

**COMPARAÇÃO DE MODELOS PREDITIVOS PARA A CLASSIFICAÇÃO
SUPERVISIONADA DE IMAGENS DE SATÉLITE, NO MUNICÍPIO DE SANTIAGO, RS**

**COMPARISON OF PREDICTIVE MODELS FOR SUPERVISED CLASSIFICATION OF
SATELLITE IMAGES IN THE MUNICIPALITY OF SANTIAGO, RS**

**COMPARACIÓN DE MODELOS PREDITIVOS PARA LA CLASIFICACIÓN
SUPERVISADA DE IMÁGENES DE SATÉLITE EN EL MUNICIPIO DE SANTIAGO, RS**

 <https://doi.org/10.56238/arev7n10-187>

Data de submissão: 16/09/2025

Data de publicação: 16/10/2025

Lucas da Silva Gonçalves
Graduando em Agronomia

Instituição: Universidade Regional Integrada do Alto Uruguai e das Missões - Santiago
E-mail: lcsgoncalves1@gmail.com

Higor Machado de Freitas
Mestre em Ciência do Solo

Instituição: Universidade Federal de Santa Maria (UFSM)
E-mail: higor.freitas@urisantiago.br

Lucas Vaz Soares
Graduando em Agronomia

Instituição: Universidade Regional Integrada do Alto Uruguai e das Missões – Santiago
E-mail: 77soareslucas77@gmail.com

João Pedro Bilo Bolzan Costa
Graduando em Agronomia

Instituição: Universidade Regional Integrada do Alto Uruguai e das Missões – Santiago
E-mail: 102330@urisantiago.br

Vanderson Fernandes Campos
Bacharel em Agronomia

Instituição: Universidade Regional Integrada do Alto Uruguai e das Missões
E-mail: vandersonfc@outlook.com

Guilherme Fávero Rosado
Bacharel em Agronomia

Instituição: Universidade Regional Integrada do Alto Uruguai e das Missões
E-mail: guilhermeefavero@gmail.com

Júlio Cesar Wincher Soares
Doutor em Engenharia Florestal

Instituição: Universidade Federal de Santa Maria (UFSM)
E-mail: juliowincher@gmail.com

RESUMO

O sensoriamento remoto tem se consolidado como uma ferramenta fundamental para o monitoramento e análise do *Land Use and Land Cover* (LULC), especialmente com o avanço das tecnologias de obtenção e processamento de imagens orbitais. Neste contexto, a classificação supervisionada de imagens de satélite é amplamente utilizada para a geração de mapas temáticos com finalidades ambientais, agrícolas e de planejamento territorial. Este trabalho teve como objetivo avaliar o desempenho dos algoritmos *Random Forest* (RF) e *Support Vector Machines* (SVM) na classificação de imagens do satélite Sentinel-2A MSI (nível L2A), referentes ao município de Santiago, localizado na região Centro-Oeste do Rio Grande do Sul. A área de estudo apresenta elevada heterogeneidade espacial, incluindo campos nativos, áreas de cultivo, manchas florestais, corpos hídricos e áreas urbanas. A classificação foi realizada no software QGIS 3.40, com aplicação de dois tratamentos: um com 30 amostras de treinamento por classe temática e outro com 150 amostras. Os resultados demonstraram que o algoritmo *Random Forest* obteve melhor desempenho geral, alcançando acurácia global de 72% e coeficiente Kappa de 0,65 com 150 amostras por classe, frente aos 64,67% de acurácia global e 0,55 de Kappa do SVM no mesmo cenário. As métricas de acurácia do produtor e do usuário também indicaram superioridade do *Random Forest*, sobretudo na identificação de áreas com alta variabilidade espectral. Conclui-se que a escolha do classificador e do número de amostras influencia significativamente os resultados da classificação, sendo o *Random Forest* o modelo mais indicado para áreas com feições complexas como as encontradas em Santiago.

Palavras-chave: Geoprocessamento. Modelagem Preditiva. Sensoriamento Remoto.

