

CLASSIFICAÇÃO DO GÊNERO DE SILVICULTURA UTILIZANDO SÉRIES TEMPORAIS MULTI-SENSOR E APRENDIZADO DE MÁQUINA

Fernanda Beatriz Jordan Rojas Dallaqua¹, Bruno Schultz¹, Rafael Antônio Rosa¹, Júlio Bandeira Guerra¹ e Thiago Gonçalves Rodrigues¹

¹Visiona Tecnologia Espacial S.A., Rua Dr. Altino Bondensan, 500 - Distrito de Eugenio de Melo, São José dos Campos - SP, 12247-016.

{fernanda.dallaqua,bruno.schultz,rafael.rosa,julio.guerra,thiago.rodrigues}@visionaespecial.com.br

RESUMO

No Sul do Brasil tem se tornado comum a introdução de espécies de Eucalipto em áreas que até então eram plantadas com os gêneros *Pinus spp.* e *Araucaria sp.*. Atualmente, existe uma necessidade de entendimento do plantio do Eucalipto no Sul do país, principalmente para análises espaciais e de inteligência de mercado. Este trabalho teve como objetivo o uso de séries temporais multi-sensor e técnicas de aprendizado de máquina e *deep learning* na separação de Pinus e Eucalipto em duas fazendas em Telêmaco Borba – PR. Foram utilizadas quatro técnicas de classificação: (i) FCN Block, (ii) t-LSTM, (iii) t-biLSTM e (iv) SVM. A melhor técnica foi a t-biLSTM, que apresentou um coeficiente Kappa de 0,88, seguida de t-LSTM (Kappa = 0,87), FCN Block e SVM (Kappa = 0,81). As técnicas que usaram t-biLSTM e t-LSTM foram iguais entre si e superiores às outras técnicas, ao nível de 95% de confiança.

Palavras-chave – Pinus, Eucalipto, LSTM, Classificação de séries temporais, *Deep learning*.

ABSTRACT

In southern Brazil, it has become common to introduce Eucalyptus species in areas that until then were planted with the genera Pinus spp. and Araucaria sp. Currently, there is a need to understand the eucalyptus plantation in the south of the country, mainly for spatial analysis and market intelligence. This work aimed to use multi-sensor time series and machine learning and deep learning techniques in the separation of Pinus and Eucalyptus in two farms in Telêmaco Borba - PR. Four classification techniques were used: (i) FCN Block, (ii) t-LSTM, (iii) t-biLSTM and (iv) SVM. The best technique was t-biLSTM, which presented a Kappa coefficient of 0.88, followed by t-LSTM (Kappa = 0.87), FCN Block and SVM (Kappa = 0.81). The techniques that used t-biLSTM and t-LSTM were equal to each other and superior to the other techniques, at the 95% confidence level.

Key words – Pinus, Eucalyptus, LSTM, Time series classification, *Deep learning*.

1. INTRODUÇÃO

O Estado do Paraná é o principal produtor de fibra para produção de papel e celulose no Sul do Brasil. Em 2020, foram registrados 271 mil hectares de Eucalipto (5,86%

de aumento em dois anos) e 733 mil hectares de Pinus (7,09% de decremento em dois anos) plantados no estado [1]. Com a adoção de práticas de melhoramento genético para resistência a fatores bióticos e abióticos (geadas), menor rotação de plantio, custo da terra, preço da celulose, entre outros, percebe-se um aumento do plantio de Eucalipto em áreas tradicionalmente manejadas com Pinus, no Paraná.

Atualmente, algumas iniciativas foram realizadas para classificação de silvicultura em estados do Sul do Brasil, utilizando sensoriamento remoto com imagens *Landsat-like*. Coutinho et al. [2] fizeram um levantamento dos plantios de silvicultura no estado do Paraná com questionários de campo e classificação de imagens de sensoriamento remoto. O trabalho foi executado com imagens RapidEye e classificação visual. No final do trabalho, os autores definiram uma chave de classificação para separação de Pinus, Eucalipto e Araucária, a partir das bandas espectrais dos dados RapidEye. A banda do RedEdge foi eficiente na separação visual dos dois gêneros (Pinus e Eucalipto).

Veiga [3] trabalhou com imagens Sentinel-2A/B, técnicas de aprendizado de máquina e edição visual para separação de Pinus e Eucalipto no estado de Santa Catarina. O autor concluiu que a classificação híbrida (automática + visual) resultou em um Kappa de 0,90, valores superiores aos dados providos pelas iniciativas públicas, como: *MapBiomass* (Kappa = 0,81) e *Transparent World* (Kappa = 0,59).

