

Desenvolvimento de ferramenta não invasiva para cálculo de densidade de aves em aviários comerciais

RESUMO

Thiago Algerithiagualgeri@gmail.com

Universidade Tecnológica Federal do Paraná, Medianeira, Paraná, Brasil

Tania Aparecida Becker-Algeritaniabecker86@yahoo.com.br

Universidade Tecnológica Federal do Paraná, Medianeira, Paraná, Brasil

Paulo G. de Abreupaulo.g.abreu@embrapa.br

Empresa Brasileira de Pesquisa Agropecuária Suínos e Aves, Concórdia, Santa Catarina, Brasil

Pedro de Paula Filhoplpf2004@gmail.com

Universidade Tecnológica Federal do Paraná, Medianeira, Paraná, Brasil

A produção de frango no Brasil tanto para consumo interno quanto para exportação tem se destacado no cenário mundial, em um momento em que a preocupação com o bem-estar animal é crescente. O estudo do comportamento animal tem um papel importante na produção, principalmente para o desenvolvimento de sistemas de produção que possuam padrões mínimos de bem-estar. A observação visual do comportamento consome tempo, é subjetiva e suscetível a erro. Desta forma este trabalho tem como objetivo a utilização de câmeras e técnicas de processamento de imagens para avaliar o comportamento expresso por frangos de corte no sistema produtivo. As imagens foram adquiridas de um aviário da região Oeste do Paraná entre dezembro de 2016 e fevereiro 2107, utilizando uma câmera de infravermelho. Foram alojadas 34.417 aves da linhagem Cobb, no final do processo produtivo foram recolhidas 33.208 aves com peso total de 92.680 kg, gerando uma média de 2,7 kg por ave. O trabalho foi desenvolvido baseando-se na quantidade de quilos de aves por m^{-2} , onde a legislação brasileira indica um valor máximo de 42 kg m^{-2} , no melhor cenário. Para esta avaliação foram utilizados os classificadores Haar-like e Local Binary Pattern (LBP) que tiveram seus resultados comparados. Os classificadores analisaram 1.920 imagens, neste processo foram identificadas quantas aves estavam dentro de um quadro de um m^{-2} , o classificador LBP demonstrou ser o mais rápido e ambos os classificadores atingiram taxa de erro médio de 17,7%. Através da abordagem proposta pode-se concluir que foi possível gerar informações para subsidiar a avaliação da densidade de aves por m^{-2} .

PALAVRAS-CHAVE: Bem-estar animal. Haar-like. Local binary pattern.

INTRODUÇÃO

A produção de frangos no Brasil vem apresentando um crescimento considerável nos últimos anos, em 2006 a produção era de 9,36 milhões de toneladas e em 2017 foi de 13,05 milhões de toneladas, um crescimento de 28%, sendo necessária uma série de medidas a fim de garantir sua qualidade, destacando-se melhoria da nutrição, genética, bem-estar, entre outros. A União Europeia um dos destinos das exportações brasileiras (15% do total), possui diretivas relacionadas com o bem-estar animal. O Ministério da Agricultura, Pecuária e Abastecimento, estabelece via Instruções Normativas 56/2008 e 59/2012 padrões e recomendações de boas práticas para o bem-estar animal (MOGAMI, 2009; DAMASCENO et al., 2010, MIELE; LEVER, 2013; ABPA, 2018).

Diante do exposto, o estudo do comportamento animal assume papel importante na produção avícola, uma vez que para racionalizar os métodos de criação desenvolveram-se técnicas de manejo, alimentação e instalações que interferem e também dependem do comportamento. Assim, o estudo do comportamento social e individual dos animais em seu habitat natural pode sinalizar para a racionalização da criação animal, principalmente em sistemas intensivos de produção (FEDERICI et al., 2016; SOUZA; MOLENTO, 2015).

