

Suinocultura de precisão: Visão computacional e tecnologias digitais

Héilton Pandorfi¹
Cristiane Guiselini²
Gledson L. P. Almeida²
Rodes A. B. Silva³
Nicoly F. Gomes³

¹ Prof. Associado, DEAGRI, UFRPE

² Prof(a) Associado(a), DEAGRI, UFRPE

³ Doutorandas, Programa de Pós-Graduação em Engenharia Agrícola, UFRPE

RESUMO

Para fornecer alimentos à população mundial, a pecuária encontra-se em franca expansão, com ênfase no atendimento da crescente demanda por proteína de origem animal, o que levou a um rápido crescimento de empresas suinícolas. No entanto, a consciência das necessidades dos animais sustenta novos padrões de produção para a saúde e o bem-estar animal. A avaliação do comportamento de suínos pode fornecer informações sobre a condição de alojamento, necessidade de adequação no fornecimento de água e alimentos, monitoramento da saúde e da eficiência produtiva. A identificação em tempo real de padrões e sinais comportamentais é um dos grandes desafios nos atuais sistemas de criação, no entanto, a crescente disponibilidade e sofisticação de novas tecnologias tem viabilizado o monitoramento automatizado do comportamento animal. As técnicas de visão computacional, como tecnologia disruptiva, pode proporcionar o alcance dos requisitos de monitoramento de maneira automatizada, sem contato, sem estresse e econômica. Objetivou-se com esta revisão descrever o estado da arte no emprego da visão de máquina, associada as técnicas de análise de imagens obtidas por câmeras 3D e 2D, para identificar atividade animal, locomoção, comportamentos agressivos e reprodutivos de suínos.

Palavras-chave: agropecuária digital; análise de imagem; comportamento animal; zootecnia de precisão

Precision livestock swine: Computer vision and digital technologies

ABSTRACT

To provide food to the world's population, livestock is booming, with an emphasis on meeting the growing demand for animal protein, which has led to a rapid growth of pig enterprises. However, awareness of animal needs underpins new production standards for animal health and welfare. Swine behavior assessment can provide information on housing condition, need for adequate water and food supply, health monitoring and productive efficiency. Real-time identification of behavioral patterns and signals is a major challenge in today's breeding systems; however, the increasing availability and sophistication of new technologies has enabled automated monitoring of animal behavior. Computer vision techniques such as disruptive technology can provide you with automated, non-contact, stress-free, and cost-effective monitoring requirements. The aim of this review was to describe the state of the art in the use of machine vision, associated with the techniques of image analysis obtained by 3D and 2D cameras, to identify animal activity, locomotion, aggressive and reproductive behavior of swine.

Key words: digital agriculture; image analysis; animal behavior; precision livestock farm

INTRODUÇÃO

A produção de proteína de origem animal é um dos seguimentos da agropecuária em franca expansão no mundo, por se tratar de uma importante fonte de alimento para o consumo humano. Nas últimas décadas, com a globalização e abertura dos mercados, tem-se observado uma série de mudanças



Recebido em: 25/08/2019

Aceito em: 21/12/2020

Publicado em: 31/12/2020

Autor correspondente: hpandorf@hotmail.com

macroeconômicas que impulsionaram positivamente o setor.

Com o advento da expansão populacional, amplia-se a demanda por alimentos em quantidade e qualidade. Em 2025, a população mundial deverá ultrapassar os 8 bilhões de pessoas e, em 2050 deverá atingir 9,6 bilhões. Este aumento de 35% nos próximos 33 anos requer métodos mais eficazes e precisos na produção de alimento (So-In, et al., 2014).

O potencial de desenvolvimento da suinocultura no cenário nacional e internacional está atrelado às exigências e demandas de mercado, com ênfase em aspectos sanitários, nutricionais e manejo do ambiente de produção, voltados a incorporação de tecnologias disruptivas que visam melhorias na gestão e na qualidade do produto final. O sistema industrial de produção de proteína de origem animal no Brasil, ainda apresenta estrangulamentos tecnológicos e não tecnológicos em seus diversos segmentos: produção, processamento, insumos, pesquisa, defesa sanitária, mão-de-obra, extensão e fomento, o que torna necessário levantamento de dados e pesquisas para geração de padrões que permitam o desenvolvimento da atividade dentro das atuais e das futuras exigências mercadológicas, com fundamentação essencialmente científica (Amaral et al., 2012).

O avanço do conhecimento e da tecnologia no século atual, juntamente com as expectativas em relação à suficiência de produtos pecuários de alta qualidade, amplia-se a necessidade de monitoramento mais preciso da produção. Inúmeros estudos demonstram como essas tecnologias podem ajudar na observação comportamental dos animais de produção. Exemplos que incluem o uso de sistemas de localização por radiofrequência para triangular um local e fornecer informações sobre o comportamento ingestivo de suínos (Andersen et al. al., 2014; Maselyne et al., 2014; Gertheiss et al., 2015). Outro exemplo de aplicação de novas tecnologias é o monitoramento do comportamento de deitar, usando acelerômetros acoplados aos animais (Aydin, 2017). Essa técnica tem sido amplamente aplicada na avaliação de locomoção e claudicação em suínos (Conte et al., 2014).

