

UNIVERSIDADE ESTADUAL DE CAMPINAS FACULDADE DE ENGENHARIA AGRÍCOLA

BRUNA CAROLINE DA SILVA OLIVEIRA

Estimation of spatio-temporal variability of pasture aboveground biomass and height in integrated systems using Sentinel 2 images

Estimativa da variabilidade espaço-temporal da biomassa acima do solo e da altura da pastagem em sistemas integrados usando imagens do Sentinel 2

> CAMPINAS 2024

BRUNA CAROLINE DA SILVA OLIVEIRA

Estimation of spatio-temporal variability of pasture aboveground biomass and height in integrated systems using Sentinel 2 images

Estimativa da variabilidade espaço-temporal da biomassa acima do solo e da altura da pastagem em sistemas integrados usando imagens do Sentinel 2

Dissertação apresentada à Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas como parte dos requisitos exigidos para obtenção do título de Mestra em Engenharia Agrícola, na Área de Gestão de Sistemas na Agricultura e Desenvolvimento Rural.

Orientadora: Prof^a. Dr^a. Gleyce Kelly Dantas Araújo Figueiredo Coorientadora: Aliny Aparecida dos Reis

ESTE TRABALHO CORRESPONDE À VERSÃO FINAL DA DISSERTAÇÃO DEFENDIDA PELA ALUNA BRUNA CAROLINE DA SILVA OLIVEIRA E ORIENTADAPELA PROFESSORA DRA. GLEYCE KELLY DANTAS ARAÚJO FIGUEIREDO.

Ficha catalográfica Universidade Estadual de Campinas Biblioteca da Área de Engenharia e Arquitetura Rose Meire da Silva - CRB 8/5974

OL4e	Oliveira, Bruna Caroline da Silva, 1990- Estimation of spatio-temporal variability of pasture aboveground biomass and height in integrated systems using sentinel-2 images / Bruna Caroline da Silva Oliveira. – Campinas, SP : [s.n.], 2024.
	Orientador: Gleyce Kelly Dantas Araújo Figueiredo. Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola.
	 Integração lavoura-pecuária. Pastagens - Manejo. Árvores de decisão. Aprendizado de máquina. Agricultura de precisão. Figueiredo, Gleyce Kelly Dantas Araújo, 1984 Universidade Estadual de Campinas. Faculdade de Engenharia Agrícola. Título.

Informações Complementares

Título em outro idioma: Estimativa da variabilidade espaço-temporal da biomassa acima do solo e da altura da pastagem em sistemas integrados usando imagens do sentinel-2 Palavras-chave em inglês: Crop-livestock integration systems Pasture - management Decision trees Machine learning Precision agriculture Área de concentração: Gestão de Sistemas na Agricultura e Desenvolvimento Rural Titulação: Mestra em Engenharia Agrícola Banca examinadora: Gleyce Kelly Dantas Araújo Figueiredo [Orientador] João Francisco Gonçalves Antunes Ana Claudia dos Santos Luciano Data de defesa: 29-04-2024 Programa de Pós-Graduação: Engenharia Agrícola

Identificação e informações acadêmicas do(a) aluno(a) - ORCID do autor: https://orcid.org/0009-0007-7785-8610 - Currículo Lattes do autor: http://lattes.cnpq.br/3849498713561529 Este exemplar corresponde à redação final da **Dissertação de Mestrado** defendida por **Bruna Caroline da Silva Oliveira**, aprovada pela Comissão Julgadora em 29 de Abril de 2024, na Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas.



A Ata da defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

AGRADECIMENTOS

Não haveria como começar sem agradecer à Deus, que me deu a vida e forças pra chegar até aqui. Me sinto uma pessoa abençoada.

Meus pais, Roberto e Adriana, me deram todo o apoio desde a minha infância, me tornando uma mulher decidida e forte, sendo exemplo de força e persistência. Não seria nada sem eles.

À minha amada irmã, o maior presente que a vida me deu, fonte de amor, carinho e cuidado comigo. Te amo sis.

Ao meu esposo, e melhor amigo Felipe, que sem dúvidas foi o maior incentivador de todas as coisas que eu me propunha a fazer e me deu os meiores presentes da vida, meus filhos. Eu te amo pra sempre.

Ao meu filho Bernardo que dentro do meu ventre me deu forças na qualificação e à minha filha Heloísa, que hoje, dentro do meu ventre, me torna ainda mais forte. Que sejamos força e exemplo pra novas gerações.

Aos meus sogros e cunhados, minha segunda família, que acredita em mim, me ajuda, me incentiva e se tornou minha por todos esses anos. E hoje, me sinto parte deles, os Oliveiras.

Á minha filha linda Jade, aonde quer que você esteja, você me fez companhia quando precisei, sem pedir nada em troca. Vocês não humanos deveriam viver eternamente. Amo você pra sempre.

À minha orientadora Gleyce, que sempre foi muito compreensiva, profissional e amiga quando precisei. Sei que minha trajetória até aqui teria sido diferente se não fosse você.

À Aliny, defini-la como coorientadora ou amiga seria muito pouco, ela se tornou um presente enviado por Deus desde o primeiro momento do Lab. Você é inspiração e luz. Que sorte a minha.

Aos meus amigos de Lab e agora de vida, Yane, João, Gisela, Marcelle e Cyntia (sim, não poderia faltar a minha amiga de gravidez, que me ajudou principalmente nessa etapa final). A todos, obrigada pelos conselhos, pelos encontros, pelas fugidinhas até a Sergel e por barrar meu cafezinho na gravidez (Bernardo não é tão agitado por conta disso (contém ironia)).

À todos do GeoIn, dos grupos de viagem de campo até Caiuá e dos funcionários da Fazenda Campina que sempre nos receberam muito bem.

À todos os meus amigos que me acompanharam nesta trajetória, pela compreensão da minha ausência, pelo companheirismo, conselhos e paciência durante todo esse tempo.

À todos meus familiares e em especial a um primo que sempre foi um exemplo e apoio quando o tema era estudo. Obrigada Dr. Primo Marco.

Special thanks to my family in Minnesota, who received a girl that didn't know and taught her much more than just words in English, taught her values and made her feel like she was part of that family. I will be forever grateful.

To my friend and best boss in the world, Victor. It gave me opportunities and encouragement to achieve my projects. I will always remember with affection and pride the years we worked together, the trips to work camps, the drone flights and bad food on the roads. Thank you for believing in me.

À Universidade Estadual de Campinas (UNICAMP) e a Faculdade de Engenharia Agrícola (FEAGRI). Em especial, a coordenação de pós-graduação do programa (CPG) e à Valéria que sempre se mostrou pró ativa e eficiente em ajudar quando precisei.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001"

RESUMO

No Brasil, a avaliação e o manejo precisos da produtividade das pastagens são cruciais, dados os incentivos governamentais para práticas agrícolas sustentáveis. Os sistemas de integração lavoura-pecuária (ILP), surgem como uma abordagem promissora para revitalizar pastagens degradadas e aumentar a produtividade. Medições precisas da biomassa e da altura das pastagens são vitais para avaliar o sucesso dos sistemas de pastoreio, permitindo que os gestores agrícolas otimizem as estratégias de alimentação animal. As estimativas de biomassa em tempo real facilitam o ajuste das taxas de lotação, melhorando a utilização das pastagens e a produtividade global. A variabilidade espacial na produção de biomassa pode informar decisões de manejo de pastagens, orientando estratégias para otimização do pastoreio em áreas com maior oferta de forragem. As técnicas de sensoriamento remoto desempenham um papel fundamental no fornecimento de informações valiosas para a caracterização espacial e temporal das pastagens e estimativa de biomassa. O objetivo desse estudo foi estimar a biomassa da pastagem em sistema de integração lavoura-pecuária utilizando imagens do satélite Sentinel-2. Para isso, foram testados diferentes variáveis (bandas espectrais, índices de vegetação e medidas de textura) derivadas de imagens do Sentinel-2 e selecionamos as características potenciais mais adequadas para estimar e explicar a variabilidade temporal e espacial da biomassa e altura da pastagem. E em seguida, foram criados mapas de variabilidade espaçotemporal da biomassa e altura da pastagem. Nesta pesquisa, diferentes cenários (S1 a S4) foram avaliados para a estimativa de biomassa seca acima do solo (AGB) e altura do dossel (CH), considerando diferentes conjuntos de características e técnicas de seleção de atributos. Os resultados indicaram que, antes dos testes com o Algoritmo Genético (GA), a melhor combinação incluía bandas espectrais, índices de vegetação e medidas de textura otimizadas para AGB, enquanto índices de vegetação se destacaram para a estimativa de CH. Após a otimização com o GA, o cenário S1, com medidas de textura otimizadas para AGB, e o S2, enfatizando bandas espectrais para CH, demonstraram maior precisão. Os resultados destacam o potencial de usar medidas de textura baseadas em medidas de textura GLCM (S1) para obter precisões aprimoradas na estimativa de AGB (RMSE = 32,74%; R2 = 0,53) e para predição da CH o melhor cenário foi o S2 (RMSE = 11,91%; R2 = 0,57). Em seguida, mapas de variações espaço-temporais no AGB e CH da pastagem ao longo da estação de crescimento da forragem foram criados. Os mesmos foram obtidos com os modelos XGBoost de melhor desempenho utilizando as medidas de textura para AGB e as bandas espectrais para CH. Provamos neste estudo, que as medidas de textura baseadas em GLCM, derivadas de imagens do Sentinel-2, aprimoraram a precisão na predição de modelos de AGB e para CH os melhores modelos preditivos foram alcançados utilizando bandas espectrais.

Palavras-chave: ILP; medidas de texturas; índices de vegetação; extreme gradient boosting; pastagem mista.

ABSTRACT

In Brazil, accurate assessment and management of pasture productivity is crucial given government incentives for sustainable agricultural practices. Integrated crop-livestock systems (ICLS) emerge as a promising approach to revitalizing degraded pastures and increasing productivity. Accurate measurements of pasture biomass and height are vital for assessing the success of grazing systems, allowing agricultural managers to optimize animal feeding strategies. Real-time biomass estimates make it easier to adjust stocking rates, improving pasture utilization and overall productivity. Spatial variability in biomass production can inform pasture management decisions, guiding strategies for optimizing grazing in areas with greater forage supply. Remote sensing techniques play a fundamental role in providing valuable information for the spatial and temporal characterization of pastures and biomass estimation. The objective of this study was to estimate pasture biomass in an integrated crop-livestock system using Sentinel-2 images. For this, we tested different variables (spectral bands, vegetation indices and texture measurements) derived from Sentinel-2 images and selected the most suitable potential characteristics to estimate and explain the temporal and spatial variability of biomass and pasture height. And then, create maps of spatio-temporal variability of biomass and pasture height. In this research, different scenarios (S1 to S4) were evaluated to estimate above-ground dry biomass (AGB) and canopy height (CH), considering different sets of characteristics and attribute selection techniques. The results indicate that, before testing with Genetic Algorithm (GA), the best combination included spectral bands, vegetation indices and texture measurements optimized for AGB, while vegetation indices were highlighted for CH prediction. After optimization with GA, scenario S1, with texture measurements optimized for AGB, and S2, emphasizing spectral bands for CH, demonstrated greater accuracy. Our results highlight the potential of using GLCM-based texture measurements (S1) to obtain improved accuracies in AGB prediction (RMSE = 32.74%; R2 = 0.53) and for CH prediction the best model was S2 (RMSE = 11.91%; R2 = 0.57). Finally, maps of spatio-temporal variations in AGB and CH of the pasture throughout the forage growing season were created. They were obtained with the best performing XGBoost models using texture measurements for AGB and spectral bands for CH. We proved in this study that GLCM-based texture measurements, derived from Sentinel-2 images, improved the accuracy in predicting AGB models and for CH the best predictive models were achieved using spectral bands.

Keywords: ICLS; texture measurements; vegetation index; extreme gradient boosting; mixed-pasture.

1. IN	TRODUÇÃO GERAL 10
1.1.	Justificativa da Pesquisa
1.2.	Objetivos
1.3.	Estrutura da Dissertação14
2. RI	EVISÃO BIBLIOGRÁFICA 15
2.1.	Importância da produção bovina15
2.2.	Sistemas de Integração 15
2.3.	Sensoriamento remoto
2.4.	Monitoramento da Pastagem por Sensoriamento Remoto 18
2.5.	Índices de Vegetação 19
2.6.	Medidas de textura
2.7.	Modelagem da biomassa 21
2.7.1.	Seleção de atributos
3. AI	RTIGO
3.1. integrat	Estimation of spatio-temporal variability of pasture aboveground biomass and height in ted systems using Sentinel-2 images
3.1.1.	Introduction
3.1.2.	Materials and Methods
3.1.2.1.	Study Area
3.1.2.2.	Field Data Collection
3.1.3.	Remote Sensing Data Collection and Preprocessing 31
3.1.3.1.	Vegetation Indices
3.1.3.2.	Texture Measures 32
3.1.3.3.	Feature Selection
3.1.3.4.	Machine Learning Algorithm
3.1.3.5.	Statistical Analysis
3.1.3.6.	Scenarios for the data analysis
3.1.4.	Results
3.1.5.	Discussion
3.1.6.	Conclusion
3.1.7.	Attachment

SUMÁRIO

4.

