

DESENVOLVIMENTO DE APLICATIVO PARA MONITORAMENTO DAS CONDIÇÕES DE PASTAGENS*

Data de aceite: 15/12/2021

Victor Rezende Franco

Ricardo Guimarães Andrade

Marcos Cicarini Hott

Leonardo Goliatt da Fonseca

Domingos Sávio Campos Paciullo

Carlos Augusto de Miranda Gomide

Guilherme Morais Barbosa

A tecnologia na área agrícola proporcionou o aumento do rendimento por área de plantio e a redução do desperdício de insumos, se tornando de grande importância para uma produção mais eficiente e sustentável. Entretanto, o levantamento de parâmetros biofísicos de plantas em larga escala é uma atividade dispendiosa e às vezes dependem de técnicas de coleta destrutiva, sendo alvo de diversos estudos (FIORANI e SCHURR, 2013; FURBANK, 2009; HOULE et al., 2010; NGUYEN et al., 2019). Esta busca, de acordo com (SANTOS e YASSITEPE, 2014), é conhecida pela comunidade científica como "gargalo de fenotipagem" (*phenotyping bottleneck*), devido à lacuna entre a quantidade e qualidade de dados genômicos e fenotípicos disponíveis. A tecnologia da informação tem

ganhado muito espaço na pecuária, tendo como sua principal fonte propulsora a busca por uma produção mais eficiente. De acordo com Santos (2017), técnicas que utilizem visão computacional e processamento de imagens são essenciais para a evolução na área de fenotipagem.

Smartphones podem integrar tecnologias de captura de imagens e o processamento das mesmas, o que tem viabilizado aplicativos que fazem uso de técnicas de visão computacional. Ainda é possível obter a geolocalização destas imagens por meio dos dispositivos e armazenar e tratar esses dados. Segundo Gichamba e Lukandu (2012), aparelhos *mobiles* possuem uma grande acessibilidade financeira e boa difusão no meio agropecuário, servindo como potencial ferramenta no auxílio da extração de informações fenotípicas de pastagens.

O objetivo desta pesquisa foi desenvolver uma aplicação *mobile* que possibilite, por meio de imagens captadas pela câmera do smartphone, estimar parâmetros biofísicos por meio de algoritmos implementados para extração de características inerentes às imagens. Posteriormente, os resultados dessas estimativas foram correlacionados com a biomassa e a altura de pastagem. A versão atual do aplicativo Capta Pasto foi implementada visando a predição dos parâmetros: Cobertura verde, altura das pastagens e biomassa.

Para o desenvolvimento do aplicativo

foi utilizado o ambiente de desenvolvimento Android Studio versão 4.2. O algoritmo foi desenvolvido utilizando a linguagem Java, para recursos de interface do aplicativo a XML (eXtensible Markup Language) e banco de dados SQLite. Para analisar as imagens, foram obtidos alguns atributos das mesmas como cobertura verde, informações de textura e Índices de Vegetação (IV). Para estimar a cobertura verde foi utilizado o espaço de cores HSV (*hue, saturation e value*), por ser menos suscetível a variação de luz. Com base em um limiar para o canal *Hue* (H) cada *pixel* foi classificado como pastagem ou não pastagem. A cobertura verde foi estimada com base na quantidade de pixels identificados como pastagem e na quantidade total de pixels na imagem. A Figura 1 exemplifica uma dessas estimativas feitas por meio do aplicativo.

