

# Deep Learning e Agricultura Digital: Avaliação de Arquiteturas para Mapeamento Automatizado de Café com Séries Temporais de Imagens Orbitais

Clara L. Moreno<sup>1</sup>, Vanessa C. O. Souza<sup>1</sup>, Melise M. V. Paula<sup>1</sup>,  
Margarete M. L. Volpato<sup>2</sup>, Helena M. R. Alves<sup>3</sup>

<sup>1</sup>Universidade Federal de Itajubá  
IESTI - IMC – Itajubá – MG – Brasil

<sup>2</sup>Empresa de Pesquisa Agropecuária de Minas Gerais (EPAMIG)  
Lavras – MG – Brasil

<sup>3</sup>Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA-CAFÉ)  
Lavras – MG – Brasil

{d2022003835, vanessa, melise}@unifei.edu.br

margarete@epamig.br, helena.alves@embrapa.br

**Abstract.** *This study evaluates TempCNN, L-TAE, and ResNet architectures for coffee mapping in Bom Sucesso (MG) using Sentinel-2 image time series. Using the Brazil Data Cube's SITS package, performance was compared across five spectral attribute sets during the 2017-2018 and 2021-2022 periods. Friedman and Wilcoxon statistical tests on the IoU indicate that TempCNN with the most complete set—including bands and spectral indices—achieved greater stability and generalization despite climatic variations. The study concludes that temporal convolutional models incorporating multiple spectral indices are effective for robust coffee monitoring in rugged terrains.*

**Resumo.** *Este trabalho avalia as arquiteturas TempCNN, L-TAE e ResNet para o mapeamento de café em Bom Sucesso (MG) a partir de séries temporais de imagens do Sentinel-2. Utilizando o pacote SITS do Brazil Data Cube, comparou-se o desempenho em cinco conjuntos de atributos espectrais nos períodos 2017-2018 e 2021-2022. Testes estatísticos de Friedman e Wilcoxon sobre o IoU indicam que a TempCNN, associada ao conjunto de atributos mais abrangente (bandas e índices de vegetação), obteve maior estabilidade e generalização frente a variações climáticas. Conclui-se que modelos convolucionais temporais, integrados a múltiplos índices espectrais, são eficazes para o monitoramento da cafeicultura em relevos acidentados.*

## 1. Introdução

O uso de algoritmos de aprendizado de máquina tem se consolidado como elemento central da Agricultura 4.0, permitindo mapeamento automatizado do uso da terra a partir de dados de sensoriamento remoto, com maior eficiência e precisão. No Brasil, a cafeicultura assume papel de protagonismo global, com o país detendo cerca de 37% da produção mundial [USDA 2025]. O estado de Minas Gerais lidera este setor, concentrando 75,2%

da área nacional de café arábica (1,38 milhão de hectares). Dada a relevância socioeconômica dessa cadeia produtiva, o conhecimento detalhado do parque cafeeiro é indispensável para a gestão eficiente e a manutenção da competitividade do estado.

Apesar dos avanços em geotecnologias e aprendizado de máquina voltados ao mapeamento automático, o café impõe desafios particulares. O relevo montanhoso das áreas de cultivo, a predominância de pequenas propriedades de agricultura familiar e a similaridade espectral entre os cafezais e a vegetação nativa dificultam a classificação precisa. Para contornar esses obstáculos, a inclusão de informações temporais tem se mostrado uma estratégia promissora [Hand et al. 2024, Le et al. 2022].

Neste trabalho, a abordagem *time-first space-later* foi aplicada a séries temporais do satélite Sentinel-2 para o mapeamento de áreas cafeeiras em Bom Sucesso (MG). Nessa abordagem, cada pixel é associado a uma série temporal. Os algoritmos primeiro classificam cada série temporal individualmente (*time-first*) e, posteriormente, é aplicado um pós-processamento espacial para capturar informações da vizinhança (*space-later*) [Simoes et al. 2021].

Baseando-se em evidências de que modelos de *Deep Learning*, como a TempCNN, superam métodos tradicionais como *Random Forest* em terrenos acidentados [Santos et al. 2025], esta pesquisa concentra-se exclusivamente em arquiteturas de aprendizado profundo, sendo elas: L-TAE, TempCNN e ResNet. Os experimentos foram conduzidos a partir de duas séries temporais distintas (2017–2018 e 2021–2022), permitindo avaliar o comportamento dos modelos em diferentes condições ambientais.