De acordo com o Farm Animal Welfare Advisory Council (2011), o bem-estar animal está baseado em cinco liberdades: Livre de fome, sede e má nutrição; Livre de desconforto; Livre de dor, ferimentos e doenças; Liberdade para expressar padrão comportamental natural; e Livre de medo e estresse. Esses aspectos devem ser considerados como uma demanda para qualquer sistema de criação que deseja ser eticamente defensável e socialmente aceitável, pois o mercado deseja produtos com qualidade ética, ou seja, animais que tenham sido criados, tratados e abatidos em sistemas que promovam o bem-estar, sustentáveis e ambientalmente corretos (CURY; SANTOS, 2009).

A certificação Global G.A.P. (Good Agricultural Practice), a European Food Safety Authority (EFSA) e a legislação brasileira orientam sobre o bem-estar na produção de frangos de corte, especificamente em relação à densidade de alojamento e a capacidade de movimentação. Quanto a densidade de alojamento a EFSA e a Global G.A.P. sugerem não ultrapassar 40 kg m⁻², já a legislação nacional permite até 42 kg m⁻², no melhor cenário (MAPA, 2008; BONAMIGO et al., 2010; SOUZA; MOLENTO, 2015).

O comportamento animal, em geral, é avaliado através da observação visual, o que consome muito tempo, é subjetivo e muito susceptível a erro. A automação desse processo, por meio de câmeras de vídeo e programas de interpretação de imagens torna possível uma melhor avaliação do comportamento dos animais, sem necessidade de estar perto deles ou influenciar no comportamento e anulando a subjetividade do observador humano (MOGAMI, 2009; USHER et al. 2014; ALGERI et al., 2016).

Neste contexto, o objetivo deste trabalho foi desenvolver um sistema, utilizando técnicas de processamento digital de imagens, capaz de medir a densidade de aves por metro quadrado dentro do aviário de produção, também foram comparados os resultados de dois classificadores com duas variações cada.

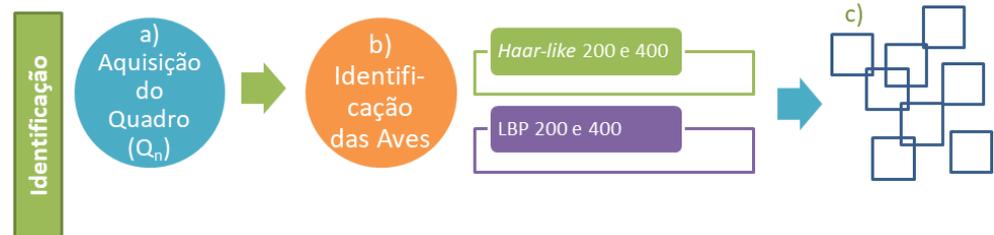
MATERIAL E MÉTODOS

O modelo de galpão selecionado foi do tipo “dark house”, que se caracteriza por possuir ambiente totalmente controlado (temperatura, ventilação e iluminação). Este está localizado na linha São Braz, município de Medianeira estado do Paraná.

O aviário possuía 2,20 metros de altura, 16 metros de largura e 150 metros de comprimento, com área disponível de 2.400m m⁻² e cama de maravalha, reutilizada por 8 lotes de frangos. O aviário também possuía dez exaustores, nebulização interna, iluminação, sistema de aquecimento a lenha e gerador de 170 cavalos de potência (utilizado em emergências). A aquisição das imagens foi realizada no verão de 2017 entre os dias 30/12/2016 e 14/02/2017. Para a gravação das imagens foi utilizada câmera digital tipo dome (modelo IR Fixed DS-2CD2110F-IWS, Hikvision, China), com recursos de WIFI, suporte a cartão micro SD de até 128 gigabytes, infravermelho 10 a 30 metros, com qualidade de 1.3 megapixel e com resolução máxima de 1280 x 960 pixels. A câmera não emitia luz ou sinal sonoro. O posicionamento da câmera seguiu o proposto por María et al. (2004), Mogami (2009), Fujii et al. (2009) e Algeri et al. (2016), utilizando para tanto, direcionada de cima para baixo em ângulo reto. A câmera foi posicionada dentro do aviário, na altura de 2,10 m de distância das aves, a 75 m da entrada e no centro do aviário. Para a gravação foram utilizadas as seguintes configurações: gravação em infravermelho, 10 frames por segundo, definição da imagem 704 x 576 pixels e armazenamento em cartão SD de 128 gigabytes.