ABSTRACT

Remote sensing has established itself as a fundamental tool for monitoring and analyzing Land Use and Land Cover (LULC), especially with the advancement of orbital image acquisition and processing technologies. In this context, supervised classification of satellite images is widely used to generate thematic maps for environmental, agricultural, and spatial planning purposes. This study aimed to evaluate the performance of Random Forest (RF) and Support Vector Machine (SVM) algorithms in classifying Sentinel-2A MSI satellite images (L2A level) for the municipality of Santiago, located in the Central-West region of Rio Grande do Sul. The study area presents high spatial heterogeneity, including native grasslands, croplands, forest patches, water bodies, and urban areas. The classification was performed in QGIS 3.40 software, applying two treatments: one with 30 training samples per thematic class and the other with 150 samples. The results demonstrated that the Random Forest algorithm performed better overall, achieving an overall accuracy of 72% and a Kappa coefficient of 0.65 with 150 samples per class, compared to an overall accuracy of 64.67% and a Kappa coefficient of 0.55 for the SVM in the same scenario. The producer and user accuracy metrics also indicated Random Forest's superiority, particularly in identifying areas with high spectral variability. It can be concluded that the choice of classifier and the number of samples significantly influences the classification results, with Random Forest being the most suitable model for areas with complex features such as those found in Santiago.

Keywords: Geoprocessing. Predictive Modeling. Remote Sensing.

RESUMEN

La teledetección se ha consolidado como una herramienta fundamental para el monitoreo y análisis del Uso y Cobertura Terrestre (LULC), especialmente con el avance de las tecnologías de adquisición y procesamiento de imágenes orbitales. En este contexto, la clasificación supervisada de imágenes satelitales se utiliza ampliamente para generar mapas temáticos con fines ambientales, agrícolas y de planificación espacial. Este estudio tuvo como objetivo evaluar el desempeño de los algoritmos Random Forest (RF) y Support Vector Machine (SVM) en la clasificación de imágenes satelitales Sentinel-2A MSI (nivel L2A) para el municipio de Santiago, ubicado en la región Centro-Oeste de Rio Grande do Sul. El área de estudio presenta una alta heterogeneidad espacial, incluyendo pastizales nativos, tierras de cultivo, parches de bosque, cuerpos de agua y áreas urbanas. La clasificación se realizó en el software QGIS 3.40, aplicando dos tratamientos: uno con 30 muestras de entrenamiento por clase temática y el otro con 150 muestras. Los resultados demostraron que el algoritmo Random Forest tuvo un mejor rendimiento general, alcanzando una precisión general del 72% y un coeficiente Kappa de 0,65 con 150 muestras por clase, en comparación con una precisión general del 64,67% y un coeficiente Kappa de 0,55 para el SVM en el mismo escenario. Las métricas de precisión del productor y del usuario también indicaron la superioridad de Random Forest, especialmente en la identificación de áreas con alta variabilidad espectral. Se puede concluir que la elección del clasificador y el número de muestras influyen significativamente en los resultados de la clasificación, siendo Random Forest el modelo más adecuado para áreas con características complejas como las de Santiago.

Palabras clave: Geoprocесamiento. Modelado Predictivo. Teledetección.

1 INTRODUÇÃO

O avanço das tecnologias de sensoriamento remoto tem proporcionado uma nova perspectiva sobre o monitoramento e análise do espaço terrestre. As imagens de satélite, cada vez mais acessíveis e com melhor resolução, são amplamente utilizadas em diversas aplicações, como monitoramento ambiental e planejamento urbano.

De acordo com Novo (2010), o sensoriamento remoto pode ser definido como a utilização conjunta de sensores e equipamentos para processamento de dados, colocados a bordo de aeronaves, espaçonaves e outras plataformas, com o objetivo de estudar eventos, fenômenos e processos que ocorrem na superfície terrestre.

O desenvolvimento da técnica de sensoriamento remoto via satélite pode ser dividido em duas épocas: uma antes do lançamento do primeiro satélite artificial pelos Russos, chamado *Sputnik 1*, em 4 de outubro de 1957, em que a técnica de aerofotogrametria era a única técnica e outra, após essa data, em que os diversos sensores de satélites foram desenvolvidos com o rápido avanço do programa de exploração espacial (LIU, 2015).

Dentre as principais funções que o sensoriamento remoto desempenha estão o levantamento e monitoramento de recursos naturais, desempenhando um papel fundamental na identificação e enfrentamento de problemas ambientais. Além disso, o uso da classificação de imagens permite a identificação e acompanhamento contínuo das transformações no uso da terra e na cobertura vegetal, por meio de informações que descrevem características da paisagem e feições do relevo de uma determinada área.

Conforme relatado por Rizzi e Rudorff (2005), em um estudo realizado no Rio Grande do Sul para estimar áreas cultivadas com soja a partir de imagens de satélite, ficou evidente a ampla aplicabilidade do sensoriamento remoto.

