

Análise de comportamento ingestivo de ruminantes e processamento de sinais

Ruminant ingestive behavior analysis and signals processing

RESUMO

Lucas Volkmer Hendges
lucashendges@alunos.utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Pato Branco, Paraná, Brasil.

Fábio Luiz Bertotti
bertotti@utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Pato Branco, Paraná, Brasil.

O monitoramento do comportamento alimentar de ruminantes tem se tornado um assunto de grande importância na indústria agropecuária visto que pesquisas recentes dão indícios de que conhecer a maneira com que o animal se alimenta no pasto, torna mais barato alimentá-lo dentro de estábulos, com rações concentradas, e isso é benéfico para a produção animal. Diversos estudos foram realizados baseando-se nesse tema, e a grande maioria deles utiliza como método de monitoramento um ou mais acelerômetros de 3 eixos acoplados, geralmente, no pescoço do animal. O objetivo desse artigo é a realização de um estudo científico de trabalhos desenvolvidos anteriormente sobre análise de comportamento ingestivo de ruminantes e processamento de sinais. Partindo dos dados obtidos por meio desta análise bibliográfica, deve-se verificar os pontos principais em que foram obtidos resultados satisfatórios em tais estudos, buscando seguir tais linhas de desenvolvimento, evitando aquelas que se mostraram menos eficazes.

PALAVRAS-CHAVE: Comportamento ingestivo. Processamento digital de sinais. Acelerômetro. Sensoriamento. Ruminantes

ABSTRACT

The monitoring of ruminants eating behavior has become a very important topic in the farming industry because recent researches show that knowing the way the animals graze, makes it cheaper to feed them in the barns, with concentrated rations, and this is good for the production, especially of milk. Several studies have been done on this field, and most of them use one or more 3-axis accelerometers, fixed generally in the animal's neck, as monitoring method. The aim of this article is perform a scientific study of previously developed works about ruminants ingestive behavior analysis and signal processing. Starting from the data obtained with this bibliographic analysis, it should be verified the main points in which there were positive results in such studies, aiming to follow those development lines, avoiding the ones that showed to be ineffective.

KEYWORDS: Ingestive behavior. Digital signals processing. Accelerometer. Sensing. Ruminants.

Recebido: 19 ago. 2019.

Aprovado: 01 out. 2019.

Direito autoral: Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



INTRODUÇÃO

Existem atualmente, diversos estudos baseando-se, de forma geral, na análise de comportamento ingestivo de ruminantes, visto que cada vez mais se faz importante o reconhecimento de padrões de comportamentos através de sensoriamento, principalmente fazendo-se uso de um ou mais acelerômetros de 3 eixos acoplados, geralmente, no pescoço do animal.

Estes trabalhos servem como base para uma análise bibliográfica, onde buscou-se criar embasamento científico para desenvolvimento de uma atividade similar.

Tal atividade busca monitorar o comportamento ingestivo de ruminantes baseando-se, também, no posicionamento de sensores nos animais, podendo assim gerar dados que servem para analisar a maneira que estes se alimentam no pasto.

Isso traz benefícios para a indústria agropecuária pois permite que haja maior conhecimento da ingestão diária de pasto pelos animais, o que facilita na hora de saber quanto alimentá-los em ração para que possam se desenvolver adequadamente.

MATERIAIS E MÉTODOS

Para o desenvolvimento do presente trabalho de revisão bibliográfica, foram utilizados artigos sobre o tema **análise de comportamento ingestivo de ruminantes e processamento de sinais** que puderam ser encontrados em diferentes bases científicas do Portal de Periódicos da CAPES.

O foco da pesquisa consiste na aplicação de sensores inerciais para avaliação do comportamento ingestivo em ruminantes. Os artigos selecionados foram analisados e os aspectos mais relevantes foram registrados. Desta forma, os principais conceitos e técnicas foram abstraídos e colocados no Capítulo de Resultados e Discussões deste artigo.

Com o estudo de tais conceitos, foi buscado criar embasamento científico para que seja desenvolvido um projeto similar de análise de comportamento ingestivo baseando-se em aquisição de sinais provenientes de sensores de monitoramento animal.

RESULTADOS E DISCUSSÕES

COMPORTAMENTO INGESTIVO DE RUMINANTES

Os acelerômetros conseguem detectar movimentações do animal em todas as direções, mas quando busca-se saber se este está se alimentando ou não, o eixo mais importante é o vertical, tendo em vista que o sensor está acoplado em um colar no pescoço do animal, ele irá abaixá-lo na hora de pastar, o que

provocará uma aceleração no eixo vertical de detecção do acelerômetro, paralela à aceleração da gravidade.

