

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
CÂMPUS MEDIANEIRA

THIAGO ALGERI

**DESENVOLVIMENTO DE FERRAMENTA NÃO INVASIVA PARA DAR
SUBSÍDIOS NA AVALIAÇÃO DO BEM-ESTAR ANIMAL EM
AVIÁRIOS**

DISSERTAÇÃO

MEDIANEIRA
2017

THIAGO ALGERI

**DESENVOLVIMENTO DE FERRAMENTA NÃO INVASIVA PARA DAR
SUBSÍDIOS NA AVALIAÇÃO DO BEM-ESTAR ANIMAL EM
AVIÁRIOS**

Dissertação de mestrado apresentado ao programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio – PPGTCA da Universidade Tecnológica Federal do Paraná – UTFPR – Campus Medianeira, como requisito parcial para a obtenção do título de “Mestre em Tecnologias Computacionais para o Agronegócio” - Área de concentração: Interdisciplinar.

Orientador: Prof. Dr. Pedro Luiz de Paula Filho
Coorientador: Dr. Paulo Giovanni de Abreu

MEDIANEIRA

2017

Dados Internacionais de Catalogação na Publicação

A395d

Algeri, Thiago

Desenvolvimento de ferramenta não invasiva para dar subsídios na avaliação do bem-estar animal em aviários. / Thiago Algeri – 2017.
64 f. : il. ; 30 cm.

Orientador: Pedro Luiz de Paula Filho

Coorientador: Paulo Giovanni de Abreu

Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócios. Medianeira, 2017.

Inclui bibliografias.

1. Industria avícola. 2. Aves Criação. 3. Computação – Dissertações. I. Paula Filho, Pedro Luiz de, orient. II. Abreu, Paulo Giovanni de, coorient. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócios. IV. Título.

CDD: 004

Biblioteca Câmpus Medianeira
Marci Lucia Nicodem Fischborn CRB: 9-1219



TERMO DE APROVAÇÃO

**DESENVOLVIMENTO DE FERRAMENTA NÃO INVASIVA PARA DAR SUBSÍDIOS NA
AVALIAÇÃO DO BEM-ESTAR ANIMAL EM AVIÁRIOS**

Por

THIAGO ALGERI

Essa dissertação foi apresentada às dez horas e trinta minutos, do dia trinta de junho de dois mil e dezessete, como requisito parcial para a obtenção do título de Mestre em Tecnologias Computacionais para o Agronegócio, Linha de Pesquisa Tecnologias Computacionais Aplicadas à Produção Agrícola, no Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio - PPGTCA, da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho _____.

Prof. Dr. Pedro Luiz de Paula Filho (Orientador – PPGTCA)

Prof. Dr. Paulo Giovanni de Abreu (Coorientador – EMBRAPA)

Prof. Dr. Arnaldo Candido Junior (Membro Interno – PPGTCA)

Prof. Dr. Jefferson Gustavo Martins (Membro Interno – UTFPR – Toledo)

Profa. Dra. Jovanir Inês Müller Fernandes (Membro Externo – UFPR – Palotina)

A via original com as assinaturas encontra-se na secretaria do programa.

AGRADECIMENTOS

A meus pais **Flavio** e **Oneida**, meu infinito agradecimento, estes que sempre acreditaram em minha capacidade, e me apoiaram em tudo que fiz. Obrigado pelo amor incondicional!

Ao meu amor, **Tania**, por ser tão importante em minha vida. Sempre estar ao meu lado, por não permitir que eu desista de meus sonhos, por transformar os meus e seus sonhos em nossos, pelo companheirismo, amizade, paciência, compreensão, apoio, alegria e amor. Obrigado por fazer parte da minha vida!

Agradeço com carinho especial meu orientador, **Prof. Dr. Pedro Luiz de Paulo Filho** pela sua dedicação e pela orientação deste trabalho e, por meio dele, eu me reporto a toda a comunidade da Universidade Tecnológica Federal do Paraná (UTFPR) pelo apoio no desenvolvimento do trabalho.

Agradeço EMBRAPA em especial ao meu coorientador, **Dr. Paulo Giovanni de Abreu** pelo apoio recebido na execução deste projeto.

E em geral a todos que apoiaram e deram suporte para que este projeto se torna-se realidade.

RESUMO

ALGERI, Thiago. Desenvolvimento de ferramenta não invasiva para dar subsídios na avaliação do bem-estar animal em aviários. Trabalho de Mestrado do Curso de Pós-graduação em Tecnologias Computacionais para o Agronegócio - PPGTCA. Universidade Tecnológica Federal do Paraná. Medianeira, 2017.

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 teve como objetivo a utilização de câmeras e técnicas de processamento de imagens para calcular a movimentação e computar a densidade de frangos de corte no sistema produtivo. As imagens foram adquiridas de um aviário da região Oeste do Paraná entre os dias 30/12/2016 a 14/02/2017. No aviário foi instalada uma câmera de infravermelho marca *Hikvision* modelo *IR Fixed Dome*. Foram alojados 34.417 frangos da linhagem COBB, no final do processo produtivo foram recolhidos 33.208 frangos com peso total de 92.680 Kg, e peso médio de 2,7 Kg por frango. O processo de avaliação foi desenvolvido de acordo com dois itens: (1) a quantidade de quilos de aves por m², onde a legislação brasileira indica um valor máximo de 42 Kg/m², no melhor cenário. Para esta avaliação foram utilizados os classificadores *Haar-like* e LBP, ambos treinados com 200 e 400 imagens positivas, e suas validações foram executadas visualmente. Os classificadores analisaram 1.920 imagens e neste processo foram identificadas quantas aves estavam dentro de um quadro de um m². (2) a capacidade de movimentação, onde a legislação brasileira e as normas EFSA e Global G.A.P. indicam que deve haver espaço para o animal movimentar-se e descansar. Para este item, foram utilizadas técnicas de rastreamento uma baseada em fluxo óptico e outra denominada KCF. As técnicas de rastreamento foram testadas por meio da avaliação de 32 vídeos, ou seja, quatro vídeos por semana, registrando a movimentação das aves. Por meio das abordagens propostas pode-se concluir que é possível gerar informações para subsidiar a avaliação do bem-estar animal em aviários através das técnicas aplicadas.

PALAVRAS-CHAVE: Bem-estar animal; Fluxo óptico; KCF; *Haar-like*; LBP;

ABSTRACT

ALGERI, Thiago. Development of a non-invasive tool to give subsidies in the evaluation of animal welfare in aviaries. Master's Degree in the Postgraduate Course in Computational Technologies for Agribusiness - PPGTCA. Federal Technological University of Paraná. Medianeira, 2017.

The poultry production in Brazil, for domestic consumption and export, has been increased, at a time when the concern for animal welfare is growing. The demand for information about the production process and trade of animal products involving ethical and commercial issues. The study of animal behavior has an important role in production, especially for the development of production systems that have minimum standards of welfare. The 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 calculate the movements and count the density of the broilers in the production system. The images were acquired from an aviary from the western region of Paraná between 12/30/2016 to 2/14/2017. An infrared camera brand Hikvision model IR Fixed Dome was used. A total of 34,417 poultries from the COBB lineage were housed. At the end of the production process, 33,208 poultries with a total weight of 92,680 kg were collected, generating an average of 2.7 kg per poultry. The welfare evaluation process was developed based on two items: (1) the amount of kilos of poultry 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 LBP classifiers were used, both were trained with 200 and 400 positive images, and their validations were performed visually. The classifiers analyzed 1,920 images, in this process were identified how many poultries were inside a frame of an m^2 . (2) the ability of movement, where Brazilian legislation and EFSA and Global G.A.P. Indicate that there should be space for the animal to move and rest. For this item, tracing techniques were used one based on Optical Flow and another one called KCF. The tracking techniques were tested through the evaluation of 32 videos, four videos per week, the evaluation recorded the movement of the poultries. Through the proposed approaches it can be concluded that it was possible to generate information to subsidize the evaluation of animal welfare in aviaries through the applied techniques.

KEY WORDS: Animal welfare; Optical flow; KCF; Haar-like; LBP;

FIGURAS

Figura 1 – Sequência de imagens para demonstrar o fluxo óptico.....	21
Figura 2 – Respostas máximas e mínimas.....	24
Figura 3 – Representação da combinação de vários classificadores fracos através da utilização do algoritmo AdaBoost	25
Figura 4 - Características básicas do detector de objetos Viola-Jones	26
Figura 5 - Demonstração da Imagem integral	27
Figura 6 - Conjunto de características estendido	28
Figura 7 – Cascata de Classificadores.....	28
Figura 8 – Processo de extração LBP.....	30
Figura 9 - Centroides que indicam o posicionamento das aves;.....	31
Figura 10 - Resultado da subtração de fundo	32
Figura 11 - Aves marcadas	32
Figura 12 - Indicação dos comedouros	33
Figura 13 - Elipses sobre as aves	34
Figura 14 – Posicionamento da câmera.....	34
Figura 15 - Caminho percorrido pela ave durante o rastreamento.....	35
Figura 16 – Sobreposição das aves.....	35
Figura 17 – Câmera Hikvision.	38
Figura 18 – Posicionamento da Câmera.....	39
Figura 19 – Posicionamento da câmera no aviário.	40
Figura 20 – Processo geral de rastreamento	41
Figura 21 – Processo para selecionar, treinar e validar os classificadores.....	42
Figura 22 – Delimitação de um m ²	45
Figura 23 – Imagens adquiridas.....	47
Figura 24 – Taxa de aceitação por tempo de treinamento	48
Figura 25 – Classificações geradas pelo classificador <i>Haar-like</i> em cascata para todas as semanas	49
Figura 26 - Classificações geradas pelo classificador LBP em cascata para todas as semanas.....	50
Figura 27 – Oclusão pela barra de suporte	54
Figura 28 – Número médio de aves em um m ² por semana e por classificador.	55
Figura 29 – Distância média em <i>pixels</i> por semana.....	57

Figura 30 – Evolução do tamanho das aves e densidade.....	58
Figura 31 – Comparação da média de distância percorrida em <i>pixels</i> pelas aves e o tamanho das aves em <i>pixels</i> quadrados.	59

TABELAS

Tabela 1 – Trabalhos relacionados com frangos.....	35
Tabela 2 – Evolução do tamanho do quadro de marcação das aves.....	46
Tabela 3 - Comparação entre os classificadores	51
Tabela 4 – Comparação geral e entre os rastreadores entre as semanas, para os parâmetros tempo médio de rastreamento, média de <i>pixels</i> por segundo, tempo médio de processamento, média de quadros monitorados e distância média em <i>pixels</i>	52
Tabela 5 – Comparação entre os algoritmos de rastreamento, quanto a tempo médio de rastreamento, média de <i>pixels</i> por segundo, tempo médio de processamento, média de quadros monitorados e distância em <i>pixels</i>	53
Tabela 6 - Número médio de aves em um m ² por classificador e semana.....	55
Tabela 7 – Evolução da quantidade de aves e peso por m ² durante as seis semanas por classificador.....	56
Tabela 8 – Tamanho das aves em <i>pixel</i> semana a semana	59

SUMÁRIO

1 INTRODUÇÃO	13
2 FUNDAMENTAÇÃO TEÓRICA	17
2.1 BEM-ESTAR ANIMAL	17
2.2 PROCESSAMENTO DIGITAL DE IMAGENS	18
2.3 RASTREAMENTO	20
2.4 FLUXO ÓPTICO	21
2.5 <i>KERNELIZED CORRELATION FILTERS</i>	23
2.6 <i>ADABOOST</i>	24
2.7 HAAR	25
2.8 <i>LOCAL BINARY PATTERN</i>	29
3 ESTADO DA ARTE	31
3.1 RASTREAMENTO DE AVES	31
3.2 RASTREAMENTO DE PESSOAS	36
3.3 CLASSIFICADORES	37
4 MATERIAL E MÉTODOS	38
4.1 MATERIAL	38
4.2 MÉTODOS	39
4.2.1 Instalação, Posicionamento e Configuração da Câmera	39
4.2.2 Tempo e condições de alojamento das Aves	40
4.2.3 Visão geral da proposta de <i>Software</i>	40
4.2.4 Identificação das Aves	42
4.2.5 Rastreamento	44
4.2.6 Geração de informações para avaliação	44
4.2.7 Análises estatísticas	46
5 RESULTADOS E DISCUSSÃO	47
5.1 AQUISIÇÃO DAS IMAGENS	47
5.2 IDENTIFICAÇÃO	47
5.3 RASTREAMENTO	51
5.4 AVALIAÇÃO DAS INFORMAÇÕES	54
6. CONCLUSÃO	60
6.1 SUGESTÕES PARA TRABALHOS FUTUROS	60

REFERÊNCIAS.....	62
------------------	----

1 INTRODUÇÃO

A produção de carne de frangos no Brasil vem apresentando um crescimento considerável nos últimos anos, devido principalmente ao fato desse alimento ser uma das principais fontes de proteína animal além de seu baixo custo de aquisição. Para garantir a qualidade e disponibilidade deste produto, o processo de produção vem sofrendo grande evolução, sendo necessária uma série de medidas a fim de garantir sua qualidade, destacando-se a melhoria da nutrição, manejo, genética, entre outros (DAMASCENO et al., 2010).

Esse segmento de produção possui grande direcionamento para o mercado externo e de acordo com dados do Relatório Anual da União Brasileira de Avicultura, em 2014, 31,6% da produção foi exportada (ABPA, 2014). Um dos principais destinos dos produtos exportados, A União Europeia, estabelece critérios diretamente relacionados com o bem-estar animal, por meio de legislações e certificações, previamente estabelecidas aos seus fornecedores. Em resposta a esta exigência, o Ministério da Agricultura, Pecuária e Abastecimento (MAPA), publicou no Diário Oficial da União as Instruções Normativas N° 56 no ano de 2008, N° 59 em 2009, e reformulou a Instrução Normativa N° 56 visando, estabelecer padrões e recomendações de boas práticas para o Bem-Estar Animal, que abrangem aspectos desde a produção até o transporte. Além disso, estudos vêm sendo realizados visando o correto manejo de aves de corte e a consequente redução de perdas relacionadas a essas práticas (MOGAMI, 2009). Abreu e Abreu (2007) demonstram que, em períodos quentes do ano, a produtividade é afetada devido à alta mortalidade, ocasionada devido ao estresse causado por calor e umidade. Na cadeia de produção brasileira, são poucos os locais que apresentam condições ideais de conforto. Desta forma, na maioria dos casos é necessário produzir estas situações. Um dos grandes desafios é construir instalações que proporcionem ambientes ideais e sem aumento de custos de produção.

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. Na prática da etologia, o bem-estar é avaliado por meio de indicadores fisiológicos e comportamentais. As medidas fisiológicas associadas ao estresse têm sido usadas, baseadas no fato de que, se o estresse aumenta, o bem-estar diminui. Já os indicadores comportamentais são baseados especialmente na ocorrência de comportamentos anormais e que se afastam do comportamento no ambiente natural (ABRAHAMSSON, 1996).

A caracterização do padrão e estrutura do comportamento animal é uma tarefa importante para entender as interações complexas entre indivíduos e o meio em que vivem. O comportamento das aves é um parâmetro que pode mostrar o caminho para o desenvolvimento dos sistemas intensivos de produção no que se refere aos recentes padrões de bem-estar exigidos pelos principais países importadores de carne de frango (HOCKING et al., 2007). Um dos itens que motiva o estudo do comportamento das aves é o bem-estar, e como um dos principais indicadores deste estado está a possibilidade de locomoção. Como exemplo, o Reino Unido possui legislação que contém itens que discorrem sobre a livre movimentação dos animais destinados à alimentação (SERGEANT et al., 1998).

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, que neste caso, 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/m², já a legislação nacional, permite até 42 Kg/m², quando existir controle veterinário e não identificado, nos últimos dois anos, problemas de baixo grau de bem-estar nas inspeções *post-mortem*.

De acordo com Abrahamsson (1996), o comportamento animal era estudado através da observação visual, o que consumia muito tempo, era subjetivo e muito susceptível ao erro humano. 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. Essa metodologia não só possibilita esta análise de forma mais eficaz para o pesquisador, como também diminui a influência da presença humana exercida sobre os animais. Além disso, permite ao pesquisador utilizar diversas estratégias de amostragem, segundo o critério que considerar mais apropriado, acrescido de todas as vantagens de uma gravação: pausar, acelerar,

retardar ou aproximar a imagem visualizada a fim de se captar detalhes, quando desejados, bem como extrair fotografias de grande utilidade para o estudo (CURY e SANTOS, 2009). Esse método de estudo de comportamento já foi utilizado para outras espécies de animais, como nos trabalhos de Sevegnani et al. (2005) utilizando frangos de corte e Cury e Santos (2009) que estudaram o comportamento de colônias de morcegos.

Ainda neste contexto, a vantagem da utilização de sistemas de visão computacional em relação ao sistema visual humano, é a possibilidade de realizar medições exatas não influenciando para tanto no comportamento animal e também anulando a subjetividade do observador humano (MOGAMI, 2009). Para Sergeant et al. (1998), a utilização da visão computacional em relação à humana para a análise do comportamento das aves é recomendada devido aos seguintes motivos: o efeito da presença humana afeta o comportamento das aves; a dificuldade de identificar movimentos devido à baixa claridade ou escuridão total do ambiente; e o tempo para coletar uma grande quantidade de informações.