No estudo da safra de soja 2021/22 no Rio Grande do Sul, Schorr et al. (2023) mostraram, de forma clara, como o sensoriamento remoto pode ser uma ferramenta útil e prática para estimar a produtividade da cultura, evidenciando sua aplicabilidade.

Os métodos de classificação digital podem ser agrupados de acordo com a existência ou não de uma fase de treinamento, na qual o analista atua diretamente com o sistema computacional. O método é dito não supervisionado quando o classificador não utiliza a priori nenhum conhecimento sobre as classes existentes na imagem e define, sem a interferência do analista, uma determinada classe para cada pixel da imagem (INPE, 1998).

A classificação supervisionada de imagens constitui uma ferramenta de grande relevância para o mapeamento de áreas da superfície terrestre associadas a temas de específicos, devido à sua

capacidade de reconhecer e mensurar dados em uma imagem de satélite (Barbosa, 2009), atribuindo rótulos a cada pixel de uma imagem com base em informações prévias já conhecidas, chamadas de amostras de treinamento. Essas amostras permitem transformar grandes volumes de dados brutos, como valores de refletância em diferentes bandas espectrais dos pixels das imagens em informações temáticas úteis, para a geração de mapas temáticos sobre diversos temas, como monitoramentos agrícola e ambiental e identificação de padrões do uso e cobertura da terra, ou Land Use and Land Cover (LULC).

Situado na região Oeste do Rio Grande do Sul, o município de Santiago apresenta paisagens predominantes do Bioma Pampa, com feições do relevo ondulado a levemente ondulado (ALMEIDA, 2017). A vegetação campestre é hegemônica nesta região, composta, segundo Boldrini (2009), por cerca de 2.200 espécies vegetais, em sua maioria de pequeno porte, especialmente rasteiro, característica de forte expressão para a região supracitada.

Embora a vegetação campestre, que historicamente sustenta a atividade pecuária amplamente desenvolvida nos campos nativos de todo o Pampa, observa-se, nos últimos anos, uma expansão significativa das áreas voltadas à atividade agrícola na região Oeste do Estado. Esse processo tem resultado na conversão de áreas do território para o cultivo de grãos durante o verão e para implantação de pastagens cultivadas no período do inverno. Esta rica e diversificada flora, que tradicionalmente tem sustentado a atividade pastoril, vem sendo progressivamente alterada por ações antrópicas, com a introdução de pastagens cultivadas, intensificação das atividades agrícolas e o reflorestamento de espécies exóticas (ALMEIDA, 2017).

Diante dessa paisagem mista entre áreas urbanas, campos nativos e áreas de cultivo, o município de Santiago se torna o cenário ideal para testar e comparar métodos de classificação supervisionada, dada a complexidade das feições presentes nas imagens de satélite.

A escolha do algoritmo de classificação supervisionada influencia diretamente a qualidade dos mapas gerados. Dessa forma, a comparação entre diferentes modelos possibilita a análise de seus respectivos desempenhos, níveis de acurácia e adequações frente à complexidade de áreas heterogêneas como a paisagem de Santiago, contribuindo para a escolha mais apropriada em outros projetos de mapeamento do LULC (ADUGNA; XU; FAN, 2022).

Nesse contexto, justifica-se o presente estudo em comparar o desempenho de dois modelos de classificação supervisionada aplicados a imagens de satélite referentes ao município de Santiago, Rio Grande do Sul, com o propósito de avaliar a acurácia na identificação de diferentes classes de LULC.

2 METODOLOGIA

A área do trabalho abrange o município de Santiago, no estado do Rio Grande do Sul, com coordenadas centrais UTM 711.657 m E e 6.778.426 m S (SIRGAS 2000, ZONA 21S), possuindo uma área de 2.419,56 km², conforme mostrado na Figura 1.

Figura 1 - Mapa de localização do município de Santiago.



