

# Detecção de Ninhos de Cupins em Pastagens com Técnicas de Visão Computacional

Pedro Lucas M. Pereira<sup>1</sup>, Lídia Bononi P. Tomaz<sup>1</sup>, Daniela Resende S. Orbolato<sup>1</sup>

<sup>1</sup>Instituto Federal do Triângulo Mineiro – Campus Uberaba Parque Tecnológico  
Uberaba – MG – Brasil

pedro.medina@estudante.iftm.edu.br, lidia@iftm.edu.br

**Abstract.** *A pasture is degraded when the grass loses the capacity to supply the requirements of the animals, which results in environmental and economic damage. In Brazil, an estimated 60% of pasture areas present some stage of degradation. Based on this fact, this work proposes to employ Computational Vision (CV) techniques to optimize a system to support the diagnostics of degraded pasture. Thus, the authors performed a study of two CV approaches based on objection detection techniques, known as Haar Cascade and YOLO, which were applied to one parameter of such a system: the occurrence of termite nests in pasture images. The results showed Haar Cascade was more efficient for the studied parameter.*

**Resumo.** *Uma pastagem está degradada quando há perda da capacidade para suprir as necessidades dos animais, o que resulta em prejuízos ambientais e econômicos. No Brasil, estima-se que 60% das áreas de pastagem estão em algum estágio de degradação. Baseado nisso, este trabalho propõe a utilização de técnicas de Visão Computacional (VC) para otimizar um sistema de diagnóstico de pastagens degradadas. Assim, os autores realizam o estudo de duas abordagens de VC baseadas em detecção de objetos conhecidas como Haar Cascade e YOLO aplicadas a um dos parâmetros deste sistema, a saber: ocorrência de ninhos de cupins em imagens de pastagem. Os resultados mostraram que o Haar Cascade foi mais eficiente para o parâmetro estudado.*

## 1. Introdução

As pastagens são o alicerce da alimentação dos ruminantes no Brasil. Estima-se que 90% dos nutrientes exigidos pelos animais e, em média, 98% da carne bovina são produzidos nas pastagens. Mesmo com esta importância, estima-se que 60% das pastagens estão degradadas ou em algum estágio de degradação [Embrapa 2022].

Em uma pastagem degradada a planta forrageira tem perda de vigor, de produtividade, de capacidade de recuperação natural para manter os níveis de produção e qualidade requeridos pelos animais [Dias-Filho 2017]. Portanto, uma pastagem nestas condições tem baixa produtividade, o que resulta em: 1) baixo desempenho dos animais, reduzindo a lucratividade do pecuarista (paralelo ao aumento do custo da produção); 2) impactos ambientais como o aumento da emissão de Gases do Efeito Estufa (GEE) na atmosfera e a necessidade de abertura de novas áreas de pasto; 3) degradação do solo por compactação e/ou erosão [Valle Júnior et al. 2019].

Com o intuito de ser uma solução que auxilie na mitigação dos danos causados pelas pastagens degradadas, foi desenvolvido um sistema de apoio ao diagnóstico de pastagens degradadas (denominado SIPADE) para contribuir com autoridades públicas na realização de ações de intervenção [Tomaz et al. 2023]. Este sistema se baseia na metodologia apresentada no trabalho de [Valle Júnior et al. 2019], em que permite avaliar um conjunto de parâmetros que são verificados em campo por fiscais capacitados em tal metodologia. Assim, em campo o fiscal utiliza um aplicativo para dispositivos móveis, onde registra uma imagem para fins de comprovação dos dados observados. Dentre os parâmetros tratados no SIPADE, destaca-se aqui o de índice de infestação por cupim, uma vez que tal tipo de infestação, apesar de ser uma ocorrência natural em pastagens, em níveis elevados, se torna um dos principais fatores para insetos-pragas [Valério 2006].

Considerando que o diagnóstico produzido pelo SIPADE é baseado em análise de imagens de pastagens, observa-se que a aplicação de técnicas de Visão Computacional (VC) pode contribuir significativamente para sua otimização. VC é uma área da Inteligência Artificial que visa extrair informações de interesse a partir de imagens. Dentre as técnicas de VC, destacam-se as Técnicas de Detecção de Objetos (TDO), que estimam a presença e localização de elementos visuais em imagens [Faria 2020].

Neste contexto, este trabalho tem como objetivo principal investigar a viabilidade da aplicação de TDO para automatizar a identificação de ninhos de cupins em imagens de pastagens, contribuindo com o aprimoramento do diagnóstico realizado pelo SIPADE. A automatização dessa etapa visa oferecer maior agilidade, padronização e acurácia na coleta de dados de campo.

