

Predição Não-Destrutiva de Biomassa em Milho Silagem via Visão Computacional e Regressão Linear

Frederico de Souza Sicorra¹, Gabriel Machado Lunardi¹, Tiago Dell Valle²

¹Centro de Tecnologia – Universidade Federal de Santa Maria (UFSM)
CEP 97105-900 – Santa Maria – RS – Brasil

²Centro de Ciências Rurais – Universidade Federal de Santa Maria (UFSM)
CEP 97105-340 – Santa Maria – RS – Brasil

frederico.sicorra@acad.ufsm.br, gabriel.lunardi@ufsm.br, tiago.valle@ufsm.br

Abstract. *This paper presents a non-destructive method for predicting corn silage biomass using Computer Vision and Machine Learning. The methodology extracts the percentage of leaf cover in RGB images via the HSV color space (OpenCV), correlating it with the plant's fresh mass. Field trials with different plant densities (1, 5, and 10) demonstrated high linearity. Simple linear regression models achieved an R^2 of 0.82 and an RMSE of 1.277 kg in the calibration stage. Results demonstrate the technical viability of digital image processing as a low-cost and efficient quantitative tool for crop yield prediction.*

Resumo. *Este artigo apresenta um método não-destrutivo para predição de biomassa de milho silagem utilizando Visão Computacional e Aprendizado de Máquina. A metodologia extrai a porcentagem de cobertura foliar em imagens RGB via espaço HSV (OpenCV), correlacionando-a com a massa fresca da planta. Ensaios em campo com diferentes densidades (1, 5 e 10 plantas) mostraram alta linearidade. Modelos de regressão linear simples atingiram um R^2 de 0,82 e RMSE de 1,277 kg na etapa de calibração. Os resultados demonstram a viabilidade técnica do processamento de imagens como ferramenta quantitativa e de baixo custo para predição de safra.*

1. Introdução

A cultura do milho (*Zea mays L.*) é uma das principais fontes de volumoso na nutrição animal [Cruz et al. 2001], sendo a silagem um componente essencial para a viabilidade econômica e produtiva das propriedades rurais. A estimativa precisa da produtividade e da biomassa verde disponível no campo antes da colheita é fundamental para o planejamento agropecuário. No entanto, os métodos tradicionais de mensuração (como o corte de parcelas, pesagem manual e secagem) são de natureza destrutiva, exigem intenso trabalho humano e demandam um tempo elevado de execução, o que frequentemente inviabiliza amostragens representativas em médias e grandes propriedades.

Para superar esses desafios, a adoção de tecnologias de Agricultura de Precisão tem se tornado uma estratégia essencial. Nos últimos anos, a Visão Computacional tem sido amplamente aplicada para o monitoramento agrícola [Bai et al. 2023], consolidando-se como uma ferramenta promissora para análises não destrutivas no campo. Devido ao baixo custo de *hardware* e à riqueza de informações visuais, algoritmos de processamento

de imagens têm sido adotados para extrair características fenológicas das plantas e automatizar o controle de processos [Liang et al. 2022].

Embora o uso de arquiteturas complexas de *Deep Learning* esteja em ascensão [Neupane et al. 2022], abordagens baseadas em processamento digital de imagens clássicas aliadas a modelos preditivos estatísticos continuam sendo soluções atraídas. Métodos de segmentação em espaços de cores, aliados a regressões lineares simples, oferecem alta explicabilidade matemática, baixo custo computacional e facilidade de implantação em dispositivos com menor capacidade de processamento.

Neste contexto, o presente trabalho propõe uma prova de conceito para um *pipeline* capaz de prever a biomassa fresca de milho silagem de forma não destrutiva. O estudo explora uma abordagem baseada em Visão Computacional, utilizando a biblioteca OpenCV em Python, para segmentar e extrair o percentual de cobertura foliar da cultura em imagens fotográficas. Posteriormente, um modelo supervisionado de Regressão Linear Simples é aplicado para correlacionar a variável visual extraída com a produtividade real. O objetivo é disponibilizar uma base metodológica inicial para o desenvolvimento de uma ferramenta quantitativa que auxilie a tomada de decisão agrônômica.