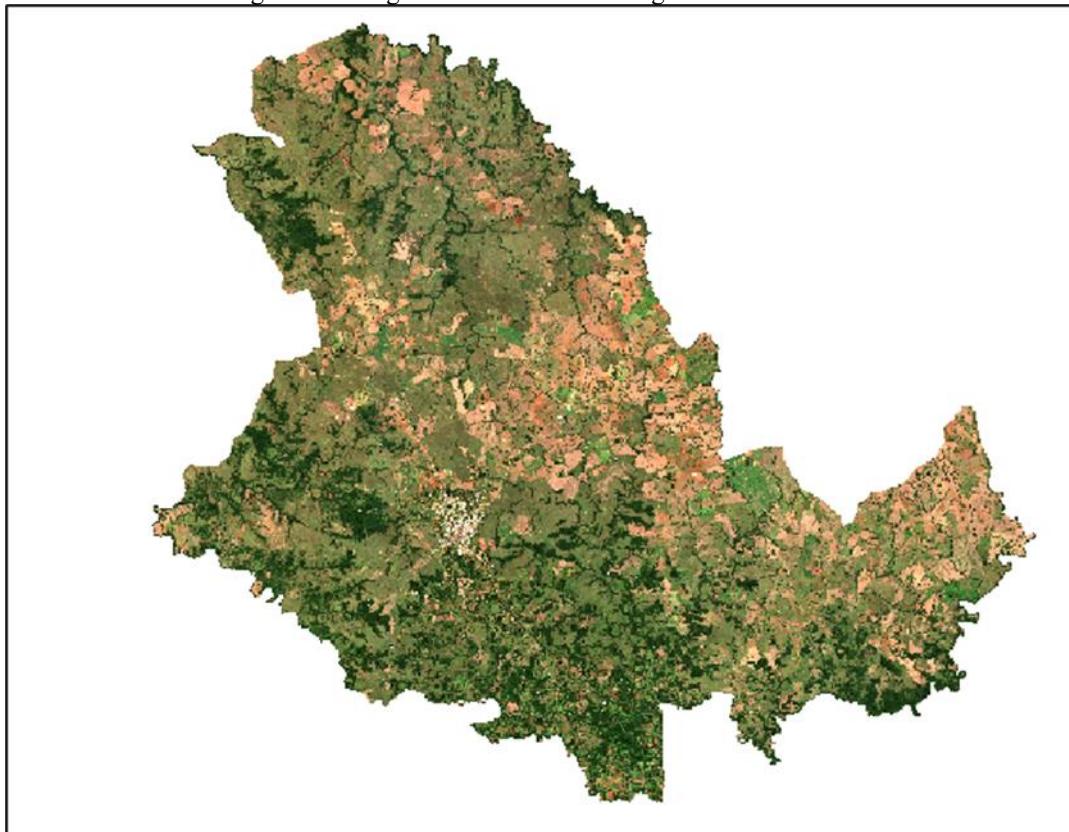
Fonte: Elaborado pelo autor.

A imagem utilizada foi obtida a partir do *Copernicus Open Access Hub*, ferramenta de visualização e utilização de imagens de satélites para observação terrestre da constelação *Copernicus Sentinel*, proveniente do Programa Espacial da União Européia, formado em 2021 juntamente com a Agência Espacial Europeia, organização intergovernamental voltada à exploração espacial (Figura 2).

O sensor é o MSI (*Multispectral Instrument*), abrangendo 13 bandas espectrais, a bordo do satélite *Sentinel-2A*, adquiridas no formato *Level-2A*, que já contempla correções atmosféricas, para remover os efeitos dos aerossóis e vapor d'água, por exemplo. Além disso, o produto obtido é georreferenciado e pronto para uso em análise de refletância de superfície, com resolução espacial de 10 metros.

A composição utilizada para análise foi a combinação de bandas B4 (*Red* -664.6 nm), B3 (*Green* – 559.8 nm) e B2 (*Blue* – 492.4 nm), formando uma imagem de cor verdadeira (RGB). Essa combinação gera uma imagem visualmente próxima ao que o olho humano veria, facilitando a identificação visual das feições do relevo e a coleta precisa das amostras de treinamento.

Figura 2 – Imagem de satélite de Santiago do ano de 2025.



Fonte: Elaborado pelo autor.

Foram definidas cinco classes temáticas para o mapeamento do uso e cobertura da terra mais representativas da área de estudo, sendo elas: Mata Nativa, Campo Nativo, Área Urbana, Área de Cultivo e Lâmina D’água. As classificações digitais supervisionadas foram executadas no software QGIS 3.40.5.

Para avaliar o impacto da quantidade de amostras de treinamento no desempenho dos modelos, foram testados dois cenários distintos: no primeiro foram realizadas trinta (30) amostras de treinamento por classe, totalizando cento e cinquenta (150) amostras. No segundo, cento e cinquenta (150) amostras por classe, resultando em setecentos e cinquenta (750) amostras totais. As amostras foram coletadas com base na análise visual da imagem de cor verdadeira. Priorizou-se a seleção de polígonos homogêneos e bem distribuídos espacialmente dentro do limite municipal.

