

Aprendizado sensível ao custo aplicado na detecção de estresse agrícola na cultura do feijão

Clara L. Moreno¹, Vanessa C. O. Souza², Marley L. Machado³, Breno H. G. S. Freitas³

¹Instituto de Engenharia de Sistemas e Tecnologia – Universidade Federal de Itajubá
(IESTI - UNIFEI) – Itajubá – MG – Brasil

²Instituto de Matemática e Computação – Universidade Federal de Itajubá
(IMC - UNIFEI) – Caixa Postal 50 – 37500-903 – Itajubá – MG – Brasil

³Empresa de Pesquisa Agropecuária de Minas Gerais (EPAMIG)
Belo Horizonte – MG – Brasil

{d2022003835, vanessa}@unifei.edu.br, {marley, breno}@epamig.br

Abstract. *This study evaluated Machine Learning algorithms, using both traditional and cost-sensitive approaches, to detect stress in bean crops based on multispectral UAV imagery. Two CRISP-DM cycles were implemented. The results highlighted the relevance of vegetation indices. The cost-sensitive approach improved model specificity. The best model was obtained during the reproductive stage of the crop, achieving 83% accuracy and 77.63% geometric mean, demonstrating potential for early stress detection.*

Resumo. *Este trabalho avaliou algoritmos de Aprendizado de Máquina, com abordagens tradicional e sensível ao custo, para detectar estresse em lavouras de feijão a partir de imagens multiespectrais de VANT. Dois ciclos do CRISP-DM foram implementados. Os resultados mostraram a relevância dos índices de vegetação. A abordagem sensível ao custo aumentou a especificidade dos modelos. O melhor modelo foi obtido na fase reprodutiva da lavoura, atingindo 83% de acurácia e 77,63% de média geométrica, indicando potencial para a detecção precoce do estresse.*

1. Introdução

No Brasil, a previsão é de que em 2025 cerca de 80 milhões de hectares serão ocupados com o cultivo de cereais, leguminosas e oleaginosas, com destaque para o aumento da produção do algodão, arroz, café, feijão, soja e milho [IBGE 2025]. No entanto, fatores bióticos, como pragas e doenças, e abióticos, como temperatura extrema e déficit ou excesso hídrico, ameaçam a produção, causando estresse nas plantas e afetando negativamente seu rendimento [Reyes-Hung et al. 2023].

A detecção precoce e precisa do estresse nas culturas é essencial para identificar problemas e aplicar medidas corretivas [Reyes-Hung et al. 2023]. No Brasil, ainda faltam estudos sistematizados que explorem a detecção de estresse em diferentes culturas agrícolas. Segundo [Reyes-Hung and Soto 2023], o uso de algoritmos de Aprendizado de Máquina (AM) associado a imagens espectrais tem-se mostrado uma estratégia promissora para enfrentar desafios agrícolas, permitindo tanto a detecção do estresse nas plantações quanto a otimização das práticas agrícolas.

Nesse contexto, o objetivo deste trabalho foi avaliar o desempenho de algoritmos de AM utilizando abordagem tradicional e sensível ao custo na predição de estresse vegetativo em lavouras de feijão. Na abordagem sensível ao custo, o desequilíbrio entre as classes é minimizado ao atribuir custos maiores aos erros de classificação da classe minoritária, impactando o treinamento do modelo [Silva et al. 2017].

Para o desenvolvimento do trabalho, foram coletadas imagens multiespectrais em campo, em duas fases fenológicas da cultura, utilizando veículos aéreos não tripulados (VANT). Sete índices de vegetação foram computados para compor as variáveis de entrada dos modelos. A metodologia utilizada foi a CRISP-DM (*Cross-Industry Standard Process for Data Mining*) [Wirth and Hipp 2000].

Este trabalho está alinhado aos princípios da Agricultura 4.0, que promove a transformação digital do setor agrícola por meio da adoção de tecnologias avançadas, uma vez que combina imagens multiespectrais de alta resolução espacial obtidas por VANT, Mineração de Dados e AM para favorecer uma tomada de decisão mais precisa e orientada a dados [Araújo et al. 2023].