Autores como Araya et al. [4] e Zeng et al. [5] enfatizaram que a extração de séries temporais a partir de atributos fenológicos aliada à *deep learning* produz resultados positivos para a classificação e separação de culturas agrícolas. No entanto, até o momento, não são encontrados trabalhos que mostrem testes de classificação de séries temporais para classificação automática de gêneros silvícolas.

Como melhoria aos projetos supracitados, o presente estudo tem como objetivo avaliar diferentes métodos de classificação de séries temporais, no intuito da separação automática de Pinus e Eucalipto em imagens *Landsat-like*, no estado do Paraná.

2. MATERIAL E MÉTODOS

A área de estudo compreende duas fazendas de plantio de silvicultura de Pinus e Eucalipto, denominadas aqui como AOI-01 e AOI-02, no município de Telêmaco Borba-PR. Os dados espaciais de cada talhão de silvicultura e sua respectiva espécie foram providos pela Empresa Klabin, para compor a base de dados de campo utilizada no projeto 2017 / 25639- 5




Figura 1: Área de estudo com as fazendas de plantio de Pinus e Eucalipto no município de Telêmaco Borba-PR.

	AOI-01	AOI-02	Total
Eucalipto	140	153	293
Pinus	192	108	300
Total	332	261	593

Tabela 1: Informações sobre o conjunto de dados utilizado.

- NRC - PIPE – Fase 2 Direta da FAPESP. A Figura 1 ilustra a localização da área de estudo.

No total, foram utilizados 593 talhões de silvicultura, dentre eles 300 de Pinus e 293 de Eucalipto, como detalhado na Tabela 1. Estes dados informaram a área disponível para a colheita de silvicultura destes gêneros para o ano de 2018.

Para a extração das séries temporais foram utilizadas imagens de sensoriamento remoto coletadas de 01/01/2000 a 31/12/2018. Essas imagens foram provenientes dos seguintes sistemas sensores/satélites: TM/Landsat-5, ETM+/Landsat-7, OLI/Landsat-8 e MSI/Sentinel-2A e B. Os produtos de sensoriamento remoto foram obtidos em reflectância da superfície, pelo acesso às coleções públicas de dados disponíveis na plataforma *Google Earth Engine* (GEE) [6].

Os dados dos sensores TM e ETM+ foram harmonizados para o sensor OLI com os coeficientes de calibração apresentados em Roy et al. [7] e para esses 3 sensores foram aplicados os fatores de escala definidos pelo *United States Geological Survey* (USGS) [8, 9]. Já para o sensor MSI, seus dados foram compatibilizados com o sensor OLI pelos coeficientes de calibração disponíveis no trabalho de Claverie et al. [10]. Após a compatibilização, foram extraídas as séries temporais de NDVI das observações de cada satélite para *buffer* de 30m ao redor do centroides interno (ponto representativo) de cada um dos 593 talhões. Foi decidido extrair dados apenas desse *buffer* e não do talhão inteiro a fim de evitar ruído.

Para a criação de uma série temporal representativa, com dados multi-sensor, da área de *buffer* ao redor do ponto representativo de cada talhão, foram aplicados cinco procedimentos operacionais no processamento dos dados brutos (observados): (1) Reamostragem das imagens para




Figura 2: Ilustração de série temporal multi-sensor processada.

AOI	id_talhão	Feature 1	Feature 2	...	Feature 230	Classe
01	154	0,8007	0,7652	...	0,8132	Eucalipto
01	64	0,8472	0,8206	...	0,8671	Pinus
02	250	0,8358	0,8120	...	0,9047	Eucalipto
02	222	0,8544	0,8394	...	0,8544	Pinus

Tabela 2: Exemplo de amostras utilizadas pelas técnicas de aprendizado de máquina e *deep learning*.

10m pelo método do vizinho mais próximo; (2) Extração da mediana espacial para obtenção dos valores de NDVI observados dos talhões; (3) Interpolação linear pelo máximo valor de NDVI observado dentro de uma janela temporal de 30 dias; (4) Filtragem pelo algoritmo suavizador mais conservador, *Flat-Bottom*, segundo Wardlow et al. [11]; (5) Interpolação linear pela média entre os dois vizinhos mais próximos para eliminação de dados faltantes na série temporal de NDVI.

