

## Determinação do comportamento de bovinos de leite a pasto baseado em dados de localização GPS e ambientais

Ingrid do Nascimento Bezerra,\* Pedro Henrique Dias Batista,\* Anderson Silva Santos,\*\* Cristiane Guiselini,\* Gledson Luiz Pontes de Almeida,\* Glauco Estácio Gonçalves,\*\*\* Victor Wanderley Costa de Medeiros\*\*

\*Universidade Federal Rural de Pernambuco, Departamento de Engenharia Agrícola,  
BR (Tel: 81-995043659; e-mail: ingridnascimentob@hotmail.com; giga\_pedro@hotmail.com; cristiane.guiselini@ufrpe.br; gledson.almeida@ufrpe.br).

\*\* Universidade Federal Rural de Pernambuco, Departamento de Estatística e Informática, BR (e-mail: anderson.silvasantos@ufrpe.br; victor.wanderley@ufrpe.br)

\*\*\* Universidade Federal do Pará, Instituto de Tecnologia, BR (e-mail: glaucogoncalves@ufpa.br)

**Abstract:** Automated determination of animal behavior through machine learning algorithms has become increasingly common in the study of animal behavior. This research aims to evaluate the performance of Random Forest, Bagging, and J48 classifiers in determining the behavior of dairy cattle on pasture using data obtained by GPS positioning sensors and environmental sensors. The data used were collected from three Girolando heifers with an average weight of 300 kg. The segmentation of variables was applied to GPS data collected from the 3 animals and provided the latitude and longitude per minute of each one of them. A mini meteorological station was installed in the study area to record environmental variables. To evaluate the classifiers, the Weka Toolkit 3.8.5 was used. Three classes of behavior were considered: eating, ruminating, and idleness. For the analyses, the trial and error method was used where the environmental variables of dry-bulb temperature in pasture and shade, relative humidity in pasture and shade, black globe temperature in shade, dew point temperature in shade, class, position, and location were being removed individually until a better accuracy in the classification of behaviors was observed. For evaluation, the cross-validation method with 10 folds was used. Random Forest and Bagging showed similar performance with an accuracy of 70.83%, while J48 had an accuracy of 65.1%.

**Resumo:** Determinar o comportamento animal de maneira automatizada por meio de algoritmos de aprendizagem de máquina vem tornando-se cada vez mais comum no estudo do comportamento animal. O principal objetivo desta pesquisa é avaliar o desempenho dos classificadores Random Forest, Bagging e J48 na determinação do comportamento de bovinos de leite a pasto utilizando dados obtidos por sensores de posicionamento GPS e sensores ambientais. Os dados utilizados foram coletados de três novilhas da raça Girolando com peso médio de 300 Kg. A segmentação de variáveis foi aplicada a dados do GPS coletados dos 3 animais e forneciam a latitude e longitude por minuto de cada um deles. Na área de estudo foi instalada uma mini estação meteorológica para registro das variáveis ambientais. Para avaliação dos classificadores utilizou-se o Weka Toolkit 3.8.5. Foram consideradas três classes de comportamento: comendo, ruminando e ócio. Para as análises foi utilizado o método de tentativa e erro onde as variáveis ambientais de temperatura de bulbo seco no pasto e à sombra, umidade relativa no pasto e à sombra, temperatura de globo negro à sombra, temperatura do ponto de orvalho à sombra, classe, posição e local foram sendo removidas de forma individual até que fosse observada uma melhor acurácia na classificação dos comportamentos. Para avaliação foi utilizado o método de cross-validation com 10 folds. O Random Forest e o Bagging apresentaram desempenho semelhante com uma acurácia de 70,83%, enquanto o J48 apresentou uma acurácia de 65,1%.

