

Aplicação de algoritmos de Visão Computacional na contagem de gado por meio de processamento de imagens aéreas

Nathan G. V. Ribeiro¹, Gustavo B. Guedes¹, Tamires T. S. Barbieri¹

¹Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Campus Hortolândia
CEP: 13183-250 – Hortolândia – SP – Brasil

nathanpirral@gmail.com, {gubartz, tamires.barbieri}@ifsp.edu.br

Abstract. *This paper describes the process of developing a software that makes use of Computational View algorithms in cattle counting through images collected in public image banks. Image processing is performed by computational view and image processing libraries available in the Python programming language. The justification for this work is in the relevance that statistical analysis of data has to the livestock sector when applied to general management, vaccination and disease control processes, especially due to the constant growth of the exports of products generated by livestock in Brazil.*

Resumo. *O presente artigo descreve o processo de desenvolvimento de um programa que aplica algoritmos de Visão Computacional na contagem de gado por meio de imagens aéreas coletadas em bancos de imagens públicas. O processamento das imagens é efetuado por bibliotecas de visão computacional e de processamento de imagens disponíveis para a linguagem de programação Python. A justificativa para desenvolvimento deste trabalho está na relevância da análise estatística dos dados coletados por pecuaristas aplicados na administração dos diversos processos de manejo, vacinação e controle de doenças em gados especialmente devido ao constante crescimento da exportação de produtos gerados pela pecuária no Brasil.*

1. Introdução

Segundo Barros et al. (2018) a pecuária no Brasil tem se expandido nos últimos 45 anos e o país se tornou líder mundial em exportação de produtos gerados pela pecuária. Sua representatividade no Produto Interno Bruto (PIB) é de 5,1% sendo maior que os setores de transporte e mineração no último censo realizado em dezembro de 2018.

De acordo com a pesquisa de Carvalho (2018) os dados levantados pelo Centro de Estudos Avançados em Economia Aplicada indicam um aumento na produtividade média da pecuária nacional, tanto no sistema de produção extensiva quanto no sistema de confinamento. Entretanto apesar dos avanços da quantidade de animais em rebanhos e no aumento do peso de bovinos, quando são comparados os índices de desmame e ocupação de menos espaço durante o sistema de cria, nota-se que o Brasil ainda tem um caminho de desafios a serem enfrentados e com o auxílio da tecnologia estas barreiras podem ser derrubadas.

A necessidade global por alimentos vai exigir cada vez mais produtividade nos processos agrícolas e pecuários. Para que isto ocorra, o uso de tecnologias como o processamento de imagem, redes de sensores sem fio e Internet das Coisas são essenciais

para aprimorar a gestão operacional de fazendas e garantir o crescimento da produtividade, necessários para a expansão do mercado pecuarista brasileiro.

Este trabalho desenvolveu um programa, que por meio de aplicação de filtros de processamento de imagem e a utilização de algoritmos de visão computacional, conseguiu realizar a contagem de gado, tanto em ambientes de confinamento como em campo aberto.

Na seção 2 apresenta-se a fundamentação teórica descrevendo todos os processos e filtros, visando contextualizar o leitor sobre os componentes do programa desenvolvido. A seção 3 apresenta os trabalhos correlatos detalhando as distintas abordagens para solucionar a contagem de objetos e animais.

A seção 4 descreve a metodologia empregada no desenvolvimento. Já a seção 5 elabora as discussões dos resultados para que na seção 6 sejam apresentadas as conclusões e descobertas da pesquisa, evidenciando as deduções extraídas com o trabalho, sugerindo ainda, possíveis melhorias a serem aplicadas em trabalhos futuros.

2. Fundamentação Teórica

Esta seção apresenta os principais conceitos utilizados no trabalho para o processamento das imagens coletadas, apresentando-se a definição dos conceitos de visão computacional e suas áreas de pesquisa, assim como, expõe as tecnologias escolhidas para a contagem de gado.

