

# Detecção e Contagem de Bovinos em Imagens Aéreas utilizando Visão Computacional

Juliana Midlej do Espírito Santo<sup>1</sup>, Jorge Lima de Oliveira Filho<sup>1</sup>

<sup>1</sup> Departamento de Ciências Exatas e Tecnológicas  
Universidade Estadual de Santa Cruz (UESC) – Ilhéus, BA – Brazil

jmesanto91@gmail.com, jorgelima@gmail.com

**Abstract.** *This article presents a solution to identification and counting of white cattle in aerial images obtained by a drone using computer vision methods. The Python programming language and the OpenCV (Open Source Computer Vision) library were used for image treatment and segmentation. The developed solution was tested in images of the dry or rainy season and used different parameters for each one in its processing, increasing efficiency and reducing the error rate.*

**Resumo.** *Este artigo apresenta uma solução para identificação e contagem de bovinos brancos em imagens aéreas obtidas através de um drone utilizando métodos de visão computacional. Foram utilizadas a linguagem de programação Python e a biblioteca OpenCV (Open Source Computer Vision) para tratamento e segmentação das imagens. A solução desenvolvida foi testada em imagens do período seco ou período chuvoso e utilizou diferentes parâmetros para cada uma em seu processamento, aumentando a eficácia e reduzindo a taxa de erros.*

## 1. Introdução

A criação de bovinos no Brasil está presente desde o início de sua colonização até os dias atuais. Segundo Batistella et al. (2011), em meados dos anos 1970, ela representava uma das mais importantes atividades econômicas da agropecuária brasileira. A bovinocultura ocupa cerca de um quinto do território nacional e o país possui um dos maiores rebanhos mundiais do produto, sendo também um dos líderes em exportação e consumo.

O desenvolvimento de um software capaz de detectar bovinos brancos através de imagens aéreas obtidas por meio de drones tem por objetivo tornar mais fácil a contagem e controle dos bovinos nas propriedades. Além disso, segundo Oliveira et al. (2002), raças indianas, como a Nelore, possuem destaque na pecuária brasileira, além de uma melhor adaptação ao ambiente tropical e reprodução do que raças europeias também introduzidas no território. Um grande número dos bovinos no Brasil pertence a raça Nelore, uma raça que possui pelagem curta e branca. Essa raça está largamente presente nas imagens testadas.

Foram escolhidos para a pesquisa bovinos brancos devido à sua predominância nas imagens obtidas e ao melhor contraste em relação ao solo independente do período do ano, facilitando, dessa maneira, seu processamento e detecção nas imagens. Em um

período seco, com o solo mais árido e marrom, a identificação de bovinos marrons torna-se complexa.

O software desenvolvido atua sobre dois conjuntos de imagens retiradas entre 30 e 50 metros de altura. As imagens são divididas de acordo com a cor do solo entre imagens do período seco ou do período chuvoso para facilitar o processo de segmentação.

Também foram utilizados filtros provenientes da biblioteca de visão computacional OpenCV para o processamento das imagens. Os filtros visam a redução dos ruídos em busca de melhores resultados na segmentação da imagem e detecção de seus contornos.

Experimentos foram realizados em um conjunto de 103 imagens de ambos os períodos mencionados e o software desenvolvido obteve eficácia média de 89,1% no reconhecimento correto do bovino. A taxa de erros cometidos, ou seja, de demarcações feitas pelo algoritmo que não eram bovinos, corresponde a 6,5%.

## **2. Trabalhos Correlatos**

Há diversos trabalhos na linha de pesquisa da detecção e classificação de objetos. Dentre eles, Ribeiro et al. (2019) realizou um trabalho sobre a utilização da visão computacional para contagem de bovinos através de imagens aéreas. Na pesquisa realizada por eles, assim como no presente trabalho, foram utilizados métodos de diminuição de ruídos, limiarização, como a segmentação, transformações morfológicas e detecção de bordas. Os resultados alcançados pelos autores foram obtidos para oito diferentes imagens, dentre elas, imagens de campo aberto, com bovinos próximos ou distantes, e de diferentes contrastes com o solo, e também para bovinos em confinamento, obtendo melhores resultados para a detecção de bovinos brancos em campo aberto. A pesquisa desenvolvida neste artigo é realizada com 103 imagens de bovinos em campo aberto divididas nos períodos de seca ou chuva e detecta apenas bovinos brancos. Para cada período são utilizados diferentes parâmetros no tratamento das imagens e a altura em que elas são tiradas também é levada em consideração.