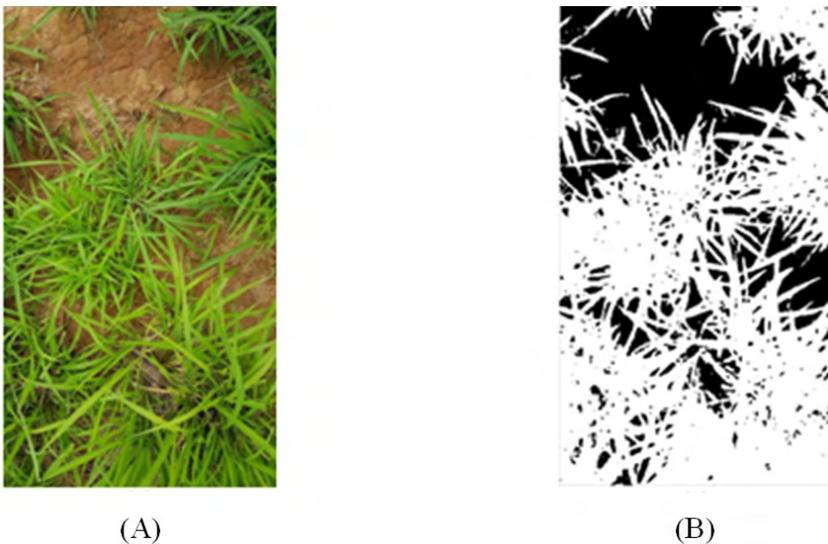


Figura 1 – Imagem original (A); imagem segmentada, com os pontos classificados como pastagem e não pastagem representados pelas cores branco e preto, respectivamente (B).

Também por meio das imagens foram obtidos os seguintes índices de vegetação, *Modified aPhotochemical Reflectance Index - MPRI* (Yang et al., 2008); *Triangular Greenness Index - TGI* (Hunt et al., 2013); *Green Leaf Index – GLI* (Louhaichi et al., 2001) e o *Visible Atmospherically Resistant Index - VARI* (Gitelson et al., 2002), conforme equações a seguir.

$$MPRI = \frac{(G - R)}{(G + R)} \quad (1)$$

$$TGI = G - (0,39 \times R) - (0,61 \times B) \quad (2)$$

$$GLI = \frac{(2 \times G - R - B)}{(2 \times G + R + B)} \quad (3)$$

$$VARI = \frac{(G - R)}{(G + R - B)} \quad (4)$$

Em que, R são os dados da imagem para a região do espectro da luz referente a cor vermelha; G os dados da imagem referente a região do espectro da luz representada pela cor verde; e B os dados da imagem que são captados na região do espectro de luz referente a cor azul. Também foram extraídas algumas informações de textura das imagens. Para isso foi utilizada uma matriz de concorrência de nível de cinza, proposta por Haralick (1979). Dessa matriz, foram extraídos os atributos: Homogeneidade, segundo momento angular e entropia. Os atributos extraídos das imagens serviram como informações para os métodos de aprendizado de máquina utilizados: regressão lasso, regressão por vetores de suporte e rede *perceptron* de múltiplas camadas. Os parâmetros dos modelos foram selecionados por meio da técnica de evolução diferencial, possibilitando realizar a predição dos parâmetros biofísicos estudados; altura e biomassa. Ao realizar uma nova captura o aplicativo obtém junto com o parâmetro selecionado as coordenadas da imagem por meio da função de localização GPS do smartphone. Em seguida todas essas informações são armazenadas no banco de dados.

A Figura 2 exemplifica uma captura de kg/ha de biomassa feita pelo aplicativo e a Figura 3 uma estimativa de altura. Para obtenção dos dados de biomassa foram feitas 3 fotografias utilizando 3 diferentes dispositivos mobile em 30 parcelas escolhidas de maneira aleatória, totalizando 90 fotografias, todas as fotografias foram tiradas de forma ortogonal a uma distância entre 1,0 e 1,4 m. As imagens óticas de pastagens de *Panicum maximum* (*syn Megathirus maximus*) foram obtidas em área experimental da Embrapa Gado de Leite, município de Coronel Pacheco, MG, em fevereiro de 2020, durante a estação do verão, período que a vegetação normalmente apresenta maior vigor. Foram retiradas amostras de todas as parcelas fotografadas em área de 0,5 m². Posteriormente, as amostras tiveram a contabilização do peso verde e, após secagem em estufa, o peso da matéria seca. Na sequência, os dados de cada parcela foram extrapolados para kg/ha.

