



## **INFERÊNCIA DE PROTEÍNA BRUTA EM PASTAGEM COM IMAGEM MULTIESPECTRAL E APRENDIZAGEM DE MÁQUINA**

Amanda Silvia Custódio, Ronaldo Toshiaki Oikawa, Lucas Prado Osco, Fábio Fernando de Araújo

### **PROBLEMÁTICA**

A avaliação do valor nutricional das pastagens é realizada por análises laboratoriais tradicionais denominadas de bromatológicas. As pastagens ocupam áreas extensas nas propriedades rurais que exploram a pecuária de corte, o que dificulta a correta amostragem. Outro fator limitante também é a ausência de laboratórios próximos das áreas produtoras. Também é levado em conta o custo dessas análises, o que reduz o monitoramento da qualidade nutricional dessas gramíneas. Desta forma, novos métodos para analisar o valor nutricional, com baixo custo e facilidade para realização, podem ser utilizados para o monitoramento das áreas de pastagem com maior possibilidade de intervenção.

### **CONHECIMENTO PRÉVIO**

Por meio de técnicas desenvolvidas com sensores remotos é possível inferir o conteúdo nutricional de culturas a partir de métodos não destrutivos, sendo vantajosos com relação a agilidade e ao custo na análise do nutriente. Nos últimos anos, diferentes métodos, processamentos e algoritmos foram implementados no processamento de imagens adquiridas com sensores a bordo de plataformas aéreas e orbitais (WEISS et al., 2020).

No sentido apresentado, os algoritmos de aprendizado de máquina têm ganhado atenção no processamento de dados, e tem se mostrado uma técnica robusta e inteligente para modelar diferentes tipos de informações espectrais. Esses algoritmos têm a vantagem de não serem paramétricos e não lineares, ao mesmo tempo em que são capazes de analisar dados ruidosos e imperfeitos. Eles também são capazes de executar inúmeras combinações e cálculos em questão de segundos, obtendo sucesso relativo em aplicações de sensoriamento remoto em relação à análise de plantas (OSCO et al., 2020).

### **DESCRIÇÃO DA PESQUISA**

O estudo foi realizado em área de integração lavoura pecuária na Fazenda Experimental do Campus II em agosto e setembro 2019. Na área estava sendo cultivada *Brachiaria brizantha* por três anos. Para o processamento dos dados, coletamos 25 pontos amostrais ao longo da área e registramos sua geolocalização com auxílio de um GNSS de alta precisão. As amostras foram trazidas para o laboratório e submetidas à análise de N total pelo método Kjeldahl. Em seguida, interpolamos esses pontos pelo método IDW e criamos uma imagem. Depois, organizamos em um banco de dados imagens multiespectrais da plataforma Sentinel 2, sensor MSI, processadas em



refletância de superfície, e calculamos dois índices espectrais de vegetação: NDVI e GNVDI. Em ambiente computacional, extraímos os valores de pixels de cada banda, índice e adotamos o algoritmo Random Forest para a predição (AUTOR?). O algoritmo foi treinado com 10k dobras dentro da validação cruzada com 317 pixels que correspondiam ao mapa de N (%) interpolado. Como métricas de validação adotamos o coeficiente de correlação, o erro médio absoluto e a raiz quadrada do erro médio. Também avaliamos a contribuição individual de cada variável (banda ou índice) na predição do modelo (Random Forest). Por último, plotamos o mapa de inferência de N (%) que pode ser estimado para proteína bruta (%) utilizando-se a fórmula de  $\%PB=N \times 6,25$ .

### RESULTADOS E DISCUSSÃO

A análise de regressão por meio do algoritmo de aprendizagem de máquina Random Forest retornou uma acurácia relativamente adequada para a predição de N (%), em torno de 0,73 (Tabela 1). Essa acurácia apresenta-se como representativa pelo conjunto de pontos avaliados na área.