No entanto, a ligação de sensores para monitorar comportamentos de animais pode causar estresse e, em alguns casos, é impraticável a sua aplicação para identificar comportamentos de grupos de animais, devido ao custo e a vulnerabilidade dos equipamentos no ambiente de criação com alto nível de confinamento.

Nesse contexto, uma tecnologia alternativa que tem sido amplamente considerada em muitos processos agrícolas e industriais é a visão computacional (Costa et al., 2014, Nasirahmadi et al., 2016, Oczak et al., 2016). Sistemas automáticos de imagens por computador podem auxiliar os produtores e pesquisadores a resolver problemas de monitoramento de animais, por exemplo, identificação de padrões e sinais comportamentais, pesagem e outras tarefas rotineiras demoradas e onerosas, que podem se tornar mais objetivas, minimizando custos, por meio do processamento de imagens.

Portanto, acompanhar as reações comportamentais se originou da observação humana, porém, com o avanço da tecnologia, torna-se possível analisar o comportamento por meio de técnicas de visão computacional. E no futuro próximo, possibilitar a automação de processos no ambiente produtivo, como acionamento de sistemas de climatização, iluminação e manejo sanitário, com ênfase no bem-estar animal.

Esta revisão apresenta algumas técnicas de visão computacional e processamento de imagens para medir

automaticamente as características comportamentais de suínos.

AQUISIÇÃO DE IMAGEM PARA MONITORAMENTO DE ANIMAIS DE PRODUÇÃO

A aquisição de imagens é o primeiro passo para implementação de qualquer sistema de visão computacional, definida como a transferência de sinais de um dispositivo de detecção, câmera, para uma forma numérica, sendo que cada tipo de câmera oferece informações diferentes sobre os parâmetros da imagem. As câmeras aplicadas na detecção de comportamento de animais podem ser divididas em câmeras CCD (Charge Coupled Device), sensor infravermelho e sensor de profundidade.

As câmeras CCD criam imagens em duas dimensões e são sensíveis a bandas de comprimentos de onda visíveis, refletidas por objetos (Mendoza et al., 2006). Esse tipo de câmera precisa de uma fonte adicional de luz para tornar a imagem visível, como por exemplo, as câmeras de vigilância (imagens noturnas).

As imagens capturadas são processadas por algoritmos para extrair propriedades de cor, forma e textura. As câmeras CCD têm a capacidade de fornecer pixels de objetos nas bandas vermelha, verde e azul (RGB). Além disso, diferentes algoritmos de processamento de imagem ajudam a converter essas bandas em informações de cinza, matiz, saturação, intensidade e outros parâmetros que permitem a segmentação das imagens.

As câmeras infravermelhas ou térmicas funcionam de maneira similar às câmeras CCD comuns, em que uma lente concentra a energia em uma série de receptores para produzir uma imagem. Ao receber e medir radiação infravermelha (8-12 μm) da superfície de um objeto, a câmera captura informações sobre o calor que o objeto está emitindo e então, o converte para uma leitura de temperatura radiante (James et al., 2014; Matzner et al., 2015).

A termografia foi desenvolvida para aplicações industriais, médicas e militares, porém, tem sido aplicada em estudos para animais de produção (McCafferty et al., 2011). Todos os animais vivos emitem radiação infravermelha e, quanto maior a temperatura de um corpo, maior a intensidade da radiação emitida, que resulta em uma imagem mais brilhante (Hristov et al., 2008).

Na última década, o número de aplicações relacionadas a sistemas de imagens 3D tem crescido rapidamente. O uso deste tipo de sistema de imagem em produtos agrícolas foi descrito por Vázquez-Arellano et al. (2016). A imagem de profundidade é um componente central de muitos sistemas de visão computacional e, dentro dessa tecnologia, as câmeras TOF (Time of Flight) e Kinect têm sido utilizadas em aplicações na produção animal. As câmeras TOF detectam a profundidade emitindo um pulso e, em seguida, registra o diferencial de tempo para a luz emitida viajar para um objeto e voltar para o detector (Pycinski et al., 2016).

O sensor de profundidade 3D permite superar problemas comuns de sistemas de imagens 2D, como a remoção de fundo, a segmentação, a extração de recursos e a sensibilidade à variação de iluminação. A informação de profundidade pode ser útil para obtenção da altura, ou para calcular as coordenadas de maneira mais simples, comparativamente aos sistemas 2D.

TÉCNICAS DE PROCESSAMENTO DE IMAGEM PARA MONITORAMENTO INDIVIDUAL

Embora os suínos sejam alojados em grupos, o monitoramento individual de animais de produção é uma das principais abordagens nos estudos que envolvem a análise de imagem, voltados a determinação do peso vivo e condição corporal, bem como a detecção de problemas de saúde, através de alterações físicas ou fisiológicas associadas ao animal.

Peso vivo

O conhecimento do peso vivo de suínos desempenha importante papel no controle de parâmetros relacionados ao desempenho do rebanho, ou seja, crescimento animal, uniformidade, conversão alimentar, espaço disponível, saúde e disponibilidade do produto final no mercado (Kongsro, 2014).