Dessa forma, este trabalho busca responder às seguintes questões: (i) qual arquitetura apresenta o melhor desempenho no mapeamento de cafezais a partir de séries temporais de sensoriamento remoto; (ii) qual a influência de diferentes conjuntos de atributos espectrais no desempenho dos modelos; e (iii) se os modelos apresentam desempenho consistente entre os dois períodos analisados. Ao responder a essas questões, espera-se identificar arquiteturas mais robustas e estáveis para o mapeamento cafeeiro em regiões declivosas, contribuindo para aplicações de sensoriamento remoto voltadas ao monitoramento agrícola e à agricultura digital.

O restante do artigo está organizado da seguinte forma. A Seção 2 apresenta uma breve revisão de literatura. A Seção 3 descreve os dados e a metodologia utilizada. A Seção 4 apresenta os resultados e a discussão. Por fim, a Seção 5 contém as considerações finais do trabalho.

## 2. Revisão de Literatura

A agricultura digital representa uma transformação nos sistemas de produção agrícola, integrando tecnologias avançadas de sensoriamento remoto, análise de dados e inteligência artificial para otimizar o manejo de culturas e recursos naturais. O sensoriamento remoto agrícola baseia-se na captura e análise de informações espectrais refletidas ou emitidas pelas culturas e pelo solo. As diferentes bandas espectrais fornecem informações complementares sobre características biofísicas das plantas, como biomassa, conteúdo de clorofila, estresse hídrico e estágio fenológico. A integração de múltiplas bandas e índices de vegetação viabiliza o mapeamento e a caracterização de culturas agrícolas [Parreiras et al. 2025].

O avanço dos algoritmos de aprendizado de máquina e das metodologias associadas ao seu uso tem impulsionado a agricultura digital. Técnicas como *Random Forest* (RF), *Support Vector Machine* e redes neurais convolucionais (CNNs), amplamente empregadas na classificação de imagens e no mapeamento de culturas [AlAli 2025], vêm gradualmente sendo substituídas por abordagens mais sofisticadas. Arquiteturas de *Deep Learning*, como U-Net, ResNet e *Transformers*, têm demonstrado capacidade superior de extrair características complexas de imagens, resultando em maior robustez frente à variabilidade espectral das culturas [Pisl et al. 2024].

Segundo [Brito et al. 2023], o uso de séries temporais no mapeamento do uso do solo aumenta a precisão das classificações ao capturar a sazonalidade e a dinâmica fenológica da vegetação. Séries temporais consistem em conjuntos de dados coletados em intervalos regulares ao longo do tempo, sendo amplamente utilizadas para identificar padrões, tendências e mudanças [Simoes et al. 2021]. No sensoriamento remoto, essas séries podem ser organizadas em cubos de dados geográficos, estruturas compostas por duas dimensões espaciais (latitude e longitude) e uma dimensão temporal, associadas às bandas espectrais das imagens [Ferreira et al. 2020].

No Brasil, o projeto *Brazil Data Cube* (BDC), desenvolvido pelo INPE, disponibiliza dados prontos para análise em escala nacional. Além da infraestrutura de dados, o projeto disponibiliza o pacote *Satellite Image Time Series* (SITS), desenvolvido em R, que permite acessar, manipular e classificar séries temporais de imagens de satélite por meio de técnicas de aprendizado de máquina [Simoes et al. 2021]. Dentre os algoritmos de *Deep Learning* supervisionados do SITS, destacam-se Rede Neural Convolucional Temporal (TempCNN), *Lightweight Temporal Attention Encoder* (L-TAE) e a Rede Residual (ResNet).

A TempCNN utiliza convoluções unidimensionais para extrair padrões das curvas espectrais ao longo do eixo temporal. A ResNet emprega blocos residuais que permitem o uso de arquiteturas profundas para identificar características complexas nos dados de satélite. Por fim, o L-TAE baseia-se em mecanismos de autoatenção para atribuir pesos diferentes às datas da série, priorizando os momentos de maior relevância fenológica para a classificação [Simoes et al. 2021]. As três arquiteturas garantem que a ordenação sequencial dos elementos da série temporal seja preservada durante o processo de aprendizado da rede neural [Werner et al. 2024].

[Werner et al. 2024] compararam RF, TempCNN, ResNet e L-TAE para mapear sistemas integrados de lavoura-pecuária (ILP) em dois estados brasileiros. Como resultado, a TempCNN apresentou o melhor desempenho, com acurácia global superior a 90% e *F1-Score* de 86,6% para a classe ILP. O RF foi competitivo em áreas mais homogêneas. Para os autores, paisagens mais complexas — com maior fragmentação e variação espacial — exigem modelos com maior capacidade de capturar padrões temporais, o que explica o melhor desempenho das arquiteturas profundas, especialmente a TempCNN.

