

## Técnicas de reconhecimento de padrões no comportamento de bovinos em função de dados de GPS

Detectar rapidamente animais que precisam de atenção extra devido a problemas de saúde ou bem-estar são essenciais. Estas anormalidades podem ser detectadas pelas mudanças no tempo padrão gasto pelo animal em atividades cotidianas como, de pé, deitado, comendo, ruminando ou andando. O objetivo desta pesquisa foi analisar o comportamento de bovinos por meio de monitoramento animal utilizando sensores de posicionamento GPS, sensores inerciais e algoritmos de reconhecimento de padrões. Os animais foram observados por um analista de domínio e seus comportamentos foram anotados por meio de um software que confere precisão e facilita o treinamento dos algoritmos de classificação supervisionados. Os sensores, de baixo custo, foram montados em colares e instalados em 11 bovinos no pasto, num total de 42 dias incontinentes, enquanto esses animais foram observados à distância, e os seus comportamentos registrados, num total de 97 horas, em que foram anotados 35.211 comportamentos. Para este conjunto de dados foi obtida uma taxa média de acerto de 91,6% de classificação das atividades analisadas: pastando, andando, deitado descansando, deitado ruminando, de pé descansando e de pé ruminando.

**Palavras-chave:** Gado de Corte; Pecuária de Precisão; Etograma; Monitoramento Animal; Bem-Estar Animal.

## Techniques of recognition of patterns in bovine behavior in GPS data function

Rapidly animals spotting that need extra attention to health or wellness issues are essential. These abnormalities can be detected by changes in the standard time spent by the animal in daily activities such as standing, lying, eating or walking. The objective of this research was to analyze the cattle behavior through animal monitoring using GPS positioning sensors and pattern recognition algorithms. The animals were observed by a domain analyst and their behaviors were annotated through software that confers precision and ease to the training of the supervised classification algorithms. The low-cost GPS receivers were mounted on collars and installed in 11 cattle in the pasture, in a total of 42 non-continuous days, while these animals were observed from a distance, and their systems, for a total of 97 hours, 35,211 behaviors were recorded. For this dataset we obtained an average success rate of 86.1% of the classification of four activities analyzed: grazing, walking, lying, and standing.


**Keywords:** Beef Cattle; Livestock Precision; Ethogram; Animal Monitoring; Animal Welfare.


Topic: **Tecnologia, Modelagem e Geoprocessamento**


Received: **02/12/2018**

Reviewed anonymously in the process of blind peer.


Approved: **26/01/2019**

**Celso Correia de Souza**   
Universidade Anhanguera, Brasil  
<http://lattes.cnpq.br/2881392515816773>  
<http://orcid.org/0000-0002-2689-8264>  
[csouza939@gmail.com](mailto:csouza939@gmail.com)

**Leandro de Jesus**   
Universidade Anhanguera, Brasil  
<http://orcid.org/0000-0001-9805-5998>  
[leandro.jesus@ifms.edu.br](mailto:leandro.jesus@ifms.edu.br)

**Marcia Ferreira Cristaldo**   
Universidade Anhanguera, Brasil  
<http://lattes.cnpq.br/2008970440541776>  
<http://orcid.org/0000-0001-8790-7163>  
[marcia.cristaldo@ifms.edu.br](mailto:marcia.cristaldo@ifms.edu.br)

**Pedro Paulo Pires**  
Embrapa Gado de Corte de Campo Grande, Brasil  
<http://lattes.cnpq.br/0593414319480487>  
[edropaulo.pires@embrapa.br](mailto:edropaulo.pires@embrapa.br)

**Hevelyne Henn da Gama Viganó**   
Universidade Anhanguera, Brasil  
<http://lattes.cnpq.br/3698694854040529>  
<http://orcid.org/0000-0001-6951-7903>  
[hevelyne.vigano@ifms.edu.br](mailto:hevelyne.vigano@ifms.edu.br)



DOI: 10.6008/CBPC2179-6858.2019.001.0028

### Referencing this:

SOUZA, C. C.; JESUS, L.; CRISTALDO, M. F.; PIRES, P. P.; VIGANÓ, H. H. G.. Técnicas de reconhecimento de padrões no comportamento de bovinos em função de dados de GPS. **Revista Ibero Americana de Ciências Ambientais**, v.10, n.1, p.340-350, 2019. DOI: <http://doi.org/10.6008/CBPC2179-6858.2019.001.0028>

## INTRODUÇÃO

Os sintomas de alterações de estado de saúde e bem-estar de um animal afetam o seu comportamento. Mudanças no tempo padrão gasto pelo animal em atividades como de pé, deitado, comendo ou andando podem indicar anormalidades causadas por infecções, febre e estresse, social ou ambiental (GODSK et al., 2011).

