

PLANO DE TRABALHO

Título do Projeto: Visão Computacional e Aprendizagem Automática para Aplicações em Agropecuária e Ciências Forenses.

Título do Plano de trabalho: Rumicam: Módulo para análise comportamental de ruminantes bovinos.

Orientador: Hemerson Pistori (pistori@ucdb.br)

Orientanda: Milena dos Santos Carmona. **RA:** 171634

Curso: Engenharia da Computação **Semestre:** 3º

Resumo

Neste trabalho tem como objetivo aprimorar o dispositivo de obtenção de imagens (Rumicam), desenvolver um módulo para automatizar o processo de análise de comportamento alimentar dos bovinos, com intuito de obter informação do período do ciclo ruminante. Desta forma, determinar a quantidade de mastigada por bolo alimentar, e a contagem do tempo durante processo de ruminação, obtendo assim, parametros que permita comparar o alimento oferecido aos ruminantes com a quantidade de fibras ingeridas. Serão utilizadas técnicas e algoritmos aplicada ao aprendizado profundo apoiada à visão computacional, que permita identificar padrões no comportamento.

1. Antecedentes e Justificativa

Os recursos tecnológicos permitem que a pecuária de precisão seja utilizada como mecanismo de gerenciamento do setor pecuária, aumento a produtividade e a rentabilidade econômica (Embrapa, 2017).

A visão computacional vem sendo utilizada como ferramenta de apoio nas mais diversas pesquisas, como suínos (Bald, 2010), peixes (Borth et al., 2016; Marcelo Rafael et al., 2016 & Pistori, 2016), couro bovinos (Pistori et al., 2010) e aves (Rodrigues, 2006).

O aspecto nutricional da alimentação é de suma importância no processo produtivo como um todo haja vista que, o peso é fundamental na tomada de decisão no setor pecuário.

Laca (2008), afirma que pesquisas em contexto com comportamento animal, vêm sendo integrado a aplicação de tecnologias e sistemas de decisão em pastoreios, a partir do conceito de pecuária de precisão. Por conseguinte, a precisão consiste na medição de diferentes parâmetros dos bovinos e do local (pasto ou confinado).

Entre elas a abordagem da análise do comportamento alimentar, na qual a medição de quantidade de fibra consumida é definida por meio do bolo alimentar durante tempo do ciclo de ruminação, permitindo avaliar condições do rebanho tendo uma estimativa de peso e análise da necessidade de alteração do plano alimentar do manejo através de estudo comparativo.

Por meio desse conhecimento, obteve-se o objetivo de desenvolver um protótipo de aquisição de dados durante a ruminação e viabilizar criação do módulo aplicado a área de visão computacional, com intuito de otimizar análise que proporcione informações para uma melhor tomada de decisão.

2. Objetivos

2.1 Geral

O objetivo geral é aprimorar o protótipo de aquisição de imagens dispositivo Rumicam e desenvolver um módulo com apoio de aprendizado profundo (do inglês *Deep Learning* (DL)), e área de visão computacional. No intuito que se realize a análise do comportamento ruminantes e a contagem do período do tempo entre os ciclos de ruminação que permita obter informações relevantes do comportamento animal.

2.2 Específicos

Para atingir o objetivo geral definido na seção 2, foram estabelecidos os seguintes objetivos específicos:

1. Executar teste e análise no dispositivo Rumicam, para identificar deficiências no equipamento.

2. Adaptação e melhoramento do equipamento de captura de imagem (Rumicam).
3. Implementação do módulo de análise da ruminação.
4. Coletar novas imagens com versão atualizada do dispositivo.
5. Executar teste no módulo desenvolvido.
6. Validação do módulo final, com interface adequada, que facilite o acesso aos dados do comportamento alimentar dos bovinos.

3. Revisão de literatura.

Neste tópico serão apresentados alguns dos conceitos que serão necessários para desenvolvimento deste trabalho.

3.1 Visão computacional na pecuária de precisão

Segundo Jahne & Haubecker (2000), a visão computacional tem como objetivo extrair informação de imagens, de modo teórico por meio de sistemas artificiais, a fim de simular a capacidade humana da visão. De acordo com Shapiro & Stockman (2001) o objetivo a interação de tomada de decisões úteis em cenários e objetos através do mesmo.