O peso vivo individual, geralmente é obtido por meio de balanças manuais ou automáticas, em que os animais são conduzidos de forma laboriosa e estressante, tanto para o animal como para os trabalhadores; além disso, as balanças automáticas geralmente são recursos que mobilizam grande aporte financeiro para sua aquisição (Kongsro, 2014).

Existem na literatura diferentes métodos de processamento de imagens para monitorar o peso vivo de suínos. Com base nas dimensões biométricas dos animais, comprimento da escápula ao focinho, comprimento da cauda à escápula, largura do ombro, largura do quadril e área limite. Doeschl-Wilson et al. (2004) usaram câmeras CCD de cima para baixo para obter estimativas do peso vivo individual de suínos. O peso vivo também foi estimado a partir de uma imagem de topo para extração e identificação da área de ocupação, perímetro, excentricidade, comprimento do eixo maior e menor e, detecção de limite, juntamente com métodos de reconhecimento por redes neurais artificiais (Wongsriworaphon et al., 2015).

Além disso, abordagens para estimativa de peso vivo de suínos por meio de uma câmera Kinect, permitiu a obtenção de imagens em 3D, para determinação do peso vivo de suínos com base no volume corporal (Shi et al., 2016). A forma e a condição corporal de suínos é um importante indicador de sua saúde, seja para reprodução ou para a qualidade da carcaça.

Saúde e doença

A detecção precoce de doença ou comportamento anormal é essencial para o atendimento do bem-estar animal e os desafios sanitários de suínos, além de minimizar perdas e mortalidade do lote. Por uma combinação de tecnologia sem fio e processamento de imagens, um método para detectar a probabilidade de um suíno ficar doente foi testado por Zhu et al. (2009). O monitoramento do movimento diário de um suíno e o comportamento ingestivo foram considerados indicadores de casos suspeitos.

O registro da temperatura corporal é um método comum para monitorar a saúde de um animal (Hoffmann et al., 2013). Como resultado, a maioria das pesquisas sobre detecção de problemas sanitários e doença é baseada na medição da temperatura da superfície do corpo do animal, por meio de câmeras térmicas.

Rastreamento da atividade animal

Para automatizar o monitoramento da saúde e do bem-estar dos animais, foram desenvolvidos métodos de rastreamento que diferem de acordo com a espécie e a situação

de criação. As ferramentas de rastreamento de animais com base em dispositivos de identificação acoplados no indivíduo, como Bluetooth, redes WiFi, métodos de radiofrequência e GPS, permitem conhecer a localização e a atividade dos animais de produção (Huhtala, 2007).

No entanto, suínos normalmente têm mais contato físico no alojamento e não podem transportar facilmente dispositivos de medição sem risco de danos (Ahrendt et al., 2011). Além disso, são necessários muitos dispositivos para um grupo ou lote de animais, o que inviabiliza economicamente o seu emprego. Como resultado, o rastreamento de animais por meio da visão computacional tem apresentado inúmeras vantagens, comparativamente aos dispositivos eletrônicos embarcados. McFarlane e Schofield (1995) utilizou câmera 2D para rastreamento de leitões, com base na técnica de ajuste de elipse, enquanto Tillett et al. (1997) rastrearam suínos individuais usando coordenadas x e y para identificação das atividades individuais ao longo do tempo.

As abordagens de processamento de imagem têm sido usadas para rastrear a localização de suínos em baias (Guo et al., 2015; Nilsson et al., 2015). Em outro estudo, diferentes leitões foram pintados com cores diferentes nas costas para rastreamento e o algoritmo automático de extração foi baseado na detecção do valor RGB (Jover et al., 2009). Similarmente, Kashiha et al. (2013b) utilizaram imagens CCD de vista superior para determinar um padrão específico estampado nas costas dos animais, em que o algoritmo atuou para descrição da elipse formada a partir do posicionamento dos animais.

Um sistema de visão computacional em tempo real, para rastreamento de suínos foi desenvolvido por Ahrendt et al. (2011), com base na construção de mapas de apoio e um modelo gaussiano de posição e extração da forma de suínos individuais.

As escalas de validação utilizadas para determinar o desempenho de uma técnica de visão computacional são descritas como sensibilidade, especificidade, taxa de erro, precisão e exatidão. Todos os resultados são baseados na correlação com a verdade básica (referência). A verdade básica é usada para se referir aos dados fornecidos pela observação direta, em comparação às informações fornecidas pelo processamento de imagens.

COMPORTAMENTO INGESTIVO

O comportamento ingestivo contém informações importantes que podem melhorar a gestão dos animais e permitir a detecção de problemas (Brown-Brandl et al., 2013a; Brown-Brandl et al., 2013b). A detecção desses comportamentos é importante do ponto de vista econômico e de bem-estar animal, pois, desempenha papel fundamental no manejo de suínos. Tradicionalmente, o comportamento alimentar foi monitorado por observação direta ou pela técnicas de gravação de vídeo (Meiszberg et al., 2009).