A automatização da detecção e contagem de animais por fotografias aéreas realizada por Sirmacek et al. (2012) também propõe o uso de técnicas de processamento de imagens e visão computacional. Em sua pesquisa, foi utilizado o método FAST (*features from accelerated segment test*), especialmente desenvolvido para detecção de bordas por Rosten et al. (2010), mas utilizado para extrair locais de interesse em imagens. Os locais detectados são utilizados como pontos de observação para gerar uma função de densidade de probabilidade. Após o uso desta função em uma imagem, é realizada a segmentação e aplicação de uma teoria de grafos baseada em detecção de animais para obter o número real de animais presentes.

Groom et al. (2007) mapearam aves de diferentes espécies e gêneros por meio de fotografias retiradas a partir de uma câmera digital, desenvolveram e compararam a precisão dos métodos de mapeamento de imagem com base em pixel e objeto. Para o mapeamento com base em pixel, devido sua simplicidade, foi utilizado apenas o processo de *level-slicing*. Para as imagens mapeadas com base em objeto foi utilizado o processo de segmentação feito com as devidas configurações de parâmetros para derivar


objetos de imagem relacionados ao objeto de interesse do mapeamento, além da definição de características do ambiente, como a forma, cor e textura, utilizadas para rotular os objetos encontrados em classes pertencentes.

A pesquisa realizada por Groom et al. (2007) e por Sirmacek et al. (2012), assim como o presente trabalho, faz uso do processo de segmentação para auxiliar na detecção dos objetos. Já para a classificação utilizam, respectivamente, a definição de características do ambiente e a teoria de grafos. A classificação dos objetos detectados nessa pesquisa faz uso da detecção de contornos e avaliação de sua características, como o raio do menor círculo circunscrito e a área. Futuramente, visa-se a utilização das redes neurais de modo a atingir maior precisão na detecção e classificação dos animais na imagem.

### 3. Processamento de Imagens


Segundo Marengoni e Stringhini (2009), para o melhor funcionamento dos processos de visão computacional, tais como a segmentação, é necessária uma etapa de pré-processamento que envolve a utilização de filtros para remoção de ruídos e conversão da imagem para o formato necessário.

Uma das etapas do pré-processamento das imagens é a conversão do sistema de cores RGB, ou BGR (ordem utilizada na ferramenta OpenCV), para o sistema de cores HSV. A Figura 1 mostra a conversão de uma imagem para o sistema de cores HSV, os três canais desse sistema correspondem a tonalidade, saturação e brilho.



**Figura 1. Conversão de uma imagem do sistema RGB para o sistema HSV**


Dentre os filtros que proporcionam a redução de ruídos de uma imagem, está a suavização com o filtro gaussiano. O processo confere à imagem um efeito de desfoque e também melhora o desempenho dos filtros de detecção de bordas [Antonello 2017]. A Figura 2 demonstra o uso do filtro gaussiano utilizado em uma das imagens do período de chuvas.



**Figura 2. Utilização do filtro gaussiano em uma imagem**

Também foram utilizadas séries dos processos de erosão e dilatação da imagem, o que proporciona a retirada de pequenas bolhas ou ruídos restantes [Rosebrock 2015]. Ambos os processos aumentam ou diminuem as áreas segmentadas, devido à isso, o


processo de erosão pode ajudar na separação de bovinos em algumas imagens quando estão conectados, mas não estão completamente unidos, corrigindo uma posterior detecção de bordas e melhorando a precisão do programa. A Figura 3 exemplifica um caso em que ocorre a separação de dois bovinos após processos de erosão e dilatação na imagem.



**Figura 3. Série de erosões e dilatações aplicadas em uma imagem**

A segmentação através da cor é útil quando sabemos a cor do objeto procurado e ela difere do restante da imagem, os algoritmos que implementam esse tipo de binarização são extremamente rápidos e não utilizam muitos recursos [Rosebrock 2015]. A segmentação escolhida para esse trabalho é feita sobre o sistema de cores HSV, sendo necessária a conversão do sistema de cor original das imagens estudadas, o RGB, para esse sistema. Para o uso da função de segmentação são definidos como parâmetros valores mínimos e máximos nos canais de tonalidade, saturação e brilho dentro do sistema HSV nos quais apenas o objeto desejado seja destacado em relação ao restante da imagem.