Este artigo está organizado em cinco seções. A Seção 2 apresenta os trabalhos relacionados e como eles evidenciam a lacuna observada na literatura. A Seção 3 apresenta o banco de dados utilizado na análise bem como a sua estratégia de construção. Ainda nesta seção, apresenta-se o *pipeline* de análise de dados, incluindo algoritmos escolhidos e métricas de avaliação. A Seção 4 apresenta os resultados com tom analítico e de discussão a respeito da generalidade dos modelos. Por fim, a Seção 5 finaliza o documento com as principais implicações e apontamentos para trabalhos futuros.

2. Trabalhos Relacionados

O uso de técnicas de Visão Computacional e Processamento Digital de Imagens na agricultura tem sido amplamente explorado na literatura recente, tanto para o monitoramento fitossanitário quanto para a estimativa de parâmetros fenológicos. A busca por métodos não destrutivos impulsionou publicações em veículos de alto impacto e conferências especializadas.

No contexto de diagnóstico de doenças foliares na cultura do milho, estudos avaliaram a eficácia de diferentes arquiteturas de Redes Neurais Convolucionais (CNNs) utilizando vastos bancos de imagens de folhas infectadas [Ribeiro and Reis 2025]. Os resultados mostram que os algoritmos alcançaram alta precisão na detecção precoce de anomalias, demonstrando a viabilidade de métodos automatizados no campo. No entanto, a literatura destaca que a implementação dessas arquiteturas complexas esbarra em desafios práticos significativos, como a necessidade de alto poder computacional e a dificuldade de embarcar esses modelos densos em dispositivos móveis com recursos limitados.

Soluções focadas no monitoramento fitossanitário também têm sido propostas para detectar a praga *Spodoptera frugiperda* em lavouras de milho [Silva et al. 2024]. O método utilizado baseia-se no uso de armadilhas inteligentes equipadas com câmeras e algoritmos de Visão Computacional combinados com Aprendizado de Máquina. A partir dos resultados, identifica-se como vantagem principal a capacidade de automatizar a contagem de insetos, oferecendo suporte em tempo real à tomada de decisão no Manejo

Integrado de Pragas. Por outro lado, o estudo evidencia que soluções baseadas em *hardware* de coleta de imagens instalado fixamente no campo enfrentam barreiras de custo, infraestrutura e manutenção, o que pode limitar a adoção em larga escala por pequenos produtores.

Adicionalmente, pesquisas recentes buscaram estimar a biomassa acima do solo em plantações de milho utilizando sensoriamento remoto [Macedo et al. 2023, Han et al. 2019]. Os estudos foram realizados utilizando veículos aéreos não tripulados equipados com sensores multiespectrais e RGB para extrair índices de vegetação e características geométricas que alimentaram modelos de regressão. As conclusões sugerem que a combinação de dados aéreos com modelagem estatística atinge altos índices de correlação na previsão de safra. No entanto, as dificuldades apontadas incluem a forte dependência de voos de drones dispendiosos e processamentos de imagem pesados em nuvem, ferramentas que exigem conhecimentos técnicos avançados de operação e alto investimento financeiro.

Diante dos estudos apresentados, percebe-se uma crescente adesão de ferramentas de Visão Computacional e Aprendizado de Máquina para aprimorar o monitoramento e a estimativa de parâmetros na cultura do milho. Essas pesquisas indicam a existência de oportunidades para novas investigações focadas em soluções mais acessíveis, visto que a maioria dos métodos atuais exige *hardware* custoso ou alto poder de processamento. Nesse contexto, este trabalho propõe-se a preencher essa lacuna desenvolvendo um método preditivo de baixo custo. Essa abordagem baseia-se na extração simples de características bidimensionais em imagens RGB capturadas a nível de solo, buscando contribuir significativamente para democratizar a agricultura de precisão por meio de ferramentas leves e de fácil uso por profissionais em campo.