Por meio deste conhecimento, alguns pesquisadores aderiram o uso de tecnologias como uso de câmeras acopladas, para análise de comportamento animal através de imagens, tendo como foco menor interação durante observação, visando o comportamento animal como parâmetro de conforto (Scott Short, 1998).

3.1.1 Itens e etapas de um sistema de visão computacional

O desenvolvimento de um sistema apoiado a visão computacional engloba geralmente quatro itens iniciais, sendo eles: ambiente, câmera, *hardware* e *software*.

O ambiente expõe uns dos itens mais importante, contendo fatores como iluminação que pode vir à reduzir sombras e ruídos, facilitando etapas como pré-processamento. Segundo Junior (2017), a codificação em formato digital ocorre por meio da obtenção de imagens, na qual a câmera apresenta diferentes padrões entre eles, a resolução da imagem, quando baixa ou alta influência diretamente com extração de atributos. Por último e não menos

importante o *hardware* e *software*, são etapas que forma sistema computacional, na qual expõe informações das imagens coletadas (Szeliski,2010).

Como o módulo proposto têm como objetivo gerar informação automatizada durante ciclo de ruminação, é de grande importância a preocupação com os itens apresentados. As imagens por meio de video servirão de entrada para o módulo que serão capturadas em um ambiente aberto à pasto, através da Rumicam (Figura 1) que poderá apresentar um período de adaptação do bovino até início da ruminação, devido ao equipamento (Figura 2). E o ambiente não controlado poderá causar uma série de ruídos, como por exemplo alteração de luminosidade constante como sombra e reflexão de luz dependendo da posição do sol. Portanto, a administração durante coleta deverá ser realizada de maneira a reduzir esses ruídos, e o aprimoramento em equipamentos adaptáveis.



Figura 1. Rumicam, dispositivo para captura de vídeos de ruminantes.
Fonte: INOVISAO (2018).




Figura 2 - Rumicam sendo utilizado.
Fonte: INOVISAO (2018).

3.2 Extração de atributos

A utilização de extração de atributos de ponto de interesse, corresponde a identificação de componentes definido por um grupo ou conjunto de *pixels* em uma imagem (por exemplo, ponto, bordas, contornos, etc) (Szeliski, 2010). Na visão computacional a descrição da imagem ocorre por intermédio de bons extratores de atributos, na qual devem possuir repetibilidade, distintividade, localidade, quantidade, precisão e eficiência (Tuytelaars et al, 2008).

As informações obtidas por detecção dos atributos (por exemplo, cor, textura, forma, etc), são transformados em descritores locais ou de pontos de interesse, possibilitando reconhecimento de padrões de um conjunto de imagens, a partir de algoritmos de extração de atributos, entre eles :

- *Speeded Up Robust Feature* (SURF): Ao determinar os pontos de interesse que apresenta um intervalor de variância em um ou conjunto de imagens, em tons de cinza, alternando com cálculo de vetores de

características nas bordas de cada um destes pontos de interesse (Bay et al., 2008).

- *Scale Invariant Feature Transformation (SIFT)*: A detecção é invariante à escala, rotações e transformações, na qual determina cada ponto de interesse com um vetor de característica com 128 dimensões, contendo quatro estágios: atribuição de orientação, detecção extrema em espaço de escala, localização e construção dos descritores de pontos de interesse (Lowe, 1999).

Segundo Junior (2017), a extração de atributos com algoritmos de aprendizagem profunda, utiliza redes neurais com diferentes camadas (Figura 3), consiste em grande quantidade de informação, para serem treinadas. Ao decorrer do seu treinamento, os atributos aprendem de forma automática, se associando peso aos mesmos, na qual aqueles que melhor representam o problema apresenta peso maiores que as que não representam, localizando próximas à camadas de entrada.