Na cafeicultura, a modelagem de séries temporais tem sido eficaz para mapear estágios de produção e diferenciar cafezais de outras vegetações. [Parreiras et al. 2025] alcançaram *F1-score* de 0,91 para a classe café utilizando séries temporais do conjunto Harmonized Landsat–Sentinel combinadas com modelos *ensemble* baseados em *Random Forest* e XGBoost. Já [Santos et al. 2025] compararam o algoritmo *Random Forest* com

a arquitetura TempCNN em áreas cafeeiras de Minas Gerais, observando que, embora ambos superem 85% de acurácia, a rede neural profunda apresentou maior robustez em regiões de declividade acentuada.

### 3. Materiais e Métodos

A metodologia adotada seguiu o protocolo clássico de aprendizado supervisionado. A primeira etapa é a de aquisição dos dados. A segunda etapa consiste no tratamento e no pré-processamento dos dados. Na terceira etapa, modelos de aprendizado de máquina são aplicados para classificar as séries temporais. Finalmente, o desempenho dos modelos é avaliado para garantir sua precisão na quarta etapa.

#### 3.1. Aquisição de Dados

A área de estudo foi o município de Bom Sucesso, em Minas Gerais, integrante da IG Campo das Vertentes, com aproximadamente 705 km<sup>2</sup>. Os dados de uso da terra referentes à cafeicultura foram fornecidos pela Empresa de Assistência Técnica e Extensão Rural do Estado de Minas Gerais (EMATER), responsável pelo mapeamento do parque cafeeiro do estado no âmbito do projeto Geoportal do Café [EMATER 2025], que utiliza imagens de satélite e validação em campo. Foram disponibilizados dois mapeamentos, referentes aos anos de 2018 e 2022. Segundo esse levantamento, a cafeicultura ocupava 378,31 km<sup>2</sup> em 2018 (53,62% da área municipal) e 412,17 km<sup>2</sup> em 2022 (58,44%), indicando a importância da cultura para o município. Ademais, a maior área do município (393,48 km<sup>2</sup>) encontra-se na faixa de declividade Ondulado, com inclinação entre 8 e 20 graus. No entanto, apresenta áreas cultivadas com café próximas a declividades entre 20 e 45 graus (forte ondulado).

O conjunto amostral de treinamento foi composto por cinco mil pontos, sendo metade gerada aleatoriamente em áreas mapeadas como café pelo Geoportal do Café e a outra metade em áreas de não café dentro do município. Outros cinco mil pontos, obtidos da mesma forma, foram utilizados para teste, sendo que os pontos de 2018 são distintos dos de 2022.

Para cada ano de mapeamento, extraíram-se séries temporais de dois anos a partir da coleção S2-16D-2 de imagens do satélite Sentinel do BDC. Essa coleção é caracterizada por composições temporais de 16 dias com a seleção dos pixels com mínima cobertura de nuvens e 10 m de resolução espacial [Ferreira et al. 2020]. Considerando a bienalidade do café, cada série foi composta por 46 observações, utilizando as bandas B02 (B), B03 (G), B04 (R), B06 (*Red-Edge*) e B08 (NIR), além dos índices espectrais EVI e NDVI já disponíveis no cubo. Para o mapeamento de 2018 foi utilizada a série de 01/01/2017 a 31/12/2018 e, para 2022, a série de 01/01/2021 a 31/12/2022. Cada um dos dez mil pontos amostrais foi então associado às bandas, aos índices espectrais e à classe “café” ou “não café”.

#### 3.2. Tratamento e Pré-processamento dos Dados

As imagens do Sentinel-2 usadas no cubo são *Analysis Ready Data* (ARD) onde os valores brutos do sensor são convertidos para refletância de superfície escalonada, armazenada como inteiros com fator de escala 0,0001. Após a aplicação desse fator, os valores encontram-se aproximadamente no intervalo [0,1] [Ferreira et al. 2020]. Dessa forma,

não foi necessária uma etapa adicional de normalização para ajuste de escala antes do treinamento dos modelos.

No caso de haver dados faltantes na série, o que pode ocorrer se não houver um pixel suficientemente bom nos 16 dias que o cubo utiliza para gerar o dado, o pacote *SITS* aplica uma interpolação linear por padrão no momento da aquisição dos dados [Simoes et al. 2021].