Sistemas de visão artificial são sistemas computadorizados capazes de adquirir, processar e interpretar imagens correspondentes a cenas reais. Segundo Mogami (2009), as principais etapas utilizadas pelo sistema de visão artificial são o pré-processamento, segmentação, extração de características e reconhecimento e interpretação de padrões. A visão computacional tem evoluído rapidamente, com a criação de ferramentas que permitem um elevado entendimento das informações visuais. Especialmente em cenas com estruturas complexas, as informações podem ser divididas em dois níveis de abstração, processamento digital de imagens (PDI) e análise de imagens.

O PDI busca técnicas para capturar, representar e transformar imagens, permitindo extrair e identificar informações e melhorar a qualidade visual de certos aspectos, melhorando a extração de características que serão usadas posteriormente. A análise de imagens envolve técnicas como segmentação da imagem em regiões de interesse, descrições dos objetos, reconhecimento e classificação, usando imagens como entrada, processando e produzindo saída (PAULA FILHO, 2010).

Com o auxílio de técnicas de visão computacional, espera-se obter respostas quanto à densidade de alojamento e movimentação. Estas informações podem subsidiar informações para melhoria do bem-estar animal e, em

consequência, aumentar o rendimento e qualidade. Neste contexto, o objetivo deste trabalho foi desenvolver um *software* para calcular a movimentação e computar a densidade de frangos de corte no sistema produtivo, gerando informações que auxiliem avicultores, técnicos e pesquisadores nas tomadas de decisões.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 BEM-ESTAR ANIMAL

O Brasil é o terceiro maior produtor mundial e o líder em exportação de carne de frango (ABPA, 2014). Em contraste com esta classificação está a falta de legislação local quanto ao bem-estar no processo produtivo. Por outro lado, Estados Unidos da América e países da União Europeia possuem legislações mais desenvolvidas (SOUZA e MOLENTO, 2015).

De acordo com o *Farm Animal Welfare Advisory Council*, o bem-estar animal está baseado em cinco liberdades (FAWAC, 2011):

- i. Livre de fome, sede e má nutrição;
- ii. Livre de desconforto (fácil movimentação, conforto térmico, conforto para descansar);
- iii. Livre de dor, ferimentos e doenças;
- iv. Liberdade para expressar padrão comportamental natural;
- v. Livre de medo e estresse.

Esses aspectos devem ser considerados como uma demanda para qualquer sistema criatório que deseja ser eticamente defensável e socialmente aceitável, pois o mercado deseja produtos com qualidade ética. Ou seja, objetiva-se animais que tenham sido criados, tratados e abatidos em sistemas que promovam o bem-estar e que também sejam sustentáveis e ambientalmente corretos (MOGAMI, 2009).

Segundo *Humane Farm Animal Care* (HFAC, 2014) existem alguns princípios básicos de bem-estar que devem ser aplicados a frangos de corte, como: alimentação e água devem ser bem distribuídas evitando competição excessiva; o ambiente onde as aves são mantidas deve proteger as aves do desconforto térmico, medo e aflição; também, deve-se permitir que os animais mantenham seu comportamento natural; a qualidade do ar deve ser monitorada, onde concentrações de NH₃ devem ser inferiores a 10ppm e não exceder 25ppm, as concentrações de CO₂ devem ser inferiores a 3.000ppm e não exceder 5.000ppm, e as concentrações de CO deve ser inferior a 10ppm e não exceder 50ppm; a saúde das aves também deve ser observada, onde os frangos devem ser protegidos contra dor, ferimentos e doenças.

O ambiente de criação possui alto grau de importância no processo de criação de aves de corte, isto porque, influencia diretamente no conforto e grau de bem-estar, tendo como exemplos o conforto térmico e a expressão de seus comportamentos naturais, afetando o desempenho produtivo e a saúde das aves (LOURENÇONI, 2017).

A densidade de lotação de aves em sistemas criatórios foi estudada por Bonamigo et al. (2010), que identificou que o número de aves por metro quadrado influencia no peso final das aves indicando um grau menor de bem-estar.

2.2 PROCESSAMENTO DIGITAL DE IMAGENS

Os conhecimentos necessários para processamento digital de imagens (PDI) são essenciais para o desenvolvimento deste trabalho. A seguir serão apresentados alguns fundamentos dessa área de conhecimento.

Para obtenção de informações de imagens digitais são necessários alguns passos fundamentais. A imagem é, geralmente, obtida em um ambiente controlado, no qual são capturadas somente imagens do objeto a ser inspecionado. Após definido o domínio do problema, os passos necessários para obter informações da imagem digital são: aquisição da imagem, pré-processamento, segmentação, reconhecimento e interpretação (GONZALES e WOODS, 2001).

A aquisição da imagem geralmente é realizada em um ambiente controlado e faz uso de diversos modelos de câmeras. Estas possuem características diversas como, imagem em tons de cinza, colorida, infravermelha, resoluções diversas, apenas foto, vídeo, entre outras (GONZALES; WOODS, 2001). Deve-se também observar e identificar a melhor posição do dispositivo para captura da imagem do objeto a ser observado (GONZALES; WOODS, 2001).

Para a etapa de pré-processamento são descritas várias técnicas. Estas técnicas, na maioria das vezes, têm o objetivo de remover ruídos da imagem, suavizá-la ou realçar detalhes. Duas destas técnicas são as operações morfológicas conhecidas como erosão e a dilatação. A erosão é caracterizada pela redução da área do primeiro plano, o que proporciona o seu encolhimento e converte seus *pixels* em *pixels* do plano de fundo se algum elemento da estrutura os tocar. A dilatação é a operação inversa, aumentando o primeiro plano, convertendo os *pixels* do plano de fundo em *pixels* do primeiro plano se algum elemento da estrutura os tocar.

Ambas as operações utilizam como parâmetro o elemento estruturante que é uma forma (JAWAS; SUCIATI, 2013).

Ainda na etapa de pré-processamento encontram-se os filtros de imagem, os quais possuem a função de remover ruídos provenientes do processo de aquisição da imagem ou adequar a imagem para a etapa de reconhecimento e interpretação (MARENGONI; STRINGHINI, 2009). Por meio ou a partir da análise de frequência, os filtros realizam operações que amplificam e/ou removem certas faixas de frequência. O filtro “passa-baixa”, por exemplo, suaviza a imagem com a substituição de cada pixel pelo valor médio calculado para seus vizinhos. Já o filtro mediano visa a remoção de ruído discrepante, e realiza a substituição dos *pixels* pela mediana de todos os *pixels* vizinhos. Este filtro é geralmente recomendado para operações nas quais é necessário preservar a nitidez das bordas e para uniformizar a textura (CULJAK, 2012).

Na etapa de reconhecimento e interpretação, desafios como a detecção de bordas é um dos problemas fundamentais no PDI e visão computacional. Uma das funções utilizadas na detecção de bordas é o filtro linear “passa-alta” que é baseado na soma de derivadas de segunda ordem, por exemplo o filtro Laplaciano. No filtro Laplaciano a borda é definida pela passagem pelo zero na função. Na primeira etapa, a imagem é varrida e são detectadas as mudanças de sinal para dois *pixels* vizinhos. Na segunda etapa, através da limiarização da magnitude do gradiente e a função próximo a zero, são identificadas as bordas da imagem. Entretanto, escolher o limiar correto não é uma tarefa trivial (CULJAK, 2012).

Outro método para detecção de bordas conhecido é o filtro *Canny*. Este é considerado um dos mais eficientes em detecção de bordas devido a sua alta performance e sua habilidade de detecção de bordas reais. Sua utilização é recomendada em aplicações nas quais é necessária a avaliação de bordas em tempo real (TOPAL et al., 2010). Seu funcionamento está baseado na utilização de dois limiares, o limiar baixo e o limiar alto. A ideia é combinar os dois mapas de bordas gerados de maneira que os pontos do mapa de limiar baixo somente serão utilizados quando estiverem conectados no caminho dos pontos do limiar alto (CULJAK, 2012).

2.3 RASTREAMENTO

Também no campo da visão computacional o rastreamento de objetos é uma importante tarefa. Neste campo segundo Yilmaz et al. (2006) existem três passos chave para a análise de vídeos, que são:

- detecção do objeto de interesse;
- rastreamento do objeto quadro a quadro;
- análise do movimento para identificar seu comportamento .

Rastrear objetos em vídeo pode ser definido como acompanhar o objeto durante a cena, e sua realização é complexa devido à diversos fatores. Estes fatores são descritos por Yilmaz et al. (2006) como: perda de informação devido a projeção de terceira dimensão em um mundo de segunda dimensão; completa ou parcial oclusão dos objetos; objetos com formas complexas; iluminação da cena; mudança de iluminação; processamento em tempo real; e ruído na imagem.

Rastreamento visual é um problema desafiador, pois várias circunstâncias devem ser consideradas em um algoritmo. Por exemplo, o algoritmo deve considerar a variação de luminosidade e a mudança de aparência devido à variação do ponto de visão (SMEULDERS et al., 2014). Xu et al. (2014) também discorre sobre a complexidade e dos desafios de sistemas de vigilância para rastreamento e detecção de eventos. Segundo o autor, a co-ocorrência de múltiplos eventos e a quantidade massiva de dados são algumas das principais complexidades.

Informações sobre o comportamento do movimento do objeto, como velocidade e trajetória, sua forma, tamanho, são peças importantes para simplificar o algoritmo para rastreamento (YILMAZ et al., 2006). Portanto, pode-se definir rastreamento como um dos problemas mais desafiadores da visão computacional, e também pode-se simplificar este problema de forma objetiva como: rastreamento é a análise de uma sequência de vídeo com o objetivo de determinar o local do alvo sobre uma sequência de quadros (SMEULDERS et al., 2014).

Para rastrear múltiplos objetos em uma mesma cena sugere-se a detecção de informações sobre o primeiro plano da cena. Geralmente são aplicadas técnicas para remoção ou subtração do plano de fundo e, quando os objetos se sobrepõem, são utilizados métodos para prever suas trajetórias. Porém, esta técnica de predição de trajetória não é aplicável a todos os casos, tal como quando os objetos não apresentam comportamento que possa ser previsto (SERGEANT et al., 1998).

Segundo Yilmaz et al. (2006), existem várias metodologias para rastreamento de trajetória de objetos em cena, cada uma com suas características. Existem duas características consideradas básicas para qualquer algoritmo, as quais podem ser descritas como definir uma representação para o objeto e definir características da imagem como parâmetros de entrada para a estratégia de rastreamento.

Entretanto, com a proliferação de dispositivos com alto poder de processamento e câmeras de alta resolução, cresce a demanda por algoritmos automatizados de rastreamento e monitoramento (YILMAZ et al., 2006).

2.4 FLUXO ÓPTICO

Fortun (2015) discorre sobre a noção de fluxo óptico. Este é definido como o deslocamento de padrões de intensidade que se originam da percepção fisiológica da descrição visual da compreensão do mundo através da imagem formada na retina. O fluxo óptico é causado pela movimentação entre o objeto e o observador, no tempo.

A Figura 1 apresenta exemplo básico de como o fluxo óptico funciona. Esta contém dois quadros de uma sequência de imagens I no tempo t . A Figura 1a exibe os pontos com a direção do fluxo óptico em relação a Figura 1b. As setas indicam o fluxo óptico, a direção dos pontos em relação ao próximo frame (OLIVEIRA; GOMES, 2011).

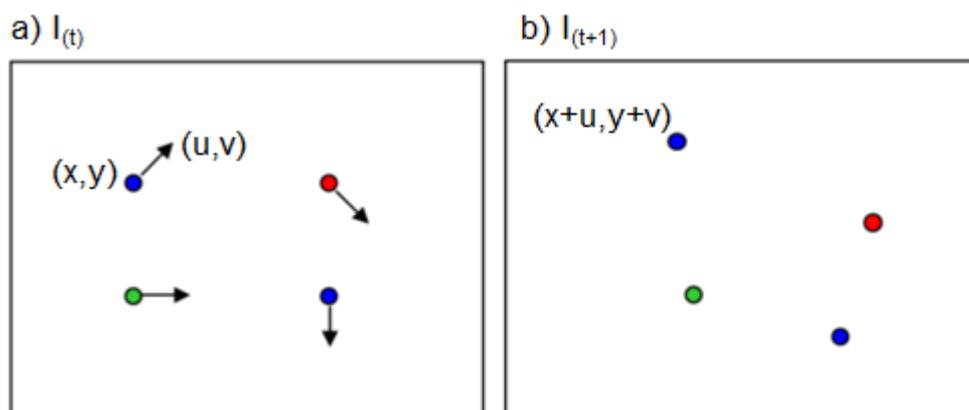


Figura 1 – Sequência de imagens para demonstrar o fluxo óptico.

Fonte: OLIVEIRA; GOMES, 2011.

A relevância da utilização do fluxo óptico se dá quando há interesse em identificar o movimento de um objeto entre dois instantes na mesma cena. Segundo Oliveira e Gomes (2011), sua utilização é geralmente aplicada em: interpretação de cena, navegação exploratória, acompanhamento de objetos, avaliação de tempo de um corpo contra outro, segmentação de objetos, visão robótica, aplicações de vigilância, entre outras.

Um dos grandes desafios na utilização de algoritmos de detecção do fluxo óptico é o alto custo computacional. Este custo, em muitos casos, inviabiliza sua utilização, principalmente em sistemas que necessitam de informação em tempo real (FORTUN, 2015).

Como já descrito anteriormente, o fluxo óptico é capaz de determinar a velocidade e a direção em que os objetos se movem em uma sequência de imagens. Os métodos Lucas e Kanade, proposto por (LUCAS e KANADE, 1981), e Horn e Schunck, proposto por (HORN e SCHUNK, 1981) são exemplos. Estes métodos foram avaliados quanto a sua eficácia e performance por Oliveira e Gomes (2011), os quais concluíram sua pesquisa indicando que ambos os métodos se mostraram eficazes no cálculo do fluxo óptico. Porém, o método Lucas e Kanade apresenta problemas de performance quando o tamanho da imagem cresce.

Ambos os métodos Lucas e Kanade e Horn e Schunck possuem a mesma premissa, a qual define que a intensidade dos quadros em uma sequência de imagem é constante. Assim, através do uso de equações diferenciais, é possível calcular o fluxo óptico. Porém, somente esta informação não é suficiente para calcular o fluxo óptico e é neste ponto que os métodos são diferentes. Lucas e Kanade utilizam outro conjunto de equações e propõem um método não iterativo que assume um fluxo óptico constante. Basicamente, seu funcionamento se dá pela divisão da imagem em janelas, e a verificação se os *pixels* mudaram de lugar entre as janelas vizinhas. Horn e Schunck, por sua vez, propõem que a velocidade da imagem é computada através das derivadas espaço-temporal das intensidades na imagem (OLIVEIRA; GOMES, 2011).

2.5 KERNELIZED CORRELATION FILTERS

"*Tracking-by-detection*" é uma abordagem promissora, está sustentada diretamente no desenvolvimento de métodos descritivos em aprendizado de máquina, e sua aplicação para detecção utilizando treinamento *off-line*. Vários destes algoritmos podem ser adaptados para treinamento *online*, onde cada detecção bem-sucedida fornece mais informações sobre o alvo (HENRIQUES et al., 2012).

O método de rastreamento *Kernelized Correlation Filters* (KCF) proposto por Henriques et al. (2012) segue a abordagem *tracking-by-detection* e seu funcionamento é descrito da seguinte forma (HENRIQUES et al., 2012):

- Um quadro de tamanho fixo (o dobro do quadro alvo) é recortado da imagem de entrada, na posição estimada ou predefinida. Na Figura 2 pode-se observar o quadro em verde (a) que representa o alvo ou objetivo e o quadro em azul (b) que representa o quadro recortado;
- Nenhuma extração de característica é executada, exceto um quadro de cossenos dos valores brutos dos *pixels* é extraído;
- O alvo é localizado por avaliação através do modelo e são localizadas as respostas máximas. Na Figura 2 pode-se observar as respostas representadas pelo gráfico de calor, onde em vermelho ou no centro são as respostas máximas e em azul e nas bordas as respostas mínimas;
- Os dados são utilizados para treinar o novo modelo;
- Para o novo modelo manter memória, ele é integrado através de interpolação linear com os parâmetros do modelo anterior.

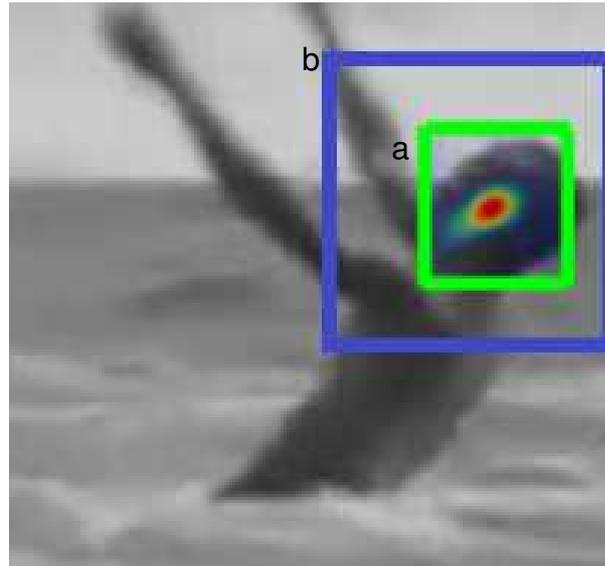


Figura 2 – Respostas máximas e mínimas

Fonte: HENRIQUES et al., 2012.