1. INTRODUÇÃO GERAL

O Brasil destaca-se como o segundo maior produtor e principal exportador mundial de carne bovina, conforme dados da Associação Brasileira das Indústrias Exportadoras de Carnes (2022). A pecuária brasileira destaca-se pela criação em pasto, sendo essa prática considerada a forma mais econômica e prática de produzir alimentos para bovinos, resultando em custos de produção mais baixos. Essa abordagem, aliada às características climáticas e à vastidão territorial do país, contribui para o Brasil ter um dos menores custos de produção de carne no mundo, segundo Ferraz e Felício (2010).

Há anos, o setor agropecuário brasileiro passa por significativas transformações, impulsionadas pelos aumentos nos custos de produção, a competitividade de mercado e a busca pelo aumento da produtividade, integrando qualidade, rentabilidade e conservação dos recursos naturais (Food and Agriculture Organization of the United Nations, 2010). No Brasil, dos 173 milhões de hectares de pastagens, 117 milhões são cultivados, e mais de 70% dessas pastagens encontram-se em algum estágio de degradação, com uma parcela considerável em estágios avançados (Empresa Brasileira de Pesquisa Agropecuária, 2018). Estudos anteriores destacam a viabilidade de aumentar significativamente a produção agrícola através da gestão eficiente do solo, desempenhando um papel crucial na segurança alimentar diante do crescimento populacional (Herrero *et al.*, 2010; Bustamante *et al.*, 2012; Strassburg *et al.*, 2014; Bellón *et al.*, 2017).

Como estratégia para otimizar a produção e preservar os recursos naturais, a Integração Lavoura-Pecuária-Floresta (ILPF) surge como uma alternativa viável, apresentando quatro modalidades distintas: Integração Lavoura-Pecuária (ILP), Integração Lavoura-Floresta (ILF), Integração Pecuária-Floresta (IPF) e a própria ILPF, que integra componentes agrícola, pecuário e florestal, permitindo uma diversificação do uso das terras (Balbino, Barcellos e Stone, 2011; Gil, Siebold e Berger, 2015). Esses sistemas de integração não só reduzem a pressão sobre os ecossistemas naturais, mas também oferecem uma série de benefícios, como melhoria nas condições do solo, aumento da eficiência na utilização de nutrientes, diversificação da produção e estabilização de renda na propriedade rural, além de contribuírem para a recuperação de áreas degradadas e a mitigação das emissões de gases de efeito estufa (Food and Agriculture Organization of the United Nations, 2007). No contexto brasileiro, o Plano ABC+, continuidade do Plano ABC destaca-se como uma iniciativa voltada para a promoção de práticas sustentáveis no setor agrícola, visando a adaptação e mitigação às mudanças climáticas, dentre as ações como recuperação de pastagens degradadas e a implementação da ILPF (Brasil, 2012).

O monitoramento de pastagens por sensoriamento remoto, emerge como uma abordagem crucial na gestão eficiente dos recursos agrícolas, particularmente em sistemas Integrados-Lavoura-Pecuária-Floresta (ILPF). O satélite Sentinel-2 oferece a capacidade de coletar dados de alta resolução espacial e espectral, possibilitando uma análise detalhada da disponibilidade da biomassa de pastagem. Além de permitir a detecção de mudanças temporais na vegetação e identificação de áreas de degradação, o sensoriamento remoto cobre extensas áreas de pastagem de maneira eficiente e econômica, contribuindo para uma gestão mais sustentável na agropecuária. (Formaggio e Sanches, 2017). O monitoramento por imagens de satélite não apenas fornece informações valiosas sobre a condição da vegetação, mas também permite uma análise integrada dos fatores ambientais que influenciam o desempenho da pastagem em sistemas ILPF, como cobertura vegetal, umidade, diversidade vegetal, monitoramento de pragas e doenças, entre outros. Essa abordagem promissora não só aprimora a produtividade e sustentabilidade dos sistemas agrícolas, mas também desempenha um papel fundamental na busca por práticas agrícolas mais eficientes e amigáveis ao meio ambiente, fornecendo subsídios para decisões informadas no manejo, como ajustes na carga animal e otimização do uso de recursos hídricos (Balbino, Barcellos e Stone, 2011). Em outras palavras o uso do sensoriamento remoto na agricultura tornou-se uma ferramenta crucial para otimizar a gestão agrícola, monitorar o crescimento das culturas e promover práticas sustentáveis (Manabe, Melo e Rocha, 2018).

O Sentinel-2, parte do programa da Agência Espacial Europeia (ESA), destaca-se como uma ferramenta notável no sensoriamento remoto espacial, com capacidades avançadas de captura de imagens em alta resolução espacial e espectral (European Space Agency, 2019). Com uma revisita global de cinco dias, o Sentinel-2 oferece uma cobertura regular e consistente, possibilitando a detecção de mudanças ao longo do tempo. Essa constância na aquisição de dados torna o Sentinel-2 uma ferramenta valiosa para aplicações diversas, desde o monitoramento de culturas e florestas até a resposta a desastres naturais (European Space Agency, 2019).

A aplicação de índices de vegetação, como o Índice de Vegetação por Diferença Normalizada (Normalized Difference Vegetation Index - NDVI), revela vantagens significativas na estimativa de biomassa em ecossistemas, proporcionando uma abordagem eficaz e não invasiva para monitorar a produtividade vegetal (Jensen, 2009). Derivados de dados espectrais obtidos por sensoriamento remoto, esses índices capturam informações sobre a condição fisiológica e estrutural das plantas, sendo o NDVI um exemplo que avalia a quantidade e saúde da vegetação com base na diferença entre as reflectâncias no espectro visível e infravermelho próximo (Huang *et al.*, 2021). Esses índices destacam-se pela capacidade de discriminar entre áreas com diferentes densidades vegetativas e níveis de biomassa, proporcionando uma avaliação contínua e eficiente da dinâmica da vegetação ao longo do tempo (Jensen, 2009)

As medidas de texturas desempenham um papel crucial na análise de imagens de sensoriamento remoto, oferecendo *insights* valiosos sobre a distribuição espacial e características intrínsecas dos objetos na cena. A matriz de coocorrência (Grey Level Cooccurrence Matrix - GLCM) é uma técnica comum para quantificar a textura, calculando a frequência de pares de pixels com valores de cinza específicos em uma dada direção, revelando informações sobre a variação tonal e a complexidade estrutural da imagem. Medidas estatísticas extraídas da GLCM, como desvio padrão e entropia, proporcionam uma representação quantitativa da textura, permitindo discriminação entre áreas com diferentes padrões, como vegetação densa, áreas urbanas e corpos d'água. A combinação dessas medidas de texturas com imagens de satélite amplia a capacidade de análise de dados de sensoriamento remoto, proporcionando uma visão mais detalhada e holística das áreas observadas. Essa abordagem aprimorada facilita a identificação precisa de alvos complexos e a análise de padrões espaciais sutis, sendo particularmente vantajosa em aplicações como monitoramento ambiental, planejamento urbano e avaliação de recursos naturais (Haralick, Shanmugam e Dinstein, 1973).

A seleção de atributos é uma etapa importante em análises de dados e modelagem, desempenhando um papel essencial na melhoria da eficiência e desempenho dos modelos. Esse processo visa escolher cuidadosamente variáveis ou características relevantes para o problema em questão, reduzindo a dimensionalidade dos dados, eliminando redundâncias e, consequentemente, aprimorando a precisão e interpretabilidade do modelo. Ao identificar os atributos mais informativos, a seleção não apenas acelera a computação, mas também evita o *overfitting*, contribuindo para modelos mais robustos e generalizáveis. Diversas técnicas, como métodos estatísticos, algoritmos de aprendizado de máquina e abordagens heurísticas, são empregadas, adaptando-se às particularidades do conjunto de dados e aos objetivos específicos da análise. Assim, a seleção de atributos desempenha um papel fundamental na otimização da eficácia de modelos analíticos, proporcionando uma abordagem mais focada e precisa para a interpretação e predição de padrões nos dados.

O Extreme Gradient Boosting (XGBoost), proposto por Chen e Guestrin (2016), é um modelo de aprimoramento de estrutura de árvore que cria árvores de decisão sequencialmente através do "boosting". Essa abordagem combina as previsões de aprendizes fracos para formar um aprendiz forte, controlando a complexidade da árvore para evitar o *overfitting*. O XGBoost é flexível, altamente escalável e eficiente para lidar com dados esparsos, proporcionando melhorias significativas na velocidade do algoritmo e na eficiência computacional durante o treinamento com grandes conjuntos de dados. O ajuste dos hiperparâmetros do XGBoost é também uma etapa crucial para otimizar o desempenho dos modelos. Essa sintonia é vital, pois a alteração de um parâmetro pode afetar os valores ótimos dos outros, e, geralmente, estudos anteriores utilizaram os valores padrão dos parâmetros, carecendo de detalhes sobre o processo de ajuste e não otimizando o modelo para os dados em questão.

1.1. Justificativa da Pesquisa

O monitoramento espaço-temporal da biomassa de pastagens em sistema de integração lavoura-pecuária é uma tarefa desafiadora devido à complexidade desses sistemas de produção. Estimativas de biomassa fornecem aos agricultores as informações necessárias para a tomada de decisão a fim de suprir as necessidades alimentares de seus animais de acordo com a quantidade de forragem disponível, permitindo assim que as taxas de lotação do piquete sejam adaptadas às condições reais de produtividade daquela área, resultando no aumento da utilização das pastagens e, consequentemente, taxas de crescimento das pastagens juntamente com a produtividade geral. Além disso, o uso de imagens de sensoriamento remoto oferecem a oportunidade de realizar assimilações de dados *in situ* para que esses dados sejam utilizados para o monitoramento de pastagens e extrapolação de estimativas de biomassa para toda a área de interesse.

1.2. Objetivos

O objetivo geral do trabalho foi estimar a biomassa da pastagem em um sistema de integração lavoura-pecuária utilizando imagens Sentinel-2.

Para isso, testamos diferentes variáveis preditoras (bandas espectrais, índices de vegetação e medidas de textura) derivadas de imagens do Sentinel-2 e selecionamos as características potenciais mais adequadas para estimar e explicar a variabilidade temporal e espacial da biomassa e altura da pastagem. E em seguida, mapas de variabilidade espaço-temporal da biomassa e altura da pastagem foram criados para permitir a análise espaço-

temporal da dinâmica do desenvolvimento da pastagem e do pastejo durante a estação de crescimento da pastagem.

1.3. Estrutura da Dissertação

A dissertação foi dividida em um capítulo de revisão bibliográfica abordando os principais assuntos para o desenvolvimento deste trabalho (Capítulo 2), um capítulo referente ao artigo científico (Capítulo 3) contendo os resultados da pesquisa, e por fim, um capítulo de Considerações Finais (Capítulo 4).

2. REVISÃO BIBLIOGRÁFICA

2.1. Importância da produção bovina

O Brasil é atualmente o segundo maior produtor e o maior exportador mundial de carne bovina, segundo a Associação Brasileira das Indústrias Exportadoras de Carnes (2022). A União Europeia é um mercado de grande importância para o Brasil e em 2022 as exportações somaram cerca de 85 mil toneladas (Associação Brasileira das Indústrias Exportadoras de Carnes, 2022).

A produção eficaz da pastagem é um tópico de extrema relevância, uma vez que uma característica importante da pecuária brasileira é ter a maior parte de seu rebanho criado a pasto (Ferraz e Felício, 2010), que se constitui na forma mais econômica e prática de produzir e oferecer alimentos para os bovinos, garantindo baixos custos de produção. Segundo a Empresa Brasileira de Pesquisa Agropecuária (2018), atualmente cerca de 95% da carne bovina é produzida em regime de pastagens. Em decorrência desses aspectos, somados às características climáticas e a extensão territorial do País, o Brasil possui um dos menores custos de produção de carne do mundo (Ferraz e Felício, 2010).

2.2. Sistemas de Integração

Os últimos anos têm sido de muitas modificações no setor agropecuário brasileiro, principalmente por conta dos aumentos no custo de produção, por conta do mercado competitivo e do aumento da produtividade ligando qualidade, rentabilidade e conservação dos recursos naturais (Food and Agriculture Organization of the United Nations, 2010).

Dos 173 milhões de hectares de pastagens no Brasil, 117 milhões de hectares são de pastagens cultivadas, e estima-se que mais de 70% das pastagens cultivadas encontra-se em algum estádio de degradação, sendo que destas uma grande parte em estágios avançados de degradação (Empresa Brasileira de Pesquisa Agropecuária, 2018).

Neste cenário, estudos previamente publicados evidenciaram a viabilidade de significativo aumento na produção agrícola em extensas áreas por meio da gestão mais eficiente do solo e da preservação dos recursos naturais. Essa abordagem, por conseguinte, desempenha um papel crucial na garantia da segurança alimentar, especialmente diante do contínuo crescimento populacional (Herrero *et al.*, 2010; Bustamante *et al.*, 2012; Strassburg *et al.*, 2014; Bellón *et al.*, 2017).