2.1. Filtros de escala de cinza (Grayscale Filters)

Segundo Klette (2014), as imagens digitais monocromáticas em escala de cinza, são imagens, cuja composição é baseada na variação de cores entre a cor preto como menor intensidade e a branca como maior intensidade. A Figura 1 exemplifica como as imagens de escala de cinza não possuem cores quando comparadas a imagens digitais multicamadas.




Figura 1. Fotografia de um cogumelo Amanita muscaria em escala de cinza.
Fonte: Pixabay, 2017.

O cálculo para conversão de uma imagem multicamadas em uma imagem de escala de cinza é apresentado na Equação 1. Esta conversão é necessária, pois é responsável por realizar a adequação da imagem pelo fato de que a identificação de cores não é uniforme com relação ao olho humano fato que também ocorre na aquisição de imagens digitais pois foram construídas para que se aproximem ao máximo possível da visualização do olho humano.

Os humanos percebem o verde mais fortemente do que o vermelho e azul, isso é decorrente do ponto de vista da biologia evolutiva, pois grande parte do mundo natural aparece em tons de verde e, portanto, os humanos desenvolveram maior sensibilidade à luz verde.

Segundo Poynton (2012), a conversão acontece por meio da normalização dos valores dos canais RGB (Red, Green e Blue) para o modelo YIQ, dentro deste modelo Y representa a luminância do pixel convertido e é um valor composto por R que descreve o valor (v) da camada de cor vermelha, G que descreve o valor (v) da camada de cor verde e B que descreve o valor (v) da camada de cor azul. Esta conversão segue os padrões de recomendação da norma ITU-R BT.601 da International Telecommunication Union ITU (2017), a qual prevê um padrão para codificação de sinais de vídeo digital, cujas constantes definem valores de conversão mais adequados para correção dos valores da escala de cinza para visualização do olho humano e são utilizados na maior parte dos programas de processamento de imagens digitais como o algoritmo padrão.

$$Y = 0,299 * R + 0,587 * G + 0,114 * B \quad (1)$$

A finalidade da utilização deste tipo de filtro de imagem, é seu refinamento, eliminando detalhes desnecessários e a preparação para a aplicação do processo de limiarização da imagem, que irá resultar em uma imagem binária que facilita a identificação dos animais presentes na imagem a ser processada.

2.2. Filtros de suavização

A suavização é uma das operações mais comuns nas aplicações de processamento de imagem. Sua finalidade é salientar determinadas características de uma imagem, além de reduzir os ruídos gerados durante o processo de aquisição, seja por uma limitação de hardware que realizou a captura, seja pela excessiva compressão a fim de reduzir o tamanho em memória ocupado ou ainda por problemas nos processos de quantização e digitalização.

Segundo Jesus and Jr (2015), existem diferentes métodos de suavização de imagens tais como: a normalização, o filtro Gaussiano, o filtro mediano e o bilateral.

O método Gaussiano, que foi utilizado no programa implementado, se baseia na distribuição estatística de valores que se agrupam em torno de uma média conhecida como distribuição Gaussiana ou distribuição normal.

O efeito visual da aplicação desta técnica gera um desfoque da imagem processada, onde, quanto menor for o valor do desvio padrão da distribuição normal, mais agrupados em torno da média os valores serão e conseqüentemente mais desfocada uma imagem será. O desfoque é o termo usado para definir os pontos ao qual convergem ou divergem um feixe de ondas eletromagnéticas, sendo os feixes de luz utilizados para a composição das imagens digitais.

2.3. Limiarização de imagens

Segundo Klette (2014), o processo de limiarização de imagens digitais (do inglês, thresholding) é um método de segmentação, cuja aplicação, faz a troca de cada um dos pixels de uma imagem por uma cor, desde que, os valores de intensidade dos mesmos, sejam menores que o valor de uma constante de limite; desta maneira um pixel cuja cor seja de baixa intensidade, pode ser relacionado à cor preta e um de alta intensidade seja relacionado à cor branca. Para que este processo seja aplicado, necessariamente a imagem de origem deve estar em escala de cinza. A Figura 2 mostra o resultado do processo de limiarização.



