁREA DE ESTUDOS .....</b>	78
2.1	<b>Seleção da área de estudos .....</b>	78
2.1.1	<u>Caracterização geográfica do estado do Mato Grosso.....</u>	78
2.1.1.1	Histórico da colonização da região e abertura de áreas .....	84
2.1.2	<u>Desenvolvimento da agropecuária .....</u>	88
2.1.3	<u>Sistemas integrados (SIs) .....</u>	90
2.2	<b>Coleta de dados em campo .....</b>	90
2.2.1	<u>Séries temporais MODIS de amostras coletadas em campo .....</u>	93
3	<b>ETAPA 1: DESENVOLVIMENTO DA ESTRATÉGIA DE CLASSIFICAÇÃO.....</b>	96
3.1	<b>Dados e métodos.....</b>	97
3.1.1	<u>Suavização das séries temporais MODIS .....</u>	98

3.1.2	<u>Extração de métricas fenológicas</u>	98
3.1.3	<u>Avaliação dos algoritmos de classificação</u>	99
3.1.4	<u>Validação da classificação</u>	99
3.2	<b>Resultados</b>	99
3.2.1	<u>Acurácia dos conjuntos de dados</u>	101
3.2.2	<u>Análise da evolução da acurácia pela dimensionalidade</u>	102
3.2.3	<u>Distribuição do nível de importância dos principais descritores</u>	103
3.3	<b>Conclusão parcial</b>	104
4	<b>ETAPA 2: ESTRATÉGIA DE CLASSIFICAÇÃO DOS SISTEMAS</b>	
	<b>INTEGRADOS APLICADOS À ESCALA</b>	106
4.1	<b>Dados e métodos</b>	106
4.1.1	<u>Estrutura hierárquica</u>	107
4.1.2	<u>Pós-tratamento</u>	108
4.1.3	<u>Estratégia para criar uma base de dados de aprendizagem</u>	109
4.1.3.1	Métodos de coleta de dados de aprendizagem	109
4.1.3.2	Balanceamento da base de dados de aprendizagem	111
4.1.4	<u>Impacto da distribuição espaço-temporal de conjuntos de dados de aprendizagem na qualidade das classificações</u>	113
4.1.4.1	Questões metodológicas	113
4.1.4.2	Impacto da distribuição temporal do conjunto de dados de aprendizagem	115
4.1.4.3	Impacto da distribuição espacial do conjunto de dados de aprendizagem	118
4.2	<b>Resultados</b>	121
4.2.1	<u>Avaliação de mapas de sistemas de cultivo em diferentes níveis</u>	121
4.2.2	<u>Acurácia global (AG)</u>	122
4.2.3	<u>Acurácia das classes dos Sistemas Integrados</u>	124
4.3	<b>Conclusão parcial</b>	125
5	<b>ETAPA 03: ANÁLISE TEMÁTICA DA IMPLANTAÇÃO DOS SISTEMAS</b>	
	<b>INTEGRADOS NO ESTADO DO MATO GROSSO</b>	127
5.1	<b>Comparação com dados estatísticos oficiais</b>	127
5.2	<b>Dinâmica temporal</b>	129
5.3	<b>Dinâmica Espacial</b>	131
5.4	<b>Conclusão parcial</b>	134
	<b>CONSIDERAÇÕES FINAIS E PERSPECTIVAS FUTURAS</b>	135
	<b>REFERÊNCIAS</b>	140



## INTRODUÇÃO

- **Contexto geral e motivações**

Diante da projeção de crescimento da população mundial, atingindo 10 bilhões de habitantes em 2050, os cenários baseados em crescimento econômico moderado apontam que será necessário, em relação ao ano de 2013, aumentar em 50% a produção mundial de alimentos pra atender a demanda projetada (FAO, 2017). Dada a disponibilidade limitada de novas terras aráveis, o aumento da produção agrícola só poderá ser alcançado pelo aumento da produtividade e / ou pela intensificação dos sistemas de produção agropecuários (FAO, 2009). A este contexto, deve-se adicionar as projeções de mudanças climáticas que aumentam a incerteza e ameaçam, a nível global, a estabilidade da produção e a segurança alimentar. Os cenários mostram o aumento das pressões ambientais, desmatamento, emissão de gases de efeito estufa, exploração dos recursos hídricos, degradação da água e da qualidade do solo, aos quais se soma a forte competição por terras. Assim, aumentar a capacidade de produção agrícola de forma efetivamente sustentável consiste no desafio que se coloca, hoje, aos países produtores como o Brasil. Produzir mais para garantir a segurança alimentar e atender à crescente demanda mundial por alimentos, fibras e biocombustíveis e, ainda, diminuir a pressão sobre os seus recursos naturais, mantendo os serviços ecossistêmicos e reduzindo as emissões dos gases de efeito-estufa, constitui o grande desafio que o setor agropecuário nacional deverá enfrentar nas próximas décadas.

Neste cenário, Ferraz e Skorupa (FERRAZ; SKORUPA, 2017) apontam que o Brasil enfrenta, particularmente, três situações desafiadoras que, ao mesmo tempo, se configuram em excelentes oportunidades para se consolidar como um dos países líderes na produção sustentável de gêneros agropecuários.

O primeiro desafio diz respeito ao aumento da capacidade produtiva nacional, por meio de incrementos de produtividade, visando atender à crescente demanda mundial. Esta perspectiva, como destacam os autores, é desafiadora para o país, mas também se configura como uma grande oportunidade para a consolidação e conquista de novos mercados para as commodities agropecuárias brasileiras.

Em conformidade com o novo Código Florestal (Lei 12.651/2012), que regulamenta o uso da terra e limita a expansão desordenada da fronteira agrícola, o segundo desafio consiste

em aumentar a produção sem aumentar significativamente a área de produção, conservando o máximo as áreas com vegetação nativa. O que parece, a princípio, uma limitação para o setor agrícola, configura na verdade uma grande oportunidade, uma vez que este cenário induz à intensificação da produção nacional.

O terceiro desafio se refere exatamente a transição tecnológica necessária para a viabilização de sistemas de produção que compatibilizem as esferas sociais, econômicas e ambientais. Concluem os autores que, em conjunto, os desafios e oportunidades convergem para a necessidade de se buscar formas de se intensificar a produção agropecuária nacional, em bases sustentáveis, maximizando o uso de recursos naturais disponíveis, respeitando os serviços ambientais e orientando a produção para as áreas, já antropizadas, com pastagens degradadas.

Deste modo, o incentivo para a adoção de sistemas sustentáveis que maximizam a rentabilidade e a produção, através da diversificação e ganhos de produtividade, e, que também geram serviços ecossistêmicos, pode configurar uma importante vantagem competitiva para o Brasil, considerando que o mercado mundial está cada vez mais exigente e seletivo aos modos de produção (FERRAZ; SKORUPA, 2017)

Em resposta a esse desafio, por ocasião da Convenção da ONU sobre o Clima, ocorrida em dezembro de 2009 em Copenhague/Dinamarca, o Brasil assumiu junto à comunidade internacional um compromisso voluntário de adotar medidas para reduzir em 37% suas emissões de GEE até 2025, considerando como linha de base o ano de 2005. Para atingir este objetivo o governo estabeleceu metas de redução para cada setor da economia brasileira. No decorrer do mesmo ano, o país sancionou a Política Nacional de Mudanças do Clima e criou o Fundo Nacional de Mudanças do Clima (Fundo do Clima) para ações de adaptação e mitigação, e, em 2015, o Brasil ratificou seu compromisso voluntário assinando o Acordo de Paris.

Particularmente para o Setor da Agricultura, foi instituído em 2010 pelo MAPA, o Plano Setorial de Mitigação e de Adaptação às Mudanças Climáticas Visando à Consolidação de uma Economia de Baixa Emissão de Carbono na Agricultura (Plano ABC). Os principais objetivos do Plano ABC consistem na redução das emissões de GEE e na adaptação do setor agropecuário às mudanças climáticas, a partir do incentivo à adoção de práticas de manejo e sistemas de produção que gerem balanço positivo de carbono, aumentando a eficiência no uso de recursos naturais e a resiliência dos sistemas produtivos. Entre essas práticas, destacam-se os sistemas integrados de produção agropecuárias (iLPF), atualmente considerados como uma estratégia de intensificação produtiva, sustentável, visto que a integração das atividades agrícolas com a pecuária e o reflorestamento promove o sinergismo dos ciclos biológicos, otimizando os meios

de produção e permitindo maior eficiência no uso dos recursos naturais. (BALBINO; BARCELOS; STONE, 2011; HERRERO et al., 2010).

O Plano ABC constitui, de fato, uma política de estado sem precedentes no mundo, tanto pelas metas estabelecidas e investimentos públicos envolvidos, quanto pelo seu caráter inovador. Os efeitos sinérgicos da política pública setorial (Plano ABC) com as ações da Rede iLPF e os esforços do Sistema Nacional de Pesquisa Agropecuária (SNPA), coordenado pela Embrapa, além do engajamento do setor produtivo, têm alavancado a adoção dos sistemas de produção integrada que, relativamente, já se encontram bastante difundidos no Brasil, principalmente no eixo centro-norte da produção de soja.

Entretanto, uma década após o lançamento do Plano ABC, ainda não foram desenvolvidas metodologias e ferramentas eficientes para o monitoramento da adoção dos sistemas integrados de produção, dificultando o acompanhamento das metas estabelecidas pelo referido plano. Como concluiu o estudo “A Governança do Plano ABC”, produzido pelo Centro de Agronegócio (GVAgro) da FGV-SP, a ausência de instrumentos para acompanhar a aplicação de recursos e monitorar as metas estabelecidas para o setor agropecuário tem causado problemas de governança para o Plano ABC. Além disso, informações sobre as taxas de adoção, expansão e distribuição espacial dos sistemas iLPF no Brasil têm sido requisitadas por diversos outros agentes interessados, como: Agências de Governo ligadas ao MAPA e ao MMA, a Rede iLPF, o Observatório ABC (FVG-SP), a Plataforma ABC (Plataforma Multiministerial coordenada pela Embrapa), Observatório do Clima (FVG) Universidades e Instituições de Pesquisa, dentre outros. Além do interesse do próprio setor produtivo, composto por Cooperativas Agropecuárias de Produtores, Empresas Agropecuárias, e demais empresas da cadeia de insumos, equipamentos e serviços. Os setores de Logística, Infraestrutura e Transporte relacionadas ao setor, também podem se valer dessas informações, uma vez que, elas possuem um caráter estratégico.

Atualmente, as poucas estimativas de adoção dos sistemas integrados (iLPF) realizadas no Brasil, foram feitas por meio de levantamentos custosos em tempo e recursos. Dentre estes, cabe mencionar o levantamento realizado por GIL, SIEBOLD & BERGER (2015), que entrevistaram, durante um período de 6 meses, cerca de 134 produtores e técnicos, visando extrair informações sobre a ocorrência e localização de sistemas integrados de produção agropecuária nos municípios do Estado do Mato Grosso (MT), para o ano safra de 2012/2013. Outro estudo, realizado em 2017 pela *Klefman Group*, gerou o relatório intitulado “iLPF em números” (EMBRAPA, 2017), no qual apresenta-se o inventário da ocorrência dos sistemas

integrados, em suas diversas modalidades (iLPF, iLP, iLF, iPF) para cada estado da Federação. Cabe observar que esses estudos, baseados em metodologias de levantamento censitário de informações, não permitem acompanhar satisfatoriamente a dinâmica de adoção, implementação e expansão dos sistemas integrados de produção para o vasto território nacional. A despeito disso, o monitoramento da dinâmica das mudanças de uso da terra neste processo de transição tecnológica é de fundamental importância para o planejamento setorial da agropecuária brasileira, assim como, para o acompanhamento das metas de redução das emissões de gases de efeito estufa, estabelecidas pelo país (BUSTAMANTE et al., 2012; RAJAO; SOARES-FILHO, 2015).

Diante dessa evidência, a justificativa e a motivação do presente trabalho se fundamentam na possibilidade de contribuir com o desenvolvimento de protocolos metodológicos para o monitoramento dos sistemas integrados de produção agropecuária (iLPF), em apoio à governança do Plano ABC.

Embora, haja consenso, na comunidade científica, sobre a necessidade de se caracterizar os sistemas de produção agrícola em escala regional, poucos são os exemplos encontrados na literatura especializada. Bégué et al. (2018), realizaram uma extensa revisão sobre a detecção de práticas e sistemas agrícolas, onde apontam que menos de 10% das publicações de sensoriamento remoto se dedicam, de fato, ao desenvolvimento de metodologias de mapeamento de sistemas e/ou práticas agrícolas e que a grande maioria dessas publicações se referem a trabalhos exploratórios, centrados em alguma prática específica a nível local.

Por outro lado, mapeamentos globais e regionais, como, por exemplo, o mapeamento de sistemas agrícolas da Organização para a Alimentação e Agricultura (FAO) (DIXON; GULIVER; GIBBSON, 2001) ou os mapeamentos da FEWS-NET (USAID, 2009), são elaborados em escalas muito generalizadas que não atendem às necessidades do monitoramento local. Leenhardt et al. (2010) revisaram diversos trabalhos de mapeamento regional dos sistemas de produção agrícola e concluíram que, na ausência de métodos de mapeamento confiáveis, os inquéritos de campo ainda permanecem primordiais. De fato, a contribuição do sensoriamento remoto para o mapeamento dos sistemas de produção agrícola ainda se encontra bastante fragmentada e diversa.

Assim sendo, a evolução dos métodos tradicionais de mapeamento da cobertura ou ocupação da terra para mapas de uso da terra e, posteriormente, para mapas de sistemas de produção agrícola, constituem ainda um desafio metodológico, requerendo o desenvolvimento de novos métodos e o processamento de novos dados, assim como, a integração entre as

diferentes disciplinas da pesquisa científica (VERBURG et al., 2009). Desta forma, mais do que a simples detecção remota e a identificação de diferentes tipos de culturas agrícolas, o mapeamento de sistemas de cultivo requer que se tenha conhecimento agronômico sobre os ciclos fenológicos, o calendário agrícola, as técnicas, práticas e as estratégias adotadas pelos produtores locais. De modo a caracterizar mais precisamente os arranjos espaciais e as sequências de práticas ou de cultivos que caracterizam cada sistema produtivo.

As Séries Temporais de Imagem de Satélite (STIS) são capazes de captar o comportamento dos ciclos fenológicos da vegetação, tornando-se possível observar a dinâmica do uso e cobertura da terra (LIU; CAI, 2012). Conforme discutido por Gómez et al. (2016), em revisão sobre o assunto, as séries temporais de índices de vegetação permitem a reconstrução de todo o ciclo fenológico da vegetação, o que em particular permite um melhor entendimento dos sistemas agrícolas complexos, sobretudo, daqueles baseados em cultivos sequenciais, evidenciados pelos distintos ciclos fenológicos. Com base nesta premissa, o satélite *Moderate Imaging Spectroradiometer* (MODIS) tem sido usado com sucesso para o mapeamento de grandes áreas com culturas solteiras ou sequenciais (duplo cultivo), destacando-se os trabalhos nos Estados Unidos da América (EUA) (WARDLOW; EGBERT; KASTENS, 2007; WARDLOW; EGBERT, 2008) e na China (MINGWEI et al., 2008; QIU et al., 2014).

No contexto da inteligência artificial, os algoritmos de aprendizado de máquina (*machine-learning e/ou deep-learning*) como o *Support Vector Machine* (SVM) e o *Random Forest* (RF), devido a sua abordagem não paramétrica e significativa flexibilidade permitem processar um grande volume de dados sem necessidade de significativo conhecimento prévio (TAMIMINIA et al., 2020). Atualmente, os algoritmos de aprendizagem de máquina têm demonstrado grande potencial para o desenvolvimento de metodologias de monitoramento automático do uso e cobertura da terra, e, de interesse imediato desta tese, para o monitoramento de sistemas de produção.

As novas tecnologias da informação (*Big Data*) e as missões de satélite recentes estão revolucionando o mundo do sensoriamento remoto e abrindo novas possibilidades para o mapeamento da cobertura e uso da terra (LI et al., 2016). Novas plataformas de processamento de dados de satélite, cada vez mais acessíveis, como o *Google Earth Engine* (GEE), possibilitam a partir de uma interface de programação acessar um catálogo de *petabytes* de imagens e usar a infraestrutura de processamento (GORELICK et al., 2017). Este novo paradigma no processamento de dados espaciais oferece um ambiente que permite compensar as limitações técnicas do processamento de imagens em grandes áreas. Assim, como mostra a

revisão publicada por Tamiminia et al., (2020), o GEE tem sido, cada vez mais, utilizado em escala global para o mapeamento de áreas agrícolas. Mas cumpre salientar que poucos são os trabalhos orientados para o mapeamento de sistemas de cultivo sequencial e, nenhum, especificamente, sobre os sistemas integrados de produção agropecuária.

Como visto anteriormente, o grande volume de informações disponíveis, bem como, os avanços tecnológicos para obtenção, tratamento e processamento de dados, trazem consigo enorme potencial para o desenvolvimento de metodologias de monitoramento da agricultura (SIMÕES et.al., 2017)

No Brasil, uma importante iniciativa liderada por uma rede colaborativa de especialistas, o Projeto Brasileiro de Mapeamento Anual da Cobertura e Uso do Solo (Mapbiomas), usa o GEE e imagens Landsat (SOUZA et al., 2020) e de forma inédita tornou possível o mapeamento de todo o território nacional com resolução de 30 m ao longo de 33 anos. Dentre os grandes grupos de classes de cobertura e uso do solo, o Mapbiomas possui em sua legenda classes específicas relativas à agropecuária. Deste modo, além da classe pastagem, estão disponibilizadas, também, as classes "soja", "cana-de-açúcar" e "outras culturas temporárias". O Mapbiomas continua a aprimorar os métodos de processamento de imagens, produzindo uma nova versão de mapas de uso e cobertura do solo a cada ano. O Mapbiomas é um produto essencial para estudar mudanças na cobertura e uso da terra em escala nacional, em particular para monitorar a expansão da agricultura brasileira. No entanto, até o momento, o grupo de classes de agricultura e pecuária não contempla informações sobre sistemas complexos, incluindo cultivos sequenciais como os sistemas de duplo cultivo e o sistemas integrados de produção (iLP).

Culturas sequenciais com duas ou até três safras anuais são sistemas muito comuns no Brasil, principalmente no eixo centro-norte da produção de soja. Eles são a principal estratégia para intensificar a agricultura. Os sistemas integrados (SIs) fazem parte da lógica do cultivo sequencial, mas possuindo uma complexidade adicional atrelada à presença de pastagens e / ou florestas plantadas. Há muito, o Brasil vem realizando estudos sobre o mapeamento de culturas sequenciais utilizando STIS (ARVOR et al., 2011; BROWN et al., 2013; CHEN et al., 2018; GALFORD et al., 2008; KASTENS et al., 2017; PICOLI et al., 2018; SPERA et al., 2014; ZHU et al., 2016), no entanto, poucos estudos foram publicados sobre o mapeamento por sensoriamento remoto de sistemas integrados de produção (KUCHLER et al., 2020; MANABE; MELO; ROCHA, 2018).

O trabalho de Câmara et al. (2016) aponta que mesmo com a disponibilização de um grande e crescente volume de dados de sensoriamento remoto, apenas uma pequena parte é realmente utilizada para pesquisas científicas e aplicações operacionais, e que os resultados publicados são com base em experimentos realizados a partir de pequenos conjuntos de dados e localizados em pequenas áreas, não sendo devidamente testados e validados em regiões com maior abrangência territorial. Em consonância com esta afirmação, Bégué et al. (2018) corroboram que a grande maioria das pesquisas sobre práticas agrícolas é realizada a nível local, geralmente condicionada à necessidade de grandes campanhas de aquisição de dados de campo para classificações supervisionadas e ao alto custo computacional. Isso levanta a questão da reprodutibilidade dos métodos e da disponibilidade de dados de aprendizagem a nível regional, que hoje permanecem as principais fontes da discrepância observada entre os muitos estudos acadêmicos publicados e os procedimentos de fato disponíveis para subsidiar políticas pública em muitos países.

Cabe ressaltar que este trabalho de tese está vinculado ao Projeto Metodologias e Inovações Tecnológicas para o Monitoramento e o Planejamento da Agricultura de Baixa Emissão de Carbono em Apoio à Governança do Plano ABC – Geo ABC. O projeto foi financiado pela CAPES/COFECUB edital 01/2015, coordenado pela Dra Margareth Simões e pela Dra Agnès Bégué, tendo como objetivo avaliar métodos e técnicas inovadoras na área do sensoriamento remoto e integração de dados espaciais para a detecção de práticas de cultivo e sistemas de produção sustentáveis alinhados às políticas de emissão de baixo carbono na agricultura, cujo propósito é disponibilizar metodologias adequadas que possam fornecer indicadores espaciais em apoio aos esforços de acompanhamento e governança do Plano ABC. Este projeto constitui a consolidação da cooperação internacional França/Brasil formada pela rede de parceiros: UERJ, Embrapa, Inpe, UMR TETIS/CIRAD, *Université Rennes 2*, visando dar continuidade as linhas de pesquisa em “agricultura sustentável e observação da terra”.

- **Hipótese**

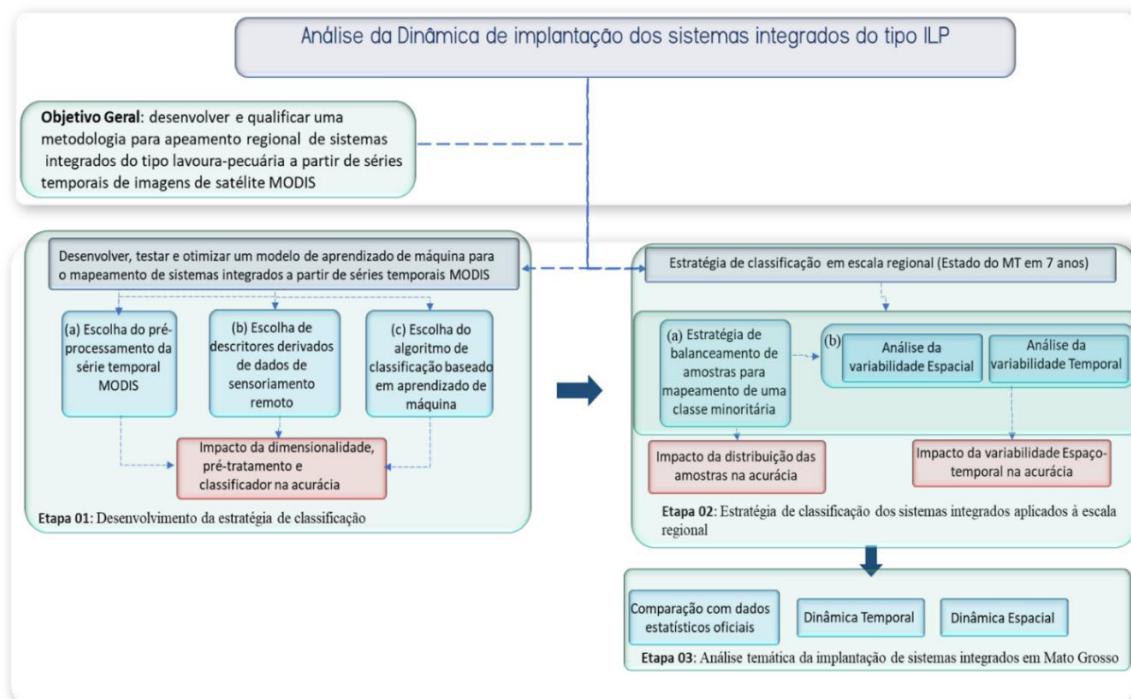
A hipótese que alicerça esta tese é que, o uso de séries temporais MODIS associadas a algoritmos de aprendizado de máquina, possibilita a detecção dos sistemas integrados de produção do tipo lavoura-pecuária (ou iLP) em escala regional.

Acredita-se que a computação paralela nas nuvens, baseada no conceito de *Big Earth Observation Data*, permite o desenvolvimento de uma metodologia eficiente e reproduzível para monitorar sistemas complexos de produção agropecuária em escala regional.

- **Objetivo geral**

Assim, o objetivo geral desta tese é desenvolver e qualificar uma metodologia para o mapeamento regional e multi-temporal dos sistemas integrados de produção do tipo integração lavoura-pecuária (iLP) a partir de séries temporais de imagens do satélite MODIS, a fim de contribuir para o estabelecimento de um protocolo de monitoramento da agricultura de baixa emissão de carbono, conforme recomendado pelo Plano ABC. Para atingir esse objetivo, o trabalho foi dividido em objetivos específicos, organizados em três etapas, como ilustrado na **Figura 1 - Estrutura Metodológica e etapas de pesquisa**.

Figura 1 - Estrutura Metodológica e etapas de pesquisa



- **Objetivos específicos**

**Etapa 1:** Desenvolvimento da estratégia de classificação.

O objetivo específico desta etapa foi desenvolver, testar e otimizar um modelo de aprendizado de máquina para o mapeamento dos sistemas iLP a partir de séries temporais MODIS. Isso passou pela:

- (a) escolha do pré-processamento da série temporal MODIS (suavização das séries temporais);
- (b) escolha de descritores derivados de dados de sensoriamento remoto (bandas espectrais, índices de vegetação, índices fenológicos etc.);
- (c) escolha do algoritmo de classificação baseado em aprendizado de máquina.

Esta estratégia de classificação foi desenvolvida e testada em uma área de estudo ao norte do estado de Mato Grosso e focado em apenas 1 ano-safra.

**Etapa 2:** Aplicação da estratégia de classificação a nível regional.

Nesta etapa, a estratégia de classificação dos sistemas iLP desenvolvida na Etapa 1 foi aplicada em nível regional, em todo o estado do Mato Grosso, e em 7 anos-safra no período que corresponde entre 2012-2019. Esta aplicação levanta novas questões metodológicas de pesquisa ligadas à concentração de dados de campo de SIs e em relação à heterogeneidade espaço-temporal das condições agro-climáticas. Essas questões demandam novos experimentos focados na estratégia de construção de uma base de dados de aprendizagem, objetivando-se:

- (a) avaliar uma estratégia de coleta de dados e construção de base de dados de aprendizagem para mapear uma classe "minoritária";
- (b) o impacto sobre a acurácia das classificações do uso de dados de aprendizagem para mapear áreas e anos que não foram amostrados. Para caracterizar a heterogeneidade espaço-temporal, foi utilizado o regime de precipitação.

**Etapa 3:** Análise temática da implantação de SIs no Mato Grosso.

Nesta etapa, objetivou-se realizar uma segunda validação, desta vez temática, dos produtos gerados na Etapa 2 através da comparação dos resultados com bases estatísticas oficiais. Também pretendeu-se realizar análises espaciais a fim de identificar a dispersão

espacial do nível de implantação dos sistemas iLP no estado, assim como a evolução anual de implantação destes sistemas. Abaixo são apresentados os três objetivos específicos desta etapa:

- (a) Comparar os resultados da Etapa 2 com dados estatísticos oficiais;
- (b) Analisar a dinâmica temporal;
- (c) Analisar a dinâmica espacial.

É importante ressaltar que os desenvolvimentos de Tecnologia da Informação (TI) deste trabalho de tese foram todos realizados com ferramentas de código aberto, fáceis de usar e de reproduzir em diferentes escalas e regiões.

- **Organização da tese**

A presente tese foi organizada em 7 capítulos. O primeiro, não numerado, trata da introdução deste trabalho. O capítulo 1 apresenta o contexto científico e discutirá os principais conceitos e bases teóricas que fundamentam a tese, começando pela discussão sobre a Intensificação da agricultura no Brasil, o Plano ABC e os sistemas integrados de produção agropecuária, assim como a discussão no âmbito da gestão pública para implantação de metas de redução de Gases de Efeito Estufa (GEE) no setor e sua relação com os sistemas integrados. A utilização de técnicas de sensoriamento remoto para mapeamento do uso e cobertura da terra em larga escala com o foco no uso agrícola, destacando-se a caracterização dos sistemas de produção agrícola, além das técnicas de processamento de séries temporais de imagens de satélite e a integração com a área de *Big Data*. O capítulo 2 apresenta a caracterização geográfica da área de estudos e revela os desafios da agricultura no Estado do Mato Grosso, assim como descreve o trabalho de coleta de dados de campo. O capítulo 3 trata dos métodos e dos principais resultados obtidos na etapa de desenvolvimento da estratégia de classificação por sensoriamento remoto. O capítulo 5 apresenta a estratégia de classificação dos sistemas integrados de produção (iLP) aplicados à escala regional, os métodos e os resultados obtidos. Por fim, no capítulo 6 é apresentada a análise temática da implantação dos sistemas integrados lavoura-pecuária (iLP) no estado do Mato Grosso. O capítulo 6 apresenta as conclusões, discussão geral, contribuições e perspectivas futuras.

# 1 FUNDAMENTAÇÃO TEÓRICA

Como introduzido anteriormente, esta tese tem como tema o processamento digital de imagens de sensoriamento remoto, com o propósito específico de desenvolver e propor uma metodologia capaz de detectar e monitorar a adoção e a expansão dos sistemas integrados de produção agropecuária, notadamente, a integração lavoura-pecuária no Brasil. Para tanto, este capítulo apresenta e discute os conceitos fundamentais que alicerçam a presente pesquisa.

## 1.1 Intensificação da agricultura no Brasil

A agricultura no Brasil sempre desempenhou um papel de destaque na economia nacional. Dentro de uma perspectiva histórica o país testemunhou sucessivos ciclos agroeconômicos caracterizados pela expansão de diversas monoculturas, orientadas sobretudo à produção de commodities de exportação como, por exemplo o ciclo colonial da cana-de açúcar, o ciclo do café do século XIX e início do XX, o ciclo do cacau no período da República Velha (1889 – 1930), algodão durante os séculos XVIII e XIX, dentre outros (FERRAZ; SKORUPA, 2017). A produção agropecuária no país se baseava principalmente nos baixos custos de produção, na mão-de-obra barata ou escrava e na existência de mercados internacionais. Tratava-se, portanto, de um modelo essencialmente extensivo de produção agrícola com baixa produtividade e emprego de tecnologia, no qual o aumento da escala de produção se relacionava muito mais com a expansão da área de produção do que com ganhos efetivos de produtividade.

A partir dos anos 70, na esteira da revolução verde, a agricultura nacional começa a se modernizar, baseada em crescente tecnificação, emprego de capital e robusta pesquisa agronômica. O setor agropecuário nacional ganha a partir de então um novo impulso, alcançando notáveis avanços em termos de produtividade e produção. O Brasil que nos anos 70 dependia da importação de alimentos básicos deu um salto sem precedentes no cenário mundial em termos de aumento da produtividade e produção nacional de grãos. Cultivando 22 milhões de hectares, aproximadamente, a produtividade média a época era muito baixa, cerca de apenas 783 quilos por hectare. Em 2010, registrou-se no país uma produtividade média de 3.173 quilos por hectare, o que representa um salto na ordem de 774% de aumento (LOPES; CONTINI, 2012). Em grande medida, aos avanços alcançados pela agricultura nacional se devem, além do

pioneerismo dos produtores, da tecnificação e do maior emprego de capital, à notável pesquisa agropecuária que, dentre outros feitos, tem permitido a “tropicalização da agricultura” nacional (FERRAZ; SKORUPA, 2017; VIEIRA FILHO et al., 2016). Tecnologias como o plantio direto na palha, o controle biológico e do manejo integrado de pragas (MIP), a fixação biológica de nitrogênio (FBN), a geração de cultivares adaptadas às diferentes condições edafoclimáticas e/ou resistentes ou tolerantes a diversas pragas e doenças, dentre outras, vem dando suporte tecnológico e conferindo vantagens competitivas ao setor da agropecuária nacional (FERRAZ; SKORUPA, 2017).

Nos últimos 25 anos o país se consolidou como o maior exportador líquido - diferença entre exportações e importações - de produtos agropecuários do mundo e, segundo a Organização Mundial do Comércio (OMC) (SNA, 2020), no ranking das exportações, o Brasil ocupa, a partir de 2019, o terceiro lugar das exportações mundiais. O relatório da OMC indica ainda que o Brasil, desde o ano de 1995, figura como o maior exportador mundial de commodities como açúcar, café e suco de laranja e que, nos últimos anos, assumiu a liderança nas exportações de soja e se firmou como um dos maiores produtores mundiais de milho, algodão, carnes dentre outros produtos agropecuários. Além da destacada posição como exportador, atualmente, o país se consolida como o maior produtor mundial de Soja e carne Bovina (USDA, 2018).

Apesar de todos os avanços alcançados nas últimas décadas relacionados aos ganhos de produtividade, o modelo de desenvolvimento da agricultura no Brasil, de forma geral, ainda se baseia, em grande medida, no paradigma da intensificação horizontal, no qual extensas áreas são cultivadas continuamente com monoculturas agrícolas (FERRAZ e SKORUPA, 2017). A implementação desse modelo de desenvolvimento agrícola extensivo, em termos de abrangência de área produtiva, mas intensivo, em termos de capital e tecnologia, conduziu sem dúvida o país a desempenhar um papel significativo na produção global de alimentos e energia, contudo, esses ciclos de monoculturas que se caracterizam pelo crescimento em larga escala de uma determinada atividade agrícola induzem, direta ou indiretamente, à expansão da fronteira agrícola e às mudanças de uso da terra. Processos de degradação ambiental como a perda da biodiversidade, a erosão dos solos, assoreamentos de corpos hídricos e escassez dos recursos hídricos estão intrinsecamente relacionados às mudanças de uso da terra e à exploração não sustentável dos recursos naturais (PARUELO; BURKE; LAUENROTH, 2001; WU, 2008). Devido aos impactos na base de recursos naturais, o processo de expansão da agricultura nacional tem gerado passivos socioeconômicos e/ou ambientais que em muitos casos conduzem

ao abandono ou subutilização de áreas em processo de degradação. Intensifica-se assim, a busca por novas áreas de produção, gerando grande pressão em áreas de fronteira agrícola, especialmente nos biomas da Amazônia e Cerrado (BARONA et al., 2010; DE MATTOS SCARAMUZZA et al., 2017).

Nas últimas décadas a agropecuária nacional sofreu profundas transformações do ponto de vista da migração espacial, partindo dos estados sulistas e ocupando novas áreas, especialmente, na região Centro-Oeste, Norte (CAMPOS, 2011) e, atualmente, se deslocando aceleradamente para o MATOPIBA<sup>1</sup>. Enquanto a frente pioneira vai avançando na direção norte/nordeste e expandindo a fronteira agrícola onde, após a supressão da vegetação nativa, predominam a pecuária extensiva de corte e alguns cultivos orientados aos mercados locais ou sub-regionais (feijão, arroz, milho e mandioca), as áreas de emigração deixadas para trás sofrem, de modo simplista, dois destinos distintos. Algumas áreas, já exauridas, sofrem desvalorização e são abandonadas ou, como normalmente ocorre, subutilizadas com atividades agropecuárias de baixa produtividade, notadamente, com uma pecuária de baixo rendimento conduzida sobre pastagens degradadas. Outras áreas, ao contrário, por conta da centralização de capitais se valorizam e se consolidam como áreas de agricultura e/ou pecuária comerciais, tecnificadas e de alto desempenho. A inserção competitiva do Brasil no mercado mundial de commodities, a centralização do capital e a transformação dos latifúndios em empresas comerciais, o fortalecimento das cadeias produtivas incluindo a integração agroindustrial, a cadeia comercial de insumos, suprimentos e mecanização, a infraestrutura de armazenamento e escoamento das safras, o acesso à tecnologia e a assessoria técnica, dentre outros, tem sido apontados como os principais fatores indutores desse processo de consolidação da agricultura em várias regiões do país (CAMPOS, 2011). Neste contexto, surgem polos de desenvolvimento agrícola, onde a transformação do espaço rural ocorre, tanto por conta do desenvolvimento urbano de pequenos municípios que oferecem suporte às cadeias produtivas, comércio e serviços, quanto por causa da consolidação agrária em um modelo monopolista de capital com enorme valorização da terra, como também, observa-se a estabilização da paisagem rural (MARTINS, 1997). A estabilização da paisagem rural ocorre em função do aproveitamento quase que total das áreas aptas disponíveis, em termos de solos férteis e topografia adequada, como também pela indução do Código Florestal (Lei 12.651/2012) que exige a averbação de reservas legais (RL) e áreas de proteção permanente (APAs).

---

<sup>1</sup> Delimitação geográfica instituída pelo decreto Decreto presidencial nº 8.447 que criou o Plano de Desenvolvimento Agropecuário do Matopiba. que inclui parte estados do Maranhão, Tocantins, Piauí e Bahia

No processo de consolidação da agricultura e estabilização da paisagem no meio rural, a limitação para integrar novas áreas para a produção, devido ao alto custo da terra e/ou à restrição para a abertura de novas áreas, mesmo que por autorização legal, tem induzido à intensificação dos sistemas produtivos. A consolidação e a intensificação da agricultura, portanto, constituem processos intrinsecamente relacionados, condicionados pela oportunidade e demanda crescente dos mercados, internos e externo e commodities agropecuários.

A expressão “intensificação da agricultura” pode conotar diferentes significados. Contudo, entende-se a princípio como agricultura intensiva os sistemas de produção que perseguem constantemente a maximização da produção e o aumento da produtividade, por meio da aplicação massiva de capital e do uso intensivo de energia, insumos, mecanização e tecnologia. Acresce a estes, o uso extremo de recursos naturais, notadamente, do solo e da água. Neste contexto, pode-se distinguir a intensificação da agricultura em termos técnico-tecnológicos, de capital empregado, de consumo de recursos naturais e energéticos. Entretanto, esses modelos de produção comercial de alto desempenho, que predominam nos grandes países produtores e exportadores de produtos agropecuários, têm apresentado claros sinais de insustentabilidade, em virtude da elevada demanda por energia e consumo de recursos naturais. (BALBINO; BARCELOS; STONE, 2011).

Considerando a crescente demanda mundial por alimentos, bioenergia e produtos florestais e a oportunidade para o incremento das exportações, em contraposição à necessidade de redução do desmatamento, manutenção dos serviços ecossistêmicos, preservação dos recursos naturais e de mitigação das emissões de GEE, a edificação de um modelo de desenvolvimento agrário e agrícola, com sustentabilidade ambiental é fundamental.

Neste cenário, o conceito de “intensificação ecológica” ganha espaço na busca por um agricultura mais sustentável, alicerçada por sistemas de produção que possibilitem maximizar a produção de alimentos com baixos impactos ambientais (GODFRAY et al., 2010; ROYAL SOCIETY OF LONDON, 2009). A base da “intensificação ecológica” da agricultura consiste na aplicação de práticas de manejo que visam aumentar a produção através do incremento dos serviços ecossistêmicos e da preservação dos recursos naturais que se revertem em benefícios para o próprio sistema produtivo, surgindo, portanto, como uma alternativa aos sistemas convencionais de agricultura intensiva de alto custo ambiental(KOVÁCS-HOSTYÁNSZKI et al., 2017; RAMOS, 2017). A intensificação ecológica consiste na otimização da produção agropecuária, não apenas evitando a degradação dos recursos naturais e/ou o comprometimento dos serviços ambientais, mas além disso, valendo-se dos processos ecossistêmicos para

aumentar da produtividade agrícola de modo mais sustentável. Deste modo, diversas práticas agroecológicas, tais como: manejo integrado de pragas, adubação orgânica ou organo-mineral, plantio direto, cobertura verde ou morta do solo, sucessão, rotação e consórcio de culturas, dentre outras, podem ser potencializadas visando à intensificação ecológica dos sistemas de produção agrícola (TITTONELL, 2014).

Há muito que o conhecimento empírico ou científico dos benefícios da agroecologia já está bem estabelecido. Diversos sistemas alternativos de produção, relativamente de baixa escala de produção, como, a agricultura orgânica; os sistemas agroflorestais (SAFs); a agricultura biodinâmica (ASSIS, 2005), dentre vários outros, já contemplam os princípios e se valem dos benefícios agroecológicos. Porém, até meados dos anos 90, não havia nenhum sistema de alto rendimento e larga escala de produção, plenamente consolidado, baseado nos pressupostos agroecológicos.

Entretanto, nas últimas 3 décadas, com a participação de alguns produtores, a pesquisa agropecuária vem aperfeiçoando sistemas integrados de produção que seguem os princípios da intensificação ecológica e, ao mesmo tempo, são apropriados para a produção agropecuária em larga escala. São os sistemas de integração Lavoura-Pecuária-Floresta (iLPF) (serão discutidos no próximo item) que permitem a produção intensiva em todas as suas dimensões - intensificação tecnológica; a intensificação do uso dos recursos naturais (solo e água), intensificação do capital empregado, e, por fim, completando o *nexus* da sustentabilidade a intensificação ecológica. Integração lavoura-pecuária-floresta, como destaca (VILELA; JR; MARCHÃO, 2012), tem sido apontada como alternativa técnica viável que concilia a produção em larga escala com os preceitos conservacionistas e agroecológicos, aumentando o potencial de produção e a produtividade agropecuária em bases mais sustentáveis.

## 1.2 Sistemas Integrados de produção agropecuária

No contexto da intensificação sustentável da agricultura nacional, os Sistemas integrados de produção agropecuária (SIs), atualmente, surgem como advento da evolução tecnológica calcada nos preceitos da intensificação ecológica, maximizando os ganhos econômicos e ambientais. A integração da agricultura com a pecuária e/ou com as atividades silviculturais, em uma mesma área, tem demonstrado ser uma solução viável e eficiente,

melhorando os índices zootécnicos de produção pecuária, maior produtividade agrícola, notadamente de grãos, além da produção madeireira (BALBINO; BARCELOS; STONE, 2011; HERRERO et al., 2010)

Diversos sistemas ancestrais, em diferentes partes do mundo, já contemplavam à lógica, mesmo de modo empírico, da integração agropecuária através da inter-relação das atividades agrícolas e a criação de animais. Assim, colocar os animais para pastejar os restos de culturas agrícolas e manejá-los para adubação orgânica das culturas constituíam e ainda constituem práticas comuns em muitos sistemas tradicionais de produção (BALBINO; BARCELOS; STONE, 2011). Mas recentemente, no entanto, surgiram os Sistemas Agroflorestais (SAFs) e os Sistemas de integração Lavoura-Pecuária-Floresta (iLPF). SAFs são sistemas produtivos que se baseiam na sucessão ecológica de modo analógico aos ecossistemas naturais, nos quais espécies arbóreas, exóticas ou nativas, são consorciadas com culturas agrícolas, perenes ou anuais, de porte herbáceo ou arbustivo, de modo a estabelecer um agroecossistema cujo propósito é conciliar a produção com a proteção ambiental (ALMEIDA, 1995; COMBE; BUDOWSKI, 1979; NAIR, 1993; SIMMONDS, 1984). Em alguns casos, sobretudo nas etapas iniciais da sucessão, podem ser introduzidas forrageiras para a pastagem ou alimentação externa de animais diversos. Os SAFs são planejados visando estabelecer arranjos espaciais e temporais – consórcios e sucessão – visando maximizar a agrobiodiversidade e aproveitar as interações ecológicas benéficas entre as diferentes espécies (ALMEIDA, 1995). Com uma base de pesquisa experimental, os sistemas iLPF, diferentemente dos SAFs, vêm sendo utilizados como sistemas de integração adaptados à produção agropecuária de larga escala. Valendo-se de meios modernos de produção, como mecanização, uso de insumos e material genético melhorado, os sistemas iLPF preconizam a intensificação do uso do solo de modo mais sistemático por meio de cultivos sequenciais, anuais ou plurianuais, pré-estabelecidos. Os iLPFs, em comparação com os SAFs utilizam menor diversidade de culturas, mas exigem operações de campo mais intensas e, neste sentido, se aproximam mais aos sistemas agrícolas convencionais, atingindo altos níveis de produção. Deste modo, a iLPF se torna uma alternativa realista em áreas onde a agricultura comercial de grande escala já está consolidada (GIL; SIEBOLD; BERGER, 2015). O grande diferencial dos sistemas de iLPF, portanto, consiste no seu potencial para a produção integrada de grãos, carne, leite e madeira, em larga escala, permitindo a intensificação do uso do solo de maneira mais sustentável.

Devido o interesse direto do presente trabalho, destaca-se os sistemas iLPF, cujos conceitos e definições seguem em discussão. O Marco Referencial: integração Lavoura-Pecuária-Floresta (iLPF) (BALBINO; BARCELOS; STONE, 2011) estabelece o seguinte conceito geral para os sistemas integrados:

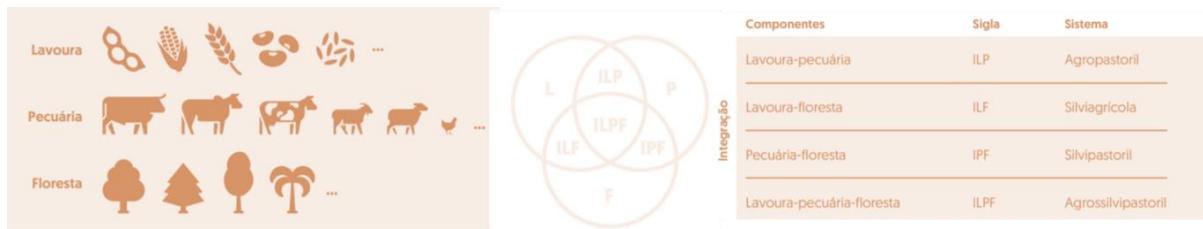
A iLPF é uma estratégia que visa a produção sustentável, que integra atividades agrícolas, pecuárias e florestais, realizadas na mesma área, em cultivo consorciado, em sucessão ou rotacionado, e busca efeitos sinérgicos entre os componentes do agroecossistemas, contemplando a adequação ambiental, a valorização do homem e a viabilidade econômica (BALBINO; BARCELOS; STONE, 2011 p. 27).

Fundamentalmente, os sistemas iLPF se baseiam na diversificação e na integração das atividades agrícolas, pastoris e florestais que são conduzidas na mesma área com diversas combinações e estratégias temporais, podendo ter uma duração e frequência anual ou plurianual. Os sistemas integrados promovem a agrobiodiversidade, o sinergismo dos ciclos biológicos e a complementariedade dos componentes bióticos e abióticos dos agroecossistemas e, desta forma, permitem maior eficiência no uso dos recursos naturais e otimização dos meios de produção, manejo dos resíduos, manejo do solo, o uso de insumos, operações e tratos culturais (BALBINO; BARCELOS; STONE, 2011).

De acordo com BALBINO et al. (2011), do ponto de vista técnico e agronômico, os sistemas iLPF podem ser definidos ou classificados em quatro modalidades ou sistemas distintos: **(i)** Integração Lavoura-Pecuária ou Agropastoril: sistema de produção que integra o componente agrícola e pecuário em rotação, consórcio ou sucessão, na mesma área e em um mesmo ano agrícola ou por múltiplos anos; **(ii)** Integração Pecuária-Floresta ou Silvipastoril: sistema de produção que integra o componente pecuário e florestal, em consórcio; **(iii)** Integração Lavoura-Floresta ou Silviagrícola: Sistema de produção que integra o componente florestal e agrícola, pela consociação de espécies arbóreas com cultivos agrícolas (anuais ou perenes); **(iv)** Integração Lavoura-Pecuária-Floresta ou Agrossilvipastoril: sistema de produção que integra os componentes agrícola, pecuário e florestal em rotação, consórcio ou sucessão, na mesma área. Neste caso, o componente "lavoura" pode ser utilizado apenas na fase inicial, consórcio/sucessão com forrageiras para formação de pastagem (fase agropastoril), para depois se introduzir o componente florestal, podendo, migrar para um sistema restritamente silvipastoril ou continuar a sucessão de atividades agrícolas e pecuárias nas entrelinhas do plantio de espécies florestais e/ou silviculturais permanecendo como um sistema iLPF completo.

Por sua vez, a Política Nacional de Integração Sistemas Lavoura-Pecuária-Floresta, estabelecido pela Lei Federal n. 12805/2013, define os sistemas integrados como: **(i)** iLP - sistemas lavoura-pecuária: É a produção integrada de grãos e gramíneas para pastejo de animais; **(ii)** IPF - sistemas pecuária-floresta: É a produção integrada de gramíneas para pastejo de animais com silvicultura; **(iii)** ILF - sistemas lavoura-floresta: É a produção integrada de grãos e silvicultura; **(iv)** ILPF - sistemas lavoura-pecuária-floresta: É a produção integrada de grãos e gramíneas para pastejo de animais e silvicultura. A **Figura 2** apresenta as diferentes modalidades de iLPF que vem sendo praticadas no Brasil.

Figura 2 - Diferentes componentes e arranjos de integração, iLP, ILF, IPF e ILPF.

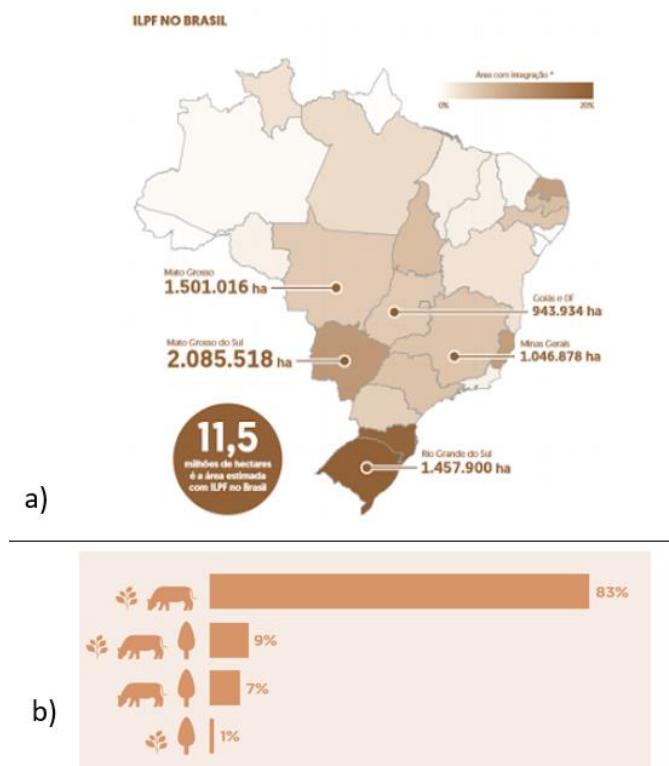


Fonte: adaptado de EMBRAPA, (2017)

Os diversos arranjos produtivos de integração, iLP, iLF, iPF e iLPF refletem as diferentes combinações possíveis entre os componentes: agricultura, pecuária e silvicultura e dizem respeito a estratégias de produção integrada que podem incorporar diversas tecnologias, práticas de manejo e sistemas de produção. O componente agricultura, por exemplo, pode incorporar culturais anuais, semiperenes ou perenes. No caso da produção de grãos anuais, normalmente se preconiza a adoção do Sistema de Plantio Direto (SPD) que consiste na semeadura direta sobre a palhada anterior sem que haja revolvimento dos solos, dispensando assim as operações de aração e gradeamento. A componente pecuária em maioria se refere à criação de bovinos para corte ou produção leiteira, mas pode contemplar a criação de outros animais de médio e grande porte, respectivamente, como: ovinos, caprinos, equinos, bubalinos. O componente florestal, dependendo do objetivo, pode fazer uso de diversas espécies arbóreas como: eucalipto, teca, mogno africano, gliricidia, cedro doce, dentre diversas outras; visando a produção de madeira, celulose, estacas e moirões, lenha, carvão, a extração de óleos essenciais ou ainda se destina para a produção de forragem ou para o bem-estar animal com formação de sombreamento na fase de pecuária.

Dentre as modalidades de iLPF, de acordo com pesquisa realizada pela Kleffmann Group, para a safra 2015/2016, a integração lavoura-pecuária (iLP) tem sido a modalidade mais adotada até o momento no Brasil. Estimou-se que 83% da área de iLPF consistia, a época, em sistemas iLP, contra 9%, 7% e 1% para os sistemas iLPF, iPF e iLF, respectivamente, para um total de 11.468.124 ha ocupados com todos os sistemas integrados de produção agropecuária. Dentre os estados com maior taxa de implantação de sistemas integrados, considerando qualquer modalidade, destacou-se o estado do Mato Grosso do Sul, com aproximadamente 2 milhões de hectares, seguido do Mato Grosso com um milhão e meio de hectares. Valor este próximo ao apresentado pelo estado do Rio Grande do Sul, figurando em seguida os estados de Minas Gerais e Goiás que apresentavam na ocasião 1.046.878 e 943.934 hectares, respectivamente (EMBRAPA, 2017). As **Erro! Fonte de referência não encontrada.**(a) e (b) a presentam, o mapa do Brasil e uma figura com a distribuição absoluta e percentual dos sistemas iLPF para todos os estados da federação.

Figura 3 - (a) Proporção entre as modalidades de SI (ILP, ILF, IPF e ILPF); (b) mapa com as áreas em ha de ILPF dos principais estados da federação, para a safra 2015/2016.

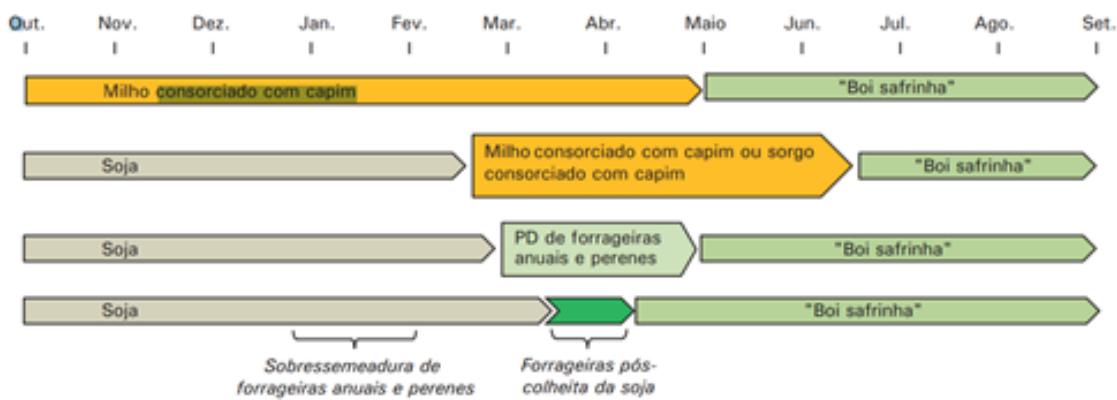


Fonte: adaptado de EMBRAPA (2017)

Como apontam os dados da pesquisa realizada pela Kleffmann Group, a região Centro-Oeste possui a maior área de sistemas de integração lavoura-pecuária (iLP) do país. Segundo Vilela; Jr; Marchão (2012) as principais estratégias de utilização de sistemas de integração iLP, atualmente praticadas pelos produtores na região Centro-Oeste (Cerrados) são as seguintes: (i) Propriedades dedicadas à pecuária em que a introdução das culturas anuais de verão, grãos como arroz, milho, sorgo ou soja, em áreas de pastagens tem por objetivo precípuo a recuperação da produtividade das pastagens a custos mais reduzidos devido à amortização das despesas por meio da renda obtida com a produção de grãos; (ii) Propriedades especializadas em lavouras de grãos que adotam as gramíneas forrageiras para melhorar a cobertura de solo (formação de palhada) para o sistema de plantio direto e, na entressafra, podem aproveitar a forragem produzida para engorda de bovinos (“boi safrinha”); e (iii) Propriedades que adotam sistematicamente a sucessão/rotação lavoura-pasto para intensificar o uso solo, diversificar e potencializar a produção e se beneficiar do sinergismo entre as distintas atividades.

Na estratégia adotada pelos pecuaristas, na qual o objetivo se concentra na recuperação da produtividade das pastagens, as culturas agrícolas são introduzidas em um único ano-safra se estabelecendo, em seguida, a pastagem em consórcio/sucessão. A pastagem formada é, então, utilizada para o pastoreio durante vários anos, até que haja a necessidade reincidente de nova recuperação. Em alguns casos, sobretudo, quando se tem parceria/arrendamento entre pecuaristas e agricultores, a área pode ser utilizada por mais de um ano, por dois ou três, antes de se perenizar a pastagem, integrando-se assim à atividade pecuária. Em qualquer caso, observa-se que na estratégia de recuperação de pastagens, a rotação lavoura-pecuária ocorre em frequência plurianual. No caso do “boi safrinha” a estratégia dos agricultores consiste em se aproveitar o excesso da biomassa forrageira produzida em consórcio ou sucessão para a engorda de bovinos antes de ser dessecada para em seguida se semear, em plantio direto, a nova safra de verão. Como destaca Vilela; Marchão; Guimarães Jr, (2017), o sistema “Boi safrinha” objetiva, além da produção de palhada para o plantio da safra seguinte, aproveitar parte da forragem produzida em consórcio com milho ou em sobressemeadura em soja para a alimentação de bovinos (cria, recria e, preferencialmente, engorda) na entressafra. Consiste em uma estratégia de integração intranual, ou seja, a cada ano-safra a sequência em consórcio/sucessão se repete. A **Erro! Fonte de referência não encontrada.** apresenta um diagrama representando as diferentes estratégias de implementação dos sistemas integrados lavoura-pecuária, modalidade “boi safrinha” que tem sido adotada pelos produtores do Cerrado Brasileiro.

Figura 4 - Diferentes estratégias de implementação dos sistemas integrados lavoura-pecuária na modalidade “Boi safrinha” praticados no Cerrado.



Fonte: Vilela et al. (2017).

A terceira estratégia de iLP, adotada, principalmente, por produtores de perfil empresarial, objetiva maximizar tanto a produção agrícola quanto a pecuária a partir da implantação de sistemas de sucessão interanual ou rotação plurianual. O foco neste tipo de estratégia é a intensificação do uso da terra através da diversificação da produção sem que haja, necessariamente, uma atividade prioritária.

Independentemente da estratégia de iLP adotada pelo produtor em função das suas prioridades e objetivos, a implantação de espécies forrageiras/pastagem em sucessão às culturas anuais de verão, que caracteriza estes sistemas, sempre ocorrerá no mesmo ano-safra.

Com base no conceito apresentado pela Embrapa (2011), nota-se que, para que um sistema iLPF seja considerado efetivamente sustentável deve ser tecnicamente eficiente, economicamente viável, socialmente aceitável e ambientalmente adequado. A eficiência técnica diz respeito ao manejo adequado e à utilização de técnicas recomendadas e baseadas na pesquisa agropecuária. A utilização eficiente dos recursos financeiros, assim como, o uso adequado dos recursos naturais, a diversificação produtiva, a minimização de riscos e a maior rentabilidade garantem a viabilidade econômica. Por socialmente aceitável, pressupõe-se que a tecnologia deva ser aplicável para todos os produtores, independentemente, do nível de infraestrutura e capital e que possa gerar empregos e garantir maior equidade e distribuição da renda no campo. Como ambientalmente adequado, a aplicação da tecnologia deve contemplar o uso judicioso dos recursos naturais, a provisão de serviços ecossistêmicos, a aptidão agrícola dos solos, as boas práticas de manejo e os preceitos conservacionistas. O conjunto dessas dimensões concorrem para aumentar a sustentabilidade e a competitividade do agronegócio brasileiro.

Segundo Balbino; Barcelos; Stone, (2011), os benefícios que a adoção dos sistemas iLPF conferem podem ser subdivididos em benefícios ambientais ou ecológicos, tecnológicos, econômicos e sociais. Como benefícios ambientais ou ecológicos, figuram como os principais: a utilização mais adequada dos recursos naturais; o aumento da recarga e da qualidade da água; a redução dos riscos de erosão; o aumento de matéria orgânica dos solos e a reciclagem de nutrientes; a diminuição da demanda por abertura de novas áreas produtivas e a redução da pressão sobre os remanescentes florestais; a otimização do uso de agroquímicos para controle de pragas, doenças e plantas daninhas; e, notadamente, a maior capacidade de sequestro de carbono, a redução das emissões e mitigação do efeito estufa.

Dentre os benefícios tecnológicos, destacam-se: a melhoria da fertilidade e dos atributos físicos, químicos e biológicos do solo devido ao aumento da matéria orgânica; a maior resistência a *déficits* hídricos e redução das perdas por ocorrência de veranicos; a minimização da ocorrência de problemas fitossanitários e plantas daninhas; o aumento da produtividade zootécnica em decorrência do maior conforto térmico para os animais; a maior eficiência na utilização de insumos; e, a flexibilidade da tecnologia, aplicável a diferentes unidades de produção independentemente ao tamanho das propriedades rurais.

Dentre os benefícios econômicos conferidos aos produtores, destaca-se a maior rentabilidade e a redução de riscos em função da diversificação produtiva e aumento da produtividade. Além dos ganhos econômicos em função do aumento de produtividade, diversificação e rentabilidade, a economia de insumos e a manutenção da fertilidade do solo também constituem importantes atrativos econômicos para os produtores (REIS et al., 2019). Acresce a esses ganhos a conservação dos recursos naturais e a provisão de serviços ambientais (LEMAIRE et al., 2014; SALTON et al., 2014). Do ponto de vista financeiro os produtores ainda podem se beneficiar tendo acesso às linhas de crédito do Programa ABC, lançado pelo Banco do Brasil em apoio ao Plano Setorial de Agricultura de Baixa Emissão de Carbono (Plano ABC).

Quanto aos benefícios agronômicos, especificamente, dos sistemas iLP, Lemaire et al., (2014); Salton et al., (2014) indicam que a sucessão de culturas agrícolas (leguminosas: soja, e/ou gramíneas: milho, milheto ou sorgo) com as pastagens (gramíneas dos gêneros *brachiaria*, *panicum*, dentre outros), promovem a translocação e a ciclagem dos nutrientes devido os diferentes sistemas radiculares que exploram o solo em diferentes profundidades, minimizando a competição e otimizando o uso da água e dos nutrientes minerais. As espécies forrageiras introduzidas, além da formação de pastagem para alimentação animal, têm também o

importante papel de produzir palhada para a cobertura protetora do solo, possibilitando o plantio direto das culturas anuais da safra em sequência. A cobertura de biomassa seca, além de conferir maior proteção contra à erosão, propicia a manutenção da umidade, a regulação da temperatura, o acúmulo da matéria orgânica, a ciclagem de nutrientes e o estoque de carbono do solo. As culturas agrícolas de produção de grãos, por sua vez, contribuem com a melhoria da fertilidade do solo devido ao efeito residual das adubações ou, se for uma leguminosa como a soja, devido também à fixação biológica do nitrogênio. Desta forma, as culturas agrícolas anteriores fornecem nutrientes para o cultivo posterior de gramíneas, como o milho “safrinha” ou a própria pastagem, gerando, neste caso, pastos de alta qualidade nutricional e com grande capacidade de suporte, permitindo assim o acabamento mais rápida do rebanho sob pastejo. Além disso, o menor tempo de engorda e permanência do gado no pasto contribui para diminuir as emissões de GEE por fermentação entérica. A adoção da ILP apresenta ainda grande potencial para a recuperação de pastagens degradadas, com ganhos significativos para a conservação dos recursos naturais e provisão de serviços ambientais (LEMAIRE et al., 2014; SALTON et al., 2014).

Referente à produção nacional de commodities agrícolas, como os sistemas iLPF possibilitam que o solo seja explorado economicamente durante o ano todo, a adoção desses sistemas produtivos pode potencializar a produção e a oferta de grãos, carne e leite, a custos mais baixos. Os benefícios são, portanto, o aumento da oferta de alimentos, fibras, e biocombustíveis; a redução da sazonalidade de produção e o aumento da competitividade das cadeias produtivas, tanto aquelas orientadas para a produção de commodities para o mercado internacional quanto aquelas destinadas ao abastecimento do mercado interno (BALBINO; BARCELOS; STONE, 2011). Dinamizando assim a economia e beneficiando toda a cadeia produtiva.

Além dos benefícios diretos para os produtores rurais, a adoção dos sistemas integrados (iLPF), no contexto da intensificação sustentável, gera a melhoria da imagem do setor da agropecuária nacional, propiciando maior competitividade às cadeias de produção devido à consonância com as exigências não-tarifárias e com as agendas ambientais internacionais. Aumentando, desta forma, o poder de negociação do país no âmbito das discussões da Organização Mundial do Comércio (OMC). A fim de subsidiar o planejamento da expansão dos sistemas integrados de produção (PEREIRA; MANZATTO; SKORUPA, 2018) mapearam o território brasileiro em classes de prioridade para ações de transferência de tecnologia para a estratégia de produção agropecuária Integração Lavoura-Pecuária-Floresta (ILPF).

Sendo assim, os benefícios dos sistemas integrados de produção agropecuária, particularmente da iLPF, colocam estes sistemas no centro da discussão sobre a sustentabilidade da agricultura nacional, uma vez que, possuem real potencial para contribuir com as metas do setor agrícola para a redução dos Gases de Efeito Estufa (GEE).

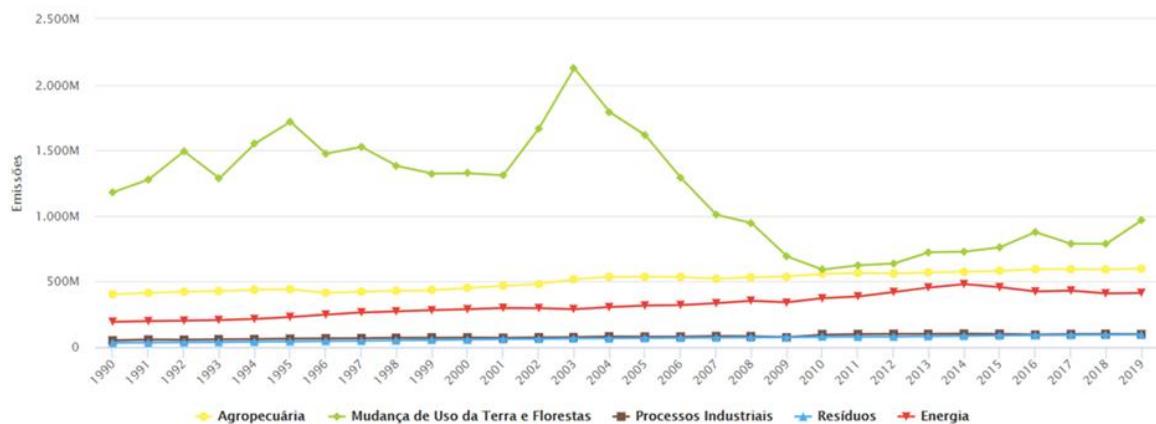
### 1.3 Agricultura de baixa emissão de carbono

Durante a 17<sup>a</sup> Conferência das Partes (COP-17) a Convenção-Quadro das Nações Unidas sobre Mudanças Climáticas (UNFCCC, sigla em inglês) anunciou que cerca de 50% das emissões dos GEE mundiais foram provenientes de apenas 5 países, ocupando o Brasil o sexto lugar no ranking, posição que se mantém até o ano de 2019 (ALBUQUERQUE; ALENCAR; ANGELO, 2020).

Analisando a série histórica das emissões de GEE brasileiras atribuídas à “mudança do uso da terra e florestas”, entre 1990 e 2019 **Erro! Fonte de referência não encontrada.**, é possível identificar que em 2003 houve um pico de emissões, para em seguida se observar uma tendência acentuada de queda até o ano de 2010, que registrou o menor valor de toda a série de emissões. Período este, em que o Brasil foi reconhecido internacionalmente pela efetividade de suas ações políticas para frear o desmatamento, figurando, em relatório produzido pela organização *Union of Concerned Scientists*, como exemplo a ser seguido (BOUCHER; ELIAS; FAIRES, 2014).

O Brasil, durante a Convenção da ONU sobre o Clima, ocorrida em dezembro de 2009, e, ratificada no acordo de Paris em 2015, assumiu junto à comunidade internacional um compromisso voluntário de redução das emissões de GEE na ordem de 36,1% a 38,9%, definindo metas de redução para cada setor da economia brasileira. Cumprindo o compromisso assumido, o país no mesmo ano sancionou a Política Nacional de Mudança do Clima e o Fundo Nacional de Mudança do Clima (Fundo Clima) para ações de adaptação e mitigação (ROMEIRO, 2016).