**Tabela 1.** Métricas de regressão voltadas para o conjunto de validação do Random Forest.

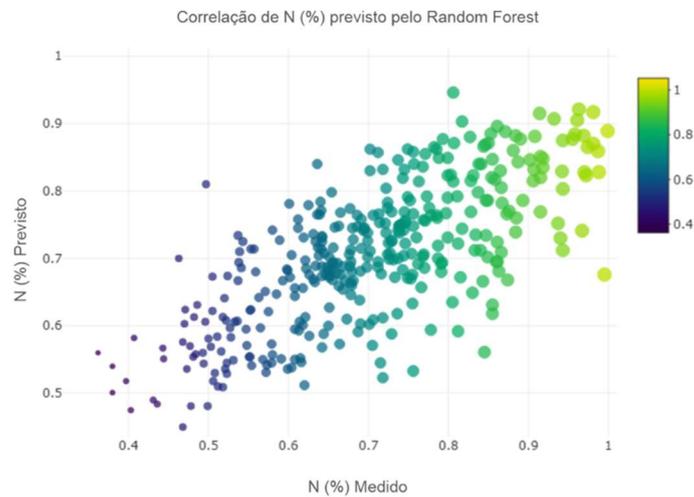
Coefficiente de correlação	Erro médio absoluto	Raiz quadrada do erro médio
0,729	0,07	0,09

A importância relativa de cada parâmetro de entrada para o algoritmo indicou que as melhores variáveis para determinar o conteúdo de N e proteína bruta na cultura analisada pertencem a região do visível (Tabela 2). Os índices espectrais, por sua vez, apresentaram a pior contribuição dentre as variáveis estudadas, contradizendo o esperado conforme discutido na literatura (OSCO et al., 2019).

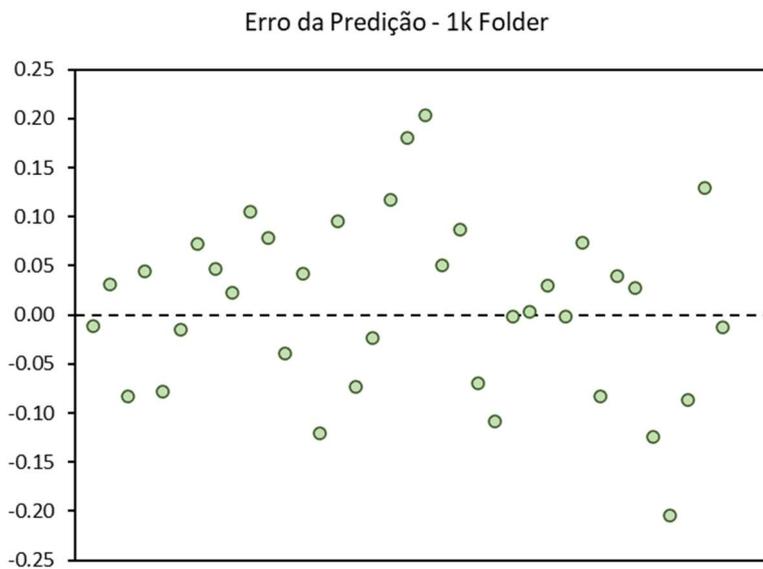
**Tabela 2.** Importância relativa indicando a contribuição de cada variável de entrada para o algoritmo.

Rank	Atributo	Métrica
1	Azul	0,248
2	Vermelho	0,219
3	Verde	0,144
4	Infravermelho	0,005
5	GNDVI	-0,110
6	NDVI	-0,173