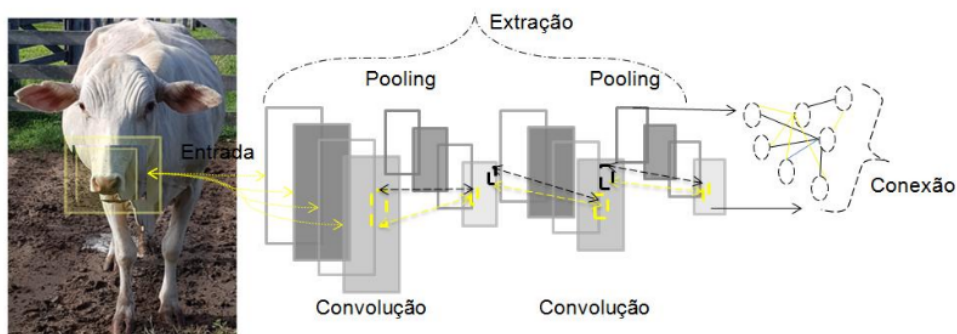


Figura 3- Ilustração de redes neurais com diferentes camadas.

Fonte: INOVISAO (2017).

4. Metodologia

Serão seguidos os tópicos definidos nos objetivos geral e específicos, para alcançar o desenvolvimento do módulo e aprimoramento da Rumican, tendo como base trabalhos desenvolvido do grupo de pesquisa e desenvolvimento INOVISAO¹.

¹ O endereço dos trabalhos desenvolvido pelo grupo pesquisa, estão disponível no website do INOVISAO em <https://inovisao.weebly.com>.

4.1. Adaptação e melhoramento do sistema de captura de imagem (Rumicam)

Para ajustar os parâmetros de contagem do módulo que será desenvolvido e também para testar seu desempenho, as imagens que serão usadas nos bancos de imagens, serão oriundas de imagens capturadas com Rumicam, na qual serão obtidas vídeos coletados pelo dispositivo. Conforme a sequência de frames das imagens que serão separadas por classes, boca aberta, boca fechada e intermediário (Figura 4), sendo assim submetidas a diferentes modelos de aprendizagem profunda do Keras² e a ferramenta Weka³ que abrangem conjunto de dados, na qual é importado pela ferramenta o arquivos ARFF (*Attribute-Relation File Format*), em formato de arquivos de textos descrito em lista os conjuntos de atributos, para determinar a avaliação do modelo criado. A ferramenta permite por meio do mesmo obter coeficientes de correlação, precisão, medida-f, matriz de confusão entre outros (Hall et al., 2009).



Figura 4- Exemplos de imagens capturadas pela Rumicam.

Fonte: INOVISAO (2017).

4.2. Desenvolvimento do módulo de análise da ruminação

O módulo será desenvolvido em Linguagem Python tendo como apoio a aprendizado Profundo (do inglês *Deep Learning* (DL)), e Visão Computacional, com objetivo de classificação de imagens de acordo com

² O Keras Applications são modelos de aprendizagem profunda com pesos pré treinados, disponível de forma gratuita em <https://keras.io/applications/>.

³ O Weka é um software livre e gratuito disponível em <http://www.cs.waikato.ac.nz/ml/weka/>.

reconhecimento de cada classes boca aberta, boca fechada e intermediário, para gerar uma função que fornece dados numéricos de quantidade de mastigada por cada bolo alimentar, dividido em período durante ciclo de ruminação e com a contagem de tempo do mesmo, possibilitando obter resultados similares a na tabela abaixo.

Tabela 1 - Exemplos de dados coletados com o vídeo de ruminação bovina

Vídeo N-1	Início	Término	Duração Ruminação	Intervalo	Duração do intervalo	Total de Mastigadas
Período 01	08:48:09	08:49:04	45 segundos	08:49:05 até 08:49:08	3 Segundos	54
Período 02	08:49:09	08:49:54	45 Segundos	08:49:55 até 08:49:59	4 Segundos	44
Período 03	08:50:00	08:50:53	53 Segundos	08:50:54 até 08:50:58	4 Segundos	50
Período 04	08:50:59	08:51:48	49 Segundos	08:51:48 até 08:51:53	5 Segundos	48

Fonte: INOVISAO (2018).

4.3. Validação do módulo

Ao decorrer do desenvolvimento do módulo serão realizados experimentos com objetivo de verificar a precisão dos algoritmos escolhidos e implementados serão comparados entre si, e o resultados que irão guiar o trabalho para uso ou não de novas técnicas, na qual terá a finalidade de validar o módulo desenvolvido. Por fim, a verificação de problemas de classificação como por exemplo a separação entre as classes do período da ruminação, serão utilizados métricas como acurácia e precisão.