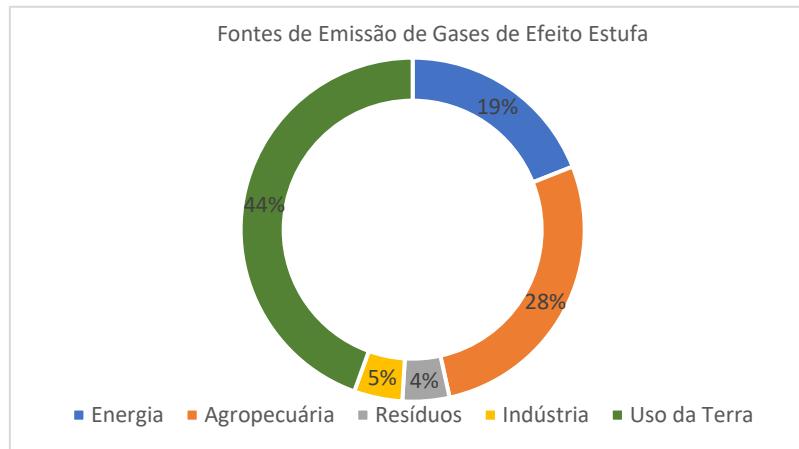
Figura 5 - Evolução das emissões de GEE por fonte emissora em toneladas de carbono equivalente.



Fonte: adaptado (ALBUQUERQUE; ALENCAR; ANGELO, 2020)

Diferente dos países industrializados e dos que apresentam uma matriz energética baseada em combustíveis fósseis, no Brasil, as principais fontes de emissões são provenientes da mudança do uso da terra e da agropecuária, representando uma fatia de 72% do total de emissões de GEE para o ano de 2019 (**Figura 6**).

Figura 6 - Proporção das emissões de GEE por fonte emissora



Fonte: adaptado (ALBUQUERQUE; ALENCAR; ANGELO, 2020)

As emissões de GEE no setor da agropecuária estão relacionadas à fermentação entérica proveniente dos animais ruminantes, ao manejo de dejetos dos animais, ao cultivo de arroz em áreas alagadas, à queima de resíduos e ao manejo do solo através de aração e utilização de fertilizantes químicos. Segundo o relatório anual do Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa (SEEG), para o ano de 2019, o estado do Mato Grosso

vem figurando, nos últimos 10 anos, como o maior emissor no setor agropecuário, com 73% das emissões provenientes da atividade pecuária de corte, 6% proveniente do uso de fertilizantes, 6% do cultivo da soja e 15% referente às demais fontes. Goiás e Minas Gerais aparecem em seguida, apresentando, ambos os estados, taxas de mais de 50% das emissões proveniente da pecuária (ALBUQUERQUE; ALENCAR; ANGELO, 2020).

Quando consideramos as emissões não contabilizadas nos inventários nacionais, o cenário das emissões de GEE do setor da agropecuária pode ser consideravelmente agravado. Neste contexto, destaca-se, a agricultura convencional e as pastagens degradadas como fontes potenciais de GEE. Devido à não utilização de cobertura morta na agricultura convencional, o solo permanece exposto e aerado por considerável período o que induz à oxidação da matéria orgânica e, consequentemente, a evolução de GEE. Nas pastagens degradadas, situação semelhante ocorre, contudo, o solo exposto, compactado e sem cobertura vegetal, é devido ao próprio processo de degradação que condiciona a baixa produção de biomassa e a perda de matéria orgânica dos solos, aumentando as emissões de GEE. Estas fontes de emissão, apesar de significativas, são de difícil estimativa, e, por isso, o IPCC *Intergovernmental Panel on Climate Change* (IPCC), sugere considerar suas estimativas como caráter facultativo. Outro ponto a ponderar, indiretamente relacionado ao setor, é referente às emissões provenientes dos desmatamentos, causados pela expansão das atividades agropecuárias nas fronteiras agrícolas (ALBUQUERQUE; ALENCAR; ANGELO, 2020).

Se por um lado, o setor da agropecuária figura como um dos principais emissores de GEE no Brasil, por outro, possui potencial para contrabalançar as emissões a partir da adoção de sistemas de produção adequados que propiciem maior sequestro de carbono orgânico, contribuindo de forma efetiva para o atingimento das metas brasileiras firmadas nos acordos internacionais (ALBUQUERQUE; ALENCAR; ANGELO, 2020).

Neste sentido, dentro dos compromissos brasileiros para o setor agrícola, foi criado o Plano Setorial de Mitigação e de Adaptação às Mudanças Climáticas Visando à Consolidação de uma Economia de Baixa Emissão de Carbono na Agricultura (Plano ABC) - instituído pelo decreto Nº 7.390, 9 de dezembro de 2010, que tem como objetivo garantir e incentivar a adoção de tecnologias e práticas de manejo das culturas e do solo que possam reduzir a emissão dos GEE.

A Política Nacional sobre Mudanças do Clima (BRASIL, 2009) vem atender aos compromissos internacionais assumidos pelo Governo Brasileiro em relação à redução multisetorial de emissões e mitigação de gases de efeito estufa. Neste contexto, no que tange

ao setor da Agricultura, cabe destacar o “Plano para a Consolidação de uma Economia de Baixa Emissão de Carbono na Agricultura”, também denominado Plano ABC (BRASIL, 2012). O Plano ABC constitui uma política de estado explícita para a redução das emissões de carbono orientada ao setor da agricultura que tanto por seu alcance, metas estabelecidas, como em investimentos públicos não encontra paralelo no mundo. O Programa ABC que constitui uma linha de crédito específica aberta pelo Banco do Brasil para financiar as atividades preconizadas pelo Plano ABC, destinou aos agricultores R\$ 4,1 bilhões em financiamento de projetos (BANCO DO BRASIL, 2013). Existem 7 programas com tecnologias/iniciativas preconizadas no plano:

- Programa 1: Recuperação de Pastagens Degradadas;
- Programa 2: Sistemas Integrados (iLPF) e Sistemas Agroflorestais (SAFs);
- Programa 3: Sistema Plantio Direto (SPD);
- Programa 4: Fixação Biológica de Nitrogênio (FBN);
- Programa 5: Florestas Plantadas;
- Programa 6: Tratamento de Dejetos Animais;
- Programa 7: Adaptação às Mudanças Climáticas.

Entre as tecnologias incentivadas pelo Plano ABC, destacam-se os sistemas de integração Lavoura-Pecuária-Floresta (ILPF) cuja meta de expansão no país é de 4 milhões de hectares até 2020. A ratificação do Acordo de Paris sobre Mudança do Clima pelo Governo Brasileiro, em 2016, fortaleceu as ações do referido Plano, incluindo em sua “Contribuição Nacionalmente Determinada - INDC” (*Nationally Determined Contribution – NDC*) o incremento de mais 5 milhões de hectares até 2030 (BRASIL, 2015).

Um ponto a se destacar relacionado à governança do Plano ABC se refere ao desafio de se criar metodologias e ferramentas para acompanhar e monitorar a implementação, evolução e alcance das ações propostas pelo referido plano e, desta forma, comprovar o cumprimento dos compromissos firmados pelo país nos fóruns internacionais (MAPA, 2011).

## 1.4 Monitoramento de uso e cobertura da terra por sensoriamento remoto

Tendo por base correntes atuais da geografia, pode-se dizer de forma simplificada que o espaço geográfico é produzido e reproduzido pelas relações sociais que, por meio do trabalho, modificam e transformam o meio físico (LEFEBVRE, 1974). Os estudos dos diversos fenômenos sociais e físico-bióticos que se materializam no espaço geográfico são fundamentais para a compreensão do desenvolvimento das sociedades humanas. Neste sentido, cada vez mais a área de conhecimento relacionada à observação da superfície terrestre se torna indispensável. Através do registro de informações sobre a cobertura da terra se torna possível cartografar os arranjos espaciais resultantes da integração de processos complexos e de longo prazo (CORRÊA, 2019). A qualificação e o entendimento destes processos em sua complexidade compõem o conceito de paisagem. A paisagem, de modo simplista, pode ser entendida como a configuração da superfície da terra resultante do uso do solo e outros aspectos naturais. O uso da terra, assim, se coloca no cerne da relação sociedade *vs.* natureza (DEFRIES; ROSENZWEIG, 2010). Diferente da ideia de cobertura, o uso da terra, está ligado a forma em que a sociedade explora sua superfície (LAMBIN; GEIST, 2006) para a realização de suas necessidades socioeconômicas, expondo a relação mais intrínseca entre sociedade *vs.* natureza (VERBURG et al., 2009). Em linhas gerais, as informações de uso qualificam e aprofundam as informações provenientes da cobertura da terra, que está mais ligado ao observável, ao descriptivo, aos padrões detectáveis da vegetação, dos solos ou das estruturas civis e urbanas (BURLEY, 1961).

Neste sentido, os dados de sensoriamento remoto não registram a atividade humana em si, contida nas relações sociais, mas um conjunto de informações sobre as características observáveis dos fenômenos da superfície terrestre. Historicamente, estas características foram sendo interpretadas e padronizadas pelos fotointérpretes, que utilizam padrões, tons ou texturas para representá-las cartograficamente na elaboração dos mapas de cobertura da terra (ANDERSON et al., 1976). Com o advento do Sensoriamento Remoto, um conjunto enorme de dados e informações sobre a cobertura da terra se torna acessível, possibilitando a evolução do mapeamento tradicional de cobertura da terra a partir da interpretação e ressignificação, com base em diversas disciplinas das ciências da terra, de cada conjunto mapeado para a elaboração dos mapas de uso. Esta ideia é defendida por Verburg et al., (2009) que propuseram a geração cartográfica de sistemas de uso da terra a partir de mapas da cobertura terrestre, por meio de

interpretações inferidas a partir de estruturas paisagísticas. Desta forma, a partir dos dados de cobertura da terra pode-se identificar e classificar diferentes tipologias de cobertura como, fitofisionomias naturais, solo exposto, dosséis de culturas agrícolas etc. Contudo, em muitos casos, para qualificar o tipo de uso de uma dada área se faz necessário um novo conjunto de informações que permitam fazer inferências sobre a sua destinação utilitária. Numa dada área florestada, por exemplo, pode-se classificar a cobertura da terra com um dado tipo fitofisionômico, mas, a mesma, pode estar sendo destinada como reserva extrativista, reserva indígena ou qualquer outro tipo de unidade de conservação. Uma área de solo exposto, por sua vez, pode evidenciar um padrão de degradação erosiva ou uma cava de mineração ou ainda uma área terraplanada para implantação de obras civis. Um campo com uma cobertura herbáeo-graminoide pode significar uma fitofisionomia natural ou uma pastagem natural ou cultivada. Neste último exemplo, a cobertura observada remotamente é um campo herbáceo que, caso esteja sendo usado como pasto, condiciona a classe de uso como “pastagem”, evidenciando a ocorrência de atividade pecuária. Para as atividades agrícolas, obviamente, a detecção de um dossel de soja ou de milho ou de qualquer outra cultura agrícola, evidencia de forma direta e inequívoca o uso agrícola da terra.

Por outro lado, muitos autores, de modo mais pragmático, utilizam o termo “cobertura da terra”, exclusivamente, para designar as categorias essencialmente naturais, reservando a expressão “uso da terra” para caracterizar os padrões de transformação antrópica da superfície terrestre, relacionados com atividades econômicas e/ou sociais, como: mineração, agricultura, pecuária, reservatórios hídricos, urbanização, dentre outras.

Trata-se, na verdade, de uma discussão conceitual. De fato, estes dois conceitos - uso e cobertura da terra - são distintos, mas com forte e de indissociável relação entre eles (FISHER; COMBER; WADSWORTH, 2005; LOVELAND; DEFRIES, 2004). Por este motivo, a utilização de legendas mistas, contendo “uso e cobertura da terra” na mesma carta temática (Em inglês: *Land Use and Land Cover- LULC*) tornou-se prática corrente (ANDERSON et al., 1976).

Uma referência clássica, internacional, na área de mapeamento de uso e cobertura da terra foi desenvolvido, em 1971, por uma Comissão Mista para Informação e Classificação do Uso da Terra, composta por Órgãos Federais dos Estados Unidos, como: Administração Nacional de Aeronáutica e Espaço (NASA, sigla em inglês), o Departamento de Agricultura dos EUA, a Associação de Geógrafos Americanos e a União Geográfica Internacional (UGI) (IBGE, 2013).

Mais recentemente, Hansen et al. (2013), usando séries de dados Landsat de resolução espacial de 30 metros, entre os anos de 2000 a 2012, produziram mapas globais da mudança da cobertura florestal.

No Brasil, a primeira iniciativa estruturada para o mapeamento da cobertura e uso da terra ocorreu na década de 70, no âmbito do projeto Radam. Primeiramente, com foco na Região Amazônica (Projeto Radar da Amazônia) o Projeto Radam, a partir de 1975, em sintonia com as políticas públicas da época, foi estendido para todo o território nacional, passando a se chamar Radam Brasil (CPRM, 2007). O projeto Radam Brasil valeu-se de imagens de radar, provenientes de aerolevantamento entre o período 1970 e 1985, para gerar diversas cartas temáticas relacionados à diferentes disciplinas e ciências naturais, incluindo a cartografia das fitofisionomias naturais e o uso da terra.

O Instituto Brasileiro de Geografia Estatística (IBGE), como órgão oficial do estado Brasileiro, disponibiliza, a cada dois anos, os resultados do Monitoramento da Cobertura e Uso da Terra do Brasil, realizado a partir da interpretação das imagens orbitais OLI/Landsat-8 e de informações complementares obtidas em levantamentos de campo em todo o país. Segundo revisão realizada por De Faria et al., (2019), para realizar esses mapeamentos, o IBGE compatibilizou as classes de uso da terra e vegetação remanescente com o Sistema de Classificação da Cobertura e Uso da Terra (SCUT) , considerando ainda a compatibilização com a Classificação Nacional de Atividades Econômicas (CNAE) (MILTON DA COSTA ARAÚJO FILHO; PAULO ROBERTO MENESES; EDSON EYJI SANO, 2007). Os dados são revisados e divulgados na base Cartográfica Contínua do IBGE (BC250) e o mapa de vegetação do IBGE, que estão disponíveis para os seguintes anos: 2000, 2010, 2012, 2014, 2016 e 2018 IBGE (2020). As informações a respeito da espacialização e quantificação da cobertura e uso da terra, para todo o território brasileiro, permite a realização e análises da dinâmica do território em termos dos processos de ocupação e transições de uso da terra.

Merece menção também, o Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira (PROBIO), iniciativa pioneira que utilizou imagens orbitais, em larga escala, para realizar o levantamento detalhado dos remanescentes de cobertura vegetal para todos os seis biomas brasileiros (MMA, 2004).

Por sua vez, o PRODES (Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite) do Instituto Nacional de Pesquisas Espaciais (INPE) monitora, anualmente, a evolução do desmatamento por meio da detecção de áreas de cortes rasos, ou seja, supressão total da cobertura florestal (PRODES, 2014). Os dados produzidos por este

programa oficial do estado brasileiro são realizados desde 1988, fornecendo as taxas anuais de desmatamento, que servem de base para o estabelecimento de diferentes políticas públicas de ordenamento territorial ou de gestão ambiental. Por exemplo, as informações do PRODES são utilizadas para a certificação das cadeias produtivas do agronegócio, subsidiando iniciativas como a Moratória da Soja, que consiste em um compromisso estabelecido pelo acordo entre governo, organizações não-governamentais e agroindústria de não comprar a commodity de áreas desmatadas, ou como o Termo de Ajustamento de Conduta da pecuária (TAC da carne) que consiste em um compromisso público da pecuária para a rastreabilidade da carne e redução dos desmatamentos na Amazônia. As informações do PRODES são utilizadas ainda para a elaboração dos inventários nacionais de Gases de Estufa - GEE (PRODES, 2014).

Em complementação ao PRODES, o INPE conta ainda com outros programas relacionados à cobertura e uso da terra, como o DETER que consiste em um sistema de alertas de desmatamento e degradação florestal na Amazônia Legal, baseado em dados do sensor de alta frequência de revisita (resolução temporal) como o MODIS e AWIFS (DINIZ et al., 2015). O DETER visa fornecer suporte aos órgãos de combate ao desmatamento ilegal, como por exemplo, as atividades de fiscalização do Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA).

A caracterização do tipo de uso subsequente dado as áreas desmatadas, detectadas e mapeadas pelo PRODES, torna-se de extrema importância para subsidiar à gestão ambiental e/ou territorial por parte dos órgãos governamentais competentes. Atendendo a esta demanda, o Instituto Nacional de Pesquisas Espaciais (INPE), juntamente com a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), lançou em 2010 o Projeto TerraClass (ALMEIDA et al., 2016), com o objetivo de qualificar as áreas desmatadas da Amazônia Legal. O TerraClass Amazônia realizou mapeamentos bianuais do uso da terra entre os anos de 2004 a 2014. Em 2013, com metodologia derivada do projeto TerraClass Amazônia, foi lançado o projeto de Mapeamento do Uso e Cobertura Vegetal do Cerrado (TerraClass Cerrado). Iniciativa esta que contou com a participação do IBAMA, INPE, Embrapa, além das Universidades Federal do Goiás (UFG) e Federal de Uberlândia (UFU). Ambas os projetos, TerraClass Amazônia e TerraClass Cerrado, utilizaram imagens Landsat e CBERS e os produtos gerados apresentam potencial para subsidiar as ações referentes ao desenvolvimento sustentável da produção agrícola, bem como, a preservação da biodiversidade e a manutenção dos serviços ambientais (ALMEIDA et al., 2016).

Orientada ao setor sucroalcooleiro, outra iniciativa que merece destaque é o projeto Canasat do INPE que utiliza imagens obtidas pelo Landsat, CBERS e Resoursat-I, para realizar o mapeamento anual da cultura da cana-de-açúcar nos estados do eixo centro-sul do Brasil. O projeto Canasat foi motivado pela iniciativa do protocolo Etanol Verde que estabelece, por meio de uma lei estadual do estado de São Paulo, a extinção da queima da palha como método de pré-colheita (AGUIAR et al., 2011).

Fora do âmbito governamental, existem atualmente iniciativas de extrema relevância por sua pertinência temática, abrangência e atualização, como é o caso dos mapas anuais de áreas de pastagens do Brasil, produzidos pelo Laboratório de Processamento de Imagens e Geoprocessamento (Lapig/UFG), elaborados a partir de séries históricas de 30 anos de Imagens LANDSAT-8 (PARENTE et al., 2017, 2019).

Ainda na esfera da iniciativa da sociedade científica organizada, por meio de uma rede colaborativa de especialistas de diversas instituições cumpre destacar o Projeto de Mapeamento Anual da Cobertura e Uso do Solo do Brasil (Mapbiomas). A partir do uso de séries temporais de imagens Landsat, classificadas a partir de algoritmos de aprendizado de máquina e computação nas nuvens que possibilita o processamento de um grande volume de dados, o Mapbiomas realiza o mapeamento anual do uso e cobertura da terra para todo território nacional. A cada ano, é disponibilizada uma nova coleção atualizada. A última coleção do Mapbiomas, lançada em 2020, conta com um histórico de cobertura e uso da terra para todo o país de 1984 a 2019 (SOUZA et al., 2020).

As legendas utilizadas nos projetos PRODES, TerraClass e Mapbiomas, podem ser observadas no Anexo.

#### 1.4.1 Monitoramento do uso agrícola em larga escala

##### 1.4.1.1 Principais iniciativas e Programas Internacionais

O grupo dos 20 países mais desenvolvidos do mundo (G20) lançou, em junho de 2011, o “*Geo Global Agricultural Monitoring*” (GEOGLAM) e o *Agricultural Market Information System* (AMIS), que constituem sistemas de informações estratégicas, visando contribuir com a estabilização dos mercados e a ampliação da transparência nas estimativas da produção agrícola mundial.

Sendo assim, a comunidade *Group on Earth Observation* (GEO) foi convidada a participar da formulação e proposição do GEOGLAM com o objetivo de melhorar as previsões mundiais de produção agrícola que são dados de entrada para a iniciativa AMIS. O GEO, lançado em 2002, na África do Sul, constitui uma rede global composta por instituições governamentais, acadêmicas e de pesquisa, provedores de dados, empresas e especialistas, que alicerçada na parceria voluntária, desenvolve e oferece soluções inovadoras para fazer frente aos desafios globais, relacionados à sustentabilidade e ao desenvolvimento humano em tempos de mudanças climáticas que transcendem fronteiras e disciplinas. Deste modo, esta parceria objetiva identificar lacunas e reduzir a duplicação de esforços na produção de informações estratégicas, obtidas por sensoriamento remoto, apoiando governos e organizações internacionais na formulação de diretrizes de gestão para a edificação de modelos sustentáveis de desenvolvimento.

Visando cumprir os objetivos propostos, a comunidade GEO criou o *Global Earth Observation System of Systems* (GEOSS), visando a integração e o compartilhamento de dados através da conexão das infraestruturas existentes e do estabelecimento de padrões. Deste modo, o GEOSS constitui um conjunto de sistemas coordenados e independentes de observação, informação e processamento de dados sobre a Terra que interagem e fornecem acesso a informações diversas para uma ampla gama de usuários dos setores público e privado.

Existem diversas iniciativas do GEOGLAM para o monitoramento da agricultura em escalas globais, regionais e a nível nacional. Cabe destacar, o *Crop Monitor for AMIS*, que constitui um projeto que reúne, desde 2013, uma rede internacional composta de aproximadamente 40 parceiros, para o monitoramento e avaliação das condições de produção de quatro culturas agrícolas de interesse estratégico (trigo, milho, arroz e soja) nos principais países produtores e exportadores, fornecendo subsídios para o relatório da AMIS. Neste projeto, a Universidade de Maryland (UMD) combinou índices globais, baseados em sensoriamento remoto, com máscaras de cultura e calendários agrícolas para identificar áreas potenciais de cultivo agrícola (FRITZ et al., 2019).

Especialistas, nacionais e internacionais, incluindo representantes governamentais (Ministérios da agricultura de diversos países) e pesquisadores de agências espaciais e universidades participaram das avaliações, fornecendo conjuntos de dados de entrada para os modelos de avaliação das condições de cultivo (HARVEST, 2015).

GEOGLAM *Crop Monitor For Early Warning* (CM4EW) constitui outra iniciativa internacional de grande relevância que objetiva estabelecer consenso e proporcionar

transparência na avaliação das condições de crescimento das culturas (FRITZ et al., 2019). Esta iniciativa utiliza múltiplas fontes de informação sobre as condições de sustentabilidade dos sistemas produtivos como as condições agroclimáticas que podem impactar os países vulneráveis levando-os à insegurança alimentar. Deste modo, pretende-se fornecer informações estratégicas para a tomada de decisões relacionadas à formulação e implementação de políticas públicas e às intervenções de caráter emergencial e humanitário. Iniciativa esta, denominada “Países em risco” do GEOGLAM, criado visando a melhor atuação das agências responsáveis pela avaliação da agricultura em regiões sob risco de insegurança alimentar como as regiões da África Oriental, África Ocidental, África Austral, Sudeste Asiático, Ásia Central e Meridional, América Central e Caribe (HARVEST, 2020).

Outra iniciativa de destaque é o *Agriculture Monitoring in The Americas* (AMA) que constitui um grupo de trabalho que se concentra no fortalecimento das capacidades de monitoramento dos sistemas nacionais de observação da Terra. Além disso, estimula a colaboração internacional para a pesquisa e desenvolvimento, além da implementação operacional de ferramentas de monitoramento para os principais tipos de culturas e pastagem. Participam deste grupo, especialistas de ministérios da agricultura, agências espaciais, universidades e empresas de mais de vinte países, incluindo o Brasil. Neste grupo são realizadas pesquisas no contexto do *Joint Experiment for Crop Assessment and Monitoring* (JECAM) objetivando o aprimoramento de metodologias, técnicas e ferramentas de monitoramento (JECAM, 2020).

O JECAM, por sua vez, constitui uma rede de áreas de estudo de caso (sites) definidos pela comunidade GEOGLAM, distribuídos em diversos países do mundo como, China, França, Bélgica, Argentina, Ucrânia, Rússia, Vietnam, Burkina Faso, Tanzânia, Etiópia, Madagascar e Brasil. Dentre os diversos tópicos de pesquisa as áreas de estudo do JECAM são utilizadas para projetos de P&D relacionados aos seguintes temas: Identificação de safra e estimativa de área de cultivo; previsão de rendimento; avaliação das condições de estresse da culturas; identificação de práticas de manejo da cultura e do solo; mapeamento de cobertura do solo, variabilidade climática e mudanças climáticas; completam o largo espectro temático.

Agência Espacial Europeia (ESA), no contexto do GEOGLAM e JECAM, desenvolveu o projeto Sentinel-2 para Agricultura (Sen2-Agri). Este projeto foi desenvolvido para demonstrar e facilitar a utilização das séries temporais do Sentinel-2 no monitoramento agrícola. De forma prática, o Sen2-Agri tem o objetivo de fornecer algoritmos validados, de

código aberto, além das melhores práticas para processar dados do Sentinel-2, de caráter operacional para os principais sistemas agrícolas (ESA, 2015).

Dada as diversas iniciativas em curso, o GEO está desenvolvendo o *GEO Knowledge Hub* (GKH), que visa criar uma estrutura “guarda-chuva” para facilitar o acesso às soluções abertas baseadas em dados de OT do grupo, facilitando o reuso de ferramental disponível.

Para uma melhor compreensão sobre as principais iniciativas regionais e globais, indicamos a leitura da análise realizada por Fritz et al., (2019), onde os principais sistemas de monitoramento agrícola atualmente em operação são comparados entre eles. Os autores também realizam uma análise das bases de dados de entrada, modelos usados, resultados produzidos e outras características, como a interação com outros sistemas, escala geográfica e dados de sensoriamento remoto utilizados, evidenciando as lacunas e oportunidades existentes.

#### 1.4.2 Monitoramento dos sistemas de produção agrícola em larga escala

Foi discutido anteriormente a distinção conceitual dos termos: Cobertura da terra e Uso da terra, *Land Cover/Land Use* e *Ocupation de la terre/Utilization de la terre*, para as traduções em inglês e francês, respectivamente. Discutiu-se que alguns autores consideram que a *ocupação ou cobertura da terra* diz respeito as características biofísicas da superfície terrestre, incluindo a vegetação natural, as superfícies cultivadas, superfícies d’água, o solo, as construções (JANSEN; GREGORIO, 2000), enquanto o conceito de *uso da terra* constitui uma tipologia de classificação conforme a utilização socioeconômica dos recursos da superfície terrestre (agricultura, pecuária, mineração, urbanização, etc). Por esta ótica, um dossel de soja constitui, embora antropizada, um tipo de cobertura vegetal que, evidencia o tipo de uso da terra: agricultura. Em contrapartida, outros autores utilizam o termo *uso da terra* para as atividades antrópicas, reservando a expressão cobertura *da terra* apenas para designar as feições naturais detectadas na superfície da terra.

No presente trabalho, adotou-se, como referencial teórico-conceitual, a abordagem que tipifica como *cobertura da terra* toda e qualquer feição biofísica da superfície terrestre, e, como *uso da terra* a ressignificação dos alvos detectados, deduzindo, assim, o tipo de utilização econômica de uma dada porção da superfície terrestre de interesse. Uma vez posta a discussão conceitual o que importa é a obtenção de informações relevantes sobre a área a ser mapeada. A

questão que se coloca a partir daqui é: *Qual é o nível de detalhamento da informação sobre a superfície terrestre que se pretende obter?* Evidentemente, vai depender do problema para o qual a informação obtida vai responder. Assim, para alguns estudos, de cunho ambiental, a distinção entre as áreas ocupadas com vegetação natural e com agropecuária pode ser o suficiente, outros, por exemplo, relacionados à estimativa da produção agrícola podem requerer a distinção entre as diferentes culturas agrícolas: soja, milho, sorgo, cana-de-açucar etc. Estudos fitofisionômicos podem não se satisfazer com a tipificação “floresta”, necessitando informações mais detalhadas sobre a diferenciação dos tipos florestais: floresta ombrófila densa, ombrófila aberta, e, assim por diante. Para os pesquisadores que trabalham com a detecção e o monitoramento de pastagens se faz relevante informações sobre o estado qualitativo ou de degradação delas. Para estudos agronômicos, a simples distinção dos tipos de culturas pode não ser suficiente, exigindo informações sobre os sistemas de produção, como; agricultura convencional, plantio direto na palha, sistema de duplo cultivo, sistemas integrados, sistemas irrigados, dentre outros.

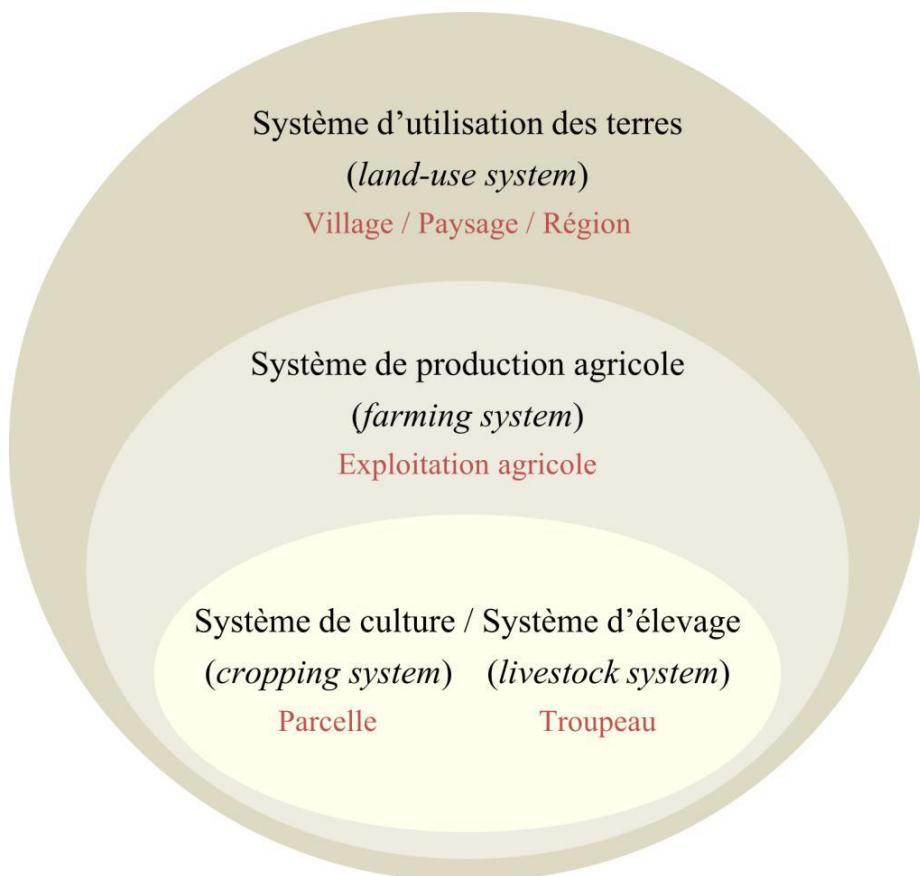
O termo sistema de produção envolve, conceitualmente, diversos tipos de sistemas onde diferentes práticas de manejo da cultura, controle fitossanitário, manejo do solo e da água são aplicadas à produção agrícola. Práticas estas, aplicadas de modo sistemático e reproduzível, a ponto de se distinguir um sistema, podendo apresentar mínimas variações que não interferem nos princípios basilares do referido sistema de produção. Por exemplo, no caso do Sistema de Plantio Direto na palha (SPD), as práticas de não revolvimento do solo (aração e gradeamento), dessecação da palhada e semeadura direta sobre ela são fundamentais e definidoras do sistema. Sistemas de produção orgânica têm por princípio básico a não utilização de agroquímicos, dentre outros requisitos. Sistemas integrados de produção seguem sequências pré-determinadas, cultivando em sucessão, consórcio ou rotação diferentes componentes de lavoura, pecuária e/ou reflorestamento silvicultural.

Os autores Geng, Hess et Auburn (1990) apresentam uma conceitualização mais geral, para os quais, os sistemas de produção agrícola podem ser considerados como um conjunto de tecnologias e atividades de gestão de recursos naturais aplicados para a geração de alimentos.

Por sua vez, Fresco et Westphal (1988) apresentam os sistemas de produção como uma hierarquia com diferentes níveis de organização em função da escala espacial a qual se referem (**Figura 7**). Desta forma, na escala regional, municipal ou da paisagem se distinguiram os sistemas de utilização da terra, que incluiria a categoria *agricultura*, na escala da fazenda, para os autores, seria apropriado distinguir os sistemas de produção agrícola - SAFs. iLPF, SPD,

bem como, para o nível de parcelas ou glebas, os sistemas de culturas agrícolas ou pecuária, nos quais se designariam os tipos de cultura (soja, milho, etc.) ou tipos de pecuária (ovinos, caprinos, equinos, bovinos de corte, leite, etc.). Embora lógico do ponto de vista da escala espacial das atividades agrícolas, tal hierarquia não baliza apropriadamente a cartografia dos diversos níveis hierárquicos apresentados. Pode-se cartografar, regionalmente, uma cultura agrícola qualquer, ou mesmo, um sistema de produção, por exemplo, que aliás, constitui o desafio motivador da presente tese.

Figura 7 - Hierarquia dos sistemas agrícolas e níveis de organização (adaptado de Fresco et Westphal (1988) et Béllon (2018))



Embora haja consenso por parte da comunidade científica sobre a necessidade de se caracterizar os sistemas de produção agrícola em escala regional, existem, na literatura especializada, pouquíssimos exemplos a este respeito.

Desenvolvimentos recentes na área de Sensoriamento Remoto oferecem muitas possibilidades para o mapeamento de áreas agrícolas em paisagens rurais e uma grande diversidade de estratégias de mapeamento, em diferentes escalas e graus de acurácia, podem

ser encontrados na literatura. Contudo, as áreas agrícolas são frequentemente descritas de acordo com tipologias de cobertura da terra com foco predominante em tipos gerais de vegetação, deste modo, as áreas agrícolas, não raro, são incluídas em classes mistas ou de mosaicos. Deste modo, o uso desses mapas para estudos específicos da agricultura torna-se bastante limitado, visto que não servem nem como máscara para a localização, nem como estimativa da área agrícola.

Produtos orientados à caracterização da cobertura global da terra, como: GLC2000, GlobCover 2005/2009, GLCShare, MODIS *Land Cover*, ESA *Land Cover CCI* (PÉREZ-HOYOS et al., 2017), dentre alguns outros, não objetivam cartografar, especificamente, os componentes agrícolas da paisagem. Por outro lado, mapas globais, como os mapas da FAO sobre sistemas agrícolas (DIXON; GULIVER; GIBBSON, 2001) ou os mapas sobre os sistemas de agricultura de subsistência da África, produzidos pelo FEWSnet (*Famine Early Warning Systems Network*) (USAID, 2009), são derivados, principalmente, de mapas de cobertura da terra obtidos em amplas escalas, complementados com informações geográficas regionais. Alternativamente, mapas de áreas agrícolas ou de culturas agrícolas (FRITZ et al., 2013; P. S. THENKABAIL et al., 2013; RAMANKUTTY et al., 2008), a nível continental, foram derivados de dados já existentes, estatísticas ou mapas, e processados por agregação ou desagregação cartográfica. O IIASA (*International Institute for Applied Systems Analysis*), através da compilação de dados existentes, elaborou um mapa de uso agrícola da terra (EOS, 2013) que vem sendo utilizado pelo IFPRI *International Food Policy Research Institute* (IFPRI) para gerar mapas de distribuição de tipos de culturas. De acordo com (RAMANKUTTY et al., 2008), as comparações iniciais realizadas com os mapas de culturas elaborados pelo IIASA mostram que os mesmos caracterizam melhor as áreas agrícolas que outros mapas existentes, contudo, em geral, esses esforços de compilação raramente podem ser atualizados, validados ou utilizados para estudos que requerem escalas mais detalhadas. Mais recentemente, o “*Global Agro-Environmental Stratification*” (GAES) do Instituto de Investigação Ambiental da Universidade de Wageningen, no âmbito do projeto SIGMA (MÜCHER et al., 2016), apresentou uma abordagem metodológica para produzir mapas globais estratificados, cartografando as “zonas de produção agrícola”, a partir da integração de diversas camadas de dados agroambientais globais com resolução de 1 km, tais como: cobertura do solo, climáticos, pedológicos, elevação, recursos hídricos, dentre outros. Vaclavik et al. (2013) derivaram uma representação global de sistemas de produção agrícola utilizando dados de intensidade de uso da terra, condições ambientais e indicadores socioeconômicos. A intensidade

do uso da terra foi obtida a partir de mapas de cobertura da terra com base em imagens de satélites e dados estatísticos regionais.

Os autores observaram que o escopo do estudo foi limitado porque a qualidade dos conjuntos de dados estatísticos mundiais usados tinham distribuição geográfica, consideravelmente, desigual. (Kuemmerle et al., 2013) propuseram, além de métricas de intensidade de uso derivadas, direta ou indiretamente, de dados de sensoriamento remoto, uma revisão nos dados de entrada (tipo de cultura, frequência de cultivo, capital, intensidade de trabalho etc.) e de saída (produtividade, estoque de carbono etc.) do modelo. Concluíram que as abordagens baseadas em aproximações que utilizam imagens de satélites ainda são experimentais e não podem ser facilmente aplicadas em grandes áreas. Todas essas abordagens metodológicas, entretanto, cabe destacar, fazem limitado uso de dados de sensoriamento remoto diretamente aplicados para a detecção dos sistemas de produção agrícola propriamente ditos.

Leenhardt et al. (2010) revisaram diferentes trabalhos que se dedicaram a mapear, em escala regional, os sistemas de produção agrícola, e, concluíram que para a maioria das regiões do mundo os mapeamentos produzidos se revelaram insatisfatórios. Desta forma, destacam Verburg et al., (2009), as abordagens baseadas exclusivamente em informações sobre a cobertura da terra, sem considerar informações sobre o manejo da cultura ou do solo, são insuficientes para se descrever adequadamente os sistemas de produção. Completam os autores, enfatizando que para se mapear adequadamente os sistemas de produção agropecuária, cada vez mais complexos, se faz necessária a implementação de novos métodos a partir do processamento de novos dados. Entretanto, a contribuição do sensoriamento remoto para o mapeamento de sistemas de produção agrícola ainda continua bastante fragmentada.

Mapas regionais de áreas de arroz do Sudeste Asiático (BRIDHIKITTI; OVERCAMP, 2012), de produção de cana-de-açúcar no Brasil (ADAMI et al., 2012) e, da cultura da soja, realizado pela iniciativa Mapbiomas foram produzidos a partir das séries temporais de dados de sensoriamento remoto com o propósito de distinguir os padrões fenológicos característicos de cada cultura. Contudo, para se descrever um sistema de produção agrícola é preciso mais do que o conhecimento sobre o tipo de cultura. Faz-se necessário, a partir do conhecimento agronômico de cada sistema e, também, do calendário agrícola regional, identificar determinadas práticas pontuais e/ou etapas sequenciais de produção, passíveis de serem detectadas remotamente, que evidenciem os sistemas de produção de interesse. Segundo Béllon (2018), a caracterização espacial dos sistemas de produção agropecuários pode ser realizado a

partir da cartografia e da análise do uso agrícola das terras, descritas pelas espécies cultivadas e as práticas agrícolas associadas, que são os componentes essenciais dos sistemas agrícolas.

Foi destacado anteriormente que, basicamente, os sistemas de produção agrícola são caracterizados, além de um conjunto de técnicas de manejo (p.ex., preparo do solo, tratos culturais, adubação, irrigação etc.), por determinados tipos de culturas agrícolas cultivadas solteiras (monoculturas), ou em sucessão, rotação ou consorciação que são utilizados pelos produtores, de modo sistemático, em uma determinada gleba. O surgimento de imagens de satélites de alta ou muito alta resolução espaço-temporal abre um campo de possibilidades para a identificação e monitoramento, em escala local, de um número crescente de práticas agrícolas. A rotação que reflete uma alternância intranual de culturas agrícolas a cada ano-safra têm sido as práticas mais frequentemente monitoradas. Outras práticas tais como, a sucessão de culturas de verão, em sistemas safra/safrinha (ARVOR et al., 2011, 2012; SIMOES et al., 2014), identificação de datas de semeadura e colheita (LEBOURGEOIS et al., 2017), irrigação e consórcio de culturas perenes (DELENNE et al., 2007), podem agora ser identificadas e mapeadas a partir de imagens de satélite de alta resolução em escala local. Em escala regional, no entanto, a questão de como sistemas de produção agrícola podem ser descritos e localizados dentro de grandes áreas e/ou áreas heterogêneas continua em aberto. Geralmente, o nível de informação não é suficiente para se obter todos os detalhes necessários para se caracterizar os sistemas de produção agrícola. A aplicação de “conhecimento especializado” pode ser uma maneira de superar a dificuldade em localizar e descrever as práticas agrícolas, mas, este recurso torna-se limitado com o aumento do intervalo de tempo e com o tamanho da unidade de observação. Na escala regional, a descrição das atividades agrícolas e de uso da terra precisa ser simplificada (LEENHARDT et al., 2010). Vintrou et al. (2012) relacionaram com sucesso padrões espaciais e temporais detectados por sensoriamento remoto para diferentes tipos de sistemas de produção agrícola na região Sul de Mali. Por alguns anos, muitos pesquisadores têm a intenção de melhorar a qualidade dos mapas de cobertura/uso da terra através de qualificação das práticas agrícolas adotadas pelos agricultores. Por exemplo, trabalhos foram realizadas para mapear variedades (ARVOR et al., 2011), superfícies irrigadas (WARDLOW; EGBERT, 2008) e rotação de culturas (ARVOR et al., 2011).

Os programas nacionais, ou independentes de mapeamento da cobertura e uso da terra em larga escala somam grandes esforços para geração de produtos capazes de auxiliar na gestão sustentável recursos naturais. Porém ainda há uma grande lacuna a ser superada na área da cartografia de sistemas de produção agrícola. Bégué et al (2018) apontam que menos de 10%

das publicações sobre sensoriamento remoto se concentram em sistemas de produção e/ou práticas agrícolas e a grande maioria destas publicações se referem à metodologias experimentais ou à estudos exploratórios focados em áreas específicas em escala local (DAUGHTRY et al., 2006; GALFORD et al., 2008; PACHECO; MCNAIRN, 2010; V. MAUS et al., 2016), apontando uma grande dificuldade de se achar abordagens derivadas de sensoriamento remoto em escala regional. Os estudos, em maioria, utilizam somente um sensor e objetivam o mapeamento de cultivos únicos, monoculturas anuais ou a culturas perenes, como pomares e vinhedos. Em menor quantidade, são expostas iniciativas de mapeamento de sistemas de cultivos sequenciais de múltiplas culturas, que caracterizam a intensificação agrícola (ARVOR et al., 2012; SIMOES et al., 2014). Nestes casos, é necessário a utilização de séries temporais de índices de vegetação com sensores de alta resolução temporal que possibilitem a captura da variabilidade sazonal e a caracterização da sucessão de distintos ciclos fenológicos dos cultivos sequenciais. A título de exemplo, nos Estados Unidos da América, (WARDLOW; EGBERT; KASTENS, 2007) avaliaram o potencial das séries temporais do índice de vegetação de diferença normalizada (NDVI, sigla em inglês) e do índice de vegetação aprimorado (EVI) para separar tipos de cultivo e sistemas de cultivo. No Norte e Centro da China, Mingwei et al (2008) e Qiu et al. (2014) mapearam sistemas de cultivo simples (algodão ou milho) e duplos cultivos (trigo de inverno com algodão, trigo de inverno com milho e trigo de inverno com arroz) com base na análise de *Fourier* e *Wavelet*, respectivamente. No Brasil, estudos conduzidos em nível local exploraram o potencial das séries temporais do índice de vegetação MODIS para discriminar sistemas de cultivo duplo e solteiro (soja e soja-milho ou soja-algodão) (ARVOR et al., 2012; BROWN et al., 2013; GALFORD et al., 2008).

Outros estudos geraram mapas, em escala regional, da intensificação dos cultivos de verão (cultivo duplo e solteiro) para todo o estado do Mato Grosso (ARVOR et al., 2012; SIMOES et al., 2014). Spera et al. (2014), também trabalhando com o estado do Mato Grosso, usaram o sensoriamento remoto para avaliar a adequabilidade da expansão agrícola no estado, entre os anos de 2001 a 2011. Os autores usaram uma série temporal de EVI do MODIS, aplicados a um algoritmo de árvore de decisão, para identificar sistemas de cultivos específicos - soja, algodão, soja-milho, soja-algodão e culturas irrigadas - usados em larga escala na região. Os autores descobriram uma intensificação do uso de sistemas de duplo cultivo e que as áreas mais adequadas para a expansão das atividades agrícolas do estado já tinham sido, em maioria, ocupadas antes de 2006. Arvor et al. (2011) também utilizaram séries temporais MODIS EVI para identificar três classes de culturas solteiras: soja, milho e algodão; e três de duplo cultivo:

soja-milho; soja-algodão; soja-milheto. Os autores coletaram, entre os anos de 2005-2006 e 2006-2007, dados de campo referentes a 1920 parcelas de 50 fazendas e, aplicando segmentação para produzir resultados mais homogêneos, utilizaram um método de classificação dividido em duas etapas. Primeiramente, utilizaram uma máscara de terra cultivada para, em seguida, discriminar as culturas de interesse. A acurácia relatada é de 85% para a máscara de agricultura e 74% para a classificação, usando dados de validação não incluídos no conjunto de treinamento. Dentre outras conclusões, o trabalho relata que a cultura do milho, para a região, é majoritariamente encontrada em sistemas de duplo cultivo, em sucessão a soja (safra/safrinha). Para descrever a dinâmica espacial da produção agrícola no estado de Mato Grosso, no período de 2001 a 2014, Kastens et al. (2017) usaram séries temporais NDVI/MODIS e dados de referência de campo para os anos de 2009 a 2016 para criar uma base de aprendizagem para o classificador *random forest*. A acurácia relatada foi de 79% para distinguir as seguintes classes de cultura estudadas: soja-pousio, algodão-pousio, soja-algodão e soja. A classe da cultura da soja incluiu também a sucessão com milho, painço, sorgo ou girassol, mas, segundo as conclusões do trabalho, estas culturas não puderam ser bem distinguidas.

Chen et al. (2018) desenvolveram uma metodologia, também aplicada ao estado de Mato Grosso, para identificar tipos de culturas, incluído soja, algodão e milho em sistemas: soja-milho, soja-algodão, soja-pasto, soja-pousio, pousio-algodão, além das culturas solteiras. Foram utilizados dados NDVI do MODIS que passaram por processo de filtragem e suavização para minimizar efeitos atmosféricos, como nuvens. Foram extraídas métricas fenológicas das séries temporais pré-processadas e posteriormente foi utilizado um classificador de árvore de decisão para o mapeamento nos anos de 2015 e 2016. Para a avaliação da classificação foram utilizados dados de campo coletados em 2016, dados secundários sobre os tipos de culturas de 2015, além da interpretação a partir de imagens Landsat de 2016. Eles alcançaram uma acurácia de 90% para áreas cultivadas, 73% para padrões de culturas e 86% para tipos de culturas. Foi feito um ajustamento para simplificar as classes em áreas cultivadas com 94% de acurácia, soja com 94%, milho com 88% e algodão com 88%. O autor discute a grande dificuldade de diferenciar pasto das culturas de algodão, milho, milheto e cana-de-açucar, apontando grande mistura espectral, devido aos perfis similares. Por este motivo, o ajustamento que resultou no aumento da acurácia apontada, foi alcançada pela fusão das culturas Soja-Milho, Soja-Algodão, Soja-Pousio, Soja-Pasto e Soja em cultura única como uma única classe chamada Soja.

Picoli et al (2018) mapearam o estado do Mato Grosso com séries temporais MODIS, dentre as classes de vegetação nativa e pastagem, os sistemas de cultivo único de algodão e soja e os sistemas de duplo cultivo de soja-milho, soja-algodão, soja-milheto e soja-girassol, com excelente acurácia encontrada para cada classe.

#### 1.4.2.1 Dados MODIS (*MODerate resolution Imaging Spectroradiometer*)

O sensor Modis (*Moderate Resolution Imaging Spectroradiometer*) a bordo dos satélites Terra e Acqua, lançados em 1999 e 2002 , ampliou a possibilidade de geração de Séries Temporais de Imagem de Satélite (STIS) voltadas a avaliação da dinâmica de uso da terra (JONATHAN et al., 2009) bem como a avaliação da dinâmica da agricultura (ARVOR et al., 2012; SAKAMOTO et al., 2005; SIMOES et al., 2014; XAVIER et al., 2006). Pertencente ao programa EOS *Earth Observing System* (EOS) da agência espacial norte-americana *National Aeronautics and Space Administration* (NASA), o MODIS foi concebido para utilização em aplicações diversas, incluindo uma gama de fenômenos terrestres, atmosféricos e dos oceanos. Preparado para o imageamento de extensas áreas, tem alta frequência, apresentando largura na faixa de imageamento de 2330km, com resolução temporal de 1-2 dias em 36 bandas espectrais, e com resolução espacial que pode chegar a 250 metros nas faixas do vermelho e do infravermelho próximo (JUSTICE et al., 1998).

O MODIS continua em operação e mesmo com duas décadas depois de seu lançamento, ainda apresenta grande potencial. A NASA disponibiliza periodicamente seus produtos, que vão além das imagens de valor de radiância capturada pelo sensor. Diferente dos seus antecessores e mesmo da série Landsat e Sentinel, a NASA disponibiliza produtos “prontos para uso”. ao todo são 44 produtos com níveis de processamento distintos disponibilizados em diferentes versões. O produto mais amplamente utilizado para o mapeamento de uso e cobertura da terra é o MOD13Q1, que é um produto fruto da composição de 16 dias de índices de vegetação, com resolução espacial de 250 metros. A composição é realizada, utilizando como base os dados diários da reflectância da superfície, através da realização de processamentos que fornecem valores corrigidos para cada célula, em uma janela temporal de 16 dias, considerando variáveis atmosféricas como nuvens, sombras, aerossóis, além das variáveis relacionadas à altitude do sensor. O produto MOD13Q1 disponibiliza os índices de vegetação NDVI e EVI, as bandas de reflectância : vermelho, infravermelho próximo, azul e infravermelho médio, além

das duas bandas de qualidade, que correspondem ao controle de qualidade de cada célula dos índices de vegetação calculados, além de conterem informações a respeito da concentração de aerossóis, nuvens e outros tipos de indicadores.

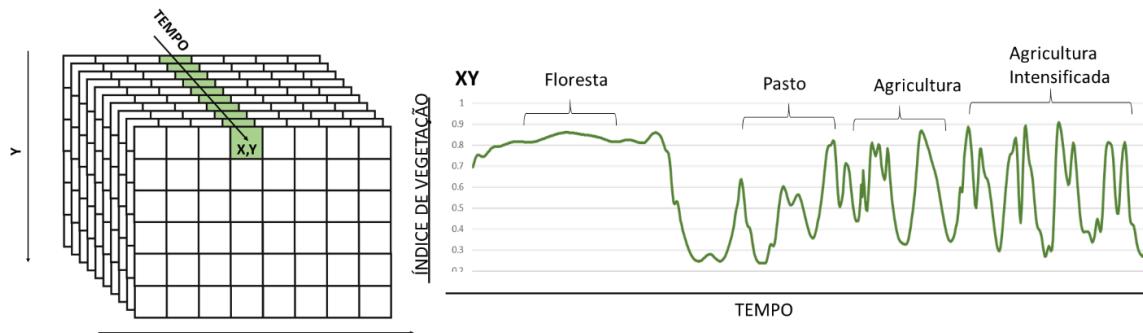
#### 1.4.2.2 Séries temporais de dados de sensoriamento remoto

Fenologia vegetal é o estudo de como a planta se desenvolve considerando-se as diferentes etapas, tanto vegetativa quanto reprodutiva, demarcando-se as épocas de ocorrência, ou seja, a sucessão das diferentes fases do ciclo de uma planta (RATHCKE; LACEY, 1985). Estas diferentes fases marcam ciclos sazonais, que correlacionam os fatores ambientais com os fatores genéticos de cada espécie, direcionando o estudo da fenologia a eventos como brotação, floração, frutificação, senescência e queda de folhas (HMIMINA et al., 2013; RATHCKE; LACEY, 1985). O estudo do comportamento fenológico de cada espécie pode ser feito quantitativamente por definições de parâmetros como tempo de ocorrência, duração, sincronia, entre outros (RATHCKE; LACEY, 1985). O estudo da fenologia das plantas é realizado geralmente, para indivíduos claramente identificados e para pequenas áreas e fornece informações detalhadas dos estágios fenológicos individuais em diferentes espécies (CLELAND et al., 2007; MELAAS; FRIEDL; ZHU, 2013). Estas observações neste nível de detalhe fornecem informações valiosas para o entendimento do comportamento vegetal, no entanto são extremamente limitadas para subsidiar análises regionais e o monitoramento em larga escala (MELAAS; FRIEDL; ZHU, 2013).

Técnicas de monitoramento da dinâmica espaço-temporais da fenologia da vegetação em escala global e regional tem sido aprimoradas a partir do desenvolvimento contínuo do Sensoriamento Remoto através da disponibilização de novos sensores, do aprimoramento da resolução espacial, temporal e espectral, do aumento da acessibilidade aos dados e através do uso de novos índices de vegetação. Apesar de, algumas fases do desenvolvimento fenológico não serem passíveis de identificação a partir de técnicas de sensoriamento remoto orbital (por exemplo a fase de crescimento de raízes), a extração das principias métricas fenológicas necessárias ao monitoramento da agricultura, podem ser derivadas de dados de satélites devido a sua alta frequência temporal, além da grande abrangência espacial (CLELAND et al., 2007).

Neste sentido, como apresentado no item 1.4.1 Monitoramento do uso agrícola em larga escala, para monitorar o crescimento das culturas ao longo das estações e identificar mudanças nas práticas agrícolas, faz-se necessária uma coleção de dados capaz de construir uma série temporal de índice de vegetação, contraponto a ideia da classificação de uma única imagem. Estas abordagens metodológicas baseadas nas séries temporais de imagens de satélite (STIS) já são amplamente utilizadas para classificação de uso de cobertura terra, uma vez que, estes conjuntos de dados podem capturar a complexidade e a dinâmica de mudanças da superfície terrestre (JONATHAN et al., 2009; LIU; CAI, 2012). As STIS baseiam-se na possibilidade de um mesmo local ser revisitado pelos sensores imaginadores diversas vezes ao longo do tempo registrando as principais características do ciclo vegetativo. Esta abordagem é baseada na autocorrelação temporal, diferenciando-se, assim, da autocorrelação espacial, usualmente utilizada nas abordagens tradicionais (JÖNSSON; EKLUNDH, 2004).

A partir das Séries Temporais de Imagens de Satélite, cada célula ou pixel é avaliada ao longo do tempo (SIMOES et al., 2014), reconstruindo-se graficamente a história, possibilitando, desta forma, a compreensão do ciclo vegetativo da vegetação (**Figura 8**  
**Figura 8 - Exemplo de séries temporais de imagens de satélite**



As STIS, portanto, possibilitam, através das curvas de índices de vegetação, a reconstrução de todo o ciclo fenológico da vegetação necessário para a compreensão dos sistemas agrícolas mais complexos como é o caso dos sistemas sequenciais Gomez et al., (2016). A recorrente utilização de dados MODIS em estudos de monitoramento da agricultura em escala regional, se deve, principalmente, a disponibilidade de dados diários e a composição de produtos prontos, a cada 16 dias, como os índices de vegetação (EVI ou NDVI), com resolução espacial de 250 m e com efeitos atmosféricos minimizados e. Apesar da limitação em

relação a resolução espacial, os aspectos positivos superam as limitações, principalmente nos aspectos relacionados a temporalidade (ARVOR et al., 2011).

Existem outros programas de monitoramento mais recentes, como é o caso do atual programa da Agência Espacial Europeia (ESA, sigla em inglês), que lançou satélites com sensores ópticos de alta resolução espacial. O Sentinel-2 é uma missão de observação da Terra do Programa Copernicus que adquire sistematicamente imagens ópticas em alta resolução espacial sobre a terra e as águas costeiras. A missão é uma constelação com dois satélites gêmeos, Sentinel-2A e Sentinel-2B (ESA) e assegurará a alta capacidade de aplicações para monitoramento do uso e cobertura da terra, incluindo o monitoramento do uso agrícola da terra. Os principais pontos fortes do Sentinel-2 referem-se a presença de 13 bandas espectrais, alta resolução espacial e uma revisita de 2 a 5 dias, bem como a disponibilidade gratuita de seus produtos. Alguns estudos utilizaram Sentinel-2 para o mapeamento do uso da terra e agricultura (BELGIU; CSILLIK, 2018; CAI; LIN; ZHANG, 2019; CSILLIK et al., 2019; DEFOURNY et al., 2019; SEGARRA et al., 2020; SON et al., 2020; VUOLO et al., 2018; WANG et al., 2019). Mesmo que esta constelação seja uma opção para a reconstrução de STIS num futuro próximo, a alta cobertura de nuvens existentes na estação de crescimento da planta, principalmente na região amazônica, ainda dificulta a utilização das informações fenológicas das culturas com estes sensores. Além disto, no Brasil, ainda não é possível obter-se uma série temporal muito longa, pois o sistema só se tornou operacional, com 5 metros de resolução, a partir de 2018. No caso do Landsat, a resolução temporal de 16 dias não é suficiente para derivar informações fenológicas contínuas, principalmente em regiões com grande quantidade de nuvens. Mesmo que a combinação entre sensores (fusão de imagens) possa ser uma opção para se derivar uma série mais densa de imagens, esta opção ainda é distante das possibilidades da revisita diária do sensor MODIS.

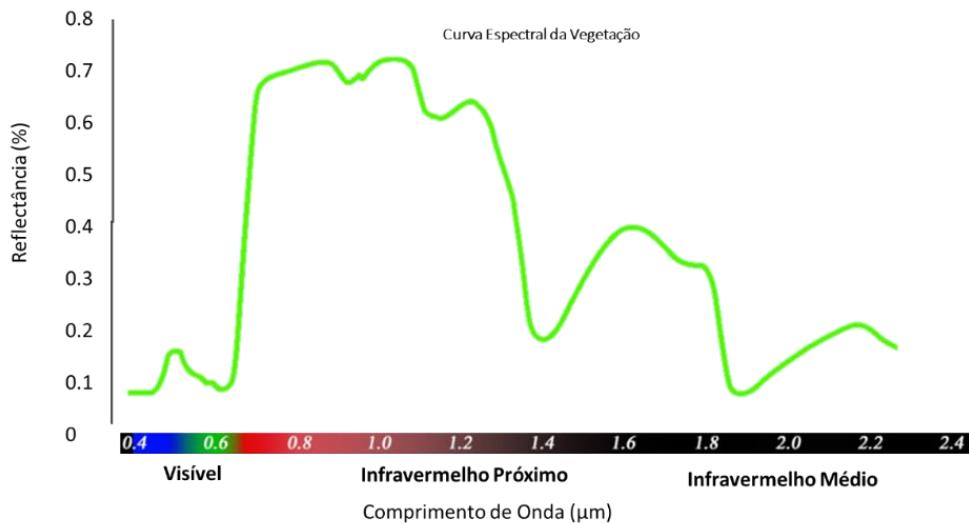
#### 1.4.2.2.1 Índices de vegetação

A capacidade apresentada por um sensor para detectar um determinado tipo de alvo, e assim diferenciá-lo dos demais, depende não apenas das características do instrumento de detecção, mas obviamente das próprias propriedades físicas dos alvos em questão, de como elas se relacionam com a energia eletromagnética e da natureza e magnitude das interferências sofridas pelo sinal antes de chegar aos detectores do sensor (Jonathan et al, 2009). A interação da radiação eletromagnética em diferentes alvos na superfície terrestre é base do sensoriamento

remoto. Esta interação é naturalmente diferente entre os diversos tipos de alvo e no caso da vegetação, apresenta um comportamento espectral de características muito peculiares, fruto de um conjunto de fenômenos relacionados aos processos bioquímicos e à própria estrutura física das plantas. Neste caso, a absorção da radiação eletromagnética é realizada pelos pigmentos fotossintetizantes como é o caso das clorofitas, chantofitas e carotenos (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Ao observarmos alvos de vegetação, observa-se um comportamento espectral bem característicos, devido a um conjunto de fenômenos relacionados aos processos bioquímicos e à própria estrutura física das plantas verifica-se um alto nível de absorção de energia eletromagnética na faixa da luz visível, decorrente da atividade fotossintética. Ao avaliar um padrão geral do comportamento espectral da vegetação (**Figura 9**), é possível identificar um pequeno pico de reflectância na faixa que corresponde ao verde do espectro eletromagnético, o que é responsável pela coloração assumida pelos vegetais. Porém é na faixa do infra-vermelho próximo, que o comportamento da cobertura vegetal irá apresentar seu comportamento mais característico, apresentando significativa reflectância (JONATHAN et al., 2009). é possível identificar um pequeno pico de reflectância na faixa do visível que corresponde ao verde do espectro eletromagnético, o que é responsável pela coloração assumida pela vegetação. Observa-se, também, que a absorção de energia pela vegetação para a realização de fotossíntese se dá exatamente numa faixa do espectro de baixa absorção atmosférica, o que maximiza a quantidade de radiação passível de ser absorvida. Na faixa do infra-vermelho próximo, a vegetação irá apresentar seu comportamento mais característico, demonstrando valores da reflectância mais elevados num fenômeno associado à estrutura da folha, observa-se, também, que o índice de reflectância nesta faixa também aumenta de acordo com o número de camadas de folhas presentes no dossel vegetativo, uma vez que nestes casos parte da energia transmitida através da primeira camada de folhas é refletida pelas camadas subsequentes (JONATHAN et al., 2009; CLEVERS, 1988; DONOGHUE, 2001).

Figura 9 - Resposta espectral da vegetação.



Fonte: Adaptado de (PONZONI; SHIMABUKURO; KUPLICH, 2012)

Com base neste comportamento espectral em diversas faixas do espectro, se torna possível a caracterização da densidade de vegetação na superfície a partir da combinação destas diferentes faixas do espectro eletromagnético. Desta forma, diversos Índices de Vegetação (IV) vêm sendo aplicados, a partir de valores de reflectância medidos por diferentes bandas de sensores remotos. De um modo geral, estes índices fazem uso principalmente das respostas captadas nas faixas do vermelho (ou alternativamente de toda a região do visível) e do infra-vermelho próximo, podendo às vezes incluir informações em outras faixas, como no azul e no infra-vermelho médio (JONATHAN et al, 2009). Os IVs podem ser definidos como relações espetrais de duas ou mais bandas de um sensor, que possibilita avaliar e identificar atividade fotossintética terrestre. Estes índices têm sido usualmente aplicados em estudos fenológicos por meio de duas abordagens, a. primeira utiliza diretamente os índices como métricas que caracterizam o comportamento fenológico da vegetação, geralmente após a aplicação de filtros para suavizar a série temporal, e a segunda, utiliza algoritmos para a extração de métricas sazonais. Diversos tipos de índices de vegetação e seus derivados são encontrados na literatura, porém, para ambas as abordagens, os mais utilizados para o monitoramento da vegetação, são o *Normalized Difference Vegetation Index* (NDVI) definido pela equação 01.

$$NDVI = \frac{IVP - V}{IVP + V} \quad (\text{Equação1})$$

sendo:

- $IVP$  : reflectância medida na faixa do infra-vermelho próximo
- $V$  : reflectância medida na faixa do vermelho

O *Enhanced Vegetation Index* (EVI) definido pela equação 2 (HUETE et al., 2002).

$$EVI = G X \frac{IVP - V}{IVP + C1 X V - C2 X Blue + L} \quad (\text{Equação2})$$

sendo:

- $IVP$  : reflectância medida na faixa do infra-vermelho próximo
- $V$  : reflectância medida na faixa do vermelho
- $C1$  e  $C2$ : coeficientes do termo de resistência do aerossol

O índice mais utilizado é o NDVI, que é mais sensível à presença de pigmentos que participam dos processos fotossintéticos, como na clorofila e pode ser aplicado em diferentes tipos de vegetação (GITELSON; KAUFMAN; MERZLYAK, 1996; HUETE, 1997). Este índice reduz algumas fontes externas de ruído como, por exemplo, sombras de nuvens (JUSTICE et al., 1998). Já o EVI é uma variante do NDVI e foi desenvolvido para minimizar os efeitos tanto do solo quanto das influências de sinal de fundo do dossel e da atmosfera, sendo mais sensível regiões de alta biomassa (HUETE et al., 2002; JUSTICE et al., 1998).

#### 1.4.2.2.2 Filtragem e suavização de séries temporais

Em geral, as STIS são consideradas muito ruidosas, mesmo no caso dos produtos MODIS, onde já foram selecionados previamente pixels para a janela temporal de 16 dias. Se por um lado esta composição do MODIS apresenta alta resolução temporal, por outro lado, pode apresentar pixels contaminados com informações espectrais que não são referentes aos do

uso e cobertura da terra, como ruídos e interferências atmosféricas, que podem erroneamente serem reconhecidos como outros tipos de cultura. Por este motivo, diversos autores consideram que um dos passos mais importantes para este tipo de estudo é o pré-processamento das séries temporais para remoção de ruído, geralmente causados pela presença de nuvens (GÓMEZ; WHITE; WULDER, 2016). Vários algoritmos para remoção de ruído em séries temporais têm sido utilizados, entre eles, o suavizador de Savitzky-Golay (CHEN et al., 2004), funções Gaussianas assimétricas (JÖNSSON; EKLUNDH, 2004) e Double-logistic(JÖNSSON; EKLUNDH, 2004; ZHANG, 2003). O filtro *Savitzky-Golay* é um dos mais utilizados, principalmente nos estudos desenvolvidos no Brasil, e apresenta uma significativa vantagem por preservar características iniciais como valores mínimos e máximos, sendo considerados mais eficazes quando se utilizam STIS do NDVI.( Chen et al., 2004).

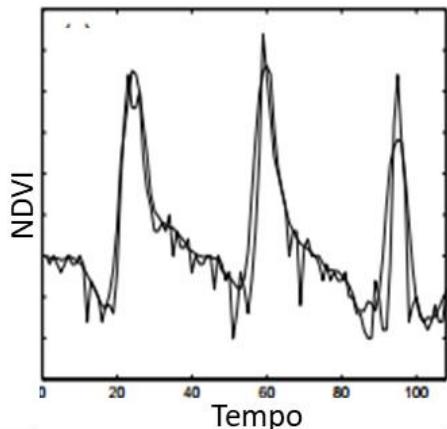
O Savitzky-Golay suaviza os dados suprimindo os ruídos e substituindo cada valor de dados  $y_i$ ,  $i = 1, \dots, N$  por uma combinação linear de valores próximos em uma janela.

(Equação3)

$$\sum_{j=-n}^n \binom{n}{k} c_j y_i + j.$$

Este método, de forma simplificada, pode ser considerado como uma média móvel, sendo os pesos,  $c_j = 1/(2n + 1)$ , e o valor de dados  $y_i$  substituído pela média dos valores na janela definida (Jönsson e Eklundh (2004)). A Figura 10 apresenta um exemplo da filtragem por Savitzky-Golay.

Figura 10 - Exemplo de filtragem e suavização por SG

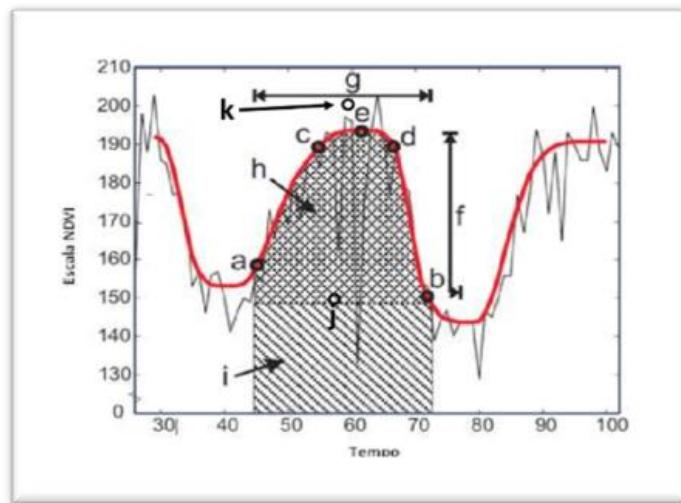


#### 1.4.2.2.3 Métricas fenológicas

A alta dimensionalidade de atributos, em geral, é considerada um problema para os algoritmos de classificação de imagens de satélite, ou seja, há um pressuposto de que quanto maior a quantidade de imagens de entrada, mais problemas o algoritmo poderá enfrentar, não somente por refletir no aumento do custo computacional, mas também devido à dificuldade de encontrar padrões significativos que possibilitem uma boa acurácia na classificação. O problema, da redundância de atributos, chegou a ser classificada como a “maldição da dimensionalidade” (DUDA; HART; STORK, 2000; JUDITSKY et al., 1995). Quando se utiliza Séries Temporais de Imagens de Satélites, entende-se que quanto maior a dimensionalidade temporal, melhor será a reconstrução do ciclo fenológico, essencial para a compreensão dos sistemas de produção agrícola. Desta forma, Gómez; White; Wulder, (2016) sugerem a seleção de um único atributo descritor, geralmente um tipo de Índice de Vegetação, a fim de se reduzir a dimensionalidade. Eles apontam ainda que em alguns casos, a fim de reduzir ainda mais a dimensionalidade, deve-se extraír métricas fenológicas, ou seja, atributos fenológicos das STIS.