Esses comportamentos geralmente são consistentes e previsíveis, mas não podem ser medidos em escala devido ao trabalho necessário para monitorar muitos animais de forma contínua. Assim, ferramentas de monitoramento e análise do comportamento animal se fazem necessárias para auxiliar no manejo do rebanho, na detecção de enfermidades, no melhoramento genético, ou na experimentação de outros gêneros bovinos, sob a hipótese de que a adoção desta tecnologia aceleraria a habilidade em perceber a adaptabilidade do animal ao ambiente (ANDERSON et al., 2013).

Os comportamentos mais comumente classificados na literatura são pastando, de pé, deitado e andando, entretanto, alguns trabalhos abordam também o comportamento ruminando (DUTTA et al., 2015; GONZÁLEZ et al., 2015; MARTISKAINEN et al., 2009). Robert et al. (2009) abordou apenas os comportamentos de pé, deitado e andando, enquanto que Moreau et al. (2009), os comportamentos andando, parado e pastando. Handcock et al. (2009) avaliaram comportamentos mais complexos do gado bovino, além dos dados de movimentação, a cobertura de pastagem e as relações sociais entre os animais do rebanho.

Dos principais sensores utilizados para medir movimentação tem-se como destaque a tecnologia GNSS (Global Navigation Satellite System - Sistema Global de Navegação por Satélite), utilizando o GPS. Oliveira (2013) e Godsk et al. (2011) utilizaram exclusivamente este dispositivo, enquanto Moreau et al. (2009), González et al. (2015) e Dutta et al. (2015) utilizaram GPS e acelerômetro. Diosdado et al. (2015), Huircán et al. (2010), Guo et al. (2009), Martiskainen et al. (2009), Robert et al. (2009) e Scheibe et al. (2006) também utilizaram sensores inerciais na medição de movimentação animal.

Martiskainen et al. (2009) coletaram dados de 30 animais por um período de 30 dias, enquanto Diosdado et al. (2015) monitoraram 6 animais por um período de apenas 36 horas. Godsk et al. (2011) monitoraram 14 vacas leiteiras no pasto por um dia. Neste trabalho, foi utilizada uma amostra de 11 animais em 3 anos diferentes num total de 849 horas de monitoramento.

Poucos estudos dispõem de informações detalhadas sobre os diversos comportamentos do gado bovino, dentre os quais pode-se citar Herbel et al. (1966), Zemo et al. (1970), Hall (1989) e, em especial, o etograma criado por Kilgour et al. (2012). Pastando, parado e ruminando s comportamentos que ocupam de 90% a 95% do dia dos bovinos (KILGOUR et al., 2012). Em alguns trabalhos (GODSK et al., 2011; ZHENG et al., 2008; HANDCOCK et al., 2009; NADIMI et al., 2008), os pesquisadores realizaram o processo de observação para a classificação utilizando caneta e papel.

O problema de reconhecimento de atividades bovinas foi abordado a partir de uma perspectiva de *software* e a classificação foi realizada utilizando-se um conjunto de ferramentas de aprendizagem de máquina, neste caso o *Weka Toolkit* (HALL et al., 2009). Este trabalho teve como objetivo apresentar um

método para a classificação de comportamentos animais por meio da otimização do pré-processamento dos dados brutos dos sensores - GPS, acelerômetro, giroscópio e magnetômetro - e a extração de características que servem como entrada para um algoritmo de aprendizagem automática.

## METODOLOGIA

Durante os períodos de coletas de dados para os experimentos quatro animais foram utilizados, sendo os mesmos apascentados em pastagem cultivada, de cerca de 52 hectares, e com suplementação mineral adequada, água à vontade, tratamento sanitário e manejados pelos profissionais da Embrapa – Gado de Corte (Campo Grande / MS) (Figura 1).



**Figura 1:** Mapa da área dos experimentos na Embrapa Gado de Corte, em Campo Grande/MS, em 2017.

Cada animal monitorado foi equipado com um colar. O colar é um dispositivo dotado de um sensor de posicionamento GPS, acelerômetro, giroscópio e magnetômetro, todos de 3 eixos; um sensor de radiação solar e um instrumento de medição de temperatura e humidade relativa do ar. Os dados foram armazenados em um cartão de memória para posterior recuperação manual, momento em que também era trocada a bateria do dispositivo.

Os comportamentos a serem classificados foram definidos como: pastando, andando, deitado descansando, deitado ruminando, de pé descansando, de pé ruminando e bebendo água. O analista de domínio, nesse caso um veterinário, observou os animais e anotou qual atividade o gado estava desempenhando, e em qual instante isso ocorreu. Neste trabalho foi desenvolvido um *software* de anotação do comportamento, denominado *Ápis*, para ser executado em qualquer dispositivo móvel com sensor GPS e que execute o sistema operacional *Android*.

Além dos dados de movimentos e posicionamentos gerados pelo colar, acoplado ao pescoço do animal, também foram registrados os tempos do satélite GPS. Esses tempos registrados nos dois dispositivos foram os elos que unem as observações do analista e os dados de posicionamento gerados pelo colar. Assim, o trabalho do analista é facilitado, pois suas ações consistem apenas em olhar para o animal e clicar no botão que representa a atividade que está sendo observada.