Em grande parte dos artigos analisados, uma amostra de cerca de 6 a 10 animais foi utilizada, para que fosse possível ter dados variados para comparação. Foram empregadas algumas situações diferentes de controle nos experimentos, e.g. em Oudshroorn (2013) dividiu-se o gado em 2 grupos: um primeiro onde havia uma diferenciação da área pastada por cada vaca, e um segundo onde diferenciou-se a altura do pasto ingerido pelas mesmas. Dentro dessas divisões, calculou-se o número de mordidas dado, a quantidade de grama ingerida, dentre outros valores. Em Alvarenga (2016) pôde-se observar a variação nos valores de aceleração em cada um dos eixos dentro dos cinco comportamentos animais diferentes avaliados: andando, pastando, deitado, ruminando e parado em pé. Estes parâmetros são muito úteis quando se deseja diferenciar uma atividade da outra.

Para isso, pode ser usado o algoritmo de árvore de decisão (*decision-tree algorithm*) apresentado em Diosdado (2015), que consiste numa série de verificações de valores da aceleração capturada pelo sensor, comparando-os com limites pré estabelecidos, baseado na quantidade de movimento que o animal executa. Este algoritmo se mostrou muito eficaz na maioria das verificações, apresentando resultados muito satisfatórios, com mais de 80% de precisão na maioria dos comportamentos verificados.

Um fator que se mostrou importante ser bem escolhido é o tempo decorrido entre uma amostra e outra, chamado de época. O estudo de Guo (2018) utilizou épocas de 5, 10 e 15 segundos, onde a de 10 segundos obteve maior precisão na maior parte dos casos. Outros estudos utilizaram épocas maiores, como de 60 segundos, e estas se mostraram mais eficazes na detecção de atividades de pouco movimento, como quando o animal se encontra deitado ou parado em pé, por exemplo, devido ao fato de que há um tempo maior de ausência de movimento.

Devido à intensa movimentação dos animais em certas atividades, tais como correr, mostrou-se necessária a fixação do sensor no pescoço, bem como decidir entre fixá-lo apertando o pescoço da vaca, ou deixando-o mais solto, permitindo que este se movimente. Porém em ambos os casos observou-se que o sensor podia se mover e girar em torno do pescoço do animal, o que não é desejado que aconteça visto que existe a aceleração da gravidade constante no eixo vertical, e quando o sensor gira, esta aceleração muda de eixo, o que é um problema pois desta maneira nunca é possível saber exatamente em qual eixo a gravidade está agindo. Uma possível solução para isso seria a fixação do sensor em um lugar que impeça eventuais rotações, como embaixo da mandíbula do animal.

Uma solução diferente para esse problema é abordada em Hämäläinen (2018): analisar a arrancada em vez de analisar a

aceleração em si. A arrancada é o resultado da derivação da aceleração, isto é, a taxa com que a aceleração varia. Quando se faz isso, elimina-se a influência da aceleração da gravidade no sensor, visto que é uma constante, ou seja, sua taxa de variação é nula, e assim, facilita-se a análise visto que há menos interferências indesejadas.

Em Martiskainen (2009) é afirmado que os valores calculados como limites de distinção de atividades em diferentes estudos variam muito, e usa-se um método chamado Máquina de vetores de suporte (*support vector machine*) que é derivado do *machine learning* para resolver o problema e classificar os seis comportamentos estudados. Este método fez com que ocorressem algumas classificações incorretas de comportamentos parecidos, porém apresentou excelentes resultados no que se trata da captação dos mesmos.

Em di Virgilio (2018), foram utilizados dois sensores de movimentação compostos por um acelerômetro, um magnetômetro, sensor de pressão e temperatura, além de dados de GPS, para monitorar os comportamentos de 15 ovelhas e classificá-los em 7 diferentes categorias. Um dos sensores, na cabeça, foi satisfatoriamente exato para os 7 comportamentos.

Algumas outras abordagens como as mostradas analisam outros sinais além dos de aceleração, como sonoros e de tensão, verificando a ingestão de alimentos e líquidos por humanos.

PROCESSAMENTO DE SINAIS

Algumas vezes, quando é necessário utilizar sensores mais compactos e/ou mais baratos, estes podem apresentar falta de precisão no processamento dos sinais, o que pode ser corrigido com a utilização de filtros e outras técnicas.

O uso de microssensores inerciais é aplicado em diversos ramos da microeletrônica, e um problema apresentado por eles é a falta de precisão, causada pelo excesso de ruído apresentado. No entanto, é possível corrigi-la de várias maneiras, como em Stubberud (2008), onde utilizou-se a média aritmética juntamente com um Filtro de Kalman.

Dependendo do caso de uso, pode-se usar um filtro passa-baixa para eliminar o ruído, deixando apenas as frequências mais baixas do sinal, seja ele digital ou analógico, como em Dudak (2016), ou então, a implementação de uma rede neural para processá-lo.

Outra maneira de processar computacionalmente esses sinais é através de técnicas de *deep learning* como em Chen (2018), onde apenas a calibração não foi suficiente para suprir os erros dos sinais vindos dos sensores, principalmente o *offset* e o erro de fator de escala.