O principal diferencial deste trabalho está no conjunto de dados coletado em campo, a partir de um experimento controlado, com áreas de estresse induzido. Espera-se que este trabalho contribua tanto por meio da metodologia proposta quanto pela resposta a questões como: os índices espectrais computados auxiliam na detecção de estresse em plantios de feijão? Caso afirmativo, quais são os mais relevantes? Qual é o impacto da fase fenológica na identificação do estresse? Os algoritmos sensíveis ao custo melhoram o desempenho na detecção de estresse?

O trabalho está organizado da seguinte forma: a Seção 2 apresenta a revisão de literatura, a Seção 3 descreve a metodologia, a Seção 4 a execução do primeiro ciclo da CRISP-DM, a Seção 5 detalha o refinamento do modelo com o segundo ciclo da CRISP-DM, as discussões são feitas na Seção 6 e as considerações finais estão na Seção 7.

2. Revisão de Literatura

Qualquer condição ou substância desfavorável que afete ou bloqueie o metabolismo, o crescimento ou o desenvolvimento de uma planta é considerada estresse. O estresse pode ser classificado como abiótico, quando é causado por fatores físicos ou químicos do ambiente, como temperatura extrema, seca ou salinidade; e biótico, quando causado por interação com organismos vivos, como pragas, patógenos e insetos, que afetam diretamente as plantas cultivadas [Gull et al. 2019]. A detecção precoce do estresse é uma prática importante para evitar perdas significativas de produtividade. O monitoramento tradicional ocorre principalmente por inspeção visual, mas é subjetivo, demorado, oneroso e ineficaz em larga escala [Zhang et al. 2024].

É nesse contexto que se insere a Agricultura 4.0, que promove o uso de tecnologias avançadas para otimizar diversos aspectos das operações agrícolas [Araújo et al. 2023]. Dentre essas tecnologias, estão o Sensoriamento Remoto, a Mineração de Dados e o Aprendizado de Máquina, que são de particular interesse neste trabalho.

O Sensoriamento Remoto (SR) permite a coleta de informações sobre alvos pela quantificação da energia refletida, sendo útil na detecção de estresse em plantas devido às alterações na refletância causadas por fatores bióticos e abióticos. Índices de vegetação

(IVs), derivados das bandas espectrais, ajudam a identificar variações no vigor das plantas, possibilitando a detecção precoce do estresse vegetativo, antes mesmo de sinais visíveis [Prabhakar et al. 2011]. Nos últimos anos, o SR por Veículos Aéreos Não Tripulados (VANTs) se popularizou, permitindo um monitoramento mais preciso e eficiente das áreas agrícolas. Como destacado por [Zhu et al. 2024], as imagens obtidas por VANTs capturam dados diretamente do dossel vegetativo (folhas, caules e estrutura da planta), preservando a integridade da lavoura e refletindo condições reais de cultivo.

Aprendizado de Máquina (AM) é um subconjunto da IA que tem se destacado na Agricultura 4.0 pelo seu potencial em otimizar processos, melhorar a tomada de decisão e aumentar a eficiência produtiva. A revisão sistemática de [Araújo et al. 2023], realizada sobre as aplicações de AM na agricultura entre 2019 e 2022, identificou que o principal domínio de aplicação é a gestão de culturas, incluindo a detecção precoce de doenças, pragas e ervas daninhas. As culturas mais estudadas são trigo, milho e arroz. O *Random Forest* (RF) foi o algoritmo mais utilizado, seguido pelo *Support Vector Machine* (SVM).

Em geral, o mapeamento automatizado do uso da terra por AM enfrenta o desafio do desbalanceamento de classes. [Silva et al. 2017] abordam o tema e apresentam o aprendizado sensível ao custo como uma possível solução. O aprendizado sensível ao custo é uma solução que ajusta pesos para falso-positivos e falso-negativos, penalizando mais os erros na classe minoritária para reduzir o viés. Nesses casos, a média geométrica é recomendada como métrica de avaliação, pois reflete o equilíbrio entre sensibilidade s e especificidade e , sendo calculada como $G = \sqrt{s * e}$.