2.6 ADABOOST

AdaBoost é um algoritmo de aprendizado de máquina proposto por Freund e Schapire (1997). Inicialmente inspirado para detecção de faces humanas e é um poderoso algoritmo de reconhecimento de padrões. Sua utilização geralmente combina outros tipos de algoritmos de classificação para aumento de performance (TIKOO, 2016).

A saída dos outros classificadores chamados de fracos é combinada em uma soma ponderada que representa a saída do classificador. É adaptativo no sentido de que os classificadores fracos subsequentes são ajustados em favor das instâncias classificadas incorretamente pelos classificadores anteriores (TIKOO, 2016).

O algoritmo pode ser facilmente entendido observando a Figura 3, na qual as funções $h(x)$ representam os classificadores fracos. Neste exemplo cada uma delas consegue identificar 50% dos dados, α identifica os pesos de cada um destes classificadores e combinados transformam-se em um classificador forte, definida pela Equação 1. Onde T , é a quantidade de classificadores fracos, a_t é o peso do classificador t , $h_t(x)$ é o resultado do classificador fraco t , e $H(x)$, é a combinação dos classificadores fracos e seus respectivos pesos (SCHAPIRE, 2013).

$$H(x) = \text{sign}\left(\sum_{t=1}^T a_t h_t(x)\right) \quad (1)$$

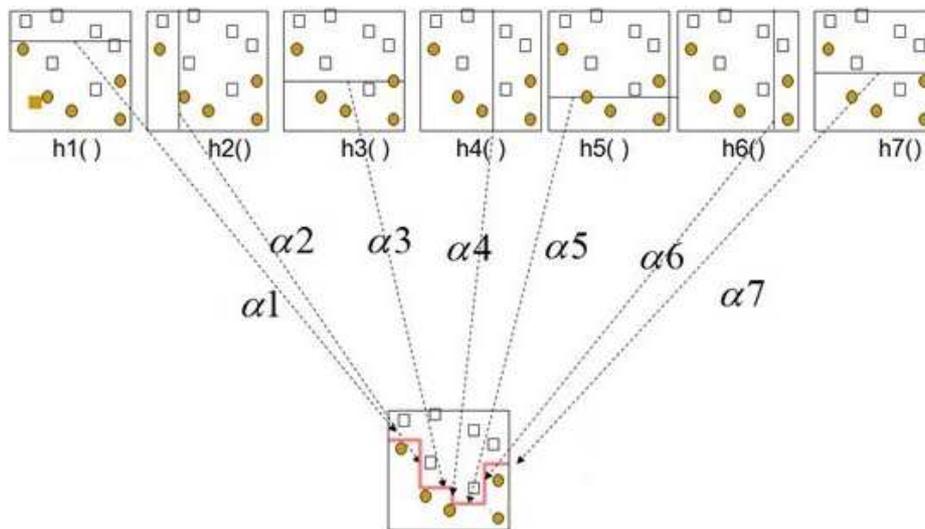


Figura 3 – Representação da combinação de vários classificadores fracos através da utilização do algoritmo AdaBoost

Fonte: KDNUGGETS, 2014.

2.7 HAAR

Detecção de objetos é uma tarefa inicial em sistemas de análise de imagens. Existem diversas técnicas que podem ser empregadas para tal tarefa, uma delas tem sido muito empregada é a descrita por Viola-Jones (2001), ela é capaz de detectar objetos com precisão, alta taxa de acerto, baixa taxa de falsos positivos e baixo custo computacional. Este algoritmo é composto por três partes. A primeira é a representação da imagem em um espaço de características baseadas nos filtros de Haar, como características básicas pode-se observar a Figura 4. A segunda delas é a montagem de um classificador baseado em *Boosting* capaz de selecionar as características mais relevantes. Na terceira e última etapa é realizada a combinação em cascata destes classificadores de modo a garantir velocidade de processamento e desempenho (HASAN et al., 2017; ARAUJO, 2010).

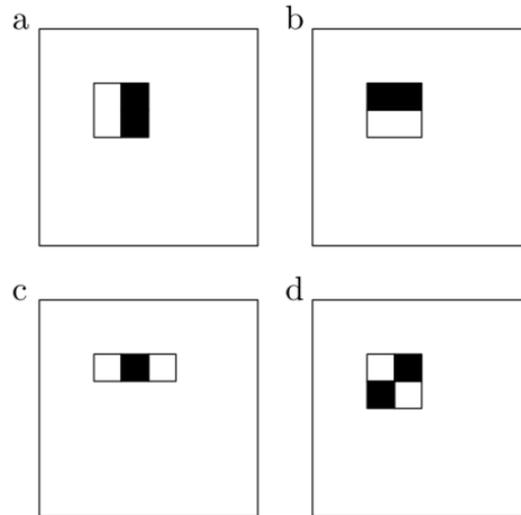


Figura 4 - Características básicas do detector de objetos Viola-Jones

Fonte: ARAUJO, 2010.

Para que seja possível computar de forma eficiente a presença ou não de uma característica *Haar-like*, foi utilizada a técnica da “imagem integral”, utilizada por BOUSSAA et al. (2015), definida pela Equação 2. Onde $ii(x,y)$ é a integral da imagem e $i(x',y')$ é a imagem original.

$$ii(x,y) = \sum_{x \geq x', y \geq y'} i(x',y') \quad (2)$$

Tendo como principal vantagem a possibilidade de calcular a soma dos elementos de qualquer retângulo contido na imagem através da soma de quatro pontos de $ii(x,y)$, além de ser obtida através de uma varredura na imagem (BOUSSAA et al., 2015).

Através da imagem integral são adquiridos conjuntos de características pela diferença entre a soma dos *pixels* de regiões retangulares. Estas características são determinadas pela subtração da média dos valores dos *pixels* da região considerada escura com a região clara, quando a diferença estiver acima de um limiar, ou seja, realmente existe uma região clara e outra escura, então a característica existe (ARAUJO, 2010).

O termo integral indica que é feita a soma dos valores de todos os *pixels* acima e à esquerda de um pixel específico, e este é representado por um ponto (m,n) da imagem. Com a integração, tem-se para cada pixel da imagem o valor da

soma dos *pixels* do retângulo formado pelo canto da origem e sua posição, onde o canto da origem é o canto superior esquerdo. Desta forma, pode-se descobrir o valor médio desta região através da divisão do valor obtido pela área do retângulo. Outro ponto simples é para obter o valor médio de uma área onde o ponto de origem não seja o de origem da imagem, são necessárias quatro etapas. Para exemplificar este processo é possível observar na Figura 5. Nesta são apresentadas quatro sub janelas, o valor da imagem integral na posição 1 é a soma dos *pixels* do retângulo (a). A posição 2 contém a soma dos *pixels* dos retângulos (a) + (b). A posição 3 contém a soma dos *pixels* dos retângulos (a) + (c). A posição 4 contém a soma dos *pixels* dos retângulos (a) + (b) + (c) + (d). Para ter a soma dos *pixels* do retângulo D é necessário realizar o seguinte calculo (posição 4 + posição 1 - (posição 2 + posição 3)) (BOUSSAA et al., 2015; ARAUJO, 2010).

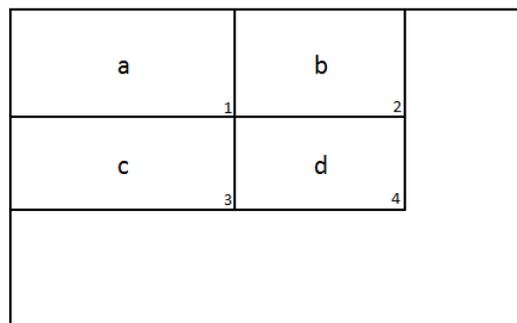


Figura 5 - Demonstração da Imagem integral

Fonte: O autor.

Além das características básicas, em versões recentes, foram adicionadas novas características. Esse conjunto possui versões rotacionadas das características utilizadas na abordagem original, na Figura 6 é possível observar a lista de características estendidas (ARAUJO, 2010).

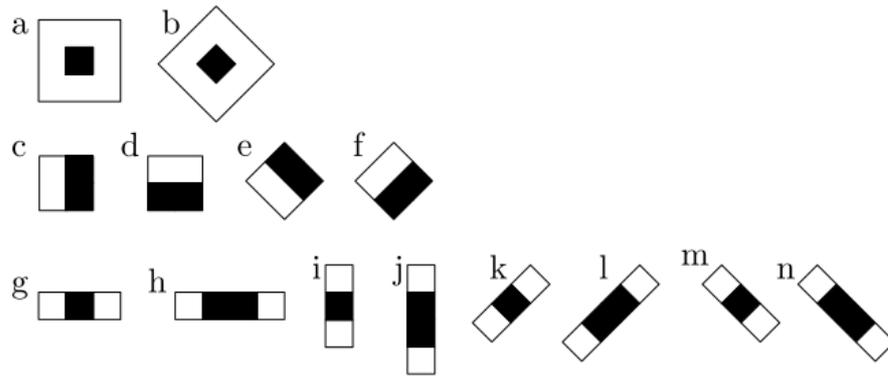


Figura 6 - Conjunto de características estendido

Fonte: ARAUJO, 2010.

O processo de treinamento exige um conjunto de treinamento que deve ser formado por (j_n, i_n) com N amostras, onde j_n é uma imagem de dimensão (x, y) e $i_n = \{0, 1\}$ é o rótulo da classe. Quando, $i_n=0$ tem-se uma imagem negativa, e se $i_n=1$ tem-se a uma imagem positiva. O número de características depende da dimensão (x, y) (CRUZ et al., 2013).

Devido ao alto número de características, a etapa de seleção de características é de extrema relevância. Para selecionar as melhores características é utilizado o classificador *Adaboost* (CRUZ et al., 2013).

Devido a taxas não satisfatórias em problemas práticos, ela não deve ser aplicada individualmente. Conforme proposto por Viola-Jones (2001), deve ser utilizada em formato de árvore degenerada, ou cascata de classificadores, conforme pode ser observado na Figura 7 (CRUZ et al., 2013).

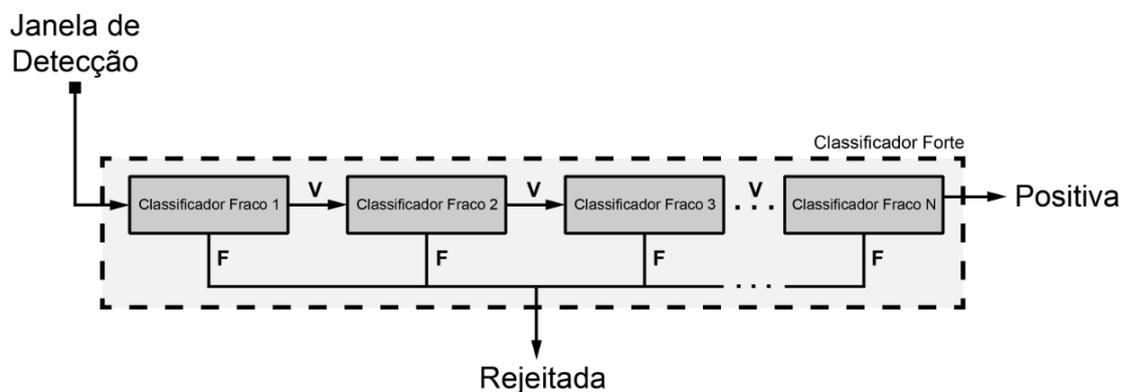


Figura 7 – Cascata de Classificadores

Fonte: CRUZ et al., 2013.

A estrutura de cascata funciona como classificador. Cada sub-janela da imagem deverá passar por esta estrutura. Em qualquer uma das etapas a sub-janela pode ser rejeitada e, quando isto ocorre, entende-se que não existe o objeto procurado. Nas etapas iniciais os classificadores são mais simples e exigem menos processamento, nas etapas finais os classificadores são mais robustos e menos performáticos. Se a sub-janela não for rejeitada pelos classificadores de toda a cascata ela é considerada aprovada (ARAUJO, 2010).

Eficiência computacional e desempenho do detector são os principais dilemas deste método. E em geral, classificadores com mais características possuem taxas de detecção positivas maiores. No entanto, estes requisitam maior tempo de processamento. Desta forma, conclui-se que para otimizar o processo, deve-se encontrar o número de etapas de classificadores adequado. Para otimização de cada etapa define-se um valor mínimo de falsos positivos. Com a evolução das etapas, este mínimo é reduzido até atingir a taxa de falso positivo e de detecção desejadas (ARAUJO, 2010; CRUZ et al., 2013; BOUSSAA et al., 2015).

2.8 LOCAL BINARY PATTERN

O operador *Local Binary Pattern* (LBP), foi inicialmente proposto por Ojala et al. (1994). O LBP é um poderoso descritor de texturas. E tem sido utilizado em uma vasta variedade de aplicações. Seu funcionamento baseia-se na teoria de que características comuns, como cantos, linhas e pontos, podem ser representadas por um valor em uma escala numérica. Com isto, é possível utilizar o LBP para reconhecimento de objetos em imagens, porém para isto, é necessário um conjunto de valores extraídos inicialmente (CRUZ et al., 2015).

O funcionamento do LBP inicia com a criação de descrição para os vizinhos do *pixel* central, utilizando uma matriz 3x3 que pode ser observada na Figura 8(a). Na Figura 8(b) observa-se os valores de intensidade dos tons de cinza do *pixel* central em vermelho e dos vizinhos em amarelo. Na próxima etapa, todos os *pixels* vizinhos são subtraídos com o valor do *pixel* central, gerando a Figura 8(c). Na sequência é aplicada função que substitui valores abaixo de zero por 0 e acima de zero por 1, gerando a Figura 8(d). Na etapa seguinte os vizinhos com valor 1 recebem os valores correspondentes da Figura 8(e), e os valores são somados, gerando o valor para o *pixel* central da matriz LBP Figura 8(f) (CRUZ et al., 2015).

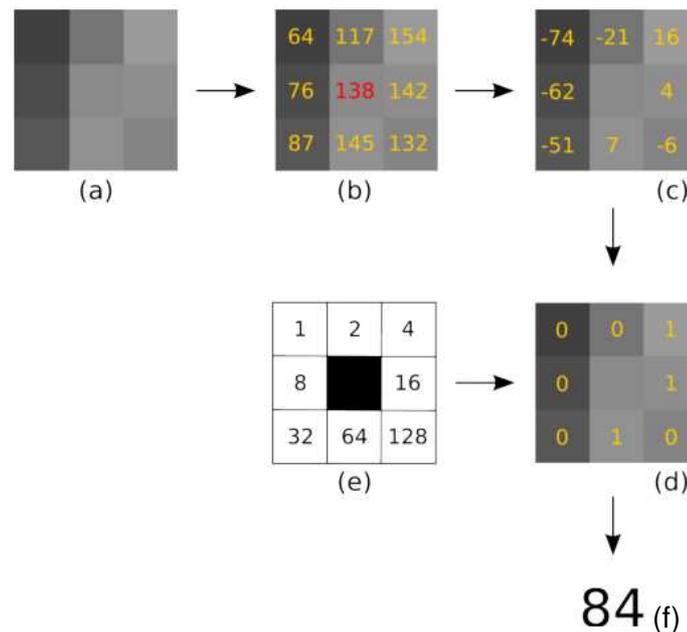


Figura 8 – Processo de extração LBP

Fonte: CRUZ et al., 2015.

Este classificador isoladamente é um classificador fraco. Porém, quando utilizado em cascata, ele se torna um poderoso classificador com alto poder de discriminação, capaz de identificar estruturas ignorando luminosidade, cor ou escala (DO; DOAN 2009).

O uso dos classificadores em cascata permite em estágios iniciais rejeitar características, com um baixo custo computacional e com uma mínima avaliação. O LBP em cascata utiliza o mesmo conceito de árvore degenerada utilizada pelo *Haar* em cascata, Figura 6 (CRUZ et al., 2015).

O treinamento do LBP em cascata deve ser realizado para o mesmo focar em um pequeno grupo de características e ignorar aquelas não críticas para melhorar a performance sem afetar a acurácia. Para classificar as características essenciais, o método *Boosting* é empregado entre as etapas de treinamento (DO; DOAN, 2009).

Devido ao fato de que as estruturas procuradas na imagem possam estar em diferentes lugares na imagem e em diferentes escalas, o método utiliza janelas deslizantes e mudança de escalas para processar a imagem (DO; DOAN, 2009).

3 ESTADO DA ARTE

Nesta seção são resumidos alguns trabalhos relacionados com rastreamento de aves. Também são considerados trabalhos relacionados ao rastreamento de pessoas em multidões, isto devido a sua similaridade com o problema.

3.1 RASTREAMENTO DE AVES

Sargeant (1998) utilizou técnicas de extração de fundo, segmentação e separação para produzir centróides de cada ave em cada quadro (Figura 9). Os centróides foram utilizados para calcular a trajetória dos animais em conjunto com câmeras posicionadas no teto e direcionadas para baixo, sem inclinação. Com isto, obteve-se resultados satisfatórios em um cenário controlado, reduzido e com poucas aves.