A Figura 2 ilustra o comportamento de uma série temporal de 2000 a 2018 que passou pelos cinco procedimentos operacionais supracitados. No passo (1) todas as imagens são reamostradas para a mesma resolução espacial. Já no passo (2) é extraída a mediana do NDVI de todos os *pixels* que estão contidos no *buffer* de 30m ao redor do ponto representativo do talhão. Com isso existe apenas um conjunto de dados observados para representar o talhão e não um conjunto para cada *pixel* (redução espacial). Esses dados observados são de múltiplos satélites (Landsat-5, Landsat-7, Landsat-8 e Sentinel 2A/2B) e estão apresentados no sub-gráfico 'Dados Observados' da Figura 2. Para uma janela de 30 dias, através do passo (3), esses dados acabam se tornando um único dado, que é definido como 'Dados Interpolados' (apresentado como círculo azul no gráfico de 2000 a 2018). Esses dados interpolados são então filtrados pelo algoritmo *Flat-Bottom*, passo (4), a fim de eliminar artefatos. Para algumas janelas de 30 dias pode ocorrer de não existirem dados por causa de uma alta incidência de nuvens ou algum problema inerente ao sensor, por exemplo. A fim de evitar esses dados faltantes na série temporal resultante é realizado o passo (5), em que o dado faltante será a média entre o dado da data anterior e o da data posterior. Após esse quinto passo, tem-se a série temporal representada pela linha verde, 'Dados Filtrados'.

A série temporal de NDVI criada para cada talhão de silvicultura continha 230 valores, espaçados a cada 30 dias. Esses valores, exemplificados na Tabela 2, foram utilizados como atributos (*features*) em quatro técnicas de classificação de séries temporais, sendo três baseadas em *deep learning* e na outra sendo utilizado *Support Vector Machine* (SVM). As

técnicas de *deep learning* foram:

- FCN (*Fully Convolutional Network*) Block [12]: rede com seis camadas convolucionais de uma dimensão, camadas de *batch normalization* e de ativação (*ReLU*), uma camada de *pooling*, *dropout* de 0.5, uma camada densa com ativação *softmax* e *learning rate* de 0,001;
- t-LSTM [13]: uma camada *Long Short Term Memory* (LSTM) conectada a uma camada densa com ativação *ReLU*, outra camada densa com ativação *softmax* e *learning rate* de 0,0005;
- t-biLSTM [13]: mesma estrutura que a t-LSTM, porém a camada recorrente é composta por uma LSTM bidirecional (biLSTM).

Para a implementação das técnicas baseadas em *deep learning* foi utilizada a biblioteca *Tensorflow* [14] e parâmetros *batch_size* = 32, 150 épocas, otimizador Adam e *categorical_crossentropy* como função de perda. Além disso, para evitar *overfitting*, foi realizado *early stopping* e os melhores modelos foram salvos em arquivos *.h5*. Já para o SVM foi utilizada a biblioteca *scikit-learn* [15], sendo realizada a otimização dos parâmetros *C* e *gamma*, respectivamente dentro dos valores [0.25, 0.5, 1, 2, 4, 8, 16, 32, 64, 128] e [0.03125, 0.0625, 0.125, 0.25, 0.5, 1, 2, 4, 8, 16].

Para a fase de treinamento x validação x teste foram montados 10 *folds* estratificados pelas classes, em que cada *fold* continha cerca de 30 amostras de Pinus e 30 amostras de Eucalipto. Para a validação cruzada, 9 *folds* foram utilizados como treinamento e 1 *fold* para teste. Para as técnicas de *deep learning*, dentro do conjunto de 9 *folds*, 10% das amostras são utilizadas como conjunto de validação dos modelos. E, a fim de o SVM utilizar o mesmo conjunto que as outras técnicas, esses 10% de amostras são descartados do treinamento para essa técnica.

Foi realizado o Teste de Tukey [16] ao nível de confiança de 95% para comprovação da diferença significativa entre a precisão dos resultados dos quatro métodos de classificação de séries temporais. Anterior a isso, foi avaliada a homoscedasticidade das médias dos resultados de Kappa dentro das amostras dos 10 experimentos realizados.

3. RESULTADOS

A Figura 3 ilustra as séries temporais filtradas de um talhão de Pinus e de Eucalipto. Em azul, a série temporal mostra a evolução do NDVI do Pinus plantado em 01/10/2005. Em verde, a série temporal mostra a evolução do NDVI do Eucalipto plantado em 13/05/2011. Ainda na série em verde, caso a plantação anterior ao plantio de 13/05/2011 tenha sido de Eucalipto, é possível perceber dois ciclos de Eucalipto em um único ciclo de Pinus, em azul. Essa comparação entre Pinus e Eucalipto mostra a eficiência da resposta do NDVI de séries temporais históricas, como atributos para diferenciação destas duas espécies silvícolas plantadas no Paraná.