Figura 2. Fotografia de uma foca após o processo de limiarização. Fonte: Pixabay, 2017.

2.4. Transformações morfológicas

A fim de refinar os dados gerados pela limiarização das imagens processadas, é necessária a aplicação de transformações morfológicas que são responsáveis por operar na limpeza das formas encontradas no processo de limiarização. O processo se fundamenta na comparação entre o valor de cada pixel de uma imagem binária com relação a seus vizinhos e baseado no formato dos objetos a serem analisados, define se um pixel deve ou não existir na imagem pós-processada, o método empregado no programa desenvolvido foi o de erosão.

De acordo com a definição de Fisher et al. (1997), a erosão enquanto operação morfológica busca remover a maior quantidade possível de ruídos existentes nas imagens binárias por meio da comparação entre os pixels vizinhos. Para definir a região dos vizinhos analisada é necessário configurar uma propriedade chamada kernel; responsável por definir o espaço, em pixels, que será percorrido por toda a imagem, utilizada na verificação dos pixels vizinhos no processamento da imagem.

O processo se baseia na verificação do pixel origem e o compara com seus vizinhos, caso possua valores iguais o pixel origem recebe o valor de seus vizinhos, caso contrário, o mesmo é mantido com o mesmo valor de origem. A Figura 3 exemplifica o processo de eliminação de um pixel de ruído em uma imagem binária com utilização de kernel = 1.




Figura 3. Processo de eliminação de pixel de ruído em uma imagem binária. Fonte: elaboração própria.

2.5. Detectores de objetos binários

Após o processo de aplicação dos operadores morfológicos, o resultado é uma imagem binária que possui grupos de objetos binários denominados Blobs (Binary Large Object) e se refere a um grupo de pixels conectados em uma imagem binária. Entretanto, somente

saber que existem grupos de objetos binários em uma imagem não indica quantidades exatas, pois podem existir grupos de forma semelhante, conectados entre si e que poderiam ser considerados um grupo único, caso não sejam aplicados filtros de detecção.

Um exemplo disso, no programa desenvolvido para o presente trabalho, é a possibilidade de os animais estarem encostados lado a lado e que os filtros de processamento de imagem acabam considerando dois animais muito próximos, como um animal apenas. A Figura 4 exemplifica este tipo de problema.



Figura 4. Propriedades de algoritmos de detecção por convexidade e inércia. Imagem original obtida de: Shutterstock (Paulo Vilela), 2017.

3. Trabalhos Correlatos

Existem diversos trabalhos na linha de pesquisa focada no reconhecimento de objetos e sua contagem utilizando algoritmos de visão computacional.

A pesquisa de Gupta and Uttarakhand (2017) serviu de referência para buscar os diferentes tipos de detecção de objetos existentes e, de acordo com a demanda da aplicação, identificar o algoritmo indicado.

A fim de facilitar a leitura, os trabalhos dos autores foram agrupados em seções que mostram as abordagens de aplicação de redes neurais e de segmentação de imagem.

3.1. Abordagens por Redes Neurais

Chamoso et al. (2014) apresenta uma abordagem utilizando redes neurais convolucionais¹ com o objetivo de solucionar problemas de reconhecimento de imagens de diferentes tipos de entrada.

A rede aplicada pelo seu trabalho era baseada em dois estágios de extração de características cujo resultado final consistia em amostras individuais de animais dos quadros de vídeos coletados pelos autores. Os resultados de seu trabalho foram positivos e a contagem de animais presentes nas fotografias e vídeos analisados tiveram grandes taxas de acerto, seus resultados compilados são apresentados na matriz de confusão da Tabela 1 onde do lado esquerdo na vertical temos o valor real identificado e no topo o valor predito pela classificação do modelo.