A escolha das amostras de validação foi feita seguindo o critério de aleatoriedade estratificada, assegurando um mínimo de 30 amostras por classe (VAN GENDEREN *et al.*, 1978). Cada amostra de validação foi verificada individualmente, com inspeção visual e contextual, garantindo que a classe atribuída refletisse fielmente a realidade da imagem.

A interpretação dos resultados foi feita por meio da geração de matrizes de confusão e cálculo dos índices de Acurácia Global (Equação 1), que avalia o total de acertos em relação ao

total de amostras da imagem e o Coeficiente Kappa (Equação 2), que mede o grau de concordância entre os valores classificados e os valores de referência, corrigindo o acaso.

$$(1) AG = \left(\frac{a}{n} \right) \times 100$$

Onde: AG = acurácia global, a = pontos amostrais corretamente classificados, n = número total de pontos amostrais.

$$(2) K = \frac{(n \times \sum x_{ii} - \sum (x_{i+} \times x_{+i}))}{(n^2 - \sum (x_{i+} \times x_{+i}))}$$

Onde K = Coeficiente de Kappa, n = número total de amostras, r = número de classes, x_{ii} = número de acertos da classe i (diagonal principal), x_{i+} = total de elementos da classe i na classificação (soma da coluna i) e x_{+i} = total de elementos da classe i na referência (soma da linha i).

De acordo com Foody (2002) e Landis & Koch (1977), valores do coeficiente Kappa entre 0,21 e 0,40 são considerados indicativos de uma qualidade de classificação “Razoável”, enquanto valores acima de 0,80 representam níveis de acurácia classificados como “Excelentes”. Isso significa que quanto maior o valor de Kappa, maior é a concordância entre a classificação e a referência da “verdade terrestre”, indicado pela tabela 1.

Tabela 1 - Valores indicadores de qualidade do coeficiente Kappa.

Coeficiente Kappa	Qualidade
0,00	Péssima
0,01 a 0,20	Ruim
0,21 a 0,40	Razoável
0,41 a 0,60	Boa
0,61 a 0,80	Muito Boa
0,81 a 1,00	Excelente

Fonte: Adaptada de LANDIS; KOCH, 1977.

Também foram utilizados, como forma de avaliar a classificação das classificações, os valores da acurácia do produtor (AP), representado na Equação 3, que consiste na proporção de pixels de uma determinada classe corretamente classificadas em relação ao total de pixels dessa classe na verdade terrestre (referência). A acurácia do usuário (AU), Equação 4, indica a confiabilidade de uma classe no mapa classificado, ou seja, a probabilidade de um pixel classificado como pertencente a uma determinada classe realmente pertencer a essa classe na realidade.

$$(3) AP = (a_{ii} / \sum_j a_{ij}) \times 100$$

Onde AP = Acurácia do Produtor, a_{ii} = número de acertos na classe i e $\sum_j a_{ij}$ = total de pixels da classe i na referência (linha da matriz de confusão).