O emprego de recursos computacionais de controle da alimentação tem sido empregado para registrar os comportamentos alimentares individualmente, usando métodos de marcação eletrônica por radiofrequência (Rushen et al., 2012). No entanto, esse equipamento apresenta alto custo e requer que os animais compartilhem locais limitados de alimentação instrumentada. Dessa forma, a visão computacional apresenta-se como método alternativo para a detecção do comportamento ingestivo e controle de consumo dos animais.

Para registrar a presença dos animais em uma área de alimentação, o emprego de um sistema de vídeo multi-

câmera, permitiu a obtenção de imagens de enquadramento descendente (Porto et al., 2015); que com auxílio de um classificador, baseado no algoritmo de Viola-Jones (Viola e Jones, 2004) utilizando formas compostas de retângulos adjacentes, baseado na diferença da soma de pixels de áreas dentro dos retângulos. Uma imagem que continha o objeto foi considerada como uma imagem positiva, enquanto uma imagem negativa continha apenas o fundo da imagem e não o objeto alvo, portanto, representativo da presença dos animais nas áreas de comedouro e bebedouro, apresentando sensibilidade de 87%, quando comparado ao reconhecimento visual.

A fim de reconhecer automaticamente os comportamentos de alimentação e consumo de porcas em lactação, foi desenvolvido um sistema de imagem por Kinect (Lao et al., 2016). Nesse método, depois de remover objetos indesejados, converteu-se a imagem em uma imagem binária, sendo as características físicas da matriz suína incluída em coordenadas x e y do centróide, cabeça e quadril. Foram utilizadas as características da imagem da matriz para dividir o corpo em 7 partes, metade superior, metade inferior, cabeça, ombro, lombo e quadril. O comportamento do ato de beber foi determinado pela busca de pixels do animal conectados a chupeta (bebedouro) ou em sua proximidade, distribuídos na horizontal e com altura maior que a altura da chupeta. Para o comportamento alimentar utilizaram a mesma estratégia, registrando quando a cabeça estava no alimentador com movimentos para cima e para baixo. O desempenho alcançado pelo método apresentou precisão de 97,4% na alimentação e 92,7% nos comportamentos de beber, quando comparado à observação direta.

O monitoramento de ações de ingestão de alimentos, por meio do processamento de imagens, apresenta alto desempenho nas suas determinações. Embora o monitoramento 2D seja baseado principalmente nas características de forma e cor do animal, alguns modelos de classificação vêm sendo testados para melhorar o processo. A distância do objeto à câmera é o princípio básico para a detecção de movimento 3D de animais. A identificação de múltiplos animais durante os períodos de alimentação e consumo representa um desafio adicional que ainda não foi completamente resolvido pelos pesquisadores neste campo.

POSTURA DE SUÍNOS (PROSTRAÇÃO)

Os suínos passam a maior parte do tempo em repouso e, em alguns casos, os animais em terminação deitam por até 90% do seu tempo diário (Ekkel et al., 2003). O comportamento deitado pode fornecer informações sobre fatores ambientais que afetam a eficiência, a saúde e o bem-estar dos animais. A temperatura é o principal parâmetro que afeta o comportamento de suínos; em altas temperaturas ambientais, os animais tendem a deitar-se em posição totalmente reclinada com os membros estendidos e evitam contato físico com outros, enquanto que em baixas temperaturas ambientais, os suínos adotam uma postura de esterno e se amontoam (Nasirahmadi et al., 2015). O design da baia, a localização dos comedouros e dos bebedouros, a velocidade e a umidade do ar são outros fatores que afetam o comportamento de deitar (Costa et al., 2014).

Shao et al. (1998) usaram câmeras CCD para obter características comportamentais de imagens binárias de suínos, ou seja, a transformada de Fourier, momento, perímetro e área, que foram utilizados como dados de entrada

para uma RNA para identificar comportamentos de suínos. A maior taxa de classificação correta foi obtida pela combinação de perímetro, área e momento.

Posteriormente, Shao e Xin (2008) usaram outras características, isto é, compactação de objeto, frequência média de mudança de pixel de fundo para primeiro plano, razão de ocupação de área e momento invariante, para detectar e classificar os comportamentos deitados de animais agrupados. O sistema de visão por máquina pode detectar com sucesso o movimento dos suínos, o que permitiu a segmentação da imagem e a classificação do estado de conforto térmico dos animais.

O emprego de imagem para detecção da postura deitado de suínos em grupo, em diferentes situações ambientais, taxa de ventilação, velocidade do ar, temperatura e umidade, foi realizada por Costa et al. (2014), em que se utilizou câmeras CCD sensíveis ao infravermelho para detecção de comportamentos posturais de suínos.

Outra abordagem foi desenvolvida por Nasirahmadi et al. (2015), em que verificaram a viabilidade de usar imagem processadas e triangulação de Delaunay (DT) para detecção de comportamentos deitados de animais agrupados, por meio de câmeras CCD de vista superior. Em cada imagem binária, as coordenadas x e y de cada objeto foram usadas para algoritmos de ajuste de elipse para localização de cada animal e identificar o comprimento do eixo maior, comprimento do eixo menor, orientação e centróide para cada elipse ajustada (Kashiha et al., 2014a). Os resultados mostraram que o valor médio dos perímetros de cada triângulo foi diferente conforme a temperatura média foi alterada na instalação, apresentando valores mais altos em temperaturas ambientais mais altas, refletindo o maior espaçamento entre os suínos nessas condições.