As técnicas de AM fazem parte do processo de descoberta de conhecimento, sendo frequentemente utilizadas para modelagem preditiva e identificação de padrões em grandes volumes de dados. Metodologias como a CRISP-DM (*Cross-Industry Standard Process for Data Mining*) [Wirth and Hipp 2000] estruturam e orientam o fluxo de trabalho, organizando as etapas da Mineração de Dados desde a compreensão do problema até a extração de conhecimento útil.

Estudos recentes comprovam a eficácia de técnicas de AM combinadas com SR por VANTs para detecção de estresse vegetativo. [Reyes-Hung et al. 2023] aplicaram IVs e algoritmos de segmentação (K-means) em plantações de cana-de-açúcar, enquanto [Herrera-Poyato et al. 2024] propuseram abordagens de *deep learn* em plantações de batata. [Calou et al. 2020] alcançaram 99,28% de acurácia com SVM no monitoramento da doença sigatoka-amarela em plantações comerciais de banana utilizando imagens RGB de alta resolução. Para culturas anuais, [Zhou et al. 2020] obtiveram 89% de acurácia com SVM na classificação de estresse hídrico em soja, empregando imagens RGB, imagens multiespectrais e IVs.

3. Metodologia

A metodologia utilizada neste trabalho foi a CRISP-DM (*Cross-Industry Standard Process of Data Mining*). Segundo [Schröer et al. 2021], projetos de análise de dados podem se beneficiar das metodologias de processo, que atuam como fatores de sucesso. Os autores destacam ainda que a CRISP-DM continua atual e é considerada padrão em projetos de Mineração de Dados. Seu processo consiste em seis fases cíclicas conforme a Figura 1. Apesar de ser composto por fases definidas, o fluxo não é unidirecional, tornando-o flexível no que diz respeito ao retorno para alguma fase anterior [Wirth and Hipp 2000].




Figura 1. Fases do modelo de processo da CRISP-DM. FONTE : Adaptado de [Wirth and Hipp 2000].

Para execução do trabalho, foram realizados dois ciclos da CRISP-DM, com exceção da fase de Aplicação que não foi executada em nenhum dos ciclos. O detalhamento das fases será apresentado nas seções 4 e 5.

4. Primeiro Ciclo CRISP-DM

4.1. Entendimento do Negócio

Nesta fase é preciso determinar os objetivos do negócio, os objetivos da tarefa de Mineração de Dados e produzir o plano do projeto. Para tanto, foi feito um levantamento dos principais conceitos envolvidos no desenvolvimento do projeto para então definir as perguntas de pesquisa e traçar o objetivo do negócio. O levantamento foi apresentado na Seção 2. Ademais, foram realizadas reuniões com os especialistas que realizaram os experimentos em campo para entender a coleta de dados e as demandas.

Diante desse cenário, o objetivo do negócio é identificar estresse em áreas cultivadas com feijão a partir de dados espectrais obtidos com VANT. A tarefa de Mineração de Dados é uma tarefa preditiva de classificação, utilizando algoritmos de Aprendizado de Máquina. Nesse trabalho não serão analisados algoritmos de *Deep Learning*. A combinação de métricas quantitativas e da análise visual do mapa classificado será utilizada para avaliar o sucesso do objetivo do negócio.

4.2. Entendimento dos Dados

Nesta fase, os dados devem ser explorados e deve haver um entendimento das variáveis envolvidas com o problema abordado. A aquisição dos dados foi realizada pela equipe da EPAMIG em um talhão cultivado com feijão no município de Arcos/MG, com uma área total de $17.549m^2$. Nesse talhão foram aleatoriamente delimitadas 32 áreas submetidas a estresse induzido por meio da aplicação controlada de defensivos agrícolas. Cada área possui aproximadamente $3m^2$, totalizando $96m^2$ de área com estresse. Foram realizados dois voos com o VANT Mavic 3M com tecnologia RTK. A viagem 1 refere-se ao estádio fenológico V4 (final da fase vegetativa), realizada em 11/04, e a viagem 2 refere-se ao estádio R5 (início da fase reprodutiva), realizada em 30/04/2024, 64 dias após o plantio.