Jönsson e Eklundh (2004) desenvolveram o programa TIMESAT que tem por objetivo a extração de informações sobre a fenologia da vegetação com base nos ciclos fenológicos a partir de dados de IV oriundos de produtos obtidos por sensores remotos. Todas as informações extraídas a partir deste programa advém de séries temporais, que inicialmente devem ser filtradas e suavizadas num estágio de pré-processamento. Após este procedimento de suavização, o TIMESAT extraí 11 atributos da série temporal, criando arquivos matriciais de métricas fenológicas. A **Erro! Fonte de referência não encontrada.** apresenta as métricas que podem ser extraídas pelo TIMESAT.

Figura 11 - Métricas extraídas pelo TIMESAT. Adaptado de Jönsson e Eklundh (2004) e Htitiou et al (2019)



Na **Figura 11**, estão representadas as séries NDVI original (preto) e após a aplicação do filtro (vermelho). As 11 métricas fenológicas são: *a* e *b* que representam: início e fim do ciclo fenológico, já os pontos *c* e *d* representam o valor médio d e tempo para que respectivamente a curva do ciclo à esquerda e à direita cresceu decresceu 80% de distribuição dos dados, o ponto *e* refere-se ao ponto mais alto, enquanto o ponto *f* diz respeito à amplitude fenológica e o ponto *g* a duração do ciclo fenológico. As integrais *h* e *i* demonstram o efeito cumulativo de crescimento da vegetação. O ponto *j* é o valor mais baixo e *k* é o meio do ciclo fenológico.

As métricas fenológicas são expressas pelas seguintes abreviações:

- Início do ciclo Fenológico ‘a’ (SOS);
- Fim do ciclo fenológico ‘b’ (EOS);
- Nível de 80% de distribuição dos dados à esquerda ‘c’ (L Derivative);
- Nível de 80% de distribuição dos dados à direita ‘d’ (R Derivative);
- Ponto mais alto de NDVI ‘e’ (Peack);
- Amplitude sazonal ‘f’ (Amplitude);
- Duração da estação ‘g’ (LOS);
- Integral Menor ‘h’ (S. Integral);
- Integral Maior ‘i’ (L. Integral);
- Valor de base da série ‘j’ (Base Value).
- Meio do ciclo fenológico ‘k’ (MOS).

Conforme indicado na Figura 11, a métrica SOS (a) indica o início da estação do ciclo fenológico, EOS (b) marca o fim do ciclo fenológico. As métricas L Derivative (c) e R-Derivative (d) representam a taxa de variação (Derivadas da borda Esquerda e Direita), onde aumenta a um valor de 80%. Em relação ao nível mínimo Base Value, (j) é o valor de base e Peack, ao valor máximo, ou seja, o pico atingido pelo IV (e). A métrica referente a Amplitude (f) é a razão entre as métricas (e) e (j). LOS, é a duração do ciclo, que se refere a métrica (g), é a diferença entre o final e o início do ciclo fenológico. S. Integral, primeira Integral Menor (h), refere-se à área da região entre a função ajustada e o nível médio dos valores mínimos da esquerda e da direita. Ela representa a vegetação sazonalmente ativa, sendo maior em florestas deciduais ou em culturas, quando comparadas com áreas de vegetação perene (JÖNSSON; EKLUNDH, 2004).

O TIMESAT possibilita a entrada de uma banda de qualidade dos dados, a fim de ponderar a suavização em pixels mais ou menos confiáveis, com valores que variam entre 0 e 1. No caso da série MODIS, pode-se utilizar o produto *píxel reliability* para tal finalidade. Diversos autores que utilizaram este sistema para extração de métricas fenológicas para mapear uso da terra e o uso agrícola da terra (BENDINI et al., 2016; HTITIOU et al., 2019; JONATHAN et al., 2009; KUCHLER et al., 2020; CHEN et al., 2018; PAN et al., 2015; XU; CONRAD; DOKTOR, 2017).

Remetemos o leitor a JÖNSSON; EKLUNDH (2004) para uma melhor compreensão acerca da extração de métricas fenológicas a partir do TIMESAT.

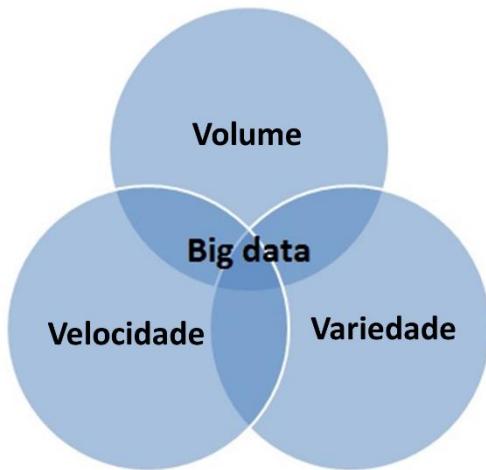
## 1.5 Big data e observação da Terra, uma estratégia

### 1.5.1 Big Earth Observation Data

A área de tecnologia vem se transformando rapidamente. Na última década estamos experimentando um aumento exponencial na produção e consumo de dados estruturados e não estruturados em um mundo cada vez mais conectado e digitalizado. Formas tradicionais de processamento e armazenamento de dados começam a se tornar insuficientes para esta nova realidade, emergindo ainda na década de 90 o conceito de “*big data*”, que a partir de 2006 foi amplamente difundido atingindo a indústria e a academia (LI et al., 2016). Para melhor definir este termo, o *big data* é usualmente dividido em três propriedades, mais conhecidas como os 3

Vs (Volume, Variedade e Velocidade) (Figura 12) **Erro! Fonte de referência não encontrada.**

Figura 12 - Os 3 Vs que compõe o Big Data.



Fonte: Adaptado de Big Data LND 2018

O volume, que é uma característica inerente do *big data*, é o V que apresenta os grandes desafios iniciais por se tratar do armazenamento e análise desta crescente produção e disponibilidade de dados (CHI et al., 2016; LI et al., 2016).

A variedade de formatos e fontes presentes neste grande volume de dados é representada pelo segundo V. Esta propriedade demanda diversos esforços tecnológicos necessários para manipular diferentes tipos de dados com estruturas complexas (TAMIMINIA et al., 2020).

O terceiro V lida com a velocidade necessária para tratamento dos fluxos de dados emergentes de diferentes fontes (LI et al., 2016).

Esta transição para o *big data* está corrente em toda área de tecnologia, inclusive na área espacial. O crescente volume de dados que descreve a superfície da Terra está sendo gerado a bordo de inúmeros novos satélites, incluindo a popularização dos *CubeSats* (nano satélites), Veículos Aéreos Não Tripulados (VANTS), novos equipamentos a bordo de aviões e a explosão de dados de geo-localização, onde cada indivíduo conectado ao seu *smartfone* pode ser um produtor e consumidor de dados espaciais. Este cenário vem transformando a pesquisa geográfica de um ambiente historicamente marcado pela escassez de dados para um ambiente rico, com grandes volumes e fluxos de dados (MILLER; GOODCHILD, 2014). A diversidade de fontes e formatos com dados cada vez mais acessíveis dão origem a ideia do *big data espacial* ou *geo-big data* (LI et al., 2016).

Com uma característica própria dentro do *geo-big data*, a *big data* de dados de Observação da Terra apresenta particulares. Atualmente, os satélites nos fornecem mais de 50 terabytes de dados por dia para registro da superfície da Terra (ESA, 2019), o que imprime uma diversidade de propriedades relacionadas a resoluções espaciais, temporais, espectrais, de ângulo, polarização, etc. Esta diversidade de possibilidades de dados cada vez mais acessíveis dá origem ao termo *Big Earth Observation Data* (BEOD) (Liu, 2015; Li et al., 2016; Haifa 2020).

Mesmo com esta quantidade e diversidade de dados disponíveis, sua profunda utilização ainda é limitada. Segundo Câmara et al. (2016), a maioria dos métodos para tratamento de dados de sensoriamento remoto ainda são baseados em arquivos, como exemplo eles apontam que para mapear o Brasil com índices de vegetação do MODIS de 2002 a 2014, seriam necessários aproximadamente 12.000 arquivos independentes. Tratar este volume de dados imprime fortes limitações aos métodos clássicos de processamento, uma vez que a análise de arquivos individuais forçava testes metodológicos particularizados em pequenas áreas e com recorte temporal limitado. Segundo os mesmos autores, o BEOD possibilita mudar esta abordagem, evoluindo para uma abordagem de mapeamento de grandes áreas, onde uma metodologia poderá ser testada por inteiro.

Dois padrões de arquitetura de sistema são comumente usados no BEOD. O primeiro são sistemas de computação de alto desempenho baseados em cluster, onde enormes questões computacionais são endereçadas e realizadas pela cooperação de vários computadores, apresentando uma imagem de sistema único (MA et al., 2015; PLAZA; CHANG, 2007). Estes sistemas apresentam uma enorme capacidade computacional, porém ainda sofrem significativo impacto ao processar enormes volumes de dados (TAMIMINIA et al., 2020). A segunda arquitetura, baseada na plataforma em nuvem, virtualizam a infraestrutura de supercomputação como computadores físicos reais, oferecendo mais acessibilidade com processadores, memória e tamanho de discos flexíveis, (MA et al., 2015).

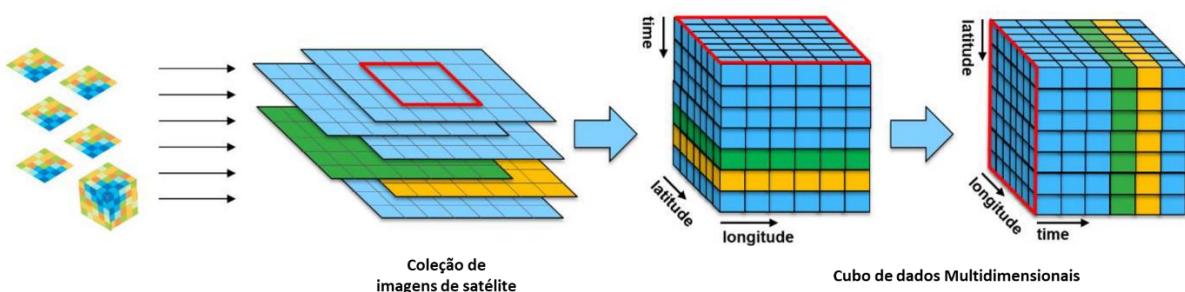
As tecnologias que irão compor estas arquiteturas, podem variar principalmente entre os bancos de dados de *Array multidimensionais distribuídos*, como SciDB (STONEBRAKER et al., 2013), extensões de DBMS objeto-relacional, como o *Rasdaman* (BAUMANN et al., 1998) e a paralelização e computação distribuída, MapReduce (GORELICK et al., 2017).

O desenvolvimento destes sistemas e plataformas computacionais e a popularização dos computadores de alta performance para computação em larga escala vem se popularizando e caindo consideravelmente seus custos de investimento (COSSU et al., 2010; GORELICK et al.,

2017; NEMANI et al., 2011). Isto impulsiona a criação de estruturas tanto comerciais, colaborativas, quanto governamentais baseadas em soluções de *Big Earth Observation Data*.

O BEOD potencializa a utilização de séries temporais de imagens de satélite com a criação de estruturas de Cubo de dados. Segundo Killough, (2019), Cubo de dados de observação da Terra pode ser definido como um *Array multidimensional de valores (espaço, tempo, propriedade)* usado para descrever uma sequência temporal de imagens (**Figura 13**).

Figura 13 - Cubo de Dados: Adaptado de (KOPP et al., 2019)



Iniciativas nacionais de construção de cubos de dados estão em andamento para resolver essas questões, como o Cubo de Dados Australiano (LEWIS et al., 2017), o Cubo de Dados Suíço (GIULIANI et al., 2017), o Cubo de Dados Americano (ASMARYAN et al., 2019), o *Catalan Data Cube* (MASO et al., 2019) e o *Africa Cube of Regional Data* (KILLOUGH, 2019). No Brasil, o projeto *Brazilian Data Cube*, liderado pelo INPE (Instituto Nacional de Pesquisas Espaciais) tem como um de seus objetivos criar cubos de dados multidimensionais com três ou mais dimensões, incluindo espaço, tempo e propriedades derivadas do espectro eletromagnético, principalmente para apoiar a análise de imagens de satélite de séries temporais. Essa estrutura conta com tecnologias de *big data*, como computação em nuvem e ambientes de processamento distribuído, para criar, armazenar e processar esses cubos de dados (FERREIRA et al., 2020).

Recentemente, o *Google Earth Engine* (GEE) está ganhando destaque na área de *Big Earth Observation Data*. GEE é uma plataforma baseada em nuvem que permite o processamento paralelizado de dados espaciais em escala global usando a nuvem do Google (GORELICK et al., 2017). Além da capacidade de processamento disponibilizada gratuitamente, o GEE hospeda dados na ordem de petabyte de mais de 40 anos de dados de sensoriamento remoto, como Landsat, MODIS, Sentinel 1, 2. A plataforma GEE aproveita a

infraestrutura computacional do *Google* para permitir o processamento paralelo de dados espaciais a fim de reduzir tempo. Sua infraestrutura conta com computação paralela, rotinas, biblioteca de imagens de sensoriamento remoto em nuvens, soluções de processamento baseadas em aprendizado de máquina, tudo acessado e controlado por meio de uma interface de programação de aplicativos (API) acessível pela Internet de forma livre.

Taminina et al. (2020), em seus 349 artigos revisados com pesquisas que utilizam o GEE, indicam que a maioria dos artigos se destinam ao mapeamento agrícola, sem significativos destaques aos sistemas de cultivo sequencial e nenhum com foco para a detecção dos sistemas integrados. Porém esta constatação dos autores é oposta à realidade anteriormente citada, onde apenas 10% dos artigos de sensoriamento remoto são dedicados à agricultura. No caso da utilização do GEE, a grande maioria dos artigos utiliza imagens multitemporais em escala regional e até global, apresentando a grande aplicação do BEOD. Uma das principais iniciativas no Brasil, o Mapbiomas, utiliza a plataforma GEE para o mapeamento anual do uso e cobertura da terra no país e atualmente possui mapas anuais de 1985 a 2019 (SOUZA et al., 2020). Dentre os 6 principais grupos de classes, o Mapbiomas, um deles concentra-se na agricultura, que além das classes pastagem, mosaico agrícola e pastagem, contém as subclasse de culturas perenes, soja, cana-de-açúcar e outras culturas temporárias, tornando-se uma importante fonte de dados e informações sobre uso e cobertura da terra e mudanças no uso e cobertura da terra em todo o país.

### 1.5.2 Mineração de dados espaciais e aprendizado de máquina

O grande volume de dados que se impõe como nova realidade nos tempos atuais, requer o desenvolvimento de soluções direcionadas para o desafio de tratar uma enorme quantidade de informações. O que no passado recente era um grande problema, atualmente pode ser visto como uma solução, considerando-se a possibilidade de tratamento do *big data* que possibilita a extração de correlações entre o grande volume de dados. As técnicas vêm evoluindo com a tecnologia de mineração de dados, aprendizagem estatística e de máquina, que tem como o principal objetivo, identificar padrões ocultos em grandes massas de dados para transformar em informação (PEI et al., 2020). Os métodos de análise de dados mais tradicionais também podem estar relacionados a mineração de dados. A regressão de dados é um exemplo, na qual seu uso

em análise de séries temporais é anterior ao campo da mineração de dados, uma vez que surgiram através da junção das análise de séries temporais, econometria e técnicas de tratamento de dados espaciais (LI et al., 2016). Atualmente, o aprendizado de máquina e aprendizagem estatística vêm sendo amplamente utilizados na área de *Big Earth Observation Data* e podem ser divididos em dois principais grupos: Os paramétricos e os não paramétricos (HOLLOWAY; MENGERSEN, 2018). O primeiro grupo utiliza uma quantidade de parâmetros, ou suposições que independem do número de amostras de treinamento, expressando em um processamento mais rápido, porém o processo de aprendizagem também pode ser mais limitado (TAMIMINIA et al., 2020). No caso dos algoritmos não paramétricos, um número flexível de parâmetros são usados e apresentam a necessidade de uma quantidade maior de amostras para o aprendizado.

No caso de técnica de *deep learning*, por exemplo, faz-se necessário uma grande quantidade de dados em seu aprendizado, um exemplo é o uso de segmentação semântica. A segmentação é de fundamental importância para a fase de análise do processo de classificação, pois por meio dela torna-se possível extrair informações valiosas a partir das imagens digitais. Porto et al (PORTO; SIMÕES; FERRAZ, 2020), por exemplo, implementaram do modelo Deeplabv3+ para segmentar imagens de pastagem degradadas a fim de diferenciar classe gramíneas da classe plantas daninhas (também conhecidas como invasoras). A tarefa de segmentação semântica é complexa e é uma das poucas áreas de visão computacional em que o desempenho das redes neurais profundas está além da performance humana.

Os Algorítmos como o *Support Vector Machine* (SVM) e o *Random Forest* (RF), muito utilizados em BEOD são modelos não paramétricos e são muito utilizados na área de BEOD por apresentarem significativa flexibilidade e a possibilidade de processar um grande volume de dados sem necessidade de conhecimento prévio (TAMIMINIA et al., 2020).

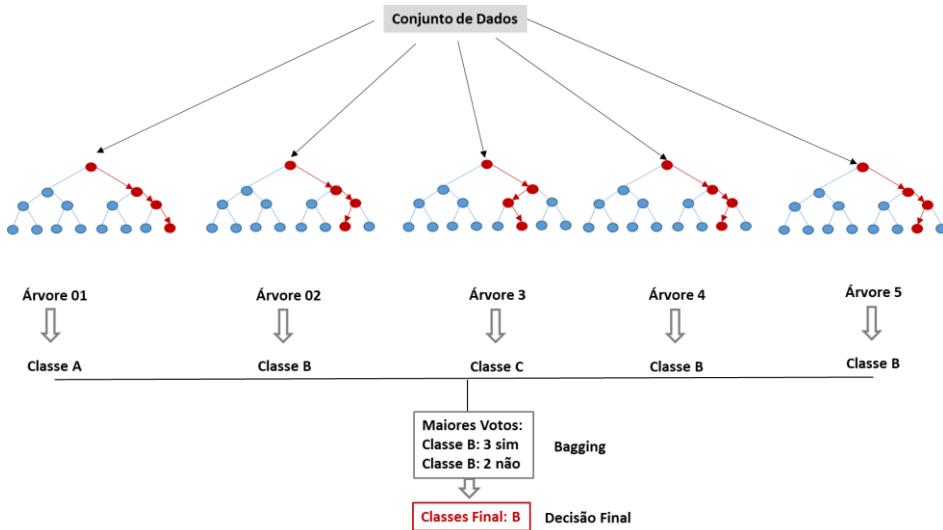
#### 1.5.2.1 Classificador *Random Forest*

*Random Forest* é uma técnica de aprendizado de máquina que gera uma infinidade de árvores de decisão aleatórias que são agregadas, para então gerar uma classificação (BREIMAN, 2001). Cada árvore de classificação é construída de um conjunto amostrado aleatoriamente composto por aproximadamente um terço do conjunto completo de dados, que será chamado no termo em inglês de *bootstraped dataset* (CUTLER et al., 2007). Cada amostra

irá percorrer aleatoriamente e individualmente cada árvore da floresta, de forma que cada árvore vai proteger a outra de seus possíveis erros individuais. Desta forma, embora algumas árvores possam estar erradas, muitas outras estarão corretas, através de votação do conjunto de resultados de cada árvore. Este processo que leva em consideração a maioria é chamado de *baging*. A **Figura 14** apresenta um exemplo de uma floresta aleatória com 5 árvores, onde uma *pseuda* amostra foi classificada diferentemente em cada árvore aleatória, construindo um *bag* com 3 votos para a classe B e dois votos para classes diferentes. Nesta simulação, a decisão final é que esta amostra fará parte da classe B pelo fato de haver mais votos para esta classe. Diferente deste exemplo, uma floresta típica de análise com RF pode chegar a 500 árvores aleatórias (CUTLER, 2007). Em estudos de classificação de uso e cobertura da terra, o classificador é considerado estável, além de envolver poucos parâmetros definidos pelo usuário e mesmo assim, obter bons níveis gerais de acurácia (LAWRENCE; WOOD; SHELEY, 2006). Também é considerado robusto, fácil de treinar, menos sensível à qualidade dos dados de treinamento e há menos parâmetros para ajustar em comparação com outros classificadores não paramétricos (BELGIU; DRĂGUȚ, 2016; MAHDIANPARI et al., 2020).

Mesmo que a complexidade aumente com o número de árvores e dados de treinamento, esta abordagem pode aumentar significativamente a acurácia da classificação (MAHDIANPARI et al., 2018). Belgiu e Drăguț (2016) relataram que a abordagem *Random Forest* aumenta a acurácia da classificação, especialmente para entrada de alta dimensionalidade de dados como imagens é o caso das imagens hiperespectrais. Em alguns casos, a baixa quantidade de dados de treinamento causa classificação incorreta.

Figura 14 - Esquema representativo de floresta aleatória.



Fonte: próprio autor.

Dos resultados gerados através da abordagem de RF, a diminuição média na precisão (DMP) para uma variável permite avaliar a importância (o grau em que uma variável é discriminante) de cada variável usado para classificação. Quanto mais a precisão do RF diminui devido à exclusão de uma única variável, mais importante é essa variável. Consequentemente, valores mais altos de DPM indicam variáveis que são mais importantes para a classificação (CUTLER, 2007).

### 1.5.2.2 Avaliação da acurácia

Qualquer processo de classificação, seja baseado em métodos clássicos, supervisionados ou não, precisa ser avaliado segundo sua acurácia. Neste sentido, geralmente a precisão do mapa pode ser quantificada criando uma matriz de erro (também comumente chamada de matriz de confusão), que compara o resultado da classificação com uma base de referência (BHOLANATH et al., 2013). Esta base de referência pode ser extraída de diversas formas a depender do alvo a ser mapeado. No caso de algoritmos como o RF e o SVM, esta etapa de validação pode ser realizada antes mesmo da classificação, ou seja, antes de ser aplicado ao modelo. Esta forma de validação é chamada de validação cruzada (CUTLER, 2007). Assim como apontado no item 2.5.2.1, para a composição do *bootstrap*, são geralmente selecionadas

2/3 das amostras totais para o treinamento do modelo RF, sobrando 1/3 destas amostras, que serão chamadas de *out of bag* (BREIMAN, 2001).

A validação cruzada é uma técnica comum na classificação de sensoriamento remoto que permite usar todo o conjunto de dados, o que é particularmente relevante quando o conjunto de dados é pequeno, além de apresentar mais confiança no desempenho do algoritmo e na qualidade dos dados (DIMA, 2018). A validação cruzada utiliza da matriz de erros para gerar o coeficiente de acerto, geralmente expresso na porcentagem de acertos.

Seja na validação cruzada, ou nos métodos clássicos de validação de resultados, é fundamental que se considere dois aspectos. O primeiro se baseia na atribuição de classes especificadas pelos dados de referência, para então calcular qual percentagem destes pontos é efetivamente classificada com o mesmo rótulo pelo algoritmo. Este índice é chamado de acurácia do produtor. Inversamente, a acurácia do usuário se refere em tomar como referência o resultado da classificação, para então verificar cada classe a percentagem de pontos que foram corretamente classificados segundo a base de referência, representando a confiabilidade das atribuições de classes realizadas pelo algoritmo.

## 1.6 Considerações sobre o Capítulo

Neste capítulo foram tratados os principais conceitos relacionados a base teórica necessária ao desenvolvimento deste estudo, iniciando pelos conceitos de intensificação agrícola, agricultura brasileira, técnicas de sensoriamento remoto no monitoramento de uso e ocupação da terra, focados na agricultura e na intensificação sustentável, com foco nos sistemas integrados de produção. A base teórica discutida nesta sessão é necessária para a construção metodológica proposta e subsidiará a compreensão das escolhas feitas visando a construção do arcabouço metodológico.

## 2 ÁREA DE ESTUDOS

### 2.1 Seleção da área de estudos

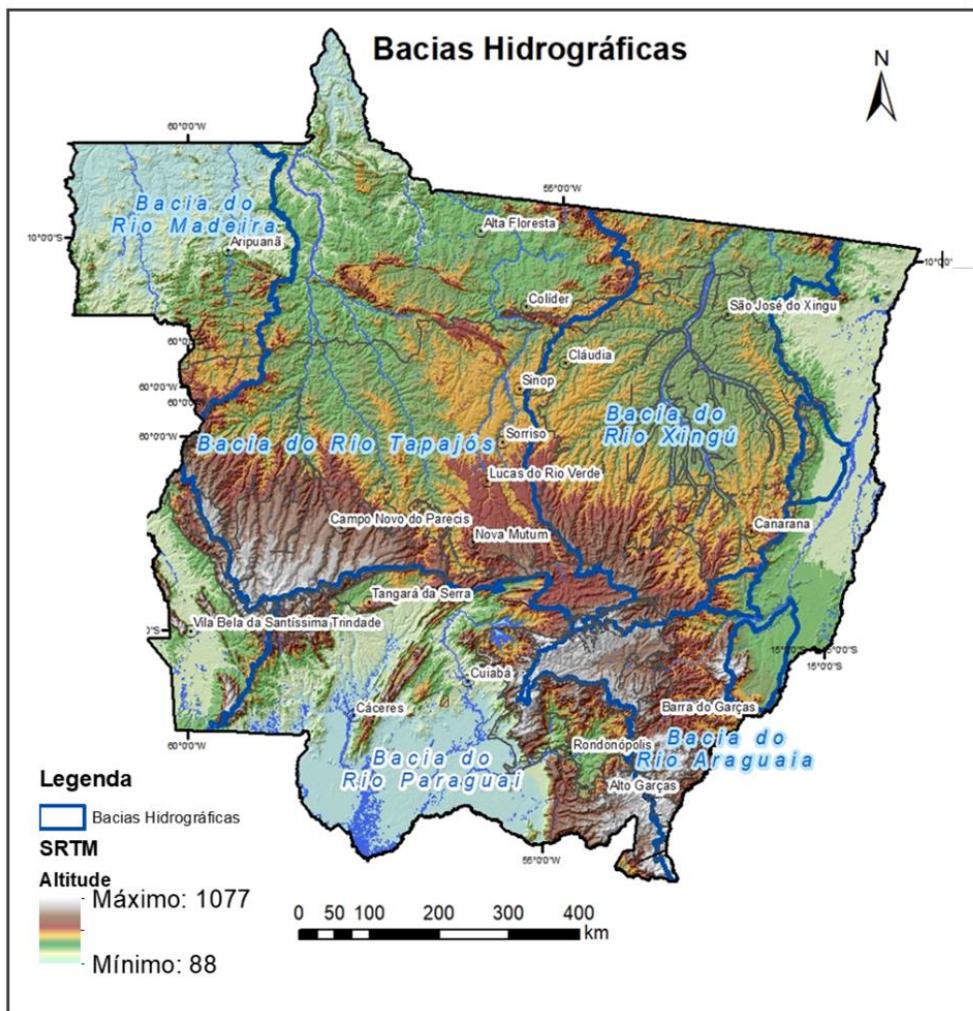
#### 2.1.1 Caracterização geográfica do estado do Mato Grosso

O estado de Mato Grosso (MT) se localiza na região Centro-Oeste do Brasil e, sendo o terceiro maior estado do país, faz limites ao norte com os estados do Amazonas e Pará, a Leste com Tocantins e Goiás, ao sul com Mato Grosso do Sul, a oeste com Bolívia e Rondônia.

Os diversos ecossistemas e ecótonos encontrados nos três Biomas que compõem o estado do Mato Grosso, condiciona a ocorrência de vegetação bastante diversificada. Apesar disto, 57% da cobertura vegetal é composta de fitofisionomias savânicas (Cerrado) e cerca de 30% são atribuídas as Florestas Estacionais, ficando o restante entre as demais formações existentes. Compõem a vegetação da região Norte quatro classes fitoecológicas: Cerrado (savana), Floresta Ombrófila Densa Tropical, Floresta Ombrófila Aberta Tropical e Floresta Estacional Decidual Tropical. Na região Central do estado, foram descritas cinco formações vegetacionais: Cerrado, Floresta Ombrófila Densa, Floresta Ombrófila Aberta, Floresta Estacional Semidecidual e Floresta Estacional Decidual. Na região Sul são encontradas quatro regiões fitoecológicas: Cerrado, Savana Estépica (Vegetação Chaquenha), Floresta Estacional Decidual e Floresta Estacional Semidecidual (VELOSO, 1974). A vegetação pantaneira se caracteriza por um mosaico composto por tipos vegetacionais diversos, com predominância de Cerrado e presença de tipos vegetacionais florestais, típicos do Bioma Amazônia, vegetação chaquenha e ecótonos com formações do Bioma Mata Atlântica (POTT; POTT, 2009).

O território do estado do MT, apresenta uma hidrografia bastante complexa com inúmeros rios de grande porte e uma extensa rede de drenagem. O planalto dos Parecis, que ocupa toda porção centro-norte do território, é o principal divisor de águas do estado, repartindo as águas para três grandes bacias hidrográficas: Bacia Amazônica, Bacia Platina e Bacia do Tocantins. Drenando cerca de 2/3 do território matogrossense a maior parte do estado se encontra na bacia amazônica Como principais sub-bacias, cabe colocar em destaque, as formadas pelos rios: Tapajós, Xingu, Madeira, Araguaia, Paraguai, Guaporé, Aripuanã, Sub-bacia do Juruena-Arinos, Teles Pires e seus vários tributários (**Figura 15**) (WEBSITE-GOV-MT).

Figura 15 - Mapa das principais bacias Hidrográficas.



Fonte: produzida pelo autor

O relevo do estado de Mato Grosso é caracterizado por amplas superfícies de aplainamento que abrangem os planaltos e chapadões e zonas de planícies, como a planície aluvial do médio Araguaia, situada a Oeste na fronteira com o estado de Goiás, e, a planície do Pantanal, localizada na porção Sudoeste do estado. As superfícies de aplainamentos de embasamento cristalino possuem altitudes na faixa de 400 a 800, sobre os quais se destacam os chapadões sedimentares. As superfícies aplainadas formam três unidades geomorfológicas distintas: planalto do Parecis, planalto dos Guimarães e o planalto do Taquari e Alto Araguaia

Localizado na porção central do estado, o planalto do Parecis, apresenta homogeneidade topográfica com dissecação predominantemente tabular, onde ocorrem unidades pedológicas das classes Argissolos Vermelhos e os Neossolos Quatzarênicos (ARAÚJO, 1982). Destaca-se

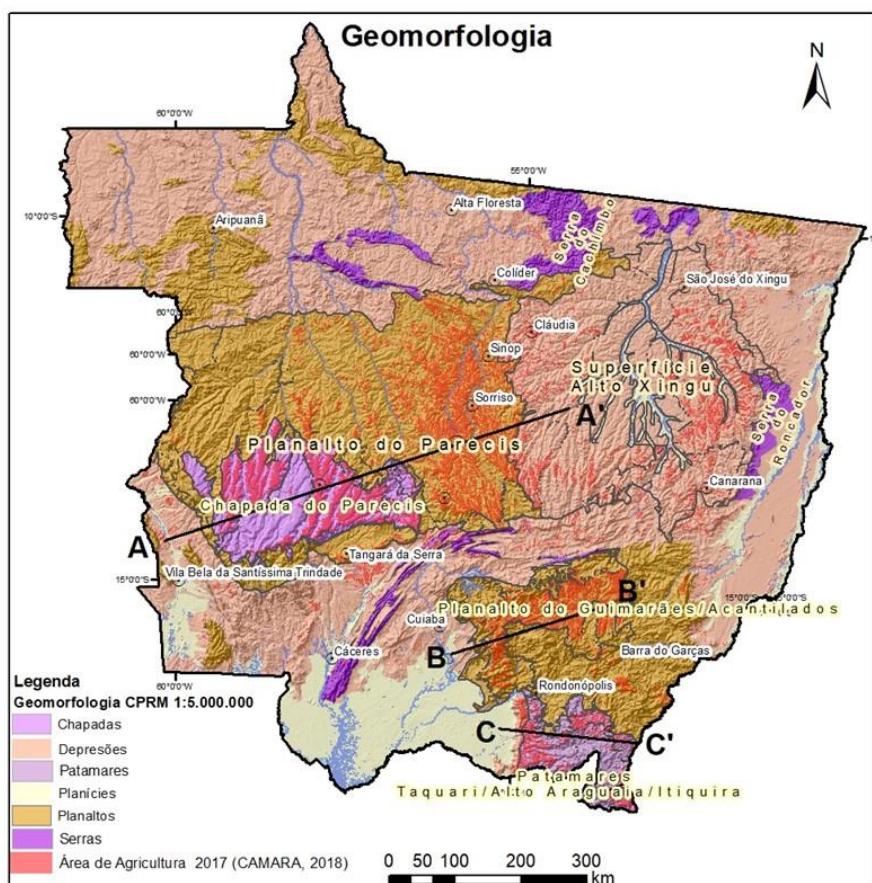
nesta unidade a Chapada do Parecis que constitui uma superfície sub nívelada extensa desenvolvida ao longo dos interflúvios, delimitados por rebordos erosivos (ARAÚJO, 1982).

A unidade geomorfológica Planalto dos Guimarães localiza-se no centro-sul do estado, possuindo elevações entre 650 a 800 metros de altitude constituí uma superfície aplainada, com predomínio de formas de suave dissecação elaboradas sobre os arenitos Bauru (SANTOS, 2000). É delimitada em quase toda sua extensão por escarpas erosivas e ressaltos topográficos e faz conexão com o Planalto dos Alcantilados.

A unidade geomorfológica do planalto do Taquari e Alto Araguaia, situando-se na região Sudeste do estado, é formada por patamares como os do Taquari, Alto Araguaia, Alto Garças e Itiquira, localmente chamadas de “chapadão”, principalmente entre as cidades de Campo Verde e Primavera do Leste (SANTOS, 2000)

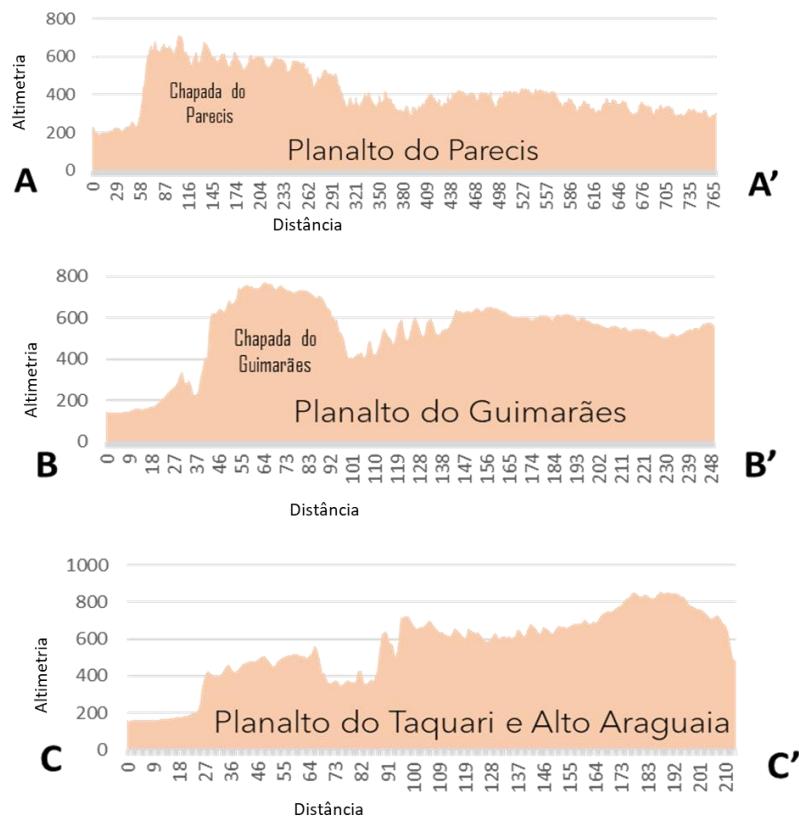
A Figura 1 apresenta a sobreposição da base 1:5.000.000 de geomorfologia do CPRM, as áreas de agricultura de 2017 mapeadas com séries temporais MODIS (CÂMARA et al., 2018) e o modelo digital de elevação do SRTM. É possível identificar as áreas agrícolas localizadas em toda a extensão dos interflúvios dos planaltos, chapadas e patamares pelo estado.

Figura 1 - Mapa Geomorfológico



**A Figura 17 Erro! Fonte de referência não encontrada.** apresenta os três cortes de perfis topográficos (um em cada principal sistemas de aplainamento do estado) indicados na Figura 1.

Figura 17 - Perfis topográficos dos sistemas de aplainamento



O estado também apresenta uma significativa variedade climática, sendo a precipitação pluviométrica o principal parâmetro para descrever as diferenças climáticas encontradas nas diferentes sub-regionais (ARVOR et al., 2013). Na porção mais ao norte do estado, a prevalência é do clima tropical super-úmido de monção e alta pluviosidade (2.000mm anuais) (ARVOR et al., 2013; DUBREUIL et al., 2004; IBGE, 2011). A região amazônica, em particular, apresenta elevados fluxos de calor latente provenientes da superfície, alto conteúdo de vapor d'água na atmosfera e, consequentemente, elevados índices pluviométricos. Os altos índices de pluviosidade e de cobertura de nuvens encontrados no norte do estado, constituem, segundo Fishch; Marengo & Nobre (1998), uma característica peculiar com grande variabilidade espaço-temporal. Considerando o estado do Mato Grosso como um todo, observa-se que a

variabilidade espacial, tanto da duração da estação chuvosa quanto dos totais de precipitação anual, ocorrem segundo um nítido gradiente Norte-Sul (DUBREUIL et al., 2004).

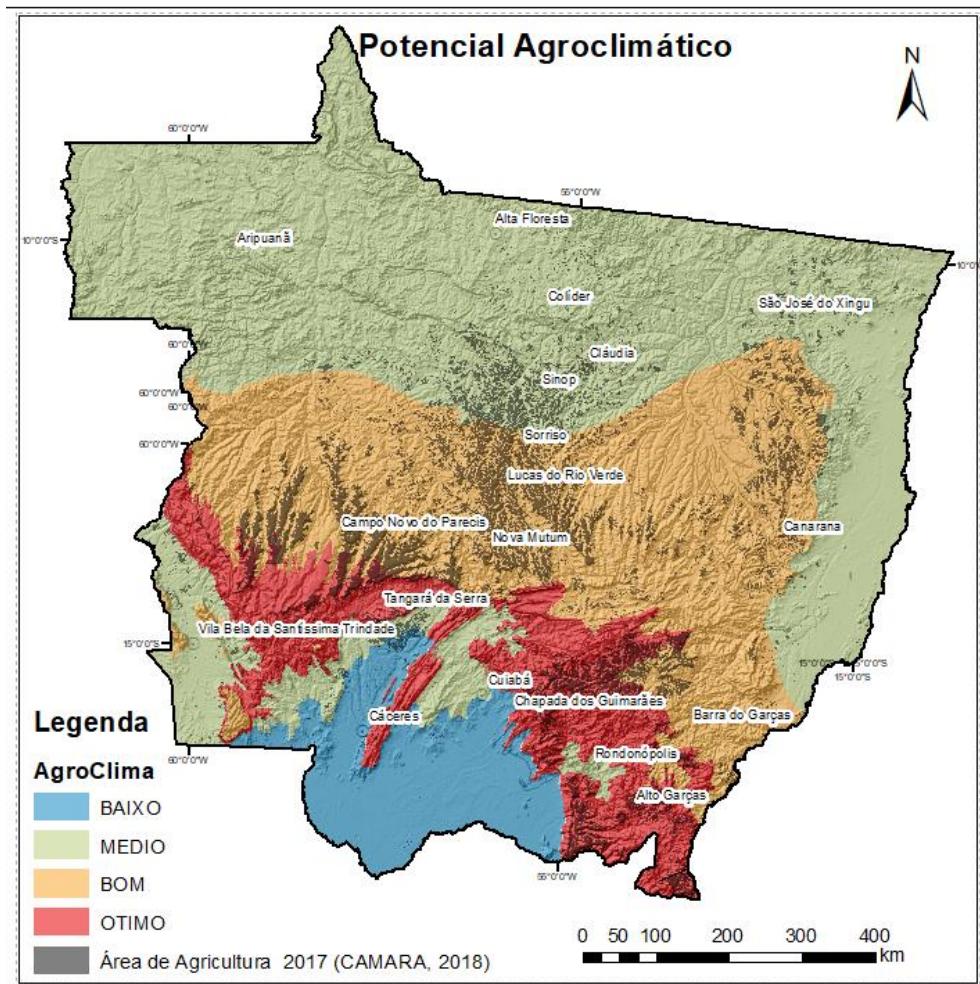
A variabilidade interanual do clima do estado de MT, em grande parte, está associada aos fenômenos “ENOS” (El-Niño e La-Niña – Oscilação Sul), a Zona de convergência do Atlântico Sul (ZCAS) e a Zona de Convergência Intertropical (ZCIT). Segundo Fishs & Marengo (1996), os fenômenos do El Niño e La Niña imprimem significativa variabilidade da circulação geral da atmosfera, onde o El Niño apesenta uma diminuição nos totais pluviométricos na região central da Amazônia, enquanto a La Niña se observa uma anomalia positiva de precipitação (ALVES; MACHADO; PRASAD, 2007; MARENKO et al., 2001).

A variabilidade intranual do estado de MT, por sua vez, é evidenciada entre as estações bem marcadas, secas e chuvosas. O período chuvoso na região pode estar associado à penetração de sistemas frontais da região sul, que estruturam e potencializam a convecção local. Enquanto o período de seca, sem grande atividade convectiva, ocorre entre os meses de maio e setembro. Os meses de abril são meses de transição entre os dois regimes (FISHS; MARENKO, 1996). A Alta Bolívia influencia o regime de precipitação do trimestre mais chuvoso, Dezembro, Janeiro, Fevereiro (DJF) nas regiões centrais e oeste da Amazônia enquanto que para o trimestre mais seco Junho, Julho, Agosto (JJA) o centro de máxima precipitação se desloca para a América Central (FISHS; MARENKO, 1996). Para a região sul do estado, observa-se uma diferenciação sazonal mais pronunciada em relação à duração das duas estações, evidenciada pela ocorrência de um período de mais longa estiagem (ARVOR et al., 2013; DUBREUIL et al., 2004).

O Zoneamento Ecológico Econômico do estado de Mato Grosso, realizado no ano 2000, apresentou, como um dos seus produtos, um mapa agroclimático para o estado elaborado a partir de uma série histórica de dados de 20 anos (SANTOS, 2000), no qual o potencial climático para a agricultura foi representado pelas seguintes classes ordinais: baixa, média, boa e ótima potencialidade climática

Observa-se que nas porções Norte e Oeste do estado de MT, e, em algumas poucas áreas ao Sul e a Sudoeste, associadas as bordas dos planaltos, o potencial agroclimático foi considerado médio. Enquanto ao Sul, associado a depressão e planície pantaneira, registrou-se um potencial agroclimático baixo. A região dos planaltos centrais, justamente a mais desenvolvida agricolalemente, o potencial agroclimático foi considerado bom para as atividades agropecuárias. Por fim, a porção mais ao Sul e a Sudeste dos planaltos apresentaram ótimas condições agroclimáticas.

Figura 18 - Potencial agroclimático e das áreas de agricultura com referência ao ano de 2017 do estado do Mato Grosso.

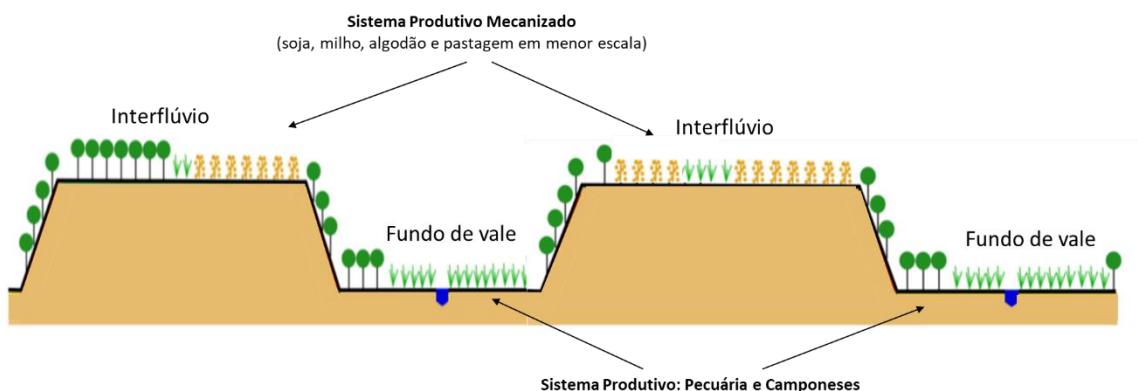


Com base na Figura 18, é possível observar, além da região localizada a Sudoeste, uma concentração das atividades agropecuárias nas regiões centrais do estado. Nesta região, de Bioma Cerrado, verifica-se uma predominância de áreas de agricultura consolidada em franca intensificação. As superfícies aplainadas dos planaltos matogrossense com extensas áreas planas para a agricultura mecanizada e solos e clima adequados, apresentam condições favoráveis para o desenvolvimento de sistemas de produção agropecuária de larga escala e alto rendimento. Nestas condições predomina uma agricultura empresarial, tecnificada, orientada à produção de grãos para a exportação. A pecuária dessas áreas também costuma apresentar índices de maior produtividade quando comparada a outras regiões do estado. Evidenciando como o meio físico exerce um papel importante na dinâmica de uso da terra e tem um peso significativo nas lógicas espaciais do desenvolvimento dos sistemas agrícolas (OSIS; LAURENT; POCCARD-CHAPUIS, 2019). Neste contexto, Raasch et al. (2019), observam

que a agricultura mecanizada ocupa as áreas planas nos interflúvios das chapadas e planaltos, enquanto a pecuária e a agricultura campesina ocupam as áreas de encosta e os fundo de vales

As frentes pioneiras de fronteira agrícola vêm se estabelecendo, dinamicamente, no Norte do estado, no contato com as florestas densas do bioma amazônico (LACERDA FILHO et al., 2004). A **Figura 19** apresenta uma representação esquemática da lógica espacial de ocupação e uso da terra em função da geomorfologia local. Esta mesma lógica também é descrita nos trabalhos de OSIS; LAURENT; POCCARD-CHAPUIS (2019) e de RAASCH; BEZERRA (2019).

Figura 19 - Esquema da lógica espacial dos sistemas de cultivo baseada na morfologia.



Fonte: Adaptado de (OSIS; LAURENT; POCCARD-CHAPUIS, 2019)

O pantanal Mato Grossense, por sua vez, não apresenta expressão significativa em termos de produção agropecuária de larga escala. A região do Pantanal, com relevos rebaixados e grandes áreas inundáveis, apresentam características peculiares que demandam práticas de manejo sustentáveis, bem adaptadas as características socioambientais regionais (EMBRAPA, 2011).

#### 2.1.1.1 Histórico da colonização da região e abertura de áreas

No início do século XX, as regiões Norte e Centro-Oeste do Brasil em seus interiores eram povoadas por populações tradicionais, em grande parte por indígenas, caboclos e ribeirinhos ao longo dos rios, sendo estes últimos grupos fixados na região após os grandes

ciclos da madeira e da borracha (THÉRY, 2006). A partir dos anos 1930-1940 o Estado novo voltou a organizar políticas de colonização na região. Políticas estas baseadas principalmente na tentativa, junto com os EUA, de retomar a produção de borracha na Amazônia, além da ideia de garantir soberania nacional nestas regiões. Estas ações foram marcadas pela chamada "Marcha para o Oeste" em 1937 que previu o fortalecimento dos laços com a Bolívia, a criação de quatro territórios federais, a criação da cidade de Goiânia (1932) e as primeiras colonizações agrícolas no cerrado com projetos estabelecidos nos estados de Goiás, Mato Grosso do Sul e Paraná (DROULERS, 2001; NÉDÉLEC, 2005). Estas políticas continuam nas décadas subsequentes e foram potencializadas, principalmente na região amazônica durante os governos militares (1964-1985).

Estes governos promoveram a abertura de novas frentes de colonização, baseadas no ideário de ‘vazio demográfico’ atribuído à região amazônica, desconsiderando formas de organização social, conhecimento e produção tradicionais que ali existiam (PORTO-GONÇALVES, 2015). O Plano de Integração Nacional (PIN) teve o papel de viabilizar estes projetos desenvolvimentistas, responsáveis por coordenar o processo, melhorando e criando a infraestrutura necessária através da construção de rodovias como a Transamazônica e a Cuiabá-Santarém que tinha como principal slogan "integrar para não entregar" (SUMMERS, 2008). Este programa de governo pode ser considerado como a continuidade da “marcha para o oeste”, com uma estratégia geopolítica articulada entre estado e capital privado, estimulando fluxos migratórios de outras regiões do país para estas regiões “periféricas”.

Além das estratégias geopolíticas e de visão de desenvolvimento, esta política teve grande papel no arrefecimento dos movimentos sociais que começaram a eclodir em várias regiões brasileiras na busca de acesso à terra e renda que marcou o início dos anos 60 (OLIVEIRA, 2001). Na busca por administrar e reprimir os movimentos populares, o governo usou os projetos de colonização como válvula de escape, o que por outro lado promoveu novos embates aprofundando as contradições anteriormente existentes (OLIVEIRA, 2001). A estrutura vigente havia sido perpetuada com a criação de novos latifundiários provenientes de grandes capitalistas nacionais e internacionais usando a estrutura da SUDAM (1966) e SUDECO (1967), que foram criados a fim de atrair colonos capitalizados para a Região. A criação destas superintendências e do BASA, no início de 1970 colocou à disposição de latifundiários e fazendeiros, estímulos e favores fiscais e de crédito, que contribuíram para a formação e o crescimento de latifúndios, fazendas ou empresas de extrativismo e mineração.

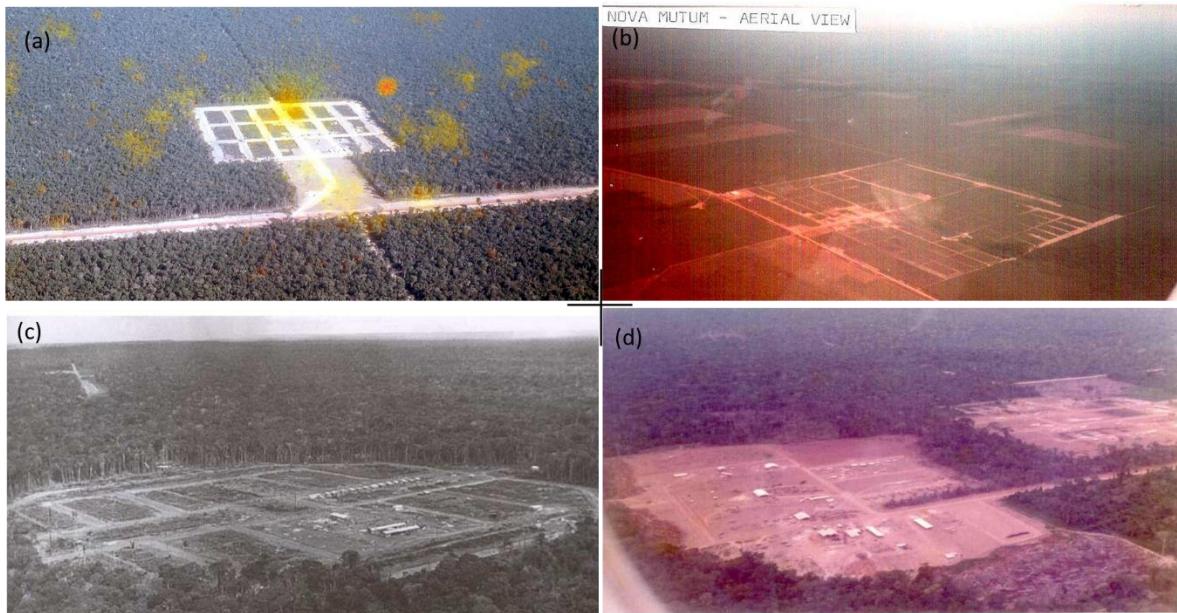
Dessa forma, intensificou-se a migração de trabalhadores, empresários, empreiteiros e fazendeiros para diferentes áreas da Amazônia (SUMMERS, 2008).

O estado do Mato Grosso ocupou grande destaque neste processo, sendo complementado com todos os programas governamentais, se tornando área preferencial para os projetos privados de colonização, concentrando cerca de 90% deste tipo de projeto em todo o país. A colonização privada ou mista destinada a produtores capitalizados no Sul está localizada principalmente no Mato Grosso através dos Projetos de Assentamentos Conjuntos (PACs) ao longo da BR-163 ((NÉDÉLEC, 2005). A modernização agrícola no Sul e Sudeste do país, forçaram a necessidade histórica de migração para os filhos de camponeses da região, o que representou 57% dos migrantes da década de 70 que foram para o Mato Grosso. Estes eram provenientes do centro-sul do país, onde 21% deste total de migrantes eram provenientes do estado do Paraná. A maioria das empresas de colonização se aproveitaram deste rápido deslocamento populacional e construíram escritórios no Sul do país. O INCRA autorizou cerca de 36 empresas privadas de colonização a operarem no estado de Mato Grosso, podemos destacar as principais como:

- (a) A Conomali – Colonizadora Noroeste Matogrossense S/A, de propriedade dos irmãos Mayer de Santa Rosa-RS, que colonizou a gleba Arinos com mais de 240 mil ha, onde fundou Porto dos Gaúchos.
- (b) A Incol – Imóveis e Colonizadora Ltda. Fundaram as cidades de São José do Rio Claro e Brianorte.
- (c) A Colonizadora Sinop S/A- Implantou no eixo da Cuiabá-Santarém, quatro cidades: Sinop, Vera, Santa Carmem e Cláudia.
- (d) A Indeco S/a – Integração, Desenvolvimento e Colonização de propriedade de Ariosto da Riva, que segundo Ariovaldo, o proprietário afirma ter adquirido 500mil ha em 1971 pelo preço de seis maços de cigarro por hectare. Desta gleba três municípios atuais foram criados: Alta Floresta, Paranaíta e Apiacás.
- (e) A Mutum Agropecuária Ltda., implantou ao longo da Cuiabá-Santarém, o projeto nova Mutum com área superior a 100 000 ha.

**A Erro! Fonte de referência não encontrada.** apresenta a abertura de áreas e o início da colonização nas cidades de Nova Mutum, SINOP e Alta Floreta.

Figura 20 - Abertura de áreas para início da colonização. (a) SINOP Julho de 1973 às margens da BR – 163 (Acervo Fotográfico TenCelJaimeRibeiro); (b) Nova Mutum início da década de 70; (c) Juína 1976; (d) Alta Floresta década de 70.



Os colonizadores pioneiros se autodenominavam como os “bandeirantes do século XX” que ao adentrar sobre a mata buscavam recursos e planejando a abertura de áreas para seus projetos privados de agropecuária, faziam contatos com povos tradicionais, forçando gradativamente a uma marcha destes povos que ali habitavam para a realocação e confinamento em reservas e parques criados e em criação (**Figura 21**).

Figura 21 - Contato entre colonos e povos indígenas em Porto dos Gaúchos e trabalhadores para a abertura de áreas em Alta Floresta



Fonte: Google fotos

Inevitavelmente, em grande parte dos casos, com a efetivação dos empreendimentos da colonização, estes contatos foram marcados por significativos conflitos territoriais e verdadeiros massacres a nações indígenas. Um dos casos emblemáticos ocorreu em 1973 quando o governo estadual do Mato Grosso solicitou ao senado a autorização de venda de 2 milhões de hectares de terras em Aripuanã, município com grande concentração de povos indígenas, principalmente os Cintas-Largas e Araras. Esta região ainda é grande palco de disputas e massacres entre garimpeiros, seringueiros e indígenas, em 2007 chegou a ocupar a oitava posição de município mais violento do Brasil segundo relatório da Organização dos Estados Íbero-Americanos para a Educação, a Ciência e a Cultura (OEA). As Terras Indígenas de Aripuanã, Serra Morena e Arara Rio Branco somente foram criadas entre 1988 e 1998.

Por outro lado, o estado do Mato Grosso se apresenta como palco de grande relevância para a política indigenista do Brasil, desde a atuação do Marechal Rondon até a grande incursão da expedição dos irmãos Villas Bôas no estado. Ambos tiveram grande importância para a criação do chamado cartão de visita da política indigenista brasileira, o PIX - Parque Indígena do Xingu, com proposta inicial em 1952 e criado em 1961(INSTITUTO SOCIALMBIENTAL, 2013).

Vários dos povos ameaçados pelas frentes colonizadoras que habitavam áreas ao redor do Xingú, foram manejados para dentro do Parque. Os índios, observaram a forma veloz da colonização, que apresentou em grande escala a derrubada da mata, degradação dos rios e a formação de extensa malha viária no entorno do Parque (INSTITUTO SOCIALMBIENTAL, 2013). Já pelo lado dos colonizadores, que viam as florestas, e os rios como recursos a serem explorados e vencidos para um modelo de desenvolvimento que seus antepassados realizaram em outras regiões do país. Nesta visão não cabe a ideia da floresta em pé, a presença de Unidades de Conservação, modos de pequena produção camponesa e terras indígenas. Estes significavam verdadeiramente um obstáculo, por representar o oposto do que acreditavam.

### 2.1.2 Desenvolvimento da agropecuária

Atualmente, o Mato Grosso é um dos principais produtores nacionais de gado e soja e o seu modelo expansionista tem sido frequentemente criticado por seus impactos sobre os recursos naturais, especialmente nas florestas tropicais (ARVOR et al., 2017) e nas savanas

neotrópicas brasileiras que têm no cerrado um *hotspot* mundial para a conservação da biodiversidade (MYERS et al., 2000).

Segundo dados da pesquisa agrícola municipal, (IBGE, 2019), na produção agrícola de 2019, 95% das áreas agrícolas do estado corresponderam a produção de 3 principais culturas: Soja com 58,47%, milho com 30,22% e algodão com 6,65%, culturas estas, que em sua grande maioria estão associadas a cultivos sequenciais. A exemplo do caso do cultivo do milho, menos de 1% foi produzido em primeira safra em 2019, o que sugere o cultivo sequencial da soja. Dados do 10º Levantamento da Safra de Grãos 2019/20 da Conab (Companhia Nacional de Abastecimento) publicados em 2020 (“Conab - Monitoramento Agrícola”, 2020), apontam pela nona vez seguida o estado do Mato Grosso como o maior produtor de grãos do país. Em paralelo, o relatório anual da SEEG (Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa) para o ano de 2019, aponta que o Mato Grosso continua liderando nos últimos 10 anos como sendo o estado com maior taxa de emissão de GEE no setor da agropecuária, representando 73% das emissões provenientes do gado de corte, 6% proveniente do uso de fertilizantes, 6% do cultivo da soja e 15% referente às demais fontes (ALBUQUERQUE; ALENCAR; ANGELO, 2020). Por ser um estado repleto de contradições, seja na grande contribuição para a balança comercial brasileira, seja nos diversos impactos ambientais e sociais, o Mato Grosso apresenta grande relevância para o desenvolvimento de sistemas produtivos que compatibilizem as esferas econômicas, sociais e ambientais, ou seja, oportunidades para a implantação dos SIs.

Consideramos que a escolha do estado permitirá testar a robustez do método, uma vez que apresenta grande variabilidade entre ambientes, principalmente nas condições específicas de precipitação, que vão influenciar as janelas de plantio/colheita, assim como a resposta espectral das diferentes SITS.

Por ser um estado repleto de contradições, seja na estrutura produtiva de base familiar, ou de grandes proprietários, de terras indígenas, unidades de conservação, de desmatamento, garimpo ilegal, ou da grande contribuição para a balança comercial brasileira, abre-se um como grande potencial para o desenvolvimento de sistemas de produção com compatibilidade entre o econômico, social e ambiental, que apresenta grandes oportunidades para a implantação dos sistemas integrados.

### 2.1.3 Sistemas integrados (SIs)

Um estudo feito por Gil; Siebold; Berger, (2015)realizado em um período de 6 meses, mapeou por meio de entrevista de 134 produtores e especialistas e identificou onde já havia implementação dos sistemas integrados no estado do Mato Grosso para o ano-safra de 2012/2013. É apresentado um valor baixo ainda de implementação para estes anos. Ela apresenta a quantidade implementada em um mapa por municípios do estado. Os municípios que apresentam maior concentração são os de Sinop, Campo Novo do Parecis e Canarana, com aproximadamente 11 SI já implementados, seguido de Sorriso com cerca de 10 SIs. Segundo Gil et al. (2015), 89% das implementações de SI foram baseados em iLP, 5% iPF, 5% iLPF e 1% iLF. Segundo estudo da EMBRAPA para o estado do Mato Grosso no ano-safra 2015/2016 um total de 1.501.016 ha de áreas implementadas, representando 4,85% da área de agricultura do estado.

## 2.2 Coleta de dados em campo

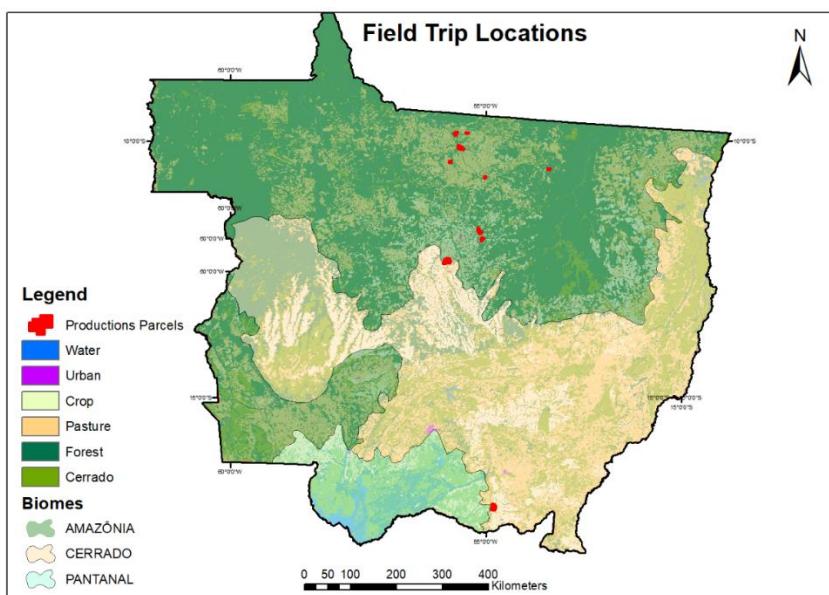
Durante os meses de outubro e novembro de 2018, foi realizado um trabalho de campo no estado do Mato Grosso, visando o reconhecimento dos alvos a serem mapeados, e a verificação da situação *in loco* dos sistemas produtivos característicos das diferentes regiões do estado. O objetivo principal foi realizar a coleta de dados para construção de uma base de aprendizagem sobre os sistemas integrados de produção lavoura-pecuária (iLP), com o intuito de realizar o treinamento do algoritmo de classificação Random Forest. Neste trabalho, foram percorridos aproximadamente 1.200 km, sendo a maior distância no sentido latitudinal, uma vez que existe um gradiente de variabilidade climático-ambiental no sentido Norte-Sul. Durante a viagem, foi possível identificar a variação entre os biomas Cerrado e Amazônico e sua zona transição, assim como a transição entre o Cerrado e o Pantanal. No eixo que vai de Cuiabá até Alta Floresta, passando pelos principais polos produtores de grãos, como Nova Mutum, Lucas do Rio Verde, Sorriso e Sinop, é possível identificar a expansão das áreas agrícolas sobre as áreas de vegetação do Cerrado. A **Figura 22** apresenta um esquema fitosionômico de transição em conjunto com fotos coletadas em campo.

Figura 22 - Fotos de campo apresentando a transição entre biomas



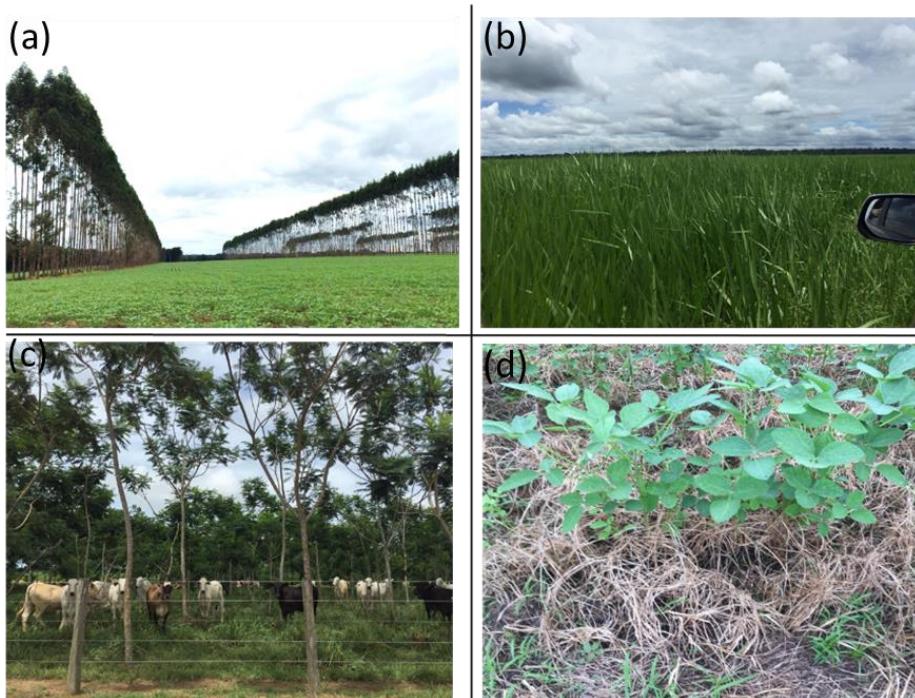
As informações foram coletadas com o apoio dos produtores identificados anteriormente com a ajuda da Embrapa Agrosilvipastoril que nos forneceram o histórico de plantação dos talhões. As informações fornecidas estavam organizadas em diversas formas, desde planilhas e plantas estruturadas até a coleta com receptores GPS das áreas produtoras. A **Figura 23** apresenta a localização das fazendas visitadas.

Figura 23 - Localização das fazendas visitadas em campo



Todos os produtores entrevistados ressaltaram o significativo ganho de rendimento ao adotar os sistemas integrados de produção, tanto o ILP quanto o ILPF. Entretanto, ficou evidente que a componente florestal era mais limitada por sua implantação e foi destinado mais aos produtores de grãos que fazem algum tipo de beneficiamento, como a secagem da soja, em sua propriedade, então utilizam a madeira como fonte de energia. Os produtores que implantaram o sistema ILP destacaram as principais vantagens deste sistema como: a redução na utilização de insumos, notadamente, de fertilizantes, a melhoria da qualidade da pastagem, semeada em consórcio com o milho ou após colheita da soja, além da produção de biomassa (palhada) para a semeadura, em plantio direto. As **Figuras 24 a e b** apresentam dois tipos de ILPF, na região médio-Norte do estado realizado com Paricá e Eucalipto, enquanto a **Figura 24 c** apresenta uma *brachiaria* manejada pós colheita da soja e a **Figura 24 d** a Soja se desenvolvendo na palhada produzida pela *brachiaria*.