Nasirahmadi et al. (2017) desenvolveram visão de máquina associada a RNA para definição e classificação de padrões de suínos deitados em grupo. As características do DT (isto é, valor médio do perímetro, valor médio do comprimento máximo e mínimo do lado de cada triângulo) obtidas da imagem binária dos animais foram usadas como variáveis de entrada (três neurônios) para um classificador de RNA e a saída do classificador definido em três categorias, temperatura do ar no interior da instalação crítica superior, inferior e de conforto. Os conjuntos de dados experimentais foram divididos aleatoriamente em conjuntos de treinamento (70%), validação (15%) e teste (15%). A precisão geral do classificador foi relatada como 95,6%.

COMPORTAMENTO DE LOCOMOÇÃO E CLAUDICAÇÃO

O monitoramento da locomoção de suínos utilizando diferentes tecnologias pode servir a diferentes propósitos, ou seja, detecção de comportamentos deitados (Kashiha et al., 2014a), detecção de claudicação (Stavarakakis et al., 2015b) e avaliação do bem-estar (Lind et al., 2005).

Técnicas de subtração de fundo e ajuste de elipse para localização de suínos em imagens de vista superior e cálculo de características da elipse tornaram o rastreamento da locomoção de suínos mais preciso (89,9%) (Kashiha et al., 2014a).

O princípio foi baseado no movimento linear do centro de uma elipse encaixada em diferentes quadros e no movimento angular (orientação da elipse) para rastrear animais marcados em imagens em uma sequência de quadros. A locomoção foi definida quando um animal (centro da elipse encaixada) movimentou mais de 40% do comprimento do corpo (valor

em pixels). De modo a tornar a técnica independentemente do tamanho do corpo, a soma dos movimentos linear e angular foi dividida pelo comprimento de cada animal. Uma abordagem semelhante foi utilizada por Nasirahmadi et al. (2015) para encontrar suínos em movimento durante os períodos de repouso.

O comportamento de locomoção também foi investigado usando o sistema de câmera Kinect para detectar claudicação de suínos. O movimento foi capturado primeiramente usando o sistema de análise de movimento optoeletrônico Vicon 3D, para detectar as alterações locomotoras características de animais coxos (Stavrakakis et al., 2015a). Este sistema foi então comparado com o sensor Kinect para distinguir animais sadios e coxos por Stavrakakis et al. (2015b). Marcadores reflexivos foram fixados no osso nasal central, no meio do pescoço proximal aos ombros, no meio do tórax posterior, no meio da pelve anterior e na base da cauda dos suínos. Dessa forma, foi encontrado coeficiente de correlação positivo alto ($P < 0,001$; $r = 0,994$) entre os dados da trajetória do marcador de Vicon e as excursões verticais do sensor Kinect para animais coxos.

COMPORTAMENTO AGRESSIVO EM SUÍNOS

Comportamento agressivo em animais pode ser definido como um comportamento que causa dano real ou potencial a outros animais. A maioria dos animais vive em grupo e o comportamento agressivo pode ser observado nos primeiros dias após a mistura de animais desconhecidos, ou quando ocorre a competição por recursos, durante os períodos de alimentação. Esse comportamento pode afetar o crescimento, a saúde e o bem-estar dos animais e, gera perdas econômicas. A maioria dos estudos de agressão detecta os comportamentos usando observação direta ou gravação de vídeo com subsequente decodificação humana.

Uma detecção automatizada contínua de comportamento agressivo entre suínos, por meio de características de imagem CCD, foi desenvolvida por Viazzi et al. (2014). Duas características foram extraídas da região segmentada da imagem do histórico de movimento; a intensidade média de movimento que representa quão forte e intenso o movimento é na imagem, e o índice de ocupação que ilustra a distribuição de movimento dentro das regiões. Uma Análise Discriminante Linear (LDA) foi utilizado para classificar interações agressivas em todos os episódios, com acurácia de 89,0%, sensibilidade de 88,7% e especificidade de 89,3%.

Em outro estudo, foram testados a viabilidade de um método para detecção de comportamento agressivo baseado em um percentual de índice de atividade (número de pixels de animais em movimento / número total de pixels) associado a uma RNA (Oczak et al., 2014). Cinco características (média, máxima, mínima, soma e variância) do índice de atividade foram calculadas a partir dos vídeos gravados em diferentes intervalos de tempo e classificados como altos eventos de agressividade, com sensibilidade de 96,1%, especificidade de 94,2% e precisão de 99,8%.