Os dados disponibilizados incluem um mosaico RGB com resolução espacial de 2cm e mosaicos das bandas espectrais *Green*, *Red*, *Red-Edge* e *NIR*, com resolução de 3cm; além de arquivos vetoriais contendo polígonos que delimitam a área de estudo e as áreas com estresse induzido.

4.3. Preparação dos Dados

Esta fase inclui todas as tarefas necessárias para gerar o conjunto de dados (*dataset*) final. Como as imagens RGB apresentam resolução espacial maior que as demais, elas tiveram píxeis reamostrados. Por se tratar de uma tarefa supervisionada, o conjunto amostral

foi gerado no SIG QGis com mil pontos selecionados aleatoriamente para a classe “Estresse” e mil pontos para classe “Não Estresse”.

Com base na literatura, foram selecionados e computados sete índices de vegetação, sendo eles: NDVI (*Normalized Difference Vegetation Index*), GNDVI (*Green Normalized Difference Vegetation Index*), NDRE (*Normalized Difference Red-edge*), VARI (*Visible Atmospherically Resistant Index*), TGI (*Triangular Greenness Index*), MCARI (*Modified Chlorophyll Absorption in Reflectance Index*) e NGRDI (*Normalized Green-Red Difference Index*). Para mais detalhes, verificar [Zhu et al. 2024].

O *dataset* final foi composto por 2 mil pontos e 15 atributos, sendo as 7 imagens, 7 índices de vegetação e o atributo relativo à classe. Como forma de verificar o real impacto das variáveis nos modelos, o conjunto de dados foi dividido em quatro experimentos, sendo eles: **Conjunto 1:** bandas RGB. **Conjunto 2:** bandas RGB e bandas espectrais NIR, Red-Edge, Red, Green. **Conjunto 3:** conjunto 2 mais os sete índices de vegetação. **Conjunto 4:** composto apenas pelos índices de vegetação.

4.4. Modelagem

É nesta fase que as técnicas (algoritmos) de mineração serão aplicadas de acordo com os objetivos desejados. Foram selecionados dois algoritmos de árvore de decisão, o *Random Forest* (RF) e o *Extreme Gradient Boosting* (XGBoost). A escolha se deu pelo fato de ambos os algoritmos demonstrarem bons resultados em classificação pixel a pixel de imagens para agricultura. O terceiro algoritmo escolhido foi o *Support Vector Machine* (SVM). Nesse caso, a escolha se deu porque o SVM é um algoritmo muito indicado para classificações binárias. Essas escolhas também foram baseadas no trabalho de [Araújo et al. 2023].

A fase de modelagem foi realizada no ambiente em nuvem Colab, na linguagem Python (versão 3.10), utilizando a biblioteca *scikit-learn* (versão 1.5.2). Após a otimização de hiperparâmetros por meio do *grid-search* com validação cruzada com cinco pastas, os modelos foram configurados com os seguintes parâmetros: $n_estimators = 200$, $max_depth = 8$, $min_samples_leaf = 2$, $min_samples_split = 5$ e $bootstrap = True$ no RF para a viagem 1 e $n_estimators = 50$, $max_depth = 8$, $min_samples_leaf = 1$, $min_samples_split = 2$ e $bootstrap = True$ para a viagem 2; $eval_metric = mlogloss$, $n_estimators = 100$, $max_depth = 3$, $learning_rate = 0.01$, $reg_alpha = 0.1$, $reg_lambda = 10$ e $colsample_bytree = 1.0$ no XGBoost para a viagem 1 e somente $n_estimators = 500$ foi alterado para a viagem 2; e $kernel = rbf$, $C = 100$ e $gamma = scale$ no SVM em ambas as viagens. Além de todos os modelos receberem $random_state = 40$ para garantir a reprodutibilidade dos experimentos.

Dos 2000 pontos, 80% foram destinados ao treinamento e 20% ao conjunto de teste. Para cada subconjunto do *dataset* original, os três algoritmos foram aplicados, resultando na geração de 24 modelos, considerando as duas viagens.