Concluimos então, que, se a mudança de período causa uma mudança significativa no tipo de imagem que é estudada, essencialmente, na predominância e distribuição das cores, é justificável a necessidade de parâmetros diferentes para ambos os períodos na realização de sua segmentação. Na Figura 4 temos uma representação do uso da segmentação na qual os parâmetros escolhidos conseguem destacar somente o bovino branco do restante da imagem.



**Figura 4. Segmentação de uma imagem a partir do sistema de cores HSV**

O último processo envolvido no software em questão é utilização de um filtro de detecção dos contornos. Após esse processo, para cada contorno encontrado, são calculados e verificados se os valores correspondentes a área do contorno e ao raio do menor círculo que o envolve completamente condizem com o objeto procurado [Rosebrock 2015]. Um raio ou área muito maior ou muito menor não é, provavelmente, o objeto buscado.

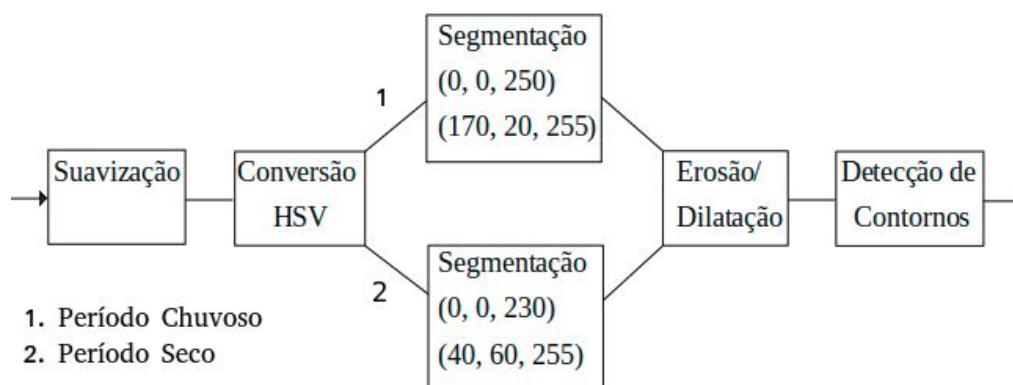
## 4. Metodologia

Para desenvolver o software apresentado neste trabalho foi levado em consideração uma série de passos que serão apresentados nesta seção. Primeiramente foram obtidas imagens aéreas obtidas com um drone. A seleção de imagens foi realizada de acordo com o período o qual a imagem pertence ao levar em conta o solo. A mudança de cor do solo de acordo com o período de seca ou de chuvas gera a necessidade de dois estudos diferentes a segmentação de cada imagem. As imagens também foram separadas por uma margem de altura em relação ao solo, já que, para classificação do bovino, a altura influencia no tamanho que ele terá na imagem. A altura relativa da imagem foi obtida através do acesso aos metadados das imagens aéreas utilizando a ferramenta Exiftool. A seleção dos períodos a qual a imagem pertence foi realizada de forma manual.

O software desenvolvido neste projeto utilizou a linguagem de programação Python e a biblioteca de visão computacional OpenCV. Foram realizados diversos testes em busca dos parâmetros e do fluxograma de processos que obtivesse o melhor resultado na detecção de bovinos brancos nas imagens selecionadas. O algoritmo, para os períodos de seca e chuva, é descrito da seguinte maneira:

- 1) Realização da suavização gaussiana da imagem;
- 2) Conversão do sistema de cores RGB para o HSV;
- 3) Segmentação da imagem de acordo com os parâmetros obtidos para cada período;
- 4) Séries de erosões e dilatações;
- 5) Detecção de contornos.

Na Figura 5 podemos observar o fluxograma apresentando os processos que a imagem passa até a detecção dos contornos. Todos os procedimentos envolvidos estão também explicados na Seção 3 deste artigo e numerados sequencialmente acima. A divergência entre os fluxogramas dos períodos seco ou chuvoso ocorre no processo de segmentação da imagem e os valores entre parêntesis representam os parâmetros utilizados em cada processo. No caso da segmentação, referem-se aos limites nos canais do sistema de cores HSV no qual o processo é realizado sobre a imagem.