Foram alojadas 34.417 aves da linhagem COBB (30/12/2016), correspondendo inicialmente a 14,34 aves m⁻². Durante o processo de engorda (45 dias) foram coletados manualmente a quantidade de água e ração consumidos, bem como o número de aves mortas. No final do confinamento, 33.208 aves foram recolhidas, pesadas (92.680 kg) e acomodadas em caminhões e encaminhadas à indústria.

Figura 1 – Fluxo utilizado para a identificação e contagem das aves



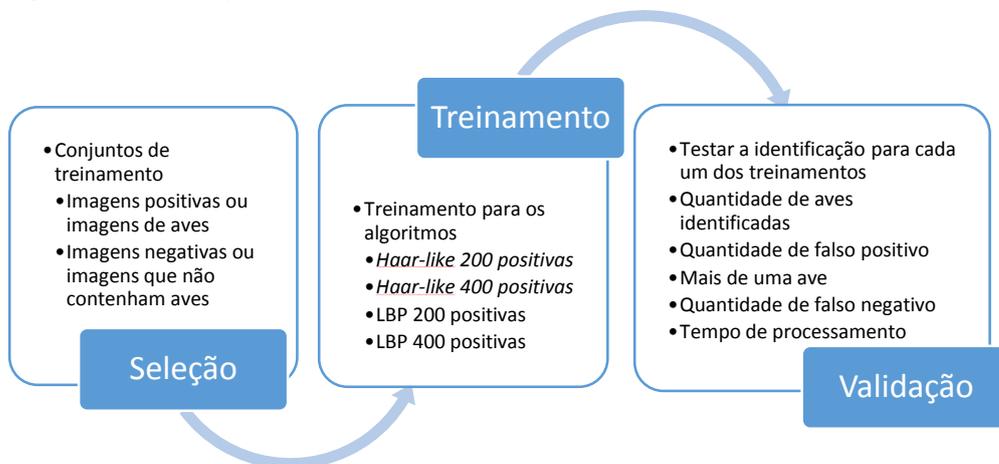
Fonte: Autoria própria

Para o processo de identificação das aves, inicialmente após a aquisição do primeiro quadro da imagem um dos algoritmos de classificação é aplicado, gerando a quantidade de aves encontrada.

A localização das aves nas imagens foi realizada utilizando-se dois algoritmos distintos: *Haar-like* (VIOLA; JONES, 2001) e LBP (OJALA et al., 1994; CRUZ et al. 2015).

Um esquema representativo do método proposto para a etapa de identificação das aves está descrito na Figura 2, separado em três etapas: seleção, treinamento e validação.

Figura 2 – Processo para selecionar, treinar e validar os classificadores.



Fonte: Autoria própria

Para o processo de seleção foi necessário criar dois conjuntos de treinamento, sendo um conjunto com imagens positivas, ou seja, que continham a aves, e outro conjunto com imagens negativas, que não continham aves.

Para a aquisição das imagens positivas e negativas foi desenvolvida uma aplicação, na qual os vídeos eram exibidos e pausados para que as aves e as não aves fossem selecionadas. Após a seleção, as imagens foram salvas em arquivos e pastas separadas. Por meio da seleção manual das amostras positivas e negativas foi possível construir um banco com 476 amostras positivas e 300 amostras negativas.

A criação do arquivo indexado das imagens positivas foi realizada por meio do programa “opencv_createsamples.exe”. Este recebe como parâmetro a lista de imagens positivas, o número de amostras a dimensão que as imagens devem ser geradas (20 x 20 pixels) e por fim este processo gera o arquivo indexado “VEC”.

Os treinamentos foram executados para ambos os classificadores, utilizando 200 e 400 imagens positivas e 290 imagens negativas, sendo que, a dimensão das imagens foi de 20 x 20 pixels, a taxa de falso alarme de 0,05 e a taxa de acerto mínimo de 0,995.