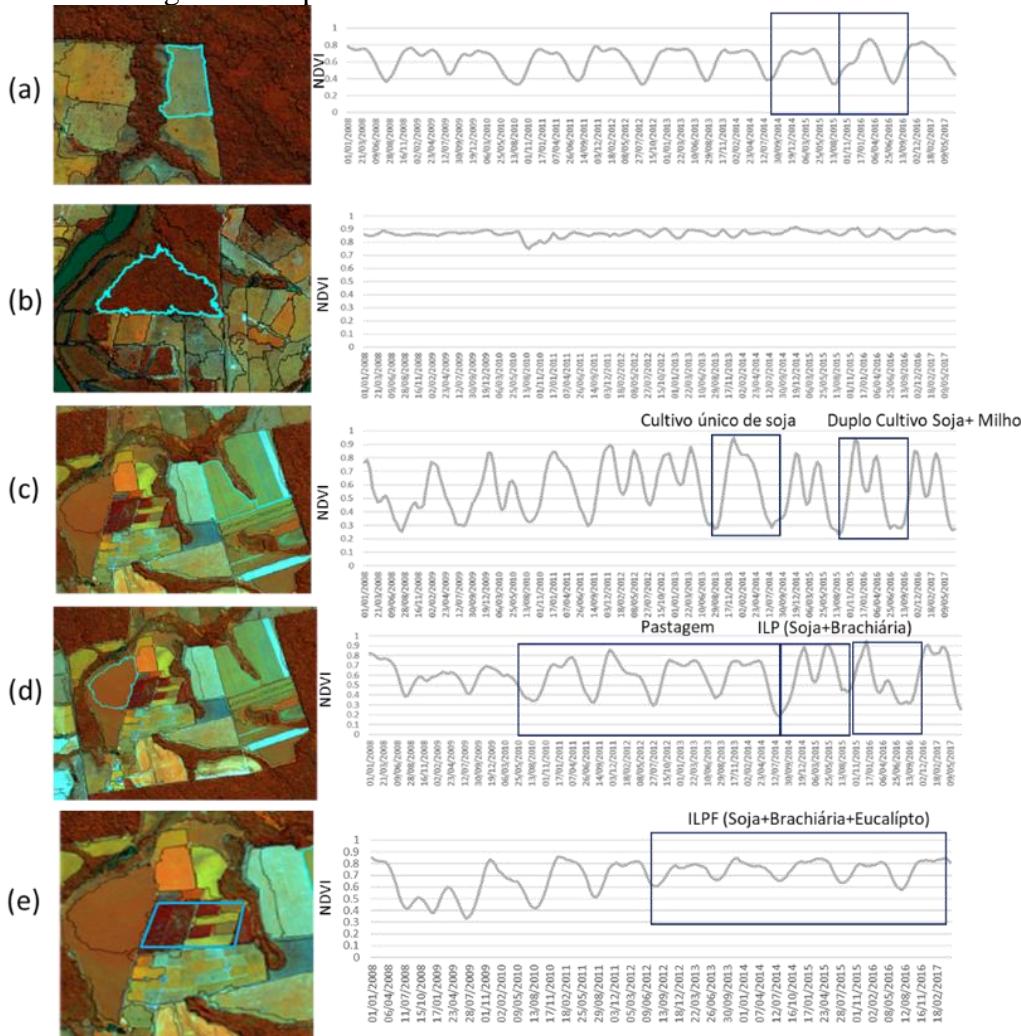
Figura 24 - Sistemas integrados fotografados em campo. (a) Sistema ILPF com soja em sucessão do milho e brachiária plantado em linhas com eucalipto; (b) brachiária em sequência da soja em sistema ILP; (c) Sistema IPF com paricá e brachiária; (d) Soja cultivada direto na palha da brachiária em Sistema ILP.



### 2.2.1 Séries temporais MODIS de amostras coletadas em campo

Objetivando entender o comportamento de alguns alvos a partir de amostras coletadas em campo, calculamos os valores médios do índice de vegetação (NDVI MODIS), utilizando como máscara algumas parcelas interpretadas em imagens Sentinel-2. Esta interpretação é significativamente facilitada quando são aplicados os filtros de remoção de ruídos como apresentado **Figura 25**.

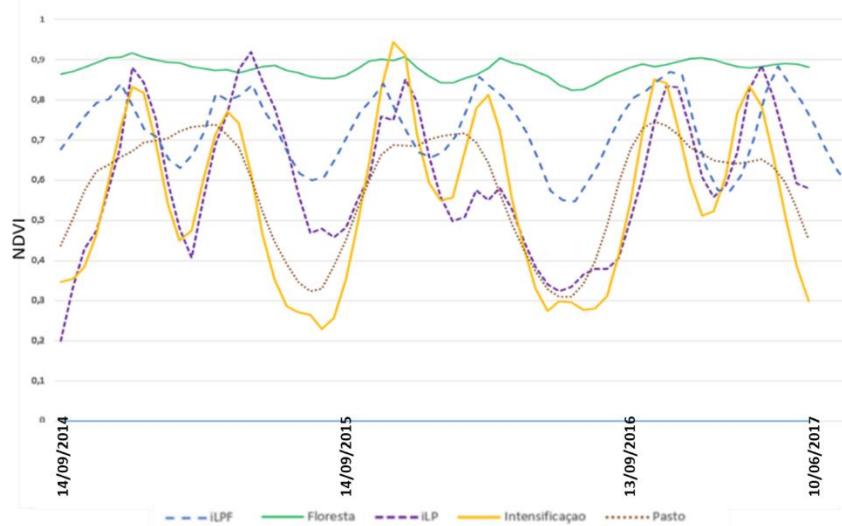
Figura 25 - Comportamento espectral das amostras de classe de cobertura e uso da terra coletados em campo. (a) série temporal da classe pastagem; (b) série temporal da classe floresta; (c) série temporal do sistema de cultivo único e duplo cultivo; (d) série temporal de pastagem e mudança para o sistema integrado ILP; (e) série temporal de pastagem e mudança de uso para o sistema integrado do tipo ILPF



É possível discriminar as classes mais características, como é o caso de: a) pastagem contínua, onde observa-se a partir da série histórica de 2008 até 2017 uma resposta constante do NDVI ao longo dos anos, apresentando uma leve mudança no ano/safra 2015/2016. Na série temporal desta classe é possível identificar um significativo aumento na variabilidade da amplitude dos valores de NDVI, indicando a resposta das gramíneas à sazonalidade climática (regime de chuvas e seca); b) a classe floresta, coletada e apresentada como forma de controle e comparação, apresenta o padrão mais bem marcado entre todas as classes testadas, com valores altos e constantes de NDVI, apresentando pouca resposta ao período seco e chuvoso, quando comparado com a classe pastagem; c) são identificados sistemas de cultivos, tanto de cultura solteira (soja), quanto o cultivo sequencial (soja+milho). É possível identificar os picos característicos da curva fenológica para as diferentes culturas anuais. A soja apresenta valores de pico bem elevados entre 0,9 e 1. No caso da soja em cultivo único, o valor de base fica próximo de 0,3, enquanto no sistema de duplo cultivo, onde cada pico é referente a uma cultura (soja e milho), o fim da estação da soja (safra mais curta), varia entre 0,4 e 0,6; c) neste quadrante é possível identificar a mudança de uso de pastagem para o sistema integrado do tipo ILP (soja+brachiária), que de forma similar ao sistema de duplo cultivo, apresenta dois picos; e) outro sistema de integração, o ILPF, que além da componente pastagem e cultura de soja, apresenta a silvicultura de eucalipto. Analisando a trajetória de pastagem para ILPF é possível identificar a mudança na resposta espectral da série temporal com uma variação de amplitude maior (pastagem) para um achatamento das curvas, tendendo a se assemelhar com as curvas apresentadas na floresta.

A **Figura 26** apresenta a sobreposição das curvas o que facilita identificar a características singulares de cada uso e cobertura, mas também destacar a similaridade, por exemplo, da classe de duplo cultivo (intensificação) de soja consorciado com milho e a brachiária na sucessão da soja (iLP).

Figura 26 - Sobreposição das curvas de STIS das classes levantadas em campo



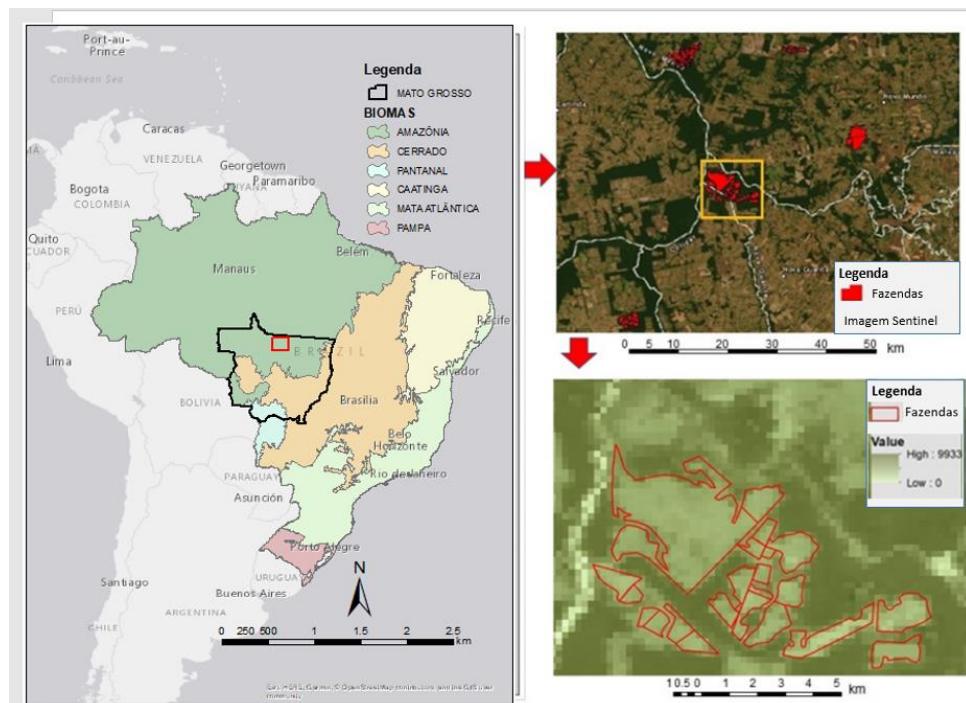
A partir da manipulação destes dados, presume-se que a coleta via interpretação visual das curvas de séries temporais da classe ILP são extremamente complexas.

### 3 ETAPA 1: DESENVOLVIMENTO DA ESTRATÉGIA DE CLASSIFICAÇÃO

Os estudos utilizando séries Temporais de Imagens de Satélite (STIS) no estado do Mato Grosso têm seguido a lógica apontada por Gómez; White; Wulder (2016), onde primeiro é selecionado um índice de vegetação para compor a SITS, depois seleciona-se o algoritmo de suavização para aplicar a SITS e por último a avalia-se a utilização ou não de atributos fenológicos. Entretanto, Picoli et al. (2018), propõem a utilização das STIS com a maior dimensionalidade possível, ou seja, mais do que a escolha de somente um índice de vegetação e sem a aplicação de filtros, sustentando que os algoritmos de classificação avançados são capazes de lidar com problemas relativos aos ruídos nas séries temporais, mesmo em locais com alta interferência de nuvens.

Dada a relevância desta questão, nesta fase da tese foi avaliado o quanto a filtragem, a extração de métricas fenológicas e a dimensionalidade de fato influenciam na acurácia do classificador *random forest* no mapeamento dos sistemas integrados de produção agropecuária. Para isso, estruturamos um experimento no norte do estado do Mato Grosso ( ).

Figura 27 - Localização da área de estudos da etapa 1 e a visualização a escala da fazenda



### 3.1 Dados e métodos

Para o desenvolvimento desta primeira fase, foi utilizada uma série temporal completa de índices de vegetação MODIS para o período de agosto de 2014 a julho de 2015. Os dois índices de vegetação considerados foram o NDVI e o EVI com resolução espacial de 250 m e resolução e temporal de 16 dias do produto MOD13Q1 (HUETE et al., 2002). Dados básicos de referência foram coletados para o ciclo agrícola de 2014/2015 por meio de entrevistas com agricultores. Este conjunto de dados de referência contém informações sobre os quatro principais sistemas de cultivo observados na área de estudo para 77 talhões em 5 fazendas (somando 778 pixels MODIS); conforme apresentado na Tabela 1. Os quatro sistemas são: Pastagem (P), principalmente brachiaria; ILP intra-anual, representado pela soja seguida por brachiaria; Monocultura (SC), representada por uma cultura principal (soja, milho ou arroz) seguida de um período de pousio; Duplo Cultivo (DC), representada pela soja como cultura principal, seguida pelo milho ou milheto. O sistema de produção agropecuária do estado do Mato Grosso é caracterizado por grandes fazendas e parcelas, geralmente maiores que 25 ha. Os dados de campo usados neste trabalho foram coletados em talhões maiores que 12,8 ha, com um tamanho médio de 80,8 ha. No entanto, para minimizar o efeito de borda em pixels mistos, uma zona tampão de -250 m foi calculada nos polígonos dos talhões, para a exclusão da primeira linha de pixels MODIS.

A fim de avaliar a influência das etapas de pré-processamento para discriminar os sistemas de cultivo, cinco conjuntos de dados correspondentes a diferentes níveis de pré-processamento foram criados, o que possibilitou também, o teste do desempenho de dois classificadores, *Random Forest* e *Support Vector Machine* em Séries Temporais de Imagem de Satélite MODIS:

- R-NDVI: série temporal de NDVI bruta (**23** variáveis no total);
- R-NDVI + R-EVI: combinação de NDVI bruto e série temporal de EVI bruto (**46** variáveis no total, 23 valores de NDVI + 23 valores de EVI);
- S-NDVI: série temporal de NDVI suavizada (**23** variáveis no total);
- P-NDVI: métrica fenológica de NDVI derivada da série temporal de NDVI bruta (**11** variáveis);
- R-NDVI + P-NDVI: combinação de séries temporais de NDVI brutas e métricas fenológicas de NDVI (**34** variáveis no total, 23 NDVI + 11 métricas fenológicas).

### 3.1.1 Suavização das séries temporais MODIS

Ambos os conjuntos de dados S-NDVI e P-NDVI foram pré-processados usando o *software* TIMESAT 3.2 (JÖNSSON; EKLUNDH, 2004). Com relação ao S-NDVI, vários métodos para suavizar séries temporais de índices de vegetação MODIS foram testados e comparados na literatura (ATKINSON et al., 2012; HRID; MCDERMID, 2008; SHAO et al., 2016). Todos enfatizaram a importância de escolher o método dependendo dos objetivos do usuário e da natureza do ruído na série temporal. Após alguns testes e com base em estudos anteriores realizados em Mato Grosso (ARVOR et al., 2008) e Tocantins, um estado vizinho (BELLÓN et al., 2017), decidiu-se usar o *Savitzky-Golay* (SG) (CAO et al., 2018; CHEN et al., 2004; SAVITZKY; GOLAY, 1964). É importante notar que apesar do *software* TIMESAT permitir que seja utilizado no processo de processo suavização a banda de qualidade fornecida pelo MOD13Q1, optamos por efetuar a filtragem não ponderada em nossa zona de estudo, devido à pouca confiabilidade destes dados em regiões caracterizada por altas taxas de cobertura de nuvens (BELLÓN et al., 2017). Foi aplicado o algoritmo *Savitzky-Golay* com os seguintes parâmetros básicos:  $d = 2$  (  $d$  se refere ao grau do polinômio de filtragem) e  $m = 2$  ( média meia largura da janela de filtragem), preconizado por (BELLÓN et al., 2017) .

### 3.1.2 Extração de métricas fenológicas

As séries temporais suavizadas foram então analisadas pelo TIMESAT para extrair onze parâmetros que compõem o conjunto de dados P-NDVI. Os onze parâmetros referem-se ao início, meio, duração e fim da estação, valor de base, valor de pico, amplitude, derivada direita, derivada esquerda e integrais, conforme descrito na sessão 2.4.2.3.

### 3.1.3 Avaliação dos algoritmos de classificação

O potencial desses cinco conjuntos de dados para discriminar sistemas de cultivo foi então testado usando classificadores de aprendizagem máquina, o *Random Forest* (RF) com o pacote *Random Forest* (LIAW, 2018), e o *Support Vector Machine* (SVM) (MOUNTRAKIS; IM; OGOLE, 2011), com o pacote *caret* (KUHN et al., 2015) do ambiente R (R CORE TEAM, 2020).

### 3.1.4 Validação da classificação

A acurácia da classificação foi avaliada usando um procedimento de validação cruzada *5-fold* (WIENS et al., 2008) usando 80% das amostras para treinamento (622 pixels) e 20% para predição (156 pixels). Cada *fold* gera uma matriz de confusão. A técnica de validação cruzada *k-fold* foi escolhida por permitir utilizar todo o conjunto de dados, o que é particularmente relevante neste caso.

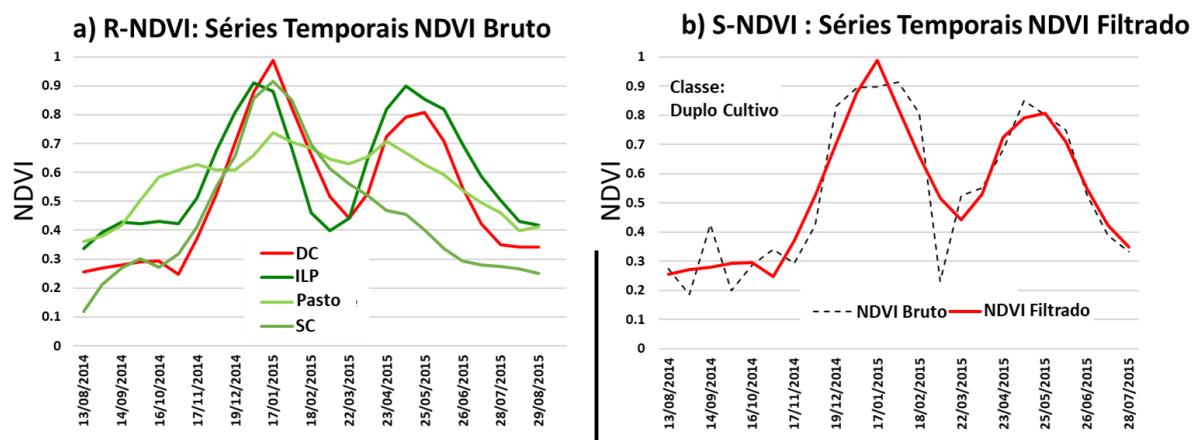
Realizou-se, também, uma análise da precisão da classificação usando a seleção de variáveis baseada em importância, a fim de avaliar o impacto das diferentes etapas de pré-processamento na redistribuição da informação discriminante apresentadas pelas séries temporais. Para tanto utilizamos o índice de diminuição média na precisão ou DMP (CUTLER et al., 2007). Os resultados do DMP indicam o número de variáveis de maior importância, de forma a otimizar a entrada de variáveis para cada conjunto de dados (LEBOURGEOIS et al., 2017). Esse processo foi realizado usando a função *rfe* disponível no pacote *caret* (KUHN et al., 2015).

## 3.2 Resultados

A análise da série temporal R-NDVI calculada sobre todos os pixels de cada classe **Erro! Fonte de referência não encontrada.**(a) mostra que o perfil temporal das pastagens (P) forma um platô com valores baixos, enquanto o perfil dos sistemas de monocultura (SC)

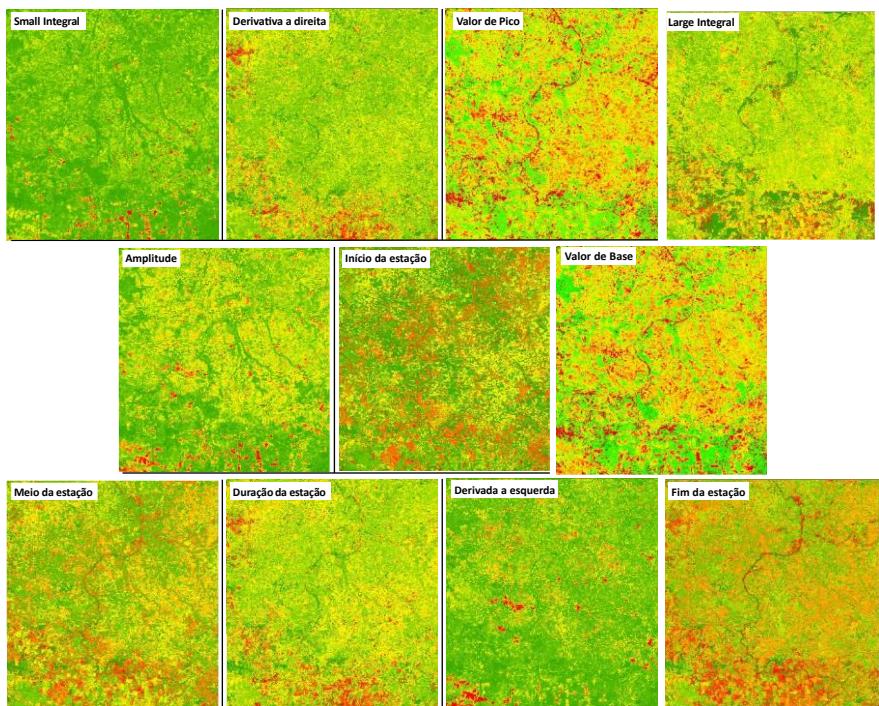
apresenta uma variação sazonal mais acentuada e altos valores de pico. Em contraste, os sistemas de cultivo duplo (DC) e integração lavoura-pecuária (ILP) são caracterizados por dois ciclos de cultivo. (**Figura 28 (a)**). Uma análise mais aprofundada mostra, no entanto, que as duas séries diferem (i) no início da estação (agosto-outubro) com valores de NDVI mais elevados para ILP, e (ii) no final da estação com um segundo ciclo mais longo para ILP do que para DC (a pastagem permanece verde por mais tempo após a colheita do milho). A **Figura 28 (b)** mostra um exemplo de uma série temporal NDVI para um único pixel, antes e depois da suavização. Picos e vales provenientes do ruído atmosférico são suavizados, facilitando a interpretação visual dos ciclos fenológicos e o cálculo dos 11 índices de fenômenos (P-NDVI) mostrados **Figura 29**.

Figura 28 - a) Séries temporais anuais do R-NDVI MODIS média para cada classe; b) Exemplo de série temporal MODIS NDVI adquirida em um pixel DC, antes e depois da suavização de Savistky-Golay.



Como resultado do TIMESAT, um total de 11 arquivos matriciais foram gerados, onde cada um representa uma das métricas fenológicas **Figura 29**. Estas 11 variáveis foram utilizadas em dois conjuntos de dados (R-NDVI e R-NDVI + P-NDVI).

Figura 29 - Métricas fenológicas calculadas pelo TIMESAT.



### 3.2.1 Acurácia dos conjuntos de dados

As melhores Acurárias Globais (AG) (0,95) foram obtidas com os conjuntos de dados R-NDVI + R-EVI e R-NDVI + P-NDVI (0,94). Analisando mais detalhadamente cada classe de cada conjunto de dados, é possível observar que para a classe ILP, com R-NDVI + R-EVI apresenta o melhor *fscore* (0,95), seguido por R-NDVI + P-NDVI (0,93). O desempenho das séries temporais não suavizadas (0,92) apresenta leve melhora em comparação com as séries suavizadas (0,90). A precisão obtida apenas com os índices fenométricos não é nada satisfatória, seja na acurácia global (0,58), seja no *fscore* da classe iLP (0,64).

Tabela 1 - Acurárias (OA = acurácia global e K = Kappa) obtidas para os diferentes classificadores

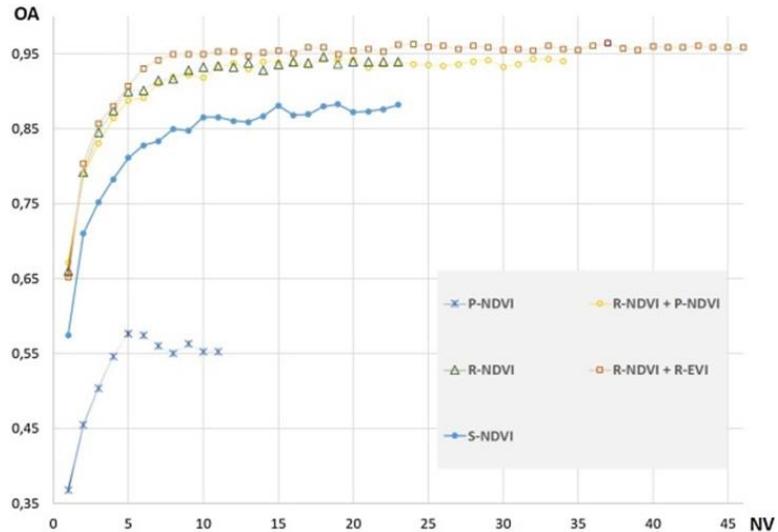
		Random Forest				SVM	
Níveis de pré- processamento		F-score				OA	K
		Pastagem	iLP	SC	DC		
<b>R-NDVI</b>	0,95	0,92	0,94	0,91	0,94	0,91	0,88
<b>R-NDVI+ R-EVI</b>	0,97	<b>0,95</b>	0,97	0,96	0,96	0,94	0,93
<b>S-NDVI</b>	0,9	0,90	0,86	0,87	0,89	0,84	0,77
<b>P-NDVI</b>	0,58	0,64	0,41	0,58	0,58	0,42	0,57
<b>R-NDVI+P-NDVI</b>	0,97	0,93	0,97	0,92	0,95	0,92	0,93
<b>Número pixels de amostras</b>	177	293	107	201			

Legenda: (RF = Random Forest e SVM = Suport Vector Machine) e F-scores obtidos com RF para as diferentes classes (P = pasto, SC = monocultura, DC = Cultura dupla e iLP = sistema integrado lavoura-pecuária).

### 3.2.2 Análise da evolução da acurácia pela dimensionalidade

A **Figura 30** mostra a mudança na precisão global das classificações de acordo com o número de variáveis de entrada usadas na classificação (as variáveis são introduzidas uma a uma de acordo com seu valor de importância DMP). Os resultados mostram que o conjunto de dados R-NDVI + R-EVI é o mais eficiente porque apresenta a melhor combinação de acurácia global vs. número de variáveis importantes, ou seja, um valor de precisão alta obtido com menos de 10 variáveis, enquanto o R-NDVI e os conjuntos de dados R-NDVI + P-NDVI alcançam um valor de precisão alta, porém com um número maior de variáveis.

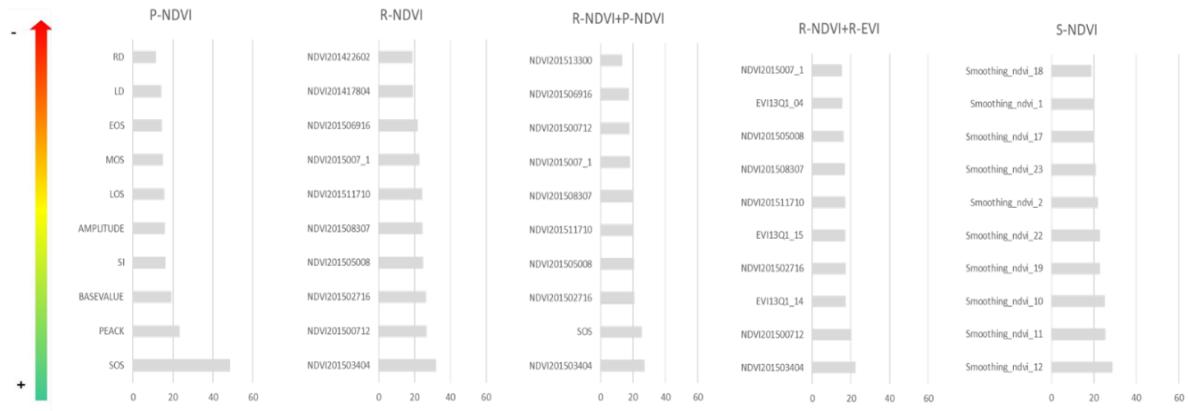
Figura 30 - Acurárias Globais em função do número de variáveis, das classificações do Random Forest para os 5 conjuntos de dados testados, onde OA significa Acurácia Global e NV número de variáveis



### 3.2.3 Distribuição do nível de importância dos principais descritores

A **Figura 31** apresenta as 10 principais variáveis, ranqueadas pelo valor DMP para cada um dos 5 conjuntos de dados avaliados. No conjunto P-NDVI, é possível identificar que a métrica SOS (referente ao início da estação), tem um peso significativamente maior do que as outras métricas. Para o conjunto de dados R-NDVI+P-NDVI o SOS é a única métrica fenológica com peso discriminatório. Esta grande importância atribuída a uma única variável não é encontrada nos outros conjuntos de dados, onde é possível observar um peso mais bem distribuído entre cada variável.

Figura 31 - Distribuição do nível de importância de cada descritor em cada conjunto de dados.



Em relação ao algoritmo de classificação, os valores globais de acurácia e o índice *Kappa* obtidos com RF e SVM são semelhantes, com uma ligeira melhora na utilização do RF (Tabela 1). Todos os resultados deste estudo foram publicados em Kuchler et al., (2020).

### 3.3 Conclusão parcial

Nesta etapa, foi avaliada a importância dos níveis de pré-processamento e a dimensionalidade das séries temporais de imagens do satélite MODIS para mapear os principais sistemas de cultivo em uma região norte do estado do Mato Grosso. Nossos resultados mostram que a suavização temporal das Séries Temporais de Imagens de Satélite e o cálculo da fenometria tendem a diminuir a precisão da classificação quando comparados com os resultados obtidos pela classificação das SITS brutas. Os resultados apresentam que os modelos baseados em aprendizagem máquina modernos, como SVM e RF, são robustos a interferências de ruídos e capazes de obter melhores resultados ao usar conjuntos de dados com alta dimensionalidade.

Esse resultado está de acordo com Chen et al. (2018) que relataram a preocupação na utilização do processamento de *Savitsky-Golay*, que, por um lado, reduz a interferência atmosférica nas séries temporais, mas, por outro, filtra informações importantes, dificultando assim a discriminação de classes similares nas séries temporais, como é o caso dos sistemas

Duplo Cultivo e ILP. Isso é ainda mais significativo ao usar um classificador RF, que visa identificar as variáveis mais discriminantes sem lidar explicitamente com correlações cruzadas: ao usar perfis NDVI suavizados, as informações discriminantes originalmente concentradas em um registro único são estendidas sobre registros vizinhos como resultado de um processo de suavização (por exemplo, uma interpolação polinomial como o *Savitsky-Golay*, e potencialmente corrompido por aquisições ruidosas, que no caso deste experimento são particularmente recorrentes devido à significativa cobertura de nuvens. Uma medida desse efeito pode ser observada na **Erro! Fonte de referência não encontrada.**, onde quatro variáveis S-NDVI mais importantes são necessárias para se aproximar da precisão da classificação das duas primeiras variáveis R-NDVI. O potencial discriminativo diminuído de S-NDVI é confirmado pelos piores resultados obtidos usando SVM e, obviamente, impacta os desempenhos das métricas fenológicas, que são derivadas diretamente desta fonte. Nguyen e Henebry, (2019) também descrevem que a modelagem das métricas fenológicas requer um número substancial de observações de boa qualidade ao longo de um ano, pode ser menos adequado para áreas com significativa cobertura de nuvens, quando apenas dados ópticos estiverem disponíveis para caracterizar a fenologia da superfície da terra; assim, os resultados desta tese também corroboram com os resultados obtidos por Picoli et al. (2018), que usou refletâncias NIR e MIR além de R-NDVI e R-EVI. Neste trabalho, a adição de R-EVI foi suficiente para aumentar a precisão do mapeamento da classe ILP, confirmando que a capacidade do *Random Forest* de ter um melhor desempenho em modelos de dimensionalidades mais altas, que é adequada para este estudo de caso. Cabe ressaltar que os resultados dos experimentos realizados nesta Etapa podem variar dependendo dos parâmetros usados no SG, assim como em outras técnicas de suavização. A divergência de resultados pode ocorrer também com os descritores, onde outras métricas podem se apresentar como bons descritores para os sistemas integrados. Com isso, a investigação sobre o impacto dos métodos de suavização e da geração de métricas fenológicas na acurácia do mapeamento dos sistemas ILP não se esgotam nesta tese. Na Etapa 2 aplicaremos este modelo em todo o estado do Mato Grosso.

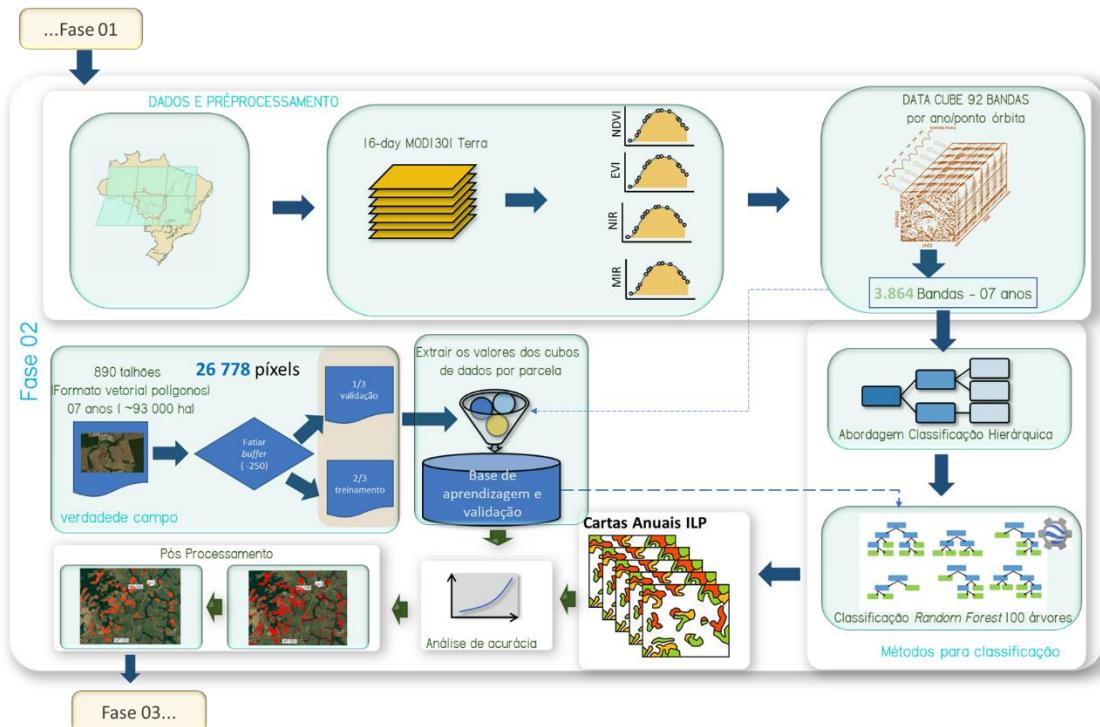
## 4 ETAPA 2: ESTRATÉGIA DE CLASSIFICAÇÃO DOS SISTEMAS INTEGRADOS APLICADOS À ESCALA REGIONAL

A estratégia de classificação estabelecida nesta etapa foi aplicada a todo o estado do Mato Grosso e em uma série histórica de 7 anos, levando-se em consideração os resultados obtidos na etapa anterior.

### 4.1 Dados e métodos

A visão geral da metodologia aqui desenvolvida, testada e proposta para o mapeamento dos sistemas integrados do tipo iLP em escala regional está apresentada na **Figura 32**. O classificador *Random Forest* (BREIMAN, 2001) foi usado com 100 árvores aleatórias, combinadas com um conjunto de dados de aprendizagem/validação de aproximadamente 25.000 pixels. Nesta etapa do trabalho, foi adotada uma abordagem de classificação hierárquica (LEBOURGEOIS et al., 2017), partindo da classe soja do produto anual do Mapbiomas. O processamento foi realizado na plataforma *Google Earth Engine* (GEE), que fornece fácil acesso a produtos prontos para uso e grandes volumes de dados, o que possibilitou processar 3.864 imagens do produto MOD13Q1 (23 datas de NDVI, EVI, NIR e MIR; 6 cenas para cobrir o Mato Grosso; 7 campanhas agrícolas entre 2012-13 e 2018-19).

Figura 32 - Fluxograma metodológico



#### 4.1.1 Estrutura hierárquica

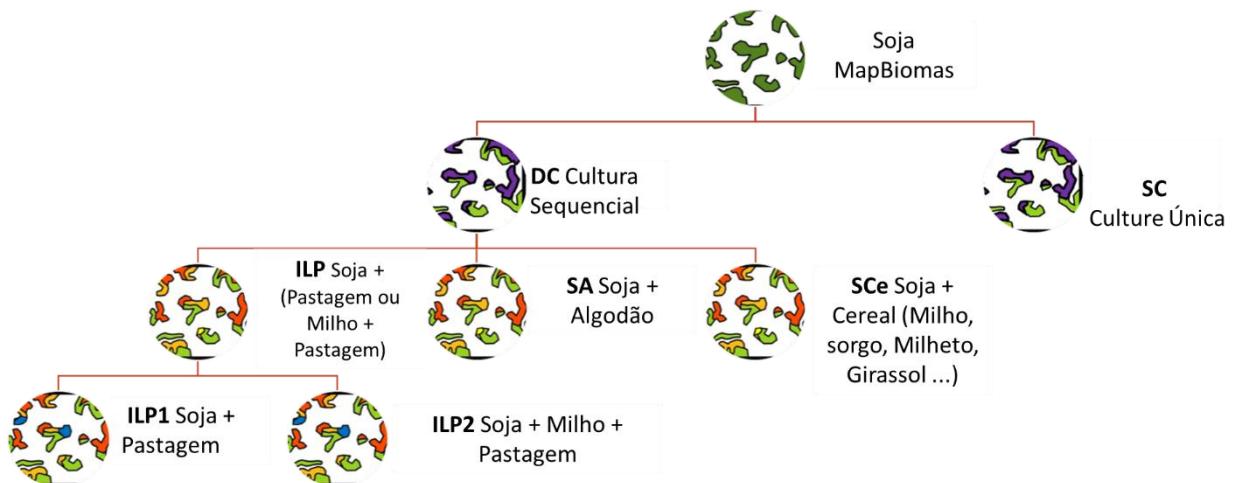
A estrutura hierárquica de classificação foi composta por quatro níveis conforme apresentados abaixo:

- Nível 0: Neste primeiro nível foi aplicada uma máscara à classe Soja do produto Mapbiomas coleção 5.0;
- Nível 1: No segundo nível foi realizada uma classificação binária, contendo a classe (SC) que representa a soja em sistema solteiro e a classe (DC) que representa a sucessão de qualquer outro tipo de cultura após a soja;
- Nível 2: Para o terceiro nível, o universo de mapeamento foi isolado à classe DC mapeada no nível anterior, que foi estratificada nos três sistemas mais comuns no estado, ou seja, soja em sucessão com algodão (SA), soja em sucessão com milho, milheto, sorgo ou girassol (SCe) e a soja com a *brachiária*, com ou sem a presença do milho, milheto ou girassol (iLP);

- Nível 3: O quarto nível é composto pela especialização da classe iLP, que foi dividida em ILP1, que representa pastagem em sucessão da soja e a classe ILP2 que representa a pastagem em sucessão da soja consorciada com o milho.

A **Figura 33** apresenta o esquema hierárquico proposto.

Figura 33 - Diagrama da estrutura hierárquica de classificação dos sistemas de cultivo.



#### 4.1.2 Pós-tratamento

Todos os mapas anuais dos sistemas agrícolas foram produzidos na escala do pixel. Com o intuito de homogeneizar os resultados, foi aplicado um filtro espacial para a classe iLP, capaz de diminuir os efeitos de borda da classificação, eliminando pixels ou grupo de pixels mal classificados, encontrados principalmente na transição entre as classes de cultura, pastagem e floresta, além dos pixels isolados. Esta situação é proveniente principalmente da mistura espectral comum em sensores com média resolução espacial (LOBELL; ASNER, 2004; OZDOGAN, 2010).

Este filtro espacial exclui pixels aos quais não estão conectados a pelo menos 5 outros pixels da mesma classe, ou seja, conjunto de pixels com a área inferior a 35 hectares. Este valor, pode parecer alto, porém foi considerado aderente, tomando como base os dados coletados em campo, onde a média de área das parcelas é de 96 hectares e o tamanho mínimo de parcela é de 30 ha.

### 4.1.3 Estratégia para criar uma base de dados de aprendizagem

#### 4.1.3.1 Métodos de coleta de dados de aprendizagem

Para produzir mapas de uso da terra, a maioria dos estudos utiliza classificadores supervisionados, que demandam uma grande quantidade de dados de aprendizagem. Esta questão permanece como um enorme desafio para o mapeamento do uso da terra agrícola em larga escala (BÉGUÉ et al., 2018; BELLÓN et al., 2017). Diversas estratégias para compor uma base de amostras de campo podem ser aplicadas.

Para o mapeamento de classes estáveis que sofrem pouca variação intra-anual, como é caso de culturas perenes e vegetação natural, alguns estudos desenvolvem uma metodologia de interpretação visual em imagens de mais alta resolução espacial (BULLOCK et al., 2020; SOUZA et al., 2020). Outras iniciativas utilizam a coleta de dados *in situ*, um exemplo é o projeto “Rally da Pecuária” que realiza coletas em campo de amostras para caracterizar a atividade pecuária em algumas regiões do Brasil. Para o mapeamento das pastagens no Brasil Parente et al. (2017, 2019), utilizam um misto de dados coletados por estas grandes incursões com dados interpretados visualmente. Esta abordagem de coleta por interpretação visual é cada vez mais utilizada, uma vez que objetivam o mapeamento retrospectivo, o que inviabiliza a coleta de campo. Para mapear os sistemas de cultivo sequenciais existe ainda uma estratégia para a composição de bases de terreno que contam com entrevistas à produtores e cooperativas em conjunto com dados coletados em trabalho de campo (ARVOR et al., 2011; CHEN et al., 2018; KASTENS et al., 2017; KUCHLER et al., 2020; LEBOURGEOIS et al., 2017; MANABE; MELO; ROCHA, 2018; PICOLI et al., 2018).

A estratégia de coleta de dados de campo via entrevista com produtores da região se torna eficaz, uma vez que para os cultivos sequenciais, a visita feita em somente uma data não possibilita a identificação do sistema anual de produção. É possível observar na maioria dos estudos, que mesmo esta estratégia apresenta limitações, pois não consegue de forma robusta, colecionar uma quantidade significativa de amostras para mapeamento de grandes áreas e principalmente em classes pouco representadas, como é o caso dos sistemas integrados. Tão pouco a interpretação visual traz uma confiabilidade (mesmo que da STIS) como foi

apresentado na sessão 2.2.1 Séries temporais MODIS de amostras coletadas em campo A exemplo, Manabe; Melo e Rocha (2018) coletam em suas entrevistas e visitas ao campo, amostras de iLP em três municípios do estado do Mato Grosso. Já Chen et al. (2018), utilizam 20 amostras da classe soja-pasto de um município também no estado do Mato Grosso, que é replicada para toda a dimensão do estado, o que segundo o próprio autor, pode ter afetado a confiabilidade do mapeamento desta classe.

No presente caso, as amostras foram coletadas e organizadas com dados provenientes de cinco diferentes fontes, que dentre elas, campo, entrevista com produtores, parceria com consultores (que apoiam a implantação dos sistemas integrados na região), visitas a unidades locais da Embrapa, assim como amostras de controle provenientes de trabalho disponível em (CÂMARA et al., 2018).

Nas entrevistas com produtores foram coletados dados de parcelas inteiras com histórico de plantio. Nesta fonte, foi utilizada a rede dos produtores que fazem parte das Unidades de Transferência Tecnológica (URT's) em parceria com a Embrapa Agrossilvipastoril. Também foram coletadas amostras com um dos maiores grupos de produção agropecuária do Brasil, o grupo Bom Futuro. Os dados disponibilizados por Câmara et al (2018) no portal Pangaea se encontram organizados pontualmente. No intuito de homogeneizar com as outras fontes, os pontos foram transformados em polígono, onde realizou-se a sobreposição com imagens Sentinel-2 da mesma data, possibilitando a fotointerpretação do talhão onde cada ponto estava contido. O conjunto destas fontes totalizaram 891 polígonos de talhões em uma área média por parcela de 96 ha contidas em 46 Municípios do estado localizados em distintas regiões. A Tabela 2 apresenta a distribuição das amostras por fonte.

Tabela 2 - Fonte das amostras de campo e sua proporcionalidade

<b>Fonte</b>	<b>Total Parcelas</b>	<b>% area de todas classes</b>	<b>Parcelas ILP</b>	<b>% area ILP</b>
Grupo Bom Futuro	612	71.51%	86	48.97%
Campo	44	4.27%	44	13.26%
Embrapa	71	9.92%	60	27.04%
Consultores	56	3.46%	55	10.73%
CAMARA et al. (2018)	108	10.84%	0	0.00%
<b>TOTAL</b>	<b>891</b>		<b>201</b>	

Para selecionar nosso universo de validação, 1/3 das parcelas foram randomicamente selecionadas e separadas dos outros 2/3 que foram utilizadas para a aprendizagem do algoritmo

*random forest*. Foi realizada a separação entre os conjuntos de aprendizagem e validação usando as parcelas e não os pixels, pois pretendeu-se particularizar ao máximo os dois conjuntos de dados, sem que haja a situação em que amostras de aprendizagem e validação sejam vizinhas em uma mesma parcela.

A partir do cruzamento entre as 92 variáveis e os 891 polígonos de amostra, eliminando todos os pixels do entorno de cada polígono (realizando uma operação vetorial de zona tampão em -250m nas parcelas), obteve-se um conjunto de validação e aprendizagem de 26 778 pixels.

#### 4.1.3.2 Balanceamento da base de dados de aprendizagem

Ao conduzir uma classificação supervisionada com algoritmos de aprendizado de máquina, como o *random forest*, a estratégia de balanceamento das amostras é fundamental, pois impacta diretamente no resultado dos mapas de saída. Estes tipos de classificadores são sensíveis às proporções das diferentes classes, ou seja, de um conjunto de dados balanceado e não balanceado.

Dados não balanceados referem-se a uma situação em que o número de observações não é o mesmo para todas as classes em uma base de aprendizagem. Como consequência, esses algoritmos tendem a favorecer a classe com a maior proporção de observações (conhecida como classe majoritária). Isso pode ser particularmente problemático quando o interesse é na classificação de uma classe "rara" (também conhecida como classe minoritária). Dado que esses algoritmos visam minimizar a taxa de erro global, em vez de prestar atenção especial à classe minoritária, eles podem falhar em fazer uma previsão precisa para esta classe se não obtiverem a quantidade necessária de informações sobre ela. Por este motivo, é fundamental realizar uma análise da sensibilidade do classificador à distribuição das amostras de treinamento.

Alguns estudos investigaram o desempenho do *random forest* para a classificação de imagens de satélite em diferentes estratégias de construção da base de aprendizagem, utilizando amostras平衡adas e não平衡adas. Dalponte et al., (2013) e Jin; Stehman; Mountrakis (2014) encontraram em seus experimentos, melhores resultados com amostras de treinamento平衡adas, onde cada classe tem a mesma quantidade de amostras. Noi e Kappas (2017) encontraram uma relação entre o tamanho da base de aprendizagem e a performance dos conjuntos de dados平衡ados e não平衡ados. Para o algoritmo *random forest* observou-

se que ele é extremamente sensível às amostras balanceadas e não balanceadas alcançando maior acurácia global nas amostras balanceadas, porém quando o conjunto de dados é composto por uma quantidade significativa de amostras, a diferença entre os dois é insignificante, concluem os autores. Já Colditz (2015) e Mellor et al. (2015) encontraram uma tendência de melhora na acurácia quando há uma divisão de amostras desbalanceadas entre as classes, de forma que representasse melhor a proporção da área de uso e cobertura da terra.

Tendo em conta as conclusões divergentes da bibliografia existente sobre o impacto do balanço de amostras na qualidade da classificação do uso e cobertura da terra e que o objetivo da tese é o mapeamento de uma classe rara (iLP), foram testados três cenários de classificação aplicados ao nível 2 para o ano 2016/2017 (ano com significativa quantidade de amostras e considerado ano típico, sem fenômenos climáticos extremos), com distribuição distinta das amostras por classe. A primeira classificação foi realizada por um conjunto de dados equilibrado (*Bset01*), ou seja, com um número de amostras semelhantes em cada classe. Outras duas classificações foram realizadas aplicando conjuntos de dados não平衡ados, um com uma distribuição de amostras por classe próxima à distribuição real encontrada no campo (estimado a partir do conjunto de dados coletado) (*Bset02*). O outro conjunto de dados não balanceados, foi composto por uma super-representação da classe rara iLP (*Bset03*) (Figura 34)

Figura 34 - Composição dos três conjuntos de dados de treinamento testados (conjunto de dados balanceados *Bset01* e conjuntos de dados não balanceados *Bset02* e *Bset03*), e detalhes associados às classes "soja + algodão" (soja + algodão), "soja + cereais" (SCe) e sistemas integrados (iLP).



A **Figura 34** apresenta as métricas de acurácia para os três mapas produzidos. É possível observar que dentre os sistemas sequenciais, a classe soja + algodão é a que apresenta menor variação condicionada ao conjunto de dados de treinamento. Por outro lado, a classe cuja precisão apresenta maior variação é a soja + cereais, com valores de *fscore* entre 0,65 e 0,96.

Os melhores valores de *fscore* da classe iLP são obtidas para *Bset01* e *Bset02* (0,81 e 0,83 respectivamente), com um erro de comissão mais alto para *Bset01* (+ 9%). No *Bset03*, onde há uma superestimação da classe iLP, o valor de *fscore* se apresentou mais baixo, condicionado por uma acurácia do usuário (0,66) extremamente baixa. A elevada acurácia do produtor (0,88 maior entre todos os conjuntos), não foi suficiente para elevar o valor do *fscore*.

A interpretação destes resultados sugere que, quando uma maior quantidade de amostras é conferida a classe iLP em uma abordagem não balanceada, o *random forest* vai supervalorizar esta classe e vai apresentar um viés com maior erro de comissão, ou seja, mais áreas que não são o iLP, serão classificadas como tal de forma errada. Neste caso, teríamos uma super estimativa de área implementada com iLP no estado do Mato Grosso, ao passo que teríamos uma área subestimada de soja + cereal com um erro de omissão de 0,46.

Tabela 2 - Métricas dos resultados de acurácia dos conjuntos balanceados e não balanceados

Métricas	<i>BSET 01</i>			<i>BESET 02</i>			<i>BESET 03</i>		
	Soja Algodão	Soja Cereal	iLP	Soja Algodão	Soja Cereal	iLP	Soja Algodão	Soja Cereal	iLP
<b>Acurácia Produtor</b>	1	0,81	0,80	1	0,91	0,76	0,99	0,54	0,88
<b>Acurácia Usuário</b>	1	0,80	0,81	1	0,79	0,90	1	0,82	0,66
<b>F-SCORE</b>	1	0,96	0,81	1	0,85	0,83	1	0,65	0,75
<b>Amostras</b>	2.241	2.383	2.107	1.361	3.796	589	2.383	885	2.383
<b>Acurácia Global</b>	<b>0,87</b>			<b>0,89</b>			<b>0,81</b>		

Frente a estes resultados, considerando a maior acurácia global, maior *fscore* e menor erro de comissão (objetivando estimar áreas de forma conservadora) para a classe de interesse iLP, o conjunto de dados *Bset02* (em que o número de amostras por classe é representativo da proporção de classes no campo) foi usado para etapas seguintes, tanto para a análise da acurácia da distribuição espaço-temporal, quanto para os mapas anuais nos níveis 02 e 03.

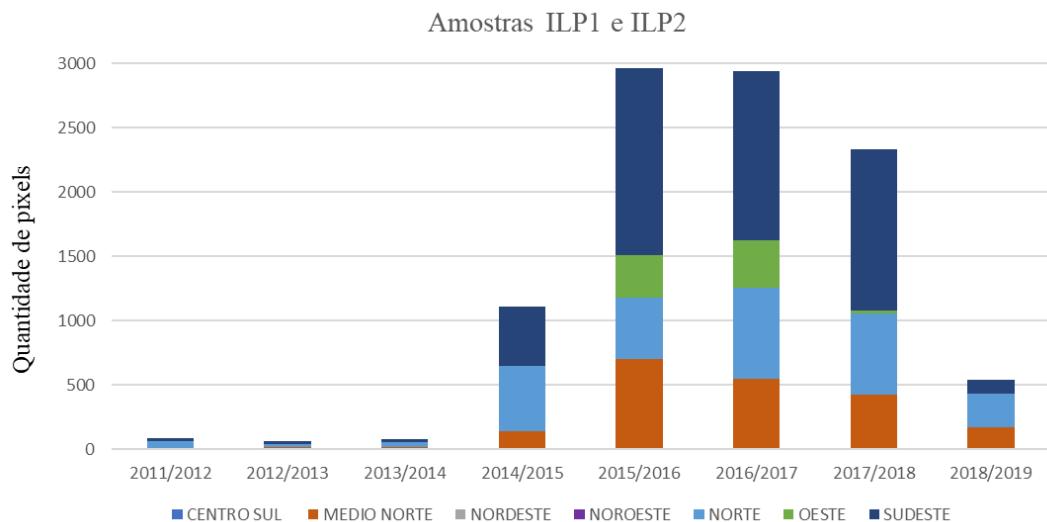
#### 4.1.4 Impacto da distribuição espaço-temporal de conjuntos de dados de aprendizagem na qualidade das classificações

##### 4.1.4.1 Questões metodológicas

Dada a dificuldade de aquisição de dados de campo, testar a robustez de uma metodologia que permita o treinamento com amostras de diferentes anos e regiões é uma etapa essencial. Diversas abordagens são encontradas na literatura. Nesse sentido, Picoli et al. (2018) usam uma base única de aprendizagem e validação de 1.800 pontos para classificar 15 anos em diferentes regiões do estado do Mato Grosso. Eles obtiveram boa acurácia na classificação para sistemas de cultivos convencionais e sequenciais utilizando MODIS. Parente et al. (2019), utilizando imagens Landsat, acreditam, que a variabilidade espectral, espacial e temporal é significativa dentro de uma mesma classe, a ponto de confundir o algoritmo *random forest*. Por isso, utilizam uma metodologia de coleta de amostras por fotointerpretação de imagens (com vários intérpretes e metodologias de controle e validação) para cada ano de estudo e em cada cena do território nacional, garantindo uma base de aprendizagem bem distribuída no tempo e no espaço.

A escolha da melhor abordagem de construção da base de aprendizagem, será condicionada principalmente pelas características dos dados utilizados e a complexidade da classe a ser mapeada. No caso da presente tese sobre sistemas integrados, e considerando os dados disponíveis, tivemos que trabalhar com amostras de treinamento e validação distribuídos de forma significativamente desigual no espaço-tempo conforme apresentada na **Figura 35**.

Figura 35 - Distribuição espaço-temporal das amostras de iLP1 e iLP2 no estado do Mato Grosso



Para estudar o impacto desta distribuição espaço-temporal dos conjuntos de dados na precisão das classificações, testamos e avaliamos a precisão dos mapas de sistemas de cultivo e mapas de ILPs de acordo com diferentes anos e regiões do Mato Grosso. Entre as várias

características edafoclimáticas que têm impacto no ciclo fenológico da vegetação e, portanto, na sua resposta espectral, destacam-se as chuvas, cujo papel é determinante para o crescimento da vegetação e que apresenta uma elevada variabilidade espaço-temporal no estado, conforme indicado no capítulo 3.

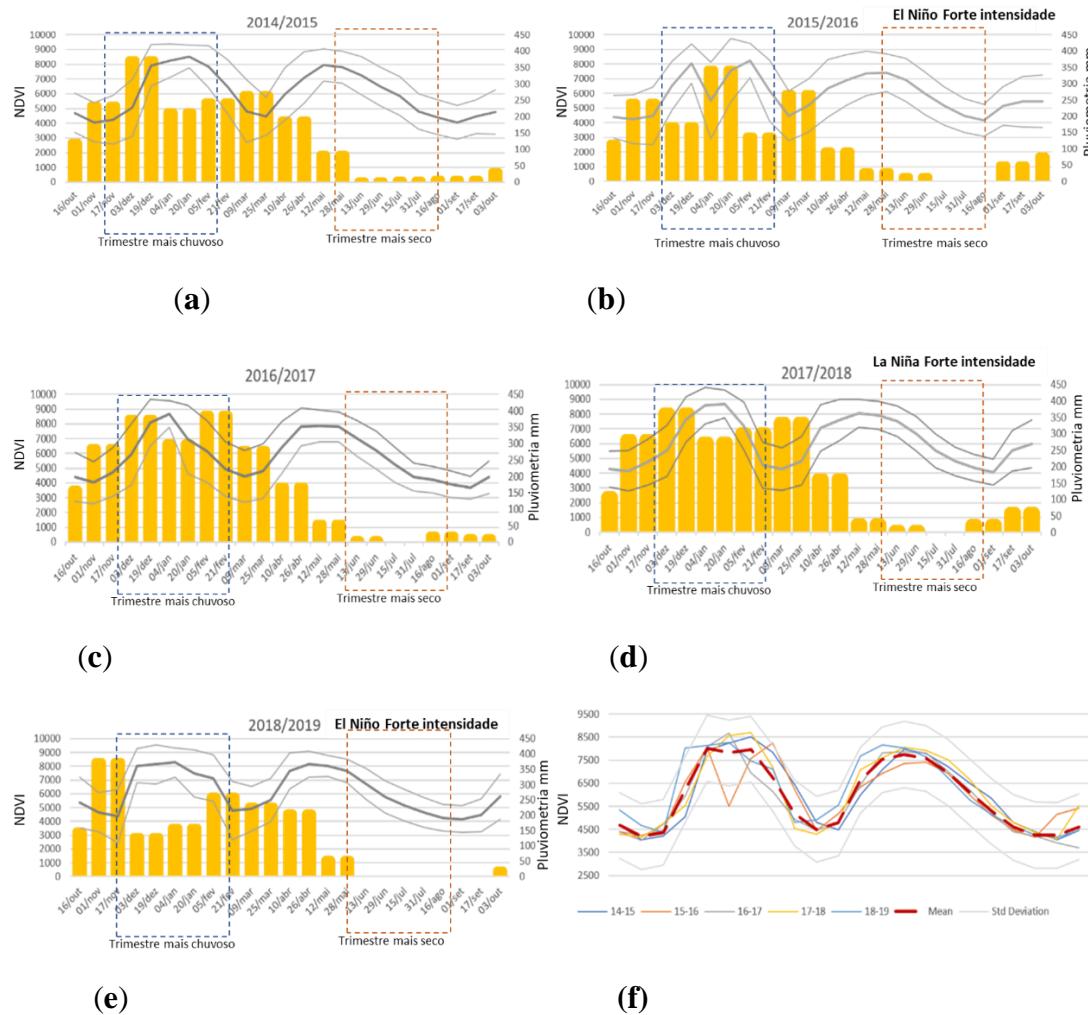
#### 4.1.4.2 Impacto da distribuição temporal do conjunto de dados de aprendizagem

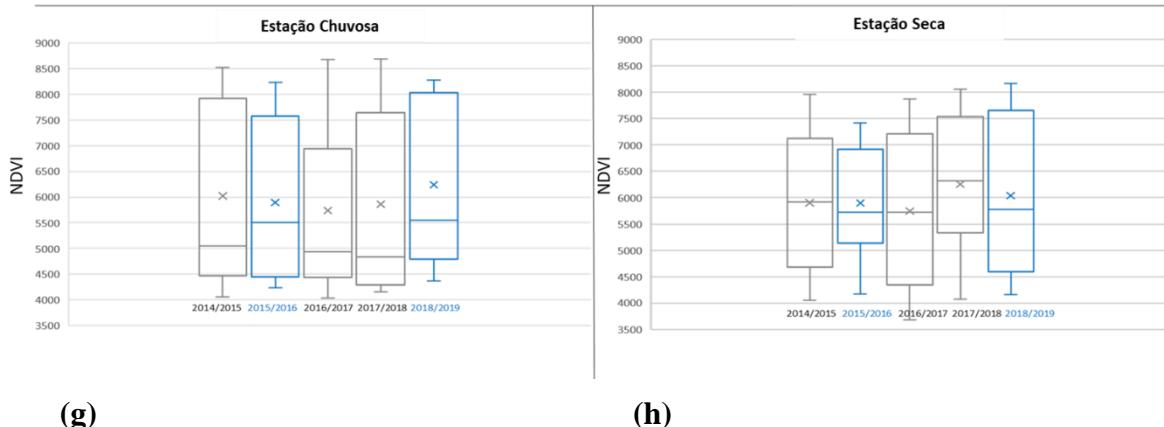
Cerca de 90% do universo amostral está concentrado entre as safras 2014/2015 e 2018/2019. Antes de quantificar o impacto desse desequilíbrio temporal na precisão das classificações plurianuais, estudamos a variabilidade intra-anual das séries temporais, usando a média dos valores NDVI do sistema soja+brachiaria e os registros mensais de precipitação coletados nas estações meteorológicas do Instituto Nacional de Meteorologia (INMET, 2019) entre 2014 e 2019 (**Figura 36 a-e**).

A análise da série temporal de NDVI (**Figura 36 a-e**) mostra uma variabilidade intra-anual significativa no perfil da classe iLP, especialmente durante a estação chuvosa de outubro a março (período de cultivo da soja). Esta variabilidade nos perfis de NDVI é particularmente marcada durante anos de alta intensidade do fenômeno El Niño e La Niña, com dois picos de crescimento de NDVI em 2015/2016 (provavelmente ligados à heterogeneidade da precipitação e interferência atmosférica (**Figura 36 Erro! Fonte de referência não encontrada.b**), e um pátô prolongado em 2018/2019 (**Figura 36 e**). Os perfis de NDVI são mais homogêneos durante o trimestre mais seco, de junho a agosto, mesmo nos anos com a presença dos fenômenos El Niño e La Niña (**Figura 36 a-f**).

A diferença entre as estações é notavelmente visível na **Figura 36 Erro! Fonte de referência não encontrada.g-h**. Nesta, observamos uma maior dispersão dos dados na estação chuvosa do que na seca, e mais assimétrica (com valores medianos distantes dos valores médios). Os resultados na **Figura 36 g-h** não mostram um efeito significativo do ENOS na dispersão e simetria dos valores de NDVI.

Figura 36 - Séries temporais da média dos valores de NDVI da classe iLP 1 e suas relações com a pluviometria media para todo o estado do MT: (a) STIS do ano-safra 2014/2015; (b) STIS do ano-safra 2015/2016, ano que houve fenômeno ENSO de forte Intensidade; (c) STIS do ano-safra 2016/2017; (d) STIS do ano-safra 2017/2018; (e) STIS do ano-safra 2018/2019, ano que houve fenômeno ENSO de forte Intensidade; (f) STIS de todos os anos apresentando a média de todos os anos, cada ano individual sobreposto e envelope do desvio padrão; g) A acurácia global e o fscore para a classe iLP de cada ano e sua relação com a quantidade de amostras.



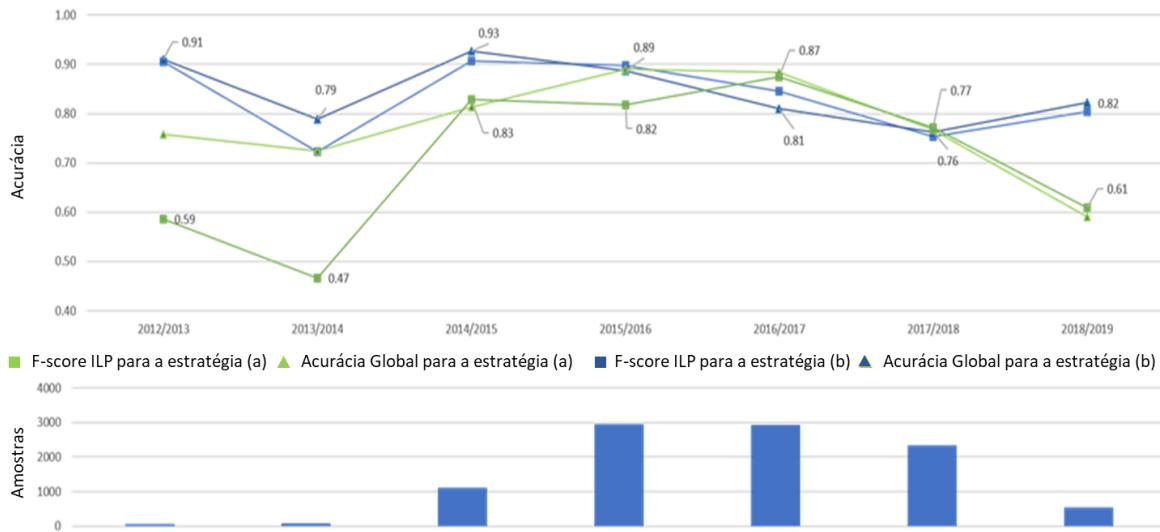


Para avaliar o impacto desse desequilíbrio temporal entre os conjuntos de dados, realizou-se a comparação da acurácia dos mapas classificados, utilizando duas estratégias de construção de base de dados de aprendizagem:

- A primeira estratégia (a), tradicional, usa 2/3 dos dados de campo adquiridos para um determinado ano para classificar as séries temporais do mesmo ano; neste caso, 1/3 das amostras restantes são reservadas para validação;
- A segunda estratégia (b) é misturar os conjuntos de dados adquiridos em anos diferentes e usá-los para classificar as séries temporais de cada ano. No presente caso, a base de dados de aprendizagem é constituída por 2/3 dos dados adquiridos entre 2014/2015 e 2018/2019 (os mais ricos em termos de dados de campo) e a validação para estes anos é feita com os dados do ano em questão (amostras não usadas para treinamento). Assim, neste cenário, a base de dados construída com dados adquiridos entre 2014/2015 e 2018/2019 é utilizada para classificar os 3 anos anteriores (2011/2012, 2012/2013 e 2013/2014). A validação das 3 classificações assim obtidas é feita a partir de dados adquiridos nesses anos (não utilizados para treino).

Os resultados mostram que a acurácia global e o *fscore* da classe iLP são maiores para a estratégia (b), ou seja, quando são utilizados os dados dos cinco anos principais. Os resultados apresentados na **Figura 37** sugerem que a precisão está mais relacionada à quantidade de amostras do que à variabilidade da precipitação anual.

**Figura 37** Acurácia global e *fscore* da classe iLP obtida para cada ano e para as duas estratégias de amostragem temporal (o número de amostras disponíveis por ano é representado por histogramas na figura inferior).

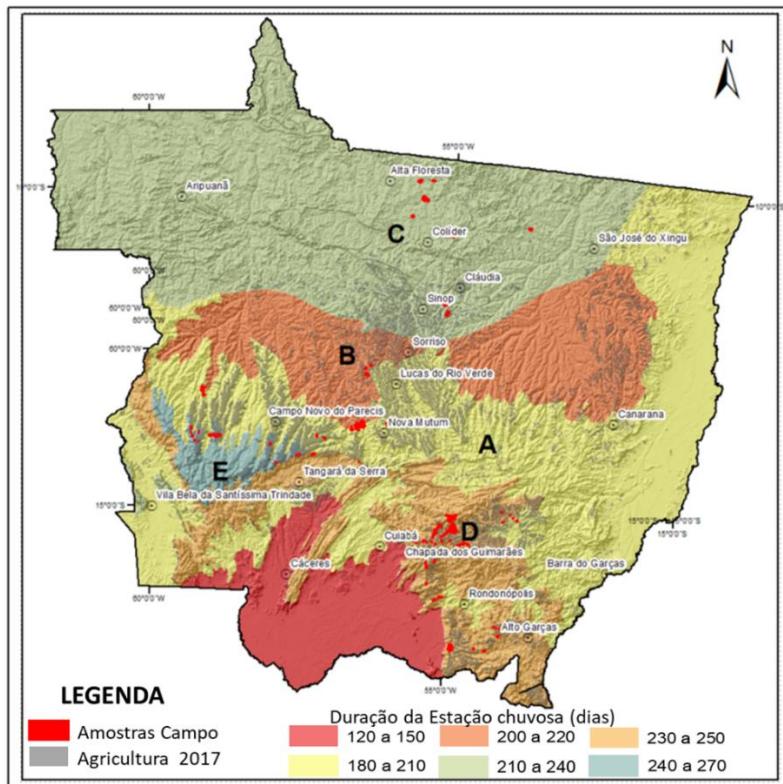


Para anos em que poucas amostras estão disponíveis, como 2012/2013, 2013/2014 e 2018/2019, a acurácia global e o *fscore* são aprimoradas quando dados de cinco anos diferentes são usados. Para anos com muitas amostras disponíveis (2015/2016, 2016/2017 e 2017/2018), a acurácia global e o *fscore* variam pouco, qualquer que seja o número de anos (entre 1 e 5 anos testados) usados para treinamento.