5. Cronograma

Tabela 2- Cronograma de trabalho

Atividades	Ano: 2018					Ano: 2019						
	08	09	10	11	12	01	02	03	04	05	06	07
1.1 Pesquisa de trabalhos correlacionados.	X	X	X									
1.2 Seleção e leitura dos trabalhos correlatos encontrados.	X	X	X									
2.1 Realização de ajuste no equipamento de captura (Rumicam).		X	X	X	X	X	X	X				
2.2 Realização da coleta de imagens.			X	X	X	X	X	X	X			
3.1 Desenvolvimento do módulo.			X	X	X	X	X	X	X			
3.2 Realização de experimentos com o módulo.				X	X	X	X	X	X	X		
4.1 Realização de experimentos estatísticos.										X	X	
4.2 Correções e ajustes no módulo.										X	X	
5.1 Análise e discussão dos resultado obtidos.											X	X
6.1 Relatórios parcial e final.					X							X

6. Referências Bibliográficas

Bald, M. F. et al. Processamento de imagens digitais para utilização no desenvolvimento de um software para estimar o peso de suínos vivos. In: **Embrapa Suínos e Aves-Artigo em anais de congresso (ALICE)**. In: JORNADA DE INICIAÇÃO CIENTÍFICA EMBRAPA/UNC, 4., 2010, Concórdia. Anais... Concórdia: Embrapa Suínos e Aves, 2010. 1 CD-ROM 4 JINC.

Bay, H., Ess, A., Tuytelaars, T., & Van Gool, L. (2008). Speeded-up robust features(surf). **Computer vision and image understanding**, 110(3), 346–359.

BORTH, M.; RIBAS, L.; PISTORI, H.; GONÇALVES, W.; DE CASTRO JÚNIOR, A.A. **Classificação de Espécies de Peixe usando Inferência Gramatical no Reconhecimento de Padrões em Problemas de Visão Computacional**. WTA -Workshop de Tecnologia Adaptativa, São Paulo. 2016.

Gasques, José Garcia; DA CONCEIÇÃO, Júnia Cristina PR. **Crescimento e produtividade da agricultura brasileira**. 1997.

Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., & Witten, I. H.(2009). The weka data mining software: an update. **ACM SIGKDD explorations newsletter**, 11(1), 10–18.

Jahne, B.; Haubecker, H. **Computer vision and applications: a guide for students and practitioners**. Academic Press, 2000.

Junior, A. S. O. **Contagem e estimativa de massa de alevinos de pintado real utilizando técnicas de visão computacional e aprendizagem de máquina**. 2018. 65 f. Qualificação de pós graduação - UFMS. 2018.

Laca, E.A. Pastoreo de precisión. In: **Bioma Campos: innovando para mantener su sustentabilidad y competitividad**. Montevideo: Tradinco, 2008, v.1, p.29-40.

Lowe, D. G. (1999). Object recognition from local scale-invariant features. In **Computer vision, 1999. The proceedings of the seventh IEEE international conference on**, volume 2 (pp. 1150–1157): Ieee.

Rodrigues, Valéria Cristina. **Distribuição espacial e bem-estar de aves poedeiras em condições de estresse e conforto térmico utilizando Visão**

Computacional e Inteligência Artificial. 2006. Tese de Doutorado. Universidade de São Paulo.

Shapiro, L. & Stockman, G. (2001). **Computer Vision.** October, 2004 (October), 608.

Short, C.E. Fundamentals of pain perception in animals. **Applied Animal Behaviour Science.** Amsterdam, v. 59, n. 1, p. 125–133, 1998.

Szeliski, R. (2010). **Computer Vision: Algorithms and Applications.** Computer, 5,832.

Tuytelaars, Tinne et al. Local invariant feature detectors: a survey. **Foundations and trends® in computer graphics and vision**, v. 3, n. 3, p. 177-280, 2008.

Pistori, H.; Souza, KP de. Tecnologia adaptativa aplicada na biotecnologia: Estudos de caso e oportunidades. In: **WORKSHOP DE TECNOLOGIA ADAPTATIVA. Escola Politécnica da USP.** 2010. p. 16-21.