Para isso, duas abordagens de TDO foram avaliadas: o algoritmo *Haar Cascade* e o YOLO (*You Only Look Once*). O *Haar Cascade* é baseado em aprendizado de máquina tradicional, utilizando classificadores em cascata treinados com o algoritmo *AdaBoost* para detectar padrões visuais por meio da análise de contrastes regionais na imagem [Viola and Jones 2001]. Sua estrutura hierárquica permite uma detecção rápida com baixo custo computacional. Por outro lado, o YOLO é baseado em Redes Neurais Convolutivas (CNNs) e realiza a detecção em tempo real ao dividir a imagem em uma grade e prever simultaneamente as classes e as caixas delimitadoras dos objetos presentes [Redmon et al. 2016].

Assim, como contribuições científicas e técnicas, este trabalho propõe: 1) a avaliação comparativa entre dois métodos consagrados como TDO aplicados ao contexto de pastagens; 2) a proposta de um processo de construção de bases de dados sintéticas, voltadas ao treinamento de modelos de detecção em cenários com limitação de amostras reais; 3) a definição de um método automatizado com potencial de ser integrado ao SIPADE, ampliando sua aplicabilidade como ferramenta de apoio ao diagnóstico de pastagens degradadas.

Os resultados indicam que o algoritmo *Haar Cascade* apresentou melhor desempenho em termos de acurácia, superando o YOLO em aproximadamente 45%. No entanto, constatou-se que a tarefa continua desafiadora, sobretudo pela similaridade visual entre ninhos de cupins e outros elementos naturais, como troncos ou aglomerados de folhas.

O presente trabalho está organizado da seguinte forma: a Seção 2 mostra os trabalhos correlatos; a Seção 3 descreve os materiais e métodos; a Seção 4 explana sobre os

resultados obtidos; e, por fim, a Seção 5 apresenta as conclusões e trabalhos futuros.

## 2. Trabalhos Correlatos

Diante do impacto ambiental e econômico causado pelas pastagens degradadas no Brasil, os autores de [Valle Júnior et al. 2019] propuseram um método de identificação dessas áreas com base na análise de imagens de satélite utilizando Sistemas de Informações Geográficas (GIS). A abordagem baseia-se na aplicação do Índice de Vegetação por Diferença Normalizada (NDVI), que explora a relação entre as bandas espectrais do infravermelho próximo e do vermelho. O estudo foi conduzido em uma região do Triângulo Mineiro.

Com base nesse método, foi desenvolvido o Sistema para Apoio ao Diagnóstico de Pastagens Degradadas (SIPADE) [Tomaz et al. 2023, SIPADE 2025]. O sistema é composto por dois módulos: um sistema web para gestão dos pontos georreferenciados e um aplicativo móvel para inspeção em campo. Este aplicativo analisa os dados coletados e determina se a pastagem está degradada ou em processo de degradação, apoiando instituições públicas na conscientização de produtores e na definição de ações de recuperação.

Durante as inspeções, é exigido o registro fotográfico dos parâmetros observados. No entanto, o SIPADE ainda não conta com um mecanismo automatizado de verificação das imagens, o que poderia reduzir erros de entrada e agilizar a identificação dos parâmetros. Além disso, o uso do sistema em campo requer que o agente responsável tenha sido previamente capacitado para identificar corretamente os sinais de degradação.

É importante ressaltar que na literatura há outros trabalhos que exploram a identificação de ninhos de cupins em pastagens [Almeida et al. 2024] e em florestas de eucalipto [Sales et al. 2021]. Todavia, todos eles utilizam imagens de drones, ao passo, que neste trabalho, as imagens utilizadas são terrestres.

## 3. Materiais e Métodos

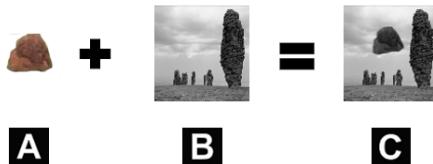
O presente trabalho foi desenvolvido em três etapas: 1) definição da base de dados; 2) treinamento da abordagem *Haar Cascade*; e 3) treinamento da abordagem baseada no *YOLO*. As subseções a seguir detalham cada uma destas etapas.

### 3.1. Base de dados

Devido à escassez de amostras com ocorrência de ninhos de cupins em pastagens, foi necessário criar uma base de dados sintética. Para isso, adotou-se uma estratégia inspirada no *Haar Cascade* [Viola and Jones 2001], utilizando imagens positivas (com ninhos de cupins, fornecidas por um especialista em forragem) e imagens negativas (sem ninhos, extraídas do banco público ImageNet [ImageNet 2021]). Foram utilizadas 3200 imagens negativas em preto e branco, com resolução de  $100 \times 100$  pixels.