No primeiro conjunto de dados coletados, chamado de DB1, os quatro bovinos utilizados no experimento foram escolhidos aleatoriamente a partir de um rebanho de 38 animais. Um único animal foi utilizado por coleta. A razão para a utilização de um único bovino em cada coleta foi baseada no desafio prático de observar os animais. É importante salientar que a cada experimento, dos quatro realizados, o animal monitorado era escolhido aleatoriamente pela ordem de chegada no mangueiro. Os dados foram coletados no final do mês setembro e durante todo o mês de outubro.

As sequências de dados DB1 se resumiram a um total de 199 horas e 20 minutos de dados de posicionamentos GPS. O analista de domínio realizou a identificação de 3.220 atividades, enquanto os dados de GPS estavam sendo coletados pelo sensor nos animais. Desta coleção de dados de identificação de atividades, a atividade pastando foi classificada 1.641 vezes, seguido por deitado com 825 observações, andando com 453 observações e, finalmente, de pé, com 300 observações.

O segundo conjunto de dados foi gerado no ano posterior ao primeiro, definido como DB2. Dois animais foram equipados com os colares e observados em dois períodos diferentes. O primeiro aconteceu entre os dias 14 e 28 de maio de 2015. O segundo período de coleta do conjunto DB2 ocorreu entre os dias 25 de junho e 06 de julho de 2015.

As sequências de dados DB2 se resumiram em cerca de 513 horas de dados de posicionamento GPS. O analista de domínio realizou mais de 70 horas de observação e a identificação de 31.991 comportamentos, sendo 13.111 pastando, 1.328 bebendo água, 2.678 andando, 3.685 de pé descansando, 2.007 de pé ruminando, 4.230 deitado descansando e, 4.952 deitado ruminando. O terceiro período de coleta, DB3, foi realizado nos dias 09 a 10 de maio de 2017 e de 22 à 25 de junho de 2017, com 3 animais. As sequências de dados DB1, DB2 e DB3 estão relacionadas no Quadro 1.

**Quadro 1:** Sequências de dados coletados, em dias e horas, sobre o comportamento do gado.

Banco de dados	Dados de monitoramento		Dados de observação	
	No. de dias	No. de horas	No. de dias	No. de horas
DB1	11	199	8	26
DB2	25	513	16	71
DB3	06	137	-	-
<b>Total</b>	<b>42</b>	<b>849</b>	<b>24</b>	<b>97</b>

Os observadores, especialistas de domínios, foram posicionados em pontos estáticos para observarem os animais à distância. Com tais posicionamentos, foi inevitável, em algum sentido, a perturbação dos animais, já que os pontos de observação tinham que oferecer visadas aos animais, para garantir o contato visual sobre os mesmos em todos os momentos. Portanto, se um bovino parasse e olhasse para um observador por algum tempo, a sequência era simplesmente anotada como realizando a atividade de pé.

As sequências de dados utilizadas nos experimentos foram formadas por informações de posicionamento GPS e por dados dos sensores inerciais, acelerômetro, giroscópio e magnetômetro, nas quais os animais executavam as seguintes atividades: pastando, deitado descansando, deitado ruminando, andando, de pé descansando, de pé ruminando ou bebendo água.

A arquitetura do módulo de classificação do comportamento bovino foi inspirada pela pesquisa feita por Zheng et al. (2008) e Godsk et al. (2011). Os pesquisadores Zheng et al. (2008) reconheceram automaticamente diferentes modos de transporte humanos como caminhar, andar de bicicleta e dirigir automóvel a partir de dados brutos de GPS. No trabalho conduzido por Godsk et al. (2011), o tratamento de dados brutos de GPS foi utilizado para reconhecer os comportamentos primários de vacas.

Assim, foi definido dois blocos de análises: (1) Analisador de Movimento GPS (AMGPS), que transforma os dados brutos de posicionamento GPS, determina o movimento que ocorre entre duas medições sucessivas e produz uma estrutura de dados de saída; (2) Analisador de Movimento Inercial (AMI), que calcula o módulo da diferença entre duas medições sucessivas dos sensores acelerômetro, giroscópio e acelerômetro. Os atributos gerados pelos analisadores estão listados no Quadro 2.