3. Metodologia

Para alcançar o objetivo proposto, o experimento foi estruturado em três etapas inter-relacionadas: (i) aquisição de dados em campo e análise biométrica; (ii) processamento digital de imagens para extração de características visuais; e (iii) modelagem preditiva estatística exploratória.

3.1. Aquisição de Dados e Biometria

A coleta de dados foi realizada em uma área de cultivo comercial do milho (*MG 616*) localizada no sul do Brasil, sob clima subtropical úmido. O solo da área, caracterizado por relevo ondulado, é de origem basáltica e classificado pedologicamente como Argissolo. As plantas selecionadas encontravam-se no estágio fenológico ideal para o corte e produção de silagem.

Para garantir a estabilidade do modelo e minimizar variáveis de confusão nesta prova de conceito, a amostragem foi estritamente padronizada. As plantas utilizadas no experimento apresentavam características biométricas homogêneas, com altura média de 2,40 metros e diâmetro de colmo aproximado de 22 milímetros. Adicionalmente, todas as fotos foram tiradas com a mesma altura em relação ao solo e no mesmo horário, a fim de diminuir quaisquer tipos de interferências nas amostras.

O método destrutivo foi aplicado para obter o “*ground truth*”, ou seja, o peso real da biomassa fresca. Nesta prova de conceito, o *dataset* constituiu-se de uma amostra-

gem reduzida. Foram capturadas exatamente três imagens fotográficas, correspondendo a uma foto para o grupo de 1 planta, uma para 5 plantas e uma para 10 plantas. Essa distribuição buscou forçar uma variabilidade de massa para a construção de uma curva de calibração. Cada grupo foi pesado individualmente utilizando uma balança de precisão, estabelecendo a variável dependente (Y). Ressalta-se que, devido ao escopo inicial, os dados alimentaram o treinamento de um modelo único de regressão para avaliar a linearidade global da predição. As imagens foram capturadas a uma distância focal padronizada de 2 metros de altura, utilizando um fundo de contraste (lona) para mitigar a interferência visual de elementos externos.

3.2. Processamento Digital de Imagens

O fluxo de processamento foi desenhado em etapas sequenciais bem definidas. O ponto de partida é a imagem original capturada no padrão RGB, ilustrada na etapa (a) da Figura 1, que passa logo de início por uma conversão para o espaço de cores HSV. Essa mudança de espaço de cor é uma estratégia importante na agricultura de precisão, pois o HSV separa a informação de brilho da informação de cor, tornando o algoritmo muito mais protegido contra sombras e variações da luz do sol do que se trabalhássemos direto no RGB.

Com a imagem convertida para o espaço HSV, aplicou-se um algoritmo de limiarização (Color Thresholding) para gerar uma máscara binária. Os parâmetros do filtro foram definidos rigidamente no código-fonte para garantir a reprodutibilidade do experimento. O limite inferior foi ajustado em [15, 10, 10] e o limite superior em [100, 255, 255], no formato [Hue, Saturation, Value]. O canal de Matiz (Hue) foi configurado entre 15 e 100, cobrindo desde os tons amarelo-palha da senescência natural das folhas mais velhas até o verde-escuro das folhas jovens, capturando assim toda a variação cromática relevante da cultura. Os canais de Saturação e Brilho (Value) foram mantidos com alta flexibilidade (10 a 255), permitindo que o algoritmo acomodasse regiões sombreadas e áreas de alta refletância luminosa sem suprimir pixels vegetativos úteis. Essa calibração mais aberta foi uma decisão deliberada para preservar a integridade da máscara em condições de iluminação natural variável.

Pipeline de Processamento Digital de Imagens



Limiaries HSV — Inferior: [H=15, S=10, V=10] | Superior: [H=100, S=255, V=255] | Cobertura foliar: 6.93%

Figura 1. (a) imagem RGB original; (b) máscara binária gerada pelo Color Thresholding; (c) máscara refinada após operações morfológicas de abertura e fechamento; (d) material vegetativo isolado.