¹Redes neurais são grupos de neurônios conectados entre si que formam um sistema nervoso, tal como o cérebro humano. As redes neurais artificiais são abstrações do modelo biológico que permitem representar os neurônios como unidades simplistas de computação. Fonte: Guedes (2017).

Tabela 1. Resultados da aplicação de redes neurais. Imagem original obtida de: Chamoso et al. (2014)

Classificação de dados de Treinamento 10.816 Amostras				Classificação de dados de Teste 2.704 Amostras		
Classe	Gado	Fundo	Eficiência	Gado	Fundo	Eficiência
Gado	5.202	206	96.2%	1.241	111	91.8%
Fundo	109	5.299	98.0%	10	1.342	99.3%
Global			97.1 %			95.5%

A pesquisa de Howse (2014) apresenta uma solução mais genérica em que é executado o processamento de vídeo e de reconhecimento de padrões com a utilização de detectores pré-treinados para identificação de humanos e gatos durante a análise de vídeo.

Seu trabalho se baseou na análise de bases de dados de imagens de gatos e de faces humanas para realizar o treinamento dos modelos de reconhecimento para tais características, seu trabalho não apresentava os resultados obtidos.

3.2. Abordagens por Segmentação

A dissertação de mestrado de Balan (2003) propõe a implementação de técnicas de segmentação de imagem para a contagem da população de aves em fotografias aéreas de ninhais.

O método de contagem implementado em seu trabalho foi o de segmentação por textura e os resultados obtidos mostram que o mesmo foi capaz de classificar corretamente a maioria das regiões das imagens correspondentes à classe dos pássaros.

Balan (2003) comenta que as falhas observadas pelo método aplicado eram decorrentes da: ocorrência de dois ou mais pássaros próximos uns aos outros e de regiões onde a textura da vegetação é muito similar à dos pássaros como é o caso de fotografias com superexposição luminosa. Vale ressaltar que tais características também foram identificadas na base de imagens utilizada neste trabalho.

4. Metodologia

Inicialmente foi realizada a coleta de artigos e referências bibliográficas para encontrar na literatura acadêmica as possíveis soluções para a contagem de objetos por meio de imagens estáticas, considerando os trabalhos levantados e já citados anteriormente a dissertação de mestrado de Balan (2003), possuía objetivos em comum como a contagem de população de animais com base nas características extraídas de imagens, em particular uma das soluções apresentadas pelo mesmo em sua dissertação, a qual se baseava nos métodos de detecção de bordas e serviu de referência para buscar as ferramentas que deveriam ser aplicadas para este método.

O método de detecção de bordas descrito por Balan (2003), se baseia na localização de regiões da imagem onde a variação dos tons de cinza ocorrem de maneira abrupta. Estas regiões são determinadas descontinuidades, podendo ocorrer na forma de pontos isolados, linhas, segmentos ou curvas, constituindo assim por meio delas os contornos, formas ou bordas dos objetos contidos na imagem.

Levando em consideração que as imagens utilizadas apresentam características que sugerem fortemente a utilização de métodos de segmentação, tais como: o contraste elevado entre os objetos de análise (animais) e o fundo das imagens (pasto ou lama). O método de detecção de bordas aliado aos métodos de limiarização se mostraram uma solução adequada à aplicação.

Em sequência foi realizada a implementação de um programa na linguagem de programação Python cujo objetivo era identificar os objetos e realizar a posterior contagem. Segue descrito abaixo os passos necessários para realizar a contagem de gado implementada pelo programa desenvolvido:

- Realizar a aplicação do filtro de escala de cinza à imagem a ser analisada;
- Efetuar a aplicação de filtros de suavização para remover ruídos e imperfeições na imagem;
- Aplicar a limiarização para definir os contornos dos objetos a serem detectados;
- Realizar transformações morfológicas para refinar os resultados e evitar problemas comuns ao processamento de imagens;
- Utilizar detectores de objetos binários para efetivamente realizar a contagem dos objetos de estudo na imagem.