#### 4.1.4.3 Impacto da distribuição espacial do conjunto de dados de aprendizagem

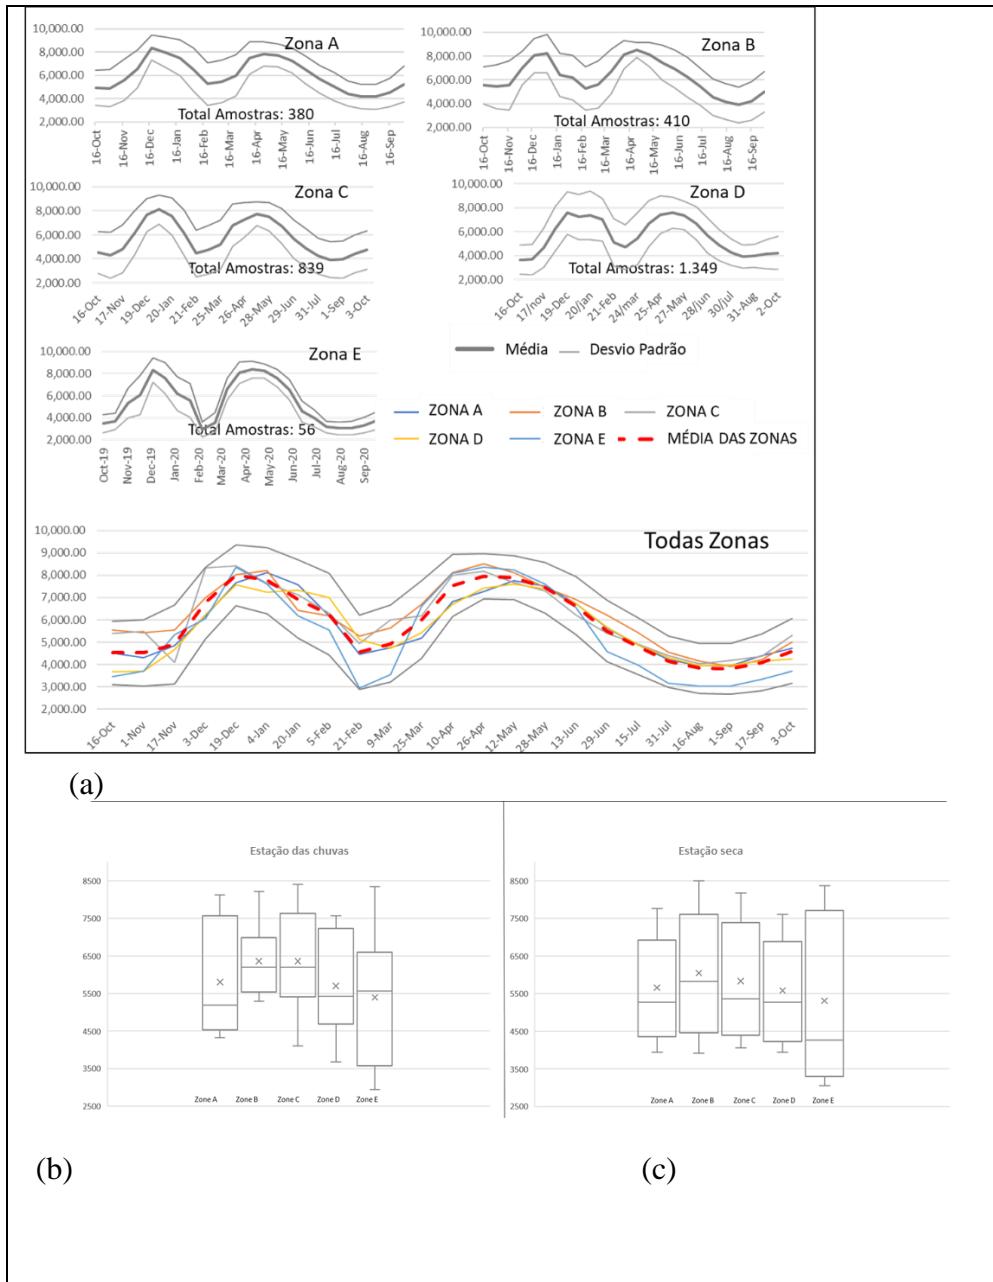
Para testar o impacto da distribuição geográfica das amostras nos resultados da classificação em nível estadual, utilizou-se regiões climáticas do zoneamento ecológico econômico do estado (SANTOS, 2000) que define seis regiões climáticas, produzidas pela média de um histórico de 20 anos. Cada região é dividida pela duração (em número de dias) de precipitação pluvial durante o trimestre mais chuvoso (**Figura 38**).

Figura 38 - Regiões pluviométricas



É possível observar uma significativa variabilidade das curvas NDVI em cada região, principalmente no período chuvoso. A zona **E** é a área para a qual a curva NDVI é mais "ruidosa", com a maior amplitude, mas também é a área que contém o menor número de amostras (56). No segundo ciclo, da estação seca, as zonas **C** e **D** se comportam de forma semelhante, embora sejam regiões com mais amostras. Ao contrário dos resultados encontrados na análise da variabilidade temporal, a dispersão e simetria da distribuição dos valores de NDVI por região não mostram uma tendência clara. No caso da zona **A**, a amplitude é maior durante a estação chuvosa, enquanto nas zonas **B**, **C** e **E**, uma maior diversidade de valores é encontrada na estação seca. No caso da zona **D**, a amplitude não varia significativamente. As **Figuras 39 b** e **c** mostram que em todas as regiões, os valores médios de NDVI entre a estação chuvosa e a estação seca não são significativamente diferentes, especialmente nas regiões **A**, **D** e **E**, com valores ligeiramente mais baixos na estação seca para as regiões **B** e **C**.

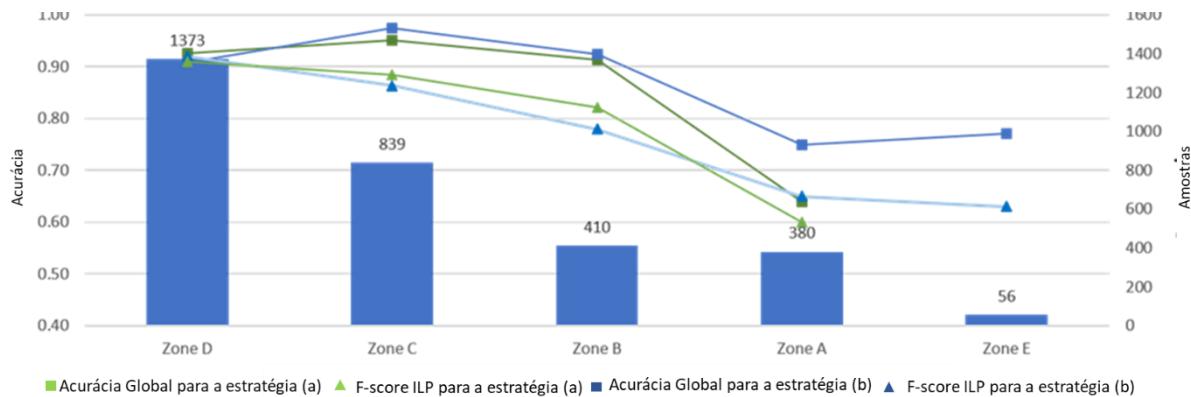
Figura 39 - Variabilidade espacial das amostras de iLP e regiões climáticas do estado de Mato Grosso. Séries temporais de valores médios e desvios padrão de NDVI para 5 regiões climáticas (a); Box plot da variabilidade do NDVI para a estação chuvosa (b) e a estação seca (c)



Duas estratégias para construir a base de dados de aprendizagem foram então testadas:

- Na estratégia (a), de forma tradicional, os dados de amostragem e validação foram divididos por região; neste caso, apenas 2/3 das amostras da mesma área foram utilizadas como base de aprendizagem (1/3 para validação) para a classificação da área. Esta estratégia não foi aplicada na zona **E**, devido ao baixo número de amostras na referida zona.
- Na estratégia (b), as amostras coletadas de todas as regiões são misturadas e usadas como dados de treinamento para cada área.

Figura 40 Acurácia global e fscore da classe iLP, obtidos para as 5 regiões climáticas (A a E) e para as duas estratégias de amostragem espacial (conjunto de dados a e b). Os histogramas mostram o número de amostras disponíveis por região



A análise da **Figura 40** permite avaliar o impacto da estratégia de amostragem espacial na acurácia global do mapa e no *fscore* da classe iLP. De maneira geral, observa-se que quanto maior o número de amostras na região, maior a acurácia global e o *fscore*, tanto no grupo de dados (a) quanto no grupo de dados (b). A acurácia global e os valores de *fscore* nas áreas **B**, **C** e **D** são próximas para as duas estratégias. Na zona **A**, quando todos os anos são usados para treinamento (estratégia b), há uma melhoria significativa na acurácia global.

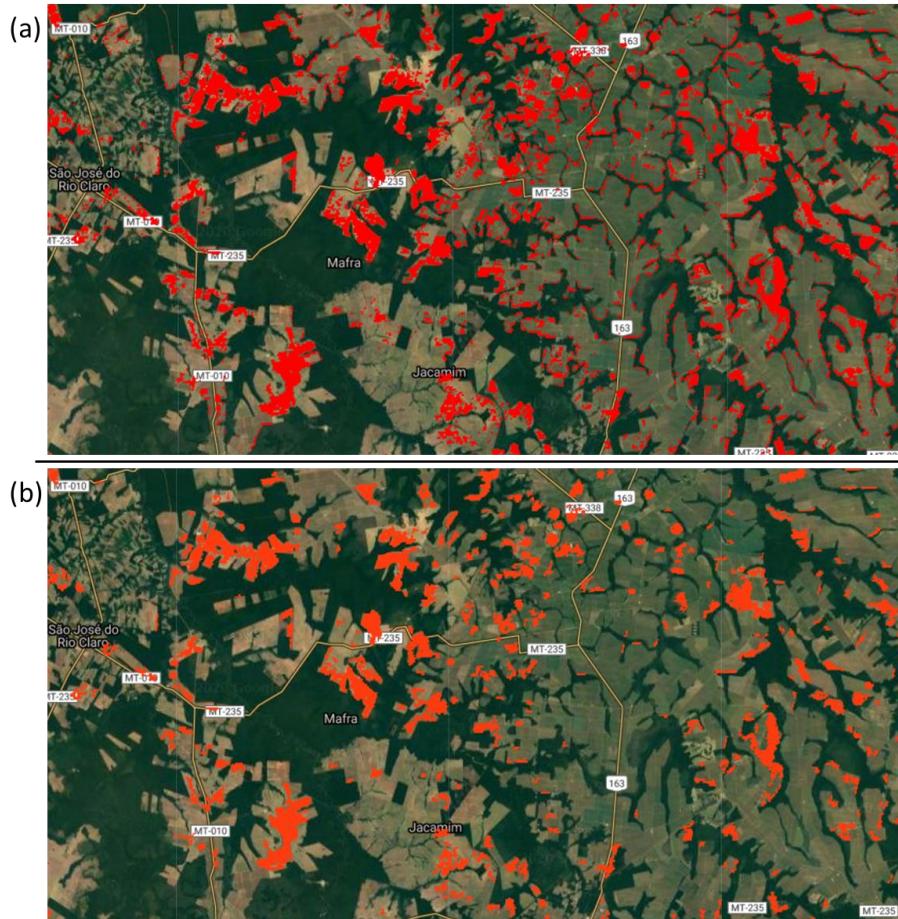
## 4.2 Resultados

### 4.2.1 Avaliação de mapas de sistemas de cultivo em diferentes níveis

Uma vez gerados e avaliados os resultados referentes às questões metodológicas inerentes ao mapeamento em larga escala e multi-temporal, esta sessão é direcionada para avaliar a acurácia dos mapas anuais de iLP gerados pelos modelos finais. As métricas de acurácia global foram geradas para todos os níveis e todos os anos, enquanto o *fscore*, acurácia do usuário e acurácia do produtor foram geradas para as classes alvo, de iLP no nível 2 e ILP1 e ILP2 no nível 3. Todas as métricas de validação foram geradas sobre os mapas pós processados, ou seja, após a aplicação do filtro espacial explicitados na sessão 5.1.3.

A Figura 41 apresenta um exemplo das áreas de iLP detectadas no nível 2 antes e depois da aplicação do filtro espacial.

Figura 41 - (a) Áreas de iLP detectadas no nível 2; (b) Mapa pós processado das áreas de iLP



É possível observar no mapa pré-processado (**Erro! Fonte de referência não encontrada.** a), que existem vários pixels isolados que seguem as áreas de remanescente florestal, exatamente na zona de contato entre os talhões com os sistemas produtivos e a floresta. Este tipo de situação ocorre possivelmente pela mistura espectral presente nestas zonas de transição. Também foi observado este tipo de comportamento nas zonas de transição entre os talhões de agricultura e pastagem permanente.

#### 4.2.2 Acurácia global (AG)

As classificações avaliadas nesta seção foram feitas usando uma base de aprendizagem e validação com todo o conjunto de amostras disponível, fruto da agregação de todas as regiões e anos. As amostras foram balanceadas com base na distribuição dos tipos de uso encontrados em campo, assim como apresentado nos resultados do *Bset-2* do experimento realizado no item 4.1.4.2

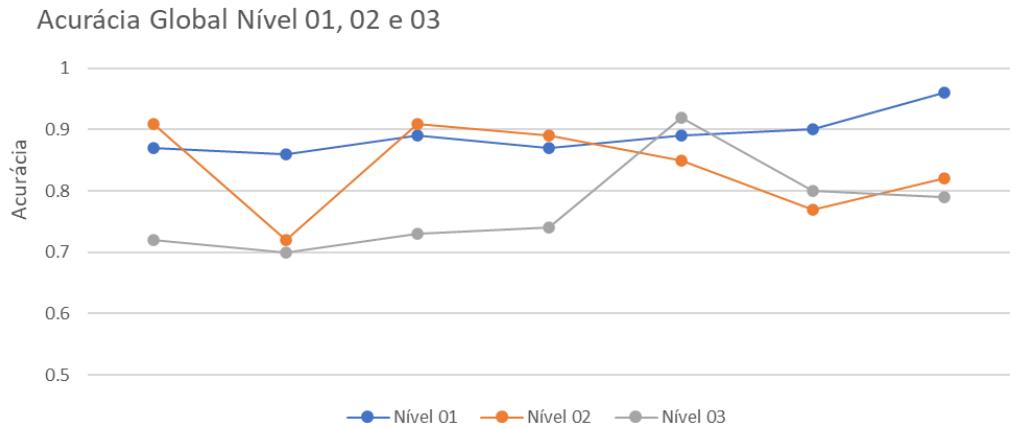
A acurácia global das classificações dos sistemas de cultivo obtidas nos três níveis está entre 0,70 e 0,96 (Tabela 4). Como esperado, o Nível 01 (classes DC e SC) obtiveram em média a melhor pontuação (em média 0,89) e apresenta a maior estabilidade plurianual (entre 0,86 e 0,96). Em seguida, vêm o Nível 02 (com 0,84 em média) e o Nível 03 (0,77 em média). Os níveis 02 e 03 possuem amplitudes de variação da mesma ordem.

Tabela 3 -Valores anuais da acurácia global do mapeamento dos sistemas de cultivo obtidos para o estado do Mato Grosso, para os diferentes níveis

Ano/safra	Acurácia Global		
	N1	N2	N3
2012/2013	0,87	0,91	0,72
2013/2014	0,86	0,72	0,70
2014/2015	0,89	0,91	0,73
2015/2016	0,87	0,89	0,74
2016/2017	0,89	0,85	0,92
2017/2018	0,90	0,77	0,8
2018/2019	0,96	0,82	0,79
Média dos 7 anos	<b>0,89</b>	<b>0,84</b>	<b>0,77</b>
Desvio padrão dos 7 anos	<b>0,03</b>	<b>0,07</b>	<b>0,07</b>

A **Figura 42** apresenta a evolução da acurácia global nos três níveis, sendo possível observar o primeiro nível com uma constância significativamente maior, quando comparada com os níveis 2 e 3.

Figura 42 - Evolução anual da acurácia global nos 3 níveis

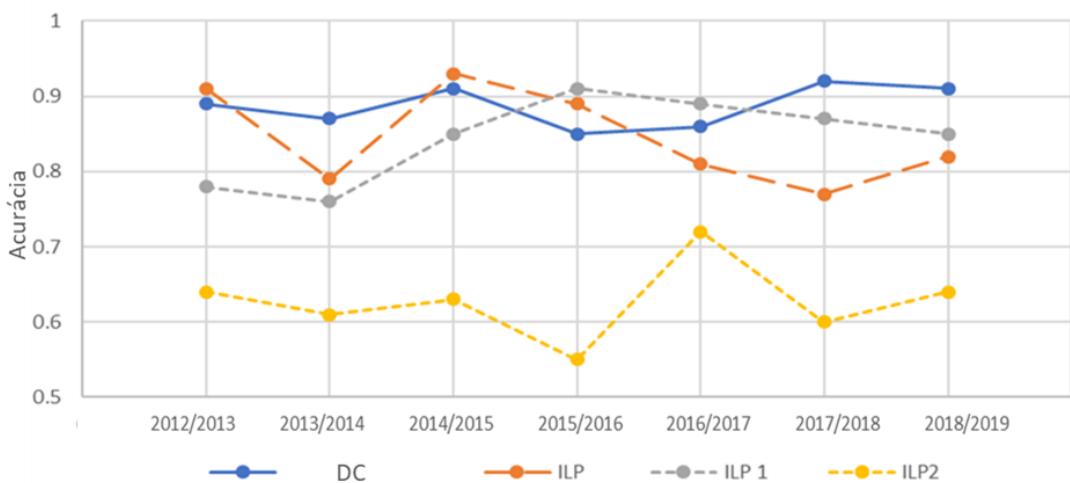


#### 4.2.3 Acurácia das classes dos Sistemas Integrados

Os *fscore* das classes dos sistemas de cultivo calculados para cada ano são apresentados na **Figura 43**. As classes DC, iLP e iLP1, embora pertençam a 3 níveis de classificação diferentes, têm precisões próximas (respectivamente 0,89, 0,85 e 0,84). A classe iLP2 apresenta um *fscore* significativamente menor (0,63).

O mapeamento das áreas com iLP, representado a partir do Nível 02, tem uma precisão do usuário entre 0,8 e 0,94 (e, portanto, um erro de comissão baixo) e uma acurácia do produtor entre 0,68 e 0,88 (e, portanto, um erro de omissão médio). O grande número de falsos negativos sugere que a área implantada com ILPs está subestimada (algumas áreas iLP foram classificadas como Soja + Cereais), por outro lado o baixo número de falsos positivos (áreas Soja + Cereais classificadas como iLP) indica uma maior confiabilidade quando um pixel é classificado como iLP. Este bom resultado se deve em parte à estratégia de balanceamento da amostra apresentada acima (escolha de uma distribuição próxima à encontrada na realidade).

Figura 43 Evolução anual do *fscore* das classes de sistema de cultivo do Nível 01 (linha contínua), Nível 02 (pontos grandes) e Nível 03 (pontos pequenos), calculado na escala do estado de Mato Grosso



A diferença na precisão da classificação entre o iLP1 e iLP2 pode ser explicada pela falta de amostras disponíveis para a classe iLP2. Para realizar um mapeamento focado na discriminação das práticas culturais entre os sistemas iLP, possivelmente será necessário compor uma nova estratégia de criação das bases de aprendizagem específicas para este nível.

#### 4.3 Conclusão parcial

O uso de dados de séries temporais MODIS e seu processamento por técnicas de aprendizado de máquina mostraram grande potencial no mapeamento de sistemas iLPs. Os limites da resolução espacial do MODIS, em termos de precisão das áreas mapeadas e da não detecção de pequenas parcelas devido à mistura espectral, permanecem toleráveis devido ao ganho de informação substancial proporcionado pela alta frequência de revisitas. A frequência de visita de satélites é uma propriedade fundamental na área de Observação da Terra nos trópicos devido às fortes perturbações atmosféricas. Mais importante quando se objetiva mapear os sistemas agrícolas complexos como os sistemas integrados, que requerem um sofisticado monitoramento sazonal. No curto prazo, mapear esses sistemas complexos com maior resolução espacial se tornará essencial. A utilização dos sistemas de observação Sentinel-2, Landsat, CBERS é um caminho a ser seguido, mas com questões ligadas à harmonização radiométrica entre diferentes sensores, baseada nas proposições de Potapov et al., (2020), por exemplo, pois estes sensores apresentarem uma frequência temporal inferior à frequência diária do MODIS.

O uso de algoritmos avançados de aprendizado de máquina aplicado a séries temporais tem se mostrado altamente eficazes, mesmo quando se utiliza descritores (variáveis) inter-relacionados e ruidosos. Esta pode ser uma oportunidade para superar as dificuldades de harmonizar séries de imagens adquiridas por diferentes sensores, conforme mencionado anteriormente, e uma forma de integração de dados de múltiplas fontes (multirresolução e óptico / radar).

O estado da federação escolhido, o Mato Grosso, serviu para testar a robustez da metodologia, uma vez que apresenta uma variabilidade significativa em termos de modelo de produção, ambientes e regimes de precipitação, além de ser um estado com grandes dimensões. A aplicabilidade de maior escala é considerada aqui viável para grande parte do corredor da soja, necessitando de amostras adicionais para ambientes diferentes.

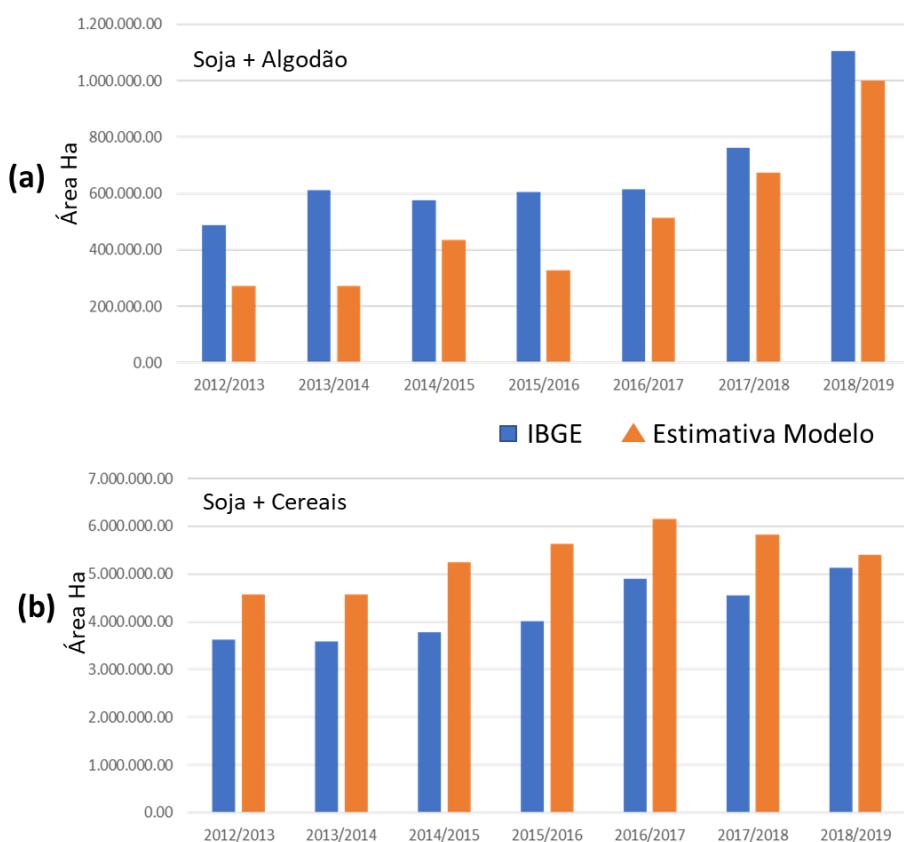
A construção de uma metodologia que permita o monitoramento de um país com dimensões continentais sempre foi um grande desafio. Anteriormente a questão mais crítica era a aquisição, processamento e armazenamento de dados de Observação da Terra, com a crescente disponibilização de petabytes destes dados de forma gratuita e o processamento em nuvem este problema praticamente inexiste. Entretanto, atualmente, nossa experiência demonstra que o desafio está na aquisição dos dados de treinamento para alimentar os algoritmos de aprendizado de máquina de forma que seja capaz de monitorar sistemas tão complexos e inovadores como os sistemas iLPs.

## 5 ETAPA 03: ANÁLISE TEMÁTICA DA IMPLANTAÇÃO DOS SISTEMAS INTEGRADOS NO ESTADO DO MATO GROSSO

### 5.1 Comparação com dados estatísticos oficiais

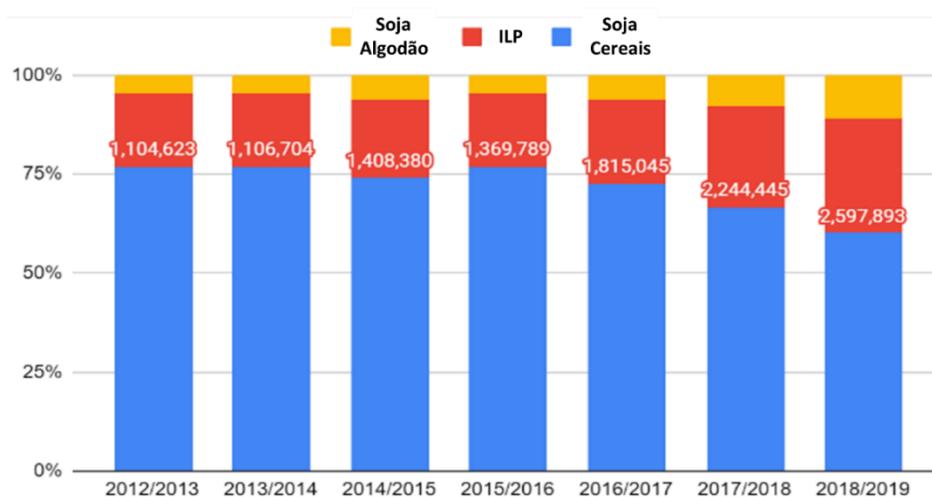
Os resultados das classificações do Nível 02 foram comparados com as estatísticas oficiais de safra do (IBGE, 2019). O IBGE realiza anualmente pesquisas amostrais da produção agropecuária ao nível municipal, os chamados Pesquisa Agrícola Municipal (PAM). Para uma melhor base de comparação, a análise foi focada nas culturas de segundo ciclo, ou seja, foram avaliadas as área de algodão e para SCe, a área de milho, girassol e ou sorgo conforme apresentado na **Figura 44**.

Figura 44 - Comparações entre as áreas cultivadas anuais do Mato Grosso fornecidas pelo IBGE-PAM e aquelas obtidas pela classificação Random Forest, para (a) algodão (classe SA), e (b) cereais (classe SCe).



Em nível estadual, as áreas de algodão, mapeadas por nosso trabalho tiveram correlação de 94%, enquanto para as áreas de SCe, foi atingido o valor de 74% quando comparado com os resultados estaduais do PAM do IBGE. A classificação superestimou as áreas de SCe, fato que ocorreu provavelmente por considerar o milheto na classificação, informação não disponível nas estatísticas do IBGE. Cabe ressaltar que os resultados do PAM do IBGE são baseados em amostras e não em levantamentos a campo, contendo incertezas, não podendo ser consideradas como referências absolutas. A evolução em área dos sistemas iLP é apresentada na **Figura 45**<sup>2</sup>

Figura 45 - Variação anual na distribuição das classes obtidas pelo método Random Forest, e valores das áreas cultivadas da classe iLP.



O IBGE não mapeia iLP, mas outros *benchmarks* podem ser utilizados como base de comparação:

- A partir de contatos com grandes produtores e cooperativas, a “Rede iLPF”<sup>2</sup> (EMBRAPA, 2017) estimou a área em sistemas iLPF para a campanha 2015/2016 em 1.501 Mha para o Mato Grosso, sendo que no Brasil, 83% dos sistemas iLPF foram implantados no modelo iLP (sem o componente florestal); se aplicarmos essa taxa de 83% para o estado de Mato Grosso, chegamos a um valor de 1,25 Mha de iLP implantado para o ano agrícola 2015/2016; esses valores devem ser comparados com a estimativa feita neste estudo, ou seja, 1,37 Mha;

<sup>2</sup> A rede iLPF (Rede iLPF) é formada pela Embrapa e pelas empresas Cocamar, Dow Agroscience, John Deere, Parker e Syngenta, que por meio de Unidades de Transferência de Tecnologia disseminam a tecnologia ILPF.

- No levantamento da campanha 2012/2013, Gil, Siebold e Berger (2015) constataram que 89% dos SIs em Mato Grosso eram iLP, ou 1,35 Mha (1,37 Mha estimado nesta tese).

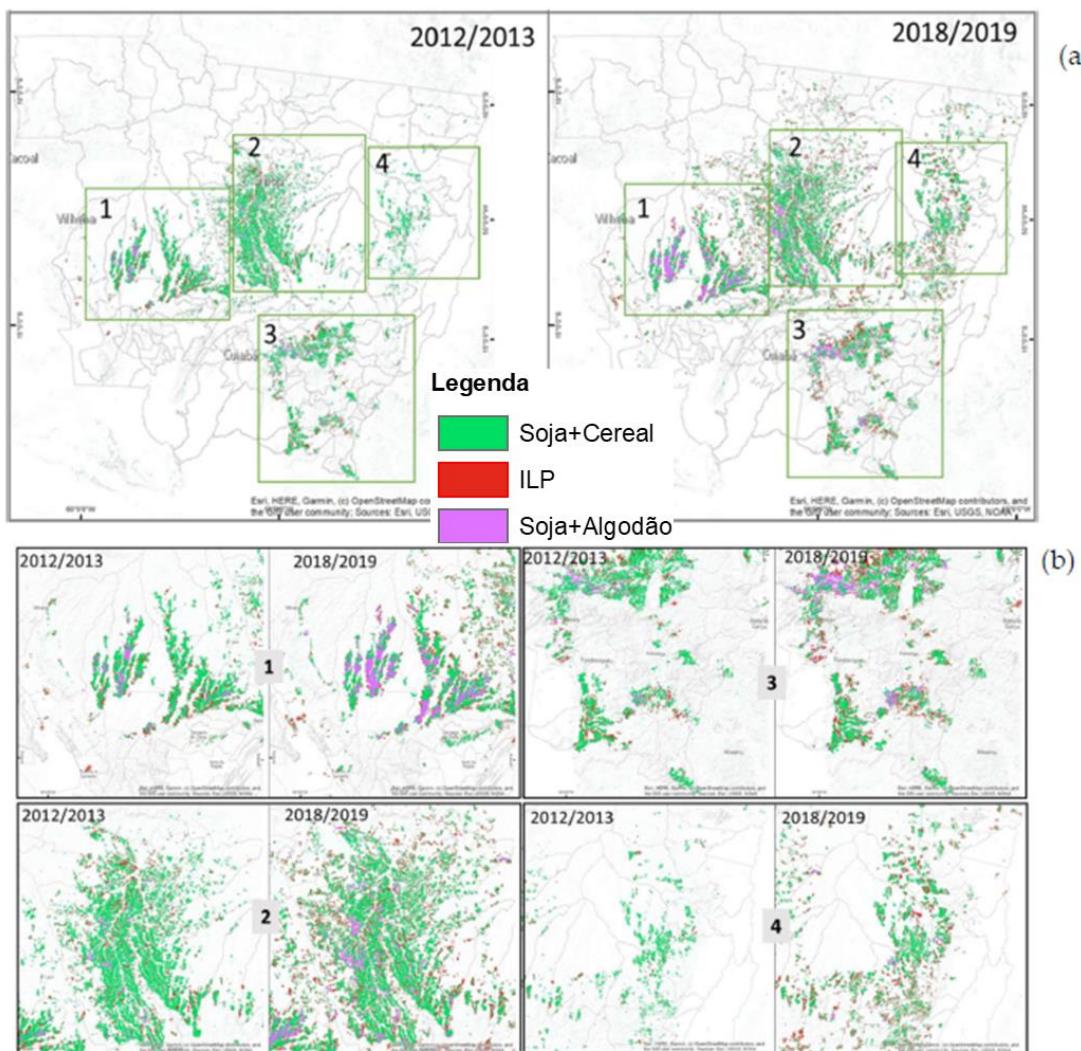
Desta forma, com as bases existentes, mesmo que limitadas, considera-se aqui que a área de iLP estimada nesta tese apresenta coerência com a realidade de campo.

## 5.2 Dinâmica temporal

Os sistemas sequenciais associados a soja são predominantes atualmente no Mato Grosso e já haviam sido apontados por outros autores (ARVOR et al., 2008; KASTENS et al., 2017; PICOLI et al., 2018; SPERA et al., 2014) preferencialmente para o milho, que veio substituindo o milheto, seguido do algodão como segundo ciclo. A intensificação sustentável pelos sistemas integrados aumentou mais de 136% no estado, passando de ~1 100 000 ha no ano safra 2012/2013 para ~2 600 000 ha no ano 2018/2019. É possível observar na **Figura 46** que dentro das opções de cultivos sequenciais os iLPs vêm ganhando maior importância, passando de 18,6% para 28,9%, a medida que o algodão aumenta sua proporcionalidade de 4,6% para 11,1%. Dentre o período analisado, o sistema SCe perde sua importância proporcional, caindo de 76,9% para 60%, sugerindo uma fase de aumento na intensificação de forma integrada no sistema lavoura-pecuária.

A **Figura 46** (a) apresenta o mapeamento realizado com a expansão das áreas de cultivo sequencial e sistemas integrados do tipo iLP.

Figura 46 - Mapas que mostram a evolução dos sistemas de cultivo do Nível 2 entre as safras 2012/2013 e 2018/2019, para (a) todo o Mato Grosso; (b) duas das quatro principais áreas de cultivo do estado (zoom).



As **Figuras 46** a e b parecem mostrar visualmente que o sistema Soja + Algodão exibe um aumento mais significativo quando comparado com as áreas de iLP. Isso é explicado pelo fato de o sistema Soja + Algodão apresentar uma concentração maior em certas regiões, além de estarem presentes em grandes áreas, possivelmente em grandes propriedades, realidade contrária às áreas de iLP. A área média calculada de superfície dos iLPs é de 65 ha, enquanto a de um sistema Soja + Algodão é de 700 ha, enquanto a de um sistema Soja + Cereais é de 600 ha. Esses resultados sugerem que os produtores que implementam SIs possuem propriedades menores, ou no caso de grandes proprietários, apenas áreas menores da fazenda seriam destinadas à integração, suposição aderente com a pesquisa realizada por Gil, Siebold e Berger

(2015). Os autores verificaram que os produtores realizam a integração entre os sistemas em apenas 30% de suas propriedades em média.

### 5.3 Dinâmica Espacial

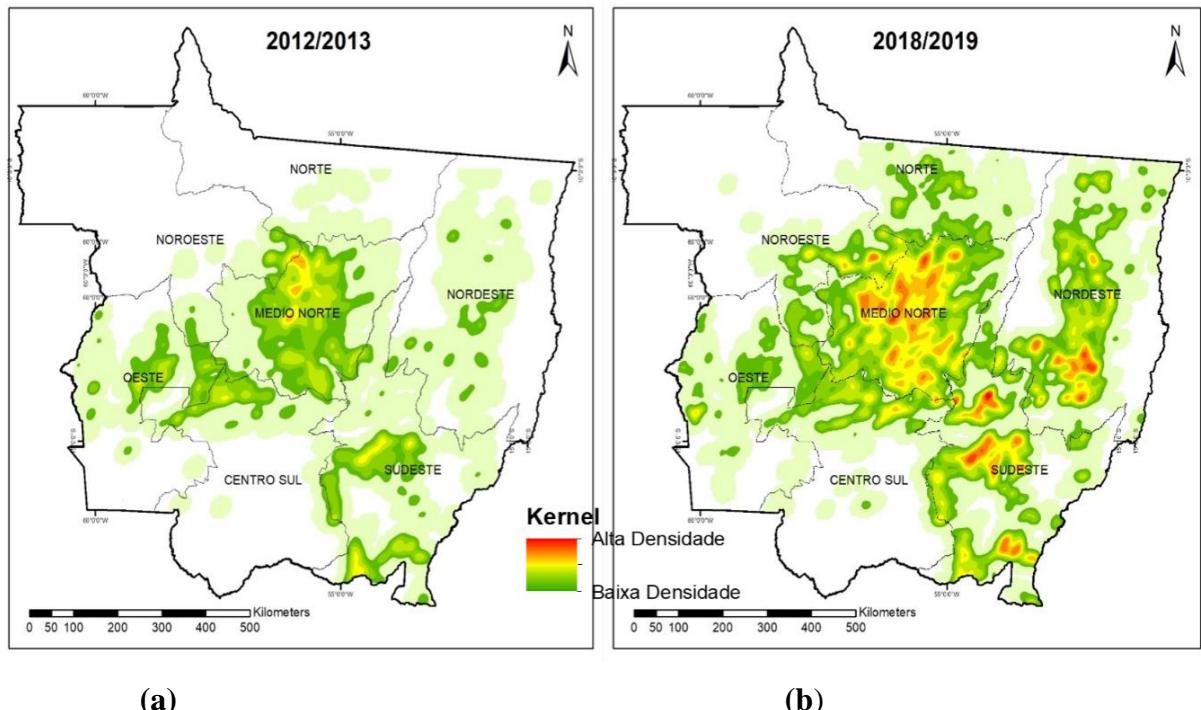
Compreender os facilitadores e restrições da ocorrência dos SIs no Brasil é essencial para o sucesso da implementação de políticas relacionadas não somente ao clima propostas pelo governo brasileiro, mas para o caminho de uma agricultura com bases sustentáveis que possibilite a coexistência entre produção e conservação. Análises espaciais que estimem a dispersão da implementação destes sistemas podem avaliar sua viabilidade potencial como estratégia de intensificação sustentável em regiões onde a pecuária extensiva persiste. Este item se propôs a iniciar uma discussão nesta direção, utilizando os sistemas detectados na metodologia aqui desenvolvida.

Foi demonstrado anteriormente que o iLP no Mato Grosso vem substituindo gradativamente o espaço dos sistemas convencionais. Para melhor visualização dessa evolução, foram calculados mapas anuais representando o índice de densidade de *Kernel*<sup>3</sup> para a classe iLP (**Figura 47**). Podemos identificar, na primeira safra da série analisada 2012/2013 (**Figura 47 a**), uma concentração de áreas de iLP entre os municípios de Sinop e Sorriso (região Centro Norte), mas com áreas dispersas no eixo norte-sul de região. Também há concentrações mais limitadas nas regiões Oeste, Sudeste e Centro-Sul. Áreas insignificantes são encontradas nas regiões Nordeste e Noroeste. Para a campanha 2018/2019 (**Figura 47b**), vemos a consolidação dos iLPs na região Centro-Norte, que continua sendo a região mais importante, mas com um padrão mais disperso. Observa-se forte aumento nas regiões Sudeste e Nordeste e início na região Norte. Nas regiões Centro-Sul e em particular no Oeste, o ganho de área não é tão expressivo como se vê no mapa.

---

<sup>3</sup> Estimativa de densidade por *Kernel* é uma forma não-paramétrica para estimar a Função densidade de probabilidade de uma variável aleatória.

Figura 47 - Mapas de densidade (índices Kernel) das áreas estabelecidas no iLP durante os anos safra 2012/2013 (a) e 2018/2019 (b)

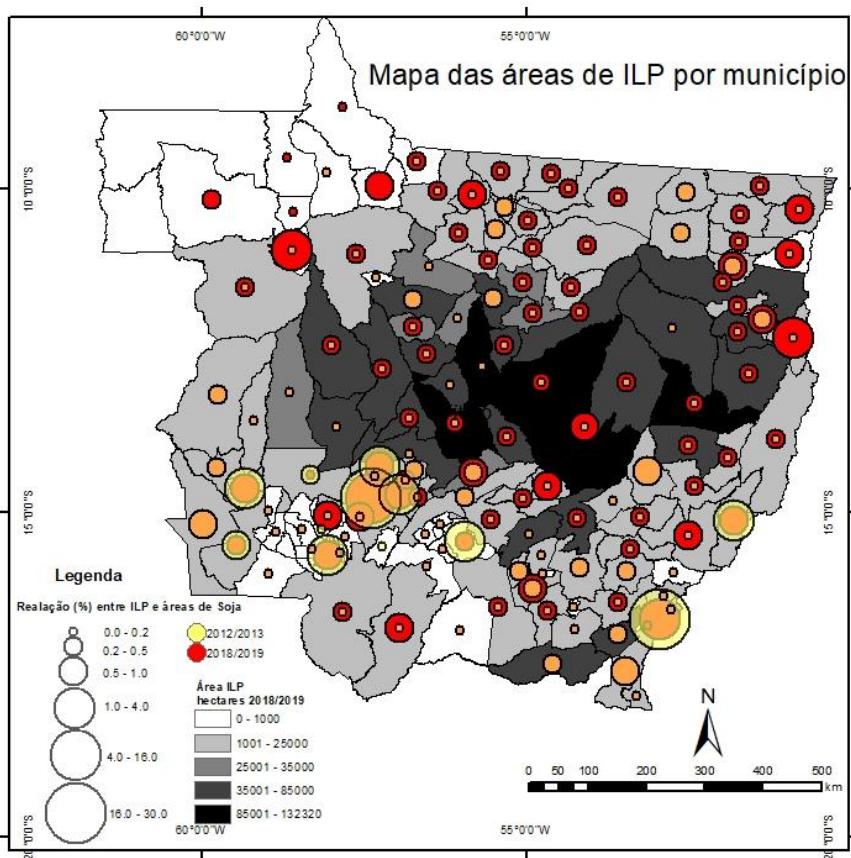


(a)

(b)

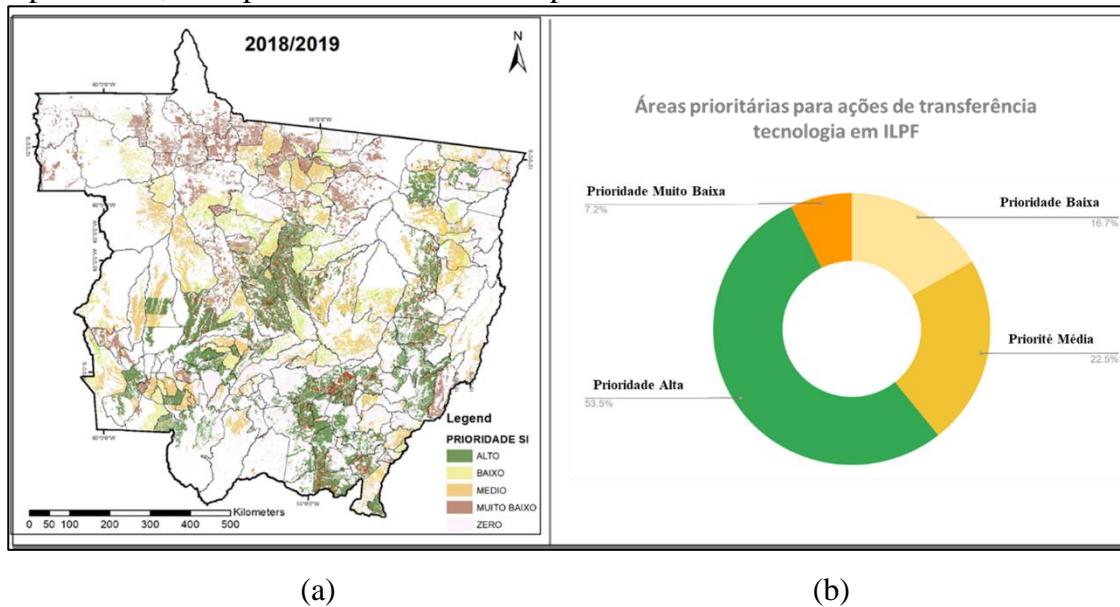
No total, para a campanha 2018/2019, 83% dos municípios do estado, ou seja, 117 dos 141 municípios tinham áreas implantadas com iLP, ante 69% (98 municípios) em 2012/2013. A **Figura 48** apresenta os principais municípios do estado com área em hectares de sistemas iLP implementados para o ano/safra 2018/2019. No APÊNDICE C é possível encontrar os mapas *kernel* com a série de 2013/2014 a 2018/2019.

Figura 48 - Mapa da quantidade de hectares de iLP implementados por município no ano/safra 2018/2019



Em 2018, a Embrapa e seus parceiros realizaram um estudo utilizando critérios espaciais para identificar áreas mais favoráveis à implantação dos sistemas integrados (PEREIRA; MANZATTO; SKORUPA, 2018). Este trabalho resultou em um zoneamento em 5 classes (zero, muito baixa, baixa, média e de alta prioridade) conforme apresentado na **Figura 49 a**. O cruzamento entre essas áreas prioritárias e a classificação do iLP realizada nesta tese (**Figura 29 b**) demonstra que mais da metade das áreas iLP implementadas em 2018/2019 estão em áreas de alta prioridade (53,5%). Para as áreas de prioridade média a taxa é de 22,5% e nenhum iLP é encontrado em áreas de prioridade zero.

Figura 49 - Correspondência entre as localizações prioritárias e as localizações reais das iLPs em Mato Grosso: (a) Mapa das áreas prioritárias da EMRAPA (2018); (b) Distribuição por zona de prioridade, de superfícies iLP estimadas por sensoriamento remoto



#### 5.4 Conclusão parcial

Os resultados encontrados apontam para uma trajetória de intensificação sustentável da agropecuária no estado do Mato Grosso. Por meio da acurácia encontrada as técnicas testadas e a modelagem realizada neste estudo mostraram serem capazes de compor uma metodologia de monitoramento de sistemas complexos de cultivo sequencial, em particular nos SIs do tipo iLP, resultados estes apresentados na acurácia encontrada. A dispersão espacial no estado do Mato Grosso dos sistemas iLP são apresentados de forma desigual entre regiões, apresentando uma significativa consolidação na região do Médio-Norte. Cabe ressaltar que a investigação das causas deste padrão de concentração é necessária para delineamentos da política territorial.

## **CONSIDERAÇÕES FINAIS E PERSPECTIVAS FUTURAS**

A observação da Terra desempenha um papel essencial no monitoramento da superfície terrestre. Suas características sinópticas e de repetitividade permitem a análise da dinâmica espacial em diferentes escalas. Nos últimos anos, dados de sensoriamento remoto têm sido utilizados para mapear práticas de intensificação agrícola (irrigação, culturas sequenciais) em escalas nacionais ou regionais, mas poucos exemplos existem no mapeamento de práticas sustentáveis de intensificação da agricultura, como sistemas integrados de lavoura-pecuária. Para atender às políticas públicas do Plano ABC, o Estado brasileiro precisa monitorar e quantificar os SIs, possibilitando a comunicação interna e externa sobre o cumprimento de suas metas, além da possibilidade de utilizar estas informações para compreender os facilitadores e barreiras locacionais. Estas podem estar relacionados a diversos fatores, seja de ordem cultural, social, ambiental e mesmo de viabilidade econômica.

Com base nos desafios encontrados na tese, pode-se concluir que para produzir mapas anuais em todo o país com base no sensoriamento remoto será necessário suprir alguns pontos: 1) entender como funcionam os SIs, que é uma condição necessária para a transição de um mapa de cobertura da terra (mais relacionado com o observável em imagens) em um mapa de uso da terra (informações interpretadas, baseadas em conhecimento); e 2) desenvolver um método de mapeamento baseado no processamento de séries temporais de imagens de sensoriamento remoto, que, por sua vez, se desdobram em quatro principais desafios a) Mapear os sistemas de cultivo complexos; b) Classificar estes sistemas a nível regional e, assim, levar em conta sua variabilidade espacial devido às condições ambientais intranuais; c) Tratar dados de sensoriamento remoto para mapear retrospectivamente, de forma multitemporal, levando em conta sua diversidade de condições ambientais interanuais; d) Processar um grande volume de dados.

### a) Sistemas complexos

Os SIs de produção agropecuária, como o ILPF, abrangem diversas estratégias produtivas, podendo apresentar diversos arranjos espaciais e temporais. As atividades relacionadas à agricultura, pecuária e silvicultura, realizadas na mesma área de forma sequencial ou simultaneamente, aumentam a complexidade do sistema e dificultam na identificação de padrões de extração de informação por sensoriamento remoto. Por essa razão,

é necessário utilizar abordagens que considerem as séries temporais de imagens de satélite e o conhecimento das práticas agrícolas, evoluindo para a confecção de mapas de uso da terra.

- b) Classificar esses sistemas a nível regional levando em conta sua variabilidade espacial devido às condições ambientais intransuas.

Um fluxo de processamento de séries temporais MODIS foi desenvolvida. Esta se baseou em pré-processamentos simplificados, como a suavização e filtragem das séries temporais ou cálculos de índices fenométricos. Foi constatado durante o desenvolvimento do trabalho que as técnicas testadas deterioram a precisão das classificações dos sistemas de cultivo e, que por outro lado, o uso de alta dimensionalidade, juntando as séries temporais de índices de vegetação e as bandas espectrais, apresentaram boas métricas de acurácia (acurácia global de 0,96). Também concluímos que o uso do algoritmo RF é ligeiramente mais eficiente do que o SVM. A escolha do estado de Mato Grosso, que apresenta significativa variedade de ambientes naturais, possibilitou avaliar a robustez dos métodos em diferentes contextos climáticos.

- c) Tratar dados de sensoriamento remoto retrospectivamente de forma multi-temporal (avaliando a diversidade de condições ambientais interanuais).

Um dos objetivos dessa tese foi identificar e avaliar a evolução espacial e temporal da implantação de SIs no estado do Mato Grosso. Esta análise demanda o desenvolvimento de uma metodologia para aplicação a uma série histórica, que neste caso foi realizada no período da safra 2012/2013 até 2018/2019, totalizando 7 anos. A escolha dessa janela de tempo foi feita principalmente pela disponibilidade de dados coletados no campo. Baseado nesta série histórica e com a dimensionalidade de 92 imagens, um total de 3.864 imagens foram processadas em conjunto com aproximadamente 25.000 pixels para treinamento/validação da classificação. Este foi facilitado pelo uso da plataforma *Google Earth Engine*, dada a facilidade de acesso, processamento, agilidade e disponibilidade de produtos prontos para uso. Outro aspecto importante que foi considerado para a utilização da plataforma do *Google Earth Engine* foi o seu caráter de código aberto, o que permite sua fácil reprodução em outras áreas ou regiões.

- d) Processar de um grande volume de dados.

A solução proposta nesta tese, traz a junção dos domínios de *big data*, processamento de dados em nuvem e algoritmos de classificação baseados em aprendizado de máquina

aplicados aos dados de observação da Terra. Esta abordagem se mostrou com grande potencial para suprir desafios anteriormente colocados na área de sensoriamento remoto, como o tratamento de grande volume de dados. Embora este tratamento possibilite desenvolvimentos metodológicos regionais, a importância do conhecimento da temática local ainda é fundamental, pois possibilita a tradução do conhecimento sobre usos agrícolas para a produção de mapas de uso da terra em dados de observação da Terra. A construção de uma base de dados de campo adequados para treinar e validar algoritmos de classificação em grandes áreas foi a etapa mais sensível, pela dificuldade de acesso. Esta coleta pode ser muito custosa, necessitando extensivas visitas à campo para realizar entrevistas a produtores. Na tese, a estratégia de classificação aplicada na série histórica (2012-2019) e nas 6 regiões climáticas do estado de Mato Grosso, utilizando uma abordagem hierárquica em 4 níveis, mostram que o uso de uma única base de dados de aprendizagem (incluindo amostras de diferentes anos e regiões) utilizados para classificar cada região e ano individualmente fornece detalhes de classificação semelhantes aos obtidos para classificações feitas com uma base de dados de aprendizagem dedicada (adquirido em cada região e para cada ano). O alto número de amostras compensa em grande parte a variabilidade espaço-temporal das classes.

A partir dos mapas produzidos, foi possível observar/quantificar um aumento significativo na implantação de sistemas integrados no estado, o que está em consonância com a pesquisa realizada a partir de entrevistas, onde foi identificada uma adoção regular, mas heterogênea de sistemas integrados a nível estadual.

Em conclusão, os resultados deste trabalho são uma importante contribuição para o desenvolvimento de um protocolo de monitoramento da agricultura de baixa emissão de carbono. Este protocolo é necessário para quantificar, qualificar e relatar esse tipo de informação a organizações nacionais e internacionais. Dessa forma, entende-se que essa tese tem potencial para contribuir tanto do ponto de vista acadêmico e científico, quanto da aplicação prática de uma melhor gestão pública na direção do desenvolvimento sustentável.

Pretende-se ainda testar/adaptar essa abordagem para todo o corredor da soja no Brasil, eventualmente levando a uma ferramenta operacional de monitoramento territorial e análise da adoção de práticas de intensificação sustentável.

### *Perspectivas metodológicas*

Este fluxo metodológico pode ser aplicado a outros anos e outros estados sujeitos às mesmas condições encontradas nesta área de estudo. Principalmente dos biomas amazônicos,

cerrado e pantanal e especialmente ao padrão de cultivo de áreas com tamanhos maiores de parcelas de produção agrícola. No futuro, pode-se considerar um maior refinamento da resolução espacial, ou seja, o uso de novas fontes de imagens de satélite, como série Landsat, CBERS-4 e 4A, Sentinel-2, Sentinel-1 (para regiões com maior nebulosidade), ou do satélite Amazônia-1, prestes a ser lançado, que tem dentre suas principais características uma alta taxa de revisita (5 dias) em combinação ou complemento com MODIS. O Sentinel é uma promessa para o monitoramento dos sistemas de cultivo, pois se propõe a juntar características de alta resolução temporal, espectral e espacial. Vale ressaltar que a periodicidade de 5 dias foi alcançada somente a partir de março de 2018, pois entre o período de 2015 a 2017 as observações Sentinel-2 eram realizadas a cada 19 dias. A vantagem do MODIS continua sendo a consistência do conjunto de dados ao longo do tempo (desde o ano 2000), com alta frequência temporal. Existem iniciativas de fusão, harmonização, normalização radiométrica entre dados de sensores com características específicas, que podem ser testadas futuramente, ou até a utilização dos produtos de diferentes sensores de forma particularizada, como descritores individuais, sem que os diferentes dados tenham que compor uma única série normalizada, uma vez que a correlação temporal, base até então dos estudos de STIS, pode não apresentar tanto peso como se imagina em um classificador de aprendizagem de máquina e em algoritmos de aprendizagem profunda, como as redes convolucionais, que começam a apresentar resultados importantes na área de sensoriamento remoto. As redes convolucionais podem ser mais uma opção a ser avaliada futuramente, inclusive para o mapeamento dos ILPFs, que apresentam uma característica espacial/geométrica peculiar.

A utilização do *Google Earth Engine* possibilitou o desenvolvimento da metodologia, com todos os aspectos positivos já mencionado, porém é necessário pontuar preocupações sobre os delineamentos e decisões futuras de uma empresa privada como a Google, que pode, por exemplo, começar a cobrar pela utilização de sua estrutura. Este tipo de risco é menor em estruturas de organizações colaborativas como o *Orfeo ToolBox* (OTB), ou estruturas governamentais como a estrutura em desenvolvimento do Cubo de Dados brasileiro, que é considerado aqui como uma opção na perspectiva deste trabalho.

### *Perspectivas Operacionais*

O monitoramento e criação de mecanismos para a aceleração da implantação da adoção dessas práticas em nível nacional é de grande importância. Esta importância se estende para toda uma rede que envolve empresas públicas, privadas e Organizações não governamentais (ONGs) que desenvolvem programas de agricultura de baixo carbono no Brasil. Esta iniciativa metodológica em parceria com a Rede ILPF pode contribuir para o aumento dos dados necessários para treinar o classificador e testar/aplicar a metodologia em outros estados do corredor da soja no Brasil, não somente com dados de iLP, mas dos sistemas com a componente florestal, possibilitando estimar a quantidade de sistemas ILPFs já implantados no Brasil. Além dos dados necessários de campo, a Rede ILPF pode ser fundamental para suprir conhecimento especializado para impulsionar a aplicação da metodologia em outros estados do corredor da soja no Brasil.

Por fim este trabalho entende como de grande importância para o programa de desenvolvimento da agricultura sustentável no Brasil, a criação de modelos de análise espacial, que possibilitem correlacionar a velocidade e o nível de implantação dos SI com variáveis como clima, solo, infraestrutura local e regional, experiência do produtor, tecnologias disponíveis. Todas as peculiaridades regionais ou até mesmo a nível da fazenda, são entendidos neste trabalho, como de grande importância para auxiliar a gestão territorial no caminho para um modelo que compatibilize a produção, conservação e diversidade.

## REFERÊNCIAS

- ADAMI, Marcos; RUDORFF, Bernardo Friedrich Theodor; FREITAS, Ramon Morais; AGUIAR, Daniel Alves; SUGAWARA, Luciana Miura; MELLO, Marcio Pupin. Remote Sensing Time Series to Evaluate Direct Land Use Change of Recent Expanded Sugarcane Crop in Brazil. **Sustainability**, [S. l.], v. 4, n. 4, 2012. ISSN: 2071-1050. DOI: 10.3390/su4040574.
- AGUIAR, Daniel Alves; RUDORFF, Bernardo Friedrich Theodor; SILVA, Wagner Fernando; ADAMI, Marcos; MELLO, Marcio Pupin. Remote Sensing Images in Support of Environmental Protocol: Monitoring the Sugarcane Harvest in São Paulo State, Brazil. **Remote Sensing**, [S. l.], v. 3, n. 12, p. 2682–2703, 2011. DOI: 10.3390/rs3122682.
- ALBUQUERQUE, Igor; ALENCAR, Ane; ANGELO, Claudio. SEEG 8 ANÁLISE DAS EMISSÕES BRASILEIRAS DE GASES DE EFEITO ESTUFA E SUAS IMPLICAÇÕES PARA AS METAS DE CLIMA DO BRASIL 1970-2019. [S. l.], p. 41, 2020.
- ALMEIDA, CMVC. Sistemas Agroflorestais como alternativa auto-sustentável para o Estado de Rondônia: Histórico, aspectos agronômicos e perspectivas de mercado. In: **Secretaria de Estado do Planejamento e Coordenação Geral**. Porto Velho: PANAFLORO;PNUD, 1995.
- ALMEIDA, Cláudio Aparecido De; COUTINHO, Alexandre Camargo; ESQUERDO, Júlio César Dalla Mora; ADAMI, Marcos; VENTURIERI, Adriano; DINIZ, Cesar Guerreiro; DESSAY, Nadine; DURIEUX, Laurent; GOMES, Alessandra Rodrigues. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. **Acta Amazonica**, [S. l.], v. 46, n. 3, p. 291–302, 2016. DOI: 10.1590/1809-4392201505504.
- ALVES, Maria Aparecida Senaubar; MACHADO, Luiz Augusto Toledo; PRASAD, Gannabathula Sri Sesha Durga. Estudo da variabilidade da cobertura de nuvens altas na Amazônia Central. **Acta Amazonica**, [S. l.], v. 37, n. 1, p. 71–79, 2007. DOI: 10.1590/s0044-59672007000100008.
- ANDERSON, James R.; HARDY, Ernest E.; ROACH, John T.; WITMER, Richard E. **A land use and land cover classification system for use with remote sensor data**. [s.l.] : US Geological Survey, 1976. DOI: 10.3133/pp964. Disponível em: <https://doi.org/10.3133/pp964>.
- ARAÚJO, HJ. T. **Folha SF.21 - Campo Grande. Projeto RADAMBRASIL; Geologia**.: RADAMBRASIL; Geologia. Rio de Janeiro: Min. das Minas e Energia; Secretaria Geral, 1982.
- ARVOR, Damien; DUBREUIL, Vincent; RONCHAIL, Josyane; SIMÕES, Margareth; FUNATSU, Beatriz M. Spatial patterns of rainfall regimes related to levels of double cropping agriculture systems in Mato Grosso (Brazil). **International Journal of Climatology**, [S. l.], v. 34, n. 8, p. 2622–2633, 2013. DOI: 10.1002/joc.3863.
- ARVOR, Damien; JONATHAN, Milton; MEIRELLES, Margareth Simões Penello; DUBREUIL, Vincent; DURIEUX, Laurent. Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil. **International Journal of Remote Sensing**, [S. l.], v. 32, n. 22, p. 7847–7871, 2011. ISSN: 0143-1161. DOI: 10.1080/01431161.2010.531783.

ARVOR, Damien; MEIRELLES, Margareth; DUBREUIL, Vincent; BÉGUÉ, Agnès; SHIMABUKURO, Yosio E. Analyzing the agricultural transition in Mato Grosso, Brazil, using satellite-derived indices. **Applied Geography**, [S. l.], v. 32, n. 2, p. 702–713, 2012. DOI: 10.1016/j.apgeog.2011.08.007.

ARVOR, Damien; TRITSCH, Isabelle; BARCELLOS, Christovam; JÉGOU, Nicolas; DUBREUIL, Vincent. Land use sustainability on the South-Eastern Amazon agricultural frontier: Recent progress and the challenges ahead. **Applied Geography**, [S. l.], v. 80, p. 86–97, 2017. DOI: 10.1016/j.apgeog.2017.02.003.

ARVOR; JONATHAN, Milton; MEIRELLES, Margareth Simões Penello; DUBREUIL, Vincent; LECERF, Remi. Comparison of Multitemporal MODIS-EVI Smoothing Algorithms and its Contribution to Crop Monitoring. In: IGARSS 2008 - 2008 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM 2008, Anais [...]. . In: IGARSS 2008 - 2008 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM. [s.l: s.n.] p. II–958. ISBN: 2153-7003. DOI: 10.1109/IGARSS.2008.4779155.

ASMARYAN, Shushanik et al. Paving the Way towards an Armenian Data Cube. **Data**, [S. l.], v. 4, n. 3, p. 117, 2019. DOI: 10.3390/data4030117.

ASSIS, R. L. De. Agricultura orgânica e agroecologia: questões conceituais e processo de conversão. [S. l.], 2005. ISSN: 1517-8498. Disponível em: <http://www.infoteca.cnptia.embrapa.br/handle/doc/628360>. Acesso em: 23 fev. 2021.

ATKINSON, Peter M.; JEGANATHAN, C.; DASH, Jadu; ATZBERGER, Clement. Inter-comparison of four models for smoothing satellite sensor time-series data to estimate vegetation phenology. **Remote Sensing of Environment**, [S. l.], v. 123, p. 400–417, 2012. DOI: 10.1016/j.rse.2012.04.001.

BALBINO, Luiz Carlos; BARCELOS, Alexandre de Oliveira; STONE, Luiz Fernando. **Marco Referencial Lavoura-Pecuária-Floresta**. Embrapa, DF, 2011.

BANCO DO BRASIL. **Agricultura de Baixo Carbono (ABC) - Você | Banco do Brasil**. 2013. Disponível em: [https://www.bb.com.br/pbb/pagina-inicial/agronegocios/agronegocio---produtos-e-servicos/credito/investir-em-sua-atividade/agricultura-de-baixo-carbono-\(abc\)#/](https://www.bb.com.br/pbb/pagina-inicial/agronegocios/agronegocio---produtos-e-servicos/credito/investir-em-sua-atividade/agricultura-de-baixo-carbono-(abc)#/). Acesso em: 23 fev. 2021.

BARONA, Elizabeth; RAMANKUTTY, Navin; HYMAN, Glenn; COOMES, Oliver T. The role of pasture and soybean in deforestation of the Brazilian Amazon. **Environmental Research Letters**, [S. l.], v. 5, n. 2, p. 024002, 2010. DOI: 10.1088/1748-9326/5/2/024002.

BAUMANN, P.; DEHMEL, A.; FURTADO, P.; RITSCH, R.; WIDMANN, N. The multidimensional database system RasDaMan. In: PROCEEDINGS OF THE 1998 ACM SIGMOD INTERNATIONAL CONFERENCE ON MANAGEMENT OF DATA - SIGMOD \TEXTQUOTESINGLE98 1998, Anais [...]. : ACM Press, 1998 DOI: 10.1145/276304.276386. Disponível em: <https://doi.org/10.1145/276304.276386>.

BÉGUÉ, Agnès et al. Remote Sensing and Cropping Practices: A Review. **Remote Sensing**, [S. l.], v. 10, n. 1, p. 99, 2018 a. DOI: 10.3390/rs10010099.

BÉGUÉ, Agnès; FERRAZ, Rodrigo; LEBOURGEOIS, Valentine; LELONG, Camille; SIMOES, Margareth; VERÓN, Santiago; X, X; Y, Y. Remote Sensing and Cropping Practices: A Review. **Remote Sensing**, [S. l.], v. 10, 2018 b. DOI: 10.3390/rs10010099.

BELGIU, Mariana; CSILLIK, Ovidiu. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. **Remote Sensing of Environment**, [S. l.], v. 204, p. 509–523, 2018. DOI: 10.1016/j.rse.2017.10.005.

BELGIU, Mariana; DRĂGUT, Lucian. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 114, p. 24–31, 2016. DOI: 10.1016/j.isprsjprs.2016.01.011.

BELLÓN, Beatriz; BÉGUÉ, Agnès; SEEN, Danny Lo; ALMEIDA, Claudio Aparecido De; SIMÕES, Margareth. A Remote Sensing Approach for Regional-Scale Mapping of Agricultural Land-Use Systems Based on NDVI Time Series. **Remote Sensing**, [S. l.], v. 9, p. 600, 2017. DOI: 10.3390/rs9060600.

BELLÓN DE LA CRUZ, Beatriz. **Une approche multiscalaire par télédétection pour la cartographie et la caractérisation des systèmes agricoles à l'échelle régionale**. 2018. [S. l.], 2018. Disponível em: <http://www.theses.fr/2018AGPT0002/document>.

BENDINI, H. do N.; SANCHES, I. D.; KÖRTING, T. S.; FONSECA, L. M. G.; LUIZ, A. J. B.; FORMAGGIO, A. R. Using Landsat 8 image time series for crop mapping in a region of Cerrado, Brazil. [S. l.], 2016. DOI: 10.5194/isprarchives-XLI-B8-845-2016. Disponível em: <http://www.alice.cnptia.embrapa.br/handle/doc/1071280>. Acesso em: 24 fev. 2021.

BHOLANATH, Pradeepa et al. **Integrating remote-sensing and ground-based observations for estimation of emissions and removals of greenhouse gases in forests Methods and Guidance from the Global Forest Observations Initiative**. [s.l: s.n.]. ISBN: 978-92-990047-4-6.

BOUCHER, D.; ELIAS, P.; FAIRES, J., Smith. **Histórias de sucesso no âmbito do desmatamento. Nações tropicais onde as políticas de proteção e reflorestamento deram resultado**: Brasil: as maiores reduções de desmatamento e emissões em todo o mundo. [s.l.] : Union of concerned scientists, 2014.

BRASIL. **Plano ABC - Agricultura de Baixa Emissão de Carbono**. 2012. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/sustentabilidade/plano-abc/plano-abc-agricultura-de-baixa-emissao-de-carbono>. Acesso em: 14 jan. 2021.

BREIMAN, Leo. **Machine Learning**, [S. l.], v. 45, n. 1, p. 5–32, 2001. DOI: 10.1023/a:1010933404324.

BRIDHIKITTI, Arika; OVERCAMP, Thomas J. Estimation of Southeast Asian rice paddy areas with different ecosystems from moderate-resolution satellite imagery. **Agriculture, Ecosystems & Environment**, [S. l.], v. 146, n. 1, p. 113–120, 2012. DOI: 10.1016/j.agee.2011.10.016.

BROWN, J. Christopher; KASTENS, Jude H.; COUTINHO, Alexandre Camargo; VICTORIA, Daniel de Castro; BISHOP, Christopher R. Classifying multiyear agricultural land use data from Mato Grosso using time-series MODIS vegetation index data. **Remote Sensing of**

**Environment**, [S. l.J, v. 130, p. 39–50, 2013. ISSN: 0034-4257. DOI: 10.1016/j.rse.2012.11.009.

BULLOCK, Eric L.; WOODCOCK, Curtis E.; SOUZA, Carlos; OLOFSSON, Pontus. Satellite-based estimates reveal widespread forest degradation in the Amazon. **Global Change Biology**, [S. l.J, v. 26, n. 5, p. 2956–2969, 2020. DOI: 10.1111/gcb.15029.