O treinamento dos classificadores foi executado observando o *overfitting* e desta forma, foram testados vários estágios. Os estágios que demonstraram melhores resultados foram utilizados, para o classificador *Haar* com os seguintes parâmetros: número de 13 estágios e modo ALL que indica o uso do conjunto completo de características *Haar*. Para o treinamento do classificador LBP foram utilizados 21 estágios. A escolha destes parâmetros foi definida via acompanhamento. Dessa forma, foram utilizadas taxas de aceitação, configuradas para no mínimo 10^{-4} , a fim de evitar que o modelo seja treinado excessivamente.

Para o processo de validação foram selecionadas quatro imagens por semana, gerando um total de 24 imagens e para estas imagens foram aplicadas as quatro variações dos classificadores (*haar-like 200*, *haar-like 400*, LBP 200 e LBP 400).

A avaliação dos classificadores foi realizada visualmente e os itens avaliados foram os seguintes: quantidade de aves identificadas; quantidade de falso positivo;

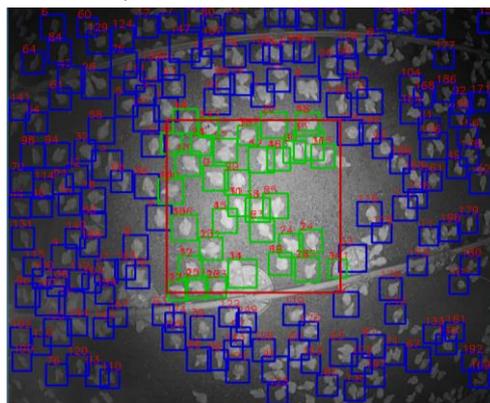
mais de uma ave selecionada no mesmo quadro; quantidade de falso negativo e tempo de processamento.

Para identificar o número de aves por metro quadrado, foram avaliados, de maneira aleatória, quatro vídeos por semana. Destes vídeos, foram avaliados 20 quadros, em intervalos de 1.000 quadros, gerando um total de 1.920 avaliações.

Para as avaliações das informações, os resultados das imagens foram comparados com as normas vigentes para o mercado interno e externo do setor avícola, a *European Food Safety Authority* – EFSA, Global G.A.P (*Good Agricultural Practice*) e a legislação brasileira vigente, que tem como base as boas práticas de produção aplicadas na cadeia avícola, levando em consideração, entre outros fatores, o bem-estar das aves (SOUZA; MOLENTO, 2015).

O critério observado nas filmagens foi a densidade de alojamento (kg m^{-2}). Para avaliação da quantidade de quilogramas de aves por metro quadrado, foi delimitada uma área no centro da imagem (Figura 3) e calculada a quantidade de aves existentes. Estas quantidades foram relacionadas com as medições de pesos, as quais foram adquiridas do borderô de acompanhamento do lote de produção.

Figura 3 – Delimitação de um m^2 para cálculo de densidade



Fonte: Autoria própria

Para o processo de contagem também foi necessário observar a evolução do tamanho das aves e devido a isto, foi necessário reajustar o tamanho do quadro de marcação, semana a semana. O algoritmo ignorava indicações de aves onde o quadro não estava entre o mínimo e máximo.

RESULTADOS E DISCUSSÃO

O processo de gravação foi iniciado em 30/12/2016 e finalizado em 14/02/2017 o qual gerou 2.412 vídeos de 256MB cada, num total de 600GB equivalente a aproximadamente 1.228 horas de gravação.

Os classificadores *Haar-like* e LBP foram treinados em cascata e ambos foram testados no quadro de número 3.000 de cada um dos vídeos gerados, totalizando 2.412 imagens. O teste também gerou uma tabela com os tempos de processamento e a quantidade de aves encontrada em cada imagem para cada um dos classificadores.

Para avaliação dos classificadores foram obtidas cinco informações: a primeira é a quantidade de falsos positivos, que indica que não existe ave na posição indicada pelo classificador; a segunda se refere a existir mais de uma ave na posição indicada pelo classificador; a terceira é referente à quantidade de falsos negativos; a quarta é o percentual de erros em relação a quantidade de aves identificadas, e a quinta e última é o tempo de processamento para identificar as aves. A relação destas informações está apresentada na Tabela 1.