Posteriormente à carga do cubo, foram computados três índices espectrais frequentemente utilizados em estudos de vegetação e considerados úteis para a cafeicultura:

- *Normalized Difference Water Index*: Realça superfícies com alta presença de água e também pode contribuir para o contraste entre vegetação densa e áreas de solo exposto ou vegetação seca.  $NDWI = \frac{G-NIR}{G+NIR}$
- *Visible Atmospherically Resistant Index*: Útil para distinguir áreas vegetadas de solo exposto ou pastagens secas.  $VARI_{green} = \frac{G-R}{G+R-B}$
- *Modified Soil-Adjusted Vegetation Index*: Útil em áreas com vegetação menos densa, como plantios jovens ou recentemente podados.

$$MSAVI = \frac{2*NIR+1-\sqrt{(2*NIR+1)^2-8*(NIR-R)}}{2}.$$

Assim, o *dataset* de cada intervalo temporal continha um cubo com 46 imagens com 10 bandas em cada uma. Para a análise *time-first space-later*, o cubo representa que cada pixel tem uma série temporal com 46 observações e, para cada observação, há 10 atributos. Esse mesmo *dataset* foi estruturado em cinco diferentes *Feature Sets*, conforme descrito na Tabela 1.

**Tabela 1. Conjuntos de atributos diferentes gerados**

| Feature Set | Bandas                                     | Feature Set | Bandas   |
|-------------|--|-------------|--|
| 1           | R, G, B, NIR                               | 4           | R, G, B, NIR, RE                               |
| 2           | R, G, B, NIR, EVI, NDVI                    | 5           | R, G, B, NIR, RE, EVI, NDVI, NDWI, VARI, MSAVI |
| 3           | R, G, B, NIR, EVI, NDVI, NDWI, VARI, MSAVI |             |  |

### 3.3. Modelos de Classificação e Avaliação

Para cada *Feature Set*, foram treinados três modelos de *Deep Learning*: TempCNN, L-TAE e ResNet. Em cada combinação entre modelo e *Feature Set*, realizou-se a seleção de hiperparâmetros por meio de um processo de *tuning* (*Random Search*) com 50 iterações, totalizando 15 modelos treinados para cada período avaliado. Para a TempCNN, o ajuste focou na arquitetura (camadas, filtros e *dropout*). Para o L-TAE e a ResNet, priorizou-se a otimização (tipo de otimizador, lote e estabilidade), incluindo o decaimento da taxa de aprendizado na ResNet. Em todos os modelos, a taxa de aprendizado e o decaimento de peso foram explorados em escala log-uniforme.

Os modelos foram avaliados inicialmente por validação cruzada estratificada de 5-folds no conjunto de treinamento. Em seguida, cada modelo foi treinado utilizando todo o conjunto de treinamento e avaliado sobre um conjunto de teste independente, composto por cinco mil pontos distintos daqueles utilizados no treinamento.

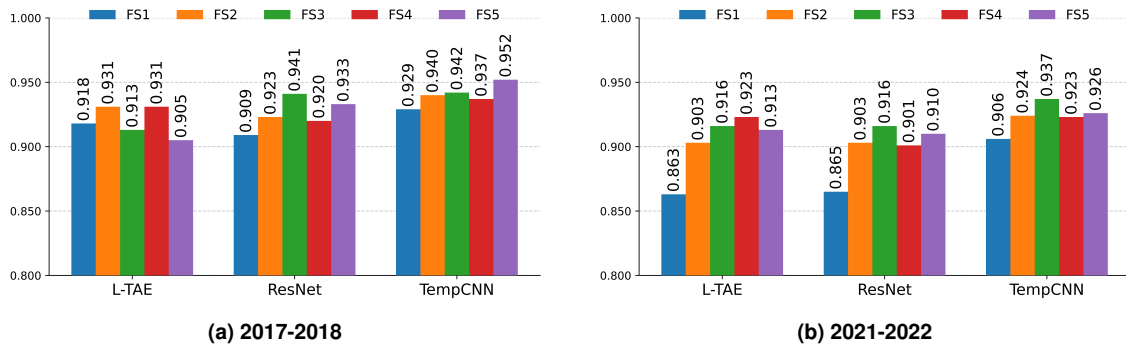
Embora a *F1-Score* forneça uma visão geral do desempenho no conjunto de teste, a análise espacial baseada em *Intersection over Union* (IoU) permite avaliar a variabilidade do desempenho no território. Neste contexto, os modelos treinados foram aplicados

à totalidade do município de Bom Sucesso (MG). Para a análise espacial comparativa, o território foi subdividido em 91 células regulares de  $3 \times 3$  km e a métrica IoU foi calculada para cada célula. Essa estratégia de subdivisão foi adotada para gerar múltiplas unidades de observação independentes e pareadas, permitindo a aplicação de testes não-paramétricos para comparação de classificadores em diferentes cenários espaciais, conforme preconizado por [Demšar 2006]. Para evitar o vazamento de dados, os 10 mil pontos utilizados no treinamento e teste foram removidos do cálculo da IoU. Células que não continham café foram excluídas do cálculo por gerarem valores de IoU inválidos (NaN), totalizando 82 células válidas para a análise estatística.