A partir das imagens positivas e negativas, realizou-se a seguinte estratégia:

- Recorte de ninhos de cupins isolados, extraídos das imagens positivas, através de um software de edição de imagens.
- Mesclagem das  $n$  imagens positivas em cada uma das  $m$  imagens negativas. Desta forma, a base resultante foi de  $m \times n$  imagens.



**Figura 1. A - Representação de uma imagem aleatória. B - Imagem de um ninho de cupim após passar pelo processo de recorte. C - Imagem resultante da união das imagens A e B.**

A Figura 2 ilustra o processo de construção de uma das imagens segundo a estratégia proposta. Para isso, foi utilizada a rotina *opencv\_createssamples*, da biblioteca OpenCV [OpenCV 2022b], para sobrepor imagens positivas sobre as negativas. Os principais parâmetros utilizados incluem: ângulo máximo de rotação da imagem positiva (0.5 para os eixos *x*, *y* e *z*), dimensões variadas das imagens positivas, quantidade de imagens geradas, transparência definida em 255 e tolerância de cor de fundo ajustada para 9.

Com base nessa estratégia, foram geradas quatro sub-bases de dados (SBD), conforme apresentadas na Tabela 1, variando-se a dimensão das imagens positivas e o número de imagens negativas. Observou-se que a ampliação dessas variáveis contribuiu para o desempenho dos modelos, conforme detalhado na Seção 4.

**Tabela 1. Sub-bases de dados (SBD) com variações na dimensão das imagens positivas e número de imagens negativas.**

SBD	Dimensão da imagem positiva	Qtd. de Imagens Positivas	Qtd. de Imagens Negativas	Total de Imagens
1	10×10	15	500	7500
2	12×12	15	800	12000
3	15×15	15	1000	15000
4	24×24	25	1000	25000

### 3.2. Execução da abordagem do *Haar Cascade*

Para o treinamento do *Haar Cascade*, foi executada a rotina disponível na OpenCV denominada *opencv\_traincascade* [OpenCV 2022a]. Para isso, foi considerado um total de 60 épocas, uma vez que alcançou-se uma taxa de erro igual a 0.000001. Ressalta-se que para a execução deste treinamento, a quantidade de memória disponibilizada foi de 10GB. Um ponto a ressaltar é que foi executado um processo de treinamento para cada uma das SDB apresentadas na Tabela 1. Desta forma, ao final, foram obtidos quatro classificadores treinados.

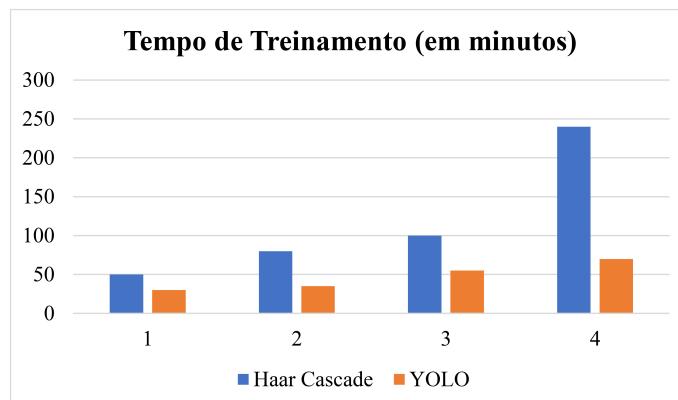
### 3.3. Execução da abordagem do *YOLO*

Para o YOLO foi necessário realizar a marcação das caixas limitadoras nas imagens de treinamento. Para isso, foi utilizado o software *Label Studio* [Studio 2022]. Na sequência, foi utilizada uma técnica conhecida como transferência de aprendizagem, onde é utilizada uma rede pré-treinada do método. Desta forma, foram obtidos os pesos iniciais da rede neural. O treinamento foi realizado por 4100 épocas até obter-se a taxa de erro 0.000001. Ressalta-se que, assim como ocorreu para o *Haar Cascade*, o YOLO foi executado para cada uma das SDB da Tabela 1. Logo, ao final, havia quatro classificadores treinados.

## 4. Resultados

Esta seção apresenta os resultados referentes ao tempo de treinamento do *Haar Cascade* e *YOLO*, bem como da acurácia obtida no processo de validação para detecção de ninhos de cupins em imagens de pasto. Tais resultados foram obtidos através das execuções realizadas em uma máquina com a seguinte configuração: Processador de 11a geração do Processador Intel(R) Core(TM) i7-11800H; Memória RAM de 16GB (2-8GB), DDR4; Disco rígido SSD 1TB M.2; Placa de vídeo GeForce GTX 1650 de 4Gb.