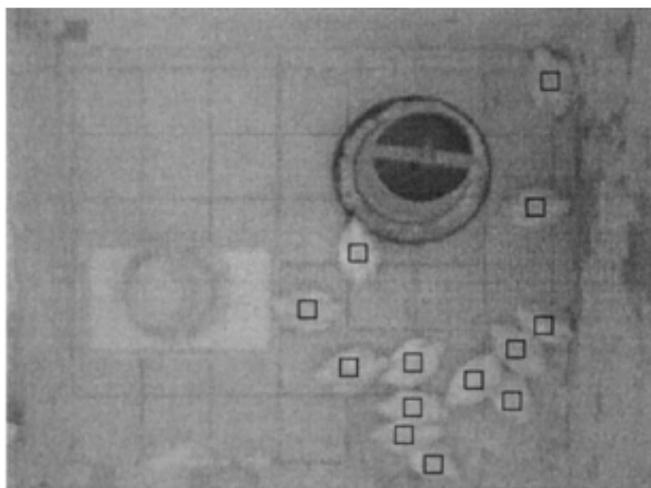


Figura 9 - Centroides que indicam o posicionamento das aves;

Fonte: SERGEANT et al., 1998.

Ambientes controlados são geralmente utilizados na produção de aves. Estes ambientes possuem principalmente, controles de umidade, temperatura e luminosidade. Figueiredo e Benson (2003) desenvolveram um sistema de análise de imagens para extrair respostas quanto a mudanças de temperatura e comportamento da alimentação, para configurações comerciais de ambientes controlados de produção. Para alcançar os objetivos, câmeras foram instaladas no

forro apontadas para baixo. Os autores separaram a imagem em áreas e monitoram os aglomerados de aves, se eles estavam próximos a bebedouros, comedouros ou não. Como técnicas de visão computacional, os autores utilizaram subtração de fundo, conforme demonstrado na Figura 10, morfologia e segmentação da imagem.

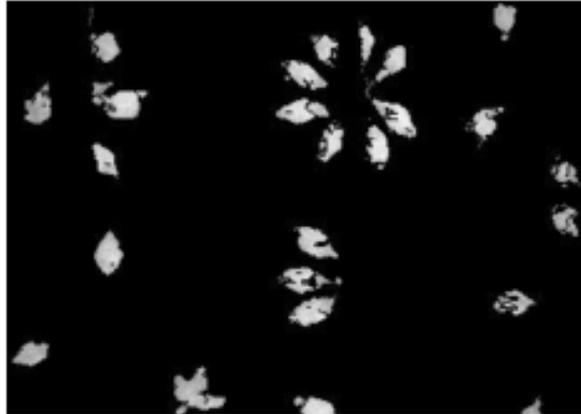


Figura 10 - Resultado da subtração de fundo

Fonte: FIGUEIREDO; BENSON, 2003.

María et al. (2003) analisou o comportamento de aves separando-as em quatro grupos de sete animais. Os animais foram identificados com números na parte superior, entre as asas (Figura 11). As imagens foram realizadas por observadores humanos em curtos períodos de tempo (30 minutos), e os resultados submetidos à análise estatística utilizando *Detrended Fluctuation Analyses* (DFA). A autora observou que, em condições de estresse (limitação de alimentos), ocorreu diminuição de movimentações complexas.

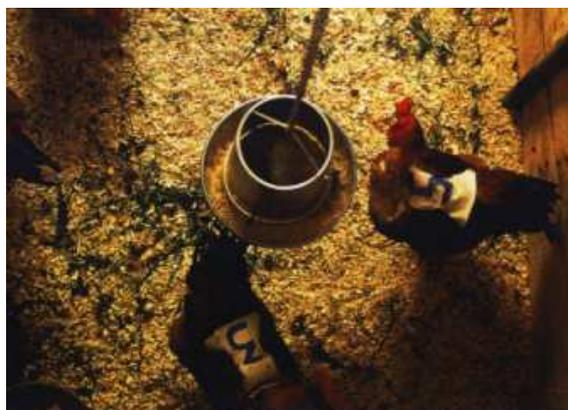


Figura 11 - Aves marcadas

Fonte: MARÍA et al., 2004.

A fim de avaliar o comportamento de aves de corte em diferentes condições térmicas, Mogami (2009) coletou imagens diariamente em intervalos de 1 minuto. Foram monitorados também a temperatura e a umidade relativa do ar em intervalos de 15 minutos, ambos durante a fase final de criação das aves. A câmera utilizada foi posicionada no teto apontada para baixo e as técnicas de visão computacional utilizadas foram subtração de fundo, morfologia e segmentação (Figura 12).

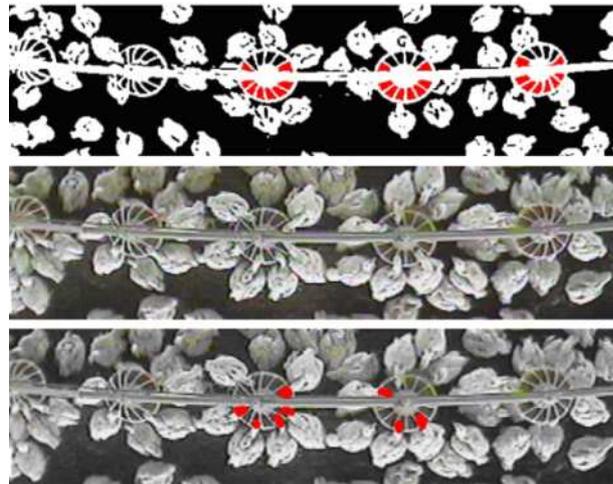


Figura 12 - Indicação dos comedouros

Fonte: MOGAMI, 2009.

Fujii et al. (2009) desenvolveu um sistema para rastreamento de frangos para análise de comportamento a fim de identificar infecções por gripe aviária, sua teoria é que aves infectadas podem ser identificadas observando sua locomoção, seu ciclo de sono e acordar. O algoritmo utilizado foi o *particle filter* e como conceito o autor utilizou a forma geométrica de uma elipse para identificar os frangos (Figura 13). As imagens foram obtidas por uma câmera com lente olho de peixe posicionada no topo apontada para baixo (Figura 14). O sistema mostrou-se apto a reconhecer e rastrear frangos, embora a duração do rastreamento não foi satisfatória.



Figura 13 - Elipses sobre as aves

Fonte: Fujii et al. (2009)

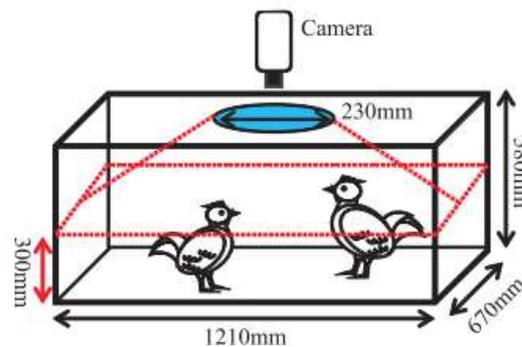


Figura 14 – Posicionamento da câmera.

Fonte: Adaptado de Fujii et al., 2009.

Um sistema de rastreamento de frangos em aviários utilizando câmeras infravermelhas foi desenvolvido por Algeri (2014). O autor utilizou como método de rastreamento a técnica fluxo óptico (Figura 15). Seus resultados possibilitaram o rastreamento das aves além de permitir a obtenção de informações como tempo em bebedouro, comedouro e descansando. No entanto, devido a problemas como a baixa qualidade das imagens e do ângulo de gravação, os tempos de rastreamento não foram satisfatórios. Como sugestão, o autor indica a utilização de câmeras com melhor qualidade e posicionadas de cima para baixo, pois o ângulo de gravação gerou oclusão e sobreposição das aves (Figura 16).



Figura 15 - Caminho percorrido pela ave durante o rastreamento

Fonte: Algeri, 2014.

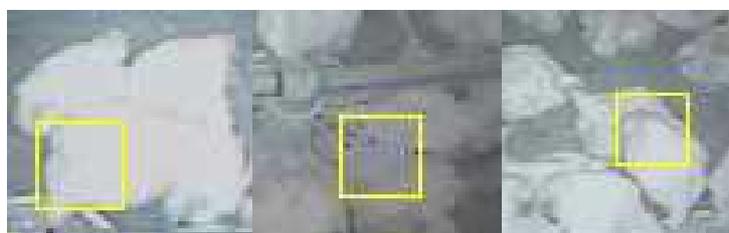


Figura 16 – Sobreposição das aves

Fonte: Algeri (2014)

Em síntese, a Tabela 1 exibe um comparativo entre os trabalhos relacionados com frangos e destaca os objetivos das pesquisas, métodos utilizados e duração.

Tabela 1 – Trabalhos relacionados com frangos

Autores	Objetivo	Método Utilizado	Duração
Sergeant et al, 1998	Rastreamento de frangos	Subtração de fundo e morfologia matemática	Não informada
Figueiredo e Benson, 2003	Rastreamento de frangos	Subtração de fundo e morfologia matemática	Não informada
María et al., 2004	Avaliar comportamento	Observação humana	Não informada
Mogami, 2009	Evolução de massa corporal	Subtração de fundo e morfologia matemática	Não informada
Fujii et al, 2009	Rastreamento de frangos	Particle Filter	Não satisfatória
Algeri, 2014	Rastreamento de frangos	Fluxo óptico	Não satisfatória

Fonte: o autor

3.2 RASTREAMENTO DE PESSOAS

Em multidões de pessoas, a cabeça é a parte com maior visibilidade, e por isso, são utilizadas como parâmetro de detecção. Ali e Dailey (2012) introduziram um algoritmo de detecção de múltiplos objetos em densas multidões com alta oclusão que utiliza detecção de cabeças humanas e rastreamento em um único *framework*. Para detecção, os autores utilizaram os métodos Viola e Jones, AdaBoost, e *particle filter* para rastreamento. Seus resultados diminuíram os erros de rastreamento, mas, este problema ainda continua em aberto devido a sua dificuldade e complexidade.

Jin e Bhanu (2012) propuseram um método de rastreamento de pedestres utilizando múltiplas câmeras com diferentes visões da mesma cena. O método possui dois grandes componentes. O primeiro é o algoritmo de rastreamento por detecção baseado em informações de apenas uma câmera e o segundo é o responsável por estimar a posição real do pedestre no plano, baseado nas informações do primeiro. Para a implementação do algoritmo de rastreamento por detecção, os autores combinaram os métodos *particle filter*, *boosting classifier* e um detector de humanos.

Para Kratz e Nishino (2012), o maior desafio no rastreamento de pessoas em multidões é o grande número de pedestres e a frequente oclusão que eles produzem. No entanto, esse movimento pode contribuir, pois exibe um padrão de estrutura temporal e espacial. Nesse trabalho, os autores construíram um modelo espaço-tempo da movimentação da multidão que utilizou o modelo oculto de Markov treinado com os padrões de movimentação da multidão.

Shao et al. (2013) rastreou individualmente pessoas em multidões, utilizando o método *particle filter* com uma combinação linear de *templates*. Os resultados provaram que o algoritmo gerou resultados satisfatórios em todos os tipos de cenas superlotadas.

Rahmatian e Safabakhsh (2014) desenvolveram um rastreador-por-detecção *online* de múltiplas pessoas utilizando combinações de classificadores de pessoas baseados em máquinas de vetores de suporte (*Support Vector Machine -SVM*) e o algoritmo Hungarian. O método não necessitou de treinamento e não impôs condições ao ambiente.

3.3 CLASSIFICADORES

Os classificadores *Haar-like* em cascata e LBP em cascata são apontados na literatura com os mais utilizados, pois estas técnicas possuem alta performance e são robustas, podendo até em alguns casos atingirem performances em tempo real. Suas utilizações vão além do uso acadêmico, estendendo-se principalmente à identificação de características humanas, porém seu uso é aplicável a qualquer tipo de objeto (CRUZ et al., 2015).

Cruz et al. (2015) comparou os classificadores *Haar-like*, LBP e HOG (*Histogram of Oriented Gradients*) para a detecção de estradas de concreto e asfalto em imagens de alta definição. O autor observou que *Haar-like* e LBP tiveram taxa de acerto de aproximadamente 80%, enquanto que HOG teve uma taxa de acerto de 54%.

Boussaa (2015) utilizou uma combinação do classificador *Haar-like* e rede neural artificial para classificar imagens de eletrocardiogramas de pessoas normais e doentes em tempo real. Esta combinação provou ser robusta fornecendo informações de suporte. O classificador *Haar-like* foi utilizado também por Zhao et al. (2016) para identificar tomates prontos para colheita, a partir da identificação dos frutos e classificá-los com o uso de análise de cores.

Hasan et al. (2017) comparou o classificador *Haar-like* com o *blob statistics* para identificar veículos no tráfego urbano. O classificador *Haar* teve acurácia de mais de 80%, enquanto que o *blob statistics* chegou a aproximadamente 66% de acurácia.

4 MATERIAL E MÉTODOS

4.1 MATERIAL

As imagens foram obtidas de um galpão indicado por meio da parceria com a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) Suínos e Aves de Concórdia (SC). O modelo de galpão selecionado foi o do tipo “*dark house*”, que se caracteriza por possuir o 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, 150 metros de comprimento, com área disponível de 2400m² e cama (cobertura do chão formada por maravalha) que já recebeu 8 lotes de produção. O aviário também possuía dez exaustores, nebulização interna e externa, iluminação e temperatura controladas, gerador de 170 cavalos de potência (utilizado em emergências) e sistema de aquecimento a lenha.

Para a gravação das imagens foi utilizada câmera da marca *Hikvision* modelo *IR Fixed Dome* (DS-2CD2110F-IWS), com recursos de *WIFI*, suporte a cartão micro SD de até 128 gigabytes, infravermelho 10 à 30 metros, com qualidade de 1.3 mega pixel, e com resolução máxima de 1280 x 960 *pixels* (Figura 17). A câmera não emite luz ou sinal sonoro.



Figura 17 – Câmera Hikvision.

Fonte: HIKVISION, 2017.

A aquisição das imagens foi realizada no verão de 2017 entre os dias 30/12/2016 e 14/02/2017.

4.2 MÉTODOS

4.2.1 Instalação, Posicionamento e Configuração da Câmera

O posicionamento da câmera seguiu o proposto por María et al. (2004), Mogami (2009), Fujii et al. (2009) e Algeri (2014), utilizando para tanto, câmera direcionada de cima para baixo em ângulo reto (Figura 18).

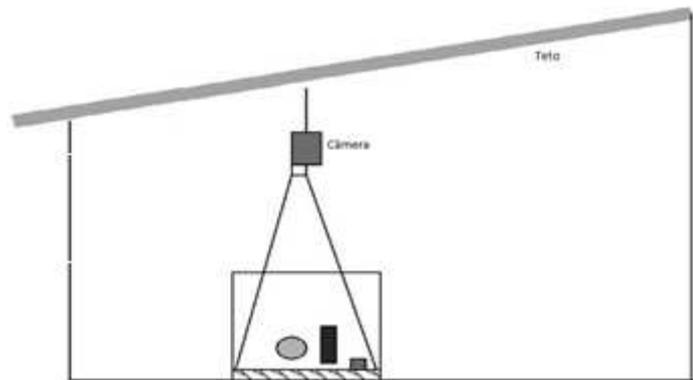


Figura 18 – Posicionamento da Câmera.

Fonte: Adaptado de MARÍA et al., 2004.

A Figura 19 demonstra a câmera posicionada dentro do aviário, a 2,10 m de distância das aves, a 75 m da entrada, isto é no centro do aviário. Para gravação foram utilizadas as seguintes configurações: gravação em infravermelho, 10 frames por segundo, definição da imagem 704 x 576 e armazenamento em cartão SD de 128 *gigabytes*.



Figura 19 – Posicionamento da câmera no aviário.

Fonte: O Autor.

Devido à restrição do cartão de memória da câmera, a cada seis dias a câmera foi removida para extração dos vídeos do cartão, processo que durava 24 horas. Após extração dos vídeos, a câmera era reposicionada e as imagens reiniciadas, este processo foi executado seis vezes.

4.2.2 Tempo e condições de alojamento das Aves

Foram alojadas 34.417 aves da linhagem COBB (30/12/2016), correspondendo inicialmente a 14,34 aves por metro quadrado. Durante o processo de engorda (45 dias) foram quantificados a quantidade de água e ração consumidos, bem como o número de aves mortas.

Após 45 dias de confinamento, 33.208 aves foram recolhidas, pesadas (92.680 Kg) acomodadas em 9 caminhões e encaminhadas à indústria.

4.2.3 Visão geral da proposta de *Software*

A proposta teve por objetivo o desenvolvimento de *software*, ela foi dividida em duas etapas, na primeira etapa foram utilizados processos para identificação e posicionamento das aves. Na segunda etapa, as informações da primeira foram utilizadas como ponto de partida, e através delas juntamente com técnicas de rastreamento foi realizado o processo de rastreamento. A Figura 20 exemplifica de maneira geral o funcionamento do *software*.