**Keywords:** Comportamento animal, aprendizagem de máquina, Random Forest, Bagging, J48.

### 1. INTRODUÇÃO

A pecuária de precisão é definida como a aplicação de princípios e técnicas de engenharia de processo à pecuária para monitorar, modelar e gerenciar automaticamente a produção animal (Tullo; Finzi; Guarino, 2019). Ela vem se disseminando mundialmente por sua utilização em fazendas tanto no sistema intensivo quanto extensivo (Lovarelli; Bacenetti; Guarino, 2020) de modo a aperfeiçoar os custos de

produção, reduzir os impactos ambientais e aumentar a produtividade. Dessa forma, ferramentas de monitoramento e análise do comportamento animal são necessárias para auxiliar na detecção de enfermidades, melhoramento genético, entre outros fatores, permitindo uma melhor percepção da adaptabilidade do animal ao ambiente em que ele está inserido (Anderson & Cibils, 2013). A determinação automática do comportamento animal tornou-se cada vez mais precisa e presente na pecuária de precisão (Werner et al.,

2019; Williams; James; Rose, 2019). Em Homburger et al. (2014), um modelo de monitoramento de vacas leiteiras que utiliza o sistema de posicionamento global GPS através de técnicas de mineração e aprendizagem de máquina é apresentado. Williams et al. (2016) tiveram como objetivo construir um modelo autônomo de monitoramento de rebanhos de vacas, através de dados do GPS coletados por colares ao redor do pescoço das vacas. Para isso, utilizaram técnicas de mineração de dados e de aprendizagem de máquina, Naive Bayes, JRip, J48 e Random Forest, para classificar três categorias de comportamento: pastando, repouso e caminhando.

Os algoritmos de aprendizagem de máquina supervisionado (AMS) são classificadores que interpretam dados e uma das possíveis aplicações é a determinação do comportamento de bovinos de maneira automatizada. Por meio destas interpretações é possível observar a frequência de ocorrência de determinados comportamentos, auxiliando o pecuarista no manejo do rebanho. Na pecuária de precisão a identificação individual do gado é necessária para a análise automatizada dos animais, tornando-se possível monitorar o potencial de cada animal, em busca de melhores estratégias de manejo (Qiao et al., 2020).

## 2. MATERIAIS E MÉTODOS

Os dados utilizados nesta pesquisa foram coletados no contexto do trabalho de dissertação de mestrado intitulado “Comportamento de bovinos de leite a pasto e variabilidade espacial de atributos físicos do solo em função da intensidade de pisoteio”, de autoria do aluno do Programa de Pós-graduação em Engenharia Agrícola da UFRPE, Pedro Henrique Dias Batista. Estes dados foram coletados em uma propriedade comercial de bovinos de leite, localizada no município de Capoeiras, Mesorregião Agreste do Estado de Pernambuco, latitude  $8^{\circ}36'S$ , longitude de  $36^{\circ}37'W$  e altitude de 850 m, no período de 16/10/2016 à 05/11/2016. Segundo a classificação climática de Köppen, o clima da região é caracterizado como semiárido (Bsh). A precipitação pluviométrica média anual da região é de 588 mm (Figura 1).

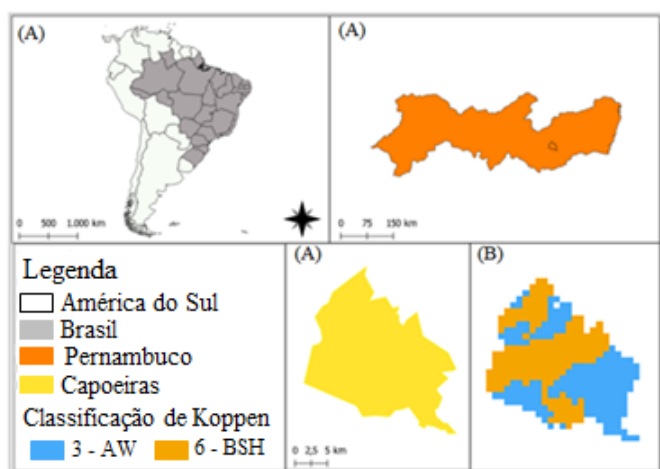


Fig. 1 Mapa localização da fazenda Roçadinho (A); Classificação de Köppen (B).

### 2.1 Experimento em Campo

Na propriedade, delimitou-se um piquete de  $40 \times 40$  m com anexo de área de descanso para os animais medindo  $8 \times 10$  m, compreendendo bebedouro e área de sombra com cerca de  $15 \text{ m}^2$  (Figura 2). A área foi manejada em sistema de pastejo contínuo sob pastagem de *Brachiária decumbens*. Foram utilizadas três novilhas da raça Girolando com peso médio de 300 kg.