O fluxo completo do pipeline é ilustrado na Figura 1, composta por quatro etapas sequenciais. Em (a), apresenta-se a imagem original capturada no padrão RGB sobre o fundo de contraste. Em seguida, aplica-se o algoritmo de limiarização (Color Thresholding) no espaço HSV, gerando a máscara binária bruta exibida em (b), onde os pixels pertencentes ao espectro vegetativo aparecem em branco e o fundo é suprimido. Em (c), operações morfológicas de abertura e fechamento são aplicadas para eliminar ruídos pontuais e suavizar as bordas, resultando na máscara refinada. Por fim, em (d), a máscara é aplicada sobre a imagem original, isolando o material vegetativo sobre fundo preto, resultado utilizado para o cálculo da porcentagem de cobertura foliar.

3.3. Modelagem Preditiva

Com a extração da variável visual concluída, a etapa estatística foi conduzida para estabelecer a relação quantitativa entre a proporção de área verde detectada nas imagens e a massa fresca real aferida em campo. Todo o processo de ajuste do algoritmo foi implementado na linguagem Python, utilizando o módulo de modelos lineares da biblioteca *Scikit-Learn* [Pedregosa et al. 2011].

Optou-se pela aplicação de um modelo de Regressão Linear Simples para mapear a relação matemática entre a área verde detectada e a massa da planta. A preferência por uma abordagem paramétrica tradicional, em vez de arquiteturas complexas de aprendizado profundo, foi motivada pela busca de uma alta explicabilidade agrônômica aliada a um baixo custo computacional. Essa escolha estratégica visa garantir que a equação preditiva gerada possa ser, futuramente, embarcada e executada de forma instantânea em dispositivos móveis convencionais, viabilizando o seu uso prático por técnicos durante as vistorias a campo.

Dada a natureza exploratória desta prova de conceito e o dimensionamento controlado da amostragem em campo, o conjunto de dados foi utilizado em sua totalidade para a fase de calibração do modelo. Ou seja, neste primeiro momento, não houve o particionamento clássico entre dados de treinamento e teste (*holdout*), uma vez que o objetivo primário foi validar a existência da linearidade temporal e traçar a reta de melhor ajuste para as condições padronizadas do ensaio.

Para avaliar a confiabilidade dessa relação, o desempenho do modelo foi quantificado por meio de duas métricas complementares. O Coeficiente de Determinação (R^2), descrito na Equação 1, foi utilizado para mensurar o quão bem a variabilidade do peso da planta é explicada pela variação da cobertura foliar identificada pelo algoritmo.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

Em que y_i é a massa real aferida em campo, \hat{y}_i é a massa predita pelo modelo, e \bar{y} é a média das observações reais. Adicionalmente, a Raiz do Erro Quadrático Médio foi adotada para estimar a dispersão dos resíduos. A principal vantagem do uso do RMSE neste contexto agrônômico é que ele retorna a margem de erro na própria unidade de medida da variável alvo, oferecendo uma percepção física, real e direta da precisão da estimativa de biomassa.

4. Resultados e Discussão

Os ensaios preliminares demonstraram a viabilidade técnica da abordagem proposta. A primeira etapa de validação concentrou-se na eficácia do algoritmo de segmentação em isolar a biomassa útil do milho em relação ao fundo da imagem.

Para evitar a supressão dessas áreas úteis, o limiar do espaço de cores HSV precisou ser calibrado com maior tolerância no canal de Matiz (Hue), estendendo-se do amarelo-palha ao verde-escuro, e permitindo alta flexibilidade nos canais de saturação e brilho para acomodar áreas de sombreamento natural. O resultado bem-sucedido desta calibração pode ser observado nas etapas (c) e (d) da Figura 1, evidenciando o material vegetativo isolado com preservação das áreas sombreadas e extremidades amareladas.

Após a extração da porcentagem de área vegetativa nas amostras de 1, 5 e 10 plantas, os dados numéricos foram submetidos ao modelo de Regressão Linear Simples para cruzamento com a massa fresca real. Na etapa de calibração do modelo, obteve-se um coeficiente de determinação (R^2) de 0,82 e uma Raiz do Erro Quadrático Médio (RMSE) de 1,277 kg. Este índice indica que 82% da variabilidade do peso da biomassa fresca pôde ser explicada matematicamente pela variação da área de cobertura foliar detectada na imagem RGB. A Figura 2 apresenta a reta de regressão ajustada sobre os dados coletados.