Portanto, enquanto estratégia, a ILPF (Integração Lavoura-Pecuária-Floresta) pode ser adotada por meio de diferentes sistemas de integração. Conforme Balbino, Barcellos e Stone (2011), os Sistemas Integrados de Produção Agropecuária (SIPAs) englobam quatro modalidades distintas, e a adoção dessas tecnologias varia conforme os objetivos e a infraestrutura específica de cada produtor. As modalidades incluem:

- a) Integração Lavoura-Pecuária (ILP) ou Agropastoril: integração dos componentes agrícola e pecuário, seja por meio de rotação, consórcio ou sucessão, ocorrendo na mesma área durante um ano agrícola ou em múltiplos anos.
- b) Integração Lavoura-Floresta (ILF) ou Silviagrícola: consorciação de componentes florestal e agrícola, envolvendo o plantio simultâneo de espécies arbóreas com cultivos agrícolas, sejam anuais ou perenes. A lavoura pode ser empregada na fase inicial da implantação da parte florestal ou em ciclos ao longo do desenvolvimento do sistema.
- c) Integração Pecuária-Floresta (IPF) ou Silvipastoril: consórcio dos componentes pecuário e florestal.
- d) Integração Lavoura-Pecuária-Floresta (ILPF) ou Agrossilvipastoril: integração dos componentes agrícola, pecuário e florestal, seja por rotação, consórcio ou sucessão, dentro da mesma área. No caso desse sistema, o componente "lavoura" pode ser empregado na fase inicial da implantação do componente florestal ou em ciclos ao longo do desenvolvimento do sistema.

Em suma, os sistemas de integração visam à diversificação do uso das terras, com base na integração espacial e temporal dos componentes do sistema produtivo (lavoura e pecuária), causando a redução da pressão sobre os ecossistemas naturais (Alves, Madari e Boddey, 2017). Ou seja, nesses tipos de sistemas, há uma alternância na mesma área, do cultivo de pastagens anuais ou perenes, destinadas à alimentação animal, e das culturas destinadas à produção vegetal, sobretudo grãos.

A intensificação da produção, observada em sistemas de ILPF, acarreta diversos benefícios ao produtor e ao meio ambiente, ou seja, melhora as condições físicas, químicas e biológicas do solo; aumenta a ciclagem e a eficiência na utilização dos nutrientes; reduz ou amortiza custos de produção das atividades agrícola, pecuária e florestal ao longo do tempo; diminui a ociosidade do uso das áreas agrícolas; diversifica a produção e estabiliza a renda na propriedade rural; viabiliza a recuperação de áreas com pastagens degradadas; mitiga emissões de gases de efeito estufa, aumenta o sequestro de carbono, o bem-estar e a produtividade animal, além de outros benefícios (Food and Agriculture Organization of the United Nations, 2007).

No Brasil, o Plano Agricultura de Baixa Emissão de Carbono (Plano ABC) do Ministério da Agricultura, Pecuária e Abastecimento (MAPA) é um exemplo materializado com estímulos para produtores rurais que adotam práticas conservacionistas e ações que buscam reduzir as emissões de gases do efeito estufa (período de 2010 a 2020). Mais recentemente, o lançamento do Plano ABC+, com ajustes e avanços, estipulou metas ainda mais ambicionas para o sequestro de C em nossas lavouras, para o período 2020 a 2030 (Martin-Neto *et al.*, 2023) O "ABC" refere-se ao Plano Setorial de Mitigação e de Adaptação às Mudanças Climáticas para a Consolidação de uma Economia de Baixa Emissão de Carbono na Agricultura, enquanto o "+" indica a expansão e aprimoramento desse plano. O ABC+ busca promover ações como a recuperação de pastagens degradadas, integração lavoura-pecuária-floresta (ILPF), florestamento e reflorestamento, além do estímulo a práticas agrícolas sustentáveis. O objetivo central é conciliar o desenvolvimento do setor agrícola com a redução das emissões de gases de efeito estufa, a conservação dos recursos naturais e o aumento da resiliência do setor frente às mudanças climáticas (Brasil, 2012).

Independentemente do tipo de integração, todas melhoram a qualidade do solo, e consequentemente a produtividade, pois são sistemas complexos que privilegiam o cultivo diversificado de plantas aliado ao pastejo animal.

2.3. Sensoriamento remoto

O uso de sensoriamento remoto na agricultura se tornou uma ferramenta essencial para otimizar a gestão agrícola, monitorar o crescimento das culturas e promover práticas sustentáveis (Formaggio e Sanches, 2017). Monitorar a mudança do uso da terra é importante para o gerenciar a produção de alimentos, avaliar as mudanças climáticas e informar e avaliar políticas para enfrentar esses desafios. A tecnologia permite a coleta de dados precisos e em larga escala por meio de imagens obtidas por satélites, aeronaves ou drones, proporcionando uma visão abrangente das condições das plantações. Essas imagens são processadas para extrair informações valiosas, como índices de vegetação, padrões de crescimento, e até mesmo a detecção de pragas e doenças (Jensen, 2009). Essa abordagem remota fornece uma visão em tempo quase real e informações detalhadas sobre o estado das culturas. O sensoriamento remoto na agricultura contribui significativamente para aumentar a produtividade, reduzir custos e promover práticas agrícolas mais sustentáveis e orientadas para o futuro (Bishop-Taylor, Tulbure e Broich, 2018; Rapinel *et al.*, 2019).

O Sentinel-2 representa uma conquista notável no campo do sensoriamento remoto espacial. Lançado como parte do programa Copernicus da Agência Espacial Europeia (ESA), o Sentinel-2 é um satélite de observação da Terra que desempenha um papel crucial no monitoramento de mudanças ambientais, gestão de recursos naturais e agricultura. Equipado com um sistema avançado de sensores multiespectrais, o Sentinel-2 é capaz de capturar imagens em alta resolução espacial e espectral. Sua capacidade inclui a observação de uma ampla gama de comprimentos de onda, desde o visível até o infravermelho próximo, permitindo a análise detalhada da cobertura terrestre. Com uma revisita global de cinco dias, o Sentinel-2 oferece uma cobertura regular e consistente, possibilitando a detecção de mudanças ao longo do tempo. Essa constância na aquisição de dados torna o Sentinel-2 uma ferramenta valiosa para aplicações diversas, desde o monitoramento de culturas e florestas até a resposta a desastres naturais (European Space Agency, 2019)

O destaque do Sentinel-2 entre os satélites de observação da Terra é evidenciado por diversas vantagens notáveis. Em primeiro lugar, sua órbita polar heliossíncrona assegura uma cobertura global regular, possibilitando a aquisição sistemática de dados em intervalos curtos. A incorporação de sensores multiespectrais avançados no Sentinel-2 oferece imagens com elevada resolução espacial e espectral, proporcionando uma análise detalhada da superfície terrestre. A capacidade de observação em faixas espectrais diversas, desde o visível até o infravermelho próximo, fornece informações cruciais para aplicações como monitoramento agrícola, detecção de mudanças ambientais e gestão de recursos naturais, além da disponibilidade gratuita de seus dados. Quanto à resolução temporal, o Sentinel-2 possui uma revisita global de cinco dias, garantindo uma cobertura regular e consistente de áreas específicas ao longo do tempo. Essa frequência de aquisição de dados é crucial para o acompanhamento de mudanças sazonais, resposta a eventos climáticos e gestão de recursos naturais em diversas escalas. Essa combinação de resolução espacial e temporal confere ao Sentinel-2 uma posição proeminente no arsenal de ferramentas de sensoriamento remoto, beneficiando aplicações que exigem análises detalhadas e recorrentes da superfície terrestre (Torres et al., 2012; Snoeij et al., 2009; Servello, Sano e Pantoja, 2015).

2.4. Monitoramento da Pastagem por Sensoriamento Remoto

O monitoramento da pastagem por sensoriamento remoto representa uma abordagem crucial para a gestão eficiente dos recursos agrícolas, especialmente em sistemas Integrados-Lavoura-Pecuária-Floresta (ILPF). O uso de tecnologias espaciais, como o s atélite Sentinel-2, oferece a capacidade de coletar dados de alta resolução espacial e espectral, permitindo uma análise detalhada da saúde e da biomassa da pastagem. Essa metodologia possibilita a detecção de mudanças temporais na vegetação, identificação de áreas de degradação e avaliação do impacto das práticas de manejo. Além disso, o sensoriamento remoto permite uma cobertura extensiva, facilitando a monitorização em grandes áreas de pastagem de maneira eficiente e econômica, contribuindo para uma abordagem mais sustentável na gestão agropecuária (Formaggio e Sanches, 2017).

A aplicação do sensoriamento remoto no monitoramento da pastagem não apenas fornece dados valiosos sobre a condição da vegetação, mas também permite uma análise integrada dos fatores ambientais que afetam o desempenho da pastagem em sistemas ILPF. A interpretação das informações coletadas contribui para a tomada de decisões informadas em relação ao manejo, como ajustes na carga animal, otimização da utilização de recursos hídricos e identificação de áreas propícias à expansão ou reabilitação. Essa abordagem inovadora não apenas aprimora a produtividade e sustentabilidade dos sistemas agrícolas, mas também desempenha um papel fundamental na busca por práticas agrícolas mais eficientes e amigáveis ao meio ambiente (Punalekar *et al.*, 2018).

Em Ali *et al.* (2016), os autores conduziram uma revisão abrangente dos métodos de monitoramento e observação de pastagens, aproveitando dados de sensoriamento remoto por satélite. Eles exploraram os avanços tecnológicos e metodológicos associados com o objetivo de extrair informações valiosas sobre pastagens. Os autores observaram uma mudança na recuperação de parâmetros biofísicos de pastagens da análise de regressão convencional para abordagens de modelagem mais mecanicistas, impulsionadas pela integração de dados de satélite. Esta transição é vista como um movimento em direção a técnicas de modelagem mais robustas e sofisticadas.

2.5. Índices de Vegetação

O índice de vegetação é uma medida radiométrica adimensional utilizada para modelar os parâmetros biofísicos da vegetação sendo associado a assinatura espectral e parâmetros mensuráveis no campo (Jensen, 2009). A utilização de índices de vegetação oferece vantagens significativas na estimativa de biomassa em ecossistemas, proporcionando uma abordagem eficaz e não invasiva para monitorar a produtividade vegetal. Esses índices, derivados de dados espectrais obtidos por sensoriamento remoto, capturam informações sobre a condição fisiológica e estrutural das plantas (Xue e Su, 2017). Um exemplo é o Índice de Vegetação por Diferença Normalizada (NDVI), que utiliza a diferença entre as reflectâncias no espectro visível e infravermelho próximo para avaliar a quantidade e a saúde da vegetação (Huang *et al.*, 2021). A principal vantagem reside na capacidade dos índices de vegetação em discriminar entre áreas com diferentes densidades vegetativas e níveis de biomassa. Além disso,

esses índices proporcionam uma avaliação contínua e eficiente da dinâmica da vegetação ao longo do tempo. Ao integrar esses indicadores nas estimativas de biomassa, os pesquisadores e gestores podem obter uma compreensão mais abrangente e dinâmica das condições do ecossistema, facilitando práticas de manejo mais informadas e sustentáveis. (Jensen, 2009).

Várias abordagens metodológicas para estimativas de biomassa de pastagem foram aplicadas a conjuntos de dados ópticos de SR com diferentes resoluções espaciais e temporais (Lu, 2006; Wang *et al.*, 2019). Dusseux *et al.* (2015), por exemplo, estimaram a biomassa de pastagens em áreas agrícolas, aplicando o índice de vegetação com diferença normalizada (NDVI) e duas variáveis biofísicas, índice de área foliar e fração de cobertura vegetal, obtidas pela boa resolução do satélite para observação do SPOT da terra (satélite para observação da Terra). Como resultado, a análise estatística revelou que, dentre as três variáveis derivadas de satélite, o IAF (Índice de Área Foliar) foi o melhor para estimar a biomassa das pastagens e mostrou que, com base na relação estabelecida entre os IAF, derivada dos dados de sensoriamento remoto e as medições de biomassa no campo, a biomassa e a evolução da grama podem ser estimadas levando em consideração as necessidades diárias do gado.

2.6. Medidas de textura

Alguns estudos mostraram que a combinação de respostas espectrais e texturas de imagem melhora o desempenho da estimativa de biomassa (Lu, 2006). Texturas são amplamente utilizadas para denotar diferenças em objetos com reflectância semelhante, pois podem fornecer informações essenciais sobre ordens espaciais de padrões de cores ou intensidade de reflectância do objeto (Haralick, Shanmugam e Dinstein, 1973). Diversas técnicas são empregadas para quantificar a textura em imagens, sendo uma abordagem comum a matriz de coocorrência de níveis de cinza (GLCM - Grey Level Co-occurrence Matrix). Essa matriz calcula a frequência com que pares de pixels com determinados valores de cinza ocorrem em uma dada direção, fornecendo informações sobre a variação tonal e a complexidade estrutural da imagem. Além disso, medidas estatísticas, como desvio padrão, média e entropia, extraídas da GLCM, oferecem uma representação quantitativa da textura, permitindo a discriminação entre áreas com diferentes padrões, como vegetação densa, áreas urbanas e corpos d'água (Haralick, Shanmugam and Dinstein, 1973).