Tabela 1 – Resumo dos resultados obtidos

Atributos	<i>Haar-like</i> 200	<i>Haar-like</i> 400	LBP 200	LBP 400
Falso positivo (un)	1,50 ^{ab} (0,31)	3,42 ^b (0,71)	1,17 ^a (0,32)	2,75 ^{ab} (0,68)
Mais de uma ave (un)	7,50 ^a (2,03)	7,33 ^a (1,76)	6,83 ^a (2,07)	9,33 ^a (2,67)
Falso negativo (un)	22,75 ^a (4,22)	13,75 ^a (2,05)	26,25 ^a (5,29)	14,67 ^a (1,96)
% Erro	19,12% ^a (0,03)	13,34% ^a (0,01)	23,05% ^a (0,04)	15,60% ^a (0,02)
Tempo (s)	0,60 ^b (0,08)	0,58 ^b (0,05)	0,31 ^a (0,02)	0,49 ^{ab} (0,03)

Notas:

(1) Para um mesmo parâmetro, médias com letras iguais na linha indicam que não há diferença significativa entre as médias pelo teste de Tukey ($\alpha < 0,05$).

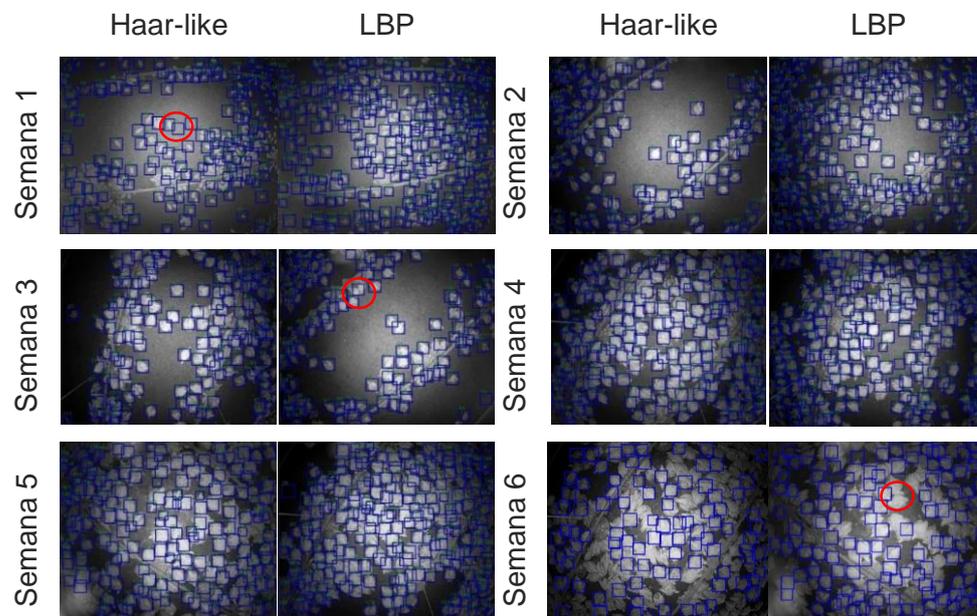
(2) Valores entre parênteses representam o erro padrão.

Entre os classificadores testados os que apresentaram melhor performance em relação ao tempo de execução foram o LBP 200 e o LBP 400 com média de tempo de 0,31 s e 0,49 s respectivamente, seguidos pelos classificadores *Haar-like* 200 com 0,60 s e *Haar-like* 400 com 0,58 s, ambos não diferem estatisticamente pelo teste de Tukey ($\alpha > 0,05$). O teste de falso positivo apontou as menores médias para os classificadores LBP 200, *Haar-like* 200 e LBP 400, e a maior média obtida foi a dos classificadores LBP 400, *Haar-like* 200 e *Haar-like* 400. Referente aos atributos ‘mais de uma ave’, ‘falso negativo’ e ‘percentual de erro’, não houve diferença significativa entre as médias dos classificadores.

