

## APLICAÇÃO DE ÁRVORES DE DECISÃO EM ATRIBUTOS EXTRAÍDOS VIA MÉTODO LOCAL BINARY PATTERNS (LBP) PARA CLASSIFICAÇÃO DO ESCORE DE MARMOREIO EM BOVINOS DE CORTE

Diógenes Lodi Pinto<sup>1</sup>, Lucas Tassoni Andrietta<sup>1</sup>, Dan Tulpan<sup>2</sup>, Gordon Vander Voort<sup>2</sup>, Jasper Munro<sup>3</sup>, Roberto Carneiro<sup>4</sup>, Júlio Cesar de Carvalho Balieiro<sup>1</sup>, Ricardo Vieira Ventura<sup>1</sup>

<sup>1</sup>Departamento de Nutrição e Produção Animal, FMVZ, USP, Pirassununga, SP, Brasil.

<sup>2</sup>Department of Animal Biosciences, UoGuelph, Guelph, ON, Canada.

<sup>3</sup>AgSights, Elora, ON, Canada.

<sup>4</sup>Departamento de Genética e Melhoramento Animal, FCAV, UNESP, Jaboticabal, SP, Brasil.

\**diogenes.pinto@usp.br*

A Visão Computacional (VC) é uma área da Ciência da Computação, voltada ao estudo de métodos e algoritmos que fazem uso de câmeras e computadores com foco na extração de atributos visuais de diferentes objetos (Szeliski, 2011). O desafio da classificação de imagens (Rosebrock, 2017), está diretamente associado com a escolha dos melhores atributos de uma imagem, pois cada tipo de aplicação possui propriedades especiais. Objetivou-se, neste estudo, investigar a implementação de um algoritmo para geração de atributos e posterior classificação do escore de marmoreio via técnicas de aprendizado de máquina (*Machine Learning*), em imagens obtidas via corte transversal do músculo *Longissimus dorsi*, em uma população de bovinos de corte, sem tratamento prévio. Um total de 600 imagens foram disponibilizadas pela empresa canadense AgSights, em formato JPG, extraídas de cortes cárneos transversais do músculo *Longissimus dorsi* obtidos entre as 12<sup>a</sup> e 13<sup>a</sup> vértebras de animais taurinos, sem composição racial prévia definida. Disponibilizou-se também os escores adotados, usados para uma subdivisão inicial em três grupos (200 imagens em cada) em relação ao nível de gordura intramuscular (GIM) na área de olho de lombo (AOL). O grupo (G1) caracterizado por apresentar poucos traços de GIM, (G2) quantidade mediana e traços longos concentrados em determinadas regiões, e (G3) traços curtos e abundantes distribuídos uniformemente ao longo de toda a AOL. Para tratamento do *background* utilizou-se o programa de edição GIMP e para inserção de rótulos nas ROI: *steak*, AOL e objeto de referência, o programa Labelme. Um script Python e bibliotecas *Numpy* e *OpenCV* foi criado para dividir a matrizes de pixels em pequenos quadrados deslizantes contendo apenas elementos não nulos. Aos quadrados aplicou-se o método LBP (Local Binary Pattern), utilizado na classificação de texturas em imagens (Ojala et al., 2002), adaptado do código de Rosebrock (2015), cujas saídas são armazenadas em vetores para uso em algoritmos de classificação. Por fim, o algoritmo de aprendizado de máquina supervisionado *Decision Tree* (DT) foi aplicado para diferentes ordens de janelas e métricas do LBP. Os resultados mostraram uma acurácia igual a 90.83% obtida usando o método LBP(8,1) composto por matrizes quadradas de ordem 40 para (N=400), sendo 70% desse total para treino e 30% para validação. Após inserção de amostras com valores medianos em relação a GIM (G2) houve redução da acurácia para 57,78%. Ao inserir o grupo intermediário, podemos notar que os vetores gerados pelo método LBP, a partir dos grupos G2 e G3, possuíam alta semelhança. Apesar de ambos os grupos conterem traços de GIM, o que os diferencia é a distribuição e configuração deste padrão de gordura ao longo da AOL. Estudos preliminares utilizando o método LBP mostraram resultados expressivos na classificação de extremos para gordura intramuscular, porém ainda há uma necessidade evidente de melhorar o entendimento dos aspectos biológicos e visuais que acarretaram na queda acentuada da acurácia de classificação após inserção de grupos intermediários de gordura intramuscular. Resultados adicionais, usando-se outros métodos de *Machine Learning* e tamanho amostral expandido, estão sendo compilados.

Agradecimentos à FAPESP: 2016/19514- 2 e 2020/04461-6.

Palavras-chave: AOL, aprendizado de máquina, escore de marmoreio, LBP, Python e Sklearn.