Para verificar diferenças significativas entre os modelos dentro de cada período analisado, aplicou-se o teste de Friedman, seguido pelo teste *post-hoc* de Wilcoxon com correção de Holm ( $\alpha = 0,05$ ), conforme indicado por [Demšar 2006]. A hipótese nula de Friedman é que  $H_0$ : todos os algoritmos possuem desempenho equivalente (mesma distribuição de rankings). Se o  $p$ -valor  $< 0,05$ , a hipótese nula é rejeitada, o que significa que os algoritmos apresentam desempenhos distintos.

Adicionalmente, o teste *Wilcoxon signed-rank* foi utilizado para avaliar a estabilidade temporal de cada modelo entre as duas séries (2017-2018 e 2021-2022). Nesse caso, a hipótese nula é definida como  $H_0$ : a mediana das diferenças de IoU entre os períodos é igual a zero, indicando que não houve mudança no desempenho do modelo entre as séries analisadas.

#### 4. Resultados e Discussão



**Figura 1. Comparação do *F1-Score* computada sobre o conjunto de teste (5 mil pontos) para ambos períodos analisados.**

A Figura 1(a) apresenta o *F1-Score* obtido no conjunto de teste dos 15 modelos para o período 2017-2018. Nota-se que a TempCNN e a ResNet alcançaram os maiores desempenhos (entre 0,952 e 0,941). Fica nítida também a influência do *Feature Set* (FS) nos resultados: para a ResNet e a TempCNN, os melhores resultados ocorreram nos conjuntos FS3 e FS5 (Tabela 1). Em contrapartida, o L-TAE apresentou seus piores resultados nesses conjuntos, obtendo seus melhores valores no FS2 e no FS4.

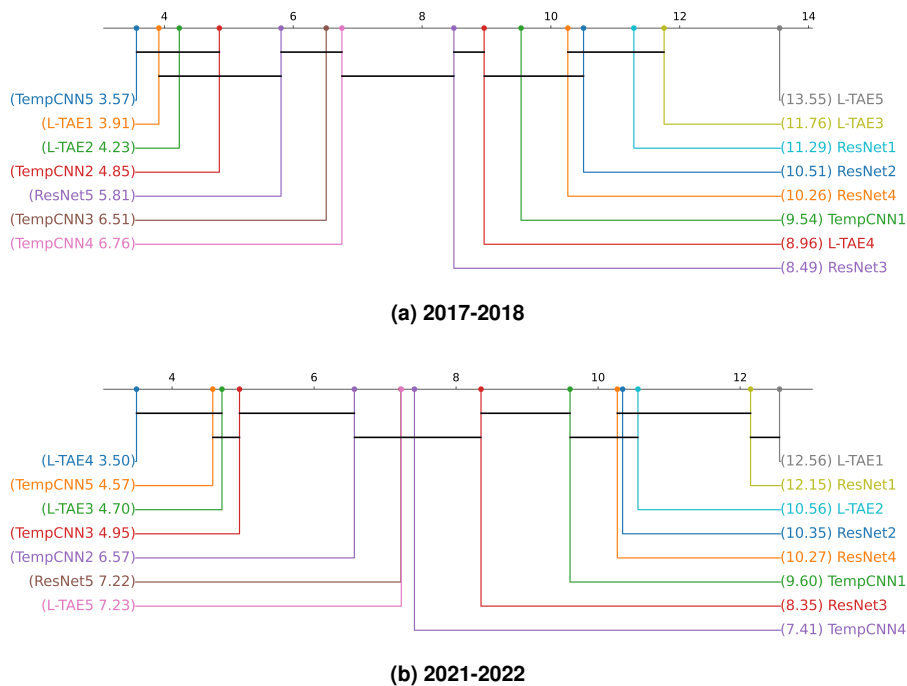
A Figura 1(b) detalha o período 2021-2022, no qual TempCNN e L-TAE lideraram com picos de 0,937 (FS3) e 0,923 (FS4), respectivamente. Houve uma queda de desempenho global comparado a 2017-2018, especialmente no conjunto FS1.

Uma possível explicação é a geada ocorrida em julho de 2021 no Sul e Sudoeste de Minas Gerais. O cafeeiro é sensível ao frio, e geadas podem causar desde danos

foliares até a morte da planta, alterando a resposta espectral devido ao amarelecimento, desfolhamento e às podas realizadas após o evento [Alves et al. 2024].