O sensor de profundidade Kinect também foi utilizado para reconhecer e classificar o comportamento agressivo entre os suínos com uma precisão de 95,7 e 90,2%, respectivamente (Lee et al., 2016). Em seu estudo, a detecção automática e o reconhecimento da agressão suína consistiram em três módulos; o pré-processador, o gerador de recursos e o detector e classificador de agressividade. Em seguida, cinco características (mínimo, máximo, média, desvio padrão de

velocidade e distância entre os porcos) foram extraídas da imagem. Finalmente, o detector de agressão classificou por meio de método de aprendizado supervisionado de máquina de vetores de suporte (Support Vector Machine) as características para detectar os eventos agressivos, com base em subtipos comportamentais, isto é, perseguindo (seguindo outro porco com mordida) e batendo cabeça-a-cabeça e cabeça-corpo.

Embora as câmeras CCD e Kinect tenham sido aplicadas para abordar a detecção de comportamento agressivo em alguns estudos, são necessários esforços adicionais em condições comerciais para desenvolver um sistema de alarme confiável para os produtores.

COMPORTAMENTO DE MONTA EM SUÍNOS

O comportamento de monta, definido quando um animal levanta suas duas patas dianteiras e as coloca sobre qualquer parte do corpo ou cabeça de outro animal, é o indicador mais usado de comportamento reprodutivo para detecção de estro (Rydmer et al., 2006).

Tanto suínos machos quanto fêmeas em crescimento também realizam eventos de montagem, com frequências diferentes, que podem aumentar o risco de lesões, como hematomas, danos à pele, claudicação ou fraturas nas pernas (Nasirahmadi et al., 2016).

Um sistema para monitoramento automático de eventos de monta entre suínos foi desenvolvido por Nasirahmadi et al. (2016) com base nas câmeras CCD de vista superior. Depois de extrair quadros de vídeos gravados, o método de subtração de plano de fundo foi aplicado para detectar os animais nas baias. Foi utilizada técnica de ajuste de elipse para localização de cada animal em imagens binárias e parâmetros de elipse calculados para etapas posteriores. A regra de detecção para eventos de monta em suínos, por sequências de quadros, foi baseada nos movimentos para a frente e monta com as pernas dianteiras em uma parte do corpo do animal montado. A distância Euclideana (DE) entre suínos também foi usada para detecção do evento de montagem. Ao encontrar a região de interesse (ROI) para dois suínos com uma DE menor que a metade do comprimento do eixo principal da elipse ajustada, em que foram registradas as coordenadas x e y do centro de dois suínos na ROI. Caso contrário, se não ocorresse nenhum evento de montagem (por exemplo, dois porcos apenas de pés juntos), o modelo ajustava uma elipse a cada animal e retornava uma DE calculada entre os animais. O método proposto apresentou sensibilidade de 94,5%, especificidade de 88,6% e precisão de 92,7%.

O potencial para detecção automatizada de comportamentos de monta tem sido pouco explorado na prática. Como o comportamento agressivo, ele se baseia em análises de sequência mais complexas envolvendo mais de um animal e, portanto, é mais desafiador do que tarefas simples de detecção de forma ou localização que podem ser usadas para outras categorias comportamentais. Como um evento de monta envolve a alteração da altura dos animais, a aplicação de sensores de profundidade 3D pode ser mais eficiente para detectar comportamentos dessa natureza.

CONSIDERAÇÕES FINAIS

O emprego de sistemas de identificação comportamental por meio da visão de máquina, mostra que a análise de

imagem 2D e 3D são comumente aplicadas no controle do ambiente de produção, por serem mais acessível e de menor custo, comparativamente aos sensores relacionados a pecuária de precisão.

Oportunidades futuras estarão relacionadas ao desenvolvimento de sistemas completos em tempo real para monitorar os comportamentos dos animais de acordo com sua biologia natural, levando em consideração as mudanças nos parâmetros ambientais.

O acesso a informações precisas sobre os comportamentos dos animais, permite ao produtor agir rapidamente para resolver problemas ou buscar intervenções. Além disso, o rastreamento automatizado e da frequência de alguns comportamentos anormais, pode facilitar o trabalho de pesquisadores e técnicos da área, que exploram métodos para prevenção ou alívio do problema comportamental.