### 2.2 Construção dos Colares

Os animais foram monitorados a partir de um protótipo composto por placas de prototipação Arduino modelo UNO R3 alimentada por três baterias de 3800 mAh e *shield* GPS, ou seja, um módulo GPS que transforma o Arduino em um receptor GPS, com armazenamento de dados em um cartão SD, gravando informações de posicionamento global (latitude e longitude) dos animais (Figura 2). A placa de prototipação Arduino UNO R3 utiliza um microcontrolador AT-mega328, com 2KB de memória SRAM e frequência de clock de 16 MHz. O *shield* GPS tem dimensões de  $62 \times 53 \times 24,5$  mm e é composto pelo módulo Ublox NEO-6M, recebendo dados de até três sistemas de satélites simultâneos (Galileo, GLONASS e BeiDou) e frequência de 1575,42 MHz. Os equipamentos foram programados usando a linguagem C/C++ e configurados para registrar o posicionamento dos animais na área com intervalo de 1 (um) minuto, durante o período de pastejo. O GPS apresentou autonomia de 15 horas. O equipamento é protegido por uma caixa acrílica, para evitar danos causados pelos animais ou chuva, e acomodados em coleiras de couro que foram colocadas na região do pescoço dos animais.




Fig. 2 Hardware do sistema desenvolvido (A); protótipo da coleira (B); coleira presa ao animal (C)

### 2.3 Base de Dados

A base de dados original utilizada neste trabalho possui 200 instâncias de dados contemplando cinco classes de comportamento: comendo, bebendo, andando, ruminando e ócio. No entanto, os comportamentos ‘bebendo’ e ‘andando’ foram removidos da base de dados devido à baixa quantidade de observações, apenas 8. Desta forma, foram utilizadas 192 instâncias referentes às classes ‘comendo’, ‘ruminando’ e ‘ócio’. A Tabela 1 indica um exemplo de instâncias da base de dados, onde também estão contidos as coordenadas geográficas latitude e longitude, e as variáveis meteorológicas: temperatura de bulbo seco - pasto/sombra, Umidade relativa - pasto/sombra, temperatura de globo negro - sombra e temperatura do ponto de orvalho - sombra.

**Tabela 1. Instâncias aleatórias da base de dados.**

REGISTROS	1°	2°	3°	4°
Latitude	-861.97	-861.97	-861.97	-861.97
Longitude	-3.661.3	-3.661.3	-3.661.3	-3.661.3
Tbs-Pasto	18.661	18.484	18.485	18.485
Ur-Pasto	82.303	82.391	82.419	82.419
Tbs-Sombra	18.129	18.200	18.176	18.176
Ur-Sombra	87.859	87.662	87.345	87.345
Tgn-sombra	32.742	32.536	32.842	32.842
Tpo-Sombra	16.105	16.140	16.060	16.060
Posição	Em-pé	Deitada	Deitada	Em-pé
Local	Pasto	Pasto	Sombra	Pasto
Classe	Comendo	Ruminando	Ócio	Ócio

Tbs: temperatura de bulbo seco; Ur: umidade relativa; Tgn: temperatura de globo negro; Tpo: temperatura ponto de orvalho.

### 2.3.1 Atividades Comportamentais

Para verificar o tempo que os animais passaram dependendo as diferentes atividades comportamentais, na área de estudo instalou-se uma câmera Full HD com tecnologia infravermelho em que as imagens foram gravadas 24 horas nos dias 26 e 27/10/16; 01 e 02/11/16. A câmera foi posicionada de forma que o campo visual incluísse toda a área de pastejo.

Os parâmetros comportamentais dos animais foram registrados pela adaptação do método de varredura instantânea (ALTMANN, 1974), em que o vídeo foi pausado a cada 10 min, e observou-se o comportamento dos animais para aquele instante. As atividades comportamentais dos animais foram classificadas como classes: comendo, ruminando, ócio; postura: em pé e deitado e local: área de sombra e área de pasto (Tabela 2) conforme a classificação feita por Almeida et al. (2013).