$$(4) AU = (a_{ii} / \sum_i a_{ji}) \times 100$$

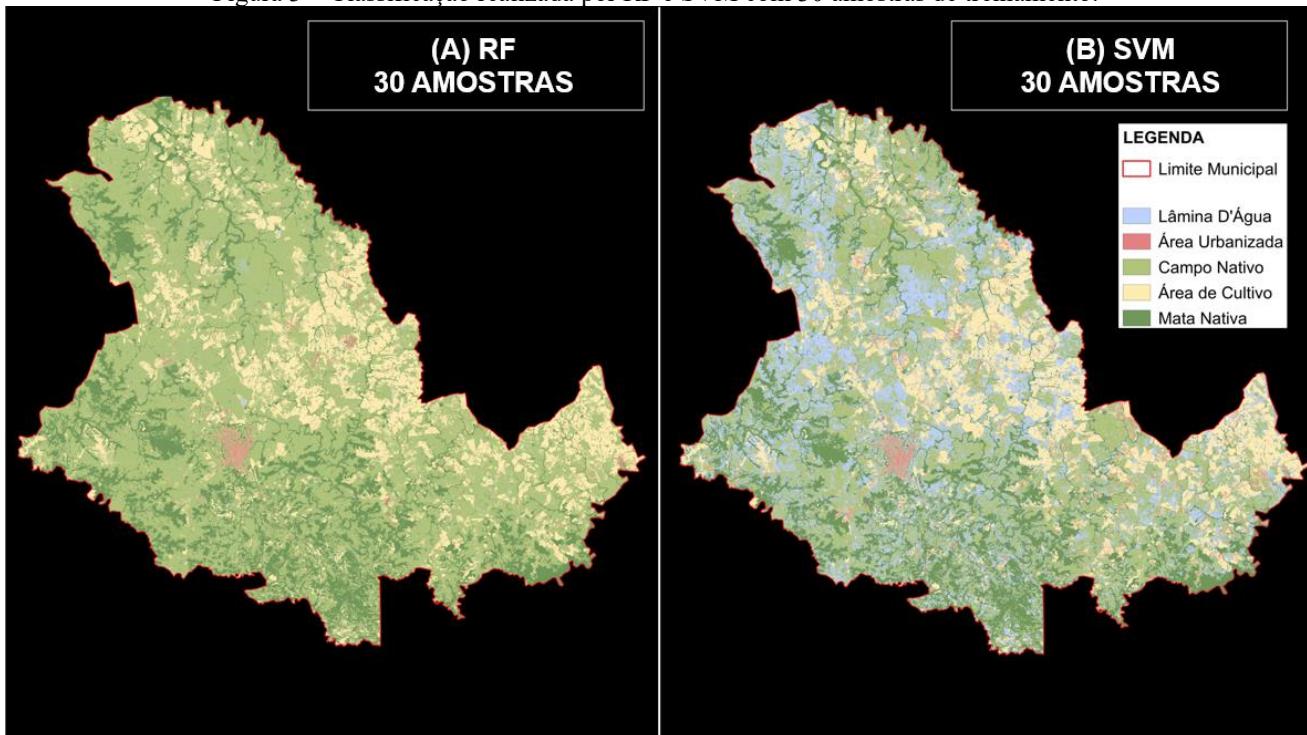
Onde AU = Acurácia do Usuário, a_{ii} = número de acertos na classe i e $\sum_i a_{ji}$ = total de pixels da classe i na referência (coluna da matriz de confusão).

A utilização dessas métricas permitiu comparar o desempenho entre os algoritmos e entre os dois cenários de amostragem.

3 RESULTADOS

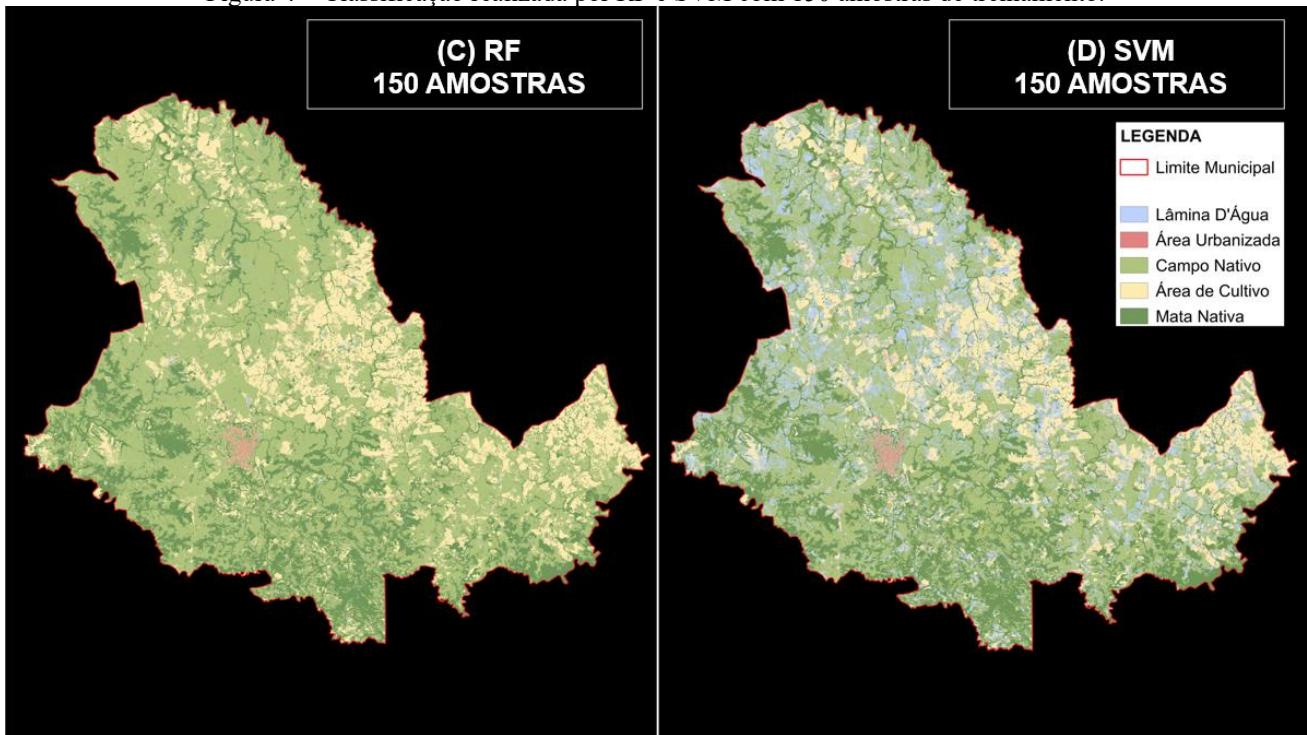
As figuras 3 e 4 representam os mapas temáticos gerados com base nas classificações realizadas, contendo as seguintes classes identificadas na legenda: Mata Nativa, Campo Nativo, Área Urbanizada, Área de Cultivo e Lâmina D'Água. Os mapas (A) e (B) representam, na devida ordem, os resultados de classificações dos modelos *Random Forest* e *Support Vector Machines* a trinta (30) amostras de treinamento por classe, enquanto os mapas (C) e (D) representam o desempenho dos mesmos modelos a cento e cinquenta (150) amostras por classe.