**Figura 5. Fluxograma dos períodos chuvosos e secos**

Após a execução do fluxograma de processos da Figura 5, é realizada a contagem dos contornos detectados. Para cada contorno, calcula-se a área do contorno e

o raio do menor círculo que o envolve completamente. Os valores obtidos a partir desse cálculo são comparados com valores de mínimo e máximo definidos através de testes empíricos de forma que o raio e a área possam corresponder corretamente a um bovino. Os valores escolhidos como mínimos foram 10 e 100 pixels para o raio e área respectivamente, e como máximos foram 200 e 12000 pixels, respectivamente.

Os valores estabelecidos podem abranger mais de um bovino em alguns casos, entretanto, um valor que sobressaia a margem que foi estabelecida para os raios é desconsiderada, podendo se tratar de um terreno mais claro ou até mesmo um telhado devido sua extensão.

A Figura 6 ilustra todo o processo da detecção, classificação e contagem de bovinos brancos executado em uma imagem, na imagem 1 temos a entrada do programa, a imagem 2 é o processo de suavização, a imagem 3 mostra a conversão para o sistema de cores HSV, a imagem 4 é a segmentação através da cor, a imagem 5 são as erosões e dilatações realizadas e a imagem 6 o resultado obtido, detectando corretamente seis bovinos na imagem.

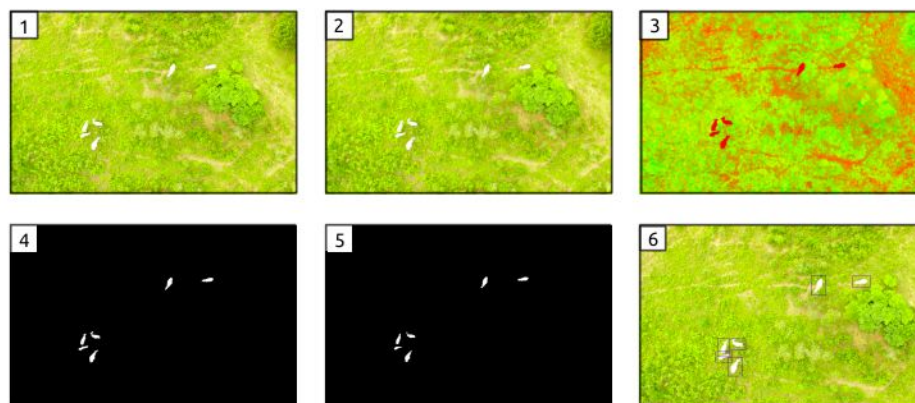


Figura 6. Fluxograma executado em uma imagem

## 5. Resultados Obtidos

Para testar a solução proposta, foram utilizadas imagens de 30 a 50 metros de altura, todas em campo aberto, totalizando 75 imagens no período de chuva e 28 imagens no período de seca. As Tabelas 1 e 2 exibem os resultados obtidos na contagem dos bovinos com este conjunto de imagens. O número de bovinos reais em cada imagem é representado por total, o número de bovinos encontrados de forma correta pelo programa é representado por detectados e as marcações que não representam bovinos são os erros. A contagem do número total de bovinos nas imagens foi realizada através da edição e marcação manual dos bovinos com um círculo vermelho e desenvolvimento de um algoritmo para contagem das marcações de cada imagem.

O percentual de reconhecimento representa a porcentagem de quantos bovinos foram corretamente encontrados, calcula-se: bovinos detectados / bovinos totais multiplicado por 100. O percentual de erro refere-se, dentro das marcações que o software afirma que são bovinos, quantas estão corretas, calcula-se: erros / (bovinos detectados + erros) multiplicado por 100. O percentual final é o percentual de efetividade do software, que subtrai do percentual de reconhecimento o percentual de erro.

**Tabela 1. Contagem de Bovinos utilizando imagens com altura de 30 a 40 metros**

| <b>Período</b> | <b>Total</b> | <b>Detectados</b> | <b>Erros</b> | <b>Reconhecimento</b> | <b>Erro</b> | <b>Efetividade</b> |
|----------------|--------------|-------------------|--------------|-----------------------|-------------|--------------------|
| Chuvoso        | 388          | 384               | 24           | 98,9%                 | 5,8%        | 93,1%              |
| Seco           | 891          | 778               | 53           | 87,3%                 | 6,3%        | 81%                |

**Tabela 2. Contagem de Bovinos utilizando imagens com altura de 40 a 50 metros**

| <b>Período</b> | <b>Total</b> | <b>Detectados</b> | <b>Erros</b> | <b>Reconhecimento</b> | <b>Erro</b> | <b>Efetividade</b> |
|----------------|--------------|-------------------|--------------|-----------------------|-------------|--------------------|
| Chuvoso        | 468          | 456               | 26           | 97,4%                 | 5,3%        | 92,1%              |
| Seco           | 667          | 535               | 48           | 80,2%                 | 8,2%        | 72%                |