A Tabela 3 apresenta as médias dos resultados obtidos pelos modelos FCN Block, t-LSTM, t-biLSTM e SVM para os 10 experimentos realizados. As técnicas de redes




Figura 3: Séries temporais filtradas para um talhão de Pinus e um talhão de Eucalipto.

	FCN Block	t-LSTM	t-biLSTM	SVM
ACC	0,91	0,93	0,94	0,91
ACC Eucalipto (recall)	0,89	0,91	0,91	0,99
ACC Pinus	0,92	0,96	0,97	0,83
Precisão	0,92	0,96	0,96	0,85
F1-score	0,90	0,93	0,94	0,92
Kappa	0,81 (B)	0,87 (A)	0,88 (A)	0,82 (B)

ACC = Acurácia. Médias do Kappa precedidos pela mesma letra são significativamente iguais ao nível de 95% de confiança pelo teste de Tukey.

Tabela 3: Métricas de validação geradas para o resultado dos modelos de *deep learning* e aprendizado de máquina.

recorrentes, com camadas LSTM, apresentaram melhores resultados de Kappa que FCN Block e SVM. Além disso, a t-biLSTM e a t-LSTM foram estatisticamente iguais ao nível de confiança de 95%. A diferença entre t-biLSTM e t-LSTM é que a biLSTM consiste na combinação de duas LSTMs, uma processando a série temporal do presente para o passado (*backward*) e do passado para o presente (*forward*). Já a t-LSTM avalia os dados em modo *forward*, sendo menos custosa computacionalmente.

Ao avaliar as métricas ACC Eucalipto (recall) e ACC Pinus, que mostram o acerto das classes, para os dois modelos LSTM, o melhor resultado foi para classificação de Pinus (0,96) comparado ao Eucalipto (0,91). No conjunto de dados foi observado uma maior quantidade de espécies de Eucalipto (*E. grandis* x *E. Urophylla*, *E. salygna*, *E. Urophylla* x *E. globulus*, *E. grandis* x *E. camaldulensis*, e *E. grandis*) e uma única espécie de Pinus (*Pinus taeda*). Esta variação pode ter comprometido a análise do gênero Eucalipto.

Mais estudos devem ser tratados no sentido de analisar a semelhança das séries temporais das espécies de Eucalipto. O *Self-Organizing Map* (SOM) publicado por Silva et al. [17], por exemplo, pode auxiliar na criação não supervisionada de *clusters* destas espécies, para melhorar o resultado da classificação dada pela t-LSTM.

4. DISCUSSÃO

As séries temporais históricas de NDVI processadas, de acordo com o método operacional proposto neste presente estudo produziu dados suficientes para os modelos de classificação de séries temporais mostrarem robustez na classificação supervisionada de Pinus e Eucalipto em um

cenário de quase 600 talhões de silvicultura.

Entre os quatro modelos testados, os modelos t-LSTM e t-biLSTM tiveram o melhor resultado de validação e foram iguais estatisticamente, ao nível de confiança de 95%. Como o SVM não extrai o contexto dos dados como as técnicas de *deep learning*, apenas analisando os valores de NDVI de maneira individual, ele apresenta algumas métricas inferiores às outras técnicas. E ao contrário de FCN Block, t-LSTM e t-biLSTM, que tiveram mais facilidade em reconhecer Pinus, o SVM quase reconheceu corretamente todos os talhões de Eucalipto, também impactando na métrica F1-score e deixando-a comparável à das outras métricas.

Para uma possível melhora dos resultados alcançados, propõem-se que as séries temporais históricas sejam pré-classificadas por métodos não supervisionados, como o SOM. Além disso, é planejada a obtenção de mais dados, abrangendo novas áreas de silvicultura, a fim de aumentar a diversidade dos modelos e dos testes.

5. CONCLUSÕES

A partir dos resultados alcançados nesse trabalho, conclui-se que as séries temporais históricas multi-sensor são capazes de gerar informação suficiente para suporte à modelos de *deep learning* na separação de Pinus e Eucalipto. As técnicas t-LSTM e t-biLSTM tiveram resultados de Kappa igual a 0,87 e 0,88, respectivamente, com resultados semelhantes ao obtido por Veiga et al. [3] (Kappa = 0,90) e superiores aos obtidos pelo *MapBiomass* (Kappa = 0,81) e *Transparent World* (Kappa = 0,59).