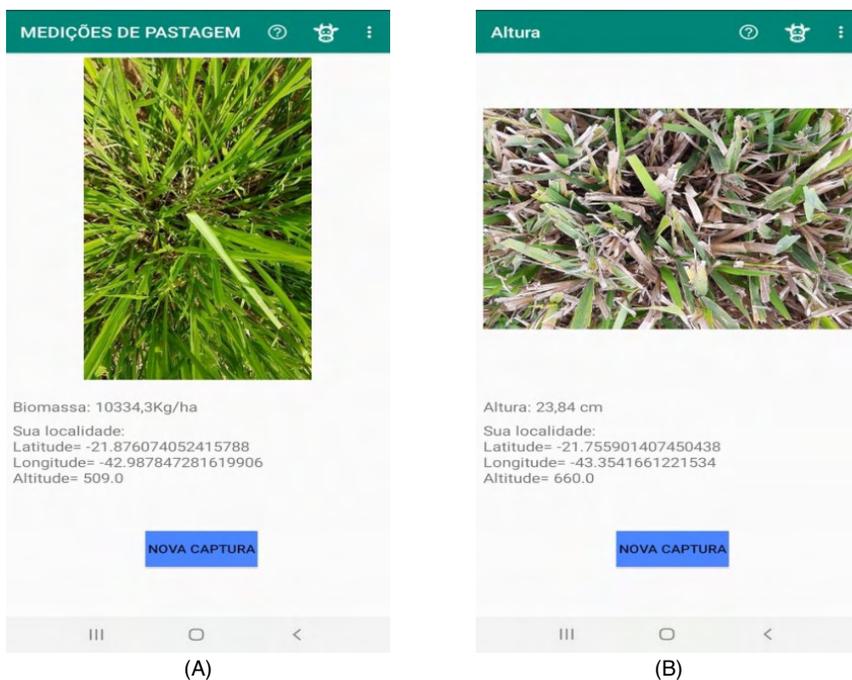


Figura 2 – Estimativa de biomassa (A) e de altura (B) por meio do aplicativo Capta Pasto.

Para implementação dos algoritmos para estimativa de altura, fotografias de 32 parcelas foram tiradas de forma ortogonal a uma distância entre 1,0 e 1,4 m. As imagens óticas da vegetação de pastagens foram obtidas no município de Mar de Espanha, MG, em julho de 2020. Em todas as amostras fotografadas foram efetuadas medições de altura do pasto com uso de uma régua graduada. Para avaliar os modelos implementados, foram utilizadas as seguintes métricas: Coeficiente de determinação (R^2), índice de Willmott (WI), Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE) e Erro Percentual Absoluto Médio (MAPE). Para avaliar o desempenho dos modelos, o método de evolução diferencial foi aplicado 30 vezes para cada técnica de ML, utilizando validação cruzada com cinco subconjuntos, tendo seus dados embaralhados por diferentes sementes aleatórias.

A Tabela 1 mostra os resultados de avaliação dos modelos implementados para estimativa de altura e biomassa, contendo a média e desvio-padrão das métricas referente as 30 simulações do algoritmo de evolução diferencial. Já a Figura 3 mostra um gráfico radar, para facilitar a comparação dos modelos. A Rede Perceptron de Múltiplas Camadas foi a que apresentou os melhores resultados, tanto para a estimativa de biomassa quanto para altura da pastagem e por isso foi escolhida como o modelo implementado no aplicativo.

	Modelo	R ²	WI	RMSE	MAE	MAPE
Biomassa	Lasso	0,398 (0,087)	0,739 (0,056)	3,03 (0,217)	2,37 (0,216)	51,18 (3,41)
	MLP	0,495 (0,010)	0,800 (0,006)	2,78 (0,026)	2,11 (0,041)	45,29 (1,96)
	SVR	0,371 (0,029)	0,709 (0,021)	3,10 (0,070)	2,18 (0,101)	45,02 (2,88)
Altura	Lasso	0,632 (0,006)	0,886 (0,002)	5,25 (0,040)	4,15 (0,038)	25,91 (0,455)
	MLP	0,656 (0,016)	0,895 (0,008)	5,07 (0,120)	4,00 (0,155)	25,72 (1,52)
	SVR	0,482 (0,008)	0,825 (0,006)	6,23 (0,045)	4,67 (0,050)	31,36 (0,439)

Tabela 1 – Resultados de avaliação dos modelos Lasso, MLP e SVR por meio do coeficiente de determinação (R²), índice de Willmott (WI), Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE) e Erro Percentual Absoluto Médio (MAPE)