Para que tais passos fossem executados, foi necessária a identificação de uma biblioteca que facilitasse a aplicação dos diferentes filtros e transformações necessárias para que o objetivo final fosse atingido. Para tal selecionou-se a biblioteca OpenCV, esta, é uma biblioteca de código aberto, implementada nas linguagens de programação C e C++ para o desenvolvimento de aplicações na área de visão computacional disponibilizando mais de três mil algoritmos para trabalhos cujos objetivos são realizar análises de visão computacional, processamento de imagem e vídeo, estrutura de dados, álgebra linear, interfaces gráficas de usuário, realidade virtual, aumentada e mista.

O próximo passo foi a coleta das imagens aéreas utilizadas para a análise estatística dos resultados obtidos com a aplicação do programa desenvolvido. As mesmas foram adquiridas por meio de pesquisas em bancos públicos de imagens com foco nas imagens aéreas de alta resolução e com seus direitos de uso liberados para reutilização não comercial.

Todas as imagens coletadas para testes estão disponíveis para acesso público na plataforma do Zenodo², as demais fotografias utilizadas em testes estão disponíveis em suas respectivas plataformas indicadas na fonte.

5. Resultados obtidos

A execução do programa, elaborado neste trabalho foi realizada em oito imagens. O resultado é apresentado com marcações vermelhas que apontam os objetos captados. Em um terminal de console é mostrada uma mensagem com a quantidade de objetos detectados na figura processada.

Para fazer os testes do programa foram coletadas imagens aéreas de gado em confinamento e em campo aberto. As imagens coletadas foram selecionadas para que oferecessem uma delimitação bem precisa de seus elementos constitutivos (animais, terreno,

²Todas as imagens coletadas estão disponíveis no repositório de arquivos do Zenodo sob a URL de acesso público mantida por Ribeiro (2019).

características da imagem), a fim de reforçar os elementos básicos para o funcionamento adequado do programa desenvolvido.

Com as imagens coletadas foram realizados testes, aplicando-se diferentes parâmetros de limite de limiarização, diferentes regiões de análise das imagens e valores distintos de convexidade e concavidade para os objetos identificados em cada imagem, todos parametrizados por interface de linha de comando passados como argumento para a execução do programa.

A Tabela 2 contém uma compilação dos resultados e apresenta a quantidade de animais detectados em cada uma das fotografias testadas (na ordem do artigo), a quantidade de animais de cores claras, a quantidade original e a taxa de acerto em porcentagem com base na quantidade de animais claros e a quantidade original de animais. Balan (2003) propõe como critério de qualidade dos resultados, os aspectos de qualidade dos resultados obtidos e critérios de convergência.

O primeiro, diz respeito à capacidade que o método empregado têm, de identificar todas, ou a maioria das regiões ou objetos relevantes na cena. O segundo consiste na análise dos desvios de falsos positivos e negativos e verdadeiros positivos e negativos gerados pelo diferente nível de escala de cinza específico de cada imagem.

Tabela 2. Compilação de resultados das execuções com base nas fotografias testadas. (continua)

Fotografia	Qtd. de detecções	Qtd. de animais claros	Qtd. original de animais	Taxa em relação a brancos	Taxa em relação ao total
1. Gado em campo aberto, distantes uns dos outros e com bom contraste com o fundo. (Figura 5)	19	19	19	100%	100%
2. Gado em campo aberto, distantes uns dos outros e com animais de cores distintas. (Figura 6)	7	7	8	100%	87,5%
3. Gado em campo aberto e com animais próximos uns dos outros e com bom contraste de fundo. (Figura 7)	22	23	23	95,7%	95,7%
4. Gado em ambiente de confinamento e com grande quantidade de animais, animais de cores distintas e de cor semelhante ao terreno. (Figura 8)	49	53	141	92,4%	34,8%