**Tabela 2. Descrição das atividades comportamentais.**

Classes	Descrição
Comendo	Apreensão de forragem durante o pastejo
Ruminando	Regurgitação, mastigação e deglutição
Ócio	Em pé ou deitada, sem realizar nenhuma das atividades anteriores
Postura	Descrição
Em pé	Em pé sobre as quatro patas
Deitado	Sobre as patas ou em decúbito
Local	Descrição

Sombra	Quando o animal estiver presente na área de sombra ou descanso
Pasto	Quando o animal estiver presente na área de pastagem

### 2.3.2 Variáveis Meteorológicas

Foram registradas as variáveis meteorológicas, temperatura de bulbo seco (TBS, °C) e umidade relativa do ar (UR, %) a cada dez minutos, na área de descanso dos animais e em abrigo meteorológico, através de *datalogger* modelo Hobo U12-12 (Onset Computer Corporation Bourne, MA, USA).

### 2.4 Classificação dos Comportamentos

#### 2.4.1 Métrica Utilizada

A métrica utilizada neste trabalho foi a acurácia, sendo definida como exatidão de um valor obtido com relação a um valor tomado como referência. Ela funciona como uma indicação geral de como o modelo performou (1).

$$Acurácia = \frac{VP + VN}{VP + FP + VN + FN} \quad (1)$$

VP - verdadeiro positivo; VN - verdadeiro negativo; FP - falso positivo; FN - falso negativo.

#### 2.4.2 Ferramenta Weka

A ferramenta Waikato Environment for Knowledge Analysis (WEKA) é uma coleção de algoritmos de aprendizado de máquina, que além de possuir uma grande coleção de algoritmos, desde os mais clássicos aos mais atuais, possibilita a inclusão de novos desde que atendam aos requisitos descritos pelo *software*. Segundo Witten, Frank e Hall (2011) o WEKA foi criado para permitir a experimentação rápida de métodos existentes em novos conjuntos de dados de maneira flexível, ele ainda fornece um suporte para todo o processo de mineração de dados experimental e conta com uma grande variedade de ferramentas de pré-processamento.

#### 2.4.3 Métodos

Os algoritmos de classificação utilizados neste trabalho são implementados e executados pela ferramenta WEKA. O critério de escolha dos algoritmos utilizados teve como base análises e pesquisas recentes relacionadas ao comportamento animal com classificadores que apresentaram bons valores de acurácia, sendo eles Random Forest, Bagging e J48, ambos avaliados para se estabelecer o classificador mais adequado para determinar de maneira automática o comportamento do animal, observando a corretude em comparação com os dados obtidos de maneira visual. Estes algoritmos foram capazes de interpretar os dados e classificá-los em uma das três possíveis classes, sendo elas: comendo, ruminando e ócio. Para as análises foi utilizado o método de tentativa e erro onde as variáveis de temperatura de bulbo seco no pasto e à sombra, umidade relativa no pasto e à sombra, temperatura de globo negro à sombra, temperatura do ponto de orvalho à sombra,

classe, posição e local foram sendo removidas de forma individual até que fosse observada uma melhor acurácia.

#### 2.4.3.1 *Árvore de Decisão*

Uma árvore de decisão é uma estrutura hierárquica dos dados, formada por um conjunto de elementos baseada em estágios de decisão que são denominados nós, estes nós são divididos em três tipos, o de probabilidade, representado por um círculo, que mostra as probabilidades de certos resultados, o nó de decisão, representado por um quadrado, que mostra uma decisão a ser tomada, e um nó de término, que mostra o resultado final de um caminho de decisão. Essa árvore se inicia com apenas um nó, que se divide em possíveis resultados, cada um desses resultados leva a outros nós adicionais que se ramificam levando a outras possibilidades. Esse modelo determina as melhores decisões no processo de análise, com a divisão do conjunto de dados em subconjuntos (Subudhi; Traço; Sabut, 2020).