4.5. Avaliação

Tida como a fase mais crítica do processo de Mineração de Dados, esta fase foi realizada em duas etapas. Na primeira, os modelos foram avaliados em relação às métricas precisão, sensibilidade, especificidade e média geométrica da classe “Estresse”, além da acurácia geral do modelo. Na segunda fase, os melhores modelos foram avaliados em conjunto

com os especialistas, por meio da análise visual do mapa. Para obter o mapa, o algoritmo treinado foi aplicado a todos os píxeis da área de estudo.

A Tabela 1 apresenta os melhores resultados quantitativos para as viagens. Para a viagem 1, o RF obteve os melhores resultados com o subconjunto 3 (bandas + índices). Já para a viagem 2, o melhor modelo foi obtido com o XGBoost e o subconjunto 4 (índices). De maneira geral, os modelos tiveram melhor desempenho na segunda viagem, onde a cultura estava mais bem formada e os dosséis mais altos, tendo menos influência do solo.

Todos os modelos testados apresentaram melhor desempenho ao utilizar os subconjuntos 3 (bandas + IV) e 4 (apenas IV). Esse achado reforça a relevância dos índices de vegetação na identificação do estresse vegetativo. Na análise de importância dos atributos fornecida pelo algoritmo RF, para a viagem 1, os índices que se destacaram foram o TGI, GNDVI e VARI. Para a segunda viagem, NGRDI, VARI, MCARI e NDVI. Interessante notar que os índices NGRDI, VARI e TGI utilizam exclusivamente bandas RGB.

Tabela 1. Métricas de avaliação dos melhores modelos - 1º Ciclo CRISP-DM

	Viagem 1	Viagem 2
Modelo	RF-C3	XGBoost-C4
Acurácia Geral	64	80
Precisão	61,50	77,03
Sensibilidade	68,23	83,85
Especificidade	60,00	76,59
Média Geométrica	63,98	80,14

Na análise visual do mapa classificado, observou-se que os modelos identificaram falsas áreas como estresse. Na avaliação conjunta com especialistas, verificou-se que parte desses erros estava associada às entrelinhas do cultivo ¹ e a regiões de estresse vegetativo natural. Além disso, verificou-se que nem todos os pontos amostrados aleatoriamente dentro das áreas delimitadas como estresse correspondiam, de fato, a regiões afetadas. Alguns desses pontos coincidiam com entrelinhas ou sombreamento. Outra conclusão da análise do mapa foi que, de maneira geral, a classe “Estresse” estava sendo superestimada. Diante disso, com base na metodologia CRISP-DM, retornou-se à fase de Preparação dos Dados, iniciando-se um novo ciclo de refinamento do modelo.

5. Segundo Ciclo CRISP-DM

A fase de **Avaliação** do primeiro ciclo também pode ser vista como a fase de **Entendimento do Negócio e dos Dados** no segundo ciclo. Inicialmente, o conceito de estresse foi restrito a áreas de estresse induzido, o que não se confirmou em campo. Além disso, os modelos superestimaram a classe “Estresse”, possivelmente devido à amostragem igualitária de classes com áreas de tamanhos desproporcionais, resultando em um viés no modelo.

Na fase de **Preparação dos Dados**, as amostras da classe “Estresse” foram revisadas por especialistas para reduzir a amostragem de entrelinhas e sombreamento dentro da área de estresse. Ademais, mil novos pontos foram criados de forma aleatória para a classe “Não Estresse”, dobrando a quantidade de amostras dessa classe.

¹Espaços sem plantio, planejados para otimizar o manejo da lavoura, incluindo trânsito de máquinas, controle de ervas daninhas e crescimento das plantas.

Na fase de **Modelagem**, para mitigar o desbalanceamento de classes, foram utilizadas as variações sensíveis ao custo dos algoritmos *Random Forest* e SVM com o parâmetro *class_weight*. O XGBoost não foi utilizado nesse ciclo pois não possui a variação sensível ao custo na *scikit-learn*. Os hiperparâmetros foram determinados utilizando o *grid-search* com validação cruzada com cinco pastas. Ademais, a métrica de desempenho utilizada foi a média geométrica.