No treinamento, conforme apresentado na Seção 3, foi realizada uma execução para cada uma das SDB da Tabela 1. Desta forma, o gráfico apresentado na Figura 2 apresenta o tempo obtido (em minutos) para cada SDB. Neste contexto, nota-se que o *YOLO* apresentou tempo de treinamento inferior ao *Haar Cascade* para as quatro sub-bases de dados, respectivamente, 40%, 56%, 45% e 70%. Assim, no aspecto tempo de treinamento, o *YOLO*, de fato, mostrou-se mais eficiente que o *Haar Cascade*. Como justificativa para este resultado, observa-se que o *YOLO* parte de uma rede já treinada, conforme exposto na seção 3.3.



**Figura 2. Tempo de treinamento das abordagens *Haar Cascade* e *YOLO* para cada uma das quatro sub-bases apresentadas na Seção 3.**

Após o treinamento, foi realizada a etapa de validação. A base de dados de imagens de validação foi composta por cinco imagens de pastagem com presença de uma média de 44 ocorrências de ninhos de cupins. Foi executado um processo de validação para cada classificador treinado. Nesta direção, a Tabela 2 apresenta os resultados obtidos para cada SBD em relação à média de ninhos de cupins identificados e a média de falsos-positivos obtidos. Os valores de média apresentados consideram o cálculo realizado sobre as cinco imagens utilizadas neste processo.

A Tabela 2 apresenta os resultados da detecção de ninhos de cupins utilizando os classificadores *Haar Cascade* e *YOLO* sobre as quatro sub-bases de dados (SBD). Observa-se que, para ambos os métodos, o aumento da dimensão das imagens positivas resultou em maior média de detecção de ninhos, mas também em crescimento na taxa de falsos-positivos. Na SBD 4, o *Haar Cascade* obteve a maior média de identificação de ninhos (31,82%), porém com elevada taxa de falsos-positivos (42,27%). Já o *YOLO*, embora tenha identificado menos ninhos (14,39%), apresentou menor taxa de falsos-positivos (16,97%).

Esses resultados indicam que, embora o *Haar Cascade* tenha se mostrado mais

**Tabela 2. Acurácia das abordagens do *Haar Cascade* e *YOLO* sobre um conjunto de cinco imagens de pastagens com ocorrência de ninhos de cupins.**

Abordagem de VC	SBD	Média de ninhos de cupins (%)	Média de falsos-positivos
Haar Cascade	1	1,82	0,45
Haar Cascade	2	2,27	0,45
Haar Cascade	3	4,55	2,73
Haar Cascade	4	31,82	42,27
YOLO	1	1,52	0,25
YOLO	2	1,97	0,35
YOLO	3	3,28	1,7
YOLO	4	14,39	16,97

sensível à presença de ninhos, também foi mais suscetível a erros de classificação. Elementos com aparência semelhante, como troncos e acúmulos de folhas, contribuíram para esses falsos-positivos.

Para mitigar esse problema, foi realizado um novo experimento utilizando apenas os classificadores treinados com a SBD 4. Aplicaram-se dois recursos na etapa de validação: (R1) filtros da OpenCV, como *scaleFactor* e *minNeighbors*, visando refinar a detecção; e (R2) segmentação das imagens com base em cores RGB, convertidas para escala de cinza. Neste segundo recurso, definiu-se empiricamente o intervalo de 79 a 169 como o mais adequado para os três canais RGB. Os resultados dessa abordagem estão apresentados na Tabela 3.

**Tabela 3. Acurácia das abordagens do *Haar Cascade* e *YOLO* sobre um conjunto de cinco imagens de pasto que apresentam o registro de ninhos de cupins.**

Abordagem de VC	SBD	Média de ninhos de cupins (%)	Média de falsos-positivos
Haar Cascade - R1	4	10,9	4,09
Haar Cascade - R2	4	31,82	3,64
YOLO - R1	4	7,86	2,92
YOLO - R2	4	14,39	2,12

Conforme apresentado nos resultados, a abordagem *Haar Cascade* com aplicação dos filtros da OpenCV (R1) alcançou uma média de detecção de ninhos de cupins de 10,9% e taxa de falsos-positivos de 4,09%. Já com o uso da segmentação por cores RGB (R2), a média de detecção aumentou para 31,82%, com redução da taxa de falsos-positivos para 3,64%. No caso do *YOLO*, a configuração com filtros (R1) obteve uma média de 7,86% de ninhos detectados e taxa de 2,92% de falsos-positivos, enquanto a versão com segmentação por cores (R2) alcançou uma média de 14,39% de detecção e 2,12% de falsos-positivos.