REFERÊNCIAS

- AHRENDT, P.; GREGERSEN, T.; KARSTOFT, H. Development of a real-time computer vision system for tracking loose-housed pigs. *Computers and Electronic in Agriculture*, v.76, p.169–174, 2011.
- AMARAL, A.G.; YANAGI JUNIOR, T.; LIMA, R. R. et al. Efeito do ambiente de produção sobre frangos de corte sexados criados em galpão comercial. *Arquivo Brasileiro de Medicina Veterinária e Zootecnia*, v.63, p.649-658, 2012.
- ANDERSEN, H.M.L.; DYBKJAER, L.; HERSKIN, M.S. Growing pigs' drinking behaviour: number of visits, duration, water intake and diurnal variation. *Animal*, v.8 p.1881–1888, 2014.
- AYDIN, A. Using 3D vision camera system to automatically assess the level of inactivity in broiler chickens. *Computers and Electronics in Agriculture*, v.135, p.4-10, 2017.
- BROWN-BRANDL, T.M.; EIGENBERG, R.A.; PURSWELL, J.L. Using thermal imaging as a method of investigating thermal thresholds in finishing pigs. *Biosystems Engineering*, v.114, p.327–333, 2013a.
- BROWN-BRANDL, T.M.; ROHRER, G.A.; EIGENBERG, R.A. Analysis of feeding behavior of group housed growing–finishing pigs. *Computers and Electronics in Agriculture*, v.96, p.246–252, 2013b.
- CONTE, S.; BERGERON, R.; GONYOU, H. et al. Measure and characterization of lameness in gestating sows using force plate, kinematic, and accelerometer methods. *Journal Animal Science*, v.92, p.5693–5703, 2014.
- COSTA, A.; ISMAYILOVA, G.; BORGONOVO, F. et al. Image-processing technique to measure pig activity in response to climatic variation in a pig barn. *Animal Production Science*, v.54, p.1075–1083, 2014.
- DOESCHL-WILSON, A.B.; WHITTEMORE, C.T.; KNAP, P.W. et al. Using visual image analysis to describe pig growth in terms of size and shape. *Animal Science*, v.79, p.415–427, 2004.
- EKKEL, E.D.; SPOOLDER, H.A.; HULSEGG, I. et al. Lying characteristics as determinants for space requirements in pigs. *Applied Animal Behavior Science*, v.80, p.19–30, 2003.
- GUO, Y.Z.; ZHU, W.X.; JIAO, P.P. et al. Multi-object extraction from topview group-housed pig images based on adaptive partitioning and multilevel thresholding segmentation. *Biosystems Engineering*, v.135, p.54–60, 2015.
- HOFFMANN, G.; SCHMIDT, M.; AMMON, C. et al. Monitoring the body temperature of cows and calves using video recordings from an infrared thermography camera. *Veterinary Research Communications*, v.37, p.91–99, 2013.
- HRISTOV, N.I.; BETKE, M.; KUNZ, T.H. Applications of thermal infrared imaging for research in aerocology. *Integrative and Comparative Biology*, v.48, p.50–59, 2008.
- HUHTALA, A.; SUHONEN, K.; MÄKELÄ, P. et al. Evaluation of instrumentation for cow positioning and tracking indoors. *Biosystems Engineering*, v.96, p.399–405, 2007.
- JAMES, C.A.; RICHARDSON, A.J.; WATT, P.W. et al. Reliability and validity of skin temperature measurement by telemetry thermistors and a thermal camera during exercise in the heat. *Journal of Thermal Biology*, v.45, p.141–149, 2014.
- JOVER, J.N.; ALCANIZ-RAYA, M.; GOMEZ, V. et al. An automatic colour-based computer vision algorithm for tracking the position of piglets. *Span. Journal of Agricultural Research*, v.7, p.535–549, 2009.
- KASHIHA, M.; BAHR, C.; OTT, S. et al. Automatic identification of marked pigs in a pen using image pattern recognition. *Computers and Electronics in Agriculture*, v.93, p.111–120, 2013.
- KASHIHA, M.A.; BAHR, C.; OTT, S. et al. Automatic monitoring of pig locomotion using image analysis. *Livestock Science*, v.159, p.141–148, 2014.
- KONGSRO, J. Estimation of pig weight using a Microsoft Kinect prototype imaging system. *Computers and Electronics in Agriculture*, v.109, p.32–35, 2014.
- LAO, F.; BROWN-BRANDL, T.; STINN, J.P. et al. Automatic recognition of lactating sow behaviors through depth image processing. *Computers and Electronics in Agriculture*, v.125, p.56–62, 2016.
- LEE, J.; JIN, L.; PARK, D. et al. Automatic recognition of aggressive behavior in pigs using a Kinect depth sensor. *Sensors*, v.16, p.631-639, 2016.
- LIND, N.M.; VINTHER, M.; HEMMINGSEN, R.P. et al. Validation of a digital video tracking system for recording pig locomotor behaviour. *Journal of Neuroscience Methods*, v.143, p.123–132, 2005.
- MASELYNE, J.; VAN NUFFEL, A.; DE KETELAERE, B. et al. Range measurements of a High Frequency Radio Frequency Identification (HF RFID) system for registering feeding patterns of growing–finishing pigs. *Computers and Electronics in Agriculture*, v.108, p.209–220, 2014.
- MATZNER, S.; CULLINAN, V.I.; DUBERSTEIN, C.A. Two-dimensional thermal video analysis of offshore bird and bat flight. *Ecological Informatics*, v.30, p.20–28, 2015.
- MCCAFFERTY, D.J.; GILBERT, C.; PATERSON, W. et al. Estimating metabolic heat loss in birds and mammals by combining infrared thermography with biophysical modelling. *Comparative Biochemistry and Physiology - Part A: Molecular & Integrative Physiology*, v.158, p.337–345, 2011.
- MCFARLANE, N.J.; SCHOFIELD, C.P. Segmentation and tracking of piglets in images. *Machine Visual and Application*, v.8, p.187–193, 1995.
- MEISZBERG, A.M.; JOHNSON, A.K.; SADLER, L.J. et al. Drinking behavior in nursery pigs: determining the accuracy between an automatic water meter versus human observers. *Journal Animal Science*, v.87, p.4173–4180, 2009.
- MENDOZA, F.; DEJMEK, P.; AGUILERA, J.M. Calibrated color measurements of agricultural foods using image analysis. *Postharvest Biology and Technology*, v.41, p.285–295, 2006.
- NASIRAHMADI, A.; HENSEL, O.; EDWARDS, S.A. et al. Automatic detection of mounting behaviours among pigs using image analysis. *Computers and Electronics in Agriculture*, v.124, p.295–302, 2016.
- NASIRAHMADI, A.; HENSEL, O.; EDWARDS, S.A. et al. A new approach for categorizing pig lying behaviour based on a Delaunay triangulation method. *Animal*, v.11, p.131–139, 2017.
- NASIRAHMADI, A.; RICHTER, U.; HENSEL, O. et al. Using machine vision for investigation of changes in pig group lying patterns. *Computers and Electronics in Agriculture*, v.119, p.184–190, 2015.