A Figura 4 exhibe as classificações geradas pelo classificador *Haar-like* em cascata, e o LBP, algumas imagens foram selecionadas como exemplo, e estão divididas por semana. Também é possível observar na semana 1 exemplo de falso positivo, onde o classificador indica a existência de uma ave porém não há. Outro

item que pode ser observado na semana 3 é mais de uma ave na marcação do classificador. Por fim é possível observar na semana 6 o falso negativo, onde o classificador não marcou uma ave existente.

Figura 4 – Classificações geradas pelos classificadores *Haar-like* e LBP para todas as semanas



Fonte: Autoria própria

Os classificadores *Haar-like* obtiveram os mesmos resultados. Já os classificadores LBP apresentaram diferenças em todas as semanas. O classificador que obteve as menores contagens foi o LBP 200. Também foi possível observar a queda da densidade de aves por metro quadrado na terceira semana. Isto foi devido à retirada das contenções do pinteiro, ou seja, a área total do aviário foi liberada. Estas contenções são utilizadas durante as primeiras semanas para que as aves não fiquem muito dispersas (Tabela 2).

Tabela 2 – Evolução da quantidade de aves e peso por m² durante as seis semanas por classificador

Sem	Peso por ave	Haar-like 200		Haar-like 400		LBP 200		LBP 400		Média	
		Qtd	Peso	Qtd	Peso	Qtd	Peso	Qtd	Peso	Qtd	Peso
1	0,170	34,76	5,91	38,08	6,47	29,73	5,05	32,93	5,60	33,88	5,75
		4,77--7,04		5,61--7,34		3,88--6,22		4,72--6,47		4,73--6,78	
2	0,462	19,85	9,17	20,51	9,48	15,75	7,28	18,00	8,32	18,52	8,55
		7,41--10,92		8,21--10,74		5,59--8,95		7,01--9,61		7,03--10,07	
3	0,913	11,46	10,46	11,92	10,88	10,17	9,29	11,03	10,07	11,15	10,17
		8,46--12,46		9,43--12,33		7,14--11,43		8,49--11,64		8,37--11,98	
4	1,450	20,51	29,74	22,03	31,94	18,61	26,98	20,05	29,07	20,30	29,43
		24,05--35,43		27,68--36,20		20,76--33,20		24,53--33,61		24,2--34,66	
5	2,128	19,41	*41,30	21,28	*45,28	18,33	39,01	19,68	*41,88	19,68	*41,87
		33,40--49,20		39,24--51,32		30,01--48,00		35,34--48,41		34,43--49,32	
6	2,766	14,80	*40,94	17,01	*47,05	12,53	34,66	13,82	38,23	14,54	*40,21
		33,10--48,76		40,77--53,33		26,66--42,65		32,26--44,19		33,06--47,36	

Notas:

(1) * valores acima da legislação brasileira. A contagem das aves foi realizada apenas por uma câmera não representando a extensão do aviário. Desta forma, os valores acima da legislação não representam todo o aviário.

(2) a coluna Qtd, refere-se à quantidade de aves encontradas por metro quadrado; a coluna peso é a multiplicação do peso por ave por semana pela quantidade de aves por metro quadrado; e os valores abaixo dos campos quantidade e peso indicam o intervalo considerando o % de erro do algoritmo (Tabela 1).

Observando a Tabela 2, pode-se acompanhar o crescimento das aves e a quantidade de aves por metro quadrado identificadas pelos classificadores, bem como a faixa de erro de classificação para o peso, desta forma podemos observar que os classificadores *Haar-like* 200, *Haar-like* 400 e LBP 400 na quinta semana encontraram densidade acima da legislação, já para a sexta semana apenas as variações do classificador *Haar-like* encontraram densidade acima da legislação.

Tendo em vista que a área do galpão é de 2.400 m² e que foram alojadas 34.417 aves, tem se aproximadamente 14,34 aves por m². Ao final do processo foram entregues 33.208 aves perfazendo o total de 92.680 kg, ou seja, aproximadamente 38,6 kg m², dentro do que rege e recomenda a legislação nacional e internacional. Porém, segundo a Tabela 2 observam-se valores superiores a este. Por observação nem toda a área do aviário fica ocupada, havendo uma grande concentração na área central do aviário, local onde a câmera está posicionada. Ainda é possível observar que a quantidade média de aves da última semana (14,54) é muito próxima da quantidade de aves entregues por m² no final do processo (14,34).