Para avaliar se há diferenças estatisticamente significativas entre os modelos, aplicou-se o teste de Friedman a partir do IoU computado em 82 células do município. O teste revelou disparidades estatísticas entre os modelos tanto para 2017–2018,  $\chi^2$  576.69 ( $p < 0.001$ ), quanto para 2021–2022,  $\chi^2$  461.54 ( $p < 0.001$ ). A rejeição da hipótese nula do teste em ambos os períodos indica que os modelos são estatisticamente diferentes.

Para analisar as diferenças apontadas pelo teste de Friedman, foi aplicado o teste de Wilcoxon pareado com correção de Holm para comparações intra-período entre os modelos. A Figura 2 ilustra o diagrama de diferença crítica baseado nos rankings médios dos algoritmos. No eixo horizontal, os modelos estão dispostos de forma que os melhores desempenhos (menores rankings) encontram-se à esquerda. Modelos conectados por uma linha horizontal não apresentam diferenças estatisticamente significativas ( $\alpha = 0,05$ ) [Demšar 2006]. Para o biênio 2017-2018, confirmou-se que o melhor modelo é o TempCNN5, mas que não há diferenças significativas em relação aos modelos L-TAE1, L-TAE2 e TempCNN2. Já para 2021-2022, o destaque foi o L-TAE4, equivalente ao TempCNN5 e L-TAE3. A Figura 3 ilustra os mapas dos melhores modelos por período.



**Figura 2. Diagrama de Diferença Crítica obtida com o *post-hoc* Wilcoxon-Holm.**

Para avaliar se o desempenho dos modelos realmente foi diferente nas duas séries analisadas, foi aplicado o *Wilcoxon signed-rank test* aos valores de IoU por célula, considerando pares correspondentes de cada modelo nos dois períodos. Os resultados são apresentados na Tabela 2. Os valores de p-value destacados em azul indicam os modelos para os quais a hipótese nula do teste é rejeitada, sugerindo evidência de diferença de desempenho entre os períodos analisados. Por outro lado, para os modelos com p-value destacado em vermelho, não há evidência estatística suficiente para rejeitar a hipótese nula, de modo que o desempenho pode ser considerado equivalente entre os períodos.

Com base nos resultados, entre os modelos avaliados, o TempCNN5 apresentou

o desempenho mais consistente entre os dois períodos, mantendo *F1-Score* semelhante e acima de 0,92 mesmo na série temporal influenciada por anomalias climáticas. Isso sugere que a arquitetura convolucional temporal possui maior capacidade de capturar padrões fenológicos relevantes da cultura do café, mesmo diante de variações climáticas. Esse resultado ficou ainda mais nítido na comparação de IoU do modelo entre os períodos. O desempenho praticamente não mudou, indicando alta estabilidade. Conforme a Tabela 2, o p-value ficou bem maior que 0,05, indicando equivalência do ponto de vista estatístico. Além disso, a diferença média foi praticamente zero.

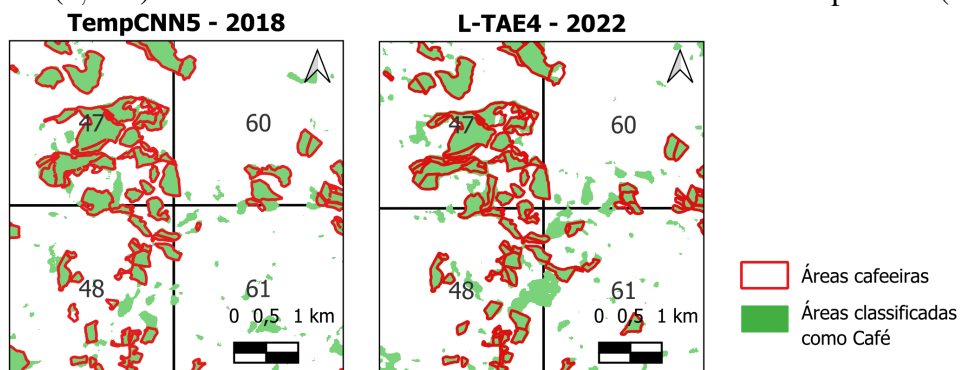
**Tabela 2. Comparação do teste de Wilcoxon entre os biênios analisados.**