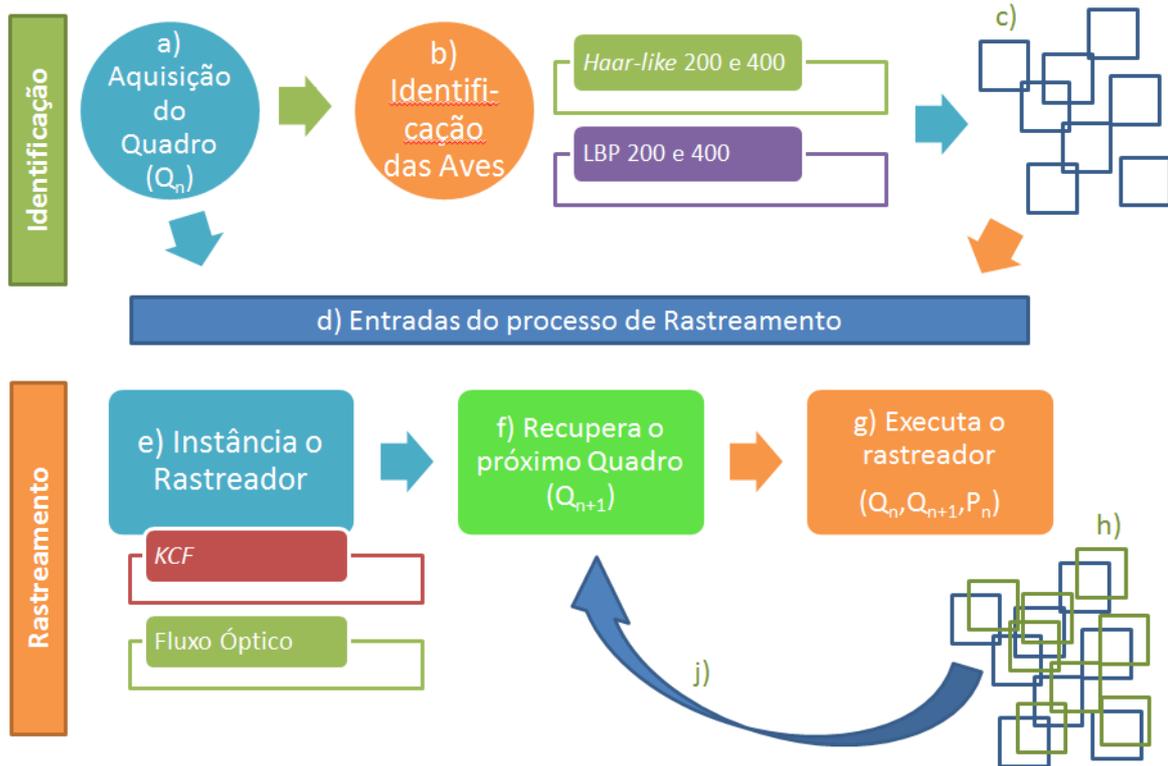


Figura 20 – Processo geral de rastreamento

Fonte: O Autor.

O processo é dividido basicamente em duas etapas principais, na primeira ocorre à identificação das aves, para isto, inicialmente o primeiro quadro da imagem é adquirido (Figura 20(a)), na sequencia um dos algoritmos de classificação é aplicado (Figura 20(b)), gerando a lista de aves encontrada (Figura 20(c)). A lista de aves encontrada e o quadro inicial são utilizados como parâmetros de entrada (Figura 20(d)) para a segunda etapa do processo. A segunda etapa é responsável pelo rastreamento das aves, inicialmente é instanciado o algoritmo de rastreamento (Figura 20(e)), em seguida o próximo quadro da imagem é recuperado (Figura 20(f)), então, o algoritmo de rastreamento utilizando o quadro anterior/inicial, o novo quadro e a posição inicial das aves realiza a estimacão das novas posições das aves (Figura 20(h)), as novas posições, juntamente com o novo quadro são utilizados para estimar a próxima posição das aves (Figura 20(j)), desta forma inicia-se o laço de rastreamento até o fim do vídeo ou até o tempo escolhido.

4.2.4 Identificação das Aves

A localização das aves nas imagens foi realizada utilizando-se dois algoritmos distintos: *Haar-like* (Viola e Jones, 2001) e LBP (Ojala et al., 1994).

Um esquema representativo do método proposto para a identificação das aves está descrito na Figura 21, separado em três etapas: seleção, treinamento e validação.

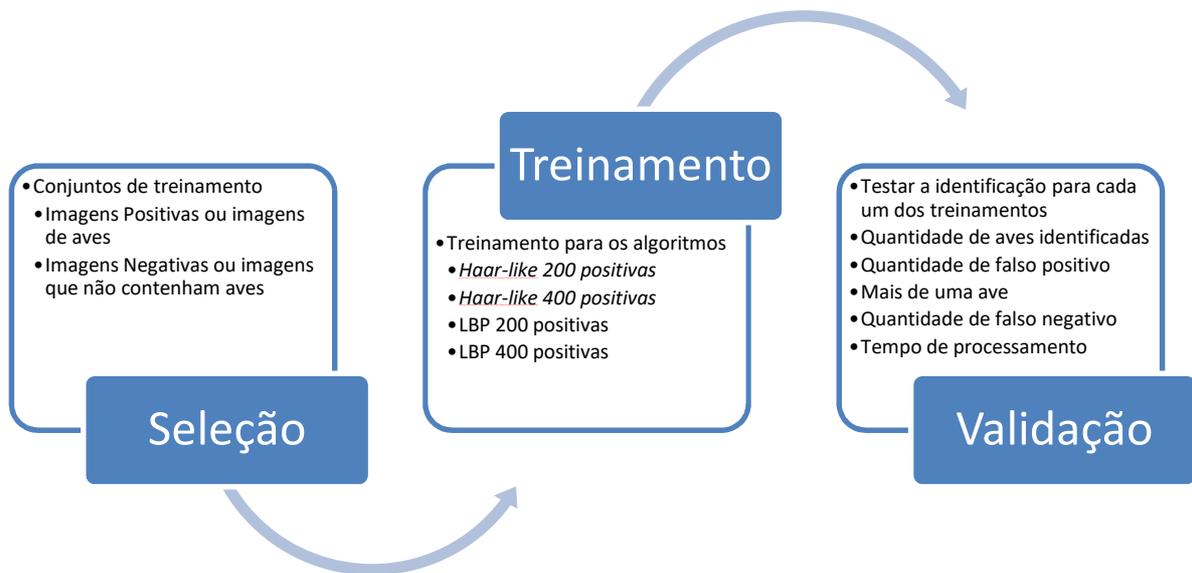


Figura 21 – Processo para selecionar, treinar e validar os classificadores.

Fonte: O Autor.

4.2.4.1 Seleção

Para o processo de seleção foi necessário criar dois conjuntos de treinamento, sendo um com imagens positivas, que continham as aves, e o outro 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 seleção, as imagens foram salvas em arquivos e pastas separadas. Através da seleção manual das amostras positivas e negativas foi possível construir um banco com 476 amostras positivas e 300 negativas.

4.2.4.2 Treinamento

Para a etapa de treinamento, as imagens foram indexadas em dois arquivos, um com as imagens positivas e outro com as imagens negativas. Para isto, foram utilizadas funcionalidades disponíveis na biblioteca OpenCV versão 3.2.

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

Os treinamentos foram executados em computador marca Dell, modelo XP, Intel Core i7-4790 3.6GHz, 4 núcleos, 8 processadores lógicos, 16GB de memória RAM (*Random Access Memory*), sistema operacional Windows Pro 10 x64.

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

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

4.2.4.3 Validação

Para o processo de validação foram selecionadas quatro imagens por semana, gerando um total de 24 imagens, 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;
- Tempo de processamento.

4.2.5 Rastreamento

Para o processo de rastreamento foram utilizadas duas abordagens. A primeira, denominada KCF que foi proposta por Henriques et al. (2012) e a segunda, baseada em fluxo óptico, foi proposta por Algeri (2014). Ambas as abordagens utilizaram como parâmetros de entrada as classificações geradas pelos classificadores *Haar-like* e LBP em cascata. A Figura 20 exemplifica o processo utilizado para o rastreamento.

A primeira etapa do processo consiste na aquisição do primeiro quadro (Q_n), seguida da etapa de identificação das aves, em que foram utilizados os classificadores *Haar-like* 200, *Haar-like* 400, LBP 200 e LBP 400. A saída dos classificadores determinam as posições iniciais das aves. Para o processo de rastreamento foram utilizados como parâmetros de entrada as posições das aves e o quadro inicial. Em seguida, o rastreador foi inicializado, recuperou-se o próximo quadro e executado o processo de rastreamento, gerando a nova posição das aves.

Foram selecionados quatro vídeos por semana de gravação, gerando um total de 32 vídeos para avaliação. A avaliação foi executada para cinco minutos de gravação, e foram monitoradas três aves de cada vídeo. O processo registrou a rota de cada uma das aves e, através de avaliação visual, foram identificados quantos quadros a ave percorreu e o tempo de percurso.

4.2.6 Geração de informações para avaliação

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

fabricação aplicadas à produção avícola, levando em consideração, entre outros fatores, o bem-estar das aves (SOUZA, 2014).

Os critérios observados nas filmagens foram: a movimentação das aves e densidade de alojamento (Kg/m^2). Para a avaliação da capacidade de movimentação das aves, foram utilizados os indicadores gerados no processo de rastreamento. Para avaliação da quantidade de quilogramas de aves por metro quadro, foi delimitada esta área no centro da imagem (Figura 22) 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.

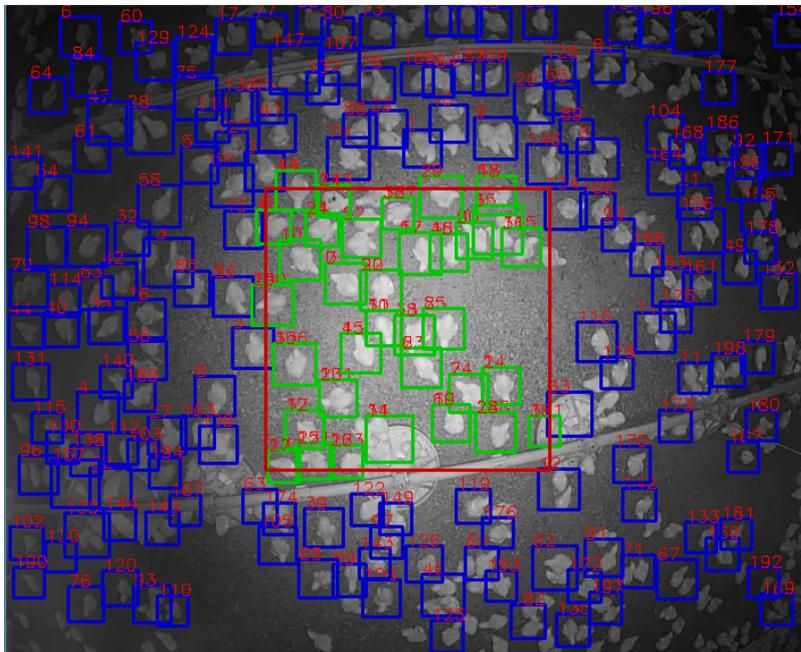


Figura 22 – Delimitação de um m^2

Fonte: O Autor

Para o processo de contagem também foi necessário observar a evolução do tamanho das aves, devido a isto foi necessário reajustar o tamanho do quadro de marcação, semana a semana. A Tabela 2 apresenta o tamanho dos quadros mínimos e máximos por semana. O algoritmo ignorava indicações de aves onde o quadro não estava entre o mínimo e máximo.

Tabela 2 – Evolução do tamanho do quadro de marcação das aves

Semana	Mínimo (<i>pixel</i>)	Máximo (<i>pixel</i>)
1	20x20	50x50
2	22x22	60x60
3	25x25	70x70
4	27x27	80x80
5	30x30	90x90
6	30x30	100x100

Fonte: O Autor

4.2.7 Análises estatísticas

A análise estatística dos resultados obtidos foi realizada utilizando o *software Statistica v. 7.0*. Foram avaliadas as médias dos experimentos e a significância de suas diferenças, empregando o teste de Tukey ao nível de confiança de 95%.

5 RESULTADOS E DISCUSSÃO

5.1 AQUISIÇÃO DAS IMAGENS

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. A Figura 23 exhibe alguns exemplos de imagens adquiridas neste processo com a semana correspondente indicada.

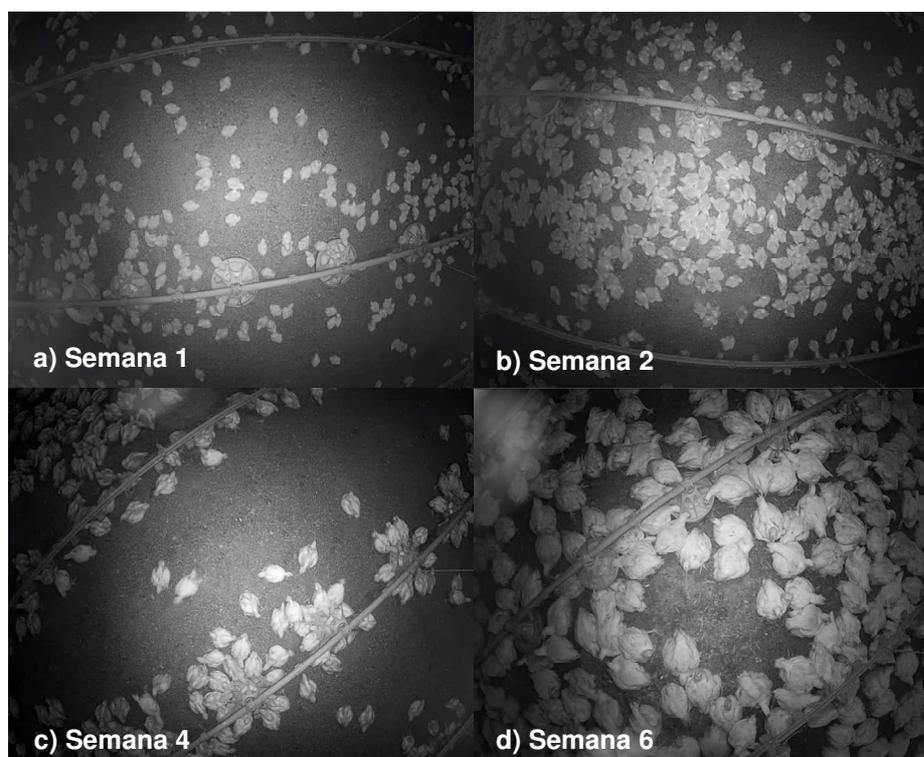


Figura 23 – Imagens adquiridas

Fonte: O autor

As imagens adquiridas foram gravadas em cartão SD e submetidas a processamento.

5.2 IDENTIFICAÇÃO

Os classificadores *Haar-like* e LBP foram treinados em cascata. A Figura 24 exhibe as taxas de aceitação encontradas e o tempo de processamento utilizado.

Como pode ser observado, o classificador *Haar-like* obteve a melhor performance em treinamento, uma vez que o classificador LBP levou aproximadamente 36 minutos para ultrapassar o limiar desejado de treinamento, enquanto que o classificador *Haar* levou aproximadamente 5 minutos.

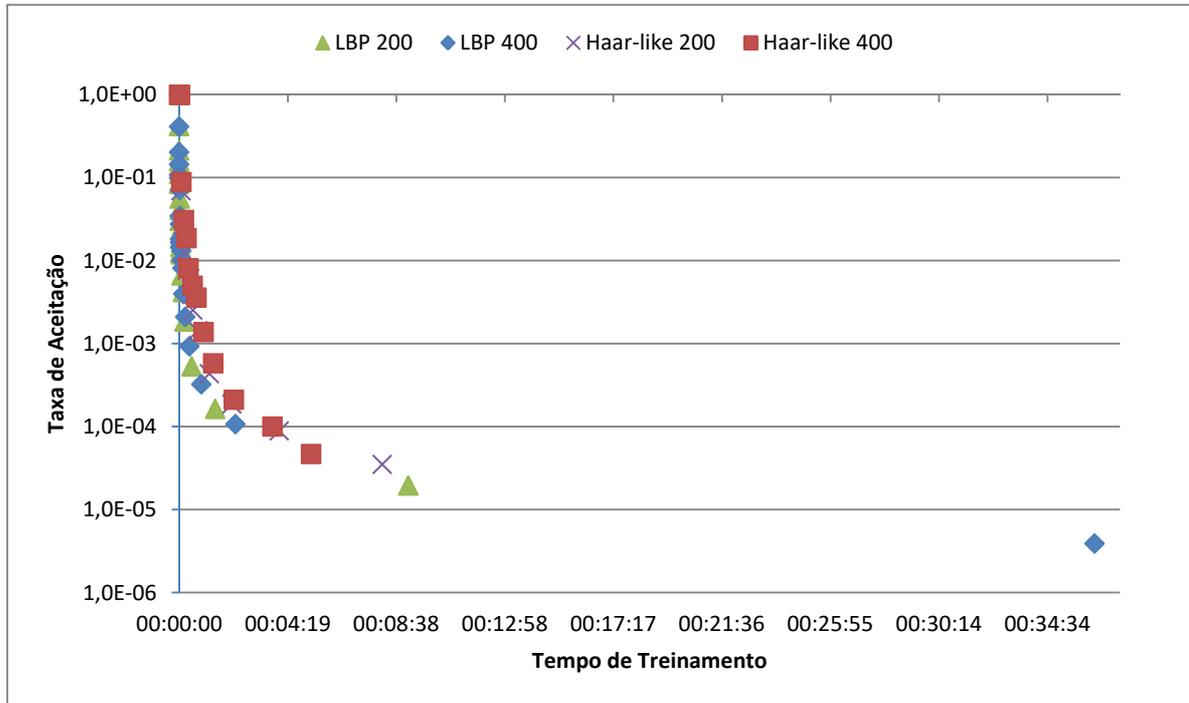


Figura 24 – Taxa de aceitação por tempo de treinamento

Fonte: O autor

Ambos os algoritmos foram testados no quadro de número 3000 de cada um dos vídeos gerados, totalizando 2412 imagens. O teste também gerou uma tabela com os tempos de processamento e a quantidade de aves encontradas em cada imagem para cada um dos classificadores. Este processo de identificação foi utilizado para início do rastreamento. A abordagem é similar à proposta por Ali e Dailey (2012) que identificaram cabeças de pessoas em multidões para posteriormente aplicar outra técnica de rastreamento.