Ao subtrair os falsos-positivos das médias de detecção para as versões R2 — consideradas as mais eficazes —, obtém-se valores líquidos de 28,18% para o *Haar Cascade* e 12,27% para o *YOLO*. Assim, observa-se que o *Haar Cascade* com segmentação RGB (R2) apresentou desempenho aproximadamente 45% superior ao *YOLO* na identificação de ninhos de cupins. Portanto, essa abordagem configura-se como a mais eficiente entre as avaliadas neste estudo.

A Figura 3 ilustra um exemplo de detecção utilizando o *Haar Cascade* com o

recurso de segmentação por cores (R2).



**Figura 3. Ilustração dos ninhos de cupins identificados a partir da execução do Haar Cascade treinado com a SDB 4 e com a aplicação de canais RGB**

## 5. Conclusão e Trabalhos Futuros

Este trabalho demonstrou o potencial da Visão Computacional (VC) na automatização do diagnóstico de pastagens degradadas, com foco na identificação de ninhos de cupins. A partir da criação de sub-bases sintéticas e aplicação das abordagens *Haar Cascade* e *YOLO*, constatou-se que a primeira, combinada à segmentação RGB, apresentou melhor desempenho, com taxa de acerto 45% superior.

O objetivo central deste estudo foi avançar na automatização da coleta de dados referentes a parâmetros de identificação de pastagens degradadas no SIPADE, com foco específico na detecção de ninhos de cupins. Ressalta-se, no entanto, que o escopo deste trabalho não contempla a determinação do nível de infestação, uma vez que tal análise exige considerações adicionais, como a área de cobertura da imagem, o que será objeto de estudos futuros.

Como trabalhos futuros, pretende-se explorar outras técnicas de VC que possam aprimorar a acurácia na identificação de ninhos de cupins. Além disso, almeja-se aplicar as abordagens propostas a outros parâmetros avaliados no SIPADE, visando analisar seu desempenho diante das particularidades visuais de cada tipo de degradação observada em campo.

## Referências

- Almeida, I. P., Fernandes, A., Parreira, W. D., Oliveira, M. F., Guckert, K. S., and Coelho, D. K. (2024). Identificação de solo exposto e cupinzeiros em pastagens utilizando deep learning. *XV Computer on the Beach*.
- Dias-Filho, M. B. (2017). *Degradação de pastagens : o que é e como evitar*. Embrapa.
- Embrapa (2022). Pastagens.

- Faria, M. P. P. (2020). Investigaçāo de mētodos de aprendizagem e de representāo de ambientes na construçāo de agentes jogadores operando em cenários variados: Aplicaçāo ao jogo fifa. Master's thesis, Universidade Federal de Uberlāndia.
- ImageNet (2021). Imagenet. <https://www.image-net.org/>. Disponível em 29 set. 2022.
- OpenCV (2022a). Cascade classifier training.
- OpenCV (2022b). Opencv about. <https://opencv.org/about/>. Disponível em 10 set. 2022.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 779–788, Los Alamitos, CA, USA. IEEE Computer Society.
- Sales, J., Marcato Junior, J., Siqueira, H., De Souza, M., Matsubara, E., and Gonçalves, W. N. (2021). Retinanet deep learning-based approach to detect termite mounds in eucalyptus forests. In *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, pages 586–589.
- SIPADE (2025). Sipade.
- Studio, L. (2022). Open source data labeling platform.
- Tomaz, L., França, M., Maciel, V., Orbolato, D., Ponciano, M., Faria, D., and Valera, C. (2023). Sipade: Uma soluçāo do brasil para apoio ao diagnóstico de pastagens degradadas. In *Anais Estendidos do XIX Simpósio Brasileiro de Sistemas de Informaçāo*, pages 99–101, Porto Alegre, RS, Brasil. SBC.
- Valle Júnior, R. F. d., Siqueira, H. E., Valera, C. A., Oliveira, C. F., Sanches Fernandes, L. F., Moura, J. P., and Pacheco, F. A. L. (2019). Diagnosis of degraded pastures using an improved ndvi-based remote sensing approach: An application to the environmental protection area of uberaba river basin (minas gerais, brazil). *Remote Sensing Applications: Society and Environment*, 14:20–33.
- Valério, J. R. (2006). Cupins-de-montículo em pastagens. Technical report, EMBRAPA.
- Viola, P. A. and Jones, M. J. (2001). Rapid object detection using a boosted cascade of simple features. In *CVPR (1)*, pages 511–518. IEEE Computer Society.