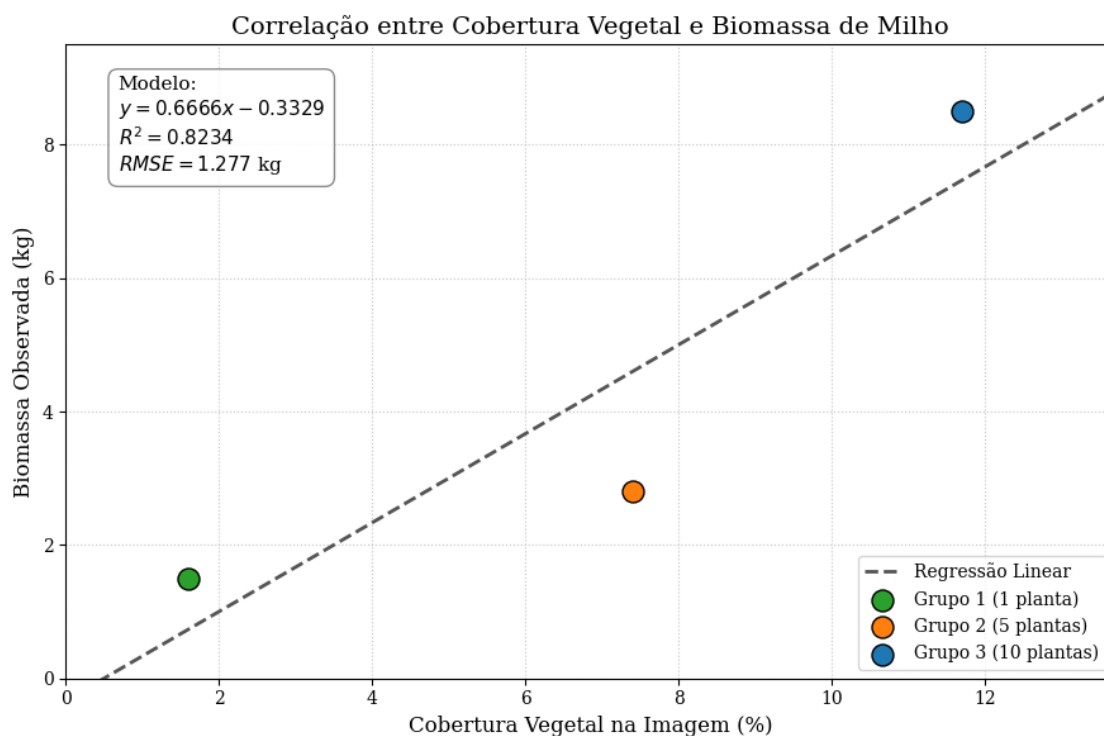


Figura 2. Correlação linear de calibração entre a área foliar extraída (%) e a biomassa fresca real aferida (kg).

Analisando a equação da reta ajustada, o coeficiente angular evidência uma correlação positiva forte, para as condições padronizadas deste estudo, cada acréscimo percentual na cobertura vegetal identificada pelo algoritmo reflete um incremento linear correspondente de biomassa fresca. Dessa forma, a ferramenta fornece uma métrica quan-

titativa e padronizada que mitiga a subjetividade das estimativas visuais tradicionais feitas por humanos no campo. A alta linearidade observada confirma que o volume tridimensional da planta projeta-se de maneira proporcional em um plano bidimensional, desde que mantido o padrão biométrico (altura e diâmetro) e a distância focal de captura.

Embora os resultados desta prova de conceito sejam promissores, é preciso reconhecer algumas limitações do modelo antes de aplicá-lo em larga escala. O primeiro ponto de atenção é que o experimento ocorreu em condições de captura muito controladas. Em um cenário real de campo aberto, as variações de luz solar e o sombreamento natural ao longo do dia certamente vão exigir uma calibração mais dinâmica do algoritmo.