Os modelos avaliados foram configurados com os seguintes parâmetros: *class_weight = balanced*, *n_estimators = 50*, *max_depth = 8*, *min_samples_split = 10*, *min_samples_leaf = 4* e *bootstrap = True* no RF para a viagem 1 e apenas os parâmetros *n_estimators = 100*, *min_samples_leaf = 1* e *bootstrap = False* foram alterados para a viagem 2; *kernel = rbf*, *C = 100*, *gamma = scale*, *class_weight = balanced* no SVM para ambas as viagens. O parâmetro *class_weight = balanced* ajusta automaticamente os pesos de forma inversamente proporcional às frequências das classes. Um segundo teste foi executado utilizando o *class_weight = 0 : 5, 1 : 1*, de forma a penalizar cinco vezes mais o erro de classificar um caso de “Não Estresse” como “Estresse”. Esse teste buscou avaliar o impacto de um ajuste manual do parâmetro *class_weight*, já que o *grid_search* o configurou sempre como *balanced*.

Para cada subconjunto do *dataset* original, os dois algoritmos foram aplicados. Ainda, para efeitos de comparação, foram gerados modelos usando os mesmos parâmetros, mas com os dados balanceados do primeiro ciclo CRISP, resultando na geração de 64 modelos, considerando as duas viagens.

Para a fase de **Análise**, observou-se as métricas quantitativas e os mapas gerados a partir dos melhores modelos. Os melhores resultados quantitativos são apresentados na Tabela 2. Para a viagem 1, o teste fixando *class_weight = 0 : 5, 1 : 1* não obteve bons resultados. O melhor desempenho foi o RF com o subconjunto 4 e os dados desbalanceados. Para a viagem 2, o melhor desempenho foi com o RF e o subconjunto 3 e os dados desbalanceados. Verifica-se que para o conjunto desbalanceado, a variação sensível ao custo melhora a especificidade da classe “Estresse”, o que significa melhorar o acerto da classe “Não Estresse”.

Para os experimentos com *class_weight = balanced*, os índices TGI, NGRDI, VARI e MCARI foram os mais relevantes para a viagem 1. Para a viagem 2, os mais relevantes foram o TGI, GNDVI, MCARI e NDVI, além das bandas *red-edge* e *green*. Já para os experimentos com *class_weight = 0 : 5, 1 : 1*, para a viagem 1, destaque para NGRDI, VARI, MCARI e NDVI, e para a viagem 2, NGRDI, VARI e MCARI.

A Figura 2 apresenta os mapas da viagem 2 obtidos a partir dos modelos do primeiro e segundo ciclo CRISP-DM. Apesar do modelo RF-C3 com *class_weight = balanced* (Figura 2c) apresentar melhor média geométrica, o modelo RF-C3 com o *class_weight = (0 : 5, 1 : 1)* fixado (Figura 2d) gerou um mapa mais próximo do esperado, onde as áreas de estresse induzido, as entrelinhas e as áreas de estresse natural foram mais bem definidas. Apesar das entrelinhas não serem estresse, o padrão vegetativo dessas regiões é parecido justamente por não conter vegetação.

6. Discussão

Com base nos experimentos realizados, é possível considerar que os índices espectrais computados auxiliam na detecção de estresse em plantios de feijão, uma vez que, em todos

Tabela 2. Métricas de avaliação dos melhores modelos - 2º Ciclo CRISP-DM

	Viagem 1 - class_weight={balanced}		Viagem 1 - class_weight={0: 5, 1: 1}	
	Balancedos	Desbalanceados	Balancedos	Desbalanceados
Modelo	RF - C3	RF - C4	RF - C3	RF - C3
Acurácia Geral	64	71	54	69
Precisão	61,50	52,38	75,00	62,50
Sensibilidade	68,23	68,75	7,81	2,60
Especificidade	60,00	71,90	97,56	99,30
Média Geométrica	63,98	70,31	27,61	16,08
	Viagem 2 - class_weight={balanced}		Viagem 2 - class_weight={0: 5, 1: 1}	
	Balancedos	Desbalanceados	Balancedos	Desbalanceados
Modelo	RF - C4	RF - C3	RF - C4	RF - C3
Acurácia Geral	80	81	77	83
Precisão	77,40	66,09	79,64	74,57
Sensibilidade	83,85	79,17	69,27	67,19
Especificidade	77,07	81,73	83,41	89,70
Média Geométrica	80,39	80,44	76,01	77,63