A combinação de medidas de texturas e imagens de satélite representa uma estratégia eficaz para ampliar a capacidade de análise e interpretação de dados provenientes do sensoriamento remoto. Enquanto as imagens de satélite fornecem informações valiosas sobre a cobertura terrestre e suas características espectrais em diferentes comprimentos de onda, a inclusão de medidas de texturas oferece uma perspectiva adicional ao capturar padrões espaciais e variações na distribuição de tons de cinza. Ao integrar essas duas fontes de informação, é possível obter uma compreensão mais detalhada e holística das áreas observadas. Essa abordagem combinada melhora a capacidade de discriminação entre diferentes tipos de terreno, facilitando a identificação precisa de alvos complexos e a análise de padrões espaciais sutis. Assim, a fusão de medidas de texturas com imagens de satélite amplia a utilidade do sensoriamento remoto, sendo particularmente vantajosa em aplicações como monitoramento ambiental, planejamento urbano e avaliação de recursos naturais. (Haralick, Shanmugam and Dinstein, 1973).

Um exemplo é o trabalho de Dos Reis *et al.*, 2020 que obteve melhores resultados utilizando medidas de textura para estimar a AGB e CH comparadas ao desempenho obtido usando apenas bandas espectrais ou índices de vegetação. O modelo utilizou o XGBoost baseados apenas em medidas de textura e alcançou precisão moderadamente alta para prever AGB e CH de pastagem, explicando 65% e 89% da variabilidade de AGB (RMSE = 26,52%) e CH (RMSE = 20,94%), respectivamente. Este estudo demonstrou o potencial do uso de medidas de textura para melhorar a precisão da previsão de modelos AGB e CH baseados em dados de imagens de satélite (PlanetScope) de alta resolução espaço-temporal em pastagens mistas intensivamente manejadas.

2.7. Modelagem da biomassa

O Extreme Gradient Boosting (XGBoost) foi proposto por Chen et al. (2016) e opera criando uma série de árvores de decisão sequencialmente com base na ideia de "boosting", que combina todas as previsões de um conjunto de aprendizes fracos para desenvolver um aprendiz forte por meio de estratégias de treinamento aditivas. O algoritmo XGBoost tem a função de controlar a complexidade da árvore para obter um modelo simples e evitar o overfitting. Em resumo, é um modelo de aprimoramento de estrutura de árvore flexível e altamente escalável que pode lidar com dados esparsos, melhorar significativamente a velocidade do algoritmo e reduzir a memória computacional no treinamento de dados em grande escala. (Chen e Guestrin, 2016)

O ajuste dos hiperparâmetros do modelo XGBoost é crucial, pois alterar qualquer um dos parâmetros pode afetar os valores ótimos dos outros. Portanto, a maioria dos estudos anteriores utilizou o valor padrão dos parâmetros para modelagem, e poucos estudos descreveram os detalhes do processo de ajuste dos parâmetros do XGBoost. Em nosso estudo, os seguintes parâmetros foram ajustados para melhorar o desempenho dos modelos XGBoost: 1) nrounds, que é o número máximo de iterações de impulso; 2) eta, que controla a taxa de aprendizado (é usado durante a atualização para evitar o overfitting); 3) gamma é a redução mínima da perda necessária para fazer uma partição adicional em um nó folha da árvore (controla a regularização ou evita o overfitting); 4) max_depth é a profundidade máxima de uma árvore individual (controla a profundidade da árvore); 5) min_child_weight, na regressão, refere-se ao número mínimo de instâncias necessárias em um nó filho; 6) subsample controla o número de amostras (observações) fornecidas a uma árvore) e; 7) colsample_bytree controla o número de características (variáveis) fornecidas a uma árvore.

Em Xie *et al.*, (2009), os autores estimaram a biomassa seca acima do solo na área de Xilingol, na Mongólia Interior, China, usando modelos de redes neurais artificiais, regressão linear múltipla e dados coletados das imagens Landsat 7 ETM +, e encontraram uma relação direta entre NDVI e biomassa. Para ambos os modelos, os mesmos conjuntos de treinamento e testes foram utilizados para garantir a comparabilidade dos resultados, e as redes neurais artificiais tiveram melhor desempenho, mesmo em pastagens onde as variáveis de diagnóstico para biomassa eram ruins e os dados eram ruidosos. Este estudo mostrou que os valores de biomassa modelados por redes neurais artificiais estavam mais próximos dos observados in situ.

Em Zhou *et al.* (2016), estimativa de biomassa de trigo usando 15 índices de vegetação e RF como um algoritmo de aprendizado de máquina; o objetivo principal foi investigar a aplicabilidade do algoritmo de regressão de RF para estimar remotamente a biomassa de trigo, além de testar o desempenho do modelo de regressão de RF e depois compará-lo com os algoritmos de aprendizagem de máquina de regressão de vetores de suporte (Suport Vector Regression - SVR) e de rede neurais artificiais. A biomassa in situ do trigo foi medida durante a aquisição de dados do dispositivo acoplado a carga de satélite HJ (HJ-CCD). Os resultados mostraram que o modelo de RF produziu estimativas mais precisas de biomassa de trigo do que os modelos SVR e ANN (rede neural artificial) em cada estágio, e sua robustez é tão boa quanto SVR, mas melhor que a RNA. Os autores concluíram que o algoritmo RF fornece uma ferramenta preditiva e exploratória útil para estimar a biomassa de trigo em larga escala no sul da China.

2.7.1. Seleção de atributos

A seleção de atributos é uma etapa crucial em análises de dados e modelagem, desempenhando um papel essencial na melhoria da eficiência e desempenho dos modelos. Este processo envolve a escolha criteriosa de variáveis ou características relevantes para o problema em questão, com o objetivo de reduzir a dimensionalidade dos dados, eliminar redundâncias e, consequentemente, aprimorar a precisão e interpretabilidade do modelo (Chandrashekar e Sahin, 2014). Ao identificar os atributos mais informativos, a seleção de atributos não apenas acelera a computação, mas também ajuda a evitar o overfitting do modelo, contribuindo para modelos mais robustos e generalizáveis. Diversas técnicas são empregadas nesse contexto, incluindo métodos estatísticos, algoritmos de aprendizado de máquina e abordagens heurísticas, cada uma adaptada às particularidades do conjunto de dados e aos objetivos específicos da análise. A seleção de atributos desempenha, assim, um papel fundamental na otimização da eficácia de modelos analíticos, proporcionando uma abordagem mais focada e precisa para a interpretação e predição de padrões nos dados (Liu e Motoda, 1998).

Há dois métodos muito utilizados, o Random Forest (RF), quando utilizado como método de seleção de atributos, destaca-se como uma abordagem poderosa e versátil. Este algoritmo de aprendizado de máquina utiliza uma floresta de árvores de decisão, treinadas em subconjuntos aleatórios do conjunto de dados, para realizar a seleção de atributos. Cada árvore contribui com uma opinião sobre a importância de cada variável, e ao final, o RF combina essas contribuições para determinar a relevância global de cada atributo. Essa técnica é particularmente valiosa para identificar características significativas em conjuntos de dados complexos, onde a relação entre variáveis pode ser não linear ou interdependente. Além disso, o RF é eficaz na gestão de overfitting, tornando-o robusto para aplicações em conjuntos de dados de diferentes naturezas. Sua capacidade de avaliar a importância relativa dos atributos aprimora a compreensão do impacto de cada variável no processo de tomada de decisões, contribuindo significativamente para a seleção eficiente de atributos em tarefas analíticas e de modelagem (Bocca e Rodrigues, 2016).

Já o algoritmo genético (Genetic Algorithm - GA) destaca-se como uma abordagem eficaz e inspirada em processos biológicos para a seleção de atributos em conjuntos de dados complexos. Este método de otimização utiliza uma abordagem evolutiva, simulando processos de seleção natural, recombinação genética e mutação para encontrar subconjuntos de atributos que otimizam a performance do modelo (Papa, 2002). No contexto da seleção de atributos, os indivíduos na população do GA representam diferentes conjuntos de atributos, sendo avaliados quanto à sua aptidão com base em critérios predefinidos, como a precisão do modelo. Os melhores indivíduos são então selecionados para cruzamento e mutação, gerando novas gerações de subconjuntos de atributos. Esse ciclo evolutivo é repetido até que um critério de parada seja atingido. O GA é particularmente vantajoso em espaços de busca extensos e não lineares, oferecendo uma solução adaptativa que pode lidar com complexidades e inter-relações entre variáveis. Sua capacidade de explorar eficientemente o espaço de soluções o torna uma ferramenta valiosa para a seleção de atributos em tarefas de modelagem e análise de dados (Goldberg, 1989).

Ambos os métodos oferecem flexibilidade e adaptabilidade, sendo a escolha entre eles muitas vezes dependente da natureza específica do problema, da estrutura dos dados e dos objetivos da modelagem.

3. ARTIGO

3.1. Estimation of spatio-temporal variability of pasture aboveground biomass and height in integrated systems using Sentinel-2 images

ABSTRACT

In Brazil, accurately and efficiently evaluating pasture productivity is crucial, particularly given government incentives for sustainable farming practices. Integrated crop-livestock systems (ICLS) offer a promising approach to rejuvenating degraded pastures and enhancing productivity. Accurate measurements of pasture biomass and height are vital for evaluating the effectiveness of grazing systems, allowing agricultural managers to fine-tune animal feeding strategies. Real-time biomass estimates facilitate the adjustment of stocking rates, improving pasture utilization and overall productivity. Spatial variations in biomass production can inform pasture management decisions, guiding strategies to optimize grazing in areas with ample forage. Remote sensing techniques are essential for delivering valuable data on the spatial and temporal characteristics of pastures and estimating biomass. The objective of this study was to estimate pasture biomass in an integrated crop-livestock system using Sentinel-2 images. To achieve this, we analyzed various variables, including spectral bands, vegetation indices, and texture measurements from Sentinel-2 images. We identified the most appropriate features to estimate and explain the temporal and spatial variability of biomass and pasture height. Subsequently, we created maps depicting the spatio-temporal variability of biomass and pasture height. This research evaluated different scenarios (S1 to S4) to estimate above-ground dry biomass (AGB) and canopy height (CH), utilizing various sets of features and attribute selection techniques. The findings suggest that, before testing with Genetic Algorithm (GA), the best combination included spectral bands, vegetation indices and texture measurements optimized for AGB, while vegetation indices were highlighted for CH prediction. After optimization with GA, scenario S1, with texture measurements optimized for AGB, and S2, emphasizing spectral bands for CH, demonstrated greater accuracy. Our results highlight the potential of using GLCM-based texture measurements (S1) to obtain improved accuracies in AGB prediction (RMSE = 32.74%; R2 = 0.53) and for CH prediction the best model was S2 (RMSE = 11.91%; R2 = 0.57). Finally, maps of spatio-temporal variations in AGB and CH of the pasture throughout the forage growing season were created. They were obtained with the best performing XGBoost models using texture measurements for AGB and spectral bands for CH. We proved in this study that GLCM-based texture measurements, derived from Sentinel-2 images, improved the accuracy in predicting AGB models and for CH the best predictive models were achieved using spectral bands.

Keywords: ICLS; texture measurements; vegetation index; extreme gradient boosting; pastagem mista.

3.1.1. Introduction

In Brazil, the identification, quantification, and monitoring of pasture productivity are topics of great interest since there are incentives from the federal government to apply techniques that promote greater sustainability of agricultural production, such as the "Programa Agricultura de Baixo Carbono" (ABC and ABC+ Program), which provides incentives for technological processes that reduce greenhouse gas emissions and promote the intensification and sustainable use of the Brazilian natural resource base (Sá *et al.*, 2017). In this context, Integrated Crop-Livestock Systems (ICLS) are promising for recovering degraded pasture areas and increasing the productivity of these pasturelands (Duarte *et al.*, 2018). The implantation of ICLS are an important productive development tool that, when well implemented, can bring many benefits to the involved segments (Duarte *et al.*, 2018).

Accurate measurements of pasture biomass and height are essential to measure the increase in pasture production of a grazing system by producers, thus allowing farm managers to adjust their animals' feeding needs better (Andersson *et al.*, 2017). Therefore, real-time biomass estimates contribute to the optimization of grazing strategies, allowing producers to adjust field stocking rates according to the actual productivity of the area, resulting in increased pasture utilization and subsequently increasing pasture growth rates along with overall productivity (Schaefer and Lamb, 2016).

The characterization of spatial differences in biomass production may benefit pasture management decisions in order to create strategies for animals to graze in places where there is a higher forage supply (Ali *et al.*, 2016). Therefore, new methodological approaches that characterize the horizontal structure of the pasture should be investigated.

Remote sensing techniques have been essential in providing valuable information for assessing vegetation conditions, assisting in decision-making aimed at improving local production systems (Manabe, Melo and Rocha, 2018). Due to the synoptic, multispectral and revisit characteristics of the satellites, remote sensing imagery allow obtaining fundamental information for the spatial and temporal characterization of pastures, as well as the estimation of biomass during forage development using remotely sensed data (Barrachina, Cristóbal and Tulla, 2015; Otgonbayar *et al.*, 2019). Compared to traditional field measurement methods, only remote sensing techniques allow the estimation of above-ground biomass at fine temporal scales and extensive spatial extensions (Lu, 2006), wherefore explaining the increasing application of remote sensing data for estimation of pastures biomass.