**Quadro 2:** Resumo dos atributos gerados pelos analisadores a partir dos dados de monitoramento.

Identificação do atributo	Descrição do atributo	Descrição dos possíveis valores
Tipo do movimento	Uma representação discreta do movimento executado	Direita, esquerda, para trás, para frente, sem movimento
Ângulo	Ângulo relativo ao movimento anterior	Dado em graus
Magnitude	Distância percorrida entre duas medições	Dado em metros
Velocidade	Velocidade estimada de duas medições em cada instante	Dado em metros por segundo
Direção	Direção absoluta do movimento	Dado em graus
Aceleração	Calculada com base na velocidade estimada de duas medições	Dado em metros por segundo ao quadrado [m/(s*s)]
Hora	Hora do dia	De 1 a 24.
deltaAx	Módulo da diferença da aceleração no eixo x	Dado em metros por segundo ao quadrado [m/(s*s)]
deltaAy	Módulo da diferença da aceleração no eixo y	Dado em metros por segundo ao quadrado [m/(s*s)]
deltaAz	Módulo da diferença da aceleração no eixo z	Dado em metros por segundo ao quadrado [m/(s*s)]
deltaGx	Módulo da diferença da direção no eixo x	Dado em graus
deltaGy	Módulo da diferença da direção no eixo y	Dado em graus
deltaGz	Módulo da diferença da direção no eixo z	Dado em graus
deltaMx	Módulo da diferença da intensidade do campo magnético no eixo x	Dado em micro Tesla (uT)
deltaMy	Módulo da diferença da intensidade do campo magnético no eixo y	Dado em micro Tesla (uT)
deltaMz	Módulo da diferença da intensidade do campo magnético no eixo z	Dado em micro Tesla (uT)

O módulo da diferença entre duas medições dos sensores inerciais foi utilizado para evitar problemas de análise dos diferentes posicionamentos que o colar pode assumir no pescoço do animal. Do contrário, seria necessário prender o colar de forma que os sensores mantivessem o posicionamento em relação ao pescoço durante todo o experimento (Figura 2).

Por fim, para cada instância (exemplo), representada pelos atributos do Quadro 2, é associada uma observação feita pelo analista de domínio. A instância possui data e hora de início e fim, obtidas por meio do satélite GPS. A observação executada pelo analista do domínio, na qual ele identificou qual era atividade que o animal estava realizando, também teve registrado sua data e hora por meio do satélite GPS. Assim, foi possível sincronizar os segmentos com a observação.



**Figura 2:** Diferentes posicionamentos que o colar pode assumir em relação ao pescoço do animal. Destaque para as posições dos eixos do sensor acelerômetro.

Baseado nos atributos e na anotação, fornecida pelo analista de domínio, foi possível criar um banco de dados de instâncias previamente classificadas. Este banco de dados de exemplos serviu como entrada para as técnicas de aprendizagem de máquina, e implementadas pelo *Weka Toolkit* (HALL et al., 2009). Foi utilizado, mais especificamente, os algoritmos *END*, *Classification Via Regression*, *SVM (SMO)*, *Random Forest*, *J48* e *Multilayer Perceptron*. O problema de reconhecimento automático das atividades dos bovinos foi tratado utilizando-se um conjunto de algoritmos clássicos de aprendizagem de máquina.

## RESULTADOS

O banco de dados de exemplos balanceado tem 26985 instâncias classificadas pelo analista de domínio. Existem ainda, outras 1589836 instâncias que não possuem classificação pois são originadas do monitoramento dos bovinos em momentos que o analista de domínio não estava em campo. No primeiro experimento, utilizando as instâncias classificadas, foram testados alguns algoritmos de aprendizagem de máquina fornecidos pelo *Weka Toolkit* (HALL et al., 2009). Na Tabela 1 são apresentados os resultados obtidos destes testes, com o algoritmo *Random Forest* obtendo o melhor desempenho em termos de taxa de instâncias classificadas corretamente. O alto índice Kappa de 0,9030 indica que o resultado da classificação está muito próximo da concordância perfeita.

Para selecionar os algoritmos com melhor desempenho, foi avaliado a acurácia da classificação do modelo, utilizando o método *cross-validation* com 10 *fold*s. Neste método o conjunto de dados é dividido em 10 partes de tamanhos aproximados, nos quais 9 partes são utilizadas como conjunto de treinamento e a parte restante como conjunto de teste. O processo repete-se 10 vezes, até que todos os *fold*s sejam utilizados como conjunto de teste.

**Tabela 1:** Comparação da taxa de acerto (acurácia) entre algoritmos de classificação.

Algoritmo de Aprendizagem de máquina	Taxa de acerto na classificação	Kappa statistic
<b>END</b>	90,2 %	0,8867
<b>ClassificationViaRegression</b>	82,7 %	0,7983
<b>SVM (SMO)</b>	47,1 %	0,3833
<b>RandomForest</b>	91,6 %	0,9030
<b>J48</b>	84,9 %	0,8248
<b>MultilayerPerceptron</b>	61,1 %	0,5467

Na avaliação do modelo utilizando o algoritmo *Random Forest* o classificador apresentou acurácia média de 91,6%. Em um universo de 26985 instâncias, 24742 foram classificadas corretamente e 2243 incorretamente. Na Tabela 2 observa-se que a classe com a menor acurácia é a do comportamento em pé descansando, com 84,3%. As classes que representam a ruminação, deitado ruminando e em pé ruminando, marcaram 90% e 93,2%, respectivamente. Destaque para a classificação das classes andando e bebendo água que apresentaram acurácia de 98,3% e 98,7%.