BURLEY, Terence M. LAND USE OR LAND UTILIZATION? **The Professional Geographer**, [S. l.J, v. 13, n. 6, p. 18–20, 1961. DOI: 10.1111/j.0033-0124.1961.136\_18.x.

BUSTAMANTE, Mercedes M. C. et al. Estimating greenhouse gas emissions from cattle raising in Brazil. **Climatic Change**, [S. l.J, v. 115, n. 3–4, p. 559–577, 2012. DOI: 10.1007/s10584-012-0443-3.

CAI, Yaotong; LIN, Hui; ZHANG, Meng. Mapping paddy rice by the object-based random forest method using time series Sentinel-1/Sentinel-2 data. **Advances in Space Research**, [S. l.J, v. 64, n. 11, p. 2233–2244, 2019. DOI: 10.1016/j.asr.2019.08.042.

CÂMARA, Gilberto et al. **Land cover change maps for Mato Grosso State in Brazil: 2001-2017 (Version 2)**, links to files, supplement to: Picoli, Michelle; Câmara, Gilberto; Sanches, Ieda; Simoes, Rolf; Carvalho, Alexandre X Y; Maciel, Adeline; Coutinho, Alexandre; Esquerdo, Julio; Antunes, Joao; Begotti, Rodrigo; Arvor, Damien; Almeida, Claudio (2018): Big earth observation time series analysis for monitoring Brazilian agriculture. **ISPRS Journal of Photogrammetry and Remote Sensing**, 145, 328-339. [s.l.] : PANGAEA - Data Publisher for Earth & Environmental Science, 2018. DOI: 10.1594/PANGAEA.895495. Disponível em: <https://doi.pangaea.de/10.1594/PANGAEA.895495>.

CAMARA, Gilberto; ASSIS, Luiz Fernando; RIBEIRO, Gilberto; FERREIRA, Karine Reis; LLAPA, Eduardo; VINHAS, Lubia. Big earth observation data analytics. In: PROCEEDINGS OF THE 5TH ACM SIGSPATIAL INTERNATIONAL WORKSHOP ON ANALYTICS FOR BIG GEOSPATIAL DATA - BIGSPATIAL \TEXTQUOTESINGLE16 2016, Anais [...]. : ACM Press, 2016 DOI: 10.1145/3006386.3006393. Disponível em: <https://doi.org/10.1145/3006386.3006393>.

CAMPOS, Margarida Cassia. MODERNIZAÇÃO DA AGRICULTURA, EXPANSÃO DA SOJA NO BRASIL E AS TRANSFORMAÇÕES SOCIOESPACIAIS NO PARANÁ. **Revista Geografar**, [S. l.J, v. 6, n. 1, 2011. DOI: 10.5380/geografar.v6i1.21808. Disponível em: <https://doi.org/10.5380/geografar.v6i1.21808>.

CAO, Ruyin; CHEN, Yang; SHEN, Miaogen; CHEN, Jin; ZHOU, Ji; WANG, Cong; YANG, Wei. A simple method to improve the quality of NDVI time-series data by integrating spatiotemporal information with the Savitzky-Golay filter. **Remote Sensing of Environment**, [S. l.J, v. 217, p. 244–257, 2018. DOI: 10.1016/j.rse.2018.08.022.

CHEN, Jin; JÖNSSON, Per; TAMURA, Masayuki; GU, Zhihui; MATSUSHITA, Bunkei; EKLUNDH, Lars. A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky-Golay filter. **Remote Sensing of Environment**, [S. l.J, v. 91, p. 332–344, 2004. DOI: 10.1016/j.rse.2004.03.014.

CHEN, Yaoliang et al. **Mapping croplands, cropping patterns, and crop types using MODIS time-series data.** [s.l: s.n.]. v. 69 DOI: 10.1016/j.jag.2018.03.005.

CHI, Mingmin; PLAZA, Antonio; BENEDIKTSSON, Jon Atli; SUN, Zhongyi; SHEN, Jinsheng; ZHU, Yangyong. Big Data for Remote Sensing: Challenges and Opportunities. **Proceedings of the IEEE**, [S. l.], v. 104, n. 11, p. 2207–2219, 2016. DOI: 10.1109/jproc.2016.2598228.

CLELAND, Elsa E.; CHUINE, Isabelle; MENZEL, Annette; MOONEY, Harold A.; SCHWARTZ, Mark D. Shifting plant phenology in response to global change. **Trends in Ecology & Evolution**, [S. l.], v. 22, n. 7, p. 357–365, 2007. ISSN: 0169-5347. DOI: 10.1016/j.tree.2007.04.003.

CLEVERS, J. G. P. W. The derivation of a simplified reflectance model for the estimation of leaf area index. **Remote Sensing of Environment**, [S. l.], v. 25, n. 1, p. 53–69, 1988. DOI: 10.1016/0034-4257(88)90041-7.

COLDITZ, René. An Evaluation of Different Training Sample Allocation Schemes for Discrete and Continuous Land Cover Classification Using Decision Tree-Based Algorithms. **Remote Sensing**, [S. l.], v. 7, n. 8, p. 9655–9681, 2015. DOI: 10.3390/rs70809655.

COMBE, J.; BUDOWSKI, Gerardo. Clasificación de las técnicas agroforestales; una revisión de literatura. [S. l.], 1979. Disponível em: <http://repositorio.bibliotecaorto.catie.ac.cr:80/handle/11554/786>. Acesso em: 22 fev. 2021.

CORRÊA, Roberto Lobato. Tempo, Espaço e Geografia - um ensaio. **Revista Brasileira de Geografia**, [S. l.], v. 64, n. 1, p. 285–294, 2019. DOI: 10.21579/issn.2526-0375\_2019\_n1\_285-294.

COSSU, Roberto et al. A roadmap for a dedicated Earth Science Grid platform. **Earth Science Informatics**, [S. l.], v. 3, n. 3, p. 135–148, 2010. ISBN: 1865-0481.

CPRM. **Serviço Geológico do Brasil**. [s.d.]. Disponível em: <http://www.cprm.gov.br/publique/Geologia/Sensoriamento-Remoto-e-Geofisica/RADAM-D-628.html>. Acesso em: 17 fev. 2021.

CSILLIK, Ovidiu; BELGIU, Mariana; ASNER, Gregory P.; KELLY, Maggi. Object-Based Time-Constrained Dynamic Time Warping Classification of Crops Using Sentinel-2. **Remote Sensing**, [S. l.], v. 11, n. 10, p. 1257, 2019. DOI: 10.3390/rs11101257.

CUTLER, David; C EDWARDS, Thomas; BEARD, Karen; CUTLER, Adele; T HESS, Kyle; GIBSON, Jacob; LAWLER, Joshua. Random Forests for Classification in Ecology. **Ecology**, [S. l.], v. 88, p. 2783–92, 2007. DOI: 10.1890/07-0539.1.

DALPONTE, Michele; ORKA, Hans Ole; GOBAKKEN, Terje; GIANELLE, Damiano; NAESSET, Erik. Tree Species Classification in Boreal Forests With Hyperspectral Data. **IEEE Transactions on Geoscience and Remote Sensing**, [S. l.], v. 51, n. 5, p. 2632–2645, 2013. DOI: 10.1109/tgrs.2012.2216272.

DAUGHTRY, C. S. T.; DORAISWAMY, P. C.; HUNT, E. R.; STERN, A. J.; MCMURTREY, J. E.; PRUEGER, J. H. Remote sensing of crop residue cover and soil tillage intensity. **Soil and Tillage Research**, [S. l.], v. 91, n. 1–2, p. 101–108, 2006. DOI: 10.1016/j.still.2005.11.013.

DE FARIA, Adriano Silva; DE ARAÚJO, Fernando Moreira; JUNIOR, Laerte Guimarães Ferreira. LEVANTAMENTO DAS INICIATIVAS DE MAPEAMENTO DA COBERTURA E USO DA TERRA NO BRASIL. [S. l.], p. 4, 2019.

DE MATTOS SCARAMUZZA, Carlos et al. Land-Use and Land-Cover mapping of the Brazilian Cerrado bases mainly on Landsat-8 Satellite Images. **Revista Brasileira de Cartografia**, [S. l.], v. 69, 2017.

DEFOURNY, Pierre et al. Near real-time agriculture monitoring at national scale at parcel resolution: Performance assessment of the Sen2-Agri automated system in various cropping systems around the world. **Remote Sensing of Environment**, [S. l.], v. 221, p. 551–568, 2019. DOI: 10.1016/j.rse.2018.11.007.

DEFRIES, R.; ROSENZWEIG, C. Toward a whole-landscape approach for sustainable land use in the tropics. **Proceedings of the National Academy of Sciences**, [S. l.], v. 107, n. 46, p. 19627–19632, 2010. DOI: 10.1073/pnas.1011163107.

DELENNE, C.; DURRIEU, S.; RABATEL, G.; DESHAYES, M.; BAILLY, J. S.; LELONG, C.; COUTERON, P. Textural approaches for vineyard detection and characterization using very high spatial resolution remote sensing data. **International Journal of Remote Sensing**, [S. l.], v. 29, n. 4, p. 1153–1167, 2007. DOI: 10.1080/01431160701311259.

DIMA, S. **5 Reasons Why You Should Use Cross-Validation in Your Data Science Projects**. KDnuggets 2018. Disponível em: <https://www.kdnuggets.com/5-reasons-why-you-should-use-cross-validation-in-your-data-science-projects.html/>. Acesso em: 5 dez. 2020.

DINIZ, Cesar Guerreiro et al. DETER-B: The New Amazon Near Real-Time Deforestation Detection System. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [S. l.], v. 8, n. 7, p. 3619–3628, 2015. DOI: 10.1109/jstars.2015.2437075.

DIXON, J.; GULIVER, A.; GIBBSON, D. **Farming Systems and Poverty: Improving farmers' livelihoods in a changing world**. 2001. Disponível em: <http://www.fao.org/3/ac349e.pdf>.

DONOOGHUE, Daniel. REMOTE SENSING AND IMAGE INTERPRETATION edited by Thomas M. Lillesand and Ralph W. Kiefer, John Wiley, New York, 2000. No. of pages: 736. Price £29.95. ISBN 0 471 25515 7. **Earth Surface Processes and Landforms**, [S. l.], v. 26, n. 12, p. 1361–1361, 2001. DOI: 10.1002/esp.267.

DROULERS, M. **Brésil: une géohistoire**: Presses universitaires de France. Paris.

DUBREUIL, Vicent; JALLET, A.; RONCHAIL, J.; MAITELLI, G. Estimation des précipitations par télédétection au Mato Grosso (Brésil). **Annales de l'Association Internationale de Climatologie**, [S. l.], v. 1, p. 133–156, 2004. DOI: 10.4267/climatologie.1058.

DUDA, Richard O.; HART, Peter E.; STORK, David G. **Pattern Classification (2nd Edition)**. USA: Wiley-Interscience, 2000. ISBN: 0-471-05669-3.

EMBRAPA. **ICLF in numbers**. Embrapa, 2017. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1073425/iclf-in-numbers>. Acesso em: 22 maio. 2019.

**EOS. Earth Observation Systems (EOS) - Earth Observation System - IIASA**. 2013. Disponível em: <https://iiasa.ac.at/web/scientificUpdate/2013/researchProgram/EcosystemsServicesandManagement/EarthObservationSystems.html>. Acesso em: 22 fev. 2021.

**ESA. Working towards AI and Earth observation**. 2019. Disponível em: [https://www.esa.int/Applications/Observing\\_the\\_Earth/Working\\_towards\\_AI\\_and\\_Earth\\_observation](https://www.esa.int/Applications/Observing_the_Earth/Working_towards_AI_and_Earth_observation). Acesso em: 24 fev. 2021.

**ESA. Objectives – Sentinel-2 for Agriculture**. [s.d.]. Disponível em: <http://www.esa-sen2agri.org/objectives/>. Acesso em: 24 fev. 2021.

FAO, U. How to feed the world in 2050. In: ROME: HIGH-LEVEL EXPERT FORUM 2009, **Anais** [...]. [s.l: s.n.] p. 733.

FERRAZ, R. P. D.; SKORUPA, L. A. Intensificação sustentável: desafios e oportunidades para a agricultura brasileira. **FERRAZ, RPD; SKORUPA, L. A. Intensificação sustentável: desafios e oportunidades para a agricultura brasileira. Embrapa Solos-Artigo em periódico indexado (ALICE), 2017.**, [S. l.], v. 43, n. n.2, p. 37–42, 2017.

FERREIRA, Karine R. et al. Earth Observation Data Cubes for Brazil: Requirements, Methodology and Products. **Remote Sensing**, [S. l.], v. 12, n. 24, p. 4033, 2020. DOI: 10.3390/rs12244033.

FISHER, Peter; COMBER, Alexis; WADSWORTH, Richard. Land use and land cover: contradiction or complement. In: [s.l: s.n.]. p. 85–98.

FISHS, Gilberto; MARENKO, José A. **Clima da Amazônia**. 1996. Disponível em: <http://climanalise.cptec.inpe.br/~rclimanl/boletim/cliesp10a/fish.html>. Acesso em: 19 fev. 2021.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS (ORG.). **The future of food and agriculture: trends and challenges**. Rome: Food and Agriculture Organization of the United Nations, 2017. ISBN: 978-92-5-109551-5.

FRESCO, L. O.; WESTPHAL, E. A Hierarchical Classification of Farm Systems. **Experimental Agriculture**, [S. l.], v. 24, n. 4, p. 399–419, 1988. ISSN: 0014-4797. DOI: 10.1017/S0014479700100146.

FRITZ, Steffen et al. The Need for Improved Maps of Global Cropland. **Eos, Transactions American Geophysical Union**, [S. l.], v. 94, n. 3, p. 31–32, 2013. DOI: 10.1002/2013eo030006.

FRITZ, Steffen et al. A comparison of global agricultural monitoring systems and current gaps. **Agricultural Systems**, [S. l.], v. 168, p. 258–272, 2019. DOI: 10.1016/j.agsy.2018.05.010.

GALFORD, Gillian L.; MUSTARD, John F.; MELILLO, Jerry; GENDRIN, Aline; CERRI, Carlos C.; CERRI, Carlos E. P. Wavelet analysis of MODIS time series to detect expansion and intensification of row-crop agriculture in Brazil. **Remote Sensing of Environment**, Soil Moisture Experiments 2004 (SMEX04) Special Issue. [S. l.], v. 112, n. 2, Soil Moisture Experiments 2004 (SMEX04) Special Issue, p. 576–587, 2008. ISSN: 0034-4257. DOI: 10.1016/j.rse.2007.05.017.

GENG, S.; HESS, C. E.; AUBURN, J. Sustainable Agricultural Systems: Concepts and Definitions. **Journal of Agronomy and Crop Science**, [S. l.], v. 165, n. 2–3, p. 73–85, 1990. DOI: 10.1111/j.1439-037x.1990.tb00837.x.

GIL, Juliana; SIEBOLD, Matthias; BERGER, Thomas. Adoption and development of integrated crop–livestock–forestry systems in Mato Grosso, Brazil. **Agriculture, Ecosystems & Environment**, [S. l.], v. 199, p. 394–406, 2015. DOI: 10.1016/j.agee.2014.10.008.

GITELSON, Anatoly A.; KAUFMAN, Yoram J.; MERZLYAK, Mark N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, [S. l.], v. 58, n. 3, p. 289–298, 1996. DOI: 10.1016/s0034-4257(96)00072-7.

GIULIANI, Gregory; CHATENOIX, Bruno; BONO, Andrea De; RODILA, Denisa; RICHARD, Jean-Philippe; ALLENBACH, Karin; DAO, Hy; PEDUZZI, Pascal. Building an Earth Observations Data Cube: lessons learned from the Swiss Data Cube (SDC) on generating Analysis Ready Data (ARD). **Big Earth Data**, [S. l.], v. 1, n. 1–2, p. 100–117, 2017. DOI: 10.1080/20964471.2017.1398903.

GODFRAY, H. Charles J. et al. Food Security: The Challenge of Feeding 9 Billion People. **Science**, [S. l.], v. 327, n. 5967, p. 812–818, 2010. ISSN: 0036-8075, 1095-9203. DOI: 10.1126/science.1185383.

GÓMEZ, Cristina; WHITE, Joanne C.; WULDER, Michael A. Optical remotely sensed time series data for land cover classification: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 116, p. 55–72, 2016. ISSN: 0924-2716. DOI: 10.1016/j.isprsjprs.2016.03.008.

GORELICK, Noel; HANCHER, Matt; DIXON, Mike; ILYUSHCHENKO, Simon; THAU, David; MOORE, Rebecca. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, [S. l.], v. 202, p. 18–27, 2017. DOI: 10.1016/j.rse.2017.06.031.

HANSEN, M. C. et al. High-Resolution Global Maps of 21st-Century Forest Cover Change. **Science**, [S. l.], v. 342, n. 6160, p. 850–853, 2013. DOI: 10.1126/science.1244693.

HERRERO, M. et al. Smart Investments in Sustainable Food Production: Revisiting Mixed Crop-Livestock Systems. **Science**, [S. l.], v. 327, n. 5967, p. 822–825, 2010. DOI: 10.1126/science.1183725.

HMIMINA, G. et al. Evaluation of the potential of MODIS satellite data to predict vegetation phenology in different biomes: An investigation using ground-based NDVI measurements. **Remote Sensing of Environment**, [S. l.], v. 132, p. 145–158, 2013. ISSN: 0034-4257. DOI: 10.1016/j.rse.2013.01.010.

HOLLOWAY, Jacinta; MENGERSEN, Kerrie. Statistical Machine Learning Methods and Remote Sensing for Sustainable Development Goals: A Review. **Remote Sensing**, [S. l.], v. 10, n. 9, p. 1365, 2018. DOI: 10.3390/rs10091365.

HRID, J. N.; MCDERMID, Greg. Noise reduction of NDVI time series: an empirical comparison of selected techniques. **Remote Sens. Environ.**, [S. l.], v. 113, p. 248–258, 2008.

HTITIOU, Abdelaziz; BOUDHAR, Abdelghani; LEBRINI, Youssef; HADRIA, Rachid; LIONBOUI, Hayat; ELMANSOURI, Loubna; TYCHON, Bernard; BENABDELOUAHAB, Tarik. The Performance of Random Forest Classification Based on Phenological Metrics Derived from Sentinel-2 and Landsat 8 to Map Crop Cover in an Irrigated Semi-arid Region. **Remote Sensing in Earth Systems Sciences**, [S. l.], v. 2, n. 4, p. 208–224, 2019. DOI: 10.1007/s41976-019-00023-9.

HUETE, A. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, [S. l.], v. 59, n. 3, p. 440–451, 1997. DOI: 10.1016/s0034-4257(96)00112-5.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, [S. l.], v. 83, n. 1, p. 195–213, 2002. ISSN: 0034-4257. DOI: [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2).

IBGE. **Climatologia**. IBGE, 2011. Disponível em: <https://www.ibge.gov.br/geociencias/informacoes-ambientais/climatologia.html>. Acesso em: 2 abr. 2020.

IBGE (ORG.). **Manual técnico de uso da terra**. 3<sup>a</sup> edição ed., Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística--IBGE, 2013. (Manuais técnicos em geociências número 7). (Manuais técnicos em geociências número 7). ISBN: 978-85-240-4307-9.

IBGE. **Municipal Agricultural Production**. IBGE, 2019. Disponível em: <http://www2.sidra.ibge.gov.br/>. Acesso em: 10 out. 2020.

INMET. **Dados das estações meteorológicas**. 2019. Disponível em: <https://portal.inmet.gov.br/>. Acesso em: 25 jul. 2020.

INSTITUTO SOCIALMBIENTAL. **Almanaque Socioambiental Parque Indígena do Xingu 50 anos**. 2013. Disponível em: <https://www.socioambiental.org/pt-br/osis/publicacoes/almanaque-socioambiental-parque-indigena-do-xingu-50-anos-0>. Acesso em: 22 fev. 2021.

JANSEN, Louisa; GREGORIO, Antonio. **Land Cover Classification System (LCCS): Classification Concepts and User Manual**. [s.l: s.n.].

JECAM. **JECAM – Joint Experiment for Crop Assessment and Monitoring**. 2020. Disponível em: <http://jecam.org/>. Acesso em: 23 fev. 2021.

JIN, Huiran; STEHMAN, Stephen V.; MOUNTRAKIS, Giorgos. Assessing the impact of training sample selection on accuracy of an urban classification: a case study in Denver,

Colorado. **International Journal of Remote Sensing**, [S. l.], v. 35, n. 6, p. 2067–2081, 2014. DOI: 10.1080/01431161.2014.885152.

JONATHAN, Milton; MEIRELLES, Margareth Simões Penello; BERROIR, Jean-Paul; HERLIN, Isabelle. CONSIDERAÇÕES PARA O MONITORAMENTO DO USO DO SOLO COM DADOS MODIS PARA LONGOS PERÍODOS E EM ESCALA REGIONAL, E SUA APLICAÇÃO NA BACIA DO ALTO TAQUARI, MS/MT. **Revista Brasileira de Cartografia**, [S. l.], v. 59, n. 1, 2009. Disponível em: <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/43957>.

JÖNSSON, Per; EKLUNDH, Lars. TIMESAT - a program for analyzing time-series of satellite sensor data. **Computers & Geosciences**, [S. l.], v. 30, n. 8, p. 833–845, 2004. ISSN: 1873-7803. DOI: 10.1016/j.cageo.2004.05.006.

JUDITSKY, Anatoli; HJALMARSSON, Håakan; BENVENISTE, Albert; DELYON, Bernard; LJUNG, Lennart; SJÖBERG, Jonas; ZHANG, Qinghua. Nonlinear black-box models in system identification: Mathematical foundations. **Automatica**, [S. l.], v. 31, n. 12, p. 1725–1750, 1995. DOI: 10.1016/0005-1098(95)00119-1.

JUSTICE, Christopher O. et al. The moderate resolution imaging spectroradiometer (MODIS): Land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, [S. l.], v. 36, n. 4, p. 1228–1249, 1998. ISSN: 0196-2892. DOI: 10.1109/36.701075.

CASTENS, Jude H.; BROWN, J. Christopher; COUTINHO, Alexandre Camargo; BISHOP, Christopher R.; ESQUERDO, Júlio César D. M. Soy moratorium impacts on soybean and deforestation dynamics in Mato Grosso, Brazil. **PLOS ONE**, [S. l.], v. 12, n. 4, p. e0176168, 2017. ISSN: 1932-6203. DOI: 10.1371/journal.pone.0176168.

KILLOUGH, B. The Impact of Analysis Ready Data in the Africa Regional Data Cube. In: IGARSS 2019 - 2019 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM 2019, **Anais** [...]. [s.l.: s.n.] DOI: 10.1109 / IGARSS.2019.8898321.

KOPP, Steve; BECKER, Peter; DOSHI, Abhijit; WRIGHT, Dawn J.; ZHANG, Kaixi; XU, Hong. Achieving the Full Vision of Earth Observation Data Cubes. **Data**, [S. l.], v. 4, n. 3, p. 94, 2019. DOI: 10.3390/data4030094.

KOVÁCS-HOSTYÁNSZKI, Anikó; ESPÍNDOLA, Anahí; VANBERGEN, Adam J.; SETTELE, Josef; KREMEN, Claire; DICKS, Lynn V. Ecological intensification to mitigate impacts of conventional intensive land use on pollinators and pollination. **Ecology Letters**, [S. l.], v. 20, n. 5, p. 673–689, 2017. DOI: 10.1111/ele.12762.

KUCHLER, Patrick Calvano; BÉGUÉ, Agnès; SIMÕES, Margareth; GAETANO, Raffaele; ARVOR, Damien; FERRAZ, Rodrigo P. D. Assessing the optimal preprocessing steps of MODIS time series to map cropping systems in Mato Grosso, Brazil. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 92, p. 102150, 2020. DOI: 10.1016/j.jag.2020.102150.

KUEMMERLE, Tobias et al. Challenges and opportunities in mapping land use intensity globally. **Current Opinion in Environmental Sustainability**, [S. l.], v. 5, n. 5, p. 484–493, 2013. DOI: 10.1016/j.cosust.2013.06.002.

KUHN, Max; JED, Weston; STEW, Williwms; KEEFER, Andre; ENGELHARDT, Chris. caret: Classificação e treinamento de regressão. Pacote R versão 6.0–21. [S. l.], 2015.

LACERDA FILHO, Joffre Valmório De; ABREU FILHO, Waldemar; VALENTE, Cidney Rodrigues; OLIVEIRA, Cipriano Cavalcante De; ALBUQUERQUE, Mário Cavalcanti De. Geologia e recursos minerais do estado de Mato Grosso. [S. l.], 2004. Disponível em: <http://rigeo.cprm.gov.br/jspui/handle/doc/4871>. Acesso em: 22 fev. 2021.

LAMBIN, E.; GEIST, H. Land-Use and Land-Cover Change: Local Processes and Global Impacts. In: [s.l: s.n.]. v. 18. ISBN: 978-3-540-32201-6. DOI: 10.1007/3-540-32202-7.

LAWRENCE, Rick L.; WOOD, Shana D.; SHELEY, Roger L. Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (randomForest). **Remote Sensing of Environment**, [S. l.], v. 100, n. 3, p. 356–362, 2006. ISSN: 00344257. DOI: 10.1016/j.rse.2005.10.014.

LEBOURGEOIS, Valentine; DUPUY, Stéphane; VINTROU, Élodie; AMELINE, Maël; BUTLER, Suzanne; BÉGUÉ, Agnès. A Combined Random Forest and OBIA Classification Scheme for Mapping Smallholder Agriculture at Different Nomenclature Levels Using Multisource Data (Simulated Sentinel-2 Time Series, VHRS and DEM). **Remote Sensing**, [S. l.], v. 9, n. 3, p. 259, 2017. DOI: 10.3390/rs9030259.

LEENHARDT, Delphine; ANGEVIN, Frédérique; BIARNÈS, Anne; COLBACH, Nathalie; MIGNOLET, Catherine. Describing and locating cropping systems on a regional scale. A review. **Agronomy for Sustainable Development**, [S. l.], v. 30, n. 1, p. 131–138, 2010. DOI: 10.1051/agro/2009002.

LEFEBVRE, Henri. **La Production de L'Espace**. [s.l: s.n.]. journal Abbreviation: L Homme et la société. v. 31 DOI: 10.3406/homso.1974.1855.

LEMAIRE, Gilles; FRANZLUEBBERS, Alan; CARVALHO, Paulo César de Faccio; DEDIEU, Benoît. Integrated crop–livestock systems: Strategies to achieve synergy between agricultural production and environmental quality. **Agriculture, Ecosystems & Environment**, [S. l.], v. 190, p. 4–8, 2014. DOI: 10.1016/j.agee.2013.08.009.

LEWIS, Adam et al. The Australian Geoscience Data Cube — Foundations and lessons learned. **Remote Sensing of Environment**, [S. l.], v. 202, p. 276–292, 2017. DOI: 10.1016/j.rse.2017.03.015.

LI, Songnian et al. Geospatial big data handling theory and methods: A review and research challenges. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 115, p. 119–133, 2016. DOI: 10.1016/j.isprsjprs.2015.10.012.

LIAW, A. randomForest: Breiman and Cutler's Random Forests for Classification and Regression. R Package Version 4.6.14. [S. l.], 2018.

LIU, Desheng; CAI, Shanshan. A Spatial-Temporal Modeling Approach to Reconstructing Land-Cover Change Trajectories from Multi-temporal Satellite Imagery. **Annals of the Association of American Geographers**, [S. l.], v. 102, n. 6, p. 1329–1347, 2012. DOI: 10.1080/00045608.2011.596357.

LOBELL, David B.; ASNER, Gregory P. Cropland distributions from temporal unmixing of MODIS data. **Remote Sensing of Environment**, [S. l.], v. 93, n. 3, p. 412–422, 2004. DOI: 10.1016/j.rse.2004.08.002.

LOPES, M. A.; CONTINI, E. Agricultura, sustentabilidade e tecnologia. **Agroanalysis**, [S. l.], v. 32, p. 28–34, 2012.

LOVELAND, Thomas R.; DEFRIES, Ruth S. Observing and monitoring land use and land cover change. In: **Ecosystems and Land Use Change**. [s.l.] : American Geophysical Union, 2004. p. 231–246. DOI: 10.1029/153gm18. Disponível em: <https://doi.org/10.1029/153gm18>.

MA, Yan; WU, Haiping; WANG, Lizhe; HUANG, Bormin; RANJAN, Rajiv; ZOMAYA, Albert; JIE, Wei. Remote sensing big data computing: Challenges and opportunities. **Future Generation Computer Systems**, [S. l.], v. 51, p. 47–60, 2015. DOI: 10.1016/j.future.2014.10.029.

MAHDIANPARI, Masoud; SALEHI, Bahram; MOHAMMADIMANESH, Fariba; BRISCO, Brian; HOMAYOUNI, Saeid; GILL, Eric; DELANCEY, Evan R.; BOURGEAU-CHAVEZ, Laura. Big Data for a Big Country: The First Generation of Canadian Wetland Inventory Map at a Spatial Resolution of 10-m Using Sentinel-1 and Sentinel-2 Data on the Google Earth Engine Cloud Computing Platform. **Canadian Journal of Remote Sensing**, [S. l.], v. 46, n. 1, p. 15–33, 2020. DOI: 10.1080/07038992.2019.1711366.

MAHDIANPARI, Masoud; SALEHI, Bahram; MOHAMMADIMANESH, Fariba; HOMAYOUNI, Saeid; GILL, Eric. The First Wetland Inventory Map of Newfoundland at a Spatial Resolution of 10 m Using Sentinel-1 and Sentinel-2 Data on the Google Earth Engine Cloud Computing Platform. **Remote Sensing**, [S. l.], v. 11, n. 1, p. 43, 2018. DOI: 10.3390/rs11010043.

MANABE, Víctor Danilo; MELO, Marcio R. S.; ROCHA, Jansle Vieira. Framework for Mapping Integrated Crop-Livestock Systems in Mato Grosso, Brazil. **Remote Sensing**, [S. l.], v. 10, n. 9, p. 1322, 2018. DOI: 10.3390/rs10091322.

MARENGO, Jose A.; LIEBMANN, Brant; KOUSKY, Vernon E.; FILIZOLA, Naziano P.; WAINER, Ilana C. Onset and End of the Rainy Season in the Brazilian Amazon Basin. **Journal of Climate**, [S. l.], v. 14, n. 5, p. 833–852, 2001. DOI: 10.1175/1520-0442(2001)014<0833:oaetor>2.0.co;2.

MARTINS, J. d S. **O tempo da Fronteira: Retorno à controvérsia sobre o tempo histórico da frente de expansão e da frente pioneira**. In: \_\_\_. **Fronteira: A degradação do outro nos confins do humano**. São Paulo: Hucitec, 1997.

MASO, Joan; ZABALA, Alaitz; SERRAL, Ivette; PONS, Xavier. A Portal Offering Standard Visualization and Analysis on top of an Open Data Cube for Sub-National Regions: The Catalan Data Cube Example. **Data**, [S. l.], v. 4, n. 3, p. 96, 2019. DOI: 10.3390/data4030096.

MELAAS, Eli K.; FRIEDL, Mark A.; ZHU, Zhe. Detecting interannual variation in deciduous broadleaf forest phenology using Landsat TM/ETM\$\\mathplus\\$ data. **Remote Sensing of Environment**, [S. l.], v. 132, p. 176–185, 2013. DOI: 10.1016/j.rse.2013.01.011.

MELLOR, Andrew; BOUKIR, Samia; HAYWOOD, Andrew; JONES, Simon. Exploring issues of training data imbalance and mislabelling on random forest performance for large area land cover classification using the ensemble margin. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 105, p. 155–168, 2015. DOI: 10.1016/j.isprsjprs.2015.03.014.

MILLER, Harvey J.; GOODCHILD, Michael F. Data-driven geography. **GeoJournal**, [S. l.], v. 80, n. 4, p. 449–461, 2014. DOI: 10.1007/s10708-014-9602-6.

MILTON DA COSTA ARAÚJO FILHO; PAULO ROBERTO MENESES; EDSON EYJI SANO. SISTEMA DE CLASSIFICAÇÃO DE USO E COBERTURA DA TERRA COM BASE NA ANÁLISE DE IMAGENS DE SATÉLITE. **Revista Brasileira de Cartografia**, [S. l.], v. 59, n. 2, 2007. Disponível em: <http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44902>. Acesso em: 23 fev. 2021.

MINGWEI, Zhang; QINGBO, Zhou; ZHONGXIN, Chen; JIA, Liu; YONG, Zhou; CHONGFA, Cai. Crop discrimination in Northern China with double cropping systems using Fourier analysis of time-series MODIS data. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 10, n. 4, p. 476–485, 2008. DOI: 10.1016/j.jag.2007.11.002.

MMA. **Probio financia mapeamento completo da cobertura vegetal dos biomas brasileiros**. 2004. Disponível em: <https://www.gov.br/mma/pt-br/noticias/probio-financia-mapeamento-completo-da-cobertura-vegetal-dos-biomas-brasileiros>. Acesso em: 17 fev. 2021.

MOUNTRAKIS, Giorgos; IM, Jungho; OGOLE, Caesar. Support vector machines in remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 66, n. 3, p. 247–259, 2011. DOI: 10.1016/j.isprsjprs.2010.11.001.

MÜCHER, Sander et al. **A new global agro-environmental stratification (GAES)**. [s.l.] : Wageningen Environmental Research, 2016. ISBN: 1566-7197.

MYERS, Norman; MITTERMEIER, Russell A.; MITTERMEIER, Cristina G.; DA FONSECA, Gustavo A. B.; KENT, Jennifer. Biodiversity hotspots for conservation priorities. **Nature**, [S. l.], v. 403, n. 6772, p. 853–858, 2000. ISSN: 1476-4687. DOI: 10.1038/35002501.

NAIR, P. K. R. An Introduction to Agroforestry. Kluwer Academic Publishers, Dordrecht. [S. l.], Kluwer Academic Publishers, Dordrecht, 1993.

NÉDÉLEC, V. **Modélisation de la colonisation agricole et de la déforestation dans le nord du Mato Grosso: approche multiscalaire par télédétection (PhD)**. 2005.

NEMANI, R.; VOTAVA, P.; MICHAELIS, A.; MELTON, F.; MILESI, C. Collaborative supercomputing for global change science. **Eos, Transactions American Geophysical Union**, [S. l.], v. 92, n. 13, p. 109–110, 2011. ISBN: 0096-3941.

NGUYEN, Lan H.; HENEBRY, Geoffrey M. Characterizing Land Use/Land Cover Using Multi-Sensor Time Series from the Perspective of Land Surface Phenology. **Remote Sensing**, [S. l.], v. 11, n. 14, p. 1677, 2019. DOI: 10.3390/rs11141677.

NOI, Phan Thanh; KAPPAS, Martin. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors*, [S. l.], v. 18, n. 2, p. 18, 2017. DOI: 10.3390/s18010018.

OLIVEIRA, Ariovaldo De. **A agricultura camponesa no Brasil**. [s.l: s.n.]. v. 03 ISBN: 85-85134-99-2.

OSIS, Reinis; LAURENT, François; POCCARD-CHAPUIS, René. A DINÂMICA DE EXPANSÃO DA SOJA NA FRENTE PIONEIRA AMAZÔNICA RELACIONADA À VARIABILIDADE ESPACIAL DOS FATORES NATURAIS. In: **MUDANÇAS NOS SISTEMAS AGRÍCOLAS E TERRITÓRIOS NO BRASIL**. [s.l.] : UERGS, 2019. p. 69–89. DOI: 10.21674/9788560231.69-89. Disponível em: <https://doi.org/10.21674/9788560231.69-89>.

OZDOGAN, Mutlu. The spatial distribution of crop types from MODIS data: Temporal unmixing using Independent Component Analysis. *Remote Sensing of Environment*, [S. l.], v. 114, n. 6, p. 1190–1204, 2010. DOI: 10.1016/j.rse.2010.01.006.

P. S. THENKABAIL; I. MARIOTTO; M. K. GUMMA; E. M. MIDDLETON; D. R. LANDIS; K. F. HUEMMRICH. Selection of Hyperspectral Narrowbands (HNBs) and Composition of Hyperspectral Twoband Vegetation Indices (HVIIs) for Biophysical Characterization and Discrimination of Crop Types Using Field Reflectance and Hyperion/EO-1 Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, [S. l.], v. 6, n. 2, p. 427–439, 2013. ISSN: 2151-1535. DOI: 10.1109/JSTARS.2013.2252601.

PACHECO, Anna; MCNAIRN, Heather. Evaluating multispectral remote sensing and spectral unmixing analysis for crop residue mapping. *Remote Sensing of Environment*, [S. l.], v. 114, n. 10, p. 2219–2228, 2010. DOI: 10.1016/j.rse.2010.04.024.

PAN, Zhuokun; HUANG, Jingfeng; ZHOU, Qingbo; WANG, Limin; CHENG, Yongxiang; ZHANG, Hankui; BLACKBURN, George Alan; YAN, Jing; LIU, Jianhong. Mapping crop phenology using NDVI time-series derived from HJ-1 A/B data. *International Journal of Applied Earth Observation and Geoinformation*, [S. l.], v. 34, p. 188–197, 2015. DOI: 10.1016/j.jag.2014.08.011.

PARENTE, Leandro; FERREIRA, Laerte; FARIA, Adriano; NOGUEIRA, Sérgio; ARAÚJO, Fernando; TEIXEIRA, Lana; HAGEN, Stephen. Monitoring the brazilian pasturelands: A new mapping approach based on the landsat 8 spectral and temporal domains. *International Journal of Applied Earth Observation and Geoinformation*, [S. l.], v. 62, p. 135–143, 2017. DOI: 10.1016/j.jag.2017.06.003.

PARENTE, Leandro; MESQUITA, Vinícius; MIZIARA, Fausto; BAUMANN, Luis; FERREIRA, Laerte. Assessing the pasturelands and livestock dynamics in Brazil, from 1985 to 2017: A novel approach based on high spatial resolution imagery and Google Earth Engine cloud computing. *Remote Sensing of Environment*, [S. l.], v. 232, p. 111301, 2019. DOI: 10.1016/j.rse.2019.111301.

PARUELO, J. M.; BURKE, I. C.; LAUENROTH, W. K. Land-use impact on ecosystem functioning in eastern Colorado, USA. *Global Change Biology*, [S. l.], v. 7, n. 6, p. 631–639, 2001. DOI: 10.1111/j.1365-2486.2001.00387.x.

**Pecuária do Pantanal - Portal Embrapa.** [s.d.]. Disponível em: <https://www.embrapa.br/pantanal/pecuaria-do-pantanal>. Acesso em: 18 fev. 2021.

PEI, Tao; SONG, Ci; GUO, Sihui; SHU, Hua; LIU, Yaxi; DU, Yunyan; MA, Ting; ZHOU, Chenghu. Big geodata mining: Objective, connotations and research issues. **Journal of Geographical Sciences**, [S. l.], v. 30, n. 2, p. 251–266, 2020. DOI: 10.1007/s11442-020-1726-7.

PEREIRA, Sandro Eduardo Marschhausen; MANZATTO, Celso Vainer; SKORUPA, Ladislau Araújo. Análise multicritério para planejamento em sistemas de Integração Lavoura, Pecuária e Floresta. [S. l.], p. 45, 2018.

PÉREZ-HOYOS, Ana; REMBOLD, Felix; KERDILES, Hervé; GALLEGOS, Javier. Comparison of Global Land Cover Datasets for Cropland Monitoring. **Remote Sensing**, [S. l.], v. 9, n. 11, p. 1118, 2017. DOI: 10.3390/rs9111118.

PICOLI, Michelle Cristina Araujo et al. Big earth observation time series analysis for monitoring Brazilian agriculture. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 145, p. 328–339, 2018. ISSN: 09242716. DOI: 10.1016/j.isprsjprs.2018.08.007.

PLAZA, Antonio J.; CHANG, Chein-I. **High performance computing in remote sensing**. [s.l.] : CRC Press, 2007.

PONZONI, F. J.; SHIMABUKURO, Yosio Edemir; KUPLICH, Tatiana Mora. **Sensoriamento Remoto no Estudo da Vegetação**. 2. ed., [s.l.] : Oficina de Textos, 2012.

PORTO, Luan; SIMÕES, Margareth; FERRAZ, Rodrigo P. D. Seminário Pibic Embrapa Solos 2019/2020. **Segmentação Semântica de imagens para a identificação de invasoras em pastagens degradadas, utilizando o modelo DeepLabelV3+**, [S. l.], 2020. ISSN: 1517-2627. Disponível em: <http://www.infoteca.cnptia.embrapa.br/handle/doc/1130137>. Acesso em: 24 fev. 2021.

PORTO-GONÇALVES, Carlos Walter. Amazônia enquanto acumulação desigual de tempos: Uma contribuição para a ecologia política da região\ast. **Revista Crítica de Ciências Sociais**, [S. l.], n. 107, p. 63–90, 2015. DOI: 10.4000/rccs.6018.

POTT, Arnildo; POTT, Vali Joana. Vegetação do Pantanal: fitogeografia e dinâmica. [S. l.], p. 12, 2009.

**PRODES — Coordenação-Geral de Observação da Terra**. [s.d.]. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>. Acesso em: 15 dez. 2020.

QIU, Bingwen; ZHONG, Ming; TANG, Zhenghong; WANG, Chongyang. A new methodology to map double-cropping croplands based on continuous wavelet transform. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 26, p. 97–104, 2014. DOI: 10.1016/j.jag.2013.05.016.

**R Core Team (2020). - Agência Europeia do Ambiente**. Methodology Reference. [s.d.]. Disponível em: <https://www.eea.europa.eu/data-and-maps/indicators/oxygen-consuming-substances-in-rivers/r-development-core-team-2006>. Acesso em: 16 jan. 2021.

RAASCH, Werlen Gonçalves; BEZERRA, Juscelino Eudâmidas. INFRAESTRUTURA E USO CORPORATIVO DO TERRITÓRIO: O AGRONEGÓCIO NA MESORREGIÃO DO SUDESTE MATO-GROSSENSE. In: **MUDANÇAS NOS SISTEMAS AGRÍCOLAS E TERRITÓRIOS NO BRASIL**. [s.l.] : UERGS, 2019. p. 42–68. DOI: 10.21674/9788560231.42-68. Disponível em: <https://doi.org/10.21674/9788560231.42-68>.

RAJAO, R.; SOARES-FILHO, B. Policies undermine Brazil\textquotesingles GHG goals. **Science**, [S. l.], v. 350, n. 6260, p. 519–519, 2015. DOI: 10.1126/science.350.6260.519-a.

RAMANKUTTY, Navin; EVAN, Amato T.; MONFREDA, Chad; FOLEY, Jonathan A. Farming the planet: 1. Geographic distribution of global agricultural lands in the year 2000. **Global Biogeochemical Cycles**, [S. l.], v. 22, n. 1, p. n/a-n/a, 2008. DOI: 10.1029/2007gb002952.

RAMOS, Davi de Lacerda. Intensificação ecológica como uma alternativa para aumentar a produção agrícola no Cerrado. [S. l.], 2017. Disponível em: <https://repositorio.unb.br/handle/10482/25311>. Acesso em: 23 fev. 2021.

RATHCKE, B.; LACEY, E. P. Phenological Patterns of Terrestrial Plants. **Annual Review of Ecology and Systematics**, [S. l.], v. 16, n. 1, p. 179–214, 1985. DOI: 10.1146/annurev.es.16.110185.001143.

REIS, Júlio César Dos et al. Assessing the economic viability of integrated crop-livestock systems in Mato Grosso, Brazil. **Renewable Agriculture and Food Systems**, [S. l.], v. 35, n. 6, p. 631–642, 2019. DOI: 10.1017/s1742170519000280.

ROMEIRO, Viviane. **O Acordo de Paris: Ponto Decisivo para uma Solução Climática**. 2016. Disponível em: <https://wribrasil.org.br/pt/node/41058>. Acesso em: 6 dez. 2020.

ROYAL SOCIETY OF LONDON. **Geoengineering the climate: science, governance and uncertainty | Royal Society**. 2009. Disponível em: <https://royalsociety.org/topics-policy/publications/2009/geoengineering-climate/>. Acesso em: 23 fev. 2021.

SAKAMOTO, T.; YOKOZAWA, M.; TORITANI, H.; SHIBAYAMA, M.; ISHITSUKA, N.; OHNO, H. A crop phenology detection method using time-series MODIS data. **Remote Sensing of Environment**, [S. l.], v. 96, n. 3–4, p. 366–374, 2005. DOI: 10.1016/j.rse.2005.03.008.

SALTON, Julio C.; MERCANTE, Fabio M.; TOMAZI, Michely; ZANATTA, Josileia A.; CONCENÇO, Germani; SILVA, Wiliam M.; RETORE, Marciana. Integrated crop-livestock system in tropical Brazil: Toward a sustainable production system. **Agriculture, Ecosystems & Environment**, [S. l.], v. 190, p. 70–79, 2014. DOI: 10.1016/j.agee.2013.09.023.

SANTOS, Mário Vital Dos. **Relatório técnico consolidado de clima para o estado de Mato Grosso VOL.1/2**. BIRD, 2000.

SAVITZKY, Abraham; GOLAY, M. J. E. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. **Analytical Chemistry**, [S. l.], v. 36, n. 8, p. 1627–1639, 1964. DOI: 10.1021/ac60214a047.

SEGARRA, Joel; BUCHAILLOT, Maria Luisa; ARAUS, Jose Luis; KEFAUVER, Shawn C. Remote Sensing for Precision Agriculture: Sentinel-2 Improved Features and Applications. **Agronomy**, [S. l.], v. 10, n. 5, p. 641, 2020. DOI: 10.3390/agronomy10050641.

SHAO, Yang; LUNETTA, Ross S.; WHEELER, Brandon; IIAMES, John S.; CAMPBELL, James B. An evaluation of time-series smoothing algorithms for land-cover classifications using MODIS-NDVI multi-temporal data. **Remote Sensing of Environment**, [S. l.], v. 174, p. 258–265, 2016. ISSN: 0034-4257. DOI: 10.1016/j.rse.2015.12.023.

SIMMONDS, N. W. Plant Research and Agroforestry. Edited by P. A. Huxley. Nairobi, Kenya: International Council for Research in Agroforestry (ICRAF) (1983), pp. 617, US\$15.00 (plus postage). **Experimental Agriculture**, [S. l.], v. 20, n. 4, p. 346–346, 1984. ISSN: 0014-4797. DOI: 10.1017/S0014479700018081.

SIMOES, Margareth; FREITAS, Pedro; FERRAZ, Rodrigo; ARVOR, Damien; DUBREUIL, Vincent. Avaliação da Dinâmica de uso da terra através de dados de Sensores Remotos para uma Agricultura Sustentável. In: [s.l.: s.n.]. p. 489–511. ISBN: 978-85-7035-356-6.

**SNA. Brasil amplia liderança no ranking mundial de superávits agrícolas. Sociedade Nacional de Agricultura** 2020. Disponível em: <https://www.sna.agr.br/brasil-amplia-lideranca-no-ranking-mundial-de-superavits-agricolas/>. Acesso em: 23 fev. 2021.

SON, Nguyen-Thanh; CHEN, Chi-Farn; CHEN, Cheng-Ru; GUO, Horng-Yuh. Classification of multitemporal Sentinel-2 data for field-level monitoring of rice cropping practices in Taiwan. **Advances in Space Research**, [S. l.], v. 65, n. 8, p. 1910–1921, 2020. DOI: 10.1016/j.asr.2020.01.028.

SOUZA, Carlos 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. 2735, 2020. DOI: 10.3390/rs12172735.

SPERA, Stephanie A.; COHN, Avery S.; VANWEY, Leah K.; MUSTARD, Jack F.; RUDORFF, Bernardo F.; RISSO, Joel; ADAMI, Marcos. Recent cropping frequency, expansion, and abandonment in Mato Grosso, Brazil had selective land characteristics. **Environmental Research Letters**, [S. l.], v. 9, n. 6, p. 064010, 2014. ISSN: 1748-9326. DOI: 10.1088/1748-9326/9/6/064010.

STONEBRAKER, Michael; BROWN, Paul; ZHANG, Donghui; BECLA, Jacek. SciDB: A Database Management System for Applications with Complex Analytics. **Computing in Science & Engineering**, [S. l.], v. 15, n. 3, p. 54–62, 2013. DOI: 10.1109/mcse.2013.19.

**SUMMERS, P. The Post-frontier: Land use and social change in the Brazilian Amazon (1992- 2002).** 2008. PhD - Virginia Polytechnic Institute and State University, USA, 2008.

TAMIMINIA, Haifa; SALEHI, Bahram; MAHDIANPARI, Masoud; QUACKENBUSH, Lindi; ADELI, Sarina; BRISCO, Brian. Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 164, p. 152–170, 2020. DOI: 10.1016/j.isprsjprs.2020.04.001.

THÉRY, H. **Franges pionnières d'hier et d'aujourd'hui. In Amérique Latine.** Zagefka P., 2006.

TITTONELL, Pablo. Ecological intensification of agriculture—sustainable by nature. **Current Opinion in Environmental Sustainability**, [S. l.J, v. 8, p. 53–61, 2014. DOI: 10.1016/j.cosust.2014.08.006.

USAID. **Application of the Livelihood Zone Maps and Profiles for Food Security Analysis and Early Warning - Guidance for Famine Early Warning Systems Network (FEWS NET) Representatives and Partners**. 2009.

USDA. **Data & analysis - livestock and poultry: world markets and trade**. 2018. Disponível em: <https://www.fas.usda.gov/data/livestock-and-poultry-world-markets-andtrade>. Acesso em: 2 maio. 2020.

V. MAUS; G. CÂMARA; R. CARTAXO; A. SANCHEZ; F. M. RAMOS; G. R. DE QUEIROZ. A Time-Weighted Dynamic Time Warping Method for Land-Use and Land-Cover Mapping. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [S. l.J, v. 9, n. 8, p. 3729–3739, 2016. ISSN: 2151-1535. DOI: 10.1109/JSTARS.2016.2517118.

VÁCLAVÍK, Tomáš; LAUTENBACH, Sven; KUEMMERLE, Tobias; SEPPELT, Ralf. Mapping global land system archetypes. **Global Environmental Change**, [S. l.J, v. 23, n. 6, p. 1637–1647, 2013. DOI: 10.1016/j.gloenvcha.2013.09.004.

VELOSO, H. P. **As regiões fitoecológicas, sua natureza e seus recursos econômicos. Estudo fitogeográfico**: Brasil. DNPM. Radam. Folha Araguaia - SB.22. [s.l: s.n.].

VERBURG, Peter H.; STEEG, Jeannette Van de; VELDKAMP, A.; WILLEMEN, Louise. From land cover change to land function dynamics: A major challenge to improve land characterization. **Journal of Environmental Management**, [S. l.J, v. 90, n. 3, p. 1327–1335, 2009. DOI: 10.1016/j.jenvman.2008.08.005.

VIEIRA FILHO, José Eustáquio Ribeiro (Organizador) et al. **Agricultura, transformação produtiva e sustentabilidade**. [s.l.] : Instituto de Pesquisa Econômica Aplicada (Ipea), 2016. Accepted: 2016-08-02T19:39:00Z. Disponível em: <http://repositorio.ipea.gov.br/handle/11058/6876>. Acesso em: 23 fev. 2021.

VILELA, Lourival; JR, Geraldo B. Martha; MARCHÃO, Leandro. INTEGRAÇÃO LAVOURA-PECUÁRIA-FLORESTA: ALTERNATIVA PARA INTENSIFICAÇÃO DO USO DA TERRA. [S. l.J, p. 8, 2012.

VILELA, Lourival; MARCHÃO, Robélio; GUIMARÃES JR, Roberto. “**Boi Safrinha**” na Integração Lavoura-Pecuária no Oeste Baiano. [s.l: s.n.].

VINTROU, Elodie; BÉGUÉ, Agnès; BARON, Christian; LO SEEN, D.; ALEXANDRE, Saad; TRAORE, Seydou. **Analysing MODIS phenometrics quality on cropped land in West Africa**. [s.l: s.n.]. journal Abbreviation: European Space Agency, (Special Publication) ESA SP. v. 707

VUOLO, Francesco; NEUWIRTH, Martin; IMMITZER, Markus; ATZBERGER, Clement; NG, Wai-Tim. How much does multi-temporal Sentinel-2 data improve crop type classification? **International Journal of Applied Earth Observation and Geoinformation**, [S. l.J, v. 72, p. 122–130, 2018. DOI: 10.1016/j.jag.2018.06.007.

WANG, Ming; LIU, Zhengjia; BAIG, Muhammad Hasan Ali; WANG, Yongsheng; LI, Yurui; CHEN, Yuanyan. Mapping sugarcane in complex landscapes by integrating multi-temporal Sentinel-2 images and machine learning algorithms. **Land Use Policy**, [S. l.], v. 88, p. 104190, 2019. DOI: 10.1016/j.landusepol.2019.104190.

WARDLOW, B.; EGBERT, S.; KASTENS, J. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains. **Remote Sensing of Environment**, [S. l.], v. 108, n. 3, p. 290–310, 2007. DOI: 10.1016/j.rse.2006.11.021.

WARDLOW, Brian D.; EGBERT, Stephen L. Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains. **Remote Sensing of Environment**, [S. l.], v. 112, n. 3, p. 1096–1116, 2008. DOI: 10.1016/j.rse.2007.07.019.

WEBSITE-GOV-MT, MT. **Geografia - mt.gov.br**. [s.d.]. Disponível em: <http://www.mt.gov.br/geografia>. Acesso em: 25 fev. 2021.

WIENS, Trevor S.; DALE, Brenda C.; BOYCE, Mark S.; KERSHAW, G. Peter. Three way k-fold cross-validation of resource selection functions. **Ecological Modelling**, [S. l.], v. 212, n. 3–4, p. 244–255, 2008. DOI: 10.1016/j.ecolmodel.2007.10.005.

WU, JunJie. Land use changes: Economic, social, and environmental impacts. **Choices**, [S. l.], p. 6–10, 2008.

XAVIER, Alexandre Cândido; RUDORFF, Bernardo F. T.; SHIMABUKURO, Yosio Edemir; BERKA, Luciana Miura Sugawara; MOREIRA, Mauricio Alves. Multi-temporal analysis of MODIS data to classify sugarcane crop. **International Journal of Remote Sensing**, [S. l.], v. 27, n. 4, p. 755–768, 2006. DOI: 10.1080/01431160500296735.

XU, Xingmei; CONRAD, Christopher; DOKTOR, Daniel. Optimising Phenological Metrics Extraction for Different Crop Types in Germany Using the Moderate Resolution Imaging Spectrometer (MODIS). **Remote Sensing**, [S. l.], v. 9, n. 3, p. 254, 2017. DOI: 10.3390/rs9030254.

ZHANG, G. Peter. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, [S. l.], v. 50, p. 159–175, 2003. DOI: 10.1016/s0925-2312(01)00702-0.

ZHU, Changming; LU, Dengsheng; VICTORIA, Daniel; DUTRA, Luciano Vieira. Mapping Fractional Cropland Distribution in Mato Grosso, Brazil Using Time Series MODIS Enhanced Vegetation Index and Landsat Thematic Mapper Data. **Remote Sensing**, [S. l.], v. 8, n. 1, p. 22, 2016. DOI: 10.3390/rs8010022.

## APÊNDICE – Resumo estendido na língua francesa



### RÉSUMÉ ÉTENDU DE LA THÈSE EN FRANÇAIS

## **Utilisation de la télédétection pour la cartographie des systèmes de culture intégrés : contribution au suivi de l'agriculture bas carbone dans l'Etat du Mato Grosso, Brésil**

Patrick Calvano Kuchler

Février 2021

Directrice de thèse française : Agnès Bégué, HDR, CIRAD

Directrice de thèse brésilienne : Margareth Simões, Prof., UERJ

### 1 Introduction

Avec une population mondiale de 10 milliards à l'horizon 2050, les scénarios basés sur une croissance économique modéré montrent que la demande en production alimentaire va augmenter de 50% comparé à 2013 (FAO, 2017). Compte-tenu du peu de disponibilité de nouvelles surfaces cultivables, des changements climatiques qui menacent la stabilité de la production et la sécurité alimentaire au niveau mondial, et de la fragilité des ressources environnementales (biodiversité, eau, sol, etc.), l'énorme défi qui se pose pour les pays producteurs est d'augmenter la production agricole de manière durable, notamment via l'intensification des systèmes de production.

Pour répondre à ce défi, à l'occasion de la Convention de l'ONU sur le Climat qui a eu lieu en décembre 2009 à Copenhague (Danemark), le Brésil s'est engagé auprès de la communauté internationale sur des mesures de réduction des émissions des gaz à effet de serre (GES), fixant des objectifs de réduction à chaque secteur de l'économie brésilienne<sup>4</sup>. Dans le secteur agricole, le Plan Sectoriel de Mitigation et d'Adaptation aux Changements Climatiques visant la Consolidation d'une Économie de Basse Émission de Carbone dans l'Agriculture (ou Plan ABC pour *Agricultura de Baixa emissão de Carbono*) institué en 2010 a pour objectif de garantir et d'encourager l'adoption de pratiques de gestion qui réduisent les émissions de GES. Parmi ces pratiques, les cultures séquentielles avec deux, voire trois,

---

<sup>4</sup> En 2015, le Brésil signe l'accord de Paris avec un engagement de réduction des GES de 37% à l'horizon 2025 et 43% à l'horizon 2030 (base 2005).

récoltes par an constituent la principale stratégie d'intensification de l'agriculture et sont déjà très répandues au Brésil, principalement dans l'axe centre-nord de la production de soja. Les systèmes intégrés de type Agriculture-Elevage-Forêt (iLPF pour *integração Lavoura-Pecuária-Floresta*) ou Agriculture-Elevage (iLP pour *integração Lavoura-Pecuária*) ont quant à eux une complexité supplémentaire liée à la présence de pâturages et/ou de forêts plantées, qui peut être un frein à leur adoption.

Une décennie après le lancement du Plan ABC, le défi de créer des mécanismes efficaces de contrôle de ces initiatives demeure. En effet, l'absence d'instruments pour suivre la mise en place des moyens d'atténuation des émissions des GES et pour suivre l'utilisation des ressources pose de graves problèmes de gouvernance (GURGEL; COSTA; SERIGATI, 2017). Aujourd'hui, le suivi est fait par des enquêtes coûteuses en temps et en ressources, comme celles réalisée par GIL; SIEBOLD; BERGER (2015) qui a duré 6 mois et qui, à partir d'entretiens avec 134 producteurs et spécialistes, a permis d'extraire des données sur quelques zones où étaient implantés des systèmes intégrés dans l'Etat du Mato Grosso pour la récolte de 2012-2013. En 2017, les systèmes intégrés implantés dans chaque Etat de la fédération ont été inventoriés à partir d'un énorme travail de collecte de données basé sur des entretiens (EMBRAPA, 2017). Ces études s'appuient sur des méthodologies qui ne permettent pas un suivi opérationnel efficace de la dynamique de l'implémentation des systèmes intégrés, or la connaissance de cette dynamique est fondamentale pour la compréhension et la planification du futur de l'agriculture et de l'élevage brésiliens, et pour le suivi de la réalisation des objectifs de développement durable du Brésil (BUSTAMANTE et al., 2012; RAJAO; SOARES-FILHO, 2015).

L'observation de la Terre fournit des données qui peuvent être utilisées pour caractériser et suivre les systèmes de production agricole à l'échelle régionale. Cependant, il n'existe que peu d'exemples dans la littérature spécialisée. Dans leur revue bibliographique, (BÉGUÉ et al., 2018) soulignent que moins de 10% des publications en télédétection se concentrent sur les pratiques agricoles, et que la grande majorité de ces publications traitent de travaux exploratoires, centrés sur une pratique donnée, et à l'échelle locale. (LEENHARDT et al., 2010) ont passé en revue les travaux sur la spatialisation des systèmes de production agricole à l'échelle régionale et concluent que les enquêtes de terrain restent primordiales en l'absence de méthodes fiables de cartographie. Ainsi, l'évolution de la traditionnelle carte d'occupation des sols vers des cartes d'utilisation des terres et, ultérieurement, vers des cartes de systèmes de production agricole, nécessite le traitement de nouvelles données, l'implémentation de nouvelles méthodes et surtout une plus grande intégration entre disciplines de recherche scientifique (VERBURG et al., 2009). La contribution de la télédétection à la cartographie des systèmes agricoles est encore fragmentée et diversifiée, mais il est clair qu'elle se fera via le traitement et l'analyse de séries temporelles d'images satellites (STIS) et la mobilisation des nouvelles technologies de l'information (*Big Data*).

Les SITS, qui s'appuient sur la possibilité qu'un même endroit puisse être revisité plusieurs fois au cours d'une même année, sont à même de capturer la complexité et la dynamique de l'occupation des sols (LIU; CAI, 2012). Comme discuté par (GÓMEZ; WHITE; WULDER, 2016), les séries temporelles permettent, à travers notamment des évolutions d'indices de végétation, la reconstruction de l'ensemble du cycle phénologique de la végétation ce qui permet notamment une meilleure compréhension des systèmes agricoles complexes avec plus d'une cycle de culture. A titre d'exemples, le satellite MODIS (*MODerate resolution Imaging Spectroradiometer*) à résolution hectométrique a été

utilisé avec succès pour la cartographie des cultures simples et séquentielles sur de vastes régions, en particulier aux États-Unis (e.g. (WARDLOW; EGBERT; KASTENS, 2007), en Chine (e.g. MINGWEI et al., 2008; QIU et al., 2014) et au Brésil (GALFORD et al., 2008; ARVOR et al., 2011; SPERA et al., 2014; ZHU et al., 2016; KASTENS et al., 2017; MANABE; MELO; ROCHA, 2018; CHEN et al., 2018; PICOLI et al., 2018).

Les nouvelles technologies de l'information (*Big Data*) et les missions satellitaires récentes et à venir, ouvrent quat à elles de nouvelles possibilités pour la cartographie de l'occupation et de l'utilisation des sols (LI et al., 2016). De nouvelles plateformes de traitement de données satellitaires de plus en plus accessibles, comme *Google Earth Engine* (GEE), permettent à partir d'une interface de programmation d'accéder à un catalogue de pétabytes d'images de satellites et d'utiliser l'infrastructure de *Google* pour les traiter (GORELICK et al., 2017). Ce nouveau paradigme dans le traitement des données spatiales offre un environnement qui permet de suppléer les limitations techniques du traitement des images sur de grandes zones. Ainsi, comme le montre la méta-analyse publiée par (TAMIMINIA et al., 2020), GEE est de plus en plus utilisé à l'échelle mondiale notamment pour la cartographie de surfaces agricoles, mais peu d'études sont faites sur la cartographie des cultures séquentielles, et aucune sur les systèmes intégrés.

Au Brésil, une initiative importante et inédite menée par un réseau collaboratif d'experts, le Projet de Cartographie Annuelle de la Couverture et de l'Utilisation du Sol du Brésil (MapBiomass), a permis de cartographier avec GEE l'ensemble du territoire national à 30 m de résolution sur 33 années (SOUZA et al., 2020). MapBiomass continue d'améliorer les méthodes de traitement des images, enrichit la nomenclature et produit chaque année une nouvelle version des cartes, ce qui en fait un produit incontournable pour l'étude des changements de l'occupation et de l'utilisation des sols sur le territoire national. La nomenclature, hiérarchique, comporte à son niveau le plus fin les classes « soja », « canne à sucre » et « autres cultures temporaires », mais ne comporte pas à ce jour d'information sur les systèmes complexes, notamment sur les cultures séquentielles. Comme nous l'avons montré précédemment, la recherche brésilienne a été l'un des pionniers de la cartographie des cultures séquentielles, mais seules deux études ont été publiées sur les systèmes intégrés sur de petites zones de l'état du Mato Grosso (KUCHLER et al., 2019; MANABE; MELO; ROCHA, 2018).

(CAMARA et al., 2016) soulignent que malgré l'énorme volume de données de télédétection disponibles, seule une petite partie est réellement utilisée pour la recherche scientifique et les applications opérationnelles, et que les résultats publiés s'appuient sur des expériences réalisées avec petits ensembles de données et petites portions de terrain, qui ne sont pas correctement testées et validées. (BÉGUÉ et al., 2018) expliquent ce décalage entre recherche scientifique et service opérationnel par le besoin de vastes campagnes d'acquisition de données de terrain pour faire des classifications supervisées sur de grandes surfaces. Se pose alors la question de la reproductibilité des méthodes et de la disponibilité de données d'apprentissage à l'échelle régionale, qui restent aujourd'hui les principales sources du décalage observé entre les nombreuses études académiques publiées et les services réellement disponibles pour les politiques publiques, et ce dans de nombreux pays (BEGUE et al., 2020).

Cette thèse a pour ambition de contribuer au développement des protocoles méthodologiques pour l'observation de l'agriculture à basse émission de Carbone en appui à la gouvernance du plan ABC. Ce

développement repose sur l'hypothèse que les séries temporelles d'images MODIS associées à des algorithmes d'apprentissage automatique sont capables de détecter des Systèmes Intégrés de type agriculture-élevage (ou iLP pour *Integração Lavoura Pecuária*), et que le calcul parallèle dans le *cloud* dans le cadre du concept de *Big Earth Observation Data* permet aujourd'hui le développement d'une méthodologie efficace et reproductible de cartographie de systèmes complexes sur de vastes zones.

Ainsi, l'**objectif général de cette thèse est de développer et de qualifier une méthodologie de cartographie à l'échelle régionale des systèmes intégrés de type agriculture-élevage à partir de séries temporelles d'images satellite MODIS**, afin de contribuer à l'établissement d'un protocole de suivi de l'agriculture à faibles émissions de carbone tel que recommandé par le Plan ABC. Pour atteindre cet objectif, le travail a été divisé en trois étapes (Figure 1) : la mise au point de la stratégie de classification sur une petite zone, l'application de cette stratégie à l'échelle de l'Etat du Mato Grosso et l'analyse des produits cartographiques obtenus.

**Etape 1 : Mise au point de la stratégie de classification** (KUCHLER et al., 2020). L'objectif spécifique est ici de développer, tester et optimiser un modèle d'apprentissage automatique pour la cartographie des systèmes intégrés à partir de séries temporelles MODIS. Cela passe par :

- a. le choix du prétraitement de la série temporelle MODIS (lissage des séries temporelles) ;
- b. le choix des descripteurs issus de données de télédétection (bandes spectrales, indices de végétation, indices phénologiques, etc.) ;
- c. le choix de l'algorithme de classification basé sur l'apprentissage automatique.

Cette stratégie de classification est développée et testée sur une petite zone d'étude au nord de l'Etat du Mato Grosso pour laquelle on dispose d'un jeu de données conséquent.