Pasture growth monitoring through remote sensing requires images collected with a high temporal resolution. However, according to Manabe, Melo and Rocha (2018), monitoring pasture biomass using time series data is not a simple process, involving several factors, such as the interpreter's experience, knowledge of the study areas, the temporal signature of the targets, as well as the methodology used. In addition to these limitations raised by the authors, it is still necessary to take into consideration that the animals will be grazing in the area at different times. When one paddock is being grazed, the other has not yet had the animal's entrance or would have been grazed (paddock rotation), thus causing a differentiated pixel response in the remotely sensed images. Another challenge is the spectral mixing of objects, especially in cases with consortium systems, when there is mixed grass (Brachiaria) and millet pasture, which may result in different spectral responses of the two crops.

Currently, the most advanced biomass estimation methods using remote sensing images make use of machine learning (ML) algorithms (Otgonbayar *et al.*, 2019). These algorithms are capable of managing large numbers of data as well as combining data from different sources and integrating large amount of information for predicting variables of interest. Some studies have shown that the combination of spectral responses and image textures improves biomass estimation performance (Lu, 2006).

The estimation of biomass, either crop or forage, is already well studied by the scientific community, but there is still the challenge to develop viable methodologies for biomass estimation in ICLS areas that are planted in rotation (forage and crop), taking into consideration not only the spatial variability of the pastures but also biomass temporal variability which is an important variable for producer planning.

This study aimed to estimate aboveground pasture biomass and height in an integrated crop-livestock system (ICLS) using Sentinel-2 data. For this purpose, we tested different variables (spectral bands, vegetation indices, and texture measures) derived from Sentinel-2 images and selected the best potential features to estimate and explain the temporal and spatial variability of pasture biomass and height. Then, we created the spatio-temporal variability maps of pasture biomass and canopy height.

3.1.2. Materials and Methods

3.1.2.1. Study Area

The study area is located in the municipality of Caiuá, the western region of São Paulo State, more precisely at Campina Farm, in the central geographic coordinates of 21°38'15 "S and 51°54'57" O (Figure 1). This region is characterized by the alternation of dry and cold season (May to August) with hot and humid season (November to February). Rainfall is concentrated in December and January, while average annual rainfall ranges from 1,200 mm to 1,400 mm. The soil of the region is classified as red oxisol with a sandy texture (Rossi, 2017) and the climate is classified by Rolim *et al.* (2007) as Aw in the Köppen classification scheme.

The study area was divided into four fields of approximately 50 ha each (200 ha total). The four fields are split into 13 paddocks on which grazing livestock (cattle) are rotated among paddocks and fields throughout the season. In this region, a system known as ICLS has been implemented, involving the rotation of cultivated pasture during the winter months (typically from April to October), and soybean farming during the summer months (typically from November to March). The primary focus of this study is on the management of pasture within this system.

The pasture consists of a mixture of brachiaria (Urochloa ruziziensis) and millet (Pennisetum glaucum), with millet and brachiaria sown at a ratio of 15 kg.ha-1 and 5 kg.ha-1 respectively, with a row spacing of 17 cm. Both grass species exhibit agronomic traits such as fast growth, strong resistance to drought, and substantial production of dry matter. The consortium of millet with tropical forages has been used as a management strategy to increase biomass production during the winter season and to decrease the time interval between sowing and the first grazing events in the study area. Pasture sowing began on March 28th, after soybean harvest, and lasted until 6th April 2019.



Figure 1 - Location of the study area at Campina Farm, located in the municipality of Caiuá - SP – Brazil and sample points.

3.1.2.2. Field Data Collection

Throughout the growing season (from May to November 2019), data on aboveground biomass (AGB) and canopy height (CH) for pasture were gathered. This was accomplished using a sampling grid consisting of one hundred randomly placed sampling points within the study area, at a sampling intensity of 25 points per field. Data collection in the field occurred on six specific dates: May 17th, May 25th, June 18th, July 14th, August 12th, and November 2nd, 2019. The field campaigns of May (17 May and 25 May) occurred before the animal's entrance in the fields. The following field campaign dates (18 June, 14 July, 12 August, and 02 November 2019) were defined in order to capture different phases of pasture growth (millet and ruzi grass) and biomass availability, as well as in function of the entry and exit of animals in the paddocks. Although we intended to collect field data in all the sampling points, we were not allowed because of the animal presence in some paddocks or even the entire study area in the months of September and October.

The farm manager defined the rotational grazing system, dates of entrance and exit of the animals in the paddocks. In the months of May and June, the area was covered by millet,

when occurred the first grazing cycle. In July, all the area was out of animals, allowing the growth of forage, especially ruzi grass. Then in August, when the ruzi grass reached an adequate level of coverage, the animals were allocated in the fields at a lower stocking rate and stayed there until the beginning of November. More detailed field management can be found in Silva et al. (2021).

The aboveground biomass (AGB) of pasture was assessed through destructive sampling within 1 m² frames, and immediately weighed using a hanging scale. Subsequently, the brachiaria and millet components were separated and weighed individually. To ascertain the dry mass (g.m-2), the fresh biomass of both brachiaria and millet was subjected to a 72-hour drying process at 65°C in the laboratory. Subsequently, the specimens were weighed to determine the overall aboveground biomass (AGB) per sampling point and field campaign. Canopy height (CH) data were collected using a Sward Stick at 11 selected locations within a 5-meter buffer zone, with each sampling point's centroid as the reference position. To derive the average canopy height, a weighted mean height was calculated, considering the proportion of millet to ruzi grass at each sampling point. The ratio of millet at a given sampling point was calculated by dividing the dry mass weight of millet by the total weight of aboveground biomass (AGB) at that point. Similarly, the proportion of ruzi grass at each sampling point. The field-based descriptive statistics for the pasture under study are summarized in Table 1.

	Field	Field- Proportion of		Descriptive statistics					
Variable	campaign	sampled points	Millet:Brachia ria (%)	Minimum	Maximim	Mean	Standard Derivation	CV(%)	
	May	99	79:21	70.33	656.08	209.53	10.82	5.16	
	June	49	44:56	61.58	259.02	136.75	54.91	40.15	
AGB	July	97	14:86	41.08	241.99	106.95	39.05	36.51	
(g.m ⁻²)	August	37	03:97	86.85	336.3	162.61	53.68	33.01	
	November	56	0:100	107.30	401.10	202.19	65.26	32.28	
	All data	338	-	41.08	656.08	163.19	81.97	50.23	
	May	99	79:21	37	120	82	16	19.52	
	June	49	44:56	22	57	33	10	29.77	
	July	97	14:86	14	68	29	10	34.32	
CH (cm)	August	37	03:97	16	38	27	6	23.44	
	November	56	0:100	12	37	20	5	24.50	
	All data	338	-	12	120	43	27	63.34	

Table 1 - Descriptive statistics of the pasture AGB and CH based on the five field campaigns.

3.1.3. Remote Sensing Data Collection and Preprocessing

Sentinel-2 multispectral images were acquired from the European Space Agency (ESA) database for the entire analysis period, from March to October - 2019 corresponding also to the in-situ data collection periods. All the images were submitted to atmospheric correction, and the surface reflectance values were obtained in the different spectral bands.

Sentinel-2 is a multi-spectral imaging (MSI) mission with rich spectral information covering 13 spectral bands from the Visible (V) and Near Infra-Red (NIR) to the Short Wave Infra-Red (SWIR): four bands have a spatial resolution of 10 m (blue (B): 490 nm, green (G): 560 nm, red (R): 665 nm and near-infrared (NIR): 842 nm); six bands have a spatial resolution of 20 m (red edge 1(RE1): 705 nm, red edge 2 (RE2): 740 nm, red edge 3 (RE3): 783 nm, red edge 4 (RE4): 865 nm, SWIR1: 1610 nm and SWIR2: 2190 nm); and three bands have a spatial resolution of 60 m spatial resolution (coastal aerosol: 443 nm, water vapor: 940 nm and SWIR cirrus: 1375 nm), spanning wavelengths from 0.4 to 2.2 μ m from the visible region to the shortwave infrared region. The width of the orbital strip is 290 km (ESA, 2019).

The Sentinel-2 complete mission comprises 2 equal satellites in the same orbit, with an angle of 180 ° to each other. The satellite provides data with a temporal resolution of 10 days at the equator with one satellite and 5 days with 2 satellites in cloudless conditions.

For this study we selected 10 bands of Sentinel-2, excluding bands 1, 9, and 10, as they mainly relate to atmosphere and water elements.

3.1.3.1. Vegetation Indices

In addition, for a better characterization of pasture AGB and CH spatial and temporal variability, some vegetation indices were calculated from the spectral bands of Sentinel-2 images, as described in Table 4. In total, 73 vegetation indices have been selected and extracted using sen2r package (appendix).

3.1.3.2. Texture Measures

Texture measures are widely used to denote the differences in vegetation areas with similar reflectance, since they can provide the essential information about spatial orders of color patterns or reflectance intensity of the vegetation (Haralick, Shanmugam e Dinstein, 1973).

In this study the Grey Level Co-occurrence Matrix (GLCM) statistical texture approach (Haralick, Shanmugam e Dinstein, 1973) was used to generate the texture images. The definition of GLCM is basically a tabulation of how often different combinations of pixel brightness values (grey levels) occur in an image. This statistical approach is used for a series of "second order" texture calculations, which means that they consider the relationship between groups of two pixels in the original image (Haralick, Shanmugam e Dinstein, 1973).

We calculated eight second-order GLCM texture measures (mean (MEA), variance (VAR), homogeneity (HOM), contrast (CON), dissimilarity (DIS), entropy (ENT), second moment (2M), and correlation (COR)) considering nine Sentinel-2 spectral bands (G, R, NIR, RE1, RE2, RE3, RE4, SWIR1, and SWIR2) using ENVI/IDL software (ENVI/IDL software (Harris Geospatial Solutions, Inc., Broomfield).

The textures calculation was performed based on angular orientation adjustments between the image pixels, window size and displacement, which can result in different measurements for the same textural parameters. Therefore, test with different adjustments are recommended (Haralick, Shanmugam e Dinstein, 1973) to determine the optimal window size for accurate AGB/CH estimation, all texture measures were calculated for each Sentinel-2 spectral bands using tree window sizes: 3×3 , 5×5 and 7×7 . For each window size, the texture measures were also calculated at five offsets, 0° , 45° , 90° , 135° and the fifth one called "Invariant". The "Invariant" spatial direction is nothing more than the average of the four offsets mentioned before (0° , 45° , 90° and 135°) (Hall, 2017).

3.1.3.3. Feature Selection

With the intention of reducing the database and information redundancy due to the large amount of data provided by remote sensing, a selection of attributes was tested. Some feature selection approaches for the same database were initially tested, being the best performing genetic algorithm, even with a higher computational cost than the others.

The Genetic Algorithm (GA) is an algorithm that consists of a series of genetic operations, such as selection and crossover, which are mutations, to generation of groups which are gradually evolved to be included or become close to the optimal solution. GA, uses the Wrapper selection methodology and the same approach is used in Zhou *et al.* (2018).

This method is considered more robust, as it explores a large number of attributes (Papa, 2002). Furthermore, it is able to explore nonlinear interactions between all attributes (Goldberg, 1989). To apply this methodology, the 'Caret' R package was used.

3.1.3.4. Machine Learning Algorithm

The Extreme Gradient Boosting (XGBoost) was proposed by Chen e Guestrin (2016) and it works creating a number of decision trees sequentially based on the idea of "boosting", combining all the predictions of a set of weak learners to develop a strong learner through additive training approach. The XGBoost algorithm aim function to control the complexity of the tree obtaining a basic model and avoid overfitting. The XGBoost, is a flexible and scalable tree structure enhancement model which deals with sparse data, improve algorithm speed, and reduce computational cost in very large-scale data training (Chen and Guestrin, 2016).

Fine-tuning the XGBoost model is essential due to the interdependence of its parameters, where altering one can influence the optimal settings of others. Consequently, many past studies have relied on default parameter values, with only a handful providing insight into the intricacies of the XGBoost parameter tuning process.

In our study, the following parameters were tuned to improve the performance of the XGBoost models: 1) *nrounds*, which is the maximum number of boosting iterations; 2) *eta*, it controls the learning rate (is used during updating to prevent overfitting); 3) *gamma* is the minimum loss reduction required to make a further partition on a leaf node of the tree (it controls regularization or prevents overfitting); 4) *max_depth* is the maximum depth of an individual tree (it controls the depth of the tree); 5) *min_child_weight*, in regression, it refers to the minimum number of instances required in a child node; 6) *subsample*, it controls the number of

samples (observations) supplied to a tree) and; 7) *colsample_bytree*, it controls the number of features (variables) supplied to a tree.