A Figura 25 exhibe as classificações geradas pelo classificador *Haar-like* em cascata, e a Figura 26 exhibe as classificações geradas pelo classificador LBP. Ambas as imagens estão separadas em semanas e cada linha representa uma semana.

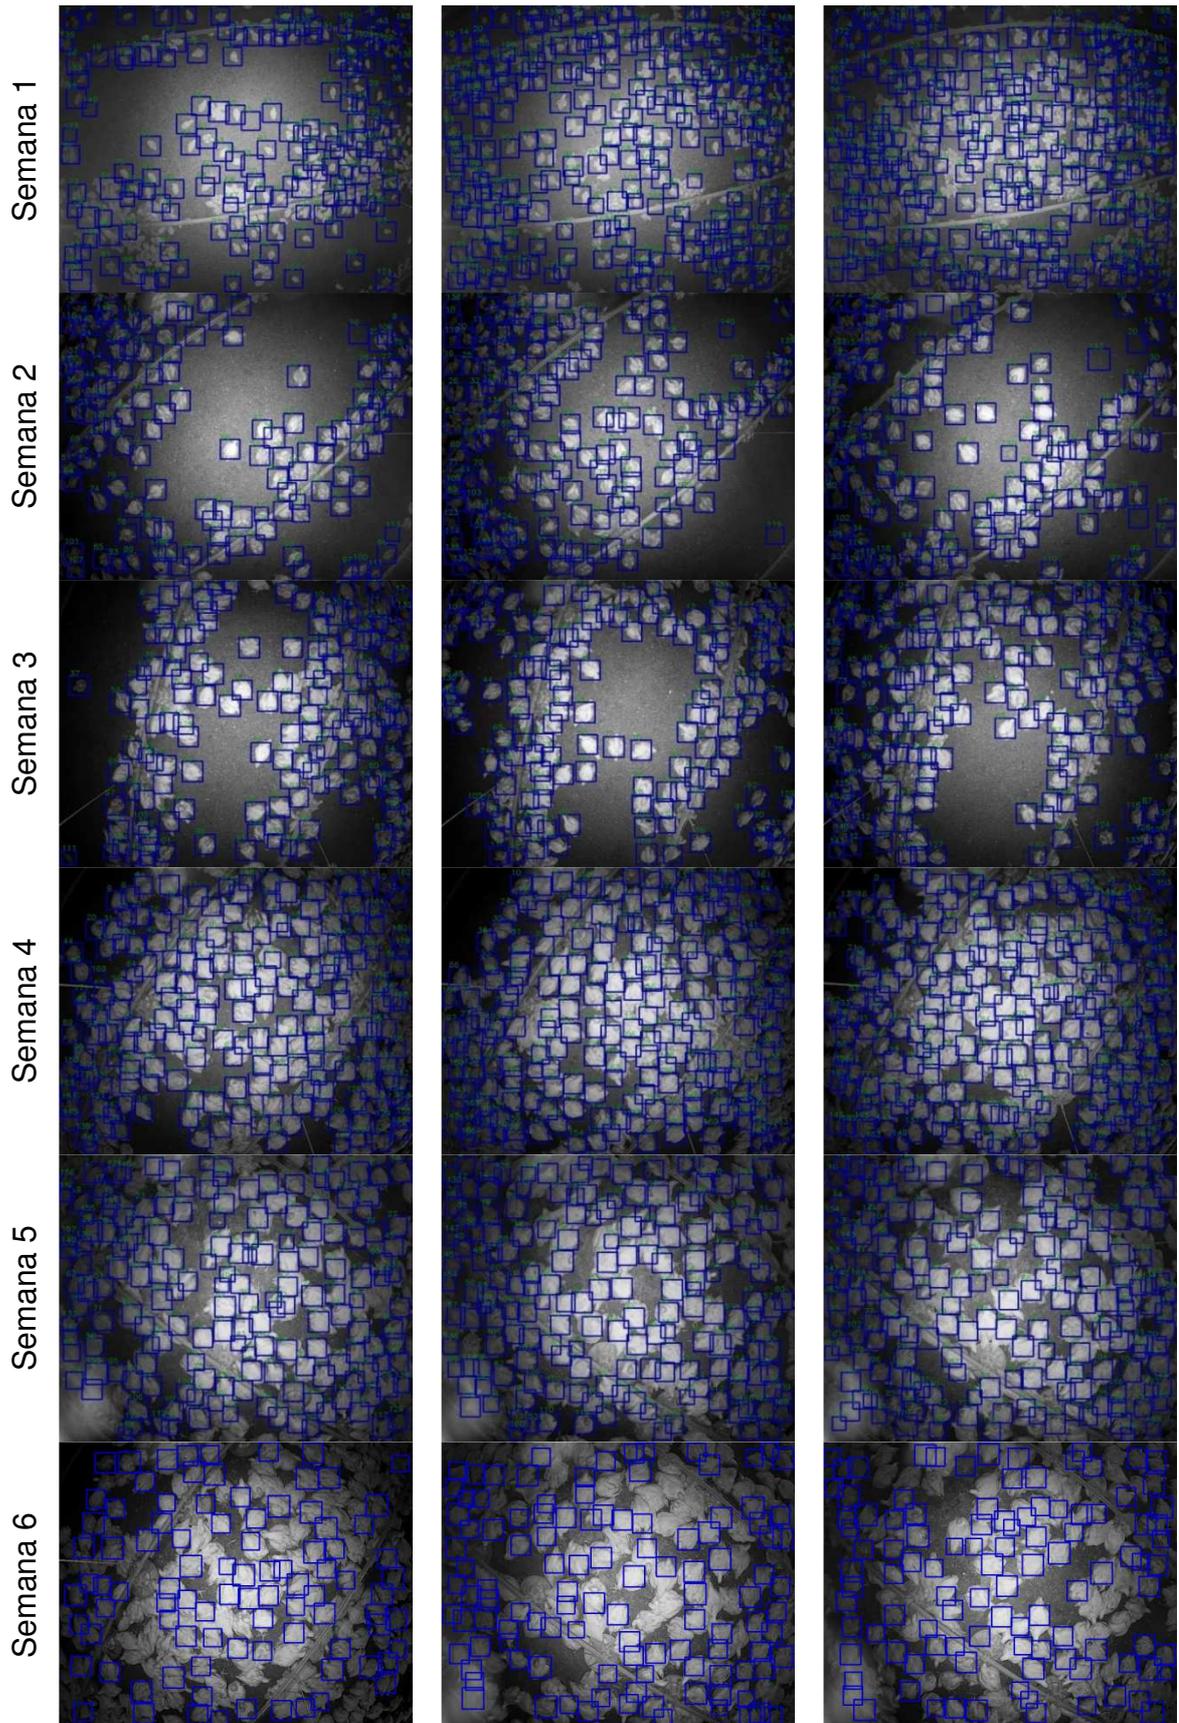


Figura 25 – Classificações geradas pelo classificador *Haar-like* em cascata para todas as semanas

Fonte: O Autor

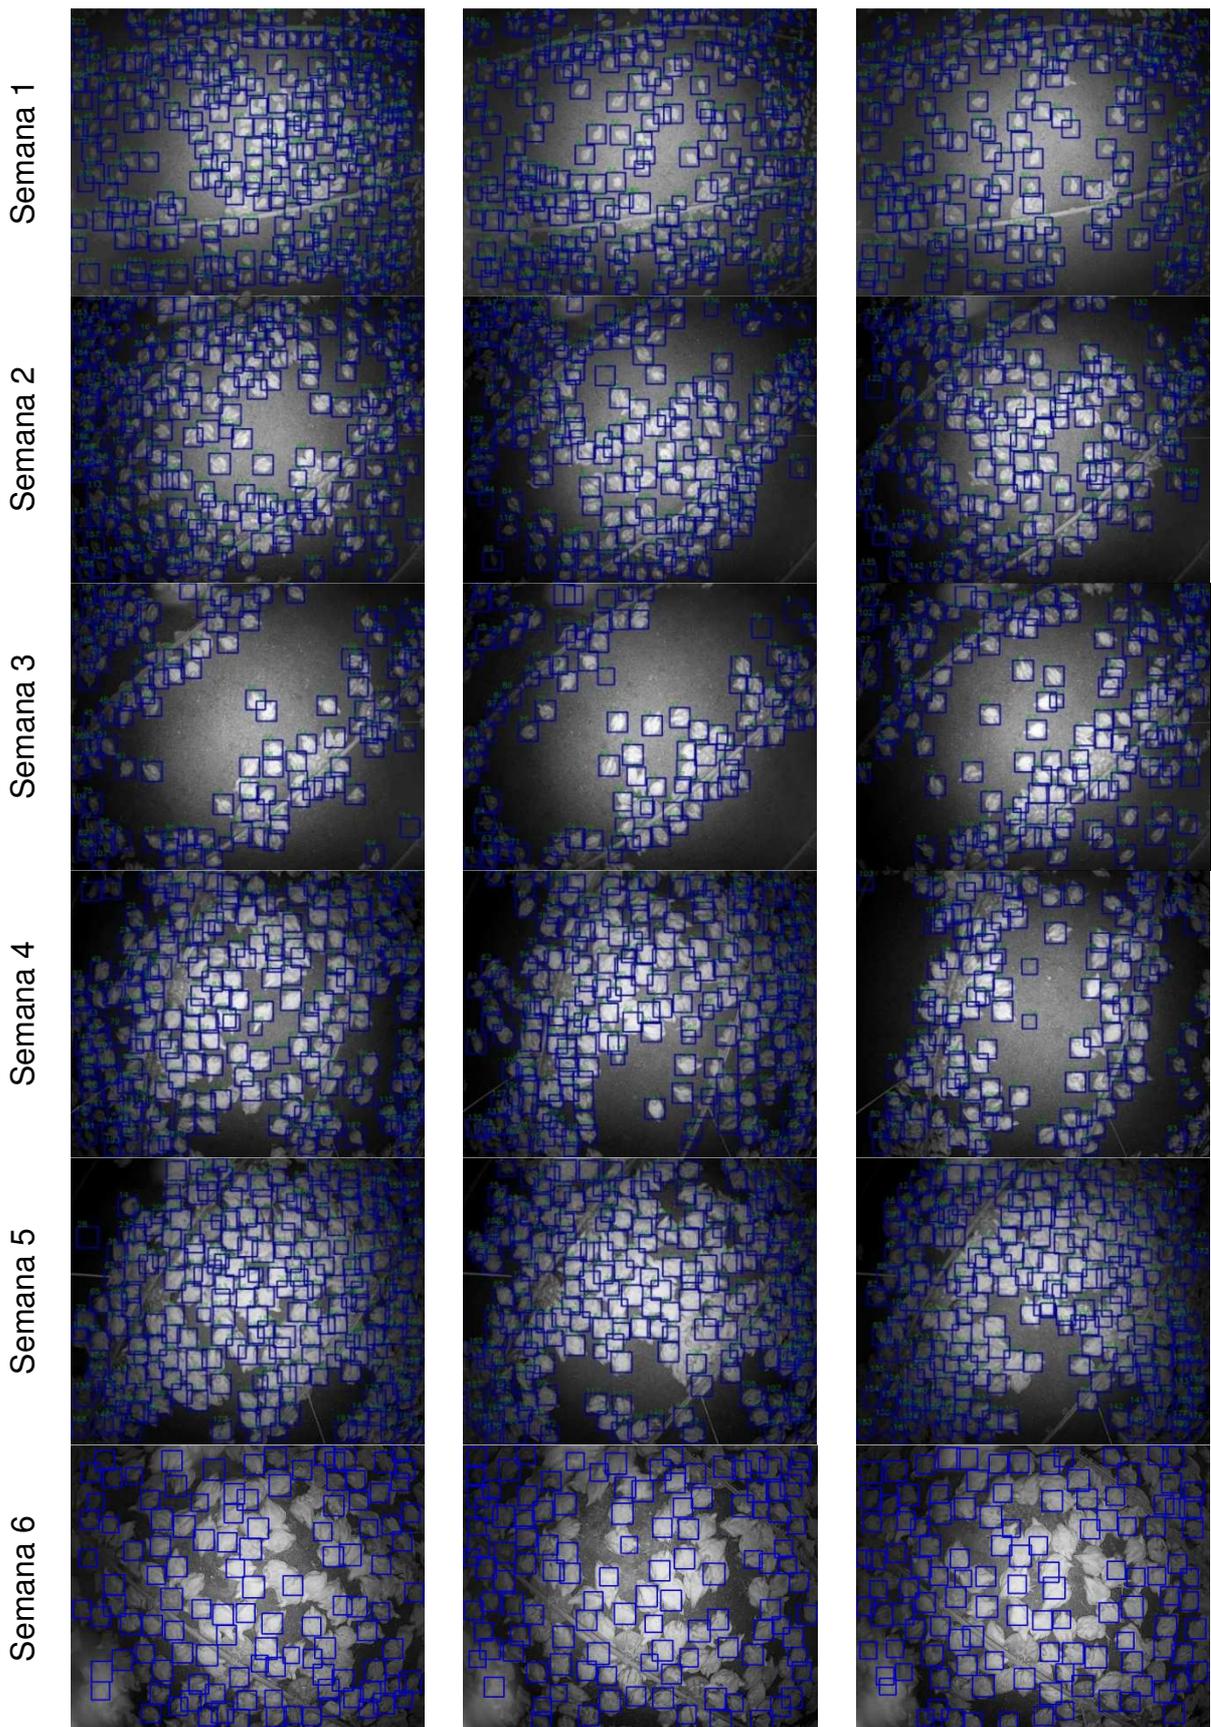


Figura 26 - Classificações geradas pelo classificador LBP em cascata para todas as semanas.

Fonte: O Autor

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 3.

Tabela 3 - Comparação entre os classificadores

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)

Fonte: O Autor

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.

5.3 RASTREAMENTO

O processo de rastreamento foi executado utilizando os quatro classificadores (32 vídeos), separados em seis semanas para três aves em cada vídeo, gerando um total de 576 registros.

A comparação dos algoritmos de rastreamento foi realizada utilizando cinco parâmetros: tempo médio de rastreamento, média de *pixels* por segundo, tempo médio de processamento, média de quadros monitorados e distância média em *pixels*. A Tabela 4 apresenta os resultados gerais e por rastreador para as seis semanas do estudo.

Tabela 4 – Comparação geral e entre os rastreadores entre as semanas, para os parâmetros tempo médio de rastreamento, média de *pixels* por segundo, tempo médio de processamento, média de quadros monitorados e distância média em *pixels*.

Parâmetro	Rastreador	Sem 1	Sem 2	Sem 3	Sem 4	Sem 5	Sem 6
Tempo médio de rastreamento (s)	Geral	129,51 ^a (11,06)	161,76 ^a (11,67)	126,01 ^a (10,86)	151,14 ^a (10,98)	246,92 ^b (8,65)	237,88 ^b (7,91)
	Fluxo óptico	68,16 ^a (10,73)	119,75 ^b (14,18)	84,82 ^{ab} (11,62)	105,72 ^{ab} (12,80)	214,98 ^c (14,08)	213,50 ^c (11,35)
	KCF	190,85 ^a (14,80)	203,76 ^a (16,56)	167,19 ^a (16,42)	196,55 ^a (15,35)	278,87 ^b (7,80)	262,26 ^b (9,90)
Média de <i>pixels</i> por segundo	Geral	4,11 ^a (0,37)	4,04 ^a (0,31)	7,35 ^b (0,44)	9,23 ^c (0,73)	5,98 ^b (0,27)	9,38 ^c (0,25)
	Fluxo óptico	4,26 ^a (0,58)	3,01 ^a (0,23)	7,54 ^b (0,67)	10,72 ^c (1,27)	7,20 ^b (0,21)	10,93 ^c (0,17)
	KCF	3,96 ^a (0,46)	5,07 ^a (0,53)	7,16 ^b (0,56)	7,74 ^b (0,68)	4,77 ^a (0,42)	7,83 ^b (0,35)
Tempo médio de processamento (s)	Geral	49,77 ^a (40,98)	66,78 ^a (50,50)	50,553 ^a (41,45)	68,03 ^a (51,10)	126,12 ^b (66,42)	119,17 ^b (60,77)
	Fluxo óptico	39,71 ^a (6,67)	69,78 ^a (8,94)	46,96 ^a (6,45)	74,46 ^a (9,22)	164,57 ^b (10,81)	156,16 ^b (9,35)
	KCF	59,82 ^a (4,67)	63,77 ^a (5,19)	54,12 ^a (5,48)	61,58 ^a (4,80)	87,69 ^b (2,44)	82,16 ^b (3,11)
Média de quadros monitorados	Geral	1295,08 ^a (110,59)	1617,58 ^a (116,71)	1260,05 ^a (108,59)	1511,39 ^a (109,80)	2469,24 ^b (86,52)	2378,78 ^b (79,12)
	Fluxo óptico	681,68 ^a (107,31)	1197,52 ^b (141,88)	848,25 ^{ab} (116,20)	1057,22 ^{ab} (128,09)	2149,81 ^c (140,86)	2135,00 ^c (113,58)
	KCF	1908,48 ^a (148,04)	2037,65 ^a (165,60)	1671,85 ^a (164,15)	1965,54 ^a (153,48)	2788,67 ^b (77,96)	2622,56 ^b (99,38)
Distância média em <i>pixels</i>	Geral	384,10 ^a (55,76)	622,32 ^{ab} (78,08)	813,35 ^{bc} (78,20)	1037,92 ^c (76,71)	1383,03 ^d (75,85)	2182,3 ^e (83,88)
	Fluxo óptico	136,57 ^a (10,25)	301,45 ^{ab} (33,83)	468,51 ^b (50,61)	770,88 ^c (79,50)	1460,81 ^d (94,57)	2302,38 ^e (115,37)
	KCF	631,64 ^a (99,29)	943,19 ^{ab} (138,27)	1158,19 ^b (130,77)	1304,96 ^b (120,14)	1305,24 ^b (118,56)	2062,23 ^c (120,49)

Fonte: O Autor

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.