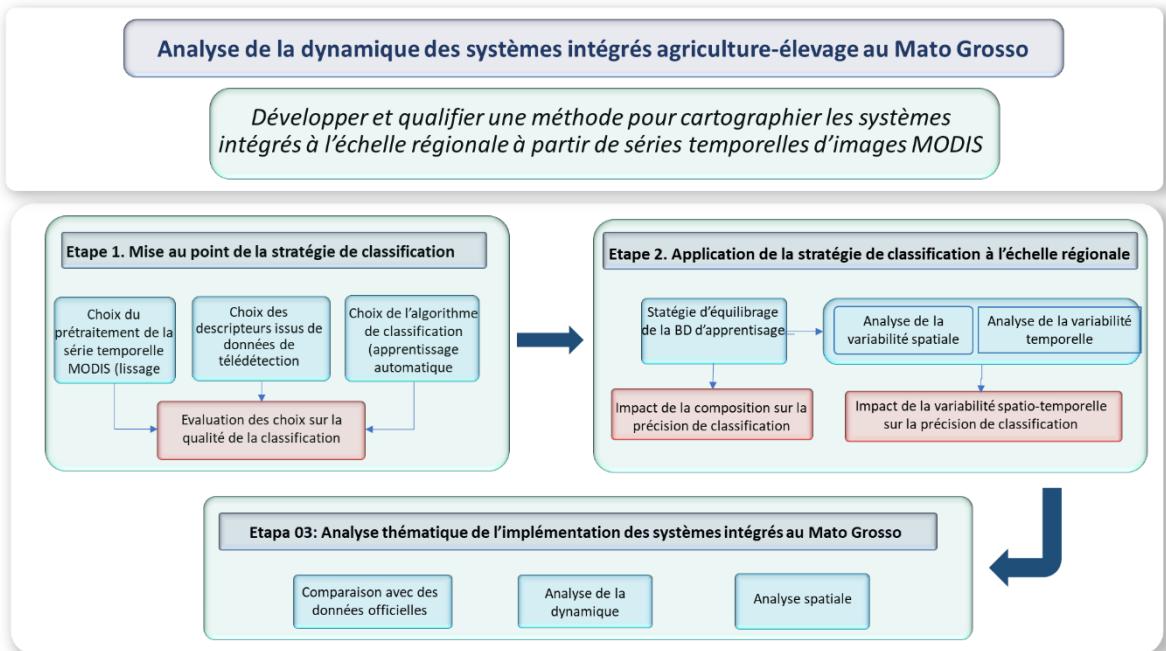
**Etape 2 : Application de la stratégie de la classification à l'échelle régionale.** La stratégie de classification des systèmes intégrés développée en Etape 1 est appliquée à l'Etat du Mato Grosso pour 7 campagnes agricoles (2012-2019). Cette application soulève de nouvelles questions de recherche méthodologique liées à la faible présence sur le terrain des systèmes intégrés, et à l'hétérogénéité spatio-temporelle des conditions agro-climatiques. Ces questions sont centrées sur la stratégie de construction et le domaine de validité de la base de données d'apprentissage :

- a. la stratégie de collecte de données et de construction de la base de données d'apprentissage pour cartographier une classe « mineure » ;
- b. l'impact sur la précision des classifications de l'utilisation de données d'apprentissage pour cartographier des zones et des années qui n'ont pas été échantillonnées. Pour caractériser l'hétérogénéité spatio-temporelle, le régime des précipitations a été utilisé.

**Etape 3 : Analyse thématique de l'implémentation des systèmes intégrés au Mato Grosso.** A partir des cartes annuelles des systèmes de culture produites en Etape 2 pour les campagnes agricoles de

2012-2013 à 2018-2019, l'implémentation des systèmes intégrés est analysée en termes de dynamique et de répartition géographique.

Il est important de signaler que les développements informatiques de ce travail de thèse ont été effectués avec des outils open source, facilement réutilisables avec d'autres jeux de données.



**Figure 1. Schéma général de la thèse.**

Dans ce résumé, le chapitre 2 présente les enjeux de l'agriculture au Mato Grosso et la pratique des systèmes intégrés ; les deux chapitres suivants présentent les méthodes et les principaux résultats obtenus sur la mise au point de la stratégie de classification (chapitre 3), et l'application de la stratégie de la classification à l'échelle régionale (chapitre 4). L'analyse thématique des produits cartographiques sur l'adoption des systèmes intégrés est résumée en chapitre 5. La conclusion en chapitre 6 fait état des principales contributions méthodologiques et thématiques de ce travail et présentent quelques perspectives méthodologiques et opérationnelles.

## 2 Enjeux et pratiques de l'agriculture au Mato Grosso

### 3 Importance du secteur agricole au Mato Grosso

Le Mato Grosso est le troisième plus grand Etat du Brésil et présente une grande diversité d'environnements, contenant trois des six biomes brésiliens (Amazonie, Cerrado et Pantanal), ainsi qu'une gamme considérable de climats. Le climat de mousson tropicale super-humide prévaut avec des précipitations élevées (2 000 mm par an), mais aussi le climat tropical avec des pluies estivales et un hiver sec et des précipitations annuelles moyennes de l'ordre de 1 500 mm (IBGE, 2011). La distribution spatio-temporelle des climats de l'Etat est en grande partie associés aux phénomènes « ENSO » (El Niño – Oscillation Sud), à la Zone de Convergence de l'Atlantique Sud et à la Zone de Convergence Intertropicale (SANTOS, 2000).

Le Mato Grosso est l'un des principaux producteurs nationaux de bœuf et de soja, et son modèle expansionniste a été fréquemment critiqué pour son impact négatif sur les ressources

environnementales, en particulier dans les forêts tropicales (ARVOR et al., 2017) et dans les savanes néotropiques brésiliennes qui sont un *hotspot* mondial pour la conservation de la biodiversité (MYERS et al., 2000).

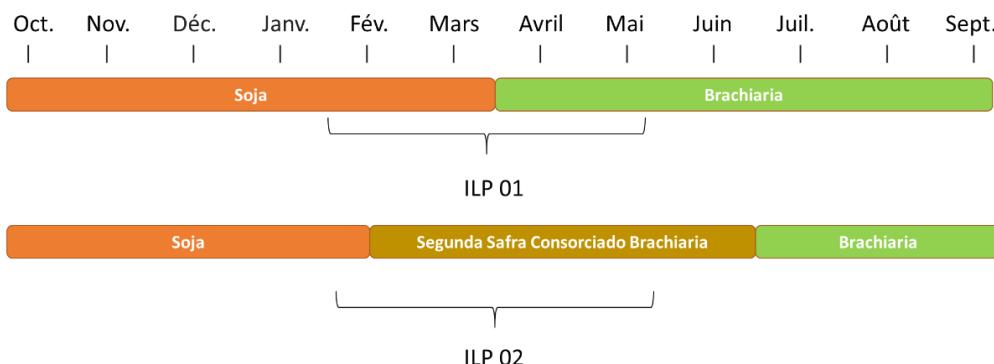
Selon les données de l'Institut Brésilien de Géographie et de Statistiques (IBGE, 2019), en 2019, 95% des zones agricoles de l'Etat étaient occupées par trois principales cultures que sont le soja (58,47%), majoritairement cultivé en culture simple, le maïs (30,22%) et le coton (6,65%) majoritairement cultivés en cultures séquentielles. Les données de l'Enquête sur la Récolte des Grains 2019/20 de la Compagnie Nationale d'Approvisionnement (CONAB - MONITORAMENTO AGRÍCOLA, 2020) montrent que le Mato Grosso est au premier rang des Etats producteurs de céréales du pays pour la neuvième année consécutive. Parallèlement, le rapport annuel de la SEEG (Système d'Estimations et d'Absorptions de Gaz à Effet de Serre) indique que le Mato Grosso est depuis 10 ans l'Etat qui a le plus fort taux d'émission de GES dans le secteur agricole et de l'élevage (73% des émissions des bovins à viande ; 6% de l'utilisation d'engrais ; 6% de la culture du soja ; 15% provenant d'autres sources (ALBUQUERQUE et al., 2020). Ces contradictions, un Etat majeur en termes de contribution à la balance commerciale brésilienne, mais avec d'importants impacts environnementaux et sociaux, font que le Mato Grosso est un territoire pertinent et prioritaire pour le déploiement de systèmes agricoles qui réconcilient les sphères économiques, sociales et environnementales, tels que les systèmes intégrés.

#### *4 Les systèmes intégrés*

Au Brésil, les systèmes intégrés agriculture-élevage-forêt (ou iLPF pour *Integração Lavoura-Pecuária-Floresta*) présentent une grande diversité liée aux conditions locales climatiques, édaphiques, aux infrastructures disponibles, à l'expérience des producteurs et aux technologies disponibles (VILELA et al., 2017). L'Etat du Mato Grosso a la plus grande surface de systèmes intégrés implantés du pays, dont plus de 80% sont des systèmes intégrés agriculture-élevage (ou iLP pour *Integração Lavoura Pecuária*), avec 1.5 Mha implantés pour la campagne 2015/2016. Sur la base de la collecte de données sur le terrain et rapportée par GIL; SIEBOLD; BERGER (2015), deux principaux systèmes iLP se trouvent dans l'Etat :

- Les iLP basés sur la rotation culture-pâturage, donc pluriannuels, sont notamment utilisés pour la récupération des pâturages dégradés car ces derniers bénéficient de la fertilité résiduelle des cultures pour restaurer la qualité du sol (e.g. KLUTHCOUSKI; YOKOYAMA; STONE, 2003; MACEDO, 2009; SALTON et al., 2014). Ce type d'intégration est généralement adopté par des exploitants dont l'activité principale est partagée entre l'élevage et l'agriculture, ou ceux dont l'activité principale est l'élevage et qui louent temporairement leurs terres aux producteurs de céréales.
- Les iLP basés sur les cultures séquentielles culture-pâturage, donc intra-annuels, sont majoritairement adoptés par des exploitants dont l'activité principale est l'agriculture et qui utilisent les pâturages pour produire du fourrage en contre-saison et des couvertures pour le semis-direct. Ce modèle d'iLP est appelé *boi safrinha* (littéralement bœuf-petite récolte). Dans ce modèle, la culture fourragère, principalement du *Brachiaria*, peut-être cultivée en relais avec du maïs, (VILELA et al., 2017). Dans ce cas, le maïs pousse en premier et est récolté avant que le pâturage soit totalement développé.

Les résultats des exploitations enquêtées pendant cette thèse montrent qu'au Mato Grosso les systèmes intégrés basés sur la rotation des cultures pratiquent également l'intégration agriculture-élevage en cultures séquentielles. Ainsi, le système iLP considéré dans ce travail fait référence au *boi safrinha*, qui se décline sous deux formes de cultures séquentielles (Figure 2) : soja puis *Brachiaria*, et soja puis association maïs/*Brachiaria* (qui se prolonge par du *Brachiaria* seul après la récolte du maïs).



**Figure 2.** Schémas des principaux systèmes intégrés agriculture-élevage (iLP) au Mato Grosso, basés sur des cultures séquentielles.

5        Etape 1 : Mise au point de la stratégie de classification

6        *Etat de l'art*

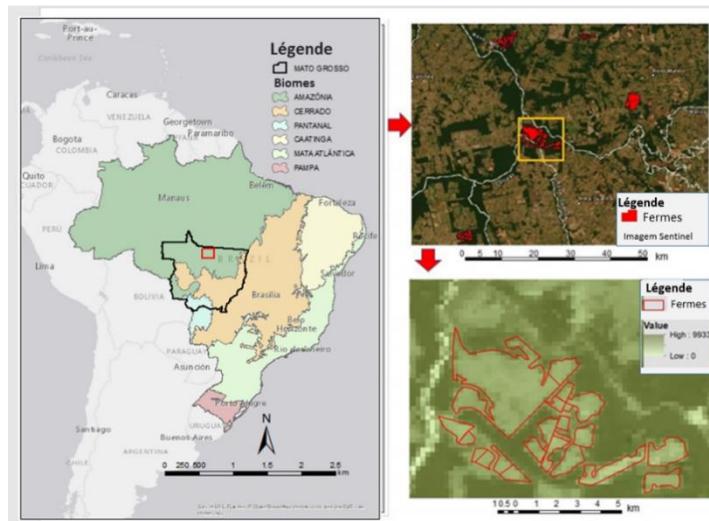
Une caractéristique cruciale dans la modélisation des classificateurs supervisés est liée à la dimensionnalité des données d'entrée. Si, d'un côté, la « malédiction de la dimensionnalité » peut entraîner un haut coût de calcul avec des descripteurs similaires, générant un degré élevé de redondance (DUDA; HART; STORK, 2000; JUDITSKY et al., 1995), d'un autre côté, l'utilisation d'une grande profondeur dans la dimensionnalité, associée aux algorithmes d'apprentissage automatique, peut être utile par l'augmentation des possibilités d'associations qui rendent le modèle plus précis (JAMES et al., 2013; PICOLI et al., 2018). (BELGIU; DRÄGUȚ, 2016) ont rapporté que les modèles *Random Forest* ont une meilleure précision de classification, en particulier lorsqu'il y a une entrée dimensionnelle élevée.

La revue de GÓMEZ; WHITE; WULDER (2016) sur l'utilisation de séries temporelles d'images satellite (STIS) optiques pour la classification de l'occupation des sols, montre que la première étape est le choix des descripteurs radiométriques. L'étape suivante est liée au choix de la méthode de filtrage et de lissage des STIS, notamment dans les zones à forte couverture nuageuse (HRID; MCDERMID, 2008; SHAO et al., 2016). Certaines études, souvent en lien avec l'utilisation agricole des sols, proposent également d'extraire des attributs phénologiques après filtrage afin de réduire davantage la dimensionnalité des variables d'entrée (XU; CONRAD; DOKTOR, 2017); (PAN et al., 2015). Les études avec STIS dans l'Etat de Mato Grosso suivent cette logique, à l'exception de (PICOLI et al., 2018) qui considèrent que les algorithmes de classification avancés sont capables traiter les lacunes dans les SITS et les bruits liés aux conditions atmosphériques, même dans des régions à forte couverture nuageuse. Ils proposent l'utilisation de STIS avec la plus grande dimensionnalité possible, sans application de filtres. De même (CHEN et al., 2018) concluent que l'utilisation de métriques phénologiques et du lissage peuvent masquer les valeurs originales des séries temporelles, et ainsi réduire la précision de la classification.

Afin d'évaluer si les conclusions de (PICOLI et al., 2018) s'appliquent aux systèmes complexes tels que les iLP, nous avons mené une expérience dans une région nord de Mato Grosso évaluant 5 jeux de données d'entrée avec différents descripteurs (indices de végétation et métriques phénologiques) et différents niveaux de prétraitement. Dans cette expérience, la précision des classificateurs *Random Forest* (RF) et *Support Vector Machine* (SVM) a également été comparée.

## 7 Données et méthodes

Pour cette étude, nous avons acquis une série temporelle complète d'indices de végétation MODIS (produit MOD13Q1) pour la période d'août 2014 à juillet 2015 (23 dates) sur une zone test située au Nord du Mato Grosso (Figure 3).



**Figure 3.** Localisation de l'état du Mato Grosso et de la zone d'étude de l'étape 1, localisation des fermes échantillonnées et exemples de parcelles échantillonnées sur un fond d'image MODIS NDVI (22/09/2014).

Les deux indices de végétation considérés sont l'Indice de Végétation par Différence Normalisée (*Normalized Difference Vegetation Index* ou NDVI) et l'Indice de Végétation Amélioré (*Enhanced Vegetation Index* ou EVI) qui ont une résolution spatiale de 250 m et une résolution temporelle de 16 jours (HUETE et al., 2002). Des données de référence sur les systèmes de culture de 77 parcelles réparties sur 5 fermes (totalisant 778 pixels MODIS ; voir Tableau 1), ont été collectées pour le cycle agricole 2014-2015 par enquêtes auprès des agriculteurs et numérisées sur des images Sentinel-2 de l'année. Ces données de référence couvrent les quatre principaux systèmes de culture observés dans la zone, soit : Pâturage (P), principalement *Brachiaria* ; iLP, représenté par le Soja suivi de *Brachiaria* ; Culture simple (SC), représentée par une culture principale (soja, maïs ou riz) suivie d'une période de jachère ; Culture séquentielle (DC), représentée par le soja comme culture principale et suivie par le maïs ou le mil. Les données du terrain utilisées dans ce travail ont été collectées dans des parcelles de plus de 13 ha (soit une « petite » parcelle pour l'Etat du Mato Grosso), avec une taille moyenne des champs échantillonnés de 81 ha. Pour minimiser l'effet de bord (pixels mixtes), seuls les pixels dont le centre était à l'intérieur des limites de parcelle ont été retenus pour les traitements.

Pour évaluer l'impact de différents prétraitements sur la discrimination des systèmes de culture, cinq jeux de données ont été créés :

- R-NDVI : série temporelle de NDVI brut (23 variables, 1 variable par date) ;
- R-NDVI + R-EVI : combinaison de séries temporelles de NDVI brut et de EVI brut (46 variables) ;

- S-NDVI : série temporelle de NDVI lissée (23 variables) ;
- P-NDVI : variables phénométriques issues de la série temporelle de NDVI brut (11 variables) ;
- R-NDVI + P-NDVI : combinaison de séries temporelles de NDVI brut et de variables phénométriques de NDVI (34 variables).

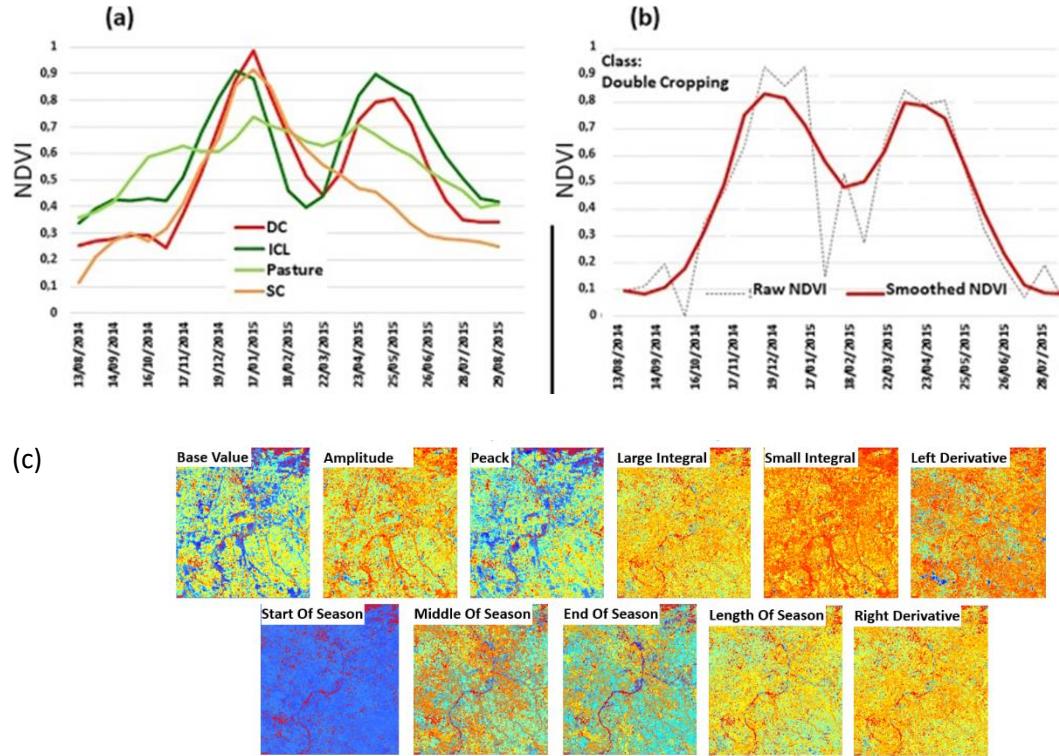
Après quelques tests, et en considérant des études précédentes menées dans le Mato Grosso (ARVOR et al., 2008) et dans l'Etat voisin du Tocantins (BELLÓN et al., 2017), nous avons décidé d'utiliser le filtre *Savitzky-Golay* (SG) (CAO et al., 2018; CHEN et al., 2004; SAVITZKY; GOLAY, 1964), proposé par le logiciel TIMESAT (EKLUNDH, L.; JÖNSSON, P., 2017). Bien que TIMESAT permette d'utiliser dans le processus de lissage les données de la *Quality band* du produit MOD13Q1, nous avons décidé d'effectuer un lissage non pondéré en raison du peu de fiabilité de ces données dans des régions fortement ennuagées (BELLÓN et al., 2017). L'algorithme SG est appliqué avec les paramètres  $d = 2$  (degré du polynôme de filtrage) et  $m = 2$  (demi-largeur de la fenêtre de filtre), préconisés par (BELLÓN et al., 2017). Les séries temporelles de NDVI lissées ont ensuite été analysées par TIMESAT pour extraire les 11 variables phénométriques qui composent le jeu de données P-NDVI, soit : a) le début du cycle phénologique ; b) la fin du cycle phénologique ; c) le niveau de 80% de distribution des données à gauche ; d) le niveau de 80% de répartition des données à droite ; e) la valeur maximale de NDVI ; f) l'amplitude saisonnière de NDVI ; g) la durée de la saison ; h) et i) les intégrales ; j) la valeur de base de la série ; k) le milieu du cycle phénologique.

Le potentiel des cinq jeux de données pour discriminer les systèmes de culture a été testé à l'aide de deux classificateurs d'apprentissage avancés recommandés pour traiter des données de haute dimensionnalité (JAMES et al., 2013). Les deux classificateurs, *Random Forest* (RF) et *Support Vector Machine* (SVM), ont été testés avec le package *caret* (KUHN et al., 2015) de l'environnement R. La précision de la classification a été évaluée à l'aide d'une procédure de validation croisée *5-fold* (Wiens et al., 2008) en utilisant 80% des échantillons pour l'apprentissage (622 pixels) et 20% pour la prédiction (156 pixels). Cette technique de validation croisée *k-fold* permet d'utiliser l'ensemble de données, ce qui est particulièrement pertinent pour de petits jeux de données (DIMA, 2018). Enfin, la précision de la classification a été analysée en fonction du type et du nombre de variables utilisées afin d'évaluer l'impact des différentes étapes de prétraitement sur la redistribution de l'information discriminante présente dans les séries temporelles. Pour ordonner les variables, nous avons utilisé l'indice de diminution moyenne de la précision (MDA) de RF (CUTLER et al., 2007). Ce processus a été réalisé à l'aide de la fonction *rfe* disponible dans le package *caret*.

## 8 Principaux résultats

L'analyse des séries temporelles R-NDVI moyennées sur l'ensemble des pixels de chaque classe (Figure 4a) montre que le profil temporel des pâturages (P) forme un plateau avec des valeurs peu élevées, tandis que celui des cultures simples (SC) a une saisonnalité plus marquée et des valeurs maximales élevées. En revanche, les systèmes de culture séquentielles ou double culture (DC) et les systèmes intégrés agriculture-élevage (iLP) sont caractérisés par deux cycles de végétation qui se ressemblent (Figure 4a). Une analyse plus poussée montre cependant que les deux séries diffèrent en début de saison (août-octobre) avec des valeurs NDVI plus élevées pour iLP, et en fin de saison avec un deuxième cycle plus long pour iLP que pour DC (le pâturage reste vert plus longtemps après la récolte du maïs). La Figure 4b montre l'exemple

d'une série temporelle NDVI pour un seul pixel, avant et après lissage. Les pics et vallées dus au bruit atmosphérique sont lissés, facilitant l'interprétation visuelle des cycles phénologiques et le calcul des 11 indices phénométriques (P-NDVI) qui sont montrés en Figure 4c.



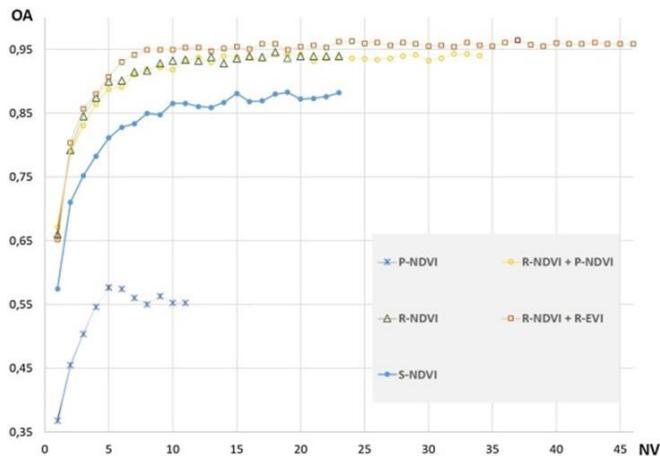
**Figure 4.** a) Série temporelle annuelle du R-NDVI MODIS moyen pour chaque classe ; b) Exemple de série temporelle MODIS NDVI acquise sur un pixel DC (Culture séquentielle), avant et après lissage Savistky-Golay ; c) Images des 11 indices phénométriques calculés par TIMESAT.

Les meilleures précisions globales de classification (OA de 0.96 et 0.95) sont obtenues respectivement avec les jeux de données R-NDVI+R-EVI et R-NDVI+P-NDVI. Le classement des jeux de données est identique lorsque l'on s'intéresse plus spécifiquement à la classe iLP, avec un *F-score* de 0.95 pour R-NDVI+R-EVI, et de 0.93 pour R-NDVI+P-NDVI. Ces résultats montrent la performance des séries temporelles non lissées par rapport aux séries lissées avec un écart de 5 points. La précision obtenue avec les indices phénométriques seuls n'est pas du tout satisfaisante, que cela soit au niveau global (0.58) ou de la classe iLP (0.64).

**Tableau 1.** Précisions (OA = précision globale et K = Kappa) obtenues pour les différents classificateurs (RF = Random Forest et SVM = Support Vector Machine) et F-scores obtenus avec RF pour les différentes classes (P = pâturage, SC = simple culture, DC = Double culture et iLP = système intégré culture-élevage).

Niveaux de prétraitement	Random Forest						SVM	
	F-score						OA	K
	Pâturage	iLP	SC	DC	OA	K		
<b>R-NDVI</b>	0,95	0,92	0,94	0,91	0,94	0,91	0,91	0,88
<b>R-NDVI + R-EVI</b>	0,97	<b>0,95</b>	0,97	0,96	<b>0,96</b>	0,94	0,95	0,93
<b>S-NDVI</b>	0,9	0,90	0,86	0,87	0,89	0,84	0,83	0,77
<b>P-NDVI</b>	0,58	0,64	0,41	0,58	0,58	0,42	0,66	0,57
<b>R-NDVI + P-NDVI</b>	0,97	0,93	0,97	0,92	0,95	0,92	0,94	0,93
<b>Number of pixel samples</b>	177	293	107	201				

La Figure 5 présente l'évolution de la précision globale des classifications en fonction du nombre de variables d'entrée utilisées dans la classification (les variables sont introduites une par une en fonction de leur valeur d'importance MDA). Les résultats montrent que le jeu de données R-NDVI+R-EVI est le plus efficace, car il affiche la meilleure combinaison précision globale vs nombre de variables importantes, soit une valeur de précision élevée obtenue avec moins de 10 variables, tandis que les jeux de données R-NDVI et R-NDVI+P-NDVI atteignent une valeur élevée de précision mais avec un plus grand nombre de variables.



**Figure 5.** Précisions globales, en fonction du nombre de variables, des classifications Random Forest pour les 5 jeux de données testés.

En termes d'algorithme de classification, les valeurs de précision globale et de Kappa obtenus avec RF et SVM sont similaires, avec une légère amélioration dans l'utilisation de *Random Forest* (Tableau 1). L'ensemble des résultats de cette étude ont été publiés dans (KUCHLER et al., 2020).

**Conclusion partielle.** Cette étude sur le pré-traitement des images MODIS montre que le lissage temporal de séries temporelles d'indices de végétation et le calcul d'indices phénométriques tend à dégrader la précision globale de classification des systèmes de culture et la précision de la classe iLP. Ce résultat est en accord avec ceux de (PICOLI et al., 2018), qui utilisent les réflectances et des indices de végétation « bruts » dans leur classification et avec ceux de (CHEN et al., 2018) qui soulignent les limites de l'utilisation d'un lissage des données de type Savitsky-Golay qui, d'un côté, réduit les bruits atmosphériques des séries temporelles, mais qui de l'autre, altère des informations importantes potentiellement discriminantes pour certaines classes, comme c'est le cas ici pour les classes double-culture et systèmes intégrés.

9      Etape 2 : Application de la stratégie de la classification à l'échelle régionale

10     *Approche de classification, nomenclature et outils*

11     La démarche générale et les outils *Big Earth Data*

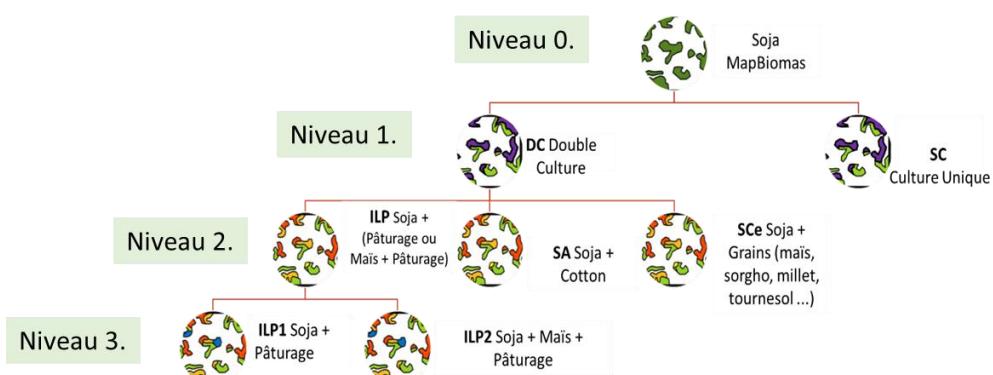
La stratégie de classification établie en Chapitre 5 a été appliquée à l'ensemble de l'Etat du Mato Grosso. Le classificateur *Random Forest* (BREIMAN, 2001) a été utilisé avec 100 arbres aléatoires, associé à un ensemble de données d'apprentissage / validation de 25 000 pixels environ. Dans ce travail, nous avons adopté une approche de classification hiérarchique (e.g. (LEBOURGEOIS et al., 2017) en partant de la classe Soja du produit annuel MapBiomas. Les traitements ont été faits avec la plateforme *Google Earth Engine* (GEE) qui permet d'accéder facilement à des produits prêts à l'emploi et de traiter de grands volumes de données. Nous avons pu ainsi traiter 3864 images du produit MOD13Q1 (23 dates de NDVI, EVI, NIR et MIR ; 6 tuiles pour couvrir le Mato Grosso ; 7 campagnes agricoles entre 2012-13 et 2018-19).

12     La nomenclature

La structure hiérarchique de classification est composée de 4 niveaux (

) :

- Niveau 0 : masque correspondant à la classe Soja du produit MapBiomas collection 5.0 ;
- Niveau 1 : la classe Soja est séparé en deux classes, soient Culture Simple (SC) et Double Culture (DC) ;
- Niveau 2 : la classe DC est séparée en Soja+Coton (SA), Soja+Céréale (SCe) principalement du maïs mais aussi du mil, sorgho ou tournesol, et Soja+*Brachiaria* (iLP) ;
- Niveau 3 : la classe iLP est séparée en iLP1 (Soja+*Brachiaria* pur) et iLP2 (Soja+*Brachiaria* en association avec du maïs principalement).



**Figure 6. Schéma qui représente la structure hiérarchique de classification des principaux systèmes de culture en 4 niveaux.**

### 13 Les post-traitements

Les cartes annuelles des systèmes agricoles sont produites à l'échelle du pixel. Un filtre spatial est ensuite appliqué à la classe iLP pour éliminer les pixels ou groupes de pixels isolés mal classés (essentiellement des pixels mixtes liés aux transitions entre les classes de culture, de pâturage et de forêt ; LOBELL; ASNER, 2004; OZDOGAN, 2010). Ce filtre spatial exclut des pixels auxquels ne sont pas connectés au minimum 5 autres pixels de la même classe, soit les patchs dont la superficie est inférieure à 35 ha environ. Ce nombre, qui peut paraître élevé, est à évaluer au regard de la taille moyenne (90 ha) et minimale (30 ha) des parcelles du jeu de données terrain.

### 14 Stratégie de création d'une base de données d'apprentissage

#### 15 Méthodes de collecte de données d'apprentissage

Pour produire des cartes d'occupation des sols, la majorité des études utilisent des classifieurs supervisés qui nécessitent un grand nombre de données d'apprentissage ; ceci reste un immense défi pour la cartographie de l'utilisation agricole des sols à grande échelle (BÉGUÉ et al., 2018; BELLÓN et al., 2017). Plusieurs stratégies peuvent être utilisées pour constituer une base d'échantillons de terrain. Pour labelliser des classes « stables », c'est-à-dire des classes qui ont peu de variation intra- et inter-annuelle (les cultures pérennes ou la végétation boisée naturelle), on peut se baser sur l'interprétation visuelle d'images à très haute résolution spatiale pour définir des zones d'apprentissage (BULLOCK et al., 2020; SOUZA et al., 2020). Pour les classes qui, au contraire, ont un cycle saisonnier et annuel marqué (les cultures annuelles), la collecte de données *in situ* reste le mode le plus fiable pour construire la base de « vérité de terrain » (DELINCE et al., 2017).

Au Brésil, pour la cartographie des pâturages, (PARENTE et al., 2017, 2019) utilisent une combinaison de données collectées par des campagnes de terrain et de données photo-interprétées. Dans le cas des systèmes de cultures séquentielles, les jeux de données sont issus généralement d'entretiens avec des producteurs et des coopératives, complétés par des données collectées sur le terrain (e.g. ARVOR et al., 2011; CHEN et al., 2018; KASTENS et al., 2017; MANABE; MELO; ROCHA, 2018; PICOLI et al., 2018; KUCHLER et al., 2019). L'identification de ces systèmes reste très difficile par photo-interprétation, même pour des spécialistes, car ce sont des systèmes très dynamiques et diversifiés, avec différentes classes de pâturage et de cultures annuelles (soja, coton, etc.). La stratégie de collecte de données de terrain via des entretiens avec les producteurs de la région est nécessaire car, dans le cas des cultures séquentielles, une visite effectuée à une seule date ne permet pas d'identifier le système de production. Dans la plupart des études, cette stratégie est toutefois limitée car elle ne permet pas de recueillir une grande quantité d'échantillons sur de vastes zones, et reste problématique pour des classes peu représentées comme les SIs.

### 16 L'équilibrage des bases de données d'apprentissage

Lors d'une classification supervisée avec des algorithmes d'apprentissage automatique, tels que *Random Forest*, la stratégie d'équilibrage des échantillons est fondamentale, car elle influe directement sur le résultat. L'enjeu est particulièrement important quand il s'agit de classer des classes rares comme c'est le cas ici des iLP.

Les données non équilibrées se réfèrent à une situation dans laquelle le nombre d'observations n'est pas le même pour toutes les classes. Les classificateurs d'apprentissage automatique visant à minimiser le taux d'erreur global ont tendance à favoriser la classe qui comporte la plus forte proportion d'observations (ou classe majoritaire). Cela peut être particulièrement problématique pour la classification d'une classe « rare » (ou classe minoritaire), telle que la classe iLP. Pour cette raison, il est essentiel de réaliser une analyse de sensibilité du classifieur à la distribution des échantillons d'apprentissage.

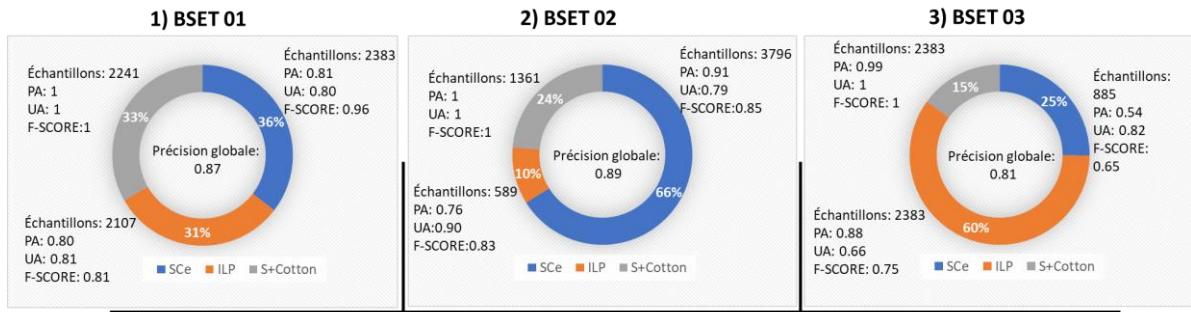
Des études précédentes sur la performance de *Random Forest* en fonction de la base d'apprentissage (DALPONTE et al., 2013)(JIN; STEHMAN; MOUNTRAKIS, 2014) montrent que de meilleurs résultats de classification sont obtenus avec des échantillons d'apprentissage équilibrés, c'est à dire avec un nombre d'échantillons équivalent dans chaque classe. De même, dans leurs travaux, (NOI; KAPPAS, 2017) concluent que l'algorithme *Random Forest* est extrêmement sensible à l'équilibre des jeux de données d'apprentissage, obtenant une plus grande précision globale dans les échantillons équilibrés. Cependant, quand le jeu de données se compose d'un nombre important d'échantillons, la différence entre jeux de données équilibrés et déséquilibrés devient non significative. D'un autre côté, (COLDITZ, 2015) et (MELLOR et al., 2015) montrent une meilleure performance de la classification lorsque la répartition des échantillons entre les classes est plus proche de la proportion réelle de la classe sur le terrain.

## 17 Expérimentations et principaux résultats

Pour constituer le jeu de données d'apprentissage, des échantillons de terrain ont été collectés à partir de cinq sources différentes : points GPS collectés sur le terrain, entretiens avec les producteurs, avec des ONG locales et des chercheurs de l'Embrapa, et données mises à disposition par les coopératives. Lors d'entretiens avec des producteurs du réseau des URT (Unités Technologiques de Référence) en partenariat avec Embrapa Agrossilvipastoril, des données sur l'historique de la mise en culture de certaines parcelles ont été collectées. Des échantillons ont également été collectés auprès du groupe Bom Futuro qui est l'un des plus grands groupes de production agricole du Brésil. L'ensemble des données collectées totalisent 891 polygones (26 778 pixels) répartis dans 46 municipios de l'Etat, dont la surface moyenne est de 96 ha. Ces polygones ont ensuite été superposés aux images MODIS ; les pixels dont le centre est à l'intérieur du polygone ont été gardés, et les pixels de bordure ont été supprimés par application d'une zone tampon de 250 m.

Le jeu de données d'apprentissage est composé de 2/3 des parcelles sélectionnées de façon aléatoire ; le 1/3 des parcelles restant est utilisé pour la validation de l'algorithme de classification. La séparation entre les jeux de données d'apprentissage et de validation est faite au niveau des parcelles et non au niveau des pixels pour éviter les biais dans la classification (dûs à des échantillons d'apprentissage et de validation localisés dans la même parcelle).

Compte-tenu des conclusions divergentes de la bibliographie sur l'impact de l'équilibre des échantillons sur la qualité de la classification de l'occupation du sol, trois scénarios de distribution d'échantillons par classe ont été testés : un jeu de données équilibré (*Bset01*) avec un nombre d'échantillons proche dans chaque classe, et deux jeux de données déséquilibrés, avec une répartition par classe des échantillons proche de la répartition réelle des classes sur le terrain telle qu'estimée à partir du jeu de données collecté (*Bset02*), et une sur-représentation de la classe rare iLP (*Bset03*). La montre la distribution des échantillons pour chaque jeu de données et les résultats obtenus pour la classe iLP.



**Figure 7. Composition des trois jeux de données d'apprentissage testés (Bset01 jeu de données équilibré, et Bset02 et Bset03 jeux de données déséquilibrés), et précisions associées aux classes « soja+ coton » (S+coton), « soja + céréales » (SCe) et système intégré (iLP).**

Le système de double culture dont la précision varie le moins en fonction du jeu de donnée d'apprentissage est la classe Soja+Coton, tandis que la classe dont la précision varie le plus est la classe Soja+Céréales (*F-score* entre 0.65 et 0.96). Les meilleurs *F-score* de la classe iLP sont obtenus pour *Bset01* et *Bset02* (respectivement 0.81 et 0.83), mais avec une erreur de commission plus élevée pour *Bset01* (+ 9%). En raison d'une plus grande précision globale, d'un *F-score* plus élevé et d'une erreur de commission plus faible pour la classe d'intérêt iLP, le jeu de données *Bset02* (dans lequel le nombre d'échantillons par classe est représentatif de la proportion des classes sur le terrain) est utilisé pour la production des cartes annuelles aux Niveaux 02 et 03.

## 18 Impact de la distribution spatio-temporelle des jeux de données d'apprentissage sur la qualité des classifications

### 19 Enjeux méthodologiques

Le Brésil a une grande diversité d'environnements et de modèles de production agricole. Sa variabilité latitudinale se reflète dans les 6 biomes qui existent sur son territoire et dans les zones de transition. Les régimes climatiques, exprimés principalement par les précipitations, présentent également une grande variabilité annuelle conditionnée principalement par des phénomènes temporaires, comme l'ENSO.

Dans ce cas, et compte tenu de la difficulté d'acquisition des données de terrain comme nous l'avons vu précédemment, tester la robustesse d'une méthodologie qui permette d'entrainer avec des échantillons de différentes années et régions est une étape incontournable. En ce sens, (PICOLI et al., 2018) utilisent une base unique d'apprentissage et de validation de 1 800 points pour les 15 années et régions de l'Etat du Mato Grosso, et obtiennent une bonne précision de classification pour les systèmes de culture conventionnels. (PARENTE et al., 2017, 2019) affirment au contraire que la variabilité spectrale spatiale et temporelle est importante au sein d'une même classe, au point de confondre l'algorithme *Random Forest*. Ils utilisent donc une méthodologie de collecte et de validation d'échantillons par photo-interprétation d'images (avec plusieurs interprètes) pour chaque année d'étude et dans chaque scène du territoire national pour entraîner les algorithmes de classification.

Dans le cas de notre étude sur les systèmes intégrés, et compte-tenu des données de terrain dont nous disposons, il a fallu travailler avec des données d'apprentissage et de validation répartis de façon très inégale dans l'espace-temps. Pour étudier l'impact de cette distribution spatio-temporelle des jeux de données sur la précision des classifications, nous avons testé et évalué la précision des cartes des

systèmes de culture en fonction de différentes années et régions du Mato Grosso. Parmi les diverses caractéristiques édaphoclimatiques qui ont un impact sur le cycle phénologique de la végétation, et donc sur sa réponse spectrale, nous nous sommes focalisés sur la pluviométrie dont le rôle est déterminant pour la croissance de la végétation et qui a une forte variabilité spatio-temporelle.

## 20 Impact de la distribution temporelle des jeux de données d'apprentissage

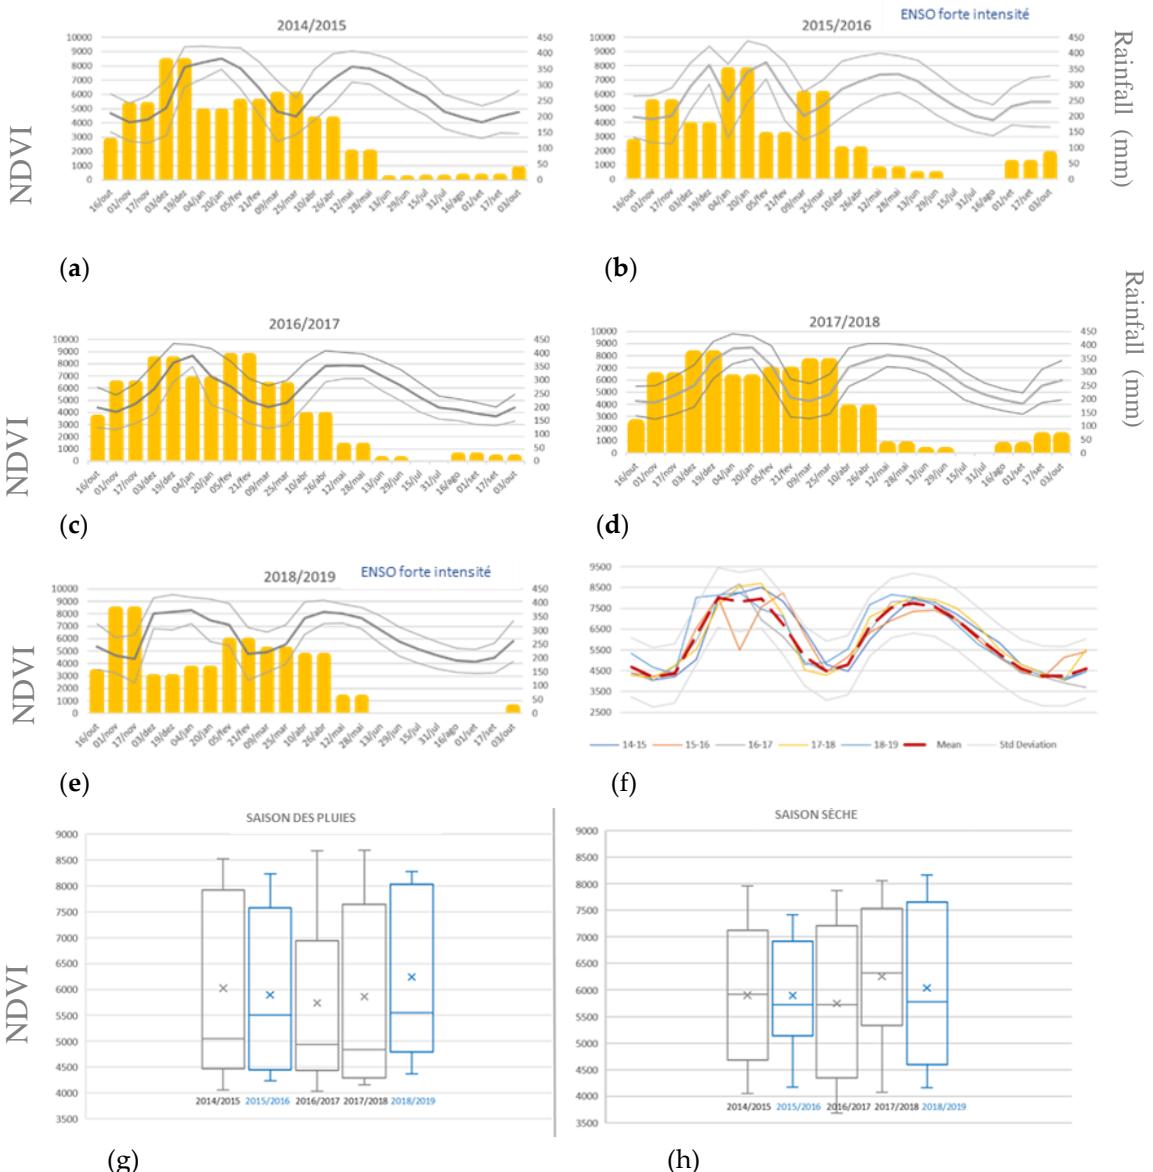
Le jeu de données de terrain dont nous disposons est fortement déséquilibré suivant les années, avec une concentration de données entre les années culturales 2014/2015 et 2018/2019, qui représentent 90% de l'ensemble du jeu de données.

Avant de quantifier l'impact de ce déséquilibre temporel sur la précision des classifications pluriannuelles, nous avons étudié la variabilité interannuelle des séries temporelles, en utilisant la moyenne des valeurs NDVI du système *Soja+Brachiaria* et les relevés de précipitations mensuelles collectés dans les stations météorologiques de l'Institut National de Météorologie (INMET, 2019) entre 2014 et 2019 (Figure 8a-e).

L'analyse des séries temporelles de NDVI (Figure 8a-e) montre une variabilité interannuelle importante du profil de la classe iLP, notamment pendant la saison humide d'octobre à mars (période de culture du soja). Cette variabilité dans les profils de NDVI est particulièrement marquée pendant les années de forte intensité ENSO, avec deux pics de croissance du NDVI en 2015/2016 (liés à l'hétérogénéité des pluies et/ou à la qualité des images, Figure 8b), et un plateau prolongé en 2018/2019 (Figure 8e). Les profils de NDVI sont plus homogènes pendant la saison sèche de juin à août, même en année ENSO (Figure 8a-f). La différence entre saisons est notamment visible en Figure 8g-h. On voit une dispersion des données plus importante en saison des pluies qu'en saison sèche, et plus asymétrique (avec des valeurs médianes éloignées des valeurs moyennes). Les résultats des Figure 8g-h ne permettent pas de voir un effet ENSO sur la dispersion et la symétrie des valeurs de NDVI.

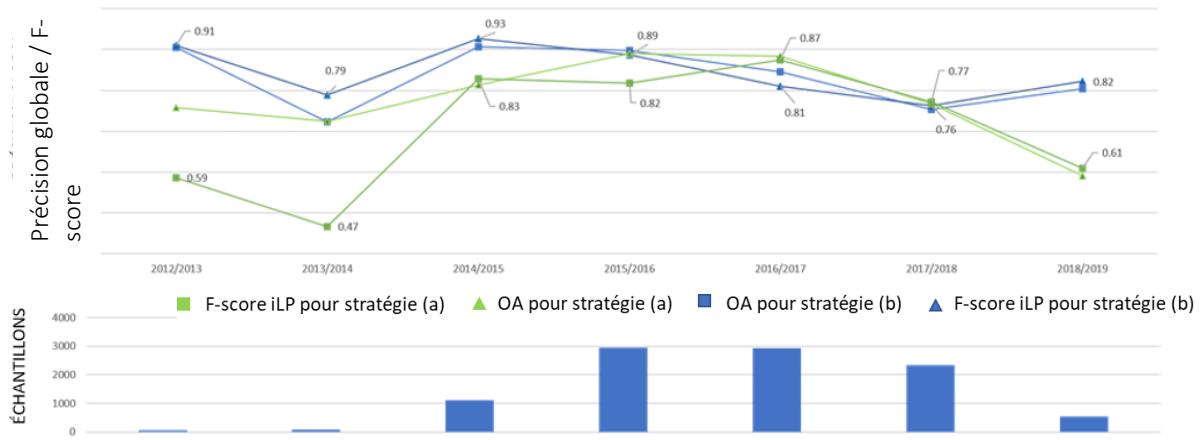
Pour évaluer l'impact de ce déséquilibre temporel entre les jeux de données, nous avons comparé la précision de classification obtenue suivant deux stratégies de construction de la base de données d'apprentissage :

- La stratégie (a), traditionnelle, utilise 2/3 des données de terrain acquises pour une année donnée pour classer les séries temporelles de la même année ; dans ce cas, le 1/3 des échantillons restants est réservé pour la validation.
- La stratégie (b) consiste à mélanger les jeux de données acquis au cours d'années différentes et à les utiliser pour classer les séries temporelles de chaque année. Dans notre cas, la base de données d'apprentissage est composée des 2/3 des données acquises entre 2014/15 et 2018/19 (les plus riches en termes de données de terrain) et la validation pour ces années-là est faite avec les données de l'année considérée (échantillons non utilisés pour l'apprentissage). Ainsi, dans ce scénario, la base de données construites avec les données acquises entre 2014/15 et 2018/19 est utilisée pour classer les 2 années antérieures (2012/13 et 2013/14). La validation des 2 classifications ainsi obtenues est faite à partir des données acquises ces années-là.



**Figure 8. Séries temporelles de la moyenne des valeurs NDVI (et écart-type en grisé) calculée sur les échantillons iLP et de la pluviométrie mensuelle moyenne du Mato Grosso, pour les campagnes : (a) 2014/15 ; b) 2015/16 (ENSO) ; c) 2016/17 ; d) 2017/18 ; e) 2018/19 (ENSO). En (f) sont représentées les moyennes de chaque année (2016/17 à 2018/19), la valeur moyenne des 5 années et l'écart-type. En g) et h), les box plots montrent la variabilité des échantillons pour la saison des pluies (déc à fév) et pour la saison sèche (juin à août).**

Les résultats de la **Erro! Fonte de referência não encontrada.** montrent que globalement la précision globale et le *F-score* de la classe iLP sont plus élevés pour la stratégie (b), c'est-à-dire lorsque les données des cinq années principales sont utilisées. Ceci est particulièrement vrai pour les années où peu d'échantillons sont disponibles, comme en 2012/2013, 2013/2014 et 2018/2019. Pour les années avec un nombre important d'échantillons disponibles (2015/2016, 2016/2017 et 2017/2018), la précision globale et le *F-score* varient peu, quel que soit le nombre d'années (entre 1 et 5 ans testés ; non montré) utilisées pour l'apprentissage. Les résultats présentés en **Erro! Fonte de referência não encontrada.** suggèrent que la précision est davantage liée à la quantité d'échantillons qu'à la variabilité des précipitations annuelles.

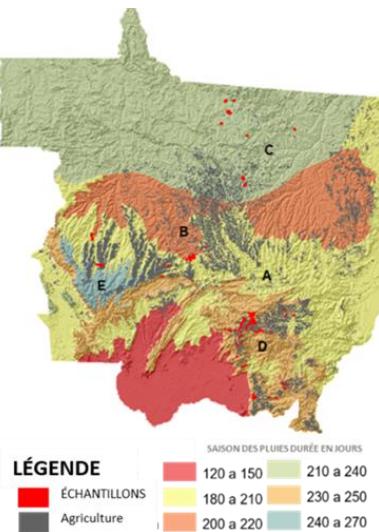


**Figure 9. Précision globale et F-score de la classe iLP obtenus pour chaque année et pour les deux stratégies d'échantillonnage temporel ; le nombre d'échantillons disponibles par année est représenté par des histogrammes dans la figure du bas.**

#### 20.1.1 Impact de la distribution temporelle des jeux de données d'apprentissage

Le jeu de données d'apprentissage est non seulement déséquilibré dans le temps, mais aussi dans l'espace avec une concentration géographique des données.

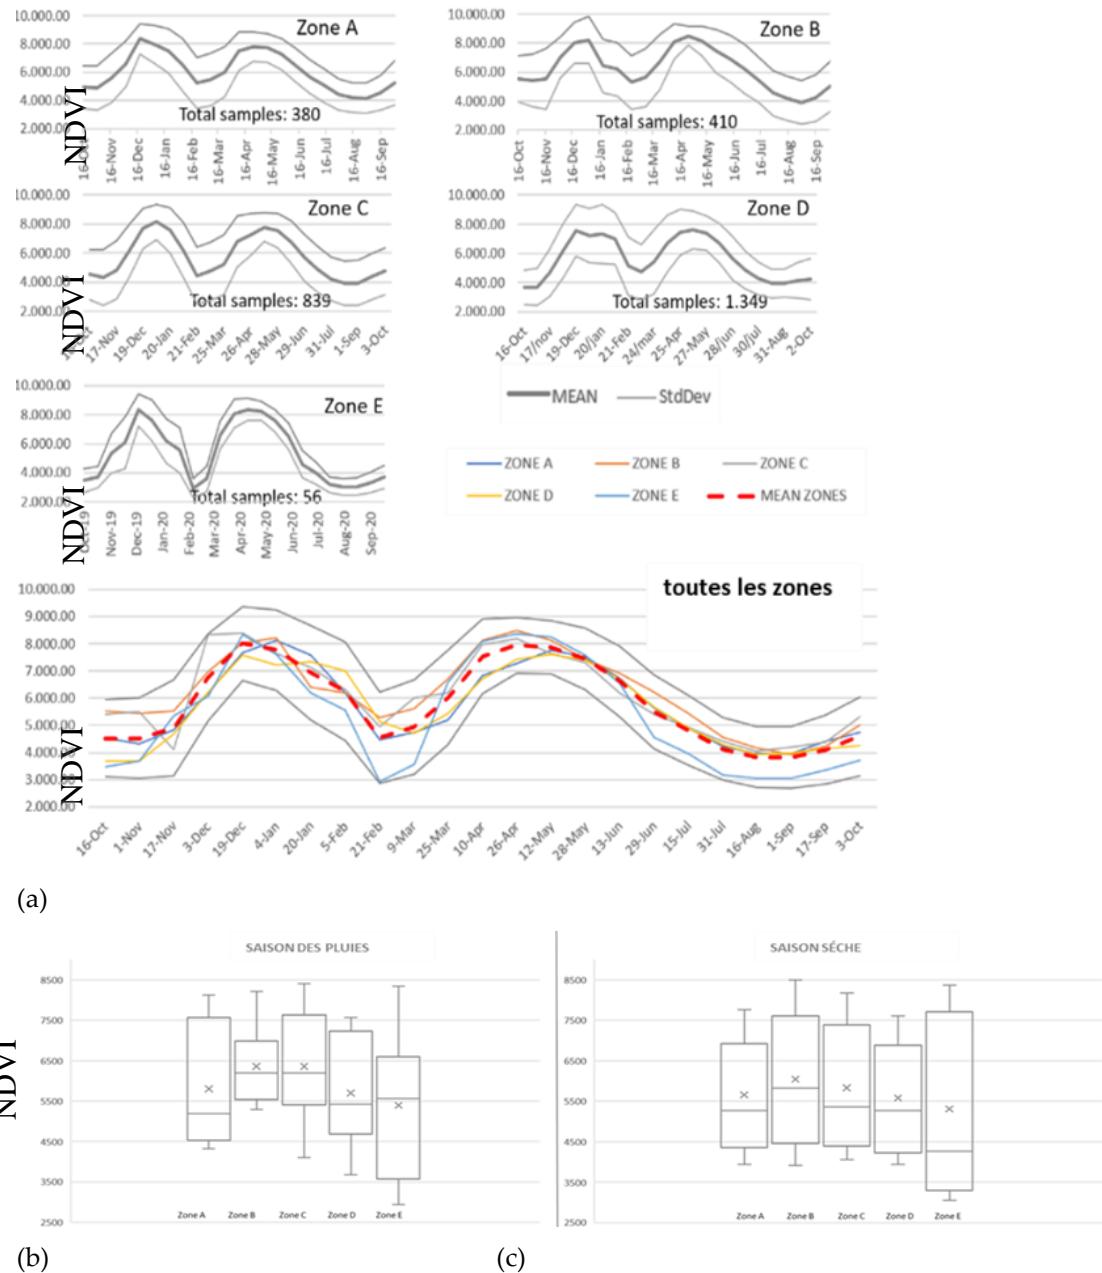
Pour tester l'impact de la distribution géographique des échantillons sur les résultats de classification à l'échelle de l'Etat, nous avons utilisé le zonage de (SANTOS, 2000) qui définit six régions selon un critère de durée des précipitations pendant la saison des pluies (Figure 10).



**Figure 10. Carte des régions climatiques basées sur la durée de la saison des pluies (d'après (SANTOS, 2000)).**

La Figure 11a montre les profils temporels moyens de NDVI (et les écarts-types) de la classe iLP calculés pour chaque région. Comme pour l'étude sur la variabilité temporelle, nous avons analysé séparément les saisons sèche (juin-août) et pluvieuse (déc-fév). On observe une forte variabilité des courbes de NDVI dans chaque région, principalement en saison des pluies. La zone E a la courbe de NDVI la plus « bruitée », avec la plus grande amplitude, mais c'est aussi la zone qui contient le moins

d'échantillons. Dans le deuxième cycle de la saison sèche, les zones C et D ont un comportement similaire, tout en étant des régions avec plus d'échantillons. La dispersion et la symétrie de la distribution des valeurs de NDVI par région ne montrent pas de tendance claire. Dans le cas de la zone A, l'amplitude est plus grande pendant la saison des pluies, tandis que pour les zones B, C et E, une plus grande diversité de valeurs se retrouve dans la saison sèche. Dans le cas de la zone D, l'amplitude ne varie pas de manière significative.

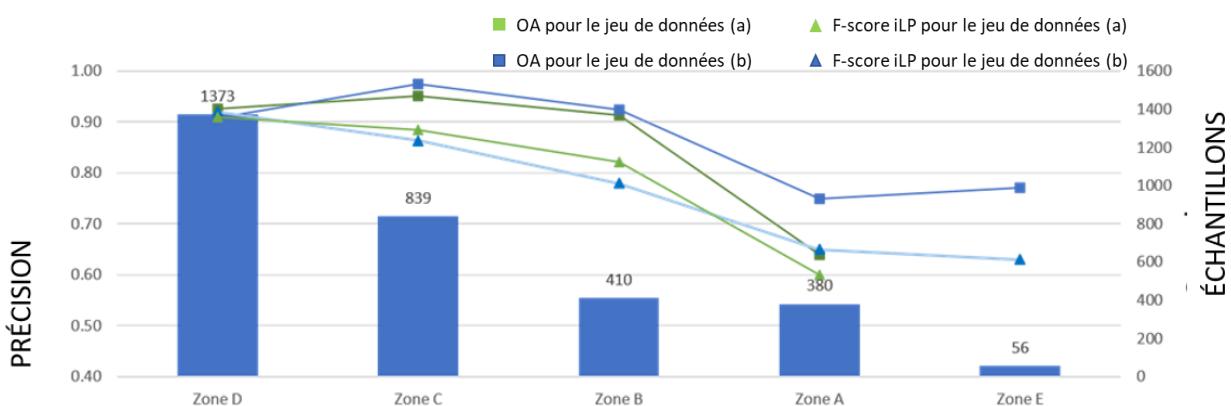


**Figure 11. Variabilité spatiale des échantillons iLP et régions climatiques de l'Etat de Mato Grosso. Séries temporelles des valeurs moyennes et des écart-types de NDVI (x 10 000) pour 5 régions climatiques (a) ; Box plot de la variabilité du NDVI pour la saison des pluies décembre-février (b), et la saison sèche juin-août (c).**

Les Figures 11b et c montrent que dans toutes les régions, les valeurs moyennes de NDVI entre saison des pluies et saison sèche ne sont pas significativement différentes, notamment dans les régions A, D et E, avec des valeurs légèrement inférieures en saison sèche pour les régions B et C.

Deux stratégies de construction de la base de données d'apprentissage ont ensuite été testées :

- dans le jeu de données (a), les données d'échantillonnage et de validation ont été divisés par région ; dans ce cas, seuls les 2/3 des échantillons d'une même zone ont été utilisés comme base d'apprentissage (1/3 pour la validation) pour la classification de la zone. Cette stratégie n'a pas été appliquée à la zone E, en raison du faible nombre d'échantillons de la zone ;
- dans le jeu de données (b), les échantillons collectés dans toutes les régions sont mélangés et utilisés comme données d'entraînement pour chaque zone.



**Figure 12. Précision globale (OA) et F-score de la classe iLP, obtenus pour les 5 régions climatiques (A à E) et pour les deux stratégies d'échantillonnage spatial (jeux de données a et b). Les histogrammes indiquent le nombre d'échantillons disponibles par région.**

L'analyse de la Figure 12 permet d'évaluer l'impact de la stratégie d'échantillonnage spatial sur la précision globale de la carte et sur le *F-score* de la classe iLP. On observe globalement que plus le nombre d'échantillons dans la région est important, plus la précision globale et le *F-score* sont élevés, à la fois dans le jeu de données (a) et dans le jeu de données (b). Les valeurs de précision globale et de *F-score* dans les zones B, C et D sont proches pour les deux stratégies. Dans la zone A, lorsque toutes les années sont utilisées pour l'apprentissage (jeu de données b), il y a une amélioration significative de la précision globale.

## 21 Evaluation des cartes des systèmes de culture aux différents niveaux

### 22 Evaluation globale

Les classifications évaluées dans cette section ont été faites en utilisant l'ensemble des échantillons disponibles - regroupement de toutes les régions et toutes les années - sans ré-équilibrage du jeu de données.

La précision globale des classifications des systèmes de culture obtenue aux trois niveaux est comprise entre 0.70 et 0.96 (Tableau 2). Comme attendu, le Niveau 01 (classes DC et SC) obtient en moyenne le meilleur score (0.89) et montre la plus grande stabilité pluri-annuelle (entre 0.86 et 0.96). Ensuite viennent le Niveau 02 (0.84 en moyenne), puis le Niveau 03 (0.77 en moyenne). Les Niveaux 02 et 03 ont des amplitudes de variation du même ordre.

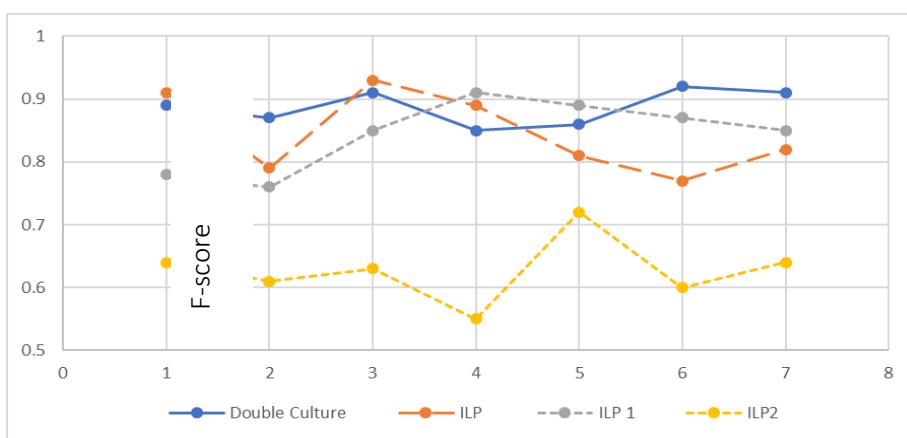
**Tableau 2. Valeurs annuelles des précisions globales de la cartographie des systèmes de culture obtenus à l'échelle de l'Etat du Mato Grosso, pour les différents niveaux.**

Campagne agricole	Précision globale		
	N1	N2	N3
2012/2013	0,87	0,91	0,72
2013/2014	0,86	0,72	0,70
2014/2015	0,89	0,91	0,73
2015/2016	0,87	0,89	0,74
2016/2017	0,89	0,85	0,92
2017/2018	0,90	0,77	0,8
2018/2019	0,96	0,82	0,79
Moyenne sur 7 ans	0,89	0,84	0,77
Ecart-type sur 7 ans	0,03	0,07	0,07

### 23 Evaluation des classes de systèmes intégrés

Les *F-score* des classes de culture calculés pour chaque année sont présentés en Figure 13. Les classes DC, iLP et iLP1, bien qu'appartenant à 3 niveaux de classification ont des précisions proches (respectivement 0.89, 0.85 et 0.84). La classe iLP2 est quant à elle moins bien classée (0.63).

La cartographie des zones iLP, représentée à partir du Niveau 02, a une précision d'utilisateur entre 0.8 et 0.94 (et donc une faible erreur de commission) et une précision du producteur entre 0.68 et 0.88 (et donc une erreur moyenne d'omission). Le nombre important de faux négatifs suggèrent que la zone implantée avec les iLP est sous-estimée (certaines zones iLP ont été classées comme Soja+Céréales), par contre le faible nombre de faux positifs (des zones Soja+Céréales classées en iLP) indique que l'on peut avoir confiance lorsqu'un pixel est classé iLP. Ce bon résultat est en partie dû à la stratégie d'équilibrage des échantillons présentée précédemment (choix d'une distribution proche de celle trouvée dans la réalité).

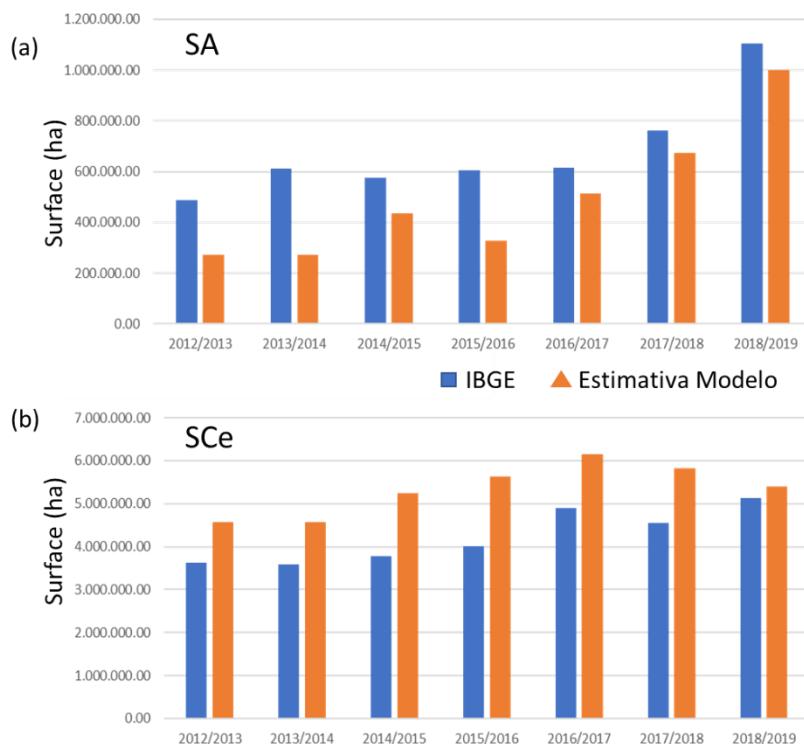


**Figure 13. Evolution annuelle (de 2012/13 à 2018/19) des *F-score* des classes de systèmes de culture du Niveau 01 (trait plein), Niveau 02 (grands pointillés) et Niveau 03 (petits pointillés), calculés à l'échelle du Mato Grosso.**

24 Etape 3 : Analyse thématique de l'implémentation des systèmes intégrés au Mato Grosso

#### 25 Comparaison avec les données statistiques officielles

Les résultats des classifications annuelles de Niveau 02 ont été comparés aux statistiques officielles de récolte de l'IBGE (SISTEMA IBGE DE RECUPERAÇÃO AUTOMÁTICA - SIDRA, 2019) qui proviennent d'enquêtes faites au niveau des municipios. L'évaluation s'est portée sur les cultures du deuxième cycle, avec la superficie plantée en coton, pour représenter la classe Soja+Coton, et la superficie en maïs, tournesol et/ou sorgho pour représenter la classe Soja+Céréales (Figure 14).