CONCLUSÕES

Os classificadores (*Haar-like* e LBP) mostraram-se eficientes para aplicação de contagem de aves no aviário. Ambos geraram informações práticas para o cálculo de densidade, com erro médio entre 13% e 23%. O classificador LBP demonstrou ser o com melhor performance.

Pode-se observar que, no ambiente onde está posicionada a câmera, a média geral de densidade dos classificadores a partir da quinta semana foi pouco acima da legislação ($40,0 \text{ kg m}^{-2}$). Para a quinta semana o valor foi $41,87 \text{ kg m}^{-2}$ e para a sexta semana $40,21 \text{ kg m}^{-2}$. Entretanto, vale ressaltar que na média geral do galpão atende a mesma ($38,6 \text{ kg m}^{-2}$).

Através da abordagem proposta pode-se concluir que é possível gerar informações para cálculo de densidade de alojamento de aves em aviários por meio de técnicas de processamento de imagem.

Development of a non-invasive tool for calculating bird density in commercial aviaries

ABSTRACT

Chicken production in Brazil, both for domestic consumption and for export, has stood out on the world stage, at a time when the concern for animal welfare is growing. The study of animal behavior has an important role in production, especially for the development of production systems that have minimum standards of well-being. Visual observation of behavior is time-consuming, subjective, and susceptible to error. In this way, the objective of this work is the use of cameras and image processing techniques to evaluate the behavior expressed by broilers in the production system. The images were acquired from an aviary from the western region of Paraná between December 2016 and February 2107, using an infrared camera. A total of 34,417 birds of the Cobb line were housed. At the end of the production process, 33,208 birds with a total weight of 92,680 kg were collected, generating an average of 2.7 kg per bird. The work was developed based on the number of kilograms of birds per m^2 , where Brazilian legislation indicates a maximum value of 42 kg m^2 , in the best scenario. For this evaluation the Haar-like and Local Binary Pattern (LBP) classifiers were used, which had their results compared. The classifiers analyzed 1,920 images, in this process we identified how many birds were within a frame of an m^2 , the LBP classifier proved to be the fastest and both classifiers achieved an average error rate of 17.7%. Through the proposed approach it can be concluded that it was possible to generate information to support the evaluation of the density of birds by m^2 .

KEYWORDS: Animal welfare. Haar-like. Local binary pattern.

REFERÊNCIAS

ABPA – Associação Brasileira de Proteína Animal. Relatório Anual 2018 (2018). Disponível em: <<http://abpa-br.com.br/storage/files/relatorio-anual-2018.pdf>>. Acesso em: 03 abril 2019.

ALGERI, T.; ABREU, P.G.; PAULA FILHO, P.L. Dinâmica espacial de frangos em granjas usando técnicas de processamento de imagens. WVC - XII Workshop de Visão Computacional. 2016.

BONAMIGO, A.; SANS, E.C. de O.; SILVA, C.B. dos S.; MACHADO, M.F.; MOLENTO, C.F.M.; Grau de bem-estar de frangos em diferentes densidades de lotação. 47a Reunião Anual da Sociedade Brasileira de Zootecnia, 2010.

CRUZ, C.J.E.; SHIGUEMORI, E.H.; GUIMARÃES, F.L.N. A comparison of Haar-like, LBP and HOG approaches to concrete and asphalt runway detection in high resolution imagery. *Journal of Computational Interdisciplinary Sciences*, 61(6):121–1363. 2015.

CURY, N.F.; SANTOS, H.F.; Dos. Metodologia de estudo do comportamento animal com uso de Câmeras de monitoramento domiciliar: Análise preliminar de caso em Ribeirão Preto - SP. Congresso de Ecologia do Brasil, São Lourenço. 2009.

DAMASCENO F.A.; YANAGI JUNIOR, T.; LIMA, R.R. de; GOMES, R.C.C.; MORAES, S.R.P. de; Evaluation of poultry well-being in two commercial climatized poultry houses. *Ciência e Agrotecnologia*, 34(4):1031–1038. 2010.