As Tabelas 1 e 2 mostram, nos campos de reconhecimento, erro e efetividade, a eficiência do software em um conjunto de imagens em ambos os períodos. Em suma, o percentual de reconhecimento, considerando todas as imagens testadas de 30 a 50 metros, corresponde a 89,1%, o percentual de erro corresponde a 6,5% e o percentual de efetividade a 82,6%. As maiores dificuldades e principais causas das marcações equívocas e de bovinos não encontrados estão em casos de obstáculos que impedem a visão completa e detecção, como árvores, a proximidade dos bovinos e objetos de cor parecida, como cavalos, cercas e terrenos mais claros. Tais dificuldades afetam diretamente os percentuais estudados e avaliados acima.

## **6. Conclusão e Trabalhos Futuros**

A solução proposta obtém bons resultados em ambientes onde o bovino está mais disperso e a fotografia está voltada para o solo. Foram testadas o maior número de imagens possíveis até o momento dentro dos padrões estabelecidos, e o algoritmo desenvolvido neste projeto abrange uma boa margem de altura. A execução do programa em várias imagens de diferentes períodos e formas permitiu ver também as principais dificuldades enfrentadas na construção e aprimoramento do algoritmo e sua eficiência, o que é de extrema relevância para continuidade desta pesquisa.

Os resultados obtidos com a utilização desse programa podem e devem ser melhorados. Os principais erros e dificuldades podem ser estudados e, possivelmente, resolvidos com o uso da aprendizagem profunda.

Como trabalho futuro é prevista a utilização de redes neurais para, após o processamento das imagens e detecção dos bovinos, assegurar a veracidade da detecção, podendo utilizar métodos de classificação binária, ou mesmo, havendo tempo e dados suficientes, métodos para realizar contagem, como a rede neural YOLO (You Only Look Once) [Redmon et al. 2016]. Dessa maneira, a proximidade dos bovinos e objetos que podem ser confundidos com os eles poderão ser melhor tratados e a precisão obtida tende a melhorar.

## **Referências**

Antonello, R. (2018), Introdução à Visão Computacional com Python e OpenCV, Santa Catarina, 1a edição.

- Batistella, M. Andrade, R. G., Bolfe, E. L., Victoria, D. D. C. e Da Silva, G. B. S. (2011). Geotecnologias e gestão territorial da bovinocultura no Brasil. Em Embrapa Territorial-Artigo em periódico indexado (ALICE), páginas 251-260.
- De Oliveira, J. H. F., Magnabosco, C. D. U. e Borges, A. D. S. (2002), Nelore: Base Genética e Evolução Seletiva no Brasil, Planaltina, 1a edição.
- Groom, G., Petersen, I. K. e Fox (2007). Sea bird distribution data with object based mapping of high spatial resolution image data. Em Challenges for earth observation-scientific, technical and commercial. Proceedings of the Remote Sensing and Photogrammetry Society Annual Conference.
- Marengoni, M. e Stringhini, S. (2009). Tutorial: Introdução à visão computacional usando opencv. Em Revista de Informática Teórica e Aplicada, páginas 125-160.
- Redmon, J., Divvala, S., Girshick, R. e Farhadi, A. (2016). You only look once: Unified, real-time object detection. Em Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, páginas 779-788.
- Ribeiro, N. G. Vi., Guedes, G. B. e Barbieri, T. T. (2019). Aplicação de algoritmos de visão computacional na contagem de gado por meio de processamento de imagens aéreas. Em Revista Eletrônica Argentina-Brasil de Tecnologias da Informação e da Comunicação.
- Rosebrock, A. (2015) “OpenCV Track Object Movement”, <https://www.pyimagesearch.com/2015/09/21/opencv-track-object-movement>, Março.
- Rosten, E., Porter, R. e Drummond, T. (2010). Faster and better: A machine learning approach to corner detection. Em IEEE Transactions on Pattern Analysis and Machine Learning, páginas 105-119.
- Sirmacek, B., Wegmann, M., Cross, A. D. P., Hopcraft, J. G. C., Reinartz, P. e Dech, S. (2012). Automatic population counts for improved wildlife management using aerial photography. Em 6th International Congress on Environmental Modelling and Software.