- NILSSON, M.; HERLIN, A.H.; ARDÖ, H. et al. Development of automatic surveillance of animal behaviour and welfare using image analysis and machine learned segmentation technique. *Animal*, v.9, p.1859–1865, 2015.
- OCZAK, M.; MASCHAT, K.; BERCKMANS, D. et al. Automatic estimation of number of piglets in a pen during farrowing, using image analysis. *Biosystems Engineering*, v.151, p.81–89, 2016.
- OCZAK, M.; VIAZZI, S.; ISMAYILOVA, G. et al. Classification of aggressive behaviour in pigs by activity index and multilayer feed forward neural network. *Biosystems Engineering*, v.119, p.89–97, 2014.
- PORTO, S.M.; ARCIDIACONO, C.; ANGUZZA, U. et al. The automatic detection of dairy cow feeding and standing behaviours in free-stall barns by a computer visionbased system. *Biosystems Engineering*, v.133, p.46–55, 2015.
- PYCINSKI, B.; CZAJKOWSKA, J.; BADURA, P. et al. Time-of-flight camera, optical tracker and computed tomography in pairwise data registration. *PLoS One*, v.11, p.7-16, 2016.
- RUSHEN, J.; CHAPINAL, N.; DE PASSILLE, A.M. Automated monitoring of behaviouralbased animal welfare indicators. *Animal Welfare*, v.21, p.339-348, 2012.
- RYDHMER, L.; ZAMARATSKAIA, G.; ANDERSSON, H.K. et al. Aggressive and sexual behaviour of growing and finishing pigs reared in groups, without castration. *Acta Agriculturae Scandinavica, Section A*, v.56, p.109–119, 2006.
- SHAO, B.; XIN, H. A real-time computer vision assessment and control of thermal comfort for group-housed pigs. *Computers and Electronics in Agriculture*, v.62, p.15–21, 2008.
- SHAO, J.; XIN, H.; HARMON, J.D. Comparison of image feature extraction for classification of swine thermal comfort behavior. *Computers and Electronics in Agriculture*, v.19, p223–232. 1998.
- SHI, C., TENG, G., LI, Z., 2016. An approach of pig weight estimation using binocular stereo system based on LabVIEW. *Computers and Electronics in Agriculture*, v.129, p.37–43, 2016.
- SO-IN, C; POOLSANGUAN, S.; RUJIRAKUL, K. A hybrid mobile environmental and population density management. *Computers and Electronics in Agriculture* 109 (2014) 287–301.
- STAVRAKAKIS, S.; GUY, J.H.; SYRANIDIS, I. et al. Pre-clinical and clinical walking kinematics in female breeding pigs with lameness: a nested casecontrol cohort study. *The Veterinary Journal*, v.205, p.38–43, 2015a.
- STAVRAKAKIS, S.; LI, W.; GUY, J.H. et al. Validity of the Microsoft Kinect sensor for assessment of normal walking patterns in pigs. *Computers and Electronics in Agriculture*, v.117, p.1–7, 2015b.
- TILLET, R.D.; ONYANGO, C.M.; MARCHANT, J.A. Using model-based image processing to track animal movements. *Computers and Electronics in Agriculture*, v.17, p.249–261, 1997.
- VÁZQUEZ-ARELLANO, M.; GRIEPENTROG, H.W.; REISER, D. et al. 3-D imaging systems for agricultural applications - a review. *Sensors*, v.16, p.618-623, 2016.
- VIAZZI, S.; ISMAYILOVA, G.; OCZAK, M. et al. Image feature extraction for classification of aggressive interactions among pigs. *Computers and Electronics in Agriculture*, v.104, p.57–62, 2014.
- VIOLA, P.; JONES, M.J. Robust real-time face detection. *International Journal of Computer Vision*, v.57, p.137–154, 2004.
- WONGSRIWORAPHON, A.; ARNONKIJPANICH, B.; PATHUMNAKUL, S. An approach based on digital image analysis to estimate the live weights of pigs in farm environments. *Computers and Electronics in Agriculture*, v.115, p.26–33, 2015.
- ZHU, W.; PU, X., LI, X.; ZHU, X. Automated detection of sick pigs based on machine vision. In: *IEEE International Conference on Intelligent Computing and Intelligent Systems*, 2009, Shanghai. *Proceedings... IEEE: People's Republic of China*, p.790-794. 2009.