FAWAC, Code of Practice for the Welfare of Laying Hens, 2011. Disponível em: <http://www.fawac.ie/media/fawac/content/publications/animalwelfare/3828_Hen_Welfare_LR.pdf>

FEDERICI, J.F.; VANDERHASSELT, R.; SANS, E.C.O.; TUYTTENS, F.A.M.; SOUZA, A.P.O.; MOLENTO, C.F.M.; Assessment of broiler chicken welfare in Southern Brazil. *Brazilian Journal of Poultry Science*, 18(1):133–140. 2016.

FUJII, T.; YOKOI, H.; TADA, T.; SUZUKI, K.; TASUKAMOTO, K.; Poultry Tracking System with Camera Using Particle Filters. International Conference on Robotics and Biomimetics. Bangkok, Thailand. 1888–1893. 2009. Disponível em: <<https://doi.org/10.1109/ROBIO.2009.4913289>>. Acessado em 20 janeiro 2018.

MAPA (Ministério da Agricultura, Pecuária e Abastecimento). Instrução normativa mapa no 56, de 6 de novembro de 2008. Estabelece os procedimentos gerais de Recomendações de Boas Práticas de Bem - Estar para Animais de Produção e de Interesse Econômico. Brasil, 2008.

MARÍA, G.A.; ESCÓS, J.; ALADOS, C.L.; Complexity of behavioural sequences and their relation to stress conditions in chickens (*Gallus gallus domesticus*): a non-invasive technique to evaluate animal welfare, *Applied Animal Behaviour Science* 86:93–104. 2004.

MIELE, M.; LEVER, J.; Civilizing the market for welfare friendly products in Europe? The techno-ethics of the Welfare Quality® assessment, *Geoforum*, 48:63–72. 2013.

MOGAMI, C.A.; Desenvolvimento de Metodologias Para Determinação do Bem-estar e Massa Corporal de Frangos de Corte Por Meio de Análise Digital de Imagens. PhD Thesis, Universidade Federal de Viçosa. 2009. Disponível em: <<http://www.locus.ufv.br/handle/123456789/656>>. Acessado em: 15 março 2017.

OJALA, T.; PIETIKAINEN, M.; HARWOOD, D.. Performance evaluation of texture measures with classification based on kullback discrimination of distributions, *International Conference on Pattern Recognition*, 1:582-585. 1994.

SOUZA, A.P.O.; MOLENTO, C.F.M.; Good agricultural practices in broiler chicken production in the state of Paraná: focus on animal welfare. *Ciência Rural*. 2015. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-84782015001202239>. Acessado em: 15 fevereiro 2017.

USHER, C.T.; DALEY, W.; WEBSTER, B.; RITZ, C.; Signal Processing for Animal Behavior Detection. *GlobalSIP 2014: Signal Processing Applications Related to Animal Environments*. 1145–1149. 2014.

VIOLA, P.; JONES, M.; Rapid object detection using a boosted cascade of simple features. *CVPR 2001 – IEEE Conference on Computer Vision and Pattern Recognition*. 2001. Disponível em: <<https://www.cs.cmu.edu/~efros/courses/LBMV07/Papers/viola-cvpr-01.pdf>>. Acessado em: 01 janeiro 2017.

Recebido: 01 out. 2018.

Aprovado: 31 dez. 2018.

DOI: <http://dx.doi.org/10.3895/rcaa.v1n2.9396>.

Como citar:

ALGERI, T.; BECKER-ALGERI, T.A.; ABREU, P. G.; PAULA FILHO, P. Desenvolvimento de ferramenta não invasiva para cálculo de densidade de aves em aviários comerciais. **Revista de Computação Aplicada ao Agronegócio**, Medianeira, v. 1, n. 2, p. 1-12, ago./dez. 2018. Disponível em: <<https://periodicos.utfpr.edu.br/rcaa/article/view/9396>>. Acesso em: Dezembro 2018.

Correspondência:

Thiago Algeri

Rua Amapá, 2441, CEP 85884-000, Bairro Nazaré, Medianeira, Paraná, Brasil.

Direito autoral:

Este artigo está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.