Outro desafio importante desse método é a tentativa de estimar um volume tridimensional (3D) usando apenas uma fotografia (2D). Como o código calcula apenas a área verde que aparece na imagem, é provável que, em lavouras muito fechadas, as folhas da frente acabem sobrepondo e escondendo a biomassa que está atrás, o que pode distorcer a nossa reta de regressão. Essa limitação fica muito evidente quando pensamos na própria espiga do milho, a espiga concentra a maior parte da massa da amostra, mas representa uma área visual proporcionalmente reduzida na projeção fotográfica se comparada ao volume das folhas.

5. Conclusão e Trabalhos Futuros

Este estudo preliminar demonstrou a viabilidade técnica da Visão Computacional para estimar a biomassa verde do milho silagem de forma não-destrutiva, alcançando um R^2 de calibração de 0,82 em condições padronizadas. O processamento no espaço HSV provou-se eficaz para isolar a área foliar, oferecendo uma alternativa de baixo custo computacional.

Como trabalhos futuros, destaca-se a coleta de mais dados a fim de tornar o banco de dados mais representativo, o que permitirá a validação externa do modelo sob condições variáveis de campo. Propõe-se, também, a integração deste *pipeline* com algoritmos avançados de detecção de objetos de estágio único, como o YOLO [Redmon et al. 2016], para segmentar e atribuir pesos específicos às espigas. Adicionalmente, investigações futuras poderão explorar a fusão de dados visuais com sensores de profundidade (RGB-D) ou a inclusão de variáveis biométricas para aprimorar a predição da massa seca sob variabilidade hídrica.

Em cenários operacionais de campo, projeta-se que este processo seja integrado a sistemas de mapeamento pré-colheita. Através da identificação individual de plantas em linha, o método permitiria estimar a biomassa disponível antes da entrada da ensiladeira na área, fornecendo um inventário quantitativo que auxilia no planejamento logístico e na gestão da produtividade da lavoura de milho silagem.

Referências

- Bai, Y., Zhang, B., Xu, N., Zhou, J., Shi, J., and Diao, Z. (2023). Vision-based navigation and guidance for agricultural autonomous vehicles and robots: A review. *Computers and Electronics in Agriculture*, 205:107584.
- Cruz, J. C., Alvarenga, R. C., and Neto, M. M. G. (2001). *Cultivo do milho*. Embrapa Milho e Sorgo.

- Han, L., Yang, G., Dai, H., Xu, B., Yang, H., Feng, H., Li, Z., and Yang, X. (2019). Estimating above-ground biomass of maize using features derived from uav-based rgb imagery. *Remote Sensing*, 11(11):1261.
- Liang, X., Chen, B., Wei, C., and Zhang, X. (2022). Inter-row navigation line detection for cotton with broken rows. *Plant Methods*, 18(1):90.
- Macedo, F. L., Nóbrega, H., Freitas, J. G. R., Ragonezi, C., Pinto, L., Rosa, J., and Carvalho, M. A. A. P. (2023). Estimation of productivity and above-ground biomass for corn (zea mays) via vegetation indices in madeira island. *Agriculture*, 13(6):1115.
- Neupane, J. et al. (2022). A literature review on deep learning applications for livestock monitoring. *Computers and Electronics in Agriculture*.
- Pedregosa, F. et al. (2011). Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, 12(Oct):2825–2830.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 779–788.
- Ribeiro, J. G. and Reis, I. B. (2025). Visão computacional na agricultura de precisão: Uma análise comparativa de arquiteturas cnn no diagnóstico de doenças foliares do milho. In *Anais da Escola Regional de Aprendizado de Máquina e Inteligência Artificial da Região Sul (ERAMIA-RS)*. SBC.
- Silva, W. S., Soares, B., Almeida, V. L., Viana, L., Pastori, P. L., Magalhães, D. M. V., and Rocha, A. R. (2024). Detecção da praga spodoptera frugiperda no cultivo de milho usando armadilhas inteligentes e visão computacional. In *Anais do Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais (WCAMA)*. SBC.