



# **AVALIAÇÃO DO POTENCIAL DAS IMAGENS DO SATÉLITE SENTINEL-1 E TEXTURA GLCM NA CLASSIFICAÇÃO DE ÁREAS DE INTEGRAÇÃO LAVOURA-PECUÁRIA (ILP)**

**Palavras-Chave:** Medidas de Textura, Séries Temporais, Agricultura Regenerativa

**Autores(as):**

**GEÓRGIA GERMER GONÇALVES, FEAGRI – UNICAMP**

**Ms. ANA PAOLA SALAS GOMES DUARTE DI TORO (coorientadora), FEAGRI - UNICAMP**

**FILIPE DE OLIVEIRA COSTA (coautor), CPqD**

**Prof<sup>(a)</sup>. Dr<sup>(a)</sup>. GLEYCE KELLY DANTAS ARAÚJO FIGUEIREDO (orientadora), FEAGRI- UNICAMP**

---

## **INTRODUÇÃO:**

A preocupação em ampliar a produção agrícola visando suprir as necessidades da crescente população mundial tem impulsionado formas sustentáveis para o aumento da produtividade em áreas agrícolas já consolidadas (HERRERO et al., 2015). Nessa perspectiva, o sistema de Integração Lavoura e Pecuária (ILP) surge como alternativa sustentável promissora, a qual se utiliza da diversificação do uso da terra com base na associação temporal e espacial dos componentes lavoura e pecuária (BALBINO et al., 2012). Diante deste cenário, o Brasil, como produtor global de alimentos, tornou-se pioneiro na adoção deste sistema apresentando, no último levantamento oficial da Rede Integração Lavoura Pecuária Floresta (REDE ILPF) em 2016, cerca de 11,5 milhões de hectares de área de ILPs.

Em função da alta complexidade e dinamismo da ILP, torna-se essencial o estabelecimento de um mecanismo de sensoriamento remoto para monitoramento sistemático contínuo de identificação e acompanhamento dessas áreas (DOS REIS; WERNER; FIGUEIREDO, 2020). Nesse contexto, o Programa Copernicus liderado pela Agência Espacial Européia (ESA) fornece dados gratuitos de observação da terra, com destaque ao satélite Sentinel 1 (dados de radar) que é amplamente utilizado para monitoramento agrícola, sobretudo áreas tropicais, como o caso brasileiro, que apresentam alta frequência de nuvens em determinados períodos do ano (PRUDENTE et al., 2020).

Em contrapartida, Caballero et al. (2020, p. 854), apresentaram resultados satisfatórios no emprego da técnica de classificação de culturas utilizando a matriz de coocorrência de níveis de cinza (Grey Level Co-occurrence Matrix - GLCM) em vales irrigados com dados do Sentinel 1. Tal estudo contou com a aplicação da técnica no Vale Bonaerense do Rio Colorado, em Buenos Aires na Argentina, para culturas principais de cebola e girassol, e, também presentes na área de estudo: cereais, alfafa, batata e milho. Nessa perspectiva, o estudo da aplicabilidade do GLCM em imagens do Sentinel 1 pode ser uma alternativa a ser considerada para monitoramento de áreas com Integração Lavoura e Pecuária. Sendo assim, o presente estudo tem como objetivo avaliar se a série temporal do satélite Sentinel 1 com textura GLCM é capaz de aprimorar o desempenho na classificação supervisionada em áreas com sistema de Integração Lavoura e Pecuária.

## METODOLOGIA:

Definiu-se como área de estudo a Fazenda Gravataí, localizada ao Centro-Oeste do Brasil no município de Itiquira-MT (Figura 1). A propriedade apresenta área total equivalente a 10.600 hectares, em que 3.300 ha são destinados à pastagem permanente e 4.060 ha destinados à lavoura. Após a colheita da soja, cerca de 3.000 ha são destinados à ILP. Em uma parte deste total é realizada a semeadura da pastagem, e em outra parte é semeado o milho em consórcio com a braquiária.