The random search approach was used to find the best combination of parameters. The range of parameters for searching the best combination set is as follows: *nround* is from 50 to 200; *eta* is from 0.01 to 0.3; *gamma* is from 0 to 0.4; *max_depth* is from 3 to 10; *min_child_weight* is from 1 to 10; *subsample* is from 0.5 to 1 and *colsample_bytree* is from 0.5 to 1.0. (Bergstra and Bengio, 2012)

3.1.3.5. Statistical Analysis

The coefficient of determination (R^2) (Formula 1), the mean absolute error (MAE) (Formula 2), and the root-mean-square error (RMSE, in absolute and percentage terms) (Formula 3) were calculated to assess the quality of the XGBoost models:

The best AGB and CH models were used to create prediction spatio-temporal variability maps for all the months studied.

$$R^{2} = 1 - \frac{\sum_{i=1}^{n} (y_{i} - \hat{y}_{i})^{2}}{\sum_{i=1}^{n} (y_{i} - \bar{y})^{2}}$$
[1]
$$MAE = \frac{1}{n} \sum_{i=1}^{n} |Y_{i} - \hat{Y}_{i}|$$
[2]
$$RMSE = \sqrt{\sum_{i=1}^{n} \frac{(\hat{y}_{i} - y_{i})^{2}}{n}}$$
[3]

3.1.3.6. Scenarios for the data analysis

In this study, four scenarios were used to predict the results. In Scenario 1 (S1) we used the optimum texture measures; in Scenario 2 (S2) only the spectral bands were used; the Scenario 3 (S3) used all the vegetation indices and Scenario 4 (S4) used the combination of spectral bands, vegetation indices, and the optimum texture measures using the XGBoost

regression algorithms. Each scenario was optimized by using the GA as feature selection method.

3.1.4. Results

For the textures, the window size and offset (orientation) parameters were compared and the best performing combination were chosen (Table 2).

Table 2 - Performance of Sentinel-2 derived texture measures in predicting pasture AGB and CH using the Extreme Gradient Boosting regression algorithm based on the validation datasets. The best performing combination of texture parameters are highlighted in boldface.

Window	Offsets		AG	B			C	н	
sizes	(θ)	RMSE	RMSE (%)	R ²	MAE	RMSE	RMSE (%)	R ²	MAE
	0°	54.76	34.46	0.47	42.42	12.81	29.57	0.77	9.09
22	45°	57.53	36.21	0.43	45.08	12.87	29.7	0.77	8.75
383	90°	54.62	34.38	0.48	42.17	11.63	26.85	0.81	7.93
	135°	53.65	33.77	0.51	42.77	11.97	27.62	0.80	8.48
	Invar	54.89	34.55	0.47	42.64	12.28	28.35	0.79	8.80
	0°	59.55	37.48	0.38	44.44	13.07	30.16	0.76	9.38
55	45°	67.87	42.72	0.25	51.17	12.27	28.33	0.79	8.55
585	90°	60.46	38.05	0.37	48.08	12.01	27.73	0.8	8.37
	135°	57.63	36.27	0.42	45.71	12.69	29.28	0.77	8.89
	Invar	62.81	39.53	0.32	49.25	12.29	28.36	0.79	8.29
	0°	66.14	41.63	0.26	50.59	13.09	30.2	0.76	9.49
77	45°	63.64	40.06	0.31	47.83	12.60	29.08	0.78	8.75
/x/	90°	61.54	38.74	0.34	47.24	13.29	30.68	0.75	9.29
	135°	59.84	37.66	0.37	47.57	12.75	29.42	0.77	8.89
	Invar	62.75	39.49	0.32	48.00	13.13	30.3	0.76	8.99

In general, for both AGB and CH the highest prediction accuracies were achieved when we used the 3x3 window size. For estimation of AGB the best offset was 135° and for the CH, 90°. The results of the four scenarios are shown below (Table 3):

Table 3 - Accuracy assessment of pasture aboveground biomass (AGB) and canopy height (CH) based on different scenarios with and without using feature selection: S1: the optimum texture measures; S2: spectral bands; S3: the vegetation indices, and S4 the combination of spectral bands, vegetation indices, and the optimum texture measures using the extreme gradient boosting (XGBoost) regression algorithms. The best performing models are highlighted in boldface.

			AGB (g.m-	-2)			CH (cm)		
Scenario		RMSE (g m)	RMSE (%)	R ²	MAE	RMSE (cm)	RMSE (%)	R ²	MAE
S1		53.65	33.77	0.51	42.77	11.63	26.85	0.81	7.93
S2	Without	56.57	35.61	0.44	45.15	11.97	27.64	0.80	8.52
S3	Selection	54.41	34.24	0.48	42.54	10.60	24.46	0.84	7.76
S4	~	53.10	33.42	0.52	41.07	11.00	25.40	0.83	7.29
S1FS		52.02	32.74	0.53	41.13	12.14	28.03	0.79	8.43
S2FS	With	61.55	38.74	0.38	46.72	5.14	11.91	0.97	3.67
S3FS	Feature Selection	54.57	34.35	0.48	43.36	10.26	23.68	0.85	7.36
S4FS		52.39	32.98	0.52	39.43	10.57	24.4	0.84	7.27

Before testing the feature selection adoption using GA, the best scenario was the combination of spectral bands, vegetation indices, and the optimum texture measures for AGB and the vegetation indices for CH. After the optimization using GA, the higher accuracy became the S1FS, using the optimum texture measures for AGB and S2FS using the spectral bands for CH prediction. The predictions of AGB and CH using the best model are shown below (Figure 2). For AGB (Figure 3(a)), the best model was using textures and for CH (Figure 3(b)) using the spectral bands of Sentinel-2.

Figure 2 - Scatterplots using the best extreme gradient boosting (XGBoost) models based on the testing dataset of the predicted versus measured values of pasture aboveground biomass (AGB, $g.m^{-2}$) (a) and canopy height (CH, cm) (b).



The maps of spatiotemporal variations in pasture AGB and CH through the forage growing season are shown below (Figures 3 and 4). The maps were obtained with the best-performing XGBoost models using the optimum texture measures for AGB (Figure 3) and the spectral bands for CH (Figure 4). Predicted AGB varied from 62 to 438 g.m⁻². For CH, the predicted values ranged from 14 to 106 cm.

Figure 3 - Pasture aboveground biomass (AGB) spatial maps predicted by the best extreme gradient boosting (XGBoost) model for the study area in the months of May (a and b), June (c), July (d), August (e), and November (f).



Figure 4 - Pasture canopy height (CH) spatial maps predicted by the best extreme gradient boosting (XGBoost) model for the study area in the months of May (a and b), June (c), July (d), August (e), and November (f).



3.1.5. Discussion

In this study, we demonstrated that Sentinel-2 could estimate aboveground pasture biomass and height in an integrated crop-livestock system (ICLS) by using the optimum texture measures for AGB and the spectral bands for CH. The spectral and textural information derived from Sentinel-2 imagery was exploited to estimate aboveground biomass (AGB) and canopy height (CH) in intensively managed fields using the machine learning algorithm XGBoost. Our research results indicate that, in general, the best prediction accuracies for the AGB and CH were achieved with the 3x3 window size. For AGB estimation, the best offset was 135°, while for CH it was 90°.

Detailed results for different window sizes and offsets are provided, highlighting the RMSE, RMSE (%), R2 and MAE for each scenario. These results can provide important insights for the selection of parameters and strategies in future analyzes and applications. The results indicate that, before testing with Genetic Algorithm (GA), the best combination included spectral bands, vegetation indices and optimal texture measurements for AGB, while vegetation indices generated the best performance CH prediction. After optimization the GA feature selection approach, scenario S1FS, with optimal texture measurements for AGB, and S2FS, exploiting the spectral bands for CH, demonstrated greater accuracy.

Our results highlight the potential of using GLCM-based texture measurements (S1FS) to obtain improved accuracies in AGB prediction (RMSE = 32.74%; R2 = 0.53) and the

spectral bands of Sentinel-2 for CH prediction (RMSE = 11.91%; R2 = 0.57) (Table 3). The integration of texture measurements with spectral bands and vegetation indices (S4FS) did not result in improvements in AGB and CH prediction accuracies.

In Werner et al. 2023, temporal profiles of NDVI were extracted from three distinct sensors (PlanetScope, Sentinel-2, and MODIS) over the course of the pasture's growing season within an ICLS region. The study revealed that all sensors successfully captured fluctuations in the phenological stages of pasture growth and the management activities within the paddocks in the surveyed area. Among them and considering the typical size of the paddocks, the availability of free data and the spatial resolution of the images, Sentinel-2/MSI showed great potential to support pasture monitoring and the assessment of the spatial variability of biomass in areas grazed by ICLS.

Reis *et al.* 2020 found that texture measurements improved AGB and CH estimates compared to performance obtained using only spectral bands or vegetation indices derived from PlanetScope images. The best results were found using XGBoost models based only on texture measurements. These models achieved moderately high accuracy for predicting pasture AGB and CH, explaining 65% and 89% of AGB (RMSE = 26.52%) and CH (RMSE = 20.94%) variability, respectively. This study demonstrated the high potential of using texture measurements to improve the prediction accuracy of AGB and CH models based on high spatiotemporal resolution PlanetScope data in intensively managed mixed pasture fields. Additionally, our findings, in conjunction with those of Reis et al. (2020), underscore the importance of spatial resolution in image data, highlighting that as spatial resolution increases, so does the potential of employing texture measures to enhance AGB estimation accuracy in pasture fields.

Freitas *et al*, 2021 showed that to estimate pasture biomass, good results using the simplest models, which explored only spectral bands and vegetation indices, were always surpassed in performance (\mathbb{R}^2) by at least one model in which texture variables were added, in all feature selection approaches tested, highlighting the importance of using feature selection to exclude high correlated and redundant predictor variables. In his study, the best models based on texture measures used feature selection approaches based on correlation, Correlation (C09) and Correlation Feature Selection (CFS), obtained an increase of 14.5% performance compared to the simplest model BDIV (total available bands and IVs), indicating that many indices and textures presented similar information. The highlight goes to the CFS method, which, when considering the contribution to the predictive power, proved to be more effective, especially in models built with few instances. Although in our study we used a different feature selection

approach, the GA is a robust method that has demonstrated significant efficacy in various domains within the literature, e.g., its ability to efficiently search through large feature spaces and identify optimal subsets has been widely acknowledged, showcasing its versatility and effectiveness in addressing complex optimization problems. Simplifying models by reducing variables is considered beneficial, especially when based on criteria of predictive power of the information.

3.1.6. Conclusion

Overall, we demonstrated that across all scenarios tested, GLCM-based texture measurements derived from Sentinel-2 imagery improved the accuracy in predicting the best above-ground dry biomass (AGB) and canopy height models. (CH) better predictive models were obtained using spectral bands. Finally, maps of spatio-temporal variations in AGB and CH of the pasture were created throughout the forage cultivation period. They were obtained with the best performing XGBoost models, i.e. using the texture measurements for AGB and the spectral bands derived from Sentinel-2 for CH.

3.1.7. Attachment

Table 4: Vegetation indices list.

Abbreviation	Vegetation Indices	Source	Sentinel-2 Formula
ATSAVI	Adjusted transformed soil-adjusted VI	http://www.indexdatabase.de/db/i- single.php?id=209	1.22*(band_8-1.22*band_4- 0.03)/(1.22*band_8+band_4- 1.22*0.03+0.08*(1+power(1.22,2)))
ARVI	Atmospherically Resistant Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=4	(band_8-band_4-1*(band_4- band_2))/(band_8+band_4-1*(band_4- band_2))
ARVI2	Atmospherically Resistant Vegetation Index 2	http://www.indexdatabase.de/db/i- single.php?id=396	-0.18+1.17*((band_8- band_4)/(band_8+band_4))
BWDRVI	Blue-wide dynamic range vegetation index	http://www.indexdatabase.de/db/i- single.php?id=136	(0.1*band_8- band_2)/(0.1*band_8+band_2)
BRI	Browning Reflectance Index	http://www.indexdatabase.de/db/i- single.php?id=480	((1)/(band_3)-(1)/(band_5))/(band_8)
CARI	Chlorophyll Absorption Ratio Index	http://www.indexdatabase.de/db/i- single.php?id=142	((band_5)/(band_4))*(sqrt(power(((band_ 5-band_3)/(150)*670+band_4+(band_3- ((band_5- band_3)/(150)*550))),2)))/(power(((band_ _5-band_3)/(power(150,2))+1),0.5))
Chlgreen	Chlorophyll Green	http://www.indexdatabase.de/db/i- single.php?id=251	power(((band_7)/(band_3)),(-1))
CIgreen	Chlorophyll Index Green	http://www.indexdatabase.de/db/i- single.php?id=128	(band_8)/(band_3)-1
CIrededge	Chlorophyll IndexRedEdge	http://www.indexdatabase.de/db/i- single.php?id=131	(band_8)/(band_5)-1
Chlred-edge	Chlorophyll Red-Edge	http://www.indexdatabase.de/db/i- single.php?id=252	power(((band_7)/(band_5)),(-1))
CVI	Chlorophyll vegetation index	http://www.indexdatabase.de/db/i- single.php?id=391	band_8*(band_4)/(power(band_3,2))
CI	Coloration Index	http://www.indexdatabase.de/db/i- single.php?id=11	(band_4-band_2)/(band_4)
Datt1	Datt1	http://www.indexdatabase.de/db/i- single.php?id=150	(band_8-band_5)/(band_8-band_4)