| Modelo | p-value  | Dif. Média Absoluta | Modelo   | p-value  | Dif. Média Absoluta | Modelo   | p-value  | Dif. Média Absoluta |
|--------|----------|---------------------|----------|----------|---------------------|----------|----------|---------------------|
| L-TAE3 | 3,99E-11 | 0,152170            | TempCNN3 | 2,44E-03 | 0,089307            | ResNet5  | 4,75E-01 | 0,068017            |
| L-TAE5 | 8,09E-11 | 0,152536            | ResNet2  | 1,67E-01 | 0,101864            | ResNet4  | 4,90E-01 | 0,129264            |
| L-TAE1 | 1,51E-09 | 0,148218            | ResNet1  | 2,38E-01 | 0,163776            | TempCNN4 | 7,55E-01 | 0,099531            |
| L-TAE2 | 3,09E-07 | 0,092204            | ResNet3  | 3,07E-01 | 0,085341            | TempCNN2 | 7,70E-01 | 0,070272            |
| L-TAE4 | 1,33E-06 | 0,105544            | TempCNN1 | 4,04E-01 | 0,117749            | TempCNN5 | 9,54E-01 | 0,068075            |

Em séries sem influência climática relevante, o L-TAE1 apresentou desempenho estatisticamente equivalente ao TempCNN5 (Figura 2), utilizando apenas as bandas R, G, B e NIR, o que resulta em cubos menores e mais simples de processar.

A análise dos conjuntos de atributos mostrou que o desempenho variou conforme o modelo e o período da série temporal, não havendo um conjunto superior em todos os cenários. Quanto à estabilidade dos classificadores entre os períodos, o teste de Wilcoxon indicou que as variações nas séries afetaram alguns modelos, mas não todos, conforme apresentado na Tabela 2. Destaca-se o L-TAE, que apresentou todos os valores de *p-value* < 0,05, indicando alta sensibilidade aos dados de entrada.

A coluna Diferença Média Absoluta da Tabela 2 representa a magnitude da variação entre os períodos; valores menores indicam maior estabilidade do modelo. O maior valor foi observado no modelo ResNet1 (0,1637), seguido pelos modelos L-TAE3 e L-TAE5 (0,152). O menor valor ocorreu nos modelos ResNet5 e TempCNN5 (0,068).



**Figura 3. Mapas dos melhores modelos por período nas células 47, 48, 60 e 61.**

Em resumo, os resultados indicam que o modelo TempCNN5 demonstrou maior estabilidade entre os períodos analisados, mantendo desempenho semelhante mesmo em uma série temporal possivelmente afetada por anomalias climáticas. A análise estatística baseada nos testes de Friedman e Wilcoxon reforça essa interpretação ao evidenciar consistência do TempCNN5 entre as duas séries avaliadas, enquanto indica diferenças entre os modelos. Outro achado importante foi que a influência do conjunto de atributos varia significativamente dependendo do modelo e da série analisada.

Os resultados deste estudo corroboram [Werner et al. 2024], que observaram melhor desempenho da TempCNN no mapeamento de sistemas integrados de lavoura-pecuária, atribuída à sua capacidade de capturar padrões espectro-temporais em séries de imagens de satélite. No mesmo estudo, o L-TAE teve desempenho médio e a ResNet os menores índices, sem ganhos pela sua maior profundidade e conexões residuais.

## 5. Considerações Finais

Este trabalho avaliou arquiteturas de *Deep Learning* para mapear áreas de café a partir de séries temporais de imagens de satélite, comparando ResNet, TempCNN e L-TAE com cinco conjuntos de atributos.

Os modelos baseados em convoluções temporais tiveram melhor desempenho, especialmente o TempCNN com todos os atributos (TempCNN5), que se destacou na série 2017-2018 e apresentou desempenho comparável ao L-TAE4 na série 2021-2022, sugerindo boa adaptação a condições distintas nas séries temporais. Não houve um conjunto de atributos claramente superior, e diferenças espectrais afetaram principalmente o L-TAE.

De forma geral, os resultados demonstram o potencial de modelos de aprendizado profundo baseados em séries temporais para o monitoramento de áreas cafeeiras, contribuindo para o desenvolvimento de métodos mais robustos para o mapeamento de cafezais utilizando dados de sensoriamento remoto.

Como trabalhos futuros, pretende-se investigar a capacidade de generalização dos modelos em diferentes cenários, incluindo: (i) a avaliação da generalização temporal; (ii) a análise da generalização espacial; e (iii) o impacto do tamanho da série temporal no desempenho dos modelos. Esses experimentos estão atualmente em desenvolvimento e deverão contribuir para uma compreensão mais ampla da robustez dessas arquiteturas em aplicações de monitoramento agrícola, em especial em regiões produtoras de café.

**Notas sobre a elaboração do artigo:** Ferramentas de inteligência artificial foram usadas como suporte durante a elaboração do artigo: ChatGPT e Gemini para revisão textual e SciSpace para busca de referências. Todas as decisões analíticas e interpretativas permaneceram sob a responsabilidade das autoras.