Tabela 2. Compilação de resultados das execuções com base nas fotografias testadas. (conclusão)

Fotografia	Qtd. de detecções	Qtd. de animais claros	Qtd. original de animais	Taxa em relação a brancos	Taxa em relação ao total
5. Gado em campo aberto, com animais próximos uns aos outros e com bom contraste de fundo. (Figura 9)	41	48	48	85,4%	85,4%
6. Gado em campo aberto, animais separados, com bom contraste de fundo e com animais de cores escuras.	3	3	5	100%	60%
7. Gado em campo aberto, com contraste ruim entre animais e fundo e com animais de cores escuras.	10	12	17	83,3%	58,9%
8. Gado em campo aberto, com bom contraste de imagem e com diversos animais próximos uns aos outros.	14	20	21	70%	66,6%

Para os animais brancos, o algoritmo apresenta uma menor taxa de erro. Para os de cor escura, dada a necessidade de aplicar filtros distintos para identificação de cada coloração, há uma dificuldade maior, pois quando existem animais marrons ou malhados no mesmo lote, o processo de limiarização não consegue distinguir os pixels de animais, cujas cores são escuras; o que faz com que sejam considerados como parte do fundo da imagem. Consequentemente não são adicionados à contagem final dos animais.

A Figura 5 apresenta o processamento de uma imagem contendo animais em um pasto com uma boa distância entre eles e um contraste relativamente grande entre objeto e fundo. Nesta imagem o algoritmo conseguiu detectar todos os animais presentes sem apresentar erros.




Figura 5. Resultado do algoritmo em uma imagem com animais brancos. Imagem original obtida de: Shutterstock (Mukola), 2017.

A Figura 6 exemplifica o resultado do algoritmo, nos casos onde existe a presença de animais de cores diversas. Nesta figura existe um animal de cor preta, o qual após a aplicação do filtro de limiarização é considerado como parte do fundo da imagem e consequentemente é descartado na contagem final.




Figura 6. Resultado do algoritmo em uma imagem com animais de múltiplas cores. Imagem original obtida de: Pixabay, 2017.

Nesta execução não foi necessária a aplicação de parâmetros diferentes do padrão e o resultado apesar da eliminação do animal de cor negra foi considerado bom tendo em consideração o verdadeiro negativo de somente um animal, representando uma identificação de 87,5% dos animais presentes na imagem.

A Figura 7 mostra o resultado do algoritmo em casos em que, no momento de retirada da fotografia, os animais se encontravam muito próximos. Nestes casos o processamento do algoritmo necessita de algumas modificações nos filtros de transformação morfológica, mais especificamente na diminuição da região de análise para que os animais que se posicionam próximos uns aos outros sejam identificados na figura processada.




Figura 7. Resultado do algoritmo em imagens com animais muito próximos. Imagem original obtida de: Shutterstock (Paulo Vilela), 2017.

O resultado do algoritmo apresentou uma boa quantidade de identificações perdendo a identificação de somente um animal que estava próximo de outro e que no processo de transformação morfológica acabou se tornando um único objeto.

A Figura 8 apresenta os resultados do algoritmo após a execução em uma fotografia que analisa a existência de 141 animais de diferentes cores em confinamento. Nela existe uma grande variação de coloração dos animais (pretos, brancos, marrons e malhados).




Figura 8. Resultado da execução do programa em uma imagem com animais de múltiplas cores, próximos uns dos outros e em terreno de cor similar à cor de alguns animais. Imagem original obtida de: Lucy Nicholson/Reuters, 2015.

Nela existe uma grande variação de coloração dos animais (pretos, brancos, marrons e malhados). Assim foi necessária a mudança dos parâmetros padrões do programa sendo modificados os limites de limiarização superior e inferior, o tamanho da região de análise e os valores de convexidade e concavidade.

O resultado não foi satisfatório, dado que, na fotografia original existiam 141 animais em confinamento, dos quais 53 possuíam colorações mais claras.