Vale ressaltar que para cada avaliação tem-se 5 minutos, com gravação a 10 quadros por segundo. Logo, gera-se um total máximo de 300s e 3000 quadros.

Para o parâmetro ‘tempo médio de rastreamento’ ambos os algoritmos obtiveram suas melhores performances nas semanas 5 e 6, com tempos médios acima de 200 s, o mesmo ocorre para o parâmetro ‘tempo médio de processamento’, porém com médias diferentes onde o KCF foi aproximadamente 50% mais rápido que o fluxo óptico.

Tabela 5 – Comparação entre os algoritmos de rastreamento, quanto a tempo médio de rastreamento, média de *pixels* por segundo, tempo médio de processamento, média de quadros monitorados e distância em *pixels*.

	Fluxo Óptico	KCF
Tempo médio de rastreamento (s)	134,49 ^a (6,14)	216,58 ^b (6,10)
Média de <i>pixels</i> por segundo	7,28 ^b (0,31)	6,09 ^a (0,22)
Tempo médio de processamento (s)	91,95 ^b (4,60)	68,19 ^a (1,93)
Média de quadros monitorados	1344,92 ^a (61,41)	2165,79 ^b (60,99)
Distância média em <i>pixels</i>	906,77 ^a (53,60)	1234,24 ^b (55,67)

Fonte: O Autor

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 ($\alpha < 0,05$).

Em todos os quesitos avaliados (Tabela 5) ambos os rastreadores apresentaram diferença significativa ($\alpha < 0,05$). Quanto ao ‘tempo médio de rastreamento’, o rastreador KCF obteve resultado aproximadamente 60% superior ao fluxo óptico (216,58 para 134,49). Em relação ao ‘tempo médio de processamento’ o rastreador KCF apresentou performance média superior ao fluxo óptico em aproximadamente 34 segundos (68,19s para 91,95s) ou seja, aproximadamente 35% mais performático. O KCF também obteve uma média de quadros percorridos superior ao fluxo óptico em aproximadamente 60% (2165,79 para 1344,92).

A avaliação dos classificadores (LBP 200, LBP 400, *Haar-like* 200 e *Haar-like* 400) quanto à influência no processo de rastreamento também foi realizada. Foram considerados os parâmetros tempo médio de rastreamento, média de *pixels* por segundo, tempo médio de processamento, média de quadros monitorados e distância média em *pixels*. Não houve diferença estatística em nenhum dos testes, indicando que nenhum parâmetro apresentou influência nesses resultados.

Um dos problemas encontrados durante o processo de rastreamento foi a oclusão pelas barras de suporte, passagem de água e alimentação, quando as aves passam por de baixo destas barras o processo de rastreamento cessa, a Figura 27 exemplifica a situação.

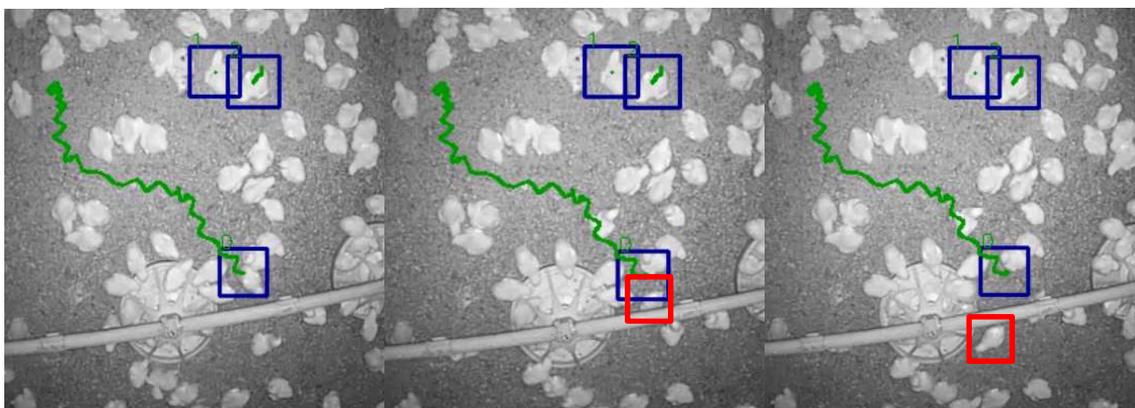


Figura 27 – Oclusão pela barra de suporte

Fonte: O Autor

5.4 AVALIAÇÃO DAS INFORMAÇÕES

O processo de geração de informações para avaliação foi dividido em duas etapas. Na primeira utilizou-se o processo de classificação para identificar o número de aves por metro quadrado. Para este processo, foram avaliados, de maneira aleatória, quatro vídeos por semana. Destes vídeos, foram avaliados 20 quadros, em intervalos de 1000 quadros, gerando um total de 1920 avaliações.

A comparação entre os classificadores e as semanas quanto à quantidade média de aves contidas em um metro quadrado é apresentada na Tabela 6 e na Figura 28. 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 é possível observar a

queda da densidade de aves por metro quadro na terceira semana, isto foi devido à retirada das contenções do aviário, 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 6 - Número médio de aves em um m² por classificador e semana

Classificador	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Semana 6
Haar-like 200	34,76 ^d (5,70)	19,85 ^a (7,09)	11,46 ^b (7,53)	20,51 ^a (5,82)	19,41 ^a (3,17)	14,80 ^c (2,34)
Haar-like 400	38,08 ^d (5,52)	20,51 ^a (7,79)	11,92 ^b (7,62)	22,03 ^a (6,41)	21,28 ^a (3,65)	17,01 ^c (2,68)
LBP 200	29,73 ^e (6,03)	15,75 ^d (5,95)	10,17 ^b (6,34)	18,61 ^a (5,51)	18,33 ^a (3,89)	12,53 ^c (2,55)
LBP 400	32,93 ^d (5,73)	18,00 ^a (6,41)	11,03 ^b (6,34)	20,05 ^a (6,10)	19,68 ^a (3,33)	13,82 ^c (2,64)

Fonte: O Autor

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 ($\alpha < 0,05$). Desvio padrão está entre parênteses abaixo da média.

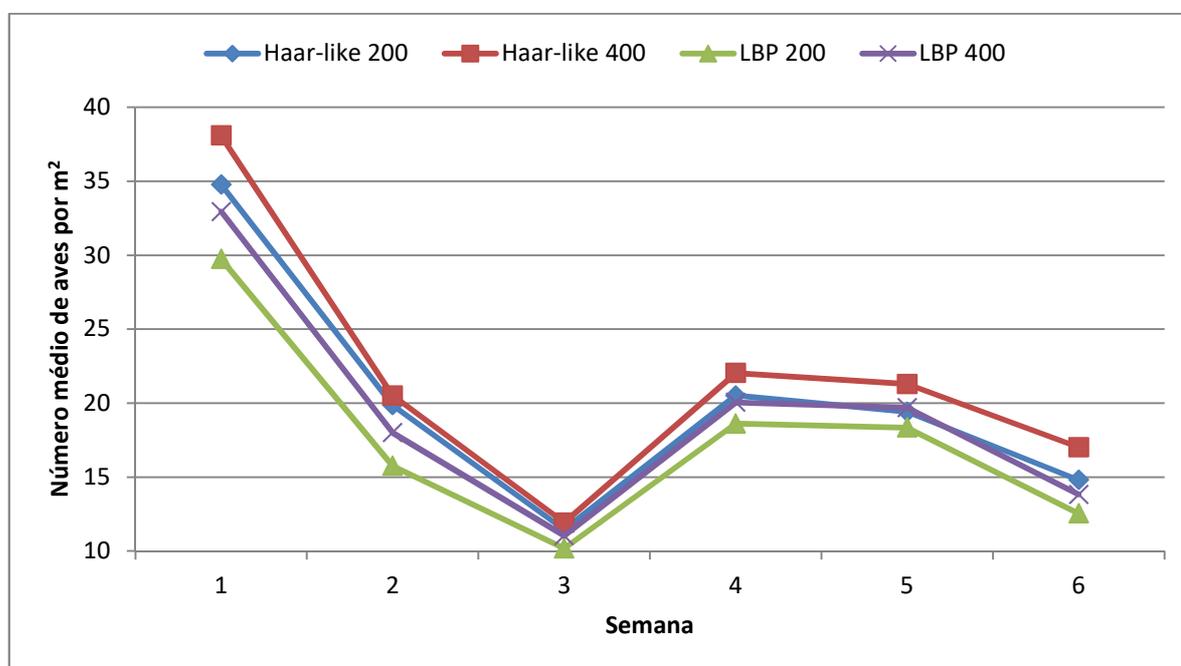


Figura 28 – Número médio de aves em um m² por semana e por classificador.

Fonte: O Autor.

As diretrizes seguidas pela *European Food Safety Authority* – EFSA, Global G.A.P (*Good Agricultural Practice*) e a legislação brasileira vigente definem quanto

ao peso máximo de aves por metro quadrado. As normas EFSA e Global G.A.P. sugerem não ultrapassar 40 Kg/m². Já a legislação brasileira permite densidades de até 42 Kg/m². Observando a Tabela 6, 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.

A Tabela 7 apresenta a evolução de peso e quantidade de aves por metro quadrado para cada um dos classificadores utilizados. O peso por ave por semana foi recuperado do borderô de produção, este peso foi tomado durante o processo produtivo através uma média de aves. A coluna Qtd, refere-se a 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.

Tabela 7 – 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	

Fonte: O Autor

Notas:

(1) * valores acima da legislação brasileira. A contagem das aves foi realizada apenas por uma câmera e ela não representa toda a extensão do aviário, desta forma os valores acima da legislação não indicam que o aviário está fora da legislação.

Tendo em vista que a área do galpão é de 2400m² e que foram entregues 34.417 aves, tem se aproximadamente 14,34 aves por m². Ao final do processo foram entregues 33.208 aves perfazendo 92.680kg. Ou seja, aproximadamente 38,6Kg/m², dentro do que rege e recomenda a legislação nacional e internacional.

Porém, segundo a Tabela 7 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 este 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).

A segunda etapa do processo de geração de informações para avaliação do bem-estar esta ligada a possibilidade de movimentação das aves, também descritas nas normas EFSA, Global G.A.P e a legislação brasileira. Para esta etapa foram utilizadas as informações de rastreamento. A Tabela 5 e a Figura 29 demonstram as distâncias médias percorridas pelas aves durante todas as semanas, exibindo assim, que existe livre movimentação. Pode-se também observar que a movimentação das aves cresce semana a semana, tendo como um pico de movimentação a sexta semana.

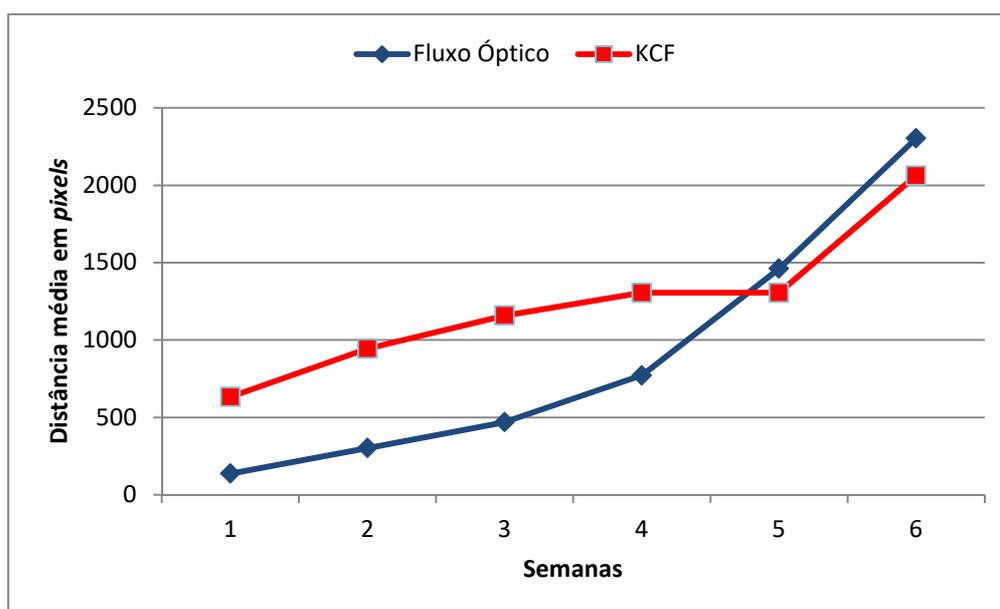


Figura 29 – Distância média em *pixels* por semana

Fonte: O Autor.

A Figura 29 apresenta crescimento da movimentação média em *pixels*, porém, antes de afirmar que existe realmente aumento na movimentação, deve-se levar em consideração que o tamanho das aves em *pixels* também aumenta. Desta forma, pode-se afirmar que é necessário correlacionar estas informações. Na Figura 30 pode ser observada semana a semana a evolução dos tamanhos das aves e a densidade de aves na imagem.

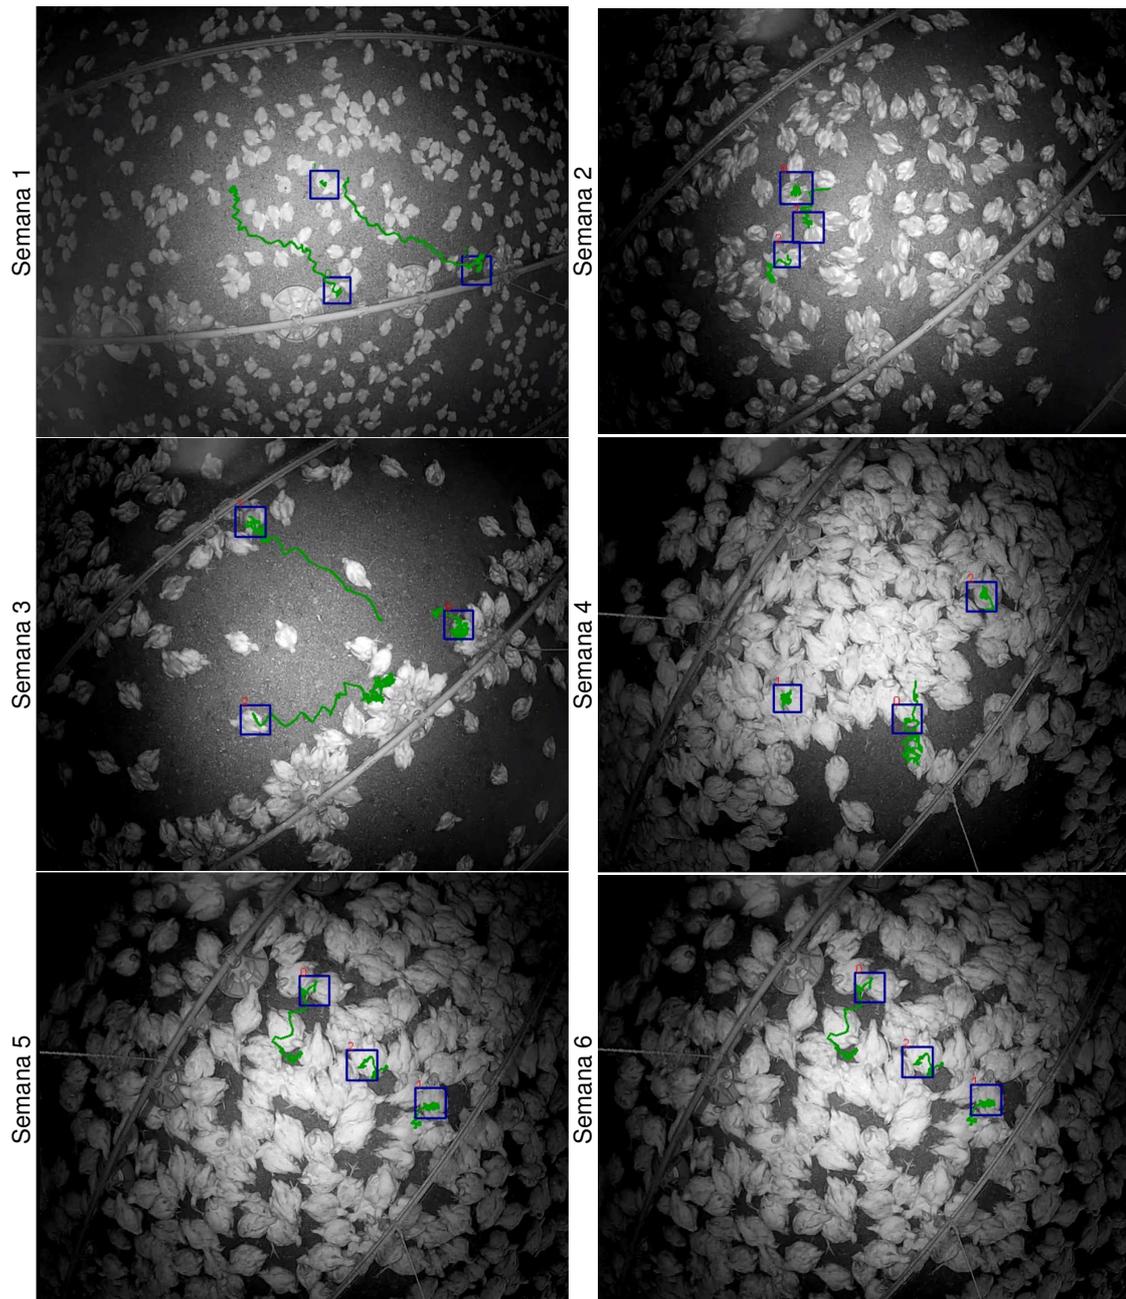


Figura 30 – Evolução do tamanho das aves e densidade

Fonte: O Autor.