## Agradecimentos

As autoras agradecem ao CNPq pela concessão de bolsa de iniciação científica e à Universidade Federal de Itajubá pelo suporte institucional e apoio à participação no congresso. Agradecem também à FAPEMIG e ao Consórcio Pesquisa Café pelo apoio aos projetos de pesquisa vinculados a este trabalho.

## Referências

- AlAli, R. (2025). Artificial intelligence for land cover and land use classification in remote sensing: Review study. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLVIII-G-2025:115–122.
- Alves, L. Q., da Silva, A. B., Putti, F. F., and Góes, B. C. (2024). Danos na cultura do café causado pelas geadas ocorridas no ano de 2021 nos municípios de alfenas e poços de caldas, brasil. *Peer Review Journals*, (9):1–15.
- Brito, P., Chaves, M., Carvalho, H., Souza, F., Silva, B., Ferreira, K., Santos, R., and de Queiroz, G. R. (2023). Uso de séries temporais para classificações de uso e co-

- bertura da terra em petrolina, pernambuco. In *Anais do XX Simpósio Brasileiro de Sensoriamento Remoto*. INPE, Instituto Nacional de Pesquisas Espaciais.
- Demšar, J. (2006). Statistical comparisons of classifiers over multiple data sets. *J. Mach. Learn. Res.*, 7:1–30.
- EMATER, E. d. A. T. e. E. R. (2025). Geoportal do café. <https://portaldocafedeminas.emater.mg.gov.br/>. Accessed: 2025-08-13.
- Ferreira, K. R., Queiroz, G. R., Vinhas, L., Marujo, R. F. B., Simoes, R. E. O., Picoli, M. C. A., Camara, G., Cartaxo, R., Gomes, V. C. F., Santos, L. A., Sanchez, A. H., Arcanjo, J. S., Fronza, J. G., Noronha, C. A., Costa, R. W., Zaglia, M. C., Zioti, F., Korting, T. S., Soares, A. R., Chaves, M. E. D., and Fonseca, L. M. G. (2020). Earth observation data cubes for brazil: Requirements, methodology and products. *Remote Sensing*, 12(24).
- Hand, B. M., Depoian, A. C., and Bailey, C. P. (2024). Efficient land use classification for brazilian coffee scenes. In *IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium*, pages 8721–8725. IEEE.
- Le, Q. T., Dang, K. B., Giang, T. L., Tong, T. H. A., Nguyen, V. G., Nguyen, T. D. L., and Yasir, M. (2022). Deep learning model development for detecting coffee tree changes based on sentinel-2 imagery in vietnam. *Ieee Access*, 10:109097–109107.
- Parreiras, T. C., Santos, C. d. O., Bolfe, L., Sano, E. E., Leandro, V. B. S., Bayma, G., Silva, L. A. P. d., Furuya, D. E. G., Romani, L. A. S., and Morton, D. (2025). Dense time series of harmonized landsat sentinel-2 and ensemble machine learning to map coffee production stages. *Remote Sensing*, 17(18).
- Pisl, J., Lenczner, G., Tuia, D., and de Morsier, F. (2024). Semantic segmentation of coffee plantations from sentinel-2 time series. In *IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium*, pages 1526–1530. IEEE.
- Santos, P. B. R., Souza, V. C. O., Mota, F. B. S., Volpato, M. M. L., and Alves, H. M. R. (2025). Cubo de dados geográfico aplicado a classificação automática de áreas cafeiras no sul de minas gerais. In *Anais do XXI Simpósio Brasileiro de Sensoriamento Remoto*. INPE, Instituto Nacional de Pesquisas Espaciais.
- Simoes, R., Camara, G., Queiroz, G., Souza, F., Andrade, P. R., Santos, L., Carvalho, A., and Ferreira, K. (2021). Satellite image time series analysis for big earth observation data. *Remote Sensing*, 13(13):2428.
- USDA, U. S. D. o. A. (2025). Coffee top producing countries. <https://www.fas.usda.gov/data/production/commodity/0711100>. Accessed: 2025-08-13.
- Werner, J. P. S., Belgiu, M., Bueno, I. T., Dos Reis, A. A., Toro, A. P. S. G. D., Antunes, J. F. G., Stein, A., Lamparelli, R. A. C., Magalhães, P. S. G., Coutinho, A. C., Esquerdo, J. C. D. M., and Figueiredo, G. K. D. A. (2024). Mapping integrated crop–livestock systems using fused sentinel-2 and planetscope time series and deep learning. *Remote Sensing*, 16(8).