Datt4	Datt4	http://www.indexdatabase.de/db/i- single.php?id=153	(band_4)/(band_3*band_5)
GDVI	Difference NIR/Green Green Difference Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=27	band_8-band_3
DVIMSS	Differenced Vegetation Index MSS	http://www.indexdatabase.de/db/i- single.php?id=569	2.4*band_9-band_4
EVI	Enhanced Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=16	2.5*(band_8- band_4)/((band_8+6*band_4- 7.5*band_2)+1)
EVI2	Enhanced Vegetation Index 2 -2	http://www.indexdatabase.de/db/i- single.php?id=576	2.5*(band_8- band_4)/(band_8+2.4*band_4+1)
GVMI	Global Vegetation Moisture Index	http://www.indexdatabase.de/db/i- single.php?id=372	((band_8+0.1)- (band_12+0.02))/((band_8+0.1)+(band_1 2+0.02))
GARI	Green atmospherically resistant vegetation index	http://www.indexdatabase.de/db/i- single.php?id=363	(band_8-(band_3-(band_2- band_4)))/(band_8-(band_3+(band_2- band_4)))
GLI	Green leaf index	http://www.indexdatabase.de/db/i- single.php?id=375	(2*band_3-band_4- band_2)/(2*band_3+band_4+band_2)
GNDVI	Green Normalized Difference Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=28	(band_8-band_3)/(band_8+band_3)
GOSAVI	Green Optimized Soil Adjusted Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=29	(band_8-band_3)/(band_8+band_3+0.16)
GSAVI	Green Soil Adjusted Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=31	(band_8- band_3)/(band_8+band_3+0.5)*(1+0.5)
GBNDVI	Green-Blue NDVI	http://www.indexdatabase.de/db/i- single.php?id=186	(band_8- (band_3+band_2))/(band_8+(band_3+ban d_2))
GRNDVI	Green-Red NDVI	http://www.indexdatabase.de/db/i- single.php?id=185	(band_8- (band_3+band_4))/(band_8+(band_3+ban d_4))
IPVI	Infrared percentage vegetation index	http://www.indexdatabase.de/db/i- single.php?id=35	((band_8)/(band_8+band_4))/(2)*(((band _4-band_3)/(band_4+band_3))+1)
I	Intensity	http://www.indexdatabase.de/db/i- single.php?id=36_	((1)/(30.5))*(band_5+band_3+band_1)
LCI	Leaf Chlorophyll Index	http://www.indexdatabase.de/db/i- single.php?id=109	(band_8-band_5)/(band_8+band_4)

MCARI-MTVI2	MCARI/MTVI2	http://www.indexdatabase.de/db/i- single.php?id=197	(((band_5-band_4)-0.2*(band_5- band_3))*((band_5)/(band_4)))/((1.5*(1. 2*(band_8-band_3)-2.5*(band_4- band_3))/(sqrt(power((2*band_8+1),2)- (6*band_8-5*sqrt(band_4))-0.5))))
MGVI	Misra Green Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=571	-0.386*band_3- 0.530*band_4+0.535*band_6+0.532*ban d_9
MYVI	Misra Yellow Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=572	0.723*band_3- 0.597*band_4+0.206*band_6- 0.278*band_9
MCARI	Modified Chlorophyll Absorption in Reflectance Index	http://www.indexdatabase.de/db/i- single.php?id=41	((band_5-band_4)-0.2*(band_5- band_3))*((band_5)/(band_4))
MCARI1	Modified Chlorophyll Absorption in Reflectance Index 1	http://www.indexdatabase.de/db/i- single.php?id=42	1.2*(2.5*(band_8-band_4)-1.3*(band_8- band_3))
MCARI2	Modified Chlorophyll Absorption in Reflectance Index 2	http://www.indexdatabase.de/db/i- single.php?id=43	(1.5*(2.5*(band_8-band_4)-1.3*(band_8- band_3))/(sqrt(power((2*band_8+1),2)- (6*band_8-5*sqrt(band_4))-0.5)))
mNDVI	Modified NDVI	http://www.indexdatabase.de/db/i- single.php?id=164	(band_8-band_4)/(band_8+band_4- 2*band_1)
mSR	Modified Simple Ratio	http://www.indexdatabase.de/db/i- single.php?id=167	(band_8-band_1)/(band_4-band_1)
MSAVIhyper	Modified Soil Adjusted Vegetation Index hyper	http://www.indexdatabase.de/db/i- single.php?id=45	(0.5)*((2*band_8+1)- sqrt(power((2*band_8+1),2)-8*(band_8- band_4)))
MTVI1	Modified Triangular Vegetation Index 1	http://www.indexdatabase.de/db/i- single.php?id=46	1.2*(1.2*(band_8-band_3)-2.5*(band_4- band_3))
MTVI2	Modified Triangular Vegetation Index 2	http://www.indexdatabase.de/db/i- single.php?id=47	(1.5*(1.2*(band_8-band_3)-2.5*(band_4- band_3))/(sqrt(power((2*band_8+1),2)- (6*band_8-5*sqrt(band_4))-0.5)))
Norm G	Norm G	http://www.indexdatabase.de/db/i- single.php?id=50	(band_3)/(band_8+band_5+band_3)
Norm NIR	Norm NIR	http://www.indexdatabase.de/db/i- single.php?id=51	(band_8)/(band_8+band_5+band_3)
Norm R	Norm R	http://www.indexdatabase.de/db/i- single.php?id=52	(band_5)/(band_8+band_5+band_3)
NGRDI	Normalized Difference Green/Red Normalized green red difference index,	http://www.indexdatabase.de/db/i- single.php?id=390	(band_3-band_4)/(band_3+band_4)

	Visible Atmospherically Resistant Indices Green (VIgreen)		
BNDVI	Normalized Difference NIR/Blue Blue- normalized difference vegetation index	http://www.indexdatabase.de/db/i- single.php?id=135	(band_8-band_2)/(band_8+band_2)
NDVI	Normalized Difference NIR/Red Normalized Difference Vegetation Index, Calibrated NDVI - CDVI	http://www.indexdatabase.de/db/i- single.php?id=58	(band_8-band_4)/(band_8+band_4)
NDRE	Normalized Difference NIR/Rededge Normalized Difference Red-Edge	http://www.indexdatabase.de/db/i- single.php?id=223	(band_8-band_5)/(band_8+band_5)
RI	Normalized Difference Red/Green Redness Index	http://www.indexdatabase.de/db/i- single.php?id=74	(band_5-band_3)/(band_5+band_3)
OSAVI	Optimized Soil Adjusted Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=63	(1+0.16)*(band_8- band_4)/(band_8+band_4+0.16)
PNDVI	Pan NDVI	http://www.indexdatabase.de/db/i- single.php?id=188	(band_8- (band_3+band_4+band_2))/(band_8+(ban d_3+band_4+band_2))
Rededge1	Red edge 1	http://www.indexdatabase.de/db/i- single.php?id=335	(band_5)/(band_4)
Rededge2	Red edge 2	http://www.indexdatabase.de/db/i- single.php?id=336	(band_5-band_4)/(band_5+band_4)
RBNDVI	Red-Blue NDVI	http://www.indexdatabase.de/db/i- single.php?id=187	(band_8- (band_4+band_2))/(band_8+(band_4+ban d_2))
REP	Red-Edge Position Linear Interpolation	http://www.indexdatabase.de/db/i- single.php?id=196	700+40*(((band_4+band_7)/(2))- band_5)/(band_6-band_5)
RDVI	Renormalized Difference Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=76	(band_8-band_4)/(sqrt(band_8+band_4))
IF	Shape Index	http://www.indexdatabase.de/db/i- single.php?id=79	(2*band_5-band_3-band_1)/(band_3- band_1)
RDI	Simple Ratio MIR/NIR Ratio Drought Index	http://www.indexdatabase.de/db/i- single.php?id=71	(band_12)/(band_8)
SRMIR-Red	Simple Ratio MIR/Red Eisenhydroxid- Index	http://www.indexdatabase.de/db/i- single.php?id=14	(band_12)/(band_4)
SRNir-700-715	Simple Ratio NIR/700-715	http://www.indexdatabase.de/db/i- single.php?id=366	(band_8)/(band_5)
GRVI	Simple Ratio NIR/G Green Ratio Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=30	(band_8)/(band_3)

SRNIR-MIR	Simple Ratio NIR/MIR	http://www.indexdatabase.de/db/i- single.php?id=479	(band_8)/(band_12)
DVI	Simple Ratio NIR/RED Difference Vegetation Index, Vegetation Index Number (VIN)	http://www.indexdatabase.de/db/i- single.php?id=12	(band_8)/(band_4)
RRI1	Simple Ratio NIR/Rededge RedEdge Ratio Index 1	http://www.indexdatabase.de/db/i- single.php?id=132	(band_8)/(band_5)
SAVI	Soil Adjusted Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=87	(band_8- band_4)/(band_8+band_4+0.5)*(1+0.5)
SLAVI	Specific Leaf Area Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=89	(band_8)/(band_4+band_12)
SIPI3	Structure Intensive Pigment Index 3	http://www.indexdatabase.de/db/i- single.php?id=291	(band_8-band_2)/(band_8-band_4)
GVIMSS	Tasselled Cap - Green Vegetation Index MSS	http://www.indexdatabase.de/db/i- single.php?id=564	-0.283*band_3- 0.660*band_4+0.577*band_6+0.388*ban d_9
GVI	Tasselled Cap - vegetation	http://www.indexdatabase.de/db/i- single.php?id=92	-0.2848*band_2-0.2435*band_3- 0.5436*band_4+0.7243*band_8+0.0840* band_11-0.1800*band_12
WET	Tasselled Cap - wetness	http://www.indexdatabase.de/db/i- single.php?id=93	0.1509*band_2+0.1973*band_3+0.3279* band_4+0.3406*band_8- 0.7112*band_11-0.4572*band_12
TCARI	Transformed Chlorophyll Absorbtion Ratio	http://www.indexdatabase.de/db/i- single.php?id=96	3*((band_5-band_4)-0.2*(band_5- band_3)*((band_5)/(band_4)))
VARIrededge	Visible Atmospherically Resistant Indices RedEdge	http://www.indexdatabase.de/db/i- single.php?id=130	(band_5-band_4)/(band_5+band_4)
WDVI	Weighted Difference Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=104	band_8-(NIR soil/Red soil)*band_4
WDRVI	Wide Dynamic Range Vegetation Index	http://www.indexdatabase.de/db/i- single.php?id=125	(0.1*band_8- band_4)/(0.1*band_8+band_4)

4. CONSIDERAÇÕES FINAIS

Neste estudo, informações espectrais e texturais derivadas de imagens do Sentinel-2 foram exploradas para estimar a biomassa acima do solo (AGB) e a altura do dossel (CH) em pastagens de manejo intensivo em um sistema de integração lavoura-pecuária (ILP), utilizando o algoritmo de aprendizado de máquina XGBoost. Os resultados da pesquisa indicam que, as melhores performances na estimativa de AGB e CH foram alcançadas utilizando-se as medidas de textura derivadas das imagens Sentinel-2. Os melhores parâmetros para o cálculo da textura foram o tamanho de janela 3x3 tanto para AGB como para CH. Com relação ao offset, para a estimativa de AGB, o melhor offset foi 135°, enquanto para CH foi 90°.

Após avaliados diferentes cenários para a estimativa de AGB e CH, considerando diferentes conjuntos de variáveis espectrais (bandas espectrais, índices de vegetação, e medidas de textura) e a adoção de técnicas de seleção de atributos, de maneira geral, nossos resultados indicam que antes da utilização do Algoritmo Genético (GA) para seleção dos atributos mais relevantes para os modelos, a melhor combinação incluía bandas espectrais, índices de vegetação se destacaram para a estimativa de CH. Após a otimização das variáveis preditoras utilizando o GA, o cenário com medidas de textura otimizadas para AGB, e o cenário, utilizando as bandas espectrais para CH, demonstraram maior precisão, correspondendo aos modelos finais para a estimativa de AGB (RMSE = 32,74%; R2 = 0,53) e CH (RMSE = 11,91%; R2 = 0,57). Nossos resultados confirmam ainda a importância da utilização de algoritmos de seleção de atributos para excluir variáveis preditoras altamente correlacionadas e redundantes.

Assim, a metodologia desenvolvida neste trabalho destacou o potencial de estimar tanto a biomassa da pastagem quanto a altura, utilizando sensoriamento remoto. O uso de medidas de textura baseadas em GLCM para obter precisões aprimoradas na previsão de AGB ou o simples uso de bandas espectrais para predição da altura (CH) permitiu criar mapas de variabilidade espaço-temporal do desenvolvimento da pastagem e do pastejo durante a estação de crescimento da pastagem.

Demonstramos assim neste estudo, que as medidas de textura baseadas em GLCM, derivadas de imagens do Sentinel-2 , aprimoraram a precisão na estimativa de biomassa acima do solo (AGB) e para a altura do dossel (CH), os melhores resultados foram alcançados utilizando bandas espectrais das imagens do Sentinel-2. Os mapas de variações espaçotemporais no AGB e CH da pastagem ao longo da estação de crescimento da forragem nos permitem avaliar a disponibilidade espacial e temporal da pastagem para o pastejo, sendo uma ferramenta extremamente valiosa para os tomadores de decisão e gestores agrícolas.

REFERÊNCIAS BIBLIOGRÁFICAS

ALI, I. *et al.* Satellite remote sensing of grasslands: From observation to management. **Journal of Plant Ecology**, v. 9, n. 6, p. 649–671, 1 dez. 2016.