#### 2.4.3.2 *Random Forest*

O algoritmo Random Forest (floresta aleatória) é um método que consiste na combinação de várias árvores de decisão que diferem entre si e não possuem relação (Subudhi; Traço; Sabut, 2020). Seu funcionamento consiste na criação do *Bootstrapped Dataset* (seleção de amostras de forma aleatória), a partir daí a cada passo é selecionado um número N de características (*features*), sendo as características, e as diversas árvores criadas a partir de subconjuntos diferentes. Posteriormente, a instância de teste deve percorrer cada árvore da floresta e o algoritmo fará as previsões utilizando os resultados que mais aparecem em casos de um problema de classificação, ou através da média dos valores obtidos.

#### 2.4.3.3 *J48*

O algoritmo J48 procura criar uma árvore de decisão a partir de um conjunto de dados, envolvendo variáveis qualitativas contínuas e discretas presentes na base de dados. Por isso, é muito utilizado no processo de descoberta de conhecimento e de criação de árvores de decisão, também é um classificador que pode apresentar os melhores resultados na indução de árvores de decisão, através de um conjunto de dados de treinamento. Para induzir uma árvore de decisão, o J48 utiliza a abordagem de dividir-para-conquistar, ou seja, divide um problema complexo em vários subproblemas mais simples, aplicando a mesma estratégia a cada subproblema, dividindo o espaço definido pelos atributos em subespaços, associando-se a eles uma classe (Costa; Bernardini; Filho, 2014).

#### 2.4.3.4 *Bagging*

O *Bagging* também chamado de *Bootstrap Aggregating* é caracterizado pela criação de múltiplas amostras, a partir de um conjunto de dados, de forma que seja possível construir várias árvores de decisão de forma sequencial para um mesmo preditor. Com isso, o *Bagging* tem como vantagem a redução de erros nos preditores de linha de base aumentando significativamente a estabilidade dos modelos na redução da variância e na melhoria da precisão (Ribeiro & Coelho, 2020).

#### 2.4.4 *Método Cross-validation*

Os registros realizados na coleta foram agrupados em um único arquivo ‘.ARFF’, sendo utilizado para avaliar cada um dos algoritmos. Por meio dos algoritmos selecionados, foi avaliada a acurácia da classificação do modelo, utilizando o método *cross-validation* com 10 *folds*. Neste método o conjunto de dados é dividido em 10 partes de tamanhos aproximados, onde 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 *folds* sejam utilizados como teste (Berrar, 2019).

### 3. RESULTADOS E DISCUSSÃO

Foram testados três algoritmos de aprendizagem de máquina (Random Forest, Bagging e J48) disponíveis no *Weka Toolkit*, para determinar qual seria o melhor classificador de todas as variáveis analisadas (Classe, postura, local, Umidade relativa - sombra/ pasto, Temperatura de bulbo seco - sombra/ pasto, Temperatura de ponto de orvalho - sombra, Temperatura de globo negro - sombra, latitude e longitude). O algoritmo Random Forest obteve o melhor desempenho com 70,83% de acurácia (Tabela 2) para a classificação que possuía todos os dados exceto a variável Temperatura de bulbo seco – sombra (Tbs<sup>1</sup>), já o algoritmo Bagging apresentou melhor desempenho também com 70,83% de acurácia (Tabela 2) para a classificação que possuía todos os dados e para a classificação que possuía todos os dados com exceção da Umidade relativa – sombra (Ur<sup>2</sup>). Com 65,1% de acurácia (Tabela 2), o algoritmo J48 obteve melhor desempenho para a classificação sem a variável Temperatura de ponto de orvalho - sombra (Tpo<sup>2</sup>). Dos três classificadores o que apresentou menor desempenho foi o J48, que apresentou menores valores de acurácia quando comparadas todas as classificações com os algoritmos Random Forest e Bagging.

A ação dos elementos meteorológicos como a temperatura de bulbo seco, umidade relativa, temperatura de ponto de orvalho e temperatura de globo negro podem interferir no comportamento dos animais (Batista et al., 2019). Por isso, alterações nos valores das variáveis meteorológicas podem influenciar no tempo em que os animais despendem para realizar as classes comendo, bebendo e ócio. Portanto, essas variáveis quando relacionadas com o comportamento dos animais, podem interferir nos valores de acurácia (Tabela 3).