Em estudo anterior, o levantamento de dados de referência terrestre para classificação de áreas de ILP foi realizado por meio de visitas à fazenda. Estes dados, por sua vez, fazem referência à safra 2020/2021 do desenvolvimento da pastagem, como, tipo de forragem, presença de consórcio entre forragens, entre outros. Tais dados foram armazenados para posterior utilização na caracterização da área e verificação dessas ocorrências nas séries temporais de imagens de satélite ao longo do desenvolvimento da ILP.

Imagens do satélite Sentinel 1 (referentes ao intervalo temporal: de 01/Set/2020 à 31/Ago/2021), disponíveis gratuitamente pelo Hub da ESA, foram adquiridas com auxílio da plataforma Google Earth Engine (GORELICK, 2019). Para este estudo, as imagens foram utilizadas no modo de aquisição Wide Interferometric (IW), que proporciona dupla polarização (VV e VH). Calculou-se a matriz de coocorrência de níveis de cinza (Grey Level Co-occurrence Matrix - GLCM) referente à cada imagem, resultando em quatro agrupamentos de imagens: banda VV; banda VH; banda VV com GLCM e banda VH com GLCM. Em seguida, foi gerado um polígono por segmentação da área de estudo (utilizando o software QGIS), a partir do qual foram calculadas as estatísticas zonais por data (média e desvio padrão) de cada bloco, as quais foram agrupadas em um dataframe que foi utilizado, por sua vez, como entrada no algoritmo Random Forest (RF) (BREIMAN; 2001).

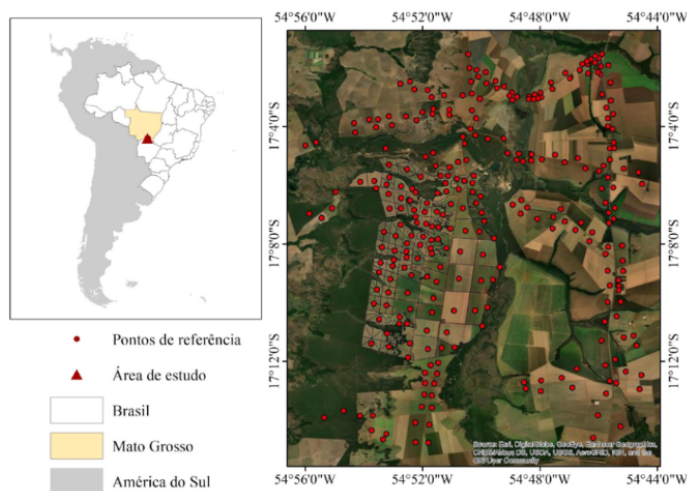
Para melhor avaliar os resultados foram geradas as matrizes de confusão referentes às classificações realizadas. A matriz de confusão, explicita o desempenho do modelo empregado na classificação de determinado teste, bem como as principais confusões que ocorreram na classificação (GUPTA et al., 2022).

## RESULTADOS E DISCUSSÃO:

Apresentam-se as matrizes de confusão resultantes no teste com o algoritmo de Random Forest para as polarizações VV+VH sem GLCM (Figura 02) e polarizações VV+VH com GLCM (Figura 03). As classes analisadas foram: Pasto Cultivado; Sistemas de Integração Lavoura e Pecuária (ILP); Cultivo Duplo; e Floresta Nativa.

Os resultados foram calculados e expressos em métricas convencionais do algoritmo não paramétrico de aprendizado de máquinas (*Machine Learning* - ML). Nessa perspectiva, a matriz de confusão, por sua vez, reflete os índices de *recall* (revocação). Nessa perspectiva, a matriz de confusão, por sua vez, reflete as porcentagem de *recall* (revocação). Já a tabela, apresenta além desse índice, as métricas de “*precision*” (precisão), “*f1-score*” e “*accuracy*” (acurácia geral) do modelo.