Uma maneira igualmente eficiente de eliminar ruídos em sinais é a calibração digital, conforme mostrada em Heinssen (2015).

O estudo em Nevlydov (2018) mostrou diversos métodos de processamento de sinais provenientes de um acelerômetro aplicados na detecção e diferenciação dos 8 diferentes estados de movimento de um robô, comparando os resultados de exatidão nessas detecções entre eles.

CONCLUSÃO

Baseado na análise realizada, é possível perceber quais são os tópicos mais importantes a serem analisados e como proceder o presente estudo.

A escolha correta da época de aquisição do sinal, seja este qual for, mostrou-se um dos aspectos mais relevantes para a análise dos dados, pois a partir de sua escolha adequada, podem ser obtidos resultados mais precisos e exatos. Baseado nos estudos analisados, é considerado adequado o uso de uma época de 10 segundos.

Um segundo aspecto considerado importante é a boa fixação dos sensores, sejam esses de quaisquer tipos, visto que se a movimentação destes for reduzida, os dados adquiridos serão mais sólidos e haverá menos erros, o que implica em uma maior precisão.

Finalmente, é desejável que haja testes em uma amostra de animais suficientemente grande para que seja possível estabelecer diferentes condições de monitoramento e comparar os sinais obtidos. Uma amostra de 6 ruminantes seria adequada.

AGRADECIMENTOS

Agradecimento à Fundação Araucária pelo apoio financeiro ao desenvolvimento deste trabalho.

REFERÊNCIAS

OUDSHOORN, F.; CORNOU C.; HELLWING, A., HANSEN, H.; MUNKSGAARD, L.; LUND, P.; KRISTENSEN, T. *Estimation of grass intake on pasture for dairy cows using tightly and loosely mounted di- and tri-axial accelerometers combined with bite count*. **Comput. Electron. Agric.** Vol. 99, pp. 227-235, Nov. 2013.

ALVARENGA, F.; BORGES, I.; PALKOVIC, L.; RODINA, J.; ODDY, V.; DOBOS, R. *Using a three-axis accelerometer to identify and*

*classify sheep behaviour at pasture, **Applied Animal Behaviour Science**. Vol. 181, pp. 91 – 99, 2016.*

DIOSDADO, J.A .V.; BARKER, Z. E.; HODGES, H. R.; AMORY, J. R.; CROFT, D. P.; BELL, N. J.; CODLING, E. A. *Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. **Animal Biotelemetry**. Vol. 3, p. 15, Jun 2015.*

GUO, L.; WELCH, M.; DOBOS, R.; KWAN, P.; WANG, W. *Comparison of grazing behaviour of sheep on pasture with different sward surface heights using an inertial measurement unit sensor. **Computers and Electronics in Agriculture**. Vol. 150, pp. 394 – 401, 2018.*

HÄMÄLÄINEN, W.; JÄRVINEN, M.; MARTISKAINEN, P.; MONONEN, J. *Jerk-based feature extraction for robust activity recognition from acceleration data. **2011 11th International Conference on Intelligent Systems Design and Applications**. Pp. 831-836, 2011.*

MARTISKAINEN, P.; JÄRVINEN, M.; SKÖN, J. P.; TIIRIKAINEN, J.; KOLEHMAINEN, M.; MONONEN, J. *Cow behaviour pattern recognition using a three-dimensional accelerometer and support vector machines. **Applied Animal Behaviour Science**. Vol. 119, no. 1, pp. 32 – 38, 2009.*

DI VIRGILIO, A.; MORALES, J. M.; LAMBERTUCCI, S.; SHEPARD, E.; WILSON, R. *Multi-dimensional precision livestock farming: A potential toolbox for sustainable rangeland management. **PeerJ**, vol. 6, 05 2018.*

STUBBERUD, P. A.; STUBBERUD, A. R. *A signal processing technique for improving the accuracy of mems inertial sensors. Pp. 13-18, Aug 2008.*

DUDAK, P.; SLADEK, I.; DUDAK, J.; SEDIVY, S. *Application of inertial sensors for detecting movements of the human body. Pp. 1-5, Dec 2016.*

CHEN, H. AGGARWAL, P.; TAHA, T. M.; CHODAVARAPU, V. P. *Improving inertial sensor by reducing errors using deep learning methodology. Pp. 197-202, 07 2018.*

HEINSEN, S.; HELLWEGE, N.; HEIDMANN, N.; PAUL, S.; DROLSHAGEN, D. P. *Robust digital calibration engine for mems inertial sensor systems. Pp. 1-4, Nov 2015.*

NEVLYDOV, I.; FILIPENKO, O.; VOLKOVA, M.; PONOMARYOVA, G. *Mems-based inertial sensor signals and machine learning methods for classifying robot motion. Pp. 13-16, 08 2018.*