**Tabela 3. Comparação dos valores de acurácia dos algoritmos utilizados com validação cruzada de 10 *folds*.**

Descrição	Random Forest	Bagging	J48
Todas as variáveis	69,27	70,83	62,5
Todas as variáveis exceto: Tbs <sup>1</sup>	70,83	68,75	63,02
Todas as variáveis exceto: Ur <sup>1</sup>	69,27	70,83	63,02
Todas as variáveis exceto: Tpo <sup>2</sup>	69,27	70,31	65,1
Todas as variáveis exceto: Ur <sup>1</sup> , Ur <sup>2</sup> e Tpo <sup>2</sup>	70,31	69,27	64,06

Ur<sup>1</sup> - Umidade relativa - pasto; Ur<sup>2</sup> - Umidade relativa - sombra; Tbs<sup>1</sup> - Temperatura de bulbo seco - sombra; Tpo<sup>2</sup> - Temperatura de ponto de orvalho - pasto.

Resultados semelhantes aos encontrados no presente estudo foram achados por Riaboff et al. (2020) que avaliaram o comportamento de vacas-leiteiras a pasto utilizando dados de GPS combinados com dados de um acelerômetro, obtendo resultados superiores a 97% de acurácia utilizando o algoritmo Random Forest com validação cruzada de 10 *folds* para os dados de treinamento. Para o classificador Bagging, Dutta et al. (2015) ao avaliar várias técnicas de aprendizado de máquina supervisionado para classificar o comportamento do gado, através de dados de um acelerômetro combinados com GPS identificaram alguns comportamentos sendo eles, pastoreio, ruminação, descanso e caminhada, utilizando o Bagging obtiveram 96% de acurácia para a média de todos os comportamentos.

Williams et al. (2019) relataram uma acurácia geral de 94% utilizando o algoritmo J48 com validação cruzada *k - fold* com  $k = 10$  para classificar o comportamento de vacas-leiteiras com os dados de GPS que incluíam latitude, longitude e velocidade, os comportamentos registrados foram pastando, descanso e andando.

É importante destacar que uma quantidade maior de dados permite uma melhor caracterização do fenômeno observado. Os trabalhos citados aqui utilizaram um número maior de animais, capturaram mais dados e observaram valores de acurácia mais elevados (Dutta et al. 2015, 24 animais; Williams et al. 2019, 40 animais; e Riaboff et al. 2020, 26 animais). Neste trabalho, utilizando apenas 3 animais e um conjunto bastante restrito de dados, observou-se uma acurácia da ordem de 70,83%, o que nos permite constatar o potencial dos algoritmos avaliados na determinação do comportamento de bovinos de leite a pasto.

#### 4. CONCLUSÕES

Por meio dos algoritmos de classificação foi possível determinar o comportamento animal de forma automatizada. Com 192 instâncias obteve-se uma acurácia de 70,83%, demonstrando o potencial dos algoritmos de aprendizagem de máquina na determinação do comportamento e contribuindo para a adoção da pecuária de precisão como ferramenta de suporte ao manejo de gado de leite a pasto. Na literatura poucos trabalhos inserem nos modelos de classificação variáveis ambientais e meteorológicas, porém na pecuária de precisão estas variáveis têm grande importância, pois influenciam diretamente no comportamento dos animais. Em trabalhos futuros pretende-se avaliar a acurácia em conjuntos maiores de dados bem como, novos algoritmos e novas métricas.

#### AGRADECIMENTOS

PET AgroEnergia (Programa de Educação Tutorial). Nós gostaríamos de agradecer a Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE APQ-0465-5.03 / 14) pelo apoio financeiro para o desenvolvimento desta pesquisa e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES, Brasil) para concessão de bolsas, ao Grupo de Pesquisa em

Ambiência Animal (GPESA) e ao Laboratório de pesquisa em infraestrutura computacional (Juá Labs).