**Figura 01:** Área de Estudo e pontos de coleta de dados em campo, no município de Itiquira, Mato Grosso, Brasil.



## Classificação Baseada em Séries Temporais: VV+VH

A matriz de confusão das séries temporais VV+VH (Figura 02), em aspectos de cor e porcentagem da diagonal principal, demonstra índices “recall” intermediários de equivalência. Nota-se que, em termos de *recall*, as classes “Floresta Nativa”, “ILP” e “Cultivo Duplo” apresentam maior incoerência no modelo de classificação, sendo confundidas, em grande parte, com “Pasto Cultivado”. A classe de “Pasto Cultivado”, por sua vez, apresentou melhor desempenho em aspectos de *recall*, sendo confundida 4% com “Cultivo Duplo” e 4% com “ILP”.

Os resultados enumerados na Tabela 01 demonstram que o modelo apresentou acurácia geral de 77%. Ademais, os valores de “*precision*” indicaram que a classe “Floresta Nativa” obteve maior acurácia, seguida por “Cultivo Duplo”, “ILP” e “Pasto Cultivado”. Por fim, em termos de “*f1-score*” a classe com maior êxito foi “Floresta Nativa”.

Figura 02: Matriz de Confusão: Classificação VV+VH




Tabela 01: Valores de Acurácia: Classificação VV+VH


	<i>precision</i>	<i>recall</i>	<i>f1-score</i>	<i>support</i>
Floresta Nativa	1.00	0.70	0.82	10
ILP	0.75	0.60	0.67	10
Cultivo Duplo	0.85	0.69	0.76	16
Pasto Cultivado	0.69	0.92	0.79	24
<i>accuracy</i>			0.77	60
<i>macro avg</i>	0.82	0.73	0.76	60
<i>weighted avg</i>	0.79	0.77	0.76	60

### Classificação Baseada em Séries Temporais: VV+VH+GLCM

A matriz de confusão das séries temporais VV+VH+GLCM (Figura 03) apresenta, em sua diagonal principal, índices de *recall* iguais ou superiores a 90%. Observa-se que as classes “ILP”, “Cultivo Duplo” e “Pasto Cultivado” apresentam maior incoerência na classificação sendo: “ILP” confundida com “Cultivo Duplo”; “Cultivo Duplo” confundida com “Pasto Cultivado”; e “Pasto Cultivado” confundido com “Floresta Nativa”. A classe de “Floresta Nativa”, apresentou melhor desempenho em aspectos de *recall*.

Os resultados presentes na Tabela 02 demonstram que o modelo exibiu acurácia geral de 95%. Ademais, os valores de *precision* indicaram que a classe “ILP” obteve maior acurácia, seguida por “Pasto Cultivado”, “Cultivo Duplo” e “Floresta Nativa”. Por fim, em termos de f1-score a classe com maior êxito foi “Pasto Cultivado”, no entanto com porcentagem próxima às demais.

**Figura 03:** Matriz de Confusão: Classificação VV+VH+GLCM



**Tabela 02:** Valores de Acurácia: Classificação VV+VH+GLCM

	<i>precision</i>	<i>recall</i>	<i>f1-score</i>	<i>support</i>
Floresta Nativa	0.91	1.00	0.95	10
ILP	1.00	0.90	0.95	10
Cultivo Duplo	0.94	0.94	0.94	16
Pasto Cultivado	0.96	0.96	0.96	24
<i>accuracy</i>			0.95	60
<i>macro avg</i>	0.95	0.95	0.95	60
<i>weighted avg</i>	0.95	0.95	0.95	60

## CONCLUSÕES:

O resultado deste estudo mostrou que a textura GLCM demonstrou-se relevante no aumento do potencial das imagens do Sentinel 1 para a diferenciação dos tipos de cultura em uma área de Integração Lavoura e Pecuária, uma vez que a acurácia geral sem a textura foi de 77%, e com a textura de 95%, exibindo, portanto, um aumento em 18%. Ressalta-se que a textura é uma das informações extraídas dos dados do sensoriamento remoto com grande utilidade de segmentar a imagem, resultando, de fato, em uma melhor identificação das classes de objetos.