**Tabela 2:** Precisão detalhada por classe utilizando o classificador *Random Forest*.

Classe	TP Rate	FP Rate	Precision	RRecall	F-Measure	MCC	ROC Area	PRC Area
Pastando/Procurando	0,899	0,022	0,87	00,899	0,884	00,865	0,989	0,941
EmPe-Descansando	0,843	0,014	0,912	00,843	0,876	00,857	0,985	0,947
Andando	0,983	0,011	0,94	00,983	0,961	00,954	0,999	0,993
Bebendo Água	0,987	0,005	0,972	00,987	0,979	00,976	0,999	0,997
Deitado-Descansando	0,875	0,012	0,924	00,875	0,898	00,883	0,988	0,955
Deitado-Ruminando	0,900	0,021	0,876	00,900	0,888	00,869	0,990	0,959
EmPe-Ruminando	0,932	0,012	0,927	00,932	0,929	00,918	0,994	0,981
<b>Média ponderada</b>	<b>0,917</b>	<b>0,014</b>	<b>0,917</b>	<b>00,917</b>	<b>0,917</b>	<b>00,903</b>	<b>0,992</b>	<b>0,968</b>

Onde: TP Rate - verdadeiros positivos: número de exemplos preditos positivos que são realmente positivos; FP Rate - falsos positivos: número de exemplos preditos positivos que são realmente negativos; Precision - fração daqueles preditos positivos que realmente são verdadeiros: TP / predito para a classe; Recall - Recall is the TP rate (also referred to as sensitivity); F-Measure - Is the harmonic mean of precision and recall:  $2 * (Precision * Recall) / (Precision + Recall)$ ; MCC - Um coeficiente de correlação entre as classificações observadas e previstas: Matthews correlation coefficient; ROC Area - A plot of true positive fraction (= sensitivity) vs. false positive fraction (=  $1 - specificity$ ) for all potential cut-offs for a test; PRC Area - A plot of true positive fraction Precision vs. Recall.

Na Tabela 3 é apresentada a matriz de confusão do modelo criado com o algoritmo *Random Forest*, mostrando detalhes do número de instâncias classificadas corretamente e incorretamente em cada classe. Analisando a classe EmPe-Descansando, que possui menor acurácia, observa-se que 215 instâncias foram classificadas incorretamente como Pastando/Procurando. Do total de exemplos incorretamente classificados para esta classe, 35,4% foram classificados como Pastando/Procurando e 18,7% Deitado-Descansando.

**Tabela 3:** Matriz de confusão utilizando o classificador RandomForest.

Classificação	a	b	c	d	e	f	g
a = Pastando/Procurando	3467	126	212	5	2	19	24
b = EmPe-Descansando	215	3248	21	63	114	98	96
c = Andando	59	4	3788	3	0	0	1
d = Bebendo Água	17	13	2	3806	5	8	4
e = Deitado-Descansando	112	59	3	20	3372	243	46
f = Deitado-Ruminando	89	41	1	10	133	3469	112
g = EmPe-Ruminando	28	71	4	10	25	125	3592

Analisando ainda a Tabela 3, verifica-se que os maiores erros nas classes Deitado-Descansando e Deitado-Ruminando são recíprocos. Assim, deve-se considerar nestes resultados os erros das observações em campo, pois um dos problemas identificados, na observação dos comportamentos, foi diferenciar os momentos em que o animal estava descansando ou ruminando, pois, dependendo da posição que ele estava, não era possível identificar se havia movimento de mastigação, característica que identifica o comportamento ruminando.

Outra observação é quanto ao movimento que caracteriza o comportamento ruminando. A variação da posição do pescoço do animal comparado ao comportamento descansando é pequena podendo dificultar a distinção dos dois comportamentos. O comportamento bebendo água obteve uma ótima acurácia média

de 98,7%. Este comportamento é caracterizado pela cabeça baixa do animal e pela ausência de movimento, características similares que o comportamento Pastando/Procurando pode assumir. Observa-se na matriz de confusão do modelo, Tabela 3, que a maior taxa de erro da classificação do comportamento é com a classe Pastando/Procurando (17 registros).

Uma característica que diferencia o comportamento bebendo água dos demais é a localização do animal no momento em que o comportamento acontece, considerando a posição fixa dos bebedouros na área de pastagem. O GPS coleta as coordenadas geográficas (latitude e longitude) do animal que podem ser utilizadas para validar o comportamento bebendo água. No entanto, não foi utilizada essa abordagem, porque a utilização das coordenadas geográficas na classificação apresenta um problema, o modelo fica restrito a dados coletados na mesma área dos dados utilizados na construção do modelo, ou seja, ele não pode ser generalizado para dados coletados em outras áreas.