Com a execução do programa, ao analisarmos apenas os animais de cor clara, foi possível detectar uma quantidade de 49 animais dentre os 53, o que equivale a 92,4%, porém se considerados o total de animais, o resultado fica bastante prejudicado sendo rebaixado a 34,8% de animais detectados.

A Figura 9 apresenta os resultados do estudo em uma fotografia de animais em campo aberto, estando muito próximos uns dos outros e sendo em maioria de coloração branca.




Figura 9. Resultado da execução do programa em uma imagem com animais de múltiplas cores, próximos uns dos outros e em terreno de cor similar à cor de alguns animais. Imagem original obtida de: Atlantide Phototravel/Corbis, 2014.

O resultado da execução foi satisfatório tendo uma taxa de acerto de 85,4%. O problema encontrado neste exemplo é a baixa resolução da imagem que prejudicou os resultados finais.

A existência de bezerros que possuem tamanho inferior ao de um animal adulto também causou distorções; resultou que fossem considerados como parte do fundo por não possuírem um tamanho relevante para serem considerados após a aplicação dos filtros morfológicos padrões. Alguns deles, além de serem bezerros, possuíam coloração semelhante à do terreno e, portanto, foram desconsiderados na contagem final.

O resultado da taxa de acerto considerada na Tabela 2 é com base na quantidade de detecções pela quantidade de animais originais na fotografia, este valor é convertido diretamente a uma porcentagem que resulta na última coluna da tabela. A quantidade de animais claros serve apenas de referência para um segundo índice que possa ser considerado no aproveitamento do programa com relação a detecção exclusivamente de animais de cores claras.

É possível observar pelos resultados compilados na Tabela 2 que o algoritmo possui uma boa taxa de acerto na maior parte dos casos, sendo afetado somente quando existem animais de cores distintas da branca na fotografia. Como os filtros escolhidos utilizam por base a cor branca, os animais de cores escuras tais como os malhados, marrons e pretos acabam sendo desconsiderados na contagem.

O resultado de significância menor, 34,8% de taxa de acerto, ocorreu numa fotografia em que os animais se encontravam em um ambiente de confinamento e por conta do terreno possuir cor similar à de alguns dos animais, por isso a taxa de acerto foi baixa. Entretanto, quando o resultado é feito em comparação a quantidade de animais de cores claras na mesma fotografia, a taxa de acerto sobe para 92,4%.

6. Conclusões e trabalhos futuros

Com os resultados obtidos pelo programa desenvolvido, foi possível identificar, implementar e comparar os diferentes algoritmos de visão computacional aplicados na detecção de objetos presentes em fotografias e vídeos.

O algoritmo implementado neste trabalho se demonstrou eficaz para a identificação de animais de coloração predominantemente branca, este fato reflete o cenário de agropecuária do Brasil, pois, segundo de Oliveira (2018), 80% do rebanho brasileiro é composto por bovinos da raça nelore, os quais apresentam pelagem branca ou cinza-clara. Entretanto, existem restrições com relação às cores dos animais que podem ser eliminadas da contagem quando os filtros aplicados são direcionados a uma determinada característica.

A diferença entre o método implementado neste trabalho para a pesquisa de Balan (2003) se trata do tipo de algoritmo utilizado. Na pesquisa de Balan é feita a utilização do método de segmentação por textura, na qual a imagem analisada é particionada e para cada fração da imagem é identificadas texturas similares a uma referência de busca.

Foi observado também que as limitações do programa são decorrentes de três características inerentes às imagens coletadas:

- Primeiramente, quando existem animais de cores escuras os filtros aplicados pelo

algoritmo acabam por considerar estes como parte do fundo da imagem e logo após a segmentação são desconsiderados da contagem final;

- Segundo problema recorrente é quando existem animais muito próximos uns dos outros e de diferentes tamanhos, desta maneira a segmentação não consegue distinguir ambos e os considera um animal somente.
- Por fim, o terceiro fator negativo encontrado, foi a semelhança de características dos animais de cor marrom com a cor do chão (composto principalmente de terra) em ambientes de confinamento.