6. AGRADECIMENTOS

Este trabalho teve apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo nº 2020/01468-0 - NRC - PIPE - Fase 2 Direta, projeto “Solução para avaliação de florestas por sensoriamento remoto”.

7. REFERÊNCIAS

- [1] Indústria Brasileira de Árvores. Relatório Anual Ibá 2021. 2021. Acessado 10-Outubro-2022.
- [2] V. M. Coutinho, A. P. Dalla Corte, C. R. Sanquetta, A. M. K. Hentz, R. L. Eisfeld, and F. A. F. Do Nascimento. Mapeamento das áreas plantadas de *Eucalyptus spp.* no estado do paraná. *Biofix Scientific Journal*, 2(1):32–43, 2017.
- [3] J. Veiga. Viabilidade de imagens sentinel-2 no mapeamento de povoamentos de *Pinus sp.* e *Eucalyptus sp.* em Santa Catarina. Dissertação de Mestrado, Universidade do Estado de Santa Catarina, 2020.
- [4] S. Araya, B. Ostendorf, G. Lyle, and M. Lewis. Crop phenology: An R package for extracting crop phenology from time series remotely sensed vegetation index imagery. *Ecological Informatics*, 46:45–56, 2018.
- [5] L. Zeng, B. D. Wardlow, D. Xiang, S. Hu, and D. Li. A review of vegetation phenological metrics extraction using time-series, multispectral satellite data. *Remote Sensing of Environment*, 237:111511, 2020.
- [6] M. Amani, A. Ghorbanian, S. A. Ahmadi, M. Kakooei, A. Moghimi, S. M. Mirmazloumi, S. H. A. Moghaddam, S. Mahdavi, M. Ghahremanloo, S. Parsian, Q. Wu, and B. Brisco. Google Earth Engine cloud computing platform for remote sensing big data applications: A comprehensive review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13:5326–5350, 2020.
- [7] D. P. Roy, V. Kovalsky, H. K. Zhang, E. F. Vermote, L. Yan, S. S. Kumar, and A. Egorov. Characterization of landsat-7 to landsat-8 reflective wavelength and normalized difference vegetation index continuity. *Remote Sensing of Environment*, 185:57–70, 2016. Landsat 8 Science Results.
- [8] U.S. Geological Survey. *Landsat 4-7 Collection 2 (C2) Level 2 Science Product (L2SP) Guide*.
- [9] U.S. Geological Survey. *Landsat 8-9 Collection 2 (C2) Level 2 Science Product (L2SP) Guide*.
- [10] M. Claverie, J. Ju, J. G. Masek, J. L. Dungan, E. F. Vermote, J.-C. R., S. V. Skakun, and C. Justice. The harmonized landsat and sentinel-2 surface reflectance data set. *Remote Sensing of Environment*, 219:145–161, 2018.
- [11] B. D. Wardlow, J. H. Kastens, and S. L. Egbert. Using usda crop progress data for the evaluation of greenup onset date calculated from modis 250-meter data. *Photogrammetric Engineering & Remote Sensing*, 72(11):1225–1234, 2006.
- [12] S. Usmankhujayev, B. Ibrokhimov, S. Baydadaev, and J. Kwon. Time series classification with InceptionFCN. *Sensors*, 22(1), 2022.
- [13] K. K. Gadiraju, B. Ramachandra, Z. Chen, and R. R. Vatsavai. Multimodal deep learning based crop classification using multispectral and multitemporal satellite imagery. In *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery Data Mining, KDD '20*, page 3234–3242, New York, NY, USA, 2020. Association for Computing Machinery.
- [14] M. Abadi, P. B., J. Chen, Z. Chen, A. Davis, J. Dean, M. Devin, S. Ghemawat, G. Irving, M. Isard, M. Kudlur, J. Levenberg, R. Monga, S. Moore, D. G. Murray, B. Steiner, P. Tucker, V. Vasudevan, P. Warden, M. Wicke, Y. Yu, and X. Zheng. TensorFlow: A system for Large-Scale machine learning. In *12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16)*, pages 265–283, Savannah, GA, November 2016. USENIX Association.
- [15] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, et al. Scikit-learn: Machine learning in python. *the Journal of machine Learning research*, 12:2825–2830, 2011.
- [16] Victor Chew. *Comparisons among treatment means in an analysis of variance*, volume 6. Department of Agriculture, Agricultural Research Service, 1977.
- [17] B. L. C. Silva, F. C. Souza, K. R. Ferreira, G. R. Queiroz, and L. A. Santos. Spatiotemporal segmentation of satellite image time series using self-organizing map. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, V-3-2022:255–261, 2022.