## DISCUSSÃO

Analisando as matrizes de confusão apresentadas nos trabalhos de Godsk et al. (2011), Martiskainen et al. (2009) e González et al. (2015) foi verificado que existe uma grande desproporção entre o número de instâncias de cada classe. Essa situação faz com que os exemplos da classe minoritária sejam classificados incorretamente. Um problema trivial de estatística que deveria ser tratado.

Para o problema da classificação com classes desbalanceadas os autores não deveriam avaliar as acurácias dos modelos, devendo focar a análise em outras medidas, como: sensibilidade (recall), especificidade, precisão, medida F1 ou até mesmo análise ROC. Neste trabalho o problema das classes desbalanceadas foi resolvido utilizando-se as técnicas de reamostragem *SMOTE + Edited Nearest Neighbor Rule (ENN)* (BATISTA et al., 2014).

O trabalho de Martiskainen et al. (2009) classificou comportamentos utilizando o algoritmo SVM e um conjunto de dados, com 11.693 registros, obtidos de colares com acelerômetro triaxial de 30 vacas, mas, apenas 3508 registros rotulados pelo analista de domínio. Os resultados apresentados pelos autores são de uma bateria de testes realizada com 1.000 instâncias. Para efeito de comparativo, as classes deste trabalho, em pé-ruminando e deitado-ruminando foram agrupadas na classe ruminando e um novo modelo foi construído e validado.

Nadimi et al. (2012) também utilizou um acelerômetro preso em um colar. O conjunto de dados utilizado possuía 1.782.000 registros do acelerômetro. O modelo de classificação foi construído com um algoritmo de Rede Neural Artificial utilizando 75% dos registros, enquanto os outros 25% foram utilizados na validação. Comparando a acurácia da classificação de cada classe, apresentada por Nadimi et al. (2012), com as obtidas neste trabalho, constata-se que todas elas tiveram melhor resultado no modelo aqui proposto.

Os resultados dos comparativos apresentados, Tabela 4, servem apenas como base para indicar os valores obtidos neste trabalho e os apresentados por outros. Considerando que os conjuntos de testes são diferentes, assim como o número de animais e o tempo de observação, não é justo afirmar que os resultados



de um ou outro são melhores. Além disso, nenhum dos trabalhos do comparativo realizou a diferenciação das posições da ruminação, em pé ou deitado.

**Tabela 4:** Comparativo dos resultados obtidos com trabalhos relacionados. Em negrito a acurácia obtida nesta pesquisa;

Classes	Martiskainen et al. (2009)	Nadimi et al. (2012)	Godsk et al. (2011)	Dutta et al. (2015)	González et al. (2015) A	González et al. (2015) B
Pastando	81% / <b>91,7%</b>	83,8% / <b>91,5%</b>	90,0% / <b>91,5%</b>	93% / <b>93,8%</b>	93,7% / <b>93,8%</b>	98,4% / <b>93,8%</b>
Andando	79% / <b>99,0%</b>	73,8% / <b>99,0%</b>	100% / <b>99,0%</b>	97% / <b>99,4%</b>	83,8% / <b>99,4%</b>	27,7% / <b>99,4%</b>
Em Pé	65% / <b>87,5%</b>	71,8% / <b>90,0%</b>	75,8% / <b>90,0%</b>	92% / <b>85,8%</b>	60,7% / <b>85,8%</b>	86,3% / <b>85,8%</b>
Deitado	83% / <b>89,9%</b>	83,2% / <b>93,9%</b>	76,5% / <b>93,9%</b>	Descansando	Descansando	Descansando
Ruminando	86% / <b>90,9%</b>	-	-	97% / <b>92,4%</b>	96,9% / <b>92,4%</b>	87,3% / <b>92,4%</b>

Os resultados são similares ao trabalho de Godsk et al. (2011) para as classes pastando/procurando e andando. Porém, o uso exclusivo do sensor GPS gerou dificuldade para diferenciar atividades que possuem como definição a ausência de movimento, em pé e deitado, prejudicando a acurácia no modelo proposto pelos autores.

No trabalho de Dutta et al. (2015) foram utilizados sensores similares aos desta pesquisa (GPS + acelerômetro). O trabalho monitorou 24 vacas e obteve um conjunto de dados com 19.603 registros, dos quais 50% foram utilizados para treinar o modelo e os outros 50% para validá-lo, utilizando o algoritmo *Bagging* com um treinador baseado em árvore de decisão. O trabalho não diferenciou os momentos que o animal estava em pé e deitado, apenas distinguindo os momentos que o animal estava descansando e ruminando, além dos momentos que estava andando e pastando.

Para possibilitar a comparação dos resultados, agrupou-se as classes Em Pé-Descansando e Deitado-Descansando na categoria Descansando, e as classes Em Pé-Ruminando e Deitado-Ruminando na categoria Ruminando, e um novo modelo foi construído e validado, com o algoritmo *Random Forest* e o método *cross-validation*. A acurácia média obtida foi de 92,8%, enquanto Dutta et al. (2015) obteve 96%.