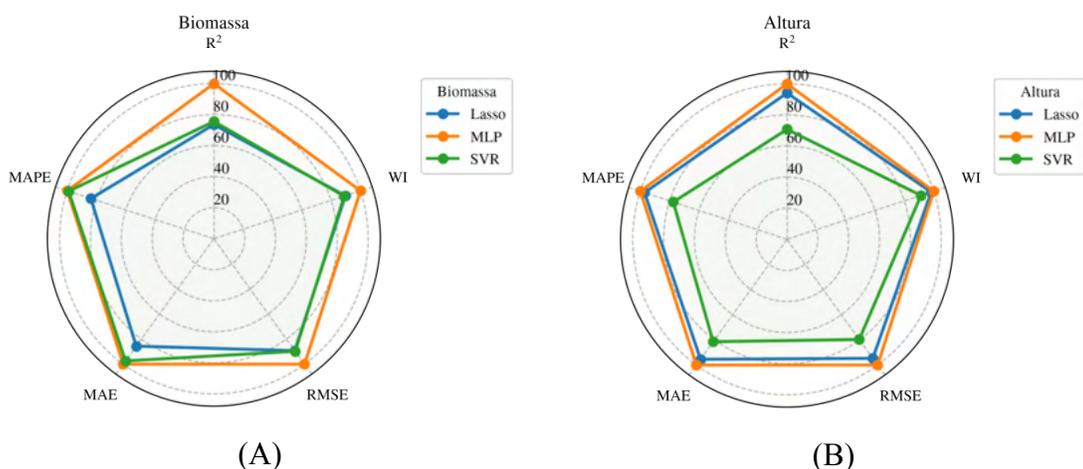


Figura 3 – Visualização de gráfico radar para avaliação comparativa dos modelos aplicados para estimativa de biomassa (A) e altura (B) do pasto.

REFERÊNCIAS

FIORANI, F.; SCHURR, U. Future scenarios for plant phenotyping, **Annual Review of Plant Biology**, v. 64, p. 267-291, 2013. doi: 10.1146/annurev-arplant-050312-120137.

*FRANCO, V. R., ANDRADE, R. G., HOTT, M. C., FONSECA, G. L., PACIULLO, D. S. C., GOMIDE, C. A. M., BARBOSA, G. M. Estimation of biophysical parameters to monitor and manage pasture using a mobile application. In: *International Journal of Advanced Engineering Research and Science (IJAERS)*, v. 7, 12, 352-355, 2020

FURBANK, R.T. Plant phenomics: from gene to form and function. **Functional Plant Biology**, v. 36, p. 5-6, 2009. https://doi.org/10.1071/FPv36n11_FO

GICHAMBA, A.; LUKANDU, I. A. A Model for designing M-Agriculture Applications for Dairy Farming. **The African Journal of Information Systems**, v. 4, n. 4, p. 120-136, 2012.

GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel Algorithms for Remote Estimation of Vegetation Fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76-87, 2002.

HARALICK, R. M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, v. 67, n. 5, p. 786-804, 1979. doi: 10.1109/PROC.1979.11328

HOULE, D.; GOVINDARAJU, D. R.; OMHOLT, S. Phenomics: the next challenge. **Nature Reviews Genetics**, v. 11, p. 855-866, 2010.

HUNT JR., E. R.; DORAISWAMY, P. C.; MCMURTREY, J. E.; DAUGHTRY, C. S. T.; PERRY, E. M. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 103-112, 2013.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. *Geocarto International*, v. 16, n. 1, p. 65-70, 2001.

NGUYEN, G.; N.; MAHARJAN, P.; MAPHOSA, L.; VAKANI, J.; THODAY-KENNEDY, E.; KANT, S. A robust automated image-based phenotyping method for rapid vegetative screening of wheat germplasm for nitrogen use efficiency. **Frontiers in Plant Science**, v. 10, 1372, 2019. <https://doi.org/10.3389/fpls.2019.01372>

SANTOS, M. R. **Desenvolvimento de um sistema de visão computacional para fenotipagem de alta precisão**. 2017. 90 f. Dissertação (Mestrado em Computação Aplicada) - Universidade de Passo Fundo, Passo Fundo, 2017.

SANTOS, T. T.; YASSITEPE, J. E. C. T. **Fenotipagem de plantas em larga escala: um novo campo de aplicação para a visão computacional na agricultura**. In: MASSRUHÁ, S. M. F. S.; LEITE, M. A. de A.; LUCHIARI JUNIOR, A.; ROMANI, L. A. S. (Ed.). *Tecnologias da informação e comunicação e suas relações com a agricultura*. Brasília, DF: Embrapa, 2014. Cap. 5. p. 85-100.

YANG, Z.; WILLIS, P.; MUELLER, R. Impact of band-ratio enhanced AWIFS image to crop classification accuracy. In: *Pecora – The Future of Land Imaging... Going Operational*, 17. 2008, Denver, Colorado, USA. **Proceedings...** Maryland: (ASPRS), 2008. 11p. Disponível em: <<http://www.asprs.org/a/publications/proceedings/pecora17/0041.pdf>>. Acesso em: 11 nov. 2021.