Ademais, todos os valores de f1-score se apresentaram mais elevados com a presença da GLCM: “Floresta Nativa” de 82% para 95%; “ILP” de 67% para 95%; “Cultivo Duplo” de 76% para 94%; “Pasto Cultivado” de 79% para 96%. Além disso, pode ser observado no presente estudo, para o Sentinel-1, que regiões de “ILP” foram as que obtiveram maior incremento em porcentagem de classificação com a textura GLCM, uma vez que este índice sem a textura foi de 67%, e com a textura de 95%, exibindo, portanto, um aumento em 28%. No entanto, apesar da elevada acurácia para a classe ILP, ainda assim esta demonstrou-se a mais complexa a ser classificada, demonstrando a relevância do presente estudo e futuros estudos complementares.

## AGRADECIMENTO:

Ao Centro de Pesquisa e Desenvolvimento em Telecomunicações (CPqD) pela concessão da bolsa de pesquisa; à Associação para Promoção da Excelência do Software Brasileiro (SOFTEX) pelo financiamento da pesquisa; ao Serviço de Apoio ao Estudante (SAE/Unicamp) pelo apoio na intermediação da bolsa; e à FAPESP (processo 2017/50205-9) pelo financiamento do projeto.

---

## BIBLIOGRAFIA

BALBINO, Luiz Carlos; BARCELLOS, Alexandre de Oliveira; STONE, Luís Fernando. **“Reference Document Crop-Livestock-Forestry Integration Luiz”**. tech. rep., Brasília, DF - Brazil, 2012.

BREIMAN, Leo. **“Random forests”**. Machine learning, vol. 45, no. 1, pp. 5–32, 2001.

CABALLERO, Gabriel Rodrigo; PLATZECK, Gabriel; PEZZOLA, Alejandro; CASELLA, Alejandra; WINSCHER, Cristina; SILVA, Samanta Soledad; LUDUENÁ, Emilia; PASQUALOTTO, Nieves; DELEGIDO, Jesús. **“Assessment of multi-date sentinel-1 polarizations and glcm texture features capacity for onion and sunflower classification in an irrigated valley: An object level approach”**. Agronomy, vol. 10, no. 6, p. 845, 2020.

DOS REIS, Aliny; WERNER, João Paulo; FIGUEIREDO, Gleyce Kelly Dantas Araújo. **“Monitoring Pasture Aboveground Biomass and Canopy Height in an Integrated Crop – Livestock System Using Textural Information from PlanetScope Imagery”**. Remote sensing, vol. 12, pp. 1–21, 2020.

GORELICK, Noel. **“Google Earth Engine”**. In EGU general assembly conference abstracts, vol. 15, p. 11997. Vienna, Austria: American Geophysical Union, 2019.

GUPTA, Deepak; KOSE, Utku; KHANNA, Ashish; BALAS, Valentina Emilia. **“Deep Learning for Medical Applications with Unique Data”**. 1ª Edição. 2022.

HERRERO, Mario; WIRSENIUS, Stefan; HENDERSON, Benjamin; RIGOLLOT, Cyrille; THORNTON, Philip; HAVLÍK, Petr; DE BOER, Imke; J.GERBER, Pierre. **“Livestock and the environment: What have we learned in the past decade?”**. Annual Review of Environment and Resources, vol. 40, no. 1, pp. 177–202, 2015.

PRUDENTE, Victor Hugo Rohden; MARTINS, Vitor Souza; VIEIRA, Denis Corte; FRANÇA E SILVA, Nildson Rodrigues; ADAMI, Marcos; SANCHES, Ieda Del’Arco. **“Limitations of cloud cover for optical remote sensing of agricultural areas across South America”**. Remote Sensing Applications: Society and Environment, vol. 20, no. May, p. 100414, 2020.