O trabalho de Dutta et al. (2015) só não obteve melhor resultado na classe Pastando e Andando. Uma diferença na técnica utilizada pelos autores foi analisar os dados em segmentos agrupados de 5 segundos, enquanto neste trabalho os dados foram analisados pontualmente, ou seja, apenas o momento em que haviam anotações do comportamento no *software* para observação. Além disso, eles capturaram os dados em frequência diferente, 4 Hz o GPS e 10 Hz o acelerômetro, enquanto que neste trabalho os sensores estavam configurados na frequência de 1 Hz.

O trabalho de González et al. (2015) também utilizou os dados capturados por um GPS e um acelerômetro, configurados na mesma frequência de Dutta et al. (2015), agrupados em segmentos de 10 segundos e divididos em dois subconjuntos. O algoritmo de classificação foi desenvolvido baseado em árvore de decisão e os dados foram divididos em dois subconjuntos advindos de locais diferentes.

## CONCLUSÕES

Foi apresentado um processo para identificação do comportamento bovino utilizando dados brutos sensores de GPS, acelerômetro, giroscópio e magnetômetro. Os animais foram observados por um analista de domínio e seus comportamentos foram anotados por meio de um *software* que confere precisão na

anotação do analista de domínio e facilita o treinamento dos algoritmos de classificação supervisionados. A adição de dados de sensores inerciais ao colar foi crucial para resolver os problemas de similaridade dos comportamentos de pé e deitado, além de prover a possibilidade de reconhecer a atividade de ruminância.

Dos algoritmos de classificação testados o que obteve o melhor desempenho foi o algoritmo *Random Forest* com 91,6% de acertos identificando 7 classes: pastando, deitado descansando, deitado ruminando, andando, de pé descansando, de pé ruminando ou bebendo água. Por fim, os resultados foram comparados a outros trabalhos relacionados que utilizaram dados de GPS e sensores inerciais. Os resultados das classificações aqui obtidos, em geral, são mais robustos que os trabalhos avaliados, visto que, nesta abordagem é classificado automaticamente um número maior de comportamentos.

**AGRADECIMENTOS:** Agradecemos à Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso do Sul - FUNDECT.

## REFERÊNCIAS

ANDERSON, R. E. D.; CIBILIS, A.. Spatiotemporal cattle data: a plea for protocol standardization. **Positioning**, v.4, n.1, p.115-136, 2013.

DOI: <http://doi.org/10.4236/pos.2013.41012>

BATISTA, G.; PRATI, R.; MONARD, M.. A Study of the Behavior of Several Methods for Balancing Machine Learning Training Data. **ACM SIGKDD Explorations Newsletter**, v.6, n.1, p.20-29, 2004.

DOI: <http://doi.org/10.1145/1007730.1007735>

DIOSDADO, J. V.; BARKER, Z.; HODGES, H.; AMORY, J.; CROFT, D.; BELL, N.; CODLING, E.. Classification of behaviour in housed dairy cows using an accelerometer based activity monitoring system. **Animal Biotelemetry**, v.3, n.1, p.15, 2015 DOI: <http://doi.org/10.1186/s40317-015-0045-8>

DUTTA, R.; SMITH, D.; RAWNSLEY, R.; BISHOP-HURLEY, G.; HILLS, J.; TIMMS, G.; HENRY, D.. Dynamic cattle behavioural classification using supervised ensemble classifiers. **Computers and Electronics in Agriculture**, v.111, p.18-28, 2015. DOI <http://doi.org/10.1016/j.compag.2014.12.002>

GODSK, T.; KJAERGAARD, M. B.. High classification rates for continuous cow activity recognition using low-cost GPS positioning sensors and standard machine learning techniques. In: PROCEEDINGS OF THE INTERNATIONAL CONFERENCE ON ADVANCES IN DATA MINING: APPLICATIONS AND THEORETICAL ASPECTS, 11. **Anais**. Berlin: Heidelberg, 2011. p.174-188.

GONZÁLEZ, L.; BISHOP-HURLEY, G.; HANDCOCK, R.; CROSSMAN, C.. Behavioral classification of data from collars containing motion sensors in grazing cattle. **Computers and Electronics in Agriculture**, v.110, p.91-102, 2015. DOI: <http://doi.org/10.1016/j.compag.2014.10.018>

GUO, Y.; POULTON, G.; CORKE, P.; BISHOP-HURLEY, G. J.; WARK, T.; SWAIN, D. L.. Using accelerometer, high sample rate GPS and magnetometer data to develop a cattle movement and behaviour model. **Ecological Modelling**,

v.220, n.17, p.2068-2075, 2009. DOI:

<http://doi.org/10.1016/j.ecolmodel.2009.04.047>

HALL, S. J. G.. Chillingham cattle: social and maintenance behaviour in an ungulate that breeds all year round. **Animal Behaviour**, v.38, n.2, p.215-225, 1989. DOI:

[http://doi.org/10.1016/S0003-3472\(89\)80084-3](http://doi.org/10.1016/S0003-3472(89)80084-3)

HALL, M.; FRANK E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H.. The weak data mining software: an update. **ACM SIGKDD Explorations Newsletter**, v.11, n.1, p.10-18, 2009.