ALVES, B. J. R.; MADARI, B. E.; BODDEY, R. M. Integrated crop–livestock–forestry systems: prospects for a sustainable agricultural intensification. **Nutrient Cycling in Agroecosystems**, v. 108, n. 1, p. 1–4, maio 2017.

ANDERSSON, K. *et al.* Estimating pasture biomass with active optical sensors. Advances in Animal Biosciences, v. 8, n. 2, p. 754–757, jul. 2017.

Associação Brasileira das Indústrias Exportadoras de Carnes. ABIEC. 2022. Disponível em: https://www.abiec.com.br/publicacoes/beef-report-2022/. Acesso em 21 mar. 2024.

BALBINO, L. C.; BARCELLOS, A. O.; STONE, L. F. Marco referencial integração lavoura-pecuária-floresta / Reference document crop-livestock-forestry integration. Empresa Brasileira de Pesquisa Agropecuária. Brasília, DF: Embrapa, 2011.

BARRACHINA, M.; CRISTÓBAL, J.; TULLA, A. F. Estimating above-ground biomass on mountain meadows and pastures through remote sensing. **International Journal of Applied Earth Observation and Geoinformation**. 2015.

BELLÓN, B.; BÉGUÉ, A.; LO SEEN, D.; DE ALMEIDA, C. A.; SIMÕES, M. A Remote Sensing Approach for Regional-Scale Mapping of Agricultural Land-Use Systems Based on NDVI Time Series. **Remote Sensing**, [s. 1.], v. 9, n. 6, p. 600, 2017.

BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. J. Mach. Learn. Res. **2012**, 13, 281–305.

BISHOP-TAYLOR R.; TULBURE M. G.; BROICH M. Evaluating static and dynamic landscape connectivity modelling using a 25-year remote sensing time series. **Landscape Ecology**. 33:625-40. 2018.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Plano setorial de mitigação e de adaptação às mudanças climáticas para a consolidação de uma economia de baixa emissão de carbono na agricultura:** plano ABC (Agricultura de Baixa Emissão de Carbono). Brasília: MAPA/ACS, 2012.

BOCCA, F.F.; RODRIGUES, L.H.A. The effect of tuning, feature engineering, and feature selection in data mining applied to rainfed sugarcane yield modelling. Computers and Electronics in Agriculture, v. 128, p. 67-76, 2016.

BUSTAMANTE, M. M. C.; NOBRE, C. A.; SMERALDI, R.; AGUIAR, A. P. D.; BARIONI, L. G.; FERREIRA, L. G.; LONGO, K.; MAY, P.; PINTO, A. S.; OMETTO, J. P. H. B. Estimating greenhouse gas emissions from cattle raising in Brazil. **Climatic Change**, [s. l.], v. 115, n. 3, p. 559–577, 2012.

CHANDRASHEKAR G; SAHIN F. A survey on feature selection methods. **Computers & electrical engineering**. 2014 Jan 1;40(1):16-28.

CHEN, T.; GUESTRIN, C. XGBoost: A scalable tree boosting system. *In*: **Proceedings of the 22nd Acm Sigkdd International Conference on Knowledge Discovery and Data Mining**. New York, NY, USA, 13–17. pp. 785–794. 2016.

DUARTE, P. M. *et al.* Integração Lavoura-Pecuária (ILP): Uma Revisão Literária. **Uniciências**, v. 22, n. 2, p. 106, 30 dez. 2018.

DUSSEUX, P.; HUBERT-MOY, L.; CORPETTI, T.; VERTÈS, F. Evaluation of SPOT imagery for the estimation of grassland biomass. International Journal of Applied Earth Observation and Geoinformation. 1:38:72-7. 2015.

Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). **Gado de Corte**. 2018. Disponível em: https://www.infoteca.cnptia.embrapa.br/bitstream/doc/951322/1/DOC189.pdf. Acesso em 21

European Space Agency (ESA). **Sentinel-2 User Handbook**. 2019. Disponível em: https://sentinel.esa.int/web/sentinel/user-guides>. Acesso em 21 mar. 2024.

mar. 2024.

FERRAZ, J. B. S.; FELÍCIO, P. E. DE. Production systems - An example from BrazilMeat **Science**, fev. 2010.

Food and Agriculture Organization of the United Nations (FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS). An international consultation on integrated crop livestock systems for development: The way forward for sustainable production intensification. **Integrated Crop Management. Rome**. v. 13, 2010.

Food and Agriculture Organization of the United Nations (FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS). **Tropical crop-livestock systems in conservation agriculture: the Brazilian experience**. Rome: 2007.

FORMAGGIO, A. R.; SANCHES, I. D. Sensoriamento remoto em agricultura. São Paulo: Oficina de Textos, 2017.

FREITAS, R. G. Estimativa da produção de pastagem cultivada utilizando índices de vegetação e variáveis de texturas a partir de imagens de drone (Doctoral dissertation, [sn]). 2020.

GIL, J.; SIEBOLD, M.; BERGER, T. Adoption and development of integrated croplivestock–forestry systems in Mato Grosso, Brazil. **Agriculture, Ecosystems & Environment**, [s. l.], v. 199, p. 394–406, 2015.

GOLDBERG, D. E., Genetic Algorithms in Search, Optimization, and Machine Learning, Addison-Wesley Publishing Company, 1989.

HALL-BEYER, M. Practical guidelines for choosing GLCM textures to use in landscape classification tasks over a range of moderate spatial scales. **International Journal of Remote Sensing**, v. 38, n. 5, p. 1312–1338, 2017a.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEIN, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610–621, nov. 1973.

HERRERO, M.; THORNTON, P. K.; NOTENBAERT, A. M.; WOOD, S.; MSANGI, S.; FREEMAN, H. A.; BOSSIO, D.; DIXON, J.; PETERS, M.; STEEG, J. Van de; LYNAM, J.; RAO, P. P.; MACMILLAN, S.; GERARD, B.; MCDERMOTT, J.; SERÉ, C.; ROSEGRANT, M. Smart Investments in Sustainable Food Production: Revisiting Mixed Crop-Livestock Systems. **Science**, [s. 1.], v. 327, n. 5967, p. 822–825, 2010.

HUANG, S. *et al.* A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. **Journal of Forestry Research**, v. 32, n. 1, p. 1–6, 2021.

JENSEN, J.R. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. São José dos Campos: **Parêntese**. 604 p. 2009.

LIU, H.; MOTODA, H, (ed.). Feature extraction, construction and selection: A data mining perspective. **Springer Science & Business Media**; 1998 Aug 31.

LU, D. The potential and challenge of remote sensing-based biomass estimation. **International Journal of Remote Sensing.** Taylor and Francis Ltd. 2006.

MANABE, V. D.; MELO, M. R. S.; ROCHA, J. V. Framework for mapping integrated croplivestock systems in Mato Grosso, Brazil. **Remote Sensing**, v. 10, n. 9, 1 set. 2018.

MARTN-NETO L, TADINI AM, BENTO LR, DOS SANTOS JV, MILORI DM, LADISLAU MARTIN NETO CN, PEREIRA DM. Estrutura e natureza química da matéria orgânica do solo. **Entendendo a matéria orgânica do solo em ambientes tropical e subtropical** Wagner Bettiol. 2023:145.

OTGONBAYAR, M. *et al.* Mapping pasture biomass in Mongolia using Partial Least Squares, Random Forest regression and Landsat 8 imagery. **International Journal of Remote Sensing**, v. 40, n. 8, p. 3204–3226, 18 abr. 2019.

PAPA, G. L. Seleção de atributos utilizando algoritmos genéticos multiobjetivos. Dissertação de Mestrado (em Informática Aplicada). Pontifícia Universidade Católica do Paraná. Curitiba – PR. 2002.

PUNALEKAR, S. M.; VERHOEF, A.; QUAIFE, T. L.; HUMPHRIES, D.; BERMINGHAM, L.; REYNOLDS, C. K. Application of Sentinel-2A data for pasture biomass monitoring using a physically based radiative transfer model. **Remote Sensing of Environment**. 2018, 218, 207–220.

RAPINEL, S.; MONY, C.; LECOQ, L.; CLÉMENT, B.; THOMAS, A.; HUBERT-MOY, L. Evaluation of Sentinel-2 time-series for mapping floodplain grassland plant communities. **Remote Sensing of Environment**. 2019 Mar 15;223:115-29.

REIS, A. A.; WERNER, J. P.; SILVA, B. C.; FIGUEIREDO, G. K.; ANTUNES, J. F.; ESQUERDO, J. C.; COUTINHO, A. C.; LAMPARELLI, R. A.; ROCHA, J. V.; MAGALHÃES, P. S. Monitoring pasture aboveground biomass and canopy height in an integrated crop–livestock system using textural information from PlanetScope imagery. **Remote Sensing**. 2020 Aug 6;12(16):2534.

ROLIM, G. S.; CAMARGO, M. P. B.; LANIA, D. G.; MORAES, J. F. L. Classificação climática de Köppen e de Thornthwaite e sua aplicabilidade na determinação de zonas agroclimáticas para o estado de São Paulo, Bragantia, 4, 711-720. 2007.

ROSSI, M. **Mapa pedológico do Estado de São Paulo**: revisado e ampliado. São Paulo: Instituto Florestal, v. 1, p. 118, 2017.

SÁ, J. C. M. *et al.* Low-carbon agriculture in South America to mitigate global climate change and advance food security. **Environment International**, 2017.

SCHAEFER, M. T.; LAMB, D. W. A combination of plant NDVI and LiDAR measurements improve the estimation of pasture biomass in tall fescue (festuca arundinacea var. fletcher). **Remote Sensing**, v. 8, n. 2, 2016.

SERVELLO, E. L.; SANO, E. E.; PANTOJA, N. V. Sentinel-1 SAR:efeito de filtros espaciais no estudo do uso do solo amazônico. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, Brasil, INPE, 25 a 29 de abril de 2015.

SILVA, Y. F.; REIS, A. A.; WERNER, J. P. S.; VALADARES, R. V.; CAMPBELL, E. E.; LAMPARELLI, R. A. C.; MAGALHÃES, P. S. G.; FIGUEIREDO, G. K. D. A. Assessing the capability of MODIS to monitor mixed pastures with high-intensity grazing at a fine-scale, **Geocarto International**. 2021.

SNOEIJ, P.; ATTEMA, E.; DAVIDSON, M.; DUESMANN, B.; FLOURY, N.; LEVRINI, G.; ROSICH, B. The Sentinel-1 radar mission: Status and performance. In 2009 International Radar Conference" Surveillance for a Safer World". **Radar**. pp. 1-6. IEEE. 2009

STRASSBURG, B. B. N.; LATAWIEC, A. E.; BARIONI, L. G.; NOBRE, C. A.; DA SILVA, V. P.; VALENTIM, J. F.; VIANNA, M.; ASSAD, E. D. When enough should be enough: Improving the use of current agricultural lands could meet production demands and spare natural habitats in Brazil. **Global Environmental Change**, [s. l.], v. 28, p. 84–97, 2014.

TORRES, R.; SNOEIJ, P.; GEUDTNER, D.; BIBBY, D.; DAVIDSON, M.; ATTEMA, E.; TRAVER, I. N. GMES Sentinel-1 mission. **Remote Sensing of Environment**, v.120, p.9-24. 2012

TSOUROS, D. C.; BIBI, S.; SARIGIANNIDIS, P. G. A review on UAV-based applications for precision agriculture. **Information (Switzerland)**, v. 10, n. 11, 2019.

WANG; J.; XIAO; X.; BAJGAIN; R.; STARKS; P.; STEINER; J.; DOUGHTY; R.B.; CHANG; Q.; 2019. Estimating leaf area index and aboveground biomass of grazing pastures using Sentinel-1, Sentinel-2 and Landsat images. ISPRS J. Photogramm. **Remote Sensing**. 154, 189–201. DOI: doi.org/10.1016/j.isprsjprs.2019.06. 007

WERNER, J. P. S.; REIS, A. A.; TORO, A. P. S. G. D.; BUENO, I. T.; ANTUNES, J. F. G.;
COUTINHO, A. C.; LAMPARELLI, R. A. C.; MAGALHÃES, P. S. G.; ESQUERDO, J. C.
D. M.; FIGUEIREDO, G. K. D. A. Temporal Comparison of Multiple Sensors for
Monitoring Paddock Management in an Integrated Crop-Livestock System, Proceedings... *In*:
XX Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brazil, 2023.

XIE, Y.; SHA, Z.; YU, M.; BAI, Y.; ZHANG, L. A comparison of two models with Landsat data for estimating above ground grassland biomass in Inner Mongolia, China. Ecological Modelling. 220(15):1810-8. 2009.

XUE, J.; SU, B. Significant Remote Sensing Vegetation Indices: A Review of Developments Significant Remote Sensing Vegetation Indices. **Journal of Sensors**. (1):1-17 2017.

ZHOU, X.; ZHU, X.; DONG, Z.; GUO, W. Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. **The Crop Journal**. 4(3):212-9. 2016.

ZHOU, Y.; ZHANG, R.; WANG, S.; WANG, F. Feature selection method based on high-resolution remote sensing images and the effect of sensitive features on classification accuracy. **Sensors**. 2018 Jun 22;18(7):2013.