**Figure 14. Comparaisons entre les surfaces cultivées annuelles du Mato Grosso données par l'IBGE-PAM et celles obtenues par classification Random Forest, pour (a) le coton (classe SA), et (b) les céréales (classe SCe).**

Au niveau de l'Etat, la corrélation entre les surfaces annuelles en coton obtenues par l'IBGE-PAM et celles obtenues par classification des images est de 94%. Pour la classe SCe, la corrélation est de 74%, avec une surestimation des surfaces pour la classification. Cette surestimation est sans doute due à la prise en compte du mil dans la classification, alors que les données sur le mil ne sont pas disponibles dans les statistiques de l'IBGE. De plus, les surfaces fournies par l'IBGE-PAM sont calculées à partir d'entretiens et ne peuvent donc pas être considérées comme des références absolues.

Concernant les systèmes intégrés, l'IBGE n'effectue pas leur cartographie, mais on peut trouver d'autres valeurs de référence :

- à partir de contacts avec les grands producteurs et coopératives, la "Rede iLPF<sup>5</sup>" a estimé la superficie en systèmes iLPF pour la campagne 2015/2016 à 1.501 Mha pour le Mato

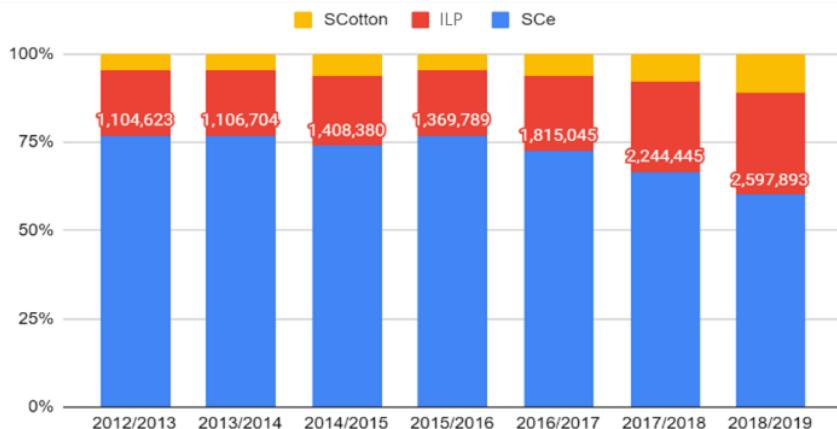
<sup>5</sup> Le réseau iLPF (Rede iLPF) est composé de l'Embrapa et des sociétés Cocomar, Dow Agroscience, John Deere, Parker et Syngenta, qui à travers les Unités de Transfert de Technologie diffusent la technologie iLPF.

Grosso ; de même cette étude a estimé qu'au Brésil 83% des systèmes iLPF étaient implantées en iLP (sans la composante forestière) ; si l'on applique ce taux au Mato Grosso, on atteint une valeur de 1.25 Mha de iLP implantés pour l'année agricole 2015/2016 ; ces valeurs sont à rapprocher de l'estimation faite dans cette étude, soit 1.37 Mha (Figure 15).

- à partir de leur enquête de la campagne 2012/2013, GIL; SIEBOLD; BERGER (2015) trouvent que 89% des systèmes intégrés au Mato Grosso étaient de l'iLP, soit 1.35 Mha (1.10 Mha estimés dans cette thèse ; Figure 15).

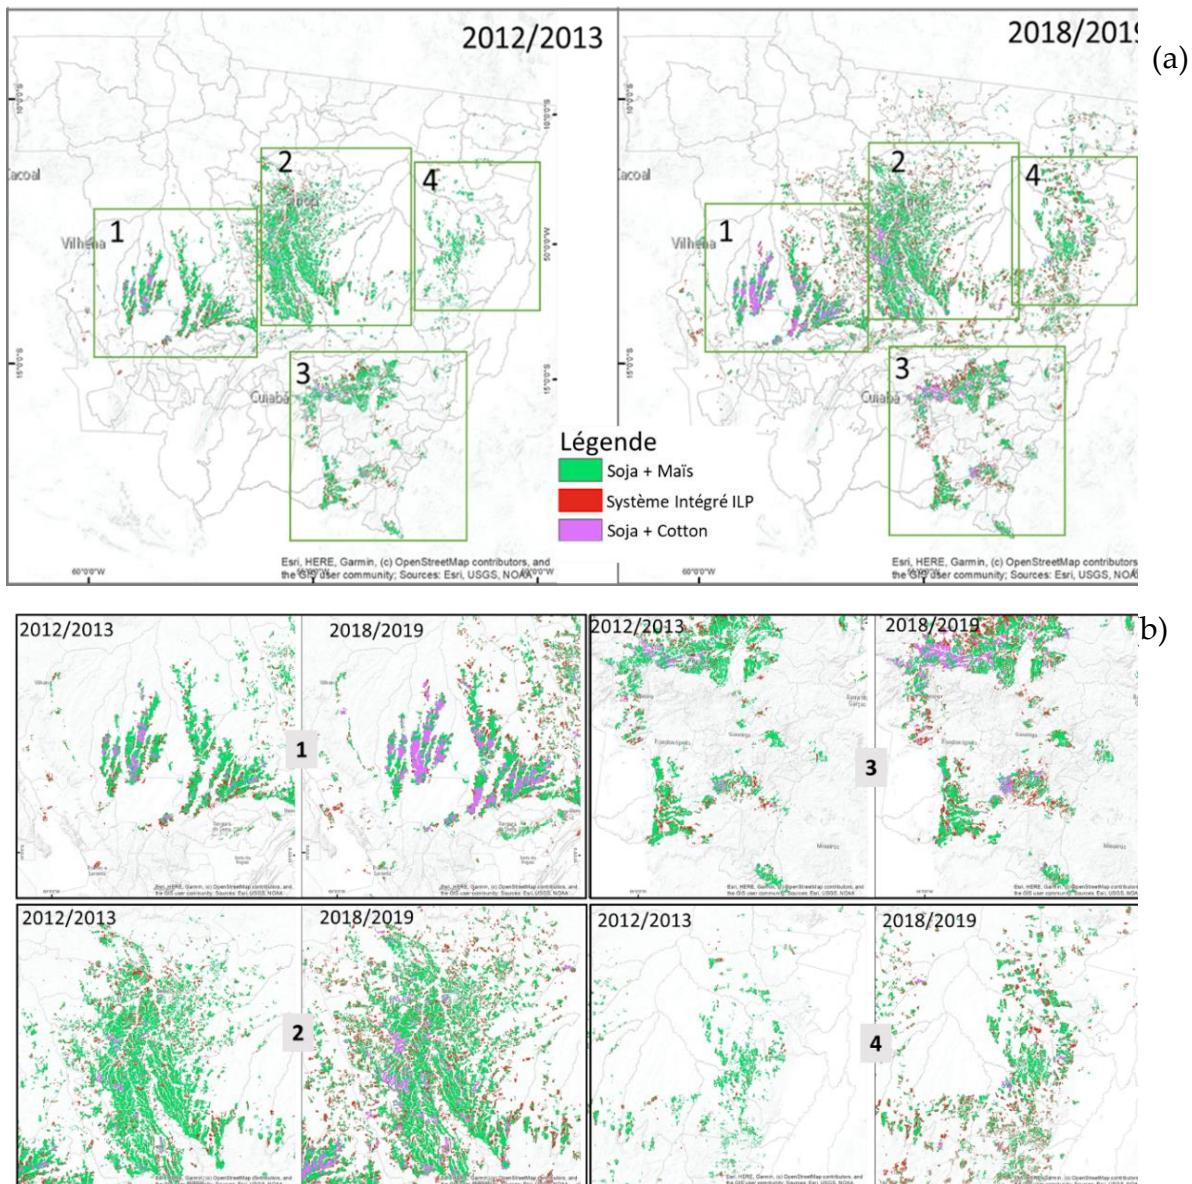
## 26 Analyse temporelle

L'analyse des résultats du Niveau 01 montre une augmentation de 66% des cultures séquentielles (Figure 15), et une diminution de 19% de la culture simple du soja (non montré). Ces résultats indiquent une intensification de la production agricole dans l'Etat qui avait déjà été souligné par d'autres auteurs (ARVOR et al., 2012 ; KASTENS et al., 2017 ; PICOLI et al., 2018 ; SPERA et al., 2014). La deuxième culture est majoritairement du maïs, qui a remplacé le mil, et du coton.



**Figure 15. Evolution annuelle de la répartition des classes de cultures séquentielles obtenues par la méthode Random Forest, et des valeurs des surfaces cultivées de la classe iLP (en ha).**

On observe sur la Figure 15 que parmi les options de culture séquentielle, les SIs gagnent en importance, passant de 18.6% à 28.9% (de ~ 1.1 Mha pour la campagne 2012/2013 à ~ 2.6 Mha pour celle de 2018/2019), ainsi que le système Soja+Coton mais dans une moindre mesure (4,6% à 11,1%). Cette augmentation se fait en grande partie au détriment du système SCe qui perd de l'importance, passant de 76.9% à 60%.



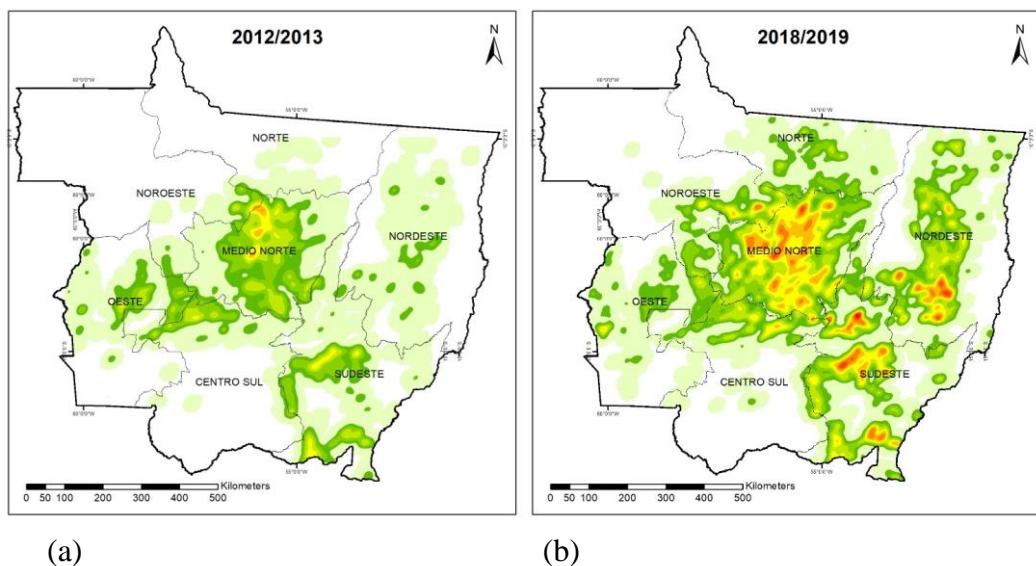
**Figure 16.** Cartes d'évolution des systèmes de culture de Niveau 2 entre les campagnes agricoles 2012/2013 et 2018/2019, pour (a) l'ensemble du Mato Grosso ; (b) les quatre principales zones de culture de l'Etat (zoom).

Sur les Figure 16a et b, le système Soja+Coton semble avoir une augmentation plus significative que les SI, en particulier dans les zones 1, 2 et 3. Cela peut être un artefact visuel dû au fait que le système Soja+Coton est cultivé sur de grandes parcelles, ce qui n'est pas le cas des SI. En effet, la surface moyenne d'un patch iLP est de 65 ha, tandis que celle d'un système Soja+Coton est de 700 ha, et celle d'un système Soja+Céréales est de 600 ha. Ces résultats suggèrent que les producteurs qui mettent en œuvre les SI ont des propriétés plus petites, ou que seules certaines zones de leur exploitation sont destinées à l'intégration.

## 27 Analyse spatiale

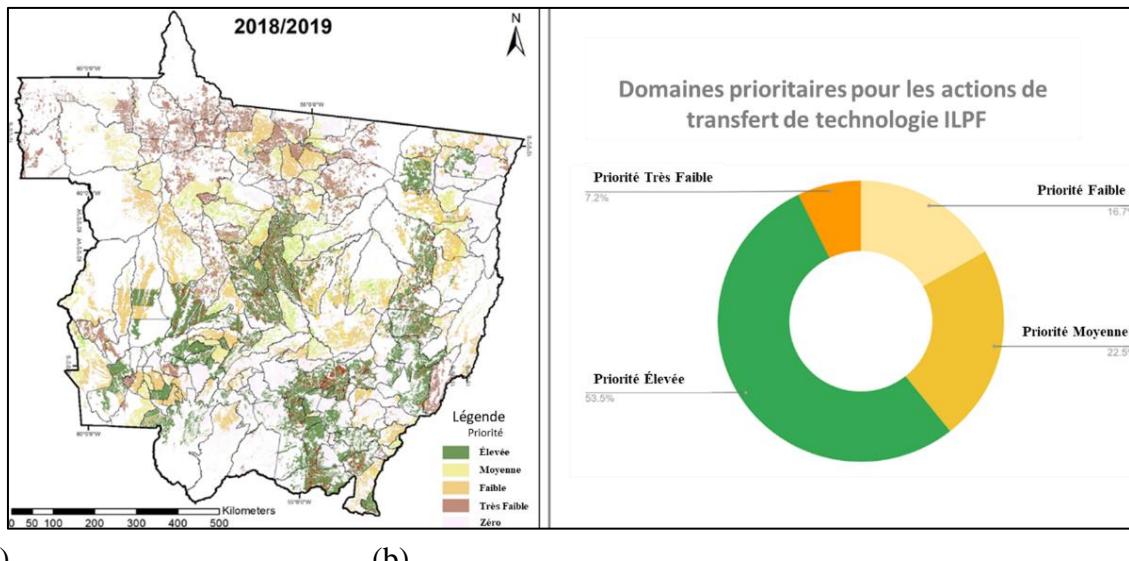
On a montré précédemment que les SI au Mato Grosso remplaçaient progressivement l'espace des systèmes conventionnels. Pour mieux visualiser cette évolution, deux cartes représentant l'indice de densité *Kernel* ont été calculées pour la classe iLP (Figure 17). On peut identifier, dans la première

campagne agricole de la série analysée 2012/2013 (Figure 17a), une concentration des zones iLP entre les municipios de Sinop et Sorriso (région du Moyen-Nord), mais avec des zones dispersées dans l'axe nord-sud de la région. Il existe aussi des concentrations, plus limitées, dans les régions Ouest, Sud-Est et Centre-Sud. Des zones peu significatives se trouvent dans les régions du Nord-Est et du Nord-Ouest. Pour la campagne 2018/2019 (Figure 17b), on constate la consolidation des iLP dans la région du Moyen-Nord, qui reste la région la plus importante, mais avec un schéma plus dispersé. Une forte augmentation est perçue dans les régions du Sud-Est et du Nord-Ouest, une augmentation dans la région du Nord-Ouest et un début dans la région Nord. Dans les régions Centre-Sud et en particulier dans l'Ouest, le gain en surfaces n'est pas significatif au point d'être perçu sur la carte. Au total, pour la campagne 2018/2019, 117 des 141 municipios avaient des surfaces implantées en iLP, contre 98 municipios en 2012/2013.



**Figure 17. Cartes de densité (indices de Kernel) des surfaces implantées en iLP au cours des campagnes agricoles 2012/2013 (a) et 2018/2019 (b). La densité augmente du vert au rouge.**

En 2018, l'Embrapa et ses partenaires ont mené une étude utilisant des critères spatiaux pour identifier les zones plus favorables à la mise en œuvre des SI (PEREIRA; MANZATTO; SKORUPA, 2018). Ce travail a abouti à un zonage en 5 classes (priorité nulle, très faible, faible, moyenne et élevée ; Figure 18a). Le croisement entre ces zones de priorité et la classification des iLP montre en que plus de la moitié des zones iLP implémentées en 2018/2019 sont dans les zones à priorité élevée (53.5%), que les % des zones iLP sont dans des zones à priorité élevée et moyenne (76%), et que l'on ne trouve pas d'iLP dans les zones à priorité nulle (Figure 18b).



**Figure 18. Adéquation entre localisations prioritaires et implantations réelles des iLP au Mato Grosso : (a) Carte des zones prioritaires de l'Embrapa (2018) ; (b) Distribution par zone prioritaire, des surfaces en iLP estimées par télédétection.**

**Conclusion partielle.** Les résultats de ces travaux indiquent une trajectoire d'intensification durable de l'agriculture et de l'élevage dans l'Etat du Mato Grosso. L'évaluation des résultats obtenus en termes de surfaces cultivées des différents systèmes montre une bonne cohérence avec les données officielles ou publiées disponibles, mais l'obtention de jeux de données fiables pour une validation plus complète des cartes de systèmes intégrés reste un vrai défi.

## 28 CONCLUSION

### 29 Principales contributions

Pour répondre aux besoins de politique publique liée à l'Agriculture à Basse Émission de Carbone (Plan ABC) de l'Etat brésilien, notamment le suivi quantifié des systèmes intégrés agriculture-élevage (iLP), nous avons développé une méthode permettant de produire des cartes annuelles des systèmes agricoles à l'échelle du pays. Pour cela nous avons relevé trois défis majeurs qui sont de nature différente :

1. *Cartographier des systèmes agricoles complexes* : Les systèmes intégrés de production agricole couvrent différentes stratégies productives avec des arrangements spatio-temporels variés d'activités agricoles, pastorales et forestières (cultures séquentielles, associées, rotation, etc.). Ce sont des systèmes complexes, difficiles à cartographier par télédétection. Dans cette thèse, la compréhension du fonctionnement des systèmes intégrés nous a donné les clés permettant de passer de l'occupation des sols, telle qu'observée par satellite, à l'utilisation des terres, qui est le marqueur de l'activité socio-économique recherché.
2. *Classer des systèmes agricoles à l'échelle régionale, et de façon rétrospective* : Dans cette thèse nous avons développé une chaîne de traitement d'images basée sur le prétraitement et la classification de séries temporelles denses d'images MODIS qui ont une résolution spatiale de 250 m, compatible avec la taille des objets à cartographier, et qui sont disponibles depuis 2000. Les développements ont été faits à l'échelle de l'Etat du Mato

Grosso et pour sept campagnes agricoles (2012-2019), ce qui nous a permis d'évaluer la robustesse des méthodes dans différents contextes climatiques.

Les résultats montrent que les pré-traitements de type lissage du signal temporel ou calcul d'indices phénométriques détériorent la précision des classifications des systèmes de culture, et que l'utilisation de séries temporelles d'indices de végétation permettent d'obtenir de bons scores de classification avec l'algorithme Random Forest. Cette stratégie de classification a ensuite été appliquée aux sept campagnes agricoles et aux six régions climatiques de l'Etat, selon une approche hiérarchique en 4 niveaux (le premier niveau est la classe Soja produite par le projet Mapbiomass). Les résultats montrent que l'utilisation d'une base de données d'apprentissage unique (c'est-à-dire regroupant des échantillons de différentes années et régions) utilisée pour classer chaque région et années individuellement permet d'obtenir des précisions de classification proches de celles obtenues pour des classifications faites avec une base de données d'apprentissage dédiée (c'est-à-dire acquise dans chaque région et pour chaque année). Le nombre élevé d'échantillons dus au regroupement compense en grande partie la variabilité spatio-temporelle des classes.

La précision globale (OA) de la carte des systèmes de culture varie entre 0.89 au niveau 2 (simples cultures et cultures séquentielles) et 0.77 au niveau 4 (5 classes : soja, soja-coton, soja-céréales, soja-*Brachiaria*, soja-*Brachiaria* en association avec du maïs) sur la période étudiée. Les F-score des classes double culture est de 0.89, et les F-score des iLP est de 0.85 (0.84 pour la classe soja-*Brachiaria*, et 0.63 pour la classe soja-*Brachiaria* en association avec du maïs).

3. *Traiter un grand volume de données* : Sur la période étudiée, un total de 3864 images ont été traitées. Les traitements d'image ont été facilités par l'utilisation de la plateforme Google Earth Engine (GEE) qui offre un accès facile aux images et qui permet de créer des chaines de traitement facilement réutilisables sur d'autres jeux de données (régions ou années). La solution proposée dans cette thèse s'appuie sur les technologies du *Big Data* - le *Cloud computing* et l'utilisation d'algorithmes d'apprentissage automatique - appliquées aux données d'observation de la Terre. Cette approche s'est avérée avoir un grand potentiel pour répondre aux défis précédemment posés dans le domaine de la télédétection, et permet le développement de méthodes à visée opérationnelle. Cependant, l'expertise locale reste fondamentale pour guider le traitement des données aboutissant à des services applicatifs.

Ces trois principaux défis relevés, des cartes annuelles des systèmes agricoles ont pu être produites à l'échelle Mato Grosso. Leur analyse a permis de quantifier les dynamiques spatiales de l'adoption des systèmes intégrés agriculture-élevage, dont les superficies sont cohérentes avec les résultats obtenus à partir d'entretiens qui montrent une adoption régulière mais hétérogène au niveau de l'Etat. En conclusion, les résultats de ces travaux constituent une contribution importante à l'élaboration d'un protocole de suivi des émissions de carbone pour le secteur agricole, à destination des organisations nationales et internationales.

### 30 Perspectives du travail

Cette thèse a un apport à la fois scientifique et applicatif pour une meilleure gestion publique dans le sens du développement durable.

#### *Perspectives méthodologiques*

La très forte dynamique de l'offre en observation de la Terre et des outils issus des sciences de données ouvre de nombreuses perspectives de recherche méthodologique. Ainsi, on peut envisager d'améliorer la chaîne de traitement des images en incluant d'autres sources de données qui ont une meilleure résolution spatiale (e.g. Landsat, CBERS, Sentinel-2) ou qui sont moins sensibles à la couverture nuageuse comme les images radar (e.g. Sentinel-1). Les données des satellites européens Sentinel du programme COPERNICUS sont extrêmement prometteuses en termes de cartographie des pratiques agricoles par leur haute résolution spatiale et temporelle et par leur richesse spectrale. Le premier satellite Sentinel-2 a été lancé en 2015, mais la fréquence de revisite de 5 jours n'a été atteinte qu'en mars 2018 pour le Brésil, ce qui limite l'utilisation de ces satellites pour des analyses rétrospectives. Ainsi, l'avantage de MODIS reste la cohérence de l'ensemble de données dans le temps depuis 2000, avec une fréquence temporelle élevée.

Il existe différentes voies de fusion de données multi-capteurs qui pourront être testées. Les nouveaux algorithmes d'apprentissage automatique permettent de traiter des données hétérogènes, multi-sources. Les algorithmes de type CNN (*Convolutional Neural Networks*) permettent de s'affranchir du choix et du calcul des descripteurs, et les algorithmes de type LSTM (*Long Short Term Memory*) permettent une meilleure prise en compte de l'information temporelle. Ainsi, ces nouveaux outils ouvrent des perspectives très intéressantes en matière de classification des images qui pourront être utiles à l'avenir pour la cartographie les iLPF. Toutefois, la puissance d'extraction de ces nouveaux outils est conditionnée par l'apprentissage des modèles des sous-jacents qui nécessite un grand nombre de données de qualité. A ce jour, les jeux de données localisés disponibles sur les systèmes agricoles ne sont pas encore suffisants pour tirer parti de cette puissance de calcul.

Enfin, l'utilisation de *Google Earth Engine* a permis le développement de la méthodologie, avec tous les aspects positifs déjà mentionnés ; cette utilisation pose toutefois le problème d'une solution proposée par un acteur privé qui peut modifier sa politique d'accès aux données et à la plateforme, et qui stocke les données et produits. Ce type de risque est moindre dans les structures collaboratives telle que l'*Orfeo ToolBox* (OTB) en France, ou dans les structures nationales telle que la structure en cours de développement du Cube de Données Brésilien qui sera l'option privilégiée pour la poursuite de ce travail.

#### *Perspectives opérationnelles*

La chaîne de traitement développée dans cette thèse peut être appliquée à d'autres années et à d'autres Etats qui présentent les mêmes biomes (principalement l'Amazonie, le Cerrado et le Pantanal) ou pour la nouvelle frontière agricole du Matopiba et ses systèmes de culture proches (parcellaire agricole de grande taille). Au-delà de l'intérêt pour le suivi des engagements internationaux en termes d'émission de GES, le suivi et la compréhension des

mécanismes d'adoption de ces pratiques au niveau national sont d'une grande importance pour de nombreux acteurs (e.g. entreprises publiques et privées, ONG) qui sont impliqués dans des programmes pour une agriculture à basse émission de carbone au Brésil. Le partenariat avec le réseau iLPF (*Rede iLPF*) peut aider à acquérir les données nécessaires pour entraîner les classificateurs et tester / appliquer la méthodologie dans d'autres Etats du corridor soja.

Enfin, des analyses spatiales plus complexes menées via des outils de type *Business Intelligence* ou via la modélisation spatiale, permettront d'étudier à différentes échelles les déterminants environnementaux (e.g. climat, type de sol) et socio-économiques (e.g. présence d'infrastructures locales et régionales, expérience des producteurs, technologies disponibles) de la mise en œuvre et de la dynamique des systèmes intégrés. Ces analyses pourront être menées au sein d'une plateforme web, telle que la plateforme brésilienne Pronasolos, et seront cruciales pour le programme de développement de l'agriculture durable au Brésil.

### 31 Références bibliographiques

- ALBUQUERQUE, Igor; ALENCAR, Ane; ANGELO, Claudio; AZEVEDO, Tasso; BARCELLOS, Felipe. Analise das emissões Braileiras de gases de efeito estufa e suas implicações para as metas de clima do Brasil 1970-2019. SEEG. [S. l.], SEEG, p. 41, 2020.
- ARVOR, Damien; JONATHAN, Milton; MEIRELLES, M. S. P.; DUBREUIL, Vincent; LECERF, R. Comparison of Multitemporal MODIS-EVI Smoothing Algorithms and its Contribution to Crop Monitoring. In: 2008, *Anais* [...] . In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS'08). [s.l: s.n.] p. II-958. ISBN: 2153-7003. DOI: 10.1109/IGARSS.2008.4779155.
- ARVOR, Damien; JONATHAN, Milton; MEIRELLES, Margareth Simões Penello; DUBREUIL, Vincent; DURIEUX, Laurent. Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil. *International Journal of Remote Sensing*, [S. l.], v. 32, n. 22, p. 7847–7871, 2011. ISSN: 0143-1161. DOI: 10.1080/01431161.2010.531783.
- ARVOR, Damien; TRITSCH, Isabelle; BARCELLOS, Christovam; JÉGOU, Nicolas; DUBREUIL, Vincent. Land use sustainability on the South-Eastern Amazon agricultural frontier: Recent progress and the challenges ahead. *Applied Geography*, [S. l.], v. 80, p. 86–97, 2017. DOI: 10.1016/j.apgeog.2017.02.003.
- BEGUE, A.; LEROUX, Louise; SOUMARÉ, Mamy; FAURE, Jean-François; DIOUF, Abdoul Aziz; AUGUSSEAU, Xavier; TONNEAU, Jean-Philippe. Remote sensing products and services in support of agricultural public policies in Africa : Overview and challenges. *Frontiers in Sustainable Food Systems*, [S. l.], p. 58, 2020.
- BÉGUÉ, Agnès; ARVOR, Damien; BELLON, Beatriz; BETBEDER, Julie; De ABELLEYRA, Diego; FERRAZ, Rodrigo P.D.; LEBOURGEOIS, Valentine; LELONG Camile; SIMÕES, Margareth; VERÓN, Santiago R. . Remote Sensing and Cropping Practices: A Review. *Remote Sensing*, [S. l.], v. 10, n. 1, p. 99, 2018. DOI: 10.3390/rs10010099.
- BELGIU, Mariana; DRĂGUȚ, Lucian. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, [S. l.], v. 114, p. 24–31, 2016. DOI: 10.1016/j.isprsjprs.2016.01.011.
- BELLÓN, Beatriz; BÉGUÉ, Agnès; SEEN, Danny Lo; ALMEIDA, Claudio Aparecido De; SIMÕES, Margareth. A Remote Sensing Approach for Regional-Scale Mapping of Agricultural Land-Use Systems Based on NDVI Time Series. *Remote Sensing*, [S. l.], v. 9, p. 600, 2017. DOI: 10.3390/rs9060600.
- BREIMAN, Leo. *Machine Learning*, [S. l.], v. 45, n. 1, p. 5–32, 2001. DOI: 10.1023/a:1010933404324.
- BROWN, J. Christopher; KASTENS, Jude H.; COUTINHO, Alexandre Camargo; VICTORIA, Daniel de Castro; BISHOP, Christopher R. Classifying multiyear agricultural land use data from Mato Grosso using time-series MODIS vegetation index data. *Remote Sensing of Environment*, [S. l.], v. 130, p. 39–50, 2013. ISSN: 0034-4257. DOI: 10.1016/j.rse.2012.11.009.
- BULLOCK, Eric L.; WOODCOCK, Curtis E.; SOUZA, Carlos; OLOFSSON, Pontus. Satellite-based estimates reveal widespread forest degradation in the Amazon. *Global Change Biology*, [S. l.], v. 26, n. 5, p. 2956–2969, 2020. DOI: 10.1111/gcb.15029.

BUSTAMANTE, Mercedes M. C. et al. Estimating greenhouse gas emissions from cattle raising in Brazil. **Climatic Change**, [S. I.], v. 115, n. 3–4, p. 559–577, 2012. DOI: 10.1007/s10584-012-0443-3.

CAMARA, Gilberto; ASSIS, Luiz Fernando; RIBEIRO, Gilberto; FERREIRA, Karine Reis; LLAPA, Eduardo; VINHAS, Lubia. Big earth observation data analytics. In: PROCEEDINGS OF THE 5TH ACM SIGSPATIAL INTERNATIONAL WORKSHOP ON ANALYTICS FOR BIG GEOSPATIAL DATA - BIGSPATIAL \TEXTQUOTESINGLE16 2016, **Anais** [...]. : ACM Press, 2016 DOI: 10.1145/3006386.3006393. Disponível em: <https://doi.org/10.1145/3006386.3006393>.

CAO, Ruyin; CHEN, Yang; SHEN, Miaogen; CHEN, Jin; ZHOU, Ji; WANG, Cong; YANG, Wei. A simple method to improve the quality of NDVI time-series data by integrating spatiotemporal information with the Savitzky-Golay filter. **Remote Sensing of Environment**, [S. I.], v. 217, p. 244–257, 2018. DOI: 10.1016/j.rse.2018.08.022.

CHEN, Jin; JÖNSSON, Per; TAMURA, Masayuki; GU, Zhihui; MATSUSHITA, Bunkei; EKLUNDH, Lars. A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky-Golay filter. **Remote Sensing of Environment**, [S. I.], v. 91, p. 332–344, 2004. DOI: 10.1016/j.rse.2004.03.014.

CHEN, Yaoliang et al. **Mapping croplands, cropping patterns, and crop types using MODIS time-series data**. [s.l: s.n.]. v. 69 DOI: 10.1016/j.jag.2018.03.005.

COLDITZ, René. An Evaluation of Different Training Sample Allocation Schemes for Discrete and Continuous Land Cover Classification Using Decision Tree-Based Algorithms. **Remote Sensing**, [S. I.], v. 7, n. 8, p. 9655–9681, 2015. DOI: 10.3390/rs70809655.

**Conab - Monitoramento Agrícola**. 2020. Disponível em: <http://www.conab.gov.br/info-agro/safras/monitoramento-agricola?start=60>. Acesso em: 11 dez. 2020.

CUTLER, David; C EDWARDS, Thomas; BEARD, Karen; CUTLER, Adele; T HESS, Kyle; GIBSON, Jacob; LAWLER, Joshua. Random Forests for Classification in Ecology. **Ecology**, [S. I.], v. 88, p. 2783–92, 2007. DOI: 10.1890/07-0539.1.

DALPONTE, Michele; ORKA, Hans Ole; GOBAKKEN, Terje; GIANELLE, Damiano; NAESSET, Erik. Tree Species Classification in Boreal Forests With Hyperspectral Data. **IEEE Transactions on Geoscience and Remote Sensing**, [S. I.], v. 51, n. 5, p. 2632–2645, 2013. DOI: 10.1109/tgrs.2012.2216272.

DELINCE, Jacques; LEMOINE, Guido; DEFOURNY, Pierre; GALLEGOS, Javier; DAVIDSON, Andrew; SHIBENDU RAY; ROJAS, Oscar; LATHAM, John; ACHARD, Frederic. Handbook on remote sensing for agricultural statistics. [S. I.], 2017. DOI: 10.13140/RG.2.2.13259.69920. Disponível em: <http://rgdoi.net/10.13140/RG.2.2.13259.69920>.

**DIMA, S. 5 Reasons Why You Should Use Cross-Validation in Your Data Science Projects. KDnuggets 2018**. Disponível em: <https://www.kdnuggets.com/5-reasons-why-you-should-use-cross-validation-in-your-data-science-projects.html/>. Acesso em: 5 dez. 2020.

DUDA, Richard O.; HART, Peter E.; STORK, David G. **Pattern Classification (2nd Edition)**. USA: Wiley-Interscience, 2000. ISBN: 0-471-05669-3.

EKLUNDH, L.; JÖNSSON, P. **TIMESAT 3.3 with seasonal trend decomposition and parallel processing**. Software Manual. Lund University, 2017.

EMBRAPA. **ICLF in numbers**. Embrapa, 2017. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1073425/iclf-in-numbers>. Acesso em: 22 maio. 2019.

FAO. **The future of food and agriculture - Trends and challenges**. Rome (Italy). Disponível em: <http://www.fao.org/3/i6583e/i6583e.pdf>.

GALFORD, Gillian L.; MUSTARD, John F.; MELILLO, Jerry; GENDRIN, Aline; CERRI, Carlos C.; CERRI, Carlos E. P. Wavelet analysis of MODIS time series to detect expansion and intensification of row-crop agriculture in Brazil. **Remote Sensing of Environment**, Soil Moisture Experiments 2004 (SMEX04) Special Issue. [S. I.], v. 112, n. 2, Soil Moisture Experiments 2004 (SMEX04) Special Issue, p. 576–587, 2008. ISSN: 0034-4257. DOI: 10.1016/j.rse.2007.05.017.

GIL, Juliana; SIEBOLD, Matthias; BERGER, Thomas. Adoption and development of integrated crop–livestock–forestry systems in Mato Grosso, Brazil. **Agriculture, Ecosystems & Environment**, [S. I.], v. 199, p. 394–406, 2015. DOI: 10.1016/j.agee.2014.10.008.

GÓMEZ, Cristina; WHITE, Joanne C.; WULDER, Michael A. Optical remotely sensed time series data for land cover classification: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. I.], v. 116, p. 55–72, 2016. ISSN: 0924-2716. DOI: 10.1016/j.isprsjprs.2016.03.008.

GORELICK, Noel; HANCHER, Matt; DIXON, Mike; ILYUSHCHENKO, Simon; THAU, David; MOORE, Rebecca. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, [S. I.], v. 202, p. 18–27, 2017. DOI: 10.1016/j.rse.2017.06.031.

GURGEL, A. C.; COSTA, C. F.; SERIGATI, F. C. **Agricultura de Baixa Emissão de Carbono: Quem cumpre as decisões?Uma análise da governança do Plano ABC no âmbito do Observatório ABC**: Collection RP / FGVAgro - Sumário Executivo. [s.l.] : FGV, 2017. Disponível em: <http://hdl.handle.net/10438/24900>.

HRID, J. N.; MCDERMID, Greg. Noise reduction of NDVI time series: an empirical comparison of selected techniques. **Remote Sens. Environ.**, [S. I.], v. 113, p. 248–258, 2008.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, [S. I.], v. 83, n. 1, p. 195–213, 2002. ISSN: 0034-4257. DOI: [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2).

IBGE. **Climatologia**. IBGE, 2011. Disponível em: <https://www.ibge.gov.br/geociencias/informacoes-ambientais/climatologia.html>. Acesso em: 2 abr. 2020.

IBGE. **Municipal Agricultural Production**. IBGE, 2019. Disponível em: <http://www2.sidra.ibge.gov.br/>. Acesso em: 10 out. 2020.

INMET. **Dados das estações meteorológicas**. 2019. Disponível em: <https://portal.inmet.gov.br/>. Acesso em: 25 jul. 2020.

JAMES, Gareth; WITTEN, Daniela; HASTIE, Trevor; TIBSHIRANI, Robert. Statistical Learning. In: **Springer Texts in Statistics**. [s.l.] : Springer New York, 2013. p. 15–57. DOI: 10.1007/978-1-4614-7138-7\_2. Disponível em: [https://doi.org/10.1007/978-1-4614-7138-7\\_2](https://doi.org/10.1007/978-1-4614-7138-7_2).

JIN, Huiran; STEHMAN, Stephen V.; MOUNTRAKIS, Giorgos. Assessing the impact of training sample selection on accuracy of an urban classification: a case study in Denver, Colorado. **International**

**Journal of Remote Sensing**, [S. I.], v. 35, n. 6, p. 2067–2081, 2014. DOI: 10.1080/01431161.2014.885152.

JUDITSKY, Anatoli; HJALMARSSON, Håakan; BENVENISTE, Albert; DELYON, Bernard; LJUNG, Lennart; SJÖBERG, Jonas; ZHANG, Qinghua. Nonlinear black-box models in system identification: Mathematical foundations. **Automatica**, [S. I.], v. 31, n. 12, p. 1725–1750, 1995. DOI: 10.1016/0005-1098(95)00119-1.

CASTENS, Jude H.; BROWN, J. Christopher; COUTINHO, Alexandre Camargo; BISHOP, Christopher R.; ESQUERDO, Júlio César D. M. Soy moratorium impacts on soybean and deforestation dynamics in Mato Grosso, Brazil. **PLOS ONE**, [S. I.], v. 12, n. 4, p. e0176168, 2017. ISSN: 1932-6203. DOI: 10.1371/journal.pone.0176168.

KLUTHCOUSKI, J.; YOKOYAMA, L. P.; STONE, Luiz Fernando. Fazendas de referência na integração lavoura-pecuária. In: **Integração lavoura-pecuária**. J. Kluthcouski, L. F. Stone, H. Aidar ed. Santo Antônio de Goiás: Embrapa Arroz e feijão. p. 535–554.

KUCHLER, Patrick Calvano; BÉGUÉ, Agnès; SIMÕES, Margareth; GAETANO, Raffaele; ARVOR, Damien; FERRAZ, Rodrigo P. D. Assessing the optimal preprocessing steps of MODIS time series to map cropping systems in Mato Grosso, Brazil. **International Journal of Applied Earth Observation and Geoinformation**, [S. I.], v. 92, p. 102150, 2020. DOI: 10.1016/j.jag.2020.102150.

KUHN, Max; JED, Weston; STEW, Williwm; KEEFER, Andre; ENGELHARDT, Chris. caret: Classificação e treinamento de regressão. Pacote R versão 6.0–21. [S. I.], 2015.

LEBOURGEOIS, Valentine; DUPUY, Stéphane; VINTROU, Élodie; AMELINE, Maël; BUTLER, Suzanne; BÉGUÉ, Agnès. A Combined Random Forest and OBIA Classification Scheme for Mapping Smallholder Agriculture at Different Nomenclature Levels Using Multisource Data (Simulated Sentinel-2 Time Series, VHRS and DEM). **Remote Sensing**, [S. I.], v. 9, n. 3, p. 259, 2017. DOI: 10.3390/rs9030259.

LEENHARDT, Delphine; ANGEVIN, Frédérique; BIARNÈS, Anne; COLBACH, Nathalie; MIGNOLET, Catherine. Describing and locating cropping systems on a regional scale. A review. **Agronomy for Sustainable Development**, [S. I.], v. 30, n. 1, p. 131–138, 2010. DOI: 10.1051/agro/2009002.

LI, Le; FRIEDL, Mark; XIN, Qinchuan; GRAY, Josh; PAN, Yaohong; FROLKING, Steve. Mapping Crop Cycles in China Using MODIS-EVI Time Series. **Remote Sensing**, [S. I.], v. 6, n. 3, p. 2473–2493, 2014. DOI: 10.3390/rs6032473.

LI, Songnian et al. Geospatial big data handling theory and methods: A review and research challenges. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. I.], v. 115, p. 119–133, 2016. DOI: 10.1016/j.isprsjprs.2015.10.012.

LIU, Desheng; CAI, Shanshan. A Spatial-Temporal Modeling Approach to Reconstructing Land-Cover Change Trajectories from Multi-temporal Satellite Imagery. **Annals of the Association of American Geographers**, [S. I.], v. 102, n. 6, p. 1329–1347, 2012. DOI: 10.1080/00045608.2011.596357.

LOBELL, David B.; ASNER, Gregory P. Cropland distributions from temporal unmixing of MODIS data. **Remote Sensing of Environment**, [S. I.], v. 93, n. 3, p. 412–422, 2004. DOI: 10.1016/j.rse.2004.08.002.

MACEDO, M. C. M. Crop and livestock integration: the state of the art and the near future. **Revista Brasileira de Zootecnia**, [S. I.], v. 38, p. 133–146, 2009.

MANABE, Víctor Danilo; MELO, Marcio R. S.; ROCHA, Jansle Vieira. Framework for Mapping Integrated Crop-Livestock Systems in Mato Grosso, Brazil. **Remote Sensing**, [S. I.], v. 10, n. 9, p. 1322, 2018. DOI: 10.3390/rs10091322.

MELLOR, Andrew; BOUKIR, Samia; HAYWOOD, Andrew; JONES, Simon. Exploring issues of training data imbalance and mislabelling on random forest performance for large area land cover classification using the ensemble margin. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. I.], v. 105, p. 155–168, 2015. DOI: 10.1016/j.isprsjprs.2015.03.014.

MINGWEI, Zhang; QINGBO, Zhou; ZHONGXIN, Chen; JIA, Liu; YONG, Zhou; CHONGFA, Cai. Crop discrimination in Northern China with double cropping systems using Fourier analysis of time-series MODIS data. **International Journal of Applied Earth Observation and Geoinformation**, [S. I.], v. 10, n. 4, p. 476–485, 2008. DOI: 10.1016/j.jag.2007.11.002.

MYERS, Norman; MITTERMEIER, Russell A.; MITTERMEIER, Cristina G.; FONSECA, Gustavo A. B. Da; KENT, Jennifer. Biodiversity hotspots for conservation priorities. **Nature**, [S. I.], v. 403, n. 6772, p. 853–858, 2000. DOI: 10.1038/35002501.

NOI, Phan Thanh; KAPPAS, Martin. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors**, [S. I.], v. 18, n. 2, p. 18, 2017. DOI: 10.3390/s18010018.

OZDOGAN, Mutlu. The spatial distribution of crop types from MODIS data: Temporal unmixing using Independent Component Analysis. **Remote Sensing of Environment**, [S. I.], v. 114, n. 6, p. 1190–1204, 2010. DOI: 10.1016/j.rse.2010.01.006.

PAN, Zhuokun; HUANG, Jingfeng; ZHOU, Qingbo; WANG, Limin; CHENG, Yongxiang; ZHANG, Hankui; BLACKBURN, George Alan; YAN, Jing; LIU, Jianhong. Mapping crop phenology using NDVI time-series derived from HJ-1 A/B data. **International Journal of Applied Earth Observation and Geoinformation**, [S. I.], v. 34, p. 188–197, 2015. DOI: 10.1016/j.jag.2014.08.011.

PARENTE, Leandro; FERREIRA, Laerte; FARIA, Adriano; NOGUEIRA, Sérgio; ARAÚJO, Fernando; TEIXEIRA, Lana; HAGEN, Stephen. Monitoring the brazilian pasturelands: A new mapping approach based on the landsat 8 spectral and temporal domains. **International Journal of Applied Earth Observation and Geoinformation**, [S. I.], v. 62, p. 135–143, 2017. DOI: 10.1016/j.jag.2017.06.003.

PARENTE, Leandro; MESQUITA, Vinícius; MIZIARA, Fausto; BAUMANN, Luis; FERREIRA, Laerte. Assessing the pasturelands and livestock dynamics in Brazil, from 1985 to 2017: A novel approach based on high spatial resolution imagery and Google Earth Engine cloud computing. **Remote Sensing of Environment**, [S. I.], v. 232, p. 111301, 2019. DOI: 10.1016/j.rse.2019.111301.

PEREIRA, Sandro Eduardo Marschhausen; MANZATTO, Celso Vainer; SKORUPA, Ladislau Araújo. Análise multicritério para planejamento em sistemas de Integração Lavoura, Pecuária e Floresta. [S. I.], p. 45, 2018.

PICOLI, Michelle Cristina Araujo et al. Big earth observation time series analysis for monitoring Brazilian agriculture. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. I.], v. 145, p. 328–339, 2018. ISSN: 09242716. DOI: 10.1016/j.isprsjprs.2018.08.007.

QIU, Bingwen; ZHONG, Ming; TANG, Zhenghong; WANG, Chongyang. A new methodology to map double-cropping croplands based on continuous wavelet transform. **International Journal of Applied**

**Earth Observation and Geoinformation**, [S. I.], v. 26, p. 97–104, 2014. DOI: 10.1016/j.jag.2013.05.016.

RAJAO, R.; SOARES-FILHO, B. Policies undermine Brazil's GHG goals. **Science**, [S. I.], v. 350, n. 6260, p. 519–519, 2015. DOI: 10.1126/science.350.6260.519-a.

SALTON, Julio C.; MERCANTE, Fabio M.; TOMAZI, Michely; ZANATTA, Josileia A.; CONCENÇO, Germani; SILVA, Wiliam M.; RETORE, Marciana. Integrated crop-livestock system in tropical Brazil: Toward a sustainable production system. **Agriculture, Ecosystems & Environment**, [S. I.], v. 190, p. 70–79, 2014. DOI: 10.1016/j.agee.2013.09.023.

SANTOS, Mário Vital Dos. **Relatório técnico consolidado de clima para o estado de Mato Grosso VOL.1/2**. BIRD, 2000.

SAVITZKY, Abraham; GOLAY, M. J. E. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. **Analytical Chemistry**, [S. I.], v. 36, n. 8, p. 1627–1639, 1964. DOI: 10.1021/ac60214a047.

SHAO, Yang; LUNETTA, Ross S.; WHEELER, Brandon; IIAMES, John S.; CAMPBELL, James B. An evaluation of time-series smoothing algorithms for land-cover classifications using MODIS-NDVI multi-temporal data. **Remote Sensing of Environment**, [S. I.], v. 174, p. 258–265, 2016. ISSN: 0034-4257. DOI: 10.1016/j.rse.2015.12.023.

SIMÕES, Margareth; FREITAS, Pedro; FERRAZ, Rodrigo; ARVOR, Damien; DUBREUIL, Vincent. Avaliação da Dinâmica de uso da terra através de dados de Sensores Remotos para uma Agricultura Sustentável. In: [s.l.: s.n.]. p. 489–511. ISBN: 978-85-7035-356-6.

**Sistema IBGE de Recuperação Automática - SIDRA**. 2019. Disponível em: <https://sidra.ibge.gov.br/pesquisa/ppm/quadros>. Acesso em: 11 dez. 2020.

SOUZA, Carlos 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. I.], v. 12, n. 17, p. 2735, 2020. DOI: 10.3390/rs12172735.

SPERA, Stephanie A.; COHN, Avery S.; VANWEY, Leah K.; MUSTARD, Jack F.; RUDORFF, Bernardo F.; RISSO, Joel; ADAMI, Marcos. Recent cropping frequency, expansion, and abandonment in Mato Grosso, Brazil had selective land characteristics. **Environmental Research Letters**, [S. I.], v. 9, n. 6, p. 064010, 2014. ISSN: 1748-9326. DOI: 10.1088/1748-9326/9/6/064010.

TAMIMINIA, Haifa; SALEHI, Bahram; MAHDIANPARI, Masoud; QUACKENBUSH, Lindi; ADELI, Sarina; BRISCO, Brian. Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. I.], v. 164, p. 152–170, 2020. DOI: 10.1016/j.isprsjprs.2020.04.001.

VERBURG, Peter H.; STEEG, Jeannette Van de; VELDKAMP, A.; WILLEMEN, Louise. From land cover change to land function dynamics: A major challenge to improve land characterization. **Journal of Environmental Management**, [S. I.], v. 90, n. 3, p. 1327–1335, 2009. DOI: 10.1016/j.jenvman.2008.08.005.

VILELA, Lourival; MANJABOSCO, Eduardo A.; MARCHÃO, Robélio Leandro; GUIMARÃES JÚNIOR, Roberto. “Boi Safrinha” na Integração Lavoura-Pecuária no Oeste Baiano. **Embarapa**, Circular Técnica, 35. [S. I.], Circular Técnica, 35, p. 6, 2017.

WARDLOW, B.; EGBERT, S.; KASTENS, J. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains. **Remote Sensing of Environment**, [S. I.], v. 108, n. 3, p. 290–310, 2007. DOI: 10.1016/j.rse.2006.11.021.

XU, Xingmei; CONRAD, Christopher; DOKTOR, Daniel. Optimising Phenological Metrics Extraction for Different Crop Types in Germany Using the Moderate Resolution Imaging Spectrometer (MODIS). **Remote Sensing**, [S. I.], v. 9, n. 3, p. 254, 2017. DOI: 10.3390/rs9030254.

ZHU, Changming; LU, Dengsheng; VICTORIA, Daniel; DUTRA, Luciano Vieira. Mapping Fractional Cropland Distribution in Mato Grosso, Brazil Using Time Series MODIS Enhanced Vegetation Index and Landsat Thematic Mapper Data. **Remote Sensing**, [S. I.], v. 8, n. 1, p. 22, 2016. DOI: 10.3390/rs8010022.

**APÊNDICE B – LISTA DOS MUNICÍPIOS E ÁREA IMPLANTADA EM HECTARES**

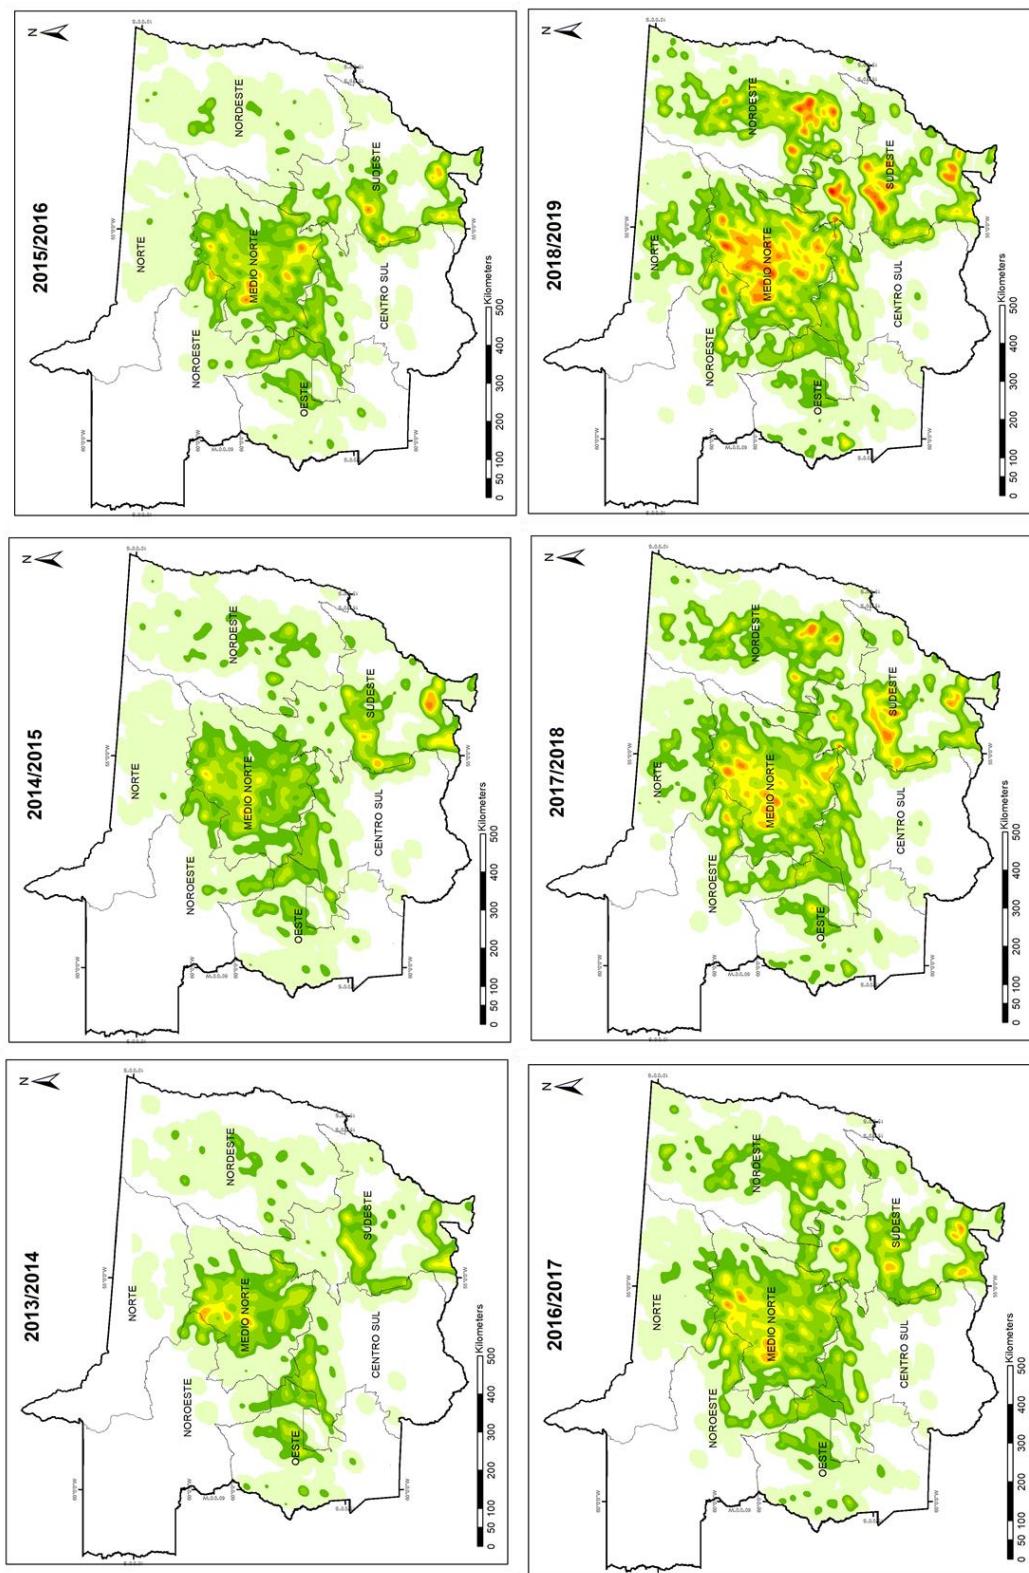
<b>Nome do Município</b>	<b>Área Implantada em ha para o ano/safra 2018/2019</b>	<b>Área Implantada em ha para o ano/safra 2012/2013</b>
Sorriso	116,951.00	72,213.00
Diamantino	74,688.00	61,994.00
Itiquira	57,809.00	50,539.00
Primavera Do Leste	82,757.00	48,825.00
Nova Ubiratã	91,088.00	48,532.00
Campo Novo Do Parecis	53,607.00	44,731.00
Nova Mutum	88,751.00	44,069.00
Sapezal	34,450.00	40,550.00
Sinop	41,519.00	33,100.00
Ipiranga Do Norte	30,563.00	32,100.00
Santa Rita Do Trivelato	41,625.00	30,425.00
Tangará Da Serra	19,975.00	30,400.00
Campos De Júlio	16,388.00	29,775.00
Tapurah	56,782.00	24,019.00
Alto Garças	41,863.00	23,138.00
Campo Verde	36,307.00	22,850.00
Vera	36,819.00	22,644.00
Lucas Do Rio Verde	35,113.00	21,613.00
Paranatinga	132,320.00	20,269.00
Porto Dos Gaúchos	57,775.00	20,256.00
Tabaporã	29,531.00	19,500.00
Brasnorte	63,488.00	16,806.00
Nova Marilândia	12,238.00	16,356.00
Querência	67,744.00	16,356.00
Feliz Natal	40,225.00	14,850.00
Comodoro	17,519.00	14,050.00
General Carneiro	20,050.00	13,650.00
Novo São Joaquim	23,163.00	13,494.00

Poxoréo	24,581.00	13,344.00
Santa Carmem	27,950.00	12,650.00
São José Do Rio Claro	44,344.00	12,638.00
Gaúcha Do Norte	62,050.00	11,588.00
Canarana	100,926.00	11,269.00
Juscimeira	19,731.00	10,856.00
Alto Araguaia	15,843.00	10,400.00
São Félix Do Araguaia	66,017.00	9,706.00
Nova Maringá	55,544.00	9,325.00
Jaciara	15,363.00	9,219.00
Nobres	26,788.00	9,138.00
Tesouro	11,494.00	8,131.00
Nortelândia	9,213.00	8,081.00
Santo Antônio Do Leste	14,850.00	7,831.00
Bom Jesus Do Araguaia	39,356.00	7,450.00
Rondonópolis	19,406.00	7,175.00
Cláudia	33,375.00	6,744.00
Itanhangá	28,250.00	6,138.00
Guiratinga	15,581.00	5,325.00
Pontes E Lacerda	5,238.00	5,306.00
Nova Xavantina	16,250.00	5,181.00
Vila Bela Da Santíssima Trindade	19,769.00	5,088.00
Água Boa	54,288.00	4,944.00
Santo Antônio Do Leverger	8,675.00	4,700.00
Ribeirão Cascalheira	38,525.00	4,619.00
Pedra Preta	7,669.00	4,319.00
Barra Do Garças	19,819.00	4,231.00
Dom Aquino	9,013.00	3,569.00
União Do Sul	16,700.00	3,513.00
Alto Taquari	5,792.00	3,422.00
Nova Olímpia	4,831.00	2,944.00
Itaúba	15,556.00	2,644.00

Canabrava Do Norte	10,419.00	2,281.00
Rosário Oeste	12,544.00	1,956.00
São José Do Xingu	13,606.00	1,675.00
Conquista D'oeste	2,006.00	1,481.00
Planalto Da Serra	15,981.00	1,444.00
Nova Lacerda	7,875.00	1,419.00
Campinápolis	17,656.00	1,394.00
Porto Alegre Do Norte	8,519.00	1,238.00
Araguaiana	2,469.00	1,227.00
Ponte Branca	443.00	1,085.00
Denise	3,175.00	1,013.00
Chapada Dos Guimarães	8,938.00	963.00
Nova Canaã Do Norte	15,419.00	738.00
Matupá	12,319.00	556.00
Nova Santa Helena	10,744.00	538.00
Ribeirãozinho	3,223.00	519.00
Confresa	13,950.00	500.00
Nova Guarita	3,144.00	331.00
Santa Terezinha	13,050.00	325.00
Mirassol D'oeste	1,031.00	250.00
Alto Paraguai	1,913.00	244.00
Santa Cruz Do Xingu	7,981.00	238.00
Vila Rica	7,181.00	188.00
Marcelândia	22,944.00	169.00
Alto Boa Vista	10,463.00	144.00
Peixoto De Azevedo	8,681.00	119.00
Serra Nova Dourada	1,856.00	119.00
Cuiabá	113.00	113.00
Arenápolis	1,625.00	113.00
Torixoréu	2,994.00	100.00
Colíder	5,450.00	88.00
Cáceres	1,750.00	81.00

Barra Do Bugres	1,700.00	75.00
Nova Brasilândia	2,288.00	50.00
Juara	14,594.00	50.00
Novo Mundo	9,063.00	38.00
Nova Nazaré	5,169.00	38.00
Luciara	356.00	0.00
Novo Santo Antônio	1,176.00	0.00
São Pedro Da Cipa	531.00	0.00
Nossa Senhora Do Livramento	106.00	0.00
Alta Floresta	6,050.00	0.00
Carlinda	3,919.00	0.00
Pontal Do Araguaia	50.00	0.00
Aripuanã	38.00	0.00
Terra Nova Do Norte	4,513.00	0.00
São José Dos Quatro Marcos	138.00	0.00
Cocalinho	3,232.00	0.00
Guarantã Do Norte	2,894.00	0.00
Salto Do Céu	819.00	0.00
Poconé	2,694.00	0.00
Nova Monte Verde	188.00	0.00
Juína	1,025.00	0.00
Novo Horizonte Do Norte	556.00	0.00
Castanheira	200.00	0.00
Santo Afonso	238.00	0.00
Paranaíta	588.00	0.00

## APÊNDICE C – MAPAS KERNEL DOS SISTEMAS ILP 2013/2014-2018/2019



## ANEXO – LEGENDAS DAS PRINCIPAIS INICIATIVAS BRASILEIRAS DE MAPEAMENTO

Neste anexo, apresentamos as diferentes legendas das principais iniciativas brasileiras de Mapeamento do Uso e Cobertura da Terra.

- (i) IBGE - Legenda do Mapeamento do Uso e Cobertura da Terra do Brasil

ANEXO I – Estrutura da vegetação e fitofisionomias	
ESTRUTURA DA VEGETAÇÃO E FITOFISIONOMIAS	
ESTRUTURA	FITOFISIONOMIA
Vegetação Florestal	Floresta Ombrófila Densa
	Floresta Ombrófila Aberta
	Floresta Ombrófila Mista
	Floresta Estacional Semidecidual
	Floresta Estacional Decidual
	Campinarana Florestada
	Savana Florestada
	Savana-Estépica Florestada
	Formação Pioneira de Influência Fluviomarinha Arbórea (Mangue)
	Formações Pioneiras de Influência Marinha (arbórea)
Vegetação Campestre	Formação Pioneira de Influência Fluvial e/ou Lacustre (Palmeiral)
	Campinarana Arborizada
	Campinarana Arbustiva
	Campinarana Gramíneo-Lenhosa
	Savana Arborizada
	Savana Parque
	Savana Gramíneo-Lenhosa
	Savana-Estépica Arborizada
	Savana-Estépica Parque
	Savana-Estépica Gramíneo-Lenhosa
	Estepe Arborizada
	Estepe Parque
	Estepe Gramíneo-Lenhosa
	Formações Pioneiras de Influência Fluviomarinha (exceto Mangue)
	Formações Pioneiras de Influência Marinha (exceto arbórea)
	Formações Pioneiras de Influência Fluvial e/ou Lacustre (exceto Palmeiral)

Fonte: IBGE. Diretoria de Geociências. Monitoramento da Cobertura e Uso da Terra do Brasil. Adaptado de Manual Técnico da Vegetação (IBGE, 2012) e Manual Técnico do Uso da Terra (IBGE, 2013)

**ANEXO II – Classes de Cobertura e Uso da Terra**

<b>CLASSE DE COBERTURA E USO DA TERRA</b>		
Cód.	Classe	Descrição
1	Área Artificial	Áreas onde predominam superfícies antrópicas não-agrícolas. São aquelas estruturadas por edificações e sistema viário, nas quais estão incluídas as metrópoles, cidades, vilas, as aldeias indígenas e comunidades quilombolas, áreas ocupadas por complexos industriais e comerciais e edificações que podem, em alguns casos, estar situadas em áreas peri-urbanas. Também pertencem a essa classe as áreas onde ocorrem a exploração ou extração de substâncias minerais, por meio de lavra ou garimpo.
2	Área Agrícola	Área caracterizada por lavouras temporárias, semi-perenes e permanentes, irrigadas ou não, sendo a terra utilizada para a produção de alimentos, fibras, combustíveis e outras matérias-primas. Segue os parâmetros adotados nas pesquisas agrícolas do IBGE e inclui todas as áreas cultivadas, inclusive as que estão em pousio ou localizadas em terrenos alagáveis. Pode ser representada por zonas agrícolas heterogêneas ou extensas áreas de <i>plantations</i> . Inclui os tanques de aquicultura.
3	Pastagem com Manejo	Áreas destinadas ao pastoreio do gado e outros animais, com vegetação herbácea cultivada (braquiária, azevém, etc) ou vegetação campestre (natural), ambas apresentando interferências antrópicas de alta intensidade. Estas interferências podem incluir o plantio; a limpeza da terra (destocamento e despedramento); eliminação de ervas daninhas de forma mecânica ou química (aplicação de herbicidas); gradagem; calagem; adubação; entre outras que descaracterizem a cobertura natural.
4	Mosaico de Ocupações em Área Florestal	Área caracterizada por ocupação mista de área agrícola, pastagem e/ou silvicultura associada ou não a remanescentes florestais, na qual não é possível uma individualização de seus componentes. Inclui também áreas com perturbações naturais e antrópicas, mecânicas ou não mecânicas, que dificultem a caracterização da área.
5	Silvicultura	Área caracterizada por plantios florestais de espécies exóticas ou nativas como monoculturas. Segue os parâmetros adotados nas pesquisas de extração vegetal e silvicultura do IBGE.
6	Vegetação Florestal	Área ocupada por florestas. Consideram-se florestais as formações arbóreas com porte superior a 5 metros de altura, incluindo-se aí as áreas de Floresta Ombrófila Densa, de Floresta Ombrófila Aberta, de Floresta Estacional, além da Floresta Ombrófila Mista. Inclui outras feições em razão de seu porte superior a 5 m de altura, como a Savana Florestada, Campinarana Florestada, Savana-Estépica Florestada, os Manguezais e os Buritizais, conforme o Manual Técnico de Uso da Terra (IBGE, 2013).
9	Área Úmida	Área caracterizada por vegetação natural herbácea ou arbustiva (cobertura de 10% ou mais), permanentemente ou periodicamente inundada por água doce ou salobra. Inclui os terrenos de charcos, pântanos, campos úmidos, estuários, entre outros. O período de inundação deve ser de no mínimo 2 meses por ano. Pode ocorrer vegetação arbustiva ou arbórea, desde que estas ocupem área inferior a 10% do total.

continua

(ii) TerraClass Amazônia – Legenda do Mapeamento do Uso e Cobertura da Terra nas Áreas Desflorestadas da Amazônia Legal.

Classes
<b>Agricultura Anual</b>
<b>Área não observada</b>
<b>Área Urbana</b>
<b>Mineração</b>
<b>Mosaico de ocupações</b>
<b>Outros</b>
<b>Pasto com solo exposto</b>
<b>Pasto limpo</b>
<b>Pasto sujo</b>
<b>Regeneração com pasto</b>
<b>Reflorestamento</b>
<b>Vegetação secundária</b>

Fonte: adaptado de (INPE, 2010)

(ii) TerraClass Cerrado - Legenda do Mapeamento do Uso e Cobertura do Cerrado

Natural	Antrópico	Não observado
Florestal	Agricultura	Queimadas
Não Florestal	(perene e anual)	Nuvens
(Savânico e	Pastagem	Sombras de
Campestre)	Silvicultura	Nuvens
Natural nao	Mineração	
vegetado (bancos	Urbano	
de areia,	Mosaico de	
afloramento	Ocupação	
rochoso)	Solo Exposto	
Corpos D' agua	outros	

Fonte adaptado de INPE (2015)

## (iv) - Legenda do Mapa de Uso e Cobertura da Terra do MapBiomas coleção 5

<b>1. Floresta</b>	<b>3. Agropecuária</b>	<b>4. Área não Vegetada</b>
1.1. Floresta Natural	3.1. Pastagem	4.1. Praia e Duna
1.1.1. Formação Florestal	3.2. Agricultura	4.2. Infraestrutura Urbana
1.1.2. Formação Savânica	3.2.1. Lavoura Temporária	4.3. Mineração
1.1.3. Mangue	3.2.1.1. Soja	4.4. Outras Áreas não Vegetadas
1.2. Floresta Plantada	3.2.1.2. Cana	<b>5. Corpo D'água</b>
<b>2. Formação Natural não Florestal</b>	3.2.1.3. Outras Lavouras Temporárias	5.1 Rio, Lago e Oceano
2.1. Campo Alagado e Área Pantanosa	3.2.2. Lavoura Perene	5.2 Aquicultura
2.2. Formação Campestre	3.3. Mosaico de Agricultura e Pastagem	6. Não observado
2.3. Apicum	2.4. Afloramento Rochoso	2.5. Outras Formações não Florestais

Fonte: adaptado de (MAPBIOMAS, 2020)