DOI: <http://doi.org/10.1145/1656274.1656278>

HANDCOCK, R. N.; SWAIN, D. L.; BISHOP-HURLEY, G. J.; PATISON, K. P.; WARK, T.; VALENCIA, P.; CORKE, P.; O'NEILL, C. J.. Monitoring animal behaviour and environmental interactions using wireless sensor networks, GPS collars and satellite remote sensing. **Sensors**, v.9, n.5, p.3586-3603, 2009. DOI: <http://doi.org/10.3390/s90503586>

HERBEL, C. H.; NELSON, A.. Activities of hereford and santa gertrudis cattle on a southern new mexico range. **Journal of Range Management**, v.19, p.173-176, 1966.

HUIRCÁN, J. I.; MUÑOZ, C.; YOUNG, H.; DOSSOW, L. V.; BUSTOS, J.; VIVALLO, G.; TONEATTI, M.. Zigbee-based wireless sensor network localization for cattle monitoring in grazing fields. **Computers and Electronics in Agriculture**, v.74, n.2, p.258-264, 2010.

DOI: <http://doi.org/10.1016/j.compag.2010.08.014>

INAMASU, R. Y.; NAIME, J. M.; RESENDE, A. V.; BASSOI, A. C. C. B.. **Agricultura de Precisão: Um Novo Olhar**. São Carlos: Embrapa Instrumentação, 2011.

KILGOUR, R. J.; UETAKE, K.; ISHIWATA, T.; MELVILLE, G. J.. The behaviour of beef cattle at pasture. **Applied Animal Behaviour Science**, v.138, n.1-2, p.12-17, 2012. DOI: <http://doi.org/10.1016/j.applanim.2011.12.001>

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**, v.119, n.1-2, p.32-38, 2009. DOI: <http://doi.org/10.1016/j.applanim.2009.03.005>

MOREAU, M.; SIEBERT, S.; BUERKERT, A.; SCHLECHT, E.. Use of a triaxial accelerometer for automated recording and classification of goats' grazing behaviour. **Applied Animal Behaviour Science**, v.119, n.3-4, p.158-170, 2009.

NADIMI, E.; JØRGENSEN, R.; BLANES-VIDAL, V.; CHRISTENSEN, S.. Monitoring and classifying animal behavior using zigbee-based mobile ad hoc wireless sensor networks and artificial neural networks. **Computers and Electronics in Agriculture**, v.82, p.44-54, 2012. DOI: <http://doi.org/10.1016/j.compag.2011.12.008>

OLIVEIRA, M. T. P.. **Análise Comportamental de Bovinos Baseada em Trajetórias Semânticas Aplicada à Pecuária de Precisão**. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de Mato Grosso do Sul, Campo Grande, 2013.

ROBERT, B.; WHITE, B. J.; RENTER, D. G.; LARSON, R. L.. Evaluation of threedimensional accelerometers to monitor and classify behavior patterns in cattle. **Computers and Electronics in Agriculture**, v.67, n.1-2, p.80-84, 2009. DOI: <http://doi.org/10.1016/j.compag.2009.03.002>

SCHEIBE, K.; GROMANN, C.. Application testing of a new three-dimensional acceleration measuring system with wireless data transfer (WAS) for behavior analysis. **Behavior Research Methods**, v.38, n.3, p.427-433, 2006. DOI: <http://doi.org/10.3758/BF03192796>

ZEMO, T.; KLEMMEDSON, J.. Behavior of fistulated steers on a desert grassland. **Journal of Range Management**, Washington, v.23, n.3, p.158-163, 1970.

ZHENG, Y.; LIU, L.; WANG, L.; XIE, X.. Learning transportation mode from raw gps data for geographic applications on the web. In: PROCEEDINGS OF THE INTERNATIONAL CONFERENCE ON WORLD WIDE WEB, 17. **Anais**. New York, 2008. p.247-256. DOI: <http://doi.org/10.1145/1367497.1367532>

A CBPC – Companhia Brasileira de Produção Científica (CNPJ: 11.221.422/0001-03) detém os direitos materiais desta publicação. Os direitos referem-se à publicação do trabalho em qualquer parte do mundo, incluindo os direitos às renovações, expansões e disseminações da contribuição, bem como outros direitos subsidiários. Todos os trabalhos publicados eletronicamente poderão posteriormente ser publicados em coletâneas impressas sob coordenação da **Sustenere Publishing**, da Companhia Brasileira de Produção Científica e seus parceiros autorizados. Os (as) autores (as) preservam os direitos autorais, mas não têm permissão para a publicação da contribuição em outro meio, impresso ou digital, em português ou em tradução.