Figura 2. Mapas classificados da segunda viagem. Em a) detalhe da área com amostras de “Estresse” e “Não Estresse”. Em b) modelo XGBoost-C4 do primeiro ciclo CRISP-DM. Em c) modelo RF-C3 desbalanceado $class_weight = balanced$ do segundo ciclo CRISP-DM. Em d) modelo RF-C3 desbalanceado $class_weight = (0 : 5, 1 : 1)$ do segundo ciclo CRISP-DM.

os experimentos, os melhores modelos foram obtidos com os conjuntos 3 e 4, com ambos apresentando, por vezes, resultados muito próximos. Na viagem 1 (estádio fenológico V4), o feijão está em crescimento vegetativo, com forte desenvolvimento foliar e alta taxa fotossintética. Assim, os índices mais relevantes foram o TGI, MCARI e VARI. Os dois primeiros destacam a clorofila e a atividade fotossintética. O VARI é um índice baseado em bandas do espectro visível (RGB) e mais voltado para a separação entre solo exposto e vegetação. Já na viagem 2 (estádio fenológico R5), a planta entra no período reprodutivo, focando na formação de grãos e os índices mais relevantes foram aqueles que capturam variações estruturais e eficiência fotossintética, como NGRDI, MCARI e NDVI. O índice VARI, apesar de ser baseado no espectro visível, também se destacou na análise.

As métricas de avaliação da viagem 1 foram todas inferiores às da viagem 2, indicando que o estágio fenológico R5 permitiu aos modelos prever com maior precisão

o estresse vegetativo. O fato de o dossel estar mais bem formado e o solo ficar menos aparente pode contribuir para esse resultado.

Os modelos com variação sensível ao custo tiveram um desempenho superior aos tradicionais. Em estudos como este, onde a classe de interesse ocupa uma área muito menor em relação à outra, o balanceamento de classes tende a super-representar a classe minoritária. Como consequência, a classe majoritária acaba sub-representada, especialmente porque sua variabilidade de padrões geralmente é maior do que a da classe menor. Nesse sentido, a solução que trouxe melhor desempenho nesse trabalho foi aumentar a representatividade da classe majoritária (“Não Estresse”) e penalizar mais o modelo quando erros de falso-positivo ocorriam.

A análise visual do mapa classificado é imprescindível para avaliar modelos de previsão de uso da terra. E, nesse sentido, a colaboração dos especialistas no negócio torna-se extremamente importante. Apesar de estatisticamente o modelo apresentar bom desempenho, nem sempre é suficientemente bom no mapa classificado. No primeiro ciclo CRISP-DM, a viagem 2 alcançou 80% de acurácia e 80,14% de média geométrica. No entanto, o mapa classificado não era satisfatório para resolver o problema. Nesse sentido, o apoio da CRISP-DM é fundamental.

7. Considerações Finais

Dentre todos os experimentos realizados, os melhores modelos foram obtidos na viagem 2, com os subconjuntos 3 e 4 e com os algoritmos sensíveis ao custo. O melhor modelo, considerando tanto a análise estatística quanto a análise visual do mapa, alcançou acurácia de 83% e média geométrica de 77,63%. Apesar de visualmente ser possível perceber que o modelo ainda detecta algumas áreas de “Não Estresse” como sendo “Estresse”, conclui-se que o resultado alcançado foi satisfatório para o objetivo pretendido. As questões levantadas na fase de entendimento do negócio da metodologia CRISP-DM foram respondidas com a execução e validação dos experimentos.

O diferencial deste trabalho é o uso de um conjunto de dados coletados em campo de forma sistemática, algo ainda pouco explorado na literatura. Nesse sentido, a evolução dos estudos realizados neste trabalho visa integrar modelos de Aprendizado de Máquina treinados a drones pulverizadores, permitindo a detecção automática de estresse e a aplicação direcionada de defensivos apenas nas áreas afetadas. Isso possibilita a redução de custos operacionais, otimiza o uso de insumos agrícolas e minimiza impactos ambientais, contribuindo para uma agricultura mais eficiente e sustentável, em alinhamento com os princípios da Agricultura 4.0.