Uma maneira de mitigar os erros apresentados no algoritmo seria a utilização de fotografias registradas com câmeras térmicas. Neste tipo de imagem, os animais que apresentam temperatura superior à da superfície terrestre tomam forma melhor em suas silhuetas, assim com a aplicação de filtros de segmentação adequados, o resultado do algoritmo poderia ser melhorado consideravelmente.

A Figura 10 mostra animais num campo, por meio de uma fotografia térmica.




Figura 10. Fotografia térmica de animais de gado em pasto aberto. Fonte: Jeremiah Karpowicz, 2017.

Outra forma de refinar ainda mais os resultados, seria a utilização de vídeos para a análise, neste caso é possível fazer comparações entre os quadros do vídeo, resultando em análises de maior fidelidade ao propósito de contagem dos animais de uma fazenda.

Uma futura melhoria a ser trabalhada para o aperfeiçoamento e automatização de parametrizações, seria a aplicação de algoritmos de inteligência artificial e aprendizagem de máquina, estes seriam aplicados para identificar os melhores parâmetros a serem considerados para cada tipo de imagem, dadas as características dos animais.

Nesta hipótese, os animais de cores escuras (marrom, preto e malhado) poderiam ser mais facilmente detectados e isso, conseqüentemente, poderia ampliar sobremaneira a quantidade de animais das mais variadas características durante o processo de contagem, ampliando assim ainda mais os resultados apurados, justificando-se portanto, a aplicação do algoritmo de visão computacional na contagem de animais por meio de processamento de imagens, conforme detalhados no presente artigo.

Referências

- Balan, A. G. R. (2003), Técnicas de segmentação de imagens aéreas para contagem de população de aves, text, Universidade de São Paulo.
- Barros, A. M. S., Tavares, A. R., Cavalcanti, A. A. P., Pereira, A. R., Krepsky, C. U. and Sobral, C. C. B. (2018), 'CONTAS NACIONAIS TRIMESTRAIS', p. 36.

- Chamoso, P., Raveane, W., Parra, V. and Arrieta, M. A. G. (2014), UAVs Applied to the Counting and Monitoring of Animals, in 'ISAmI'.
- de Carvalho, T. B. (2018), A importância do Brasil na produção mundial de carne bovina, Technical report, CEPEA ESALQ USP.
- de Oliveira, M. (2018), 'Contribuições dos bovinos brasileiros'.
- Fisher, R. B., Perkins, S., Walker, A. and Wolfart, E. (1997), *Hypermedia Image Processing Reference*, Wiley, West Sussex, England.
- Guedes, A. B. S. (2017), 'Reconhecimento de Gestos usando Redes Neurais Convolucionadas', p. 49.
- Gupta, B. and Uttarakhand, P. G. (2017), Study on Object Detection using Open CV - Python.
- Howse, J. (2014), Training detectors and recognizers in Python and OpenCV, in '2014 IEEE International Symposium on Mixed and Augmented Reality (ISMAR)', pp. 1–2.
- ITU (2017), 'Studio encoding parameters of digital television for standard 4:3 and wide-screen 16:9 aspect ratios', p. 20.
- Jesus, E. O. and Jr, R. C. (2015), 'A utilização de filtros gaussianos na análise de imagens digitais', *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics* 3(1).
- Klette, R. (2014), *Concise Computer Vision: An Introduction into Theory and Algorithms*, Undergraduate Topics in Computer Science, Springer-Verlag, London.
- Poynton, C. (2012), *Digital Video and HD: Algorithms and Interfaces*, 2 edition edn, Morgan Kaufmann, Waltham, MA.
- Ribeiro, N. (2019), 'Fotografias aéreas usadas para teste de algoritmo de visão computacional'.
- URL:** <https://doi.org/10.5281/zenodo.2636971>