Figura 3 – Classificação realizada por RF e SVM com 30 amostras de treinamento.



Fonte: Elaborado pelo autor.

Figura 4 – Classificação realizada por RF e SVM com 150 amostras de treinamento.



Fonte: Elaborado pelo autor.

4 DISCUSSÃO

Nesse contexto, os mapas gerados pelo algoritmo *Support Vector Machines*, com trinta (30) e cento e cinquenta (150) amostras de treinamento, apresentaram, respectivamente, um coeficiente Kappa de 0,42 e 0,55, apresentando uma qualidade definida como ‘‘Boa’’. Já o *Random Forest*, com os mesmos números de amostras de treinamento, obteve valores de 0,51 e 0,65, definidos como qualidade ‘‘Boa’’ e ‘‘Muito Boa’’, descritos na tabela 2.

Tabela 2 - Valores do Coeficiente Kappa.

Classificadores	Número de Amostras	Coeficiente Kappa
<i>Random Forest</i>	30	0,51
<i>Support Vector Machines</i>	30	0,42
<i>Random Forest</i>	150	0,65
<i>Support Vector Machines</i>	150	0,55

Fonte: Elaborado pelo autor.

Conforme a tabela 3, no cenário com 30 amostras por classe, o algoritmo SVM registrou acurácia global de 54%, com médias das acuráncias de usuário e produtor de 54% e 44,02%, respectivamente, evidenciando a dificuldade do modelo em generalizar corretamente para além das amostras de treinamento.

Em contrapartida, o *Random Forest*, com o mesmo número de amostras, obteve desempenho superior sob as mesmas condições: acurácia global de 61,33% e acuráncias de usuário e produtor de 61,33% e 72,30% respectivamente, ambas superiores às do SVM. Isso indica maior capacidade do *Random Forest* em distinguir corretamente os diferentes padrões espectrais presentes na imagem, mesmo com um conjunto de treinamento limitado.

Quando se ampliou o número de amostras de treinamento para cento e cinquenta (150), ambos os algoritmos apresentaram melhora significativa no desempenho. O SVM obteve uma acurácia global de 64,67%, evidenciando maior estabilidade na classificação temática. A acurácia do produtor foi consideravelmente elevada, atingindo 84,71%, o que sugere uma boa capacidade do modelo em representar as classes no mapa. No entanto, a acurácia de usuário permaneceu abaixo da média, com valor de 64%.

O *Random Forest*, com 150 amostras por classe, obteve o melhor desempenho entre todos os testes realizados. Além do Kappa de 0,65, a acurácia global alcançou 72%, indicando um grau de concordância substancial. As métricas de acurácia do produtor (72,30%) e do usuário (61,33%) sustentaram essa tendência, reforçando a robustez do modelo. A estabilidade do *Random Forest*

mesmo diante de diferentes conjuntos amostrais revela sua eficácia na classificação de áreas com heterogeneidade espectral, como é o caso de Santiago.

Tabela 3 - Valores de Acurárias Global, do Usuário e Produtor.