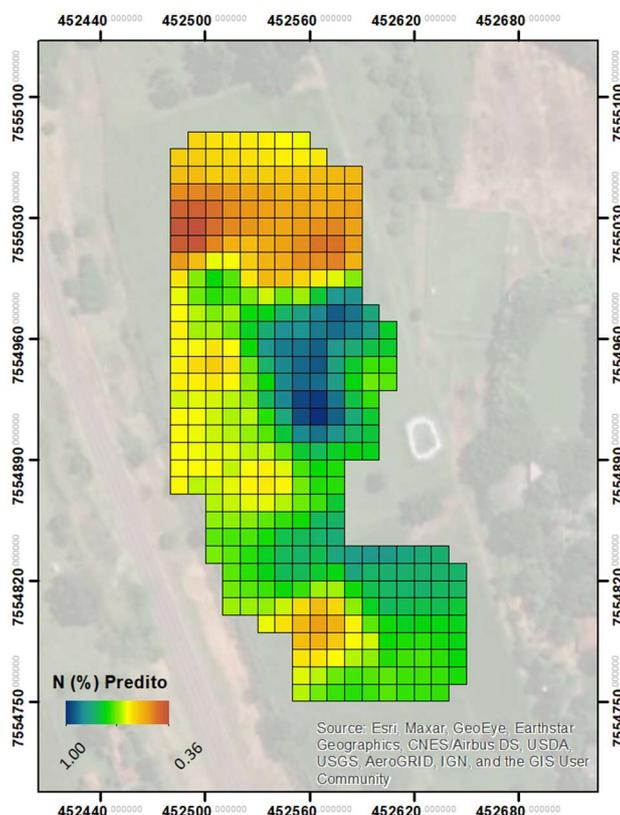
Por meio dos gráficos de dispersão e erro (Figuras 1 e 2) nota-se que as predições ocorreram de maneira similar para todo o conjunto de dados (i.e., não apresentaram um comportamento específico para nenhuma região do conjunto amostral, seja ela na baixa, média ou alta quantidade do nutriente). Por último, a Figura 3 permite uma análise qualitativa do resultado da inferência realizada pelo modelo, indicando que existem diversas variações dentro da mesma área.



**Figura 1.** Gráfico de dispersão para os 10 conjuntos (k) de teste pelo método de validação-cruzada.



**Figura 2.** Gráfico da distribuição de erro da predição para 1 conjunto (k) de teste.



**Figura 3.** Mapa demonstrando a inferência de N (%) realizada pelo Random Forest.

### APLICAÇÃO PRÁTICA

Essa predição pode auxiliar no monitoramento da qualidade nutricional das pastagens na região oeste paulista. A acurácia encontrada permite que seja feita novas avaliações em áreas maiores utilizando das imagens de satélite disponíveis. Os valores proteicos estimados vão auxiliar no monitoramento e manejo das pastagens pelos produtores rurais.

### LITERATURA CITADA

Oscó, L. P., Ramos, A. P. M., Pereira, D. R., Moriya, Érika A. S., Imai, N. N., Matsubara, E. T., Estrabis, N., De Souza, M., Junior, J. M., Gonçalves, W. N., Li, J., Liesenberg, V., & Creste, J. E. (2019). Predicting canopy nitrogen content in citrus-trees using random forest algorithm associated to spectral vegetation indices from UAV-imagery. **Remote Sensing**, 11(24), 1–17. <https://doi.org/10.3390/rs11242925>

Oscó, L. P., De Arruda, M. Dos S., Marcato Junior, J., Da Silva, N. B., Ramos, A. P. M., Moriya, É. A. S., Imai, N. N., Pereira, D. R., Creste, J. E., Matsubara, E. T., Li, J., & Gonçalves, W. N. 2020. A convolutional neural network approach for counting and geolocating citrus-trees in UAV multispectral imagery. **ISPRS**



## BOLETIM DE PESQUISA DO PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA - UNOESTE

   /unoeste

**Journal of Photogrammetry and Remote Sensing**, 160(August 2019), 97–106.  
<https://doi.org/10.1016/j.isprsjprs.2019.12.010>

WEISS, M., JACOB, F., & DUVEILLER, G. (2020). Remote sensing for agricultural applications: A meta-review. **Remote Sensing of Environment**, 236(November 2019), 111402. <https://doi.org/10.1016/j.rse.2019.111402>