#### REFERÊNCIAS

- Almeida, G. L., Pandorfi, H., Barbosa, S. B., Pereira, D. F., Guiselini, C., & de Almeida, G. A. (2013). Behavior, production and milk quality of Holstein-Gir cows under acclimatization in the corral/Comportamento, produção e qualidade do leite de vacas Holandes-Gir com climatização no curral. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 17(8), 892-900.
- Altmann, J. (1974). Observational study of behavior: sampling methods. *Behaviour*, 49(3-4), 227-266.
- Anderson, D. M., Estell, R. E., & Cibils, A. F. (2013). Spatiotemporal cattle data a plea for protocol standardization.
- Berrar, D. (2019). Cross-validation. *Encyclopedia of bioinformatics and computational biology*, v. 1, p. 542-545, 2019.
- Batista, P. H., de Almeida, G. L., Pandorfi, H., de Melo, A. A., Moraes, A. S., & Guiselini, C. (2019). Multivariate analysis of the behavior and physiology of Girolando heifers in pasture. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 23(4), 303-308.
- Costa, J. de J., Bernardini, F. C., & Viterbo Filho, J. (2014). A mineração de dados e a qualidade de conhecimentos extraídos dos boletins de ocorrência das rodovias federais brasileiras. *AtoZ: novas práticas em informação e conhecimento*, 3(2), 139-157.
- Dutta, R., Smith, D., Rawnsley, R., Bishop-Hurley, G., Hills, J., Timms, G., & Henry, D. (2015). Dynamic cattle behavioural classification using supervised ensemble classifiers. *Computers and electronics in agriculture*, 111, 18-28.
- Homburger, H., Schneider, M. K., Hilfiker, S., & Lüscher, A. (2014). Inferring behavioral states of grazing livestock from high-frequency position data alone. *PLoS One*, 9(12), e114522.
- Lovarelli, D., Bacenetti, J., & Guarino, M. (2020). A review on dairy cattle farming: Is precision livestock farming the compromise for an environmental, economic and social sustainable production?. *Journal of Cleaner Production*, 262, 121409.
- Qiao, Y., Su, D., Kong, H., Sukkarieh, S., Lomax, S., & Clark, C. (2020, August). BiLSTM-based Individual Cattle Identification for Automated Precision Livestock Farming. In 2020 IEEE 16th International Conference on Automation Science and Engineering (CASE) (pp. 967-972). IEEE.
- Riaboff, L., Couvreur, S., Madouasse, A., Roig-Pons, M., Aubin, S., Massabie, P., & Plantier, G. (2020). Use of Predicted Behavior from Accelerometer Data Combined with GPS Data to Explore the Relationship between Dairy Cow Behavior and Pasture Characteristics. *Sensors*, 20(17), 4741.
- Ribeiro, M. H. D. M., da Silva, R. G., Mariani, V. C., & dos Santos Coelho, L. (2020). Short-term forecasting COVID-19 cumulative confirmed cases: Perspectives for Brazil. *Chaos, Solitons & Fractals*, 135, 109853.

- Subudhi, A., Dash, M., & Sabut, S. (2020). Automated segmentation and classification of brain stroke using expectation-maximization and random forest classifier. *Biocybernetics and Biomedical Engineering*, 40(1), 277-289.
- Tullo, E., Finzi, A., & Guarino, M. (2019). Environmental impact of livestock farming and Precision Livestock Farming as a mitigation strategy. *Science of the total environment*, 650, 2751-2760.
- Werner, J., Umstatter, C., Leso, L., Kennedy, E., Geoghegan, A., Shalloo, L., ... & O'Brien, B. (2019). Evaluation and application potential of an accelerometer-based collar device for measuring grazing behavior of dairy cows. *animal*, 13(9), 2070-2079.
- Williams, M. L., James, W. P., & Rose, M. T. (2019). Variable segmentation and ensemble classifiers for predicting dairy cow behaviour. *biosystems engineering*, 178, 156-167.
- Williams, M. L., Mac Parthaláin, N., Brewer, P., James, W. P. J., & Rose, M. T. (2016). A novel behavioral model of the pasture-based dairy cow from GPS data using data mining and machine learning techniques. *Journal of dairy science*, 99(3), 2063-2075.
- Witten, I.H., Frank, E., Hall, M.A. (2011). *Data Mining, Practical Machine Learning Tools and Techniques*. 3<sup>o</sup> edição. Elsevier.