Classificadores	N.º Amostras	Acurácia Global (%)	AU (%)	AP(%)
<i>Random Forest</i>	30	61,33	61,33	72,30
<i>Support Vector Machines</i>	30	54,00	54,00	44,02
<i>Random Forest</i>	150	72,00	71,60	79,88
<i>Support Vector Machines</i>	150	64,67	64,00	84,71

Fonte: Elaborado pelo autor.

De modo geral, os resultados corroboram estudos anteriores (BELGIU; DRĂGUȚ, 2016; MOUNTRAKIS; IM; OGDEN, 2011), que apontam o *Random Forest* como um dos algoritmos mais confiáveis para tarefas de classificação em sensoriamento remoto. Já o SVM, embora tenha melhorado com mais amostras, mostrou-se mais sensível à quantidade e qualidade dos dados de treinamento.

5 CONCLUSÃO

O modelo Random Forest obteve resultados superiores na maioria das métricas de avaliação na classificação das imagens de satélite do município de Santiago, especialmente utilizando 150 amostras de treinamento por classe. Os resultados obtidos sugerem que este classificador é mais eficiente em cenários com elevada complexidade espectral, proporcionando resultados mais acurados e mapas temáticos com maior confiabilidade.

Conclui-se, portanto, que a escolha do algoritmo e a definição adequada do número de amostras de treinamento exercem influência significativa sobre a qualidade dos mapas temáticos gerados. Os resultados obtidos indicam que o Random Forest é a alternativa mais indicada para mapeamentos em regiões com elevada variabilidade espectral, como as encontradas no Bioma Pampa. Além disso, destaca-se a aplicabilidade prática desse tipo de análise em atividades de planejamento agrícola, monitoramento ambiental e gestão territorial, podendo subsidiar políticas públicas e decisões estratégicas.

REFERÊNCIAS

- ADANKON, M. M.; CHERIET, M. Support Vector Machine. *Encyclopedia of Biometrics*, Boston, Springer, 2014. https://doi.org/10.1007/978-3-642-27733-7_299-3.
- ADUGNA, Tesfaye; XU, Wenbo; FAN, Jinlong. Comparison of Random Forest and Support Vector Machine Classifiers for Regional Land Cover Mapping Using Coarse Resolution FY-3C Images. *Remote Sensing*, Basel, v. 14, n. 3, p. 574, fev. 2022. DOI: <https://doi.org/10.3390/rs14030574>.
- ALMEIDA, J. P. et al. Caracterização ambiental e mudanças de uso da terra no Bioma Pampa. *UFSM*, Santa Maria, 2017.
- BOLDRINI, I. I. A flora dos campos do Rio Grande do Sul. *Biodiversidade dos campos do planalto das Araucárias*, Brasília, Ministério do Meio Ambiente, 2009.
- BELGIU, M.; DRĂGUȚ, L. Random forest in remote sensing: a review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 114, p. 24–31, 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0924271616000265>.
- FOODY, G. Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, v. 80, p. 185–201, 2002. DOI: 10.1016/S0034-4257(01)00295-4. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425701002954>.
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, n. 1, p. 159–174, 1977.
- LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. *Remote sensing and image interpretation*. 7. ed. New York: Wiley, 2015.
- LIU, W. T. H. Aplicações de sensoriamento remoto. São José dos Campos: INPE, 2015. p. 31.
- MOUNTRAKIS, G.; IM, J.; OGDEN, J. Support vector machines in remote sensing: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 66, n. 3, p. 247–259, 2011.
- NOVO, Evelyn M. L. de Moraes. Sensoriamento remoto: princípios e aplicações. 4. ed. São Paulo: Blucher, 2010. p. 28.
- RIZZI, R.; RUDORFF, B. F. T. Estimativa da área de soja no Rio Grande do Sul por meio de imagens Landsat. *Revista Brasileira de Cartografia*, v. 57, n. 3, p. 226–234, 2005. Disponível em: <https://www.scielo.br/j/cr/a/mLNgGc5bJdxqXZxMGVRYBwb>.
- SCHORR, C. L. et al. Estimativa objetiva da produtividade utilizando ferramentas do sensoriamento remoto: estudo de caso na safra de soja 2021/22 no Rio Grande do Sul. *Anais do Simpósio Brasileiro de Sensoriamento Remoto*, Florianópolis, v. 21, 2023.
- VAN GENDEREN, J. L.; LOCK, B. F.; VASS, P. A. Remote sensing: statistical testing of thematic map accuracy. *Remote Sensing of Environment*, v. 7, n. 1, p. 3–14, 1978. Disponível em: <https://www.sciencedirect.com/science/article/pii/0034425778900032>.