Como trabalho futuro, além de validar os modelos treinados em plantações comerciais de feijão (ambientes não controlados), pretende-se expandir o estudo para as culturas do milho e da soja, de forma a verificar se os achados encontrados nesse estudo podem ser generalizados para outras culturas.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de Minas Gerais - FAPEMIG pelo suporte financeiro na obtenção dos dados, à UNIFEI pela concessão da bolsa de Iniciação Científica e à EPAMIG pela parceria científica, cessão de dados e consultoria.

Referências

- Araújo, S. O., Peres, R. S., Ramalho, J. C., Lidon, F., and Barata, J. (2023). Machine learning applications in agriculture: Current trends, challenges, and future perspectives. *Agronomy*, 13(12).
- Calou, V. B. C., dos Santos Teixeira, A., Moreira, L. C. J., Lima, C. S., de Oliveira, J. B., and de Oliveira, M. R. R. (2020). The use of uavs in monitoring yellow sigatoka in banana. *Biosystems Engineering*, 193:115–125.
- Gull, A., Lone, A. A., and Wani, N. U. I. (2019). Biotic and abiotic stresses in plants. In de Oliveira, A. B., editor, *Abiotic and Biotic Stress in Plants*, chapter 1. IntechOpen, Rijeka.
- Herrera-Poyato, D., Domínguez-Rull, J., Montes, R., Hernández, I., Barrio, I., Poblete-Echeverría, C., Tardaguila, J., Herrera, F., and Herrera-Poyatos, A. (2024). Small data deep learning methodology for in-field disease detection. *arXiv preprint arXiv:2409.17119*.
- IBGE (2025). Ibge prevê safra de 322,6 milhões de toneladas para 2025, com crescimento de 10,2% frente a 2024. <https://agenciadenoticias.ibge.gov.br>. Accessed: fev/2025.
- Prabhakar, M., Prasad, Y., and Rao, M. N. (2011). Remote sensing of biotic stress in crop plants and its applications for pest management. *Crop stress and its management: Perspectives and strategies*, pages 517–545.
- Reyes-Hung, L. and Soto, I. (2023). Machine learning in spectral imaging for smart farming: A review. In *2023 IEEE CHILEAN Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON)*, pages 1–4.
- Reyes-Hung, L., Soto, I., Zamorano-Illanes, R., Adasme, P., Ijaz, M., Azurdia, C., and Gutierrez, S. (2023). Crop stress detection with multispectral imaging using ia. In *2023 South American Conference On Visible Light Communications (SACVLC)*, pages 59–64.
- Schröer, C., Kruse, F., and Gómez, J. M. (2021). A systematic literature review on applying crisp-dm process model. *Procedia Computer Science*, 181:526–534. CENTERIS 2020 - International Conference on ENTERprise Information Systems / ProjMAN 2020 - International Conference on Project MANagement / HCist 2020 - International Conference on Health and Social Care Information Systems and Technologies 2020, CENTERIS/ProjMAN/HCist 2020.
- Silva, J., Bacao, F., Dieng, M., Foody, G. M., and Caetano, M. (2017). Improving specific class mapping from remotely sensed data by cost-sensitive learning. *International Journal of Remote Sensing*, 38(11):3294–3316.
- Wirth, R. and Hipp, J. (2000). Crisp-dm: Towards a standard process model for data mining. In *Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining*, pages 29–39. Springer-Verlag London, UK.
- Zhang, K., Yan, F., and Liu, P. (2024). The application of hyperspectral imaging for wheat biotic and abiotic stress analysis: A review. *Computers and Electronics in Agriculture*, 221:109008.
- Zhou, J., Zhou, J., Ye, H., Ali, M. L., Nguyen, H. T., and Chen, P. (2020). Classification of soybean leaf wilting due to drought stress using uav-based imagery. *Computers and Electronics in Agriculture*, 175:105576.
- Zhu, H., Lin, C., Liu, G., Wang, D., Qin, S., Li, A., Xu, J.-L., and He, Y. (2024). Intelligent agriculture: deep learning in uav-based remote sensing imagery for crop diseases and pests detection. *Frontiers in Plant Science*, Volume 15 - 2024.