A Tabela 8 apresenta a evolução do tamanho das aves em pixels semana a semana e a Figura 31 apresenta a comparação entre a movimentação e o tamanho das aves, observando esta comparação pode-se notar que a movimentação e o tamanho das aves crescem o que não é comparado observando-se os vídeos, analisando pontualmente pode-se identificar a causa. O algoritmo esta levando em

consideração pequenas movimentações, como exemplo a respiração que geralmente aumenta nas últimas semanas devido ao calor.

Tabela 8 – Tamanho das aves em *pixel* semana a semana

Semana	Amostras										Média de Tamanho em <i>pixel</i> ²
1		26x30		25x30		29x32		23x26		24x28	27,3
2		32x35		29x34		41x31		37x32		34x32	34,7
3		33x43		25x42		46x33		27x40		33x41	36,3
4		42x56		39x47		39x49		52x44		40x41	44,9
5		40x55		64x41		48x67		64x47		38x58	52,2
6		76x56		54x88		62x68		77x59		59x69	66,8

Fonte: O Autor.

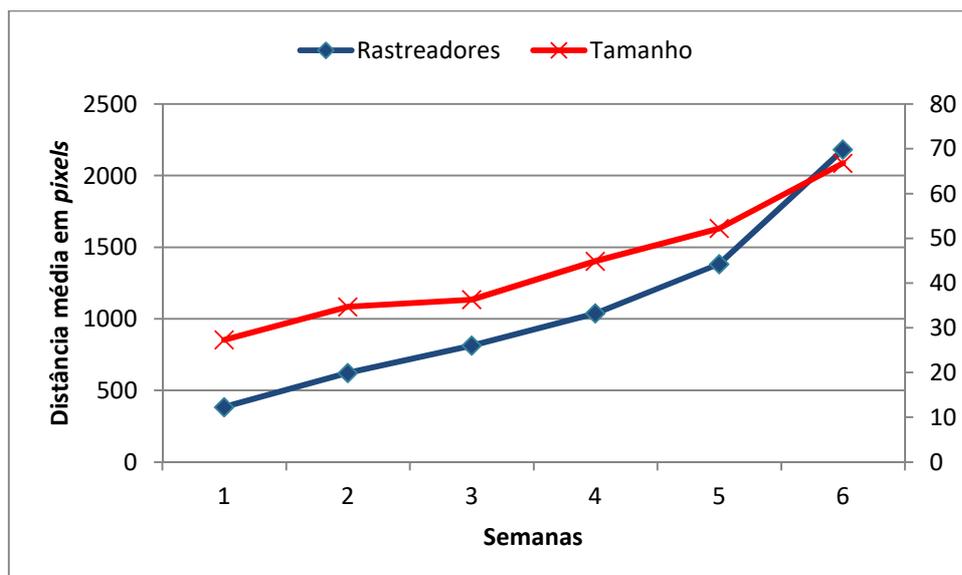


Figura 31 – Comparação da média de distância percorrida em *pixels* pelas aves e o tamanho das aves em *pixels* quadrados.

Fonte: O Autor.

6. CONCLUSÃO

Os classificadores (*Haar-like* e LBP) mostraram-se eficientes para aplicação de contagem de aves em cena. Ambos geraram informações práticas para o cálculo de densidade, um dos importantes indicadores de bem-estar em aviários.

O método de rastreamento KCF obteve melhor performance tanto para o tempo médio de processamento, quanto para o rastreamento. O mesmo foi capaz de monitorar as aves por mais tempo, e também obteve uma média de distância de monitoramento maior.

Os métodos de rastreamento também provaram serem úteis para a geração de informações para subsidiar a avaliação do bem-estar quanto a densidade e movimentação. Estes geraram indicadores de movimentação, que também indicam evolução na movimentação semana a semana. Porém necessita de avaliação quanto ao tamanho da ave e sugere-se descartar pequenas movimentações.

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 das abordagens propostas pode-se concluir que foi possível gerar informações para subsidiar a avaliação do bem-estar animal em aviários quanto a densidade de alojamento e movimentação através de técnicas de processamento de imagem.

6.1 SUGESTÕES PARA TRABALHOS FUTUROS

Para trabalhos futuros sugere-se a ampliação do número de câmeras instaladas no aviário, com intuito de validar a densidade de Kg/m^2 de aves, identificando as áreas de concentração e o motivo para isto ocorrer.

Avaliar a utilização de outros algoritmos de classificação e rastreamento.

Incluir medidores de temperatura, umidade, amônia e outros gases para correlacionar com as medições.

Correlacionar o tamanho da ave com a movimentação dela durante as semanas.

Avaliar padrões comportamentais como: ciscar, andar, parar, bater asas, comportamento social e reprodutivo, nas etapas do processo.

REFERÊNCIAS

- ABPA. **Relatório Anual 2014**. Associação Brasileira de Proteína Animal, acesso em: <<http://www.ubabef.com.br/files/publicacoes/8ca705e70f0cb110ae3aed67d29c8842.pdf>>, 2014.
- ABRAHAMSSON, P. **Furnished cages and aviaries for laying hens. Effects on production, health and use of facilities**. Swoish University of Agricultural Sciences, Upsala. Department of animal Nutrition and Management, 1996.
- ABREU, V.M.N.; ABREU, P.G. de. **Análise das condições climáticas para a produção de aves no Leste Sergipano**. [Analysis of the climate conditions for Poultry production in the east region of Sergipe (SE), Brazil]. Congresso Brasileiro De Agrometeorologia, 15. Anais. Aracaju: Aracaju, SE, 2007, 5p. 1 CD-ROM.
- ALGERI, T.; **Dinâmica espacial de frangos em granjas usando técnicas de processamento de imagens**. Trabalho de Conclusão de Pós-graduação, 2014.
- ALI, I.; DAILEY, M. N. **Multiple human tracking in high-density crowds**. Image and Vision Computing, v. 30, n. 12, p. 966–977, 2012.
- ARAUJO, G. M. **Algoritmo para reconhecimento de características faciais baseado em filtros de correlação**. Dissertação de Mestrado, UFRJ, 2010.
- 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. Anais, 2010.
- BOUSSAA, M.; ATOUF, I.; ATIBI, M.; BENNIS, A. **ECG Image Classification in Real time based on the Haar-like Features and Artificial Neural Networks**. Procedia Computer Science, v. 73, n. Awict, p. 32–39, 2015. Elsevier Masson SAS. Disponível em: <<http://dx.doi.org/10.1016/j.procs.2015.12.045>>.
- 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.** Int. Sci. J. Comp. Int. Sci, v. 6, n. 61, p. 121–1363, 2015.
- CRUZ, J. E. C.; SHIGUEMORI, E. H.; GUIMARÃES, L. N. F. **Comparação entre HOG SVM e Haar-like em cascata para a detecção de campos de futebol em imagens aéreas e orbitais.** Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE, p. 6917–6922, 2013.
- CULJAK I.; ABRAM, D.; PRIBANIC, T.; DZAPO, H.; CIFREK, M.; **A brief introduction to OpenCV,** MIPRO 2012, May 21-25, 2012, Opatija, Croatia, 2012.
- 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, 9., 2009, São Lourenço. Anais. São Lourenço: Sociedade de Ecologia do Brasil, 2009. Disponível em: <http://www.sebecologia.org.br/2009/resumos_ixceb/1108.pdf> Acesso em: 1/12/2009.
- 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, v. 34, n. 4, p. 1031–1038, 2010.
- DO, T. T.; DOAN, K. N. **Boosted of Haar-like Features and Local Binary Pattern Based Face Detection.** RIVF '09. International Conference on Computing and Communication Technologies, n. 1992, p. 1–8, 2009.
- FAWAC, **Code of Practice for the Welfare of Laying Hens,** Farm Animal Welfare Advisory Council, 2011, Disponível em <<http://www.fawac.ie/publications/animalwelfareguidelines/>>, acesso em 10/2014.
- FIGUEIREDO, G. F.; BENSON, E. R. **Development of Machine Vision Based Poultry Behavior Analysis System.** Image (Rochester, N.Y.), 2003.

- FORTUN, D.; BOUTHEMY, P.; KERVRANN, C. **Optical flow modeling and computation: A survey.** *Computer Vision and Image Understanding*, v. 134, p. 1–21, 2015.
- FREUND, Y., SCHAPIRE, R.E.: **A decision-theoretic generalization of on-line learning and an application to boosting.** *Journal of Computer and System Sciences* 55(1), 119–139, 1997.
- FUJII, T.; YOKOI, H.; TADA, T.; SUZUKI, K.; TASUKAMOTO, K. **Poultry Tracking System with Camera Using Particle Filters.** *International Conference on Robotics and Biomimetics. Anais. Bangkok, Thailand.* p.1888–1893, 2009.
- HASAN, Y.; ARIF, M. U.; ASIF, A.; RAZA, R. H. **Comparative analysis of vehicle detection in urban traffic environment using Haar cascaded classifiers and blob statistics.** *FTC 2016 - Proceedings of Future Technologies Conference*, n. December, p. 547–552, 2017.
- HENRIQUES, J. F.; CASEIRO, R.; MARTINS, P.; BATISTA, J. **Exploiting the circulant structure of tracking-by-detection with kernels.** *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, v. 7575 LNCS, n. PART 4, p. 702–715, 2012.
- HFAC, *Humane Farm Animal Care*, **Animal Care Standards**, Ago. 2014 <<http://certifiedhumane.org/wp-content/uploads/Std14.Chickens.2A-1.pdf>>. Acesso em 26/07/2017.
- HIKVISION, Disponível em: http://www.hikvision.com/en/Products_accessories.aspx?c_kind=1&c_kind2=2&c_kind3=754&c_kind4=755&id=6106, Acesso em 06/2017
- HOCKING, P.M.; RUTHERFORD, K.M.D.; PICARD, M. **Comparison of time-based frequencies, fractal analysis and T-patterns for assessing behavioural changes in broiler breeders fed on two diets at two levels of feed restriction: A case study.** *Applied Animal Behaviour Science*, v.104, p.37-48, 2007.
- HORN, B. K. B.; SCHUNCK, B. G. **Determining Optical Flow.** *Artificial Intelligence Memo 572*, v. 319, p. 185–203, 1981.

- JAWAS N., SUCIATI N., **Image Inpainting using Erosion and Dilation Operation**, International Journal of Advanced Science and Technology, Vol. 51, 127-134, February, 2013
- JIN, Z.; BHANU, B. **Integrating Crowd Simulation for Pedestrian Tracking in Multi-Camera System**. IEEE International Conference Distributed Smart Cameras (ICDSC 12), p. 1–8, 2012.
- KDNUGGETS, Disponível em: <http://www.kdnuggets.com/2014/09/advanced-data-analytics-business-leaders-explained.html>, Acesso em 01/06/2017. 2014.
- KRATZ, L.; NISHINO, K. **Tracking pedestrians using local spatio-temporal motion patterns in extremely crowded scenes**. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 34, n. 5, p. 987–1002, 2012.
- LOURENÇONI, D. **Modelagem Fuzzy das Respostas Produtivas de Frangos de Corte Criados em Diferentes Sistemas Comerciais de Produção**. 2017.
- LUCAS, B.D., KANADE, T., **An iterative image registration technique with an application to stereo vision (ijcai)** in Proceedings of the 7th International Joint Conference on Artificial Intelligence (IJCAI '81), April 1981, pp. 674–679.
- MARENGONI M., STRINGHINI D., **Tutorial: Introdução à Visão Computacional usando OpenCV**, RITA, Volume XVI, Número 1, 2009
- 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, p. 93–104, 2004.
- 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**. Tese de Doutorado, Universidade Federal de Viçosa, 2009.
- 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.

- OLIVEIRA, J. V. N.; GOMES, D. M. **Comparação de métodos para localização de fluxo óptico em sequências de imagens.** Acesso em: <<http://www.decom.ufop.br/menotti/paa111/files/PCC104-111-ars-11.1-VantuilJoseDeOliveiraNeto.pdf>> 2011.
- PAULA FILHO, P.L., SOARES, C.L., TUSSET, A.M., **Utilização de um Sistema de Visão Computacional para o Controle de um Robô Móvel**, Proceedings of the 9th Brazilian Conference on Dynamics Control and their Applications, Serra Negra, SP, 2010.
- RAHMATIAN, S.; SAFABAKHSH, R. **Online multiple people tracking-by-detection in crowded scenes.** 7th International Symposium on Telecommunications. **Anais...**2014
- SCHAPIRE, R. E. Explaining adaboost. **Empirical Inference: Festschrift in Honor of Vladimir N. Vapnik**, p. 37–52, 2013.
- SERGEANT, D., BOYLE, R., FORBES, M. (1998). **Computer visual tracking of poultry.** Computers and Electronics in Agriculture, 21(1), 1–18. [http://doi.org/10.1016/S0168-1699\(98\)00025-8](http://doi.org/10.1016/S0168-1699(98)00025-8)
- SEVEGNANI, K. B.; CARO, W. I.; PANDORFI, H.; SILVA, I. J. O. DA; MOURA, D. J. **Zootecnia de precisão: análise de imagens no estudo do comportamento de frangos de corte em estresse térmico.** *Revista Brasileira de Engenharia Agrícola e Ambiental*, v.9, n.1, p.115-119, 2005.
- SHAO, J.; DONG, N.; TONG, M. **Multi-part sparse representation in random crowded scenes tracking.** *Pattern Recognition Letters*, v. 34, n. 7, p. 780–788, maio 2013.
- SMEULDERS, A. W. M.; CHU, D. M.; CUCCHIARA, R.; CALDERARA, S.; DEGHAN, A.; SHAH, M.; **Visual tracking: An experimental survey.** *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 36, n. 7, p. 1442–1468, 2014.

- SOUZA, A. P. De O. **Certificação e boas práticas em granjas de frangos de corte no paran : efetividade para o bem-estar animal**, 2014, Disserta o (Mestre em Ci ncias Veterin rias), Universidade Federal do Paran , Curitiba, 2014
- SOUZA, A. P. O.; MOLENTO, C. F. M. Good agricultural practices in broiler chicken production in the state of Paran : focus on animal welfare. **Ci ncia Rural**, v. 0, n. 0, p. 6p., 2015.
- TIKOO, S; **Detection of Face using Viola Jones and Recognition using Backpropagation Neural Network**, Dissertation, Masters of Technology (Electronics & Communication Engineering, THE NORTHCAP UNIVERSITY, Gurgaon, Haryana, 2016.
- TOPAL C.; AKINLAR, C.; GENC, Y.; **Edge Drawing: A Heuristic Approach to Robust Real-Time Edge Detection**, 2010 International Conference on Pattern Recognition, 2424-2427, 2010.
- VIOLA, P.; JONES, M.; **Rapid object detection using a boosted cascade of simple features**. In CVPR 2001 – IEEE Conference on Computer Vision and Pattern Recognition, 2001.
- XU, J.; DENMAN, S.; REDDY, V.; FOOKES, C.; SRIDHARAN, S. **Real-time video event detection in crowded scenes using MPEG derived features: A multiple instance learning approach**. Pattern Recognition Letters, v. 44, p. 113–125, 2014. Elsevier B.V. Dispon vel em: <<http://dx.doi.org/10.1016/j.patrec.2013.11.019>>.
- YILMAZ, A.; JAVED, O.; SHAH, M.; **Object tracking**. *ACM Computing Surveys*, 38(4), 13–es. <http://doi.org/10.1145/1177352.1177355>, 2006.
- ZHAO, Y.; GONG, L.; ZHOU, B.; HUANG, Y.; LIU, C. **Detecting tomatoes in greenhouse scenes by combining AdaBoost classifier and colour analysis**. Biosystems Engineering, v. 148, n. 2009, p. 127–137, 2016. Elsevier Ltd. Dispon vel em: <<http://dx.doi.org/10.1016/j.biosystemseng.2016.05.001>>. .