



UNIVERSIDADE
ESTADUAL DE LONDRINA

GUILHERME AGOSTINIS FERREIRA

**UTILIZAÇÃO DE VISÃO COMPUTACIONAL NA
CLASSIFICAÇÃO DE CARÇAÇAS DE BOVINOS NELORE
MACHO**

Londrina
2019

GUILHERME AGOSTINIS FERREIRA

**UTILIZAÇÃO DE VISÃO COMPUTACIONAL NA
CLASSIFICAÇÃO DE CARCAÇAS DE BOVINOS NELORE
MACHO**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência Animal da Universidade Estadual de Londrina como requisito parcial para a obtenção do título de Mestre.

Orientadora: Prof^a. Dr^a. Ana Maria Bridi

Londrina
2019

Agostinis Ferreira, Guilherme.

Utilização de Visão Computacional na classificação de carcaças de bovinos Nelore macho / Guilherme Agostinis Ferreira. – Londrina, 2019.
66 f. : il.

Orientador: Ana Maria Bridi.

Dissertação (Mestrado em Ciência Animal) – Universidade Estadual de Londrina, Centro de Ciências Agrárias, Programa de Pós-Graduação em Ciência Animal, 2019.
Inclui bibliografia.

1. Maturidade fisiológica - Tese. 2. Ossificação - Tese. 3. Random Forest - Tese. 4. Support Vector Machine - Tese. I. Bridi, Ana Maria. II. Universidade Estadual de Londrina. Centro de Ciências Agrárias. . III. Título.

GUILHERME AGOSTINIS FERREIRA

**UTILIZAÇÃO DE VISÃO COMPUTACIONAL NA
CLASSIFICAÇÃO DE CARCAÇAS DE BOVINOS NELORE
MACHO**

Dissertação apresentada ao Programa de Pós- Graduação
em Ciência Animal da Universidade Estadual de Londrina
como requisito parcial para a obtenção do título de Mestre.

BANCA EXAMINADORA

Prof^a. Dr^a. Ana Maria Bridi
Universidade Estadual de Londrina - UEL

Prof^a. Dr^a Ana Paula de Souza Fortaleza Pardo
Instituto Federal do Rio Grande do Sul - IFRS

Prof. Dr. Sylvio Barbon Junior
Universidade Estadual de Londrina - UEL

Londrina, 25 de fevereiro de 2019.

AGRADECIMENTOS

Agradeço primeiramente à Deus, que sempre me proveu força para lutar contra as dificuldades do dia-a-dia, com as incertezas, com as derrotas e que acima de tudo me abençoa diariamente.

À minha mãe, Cleunice Agostinis que é meu maior exemplo, minha guerreira, que nunca mediu esforços para que eu conseguisse chegar até aqui, sempre me incentivando a seguir meus objetivos, mostrando minha capacidade, sem ferir, machucar ou passar por cima de ninguém. Te amo muito.

Ao meu irmão, Gustavo Agostinis Ferreira a quem eu sou eternamente grato por ter me compreendido durante mais essa fase de muita correria, de muita ausência, mas de um amor incondicional.

À minha família, por sempre me apoiar e principalmente por entender meus momentos de ausência, amo muito vocês.

À minha orientadora, Professora Dra. Ana Maria Bridi por ter sempre acreditado em mim durante todos esses anos, ter confiado no meu trabalho e aceitado muitas vezes meus palpites que normalmente contrariam a maioria, além de ser um exemplo de profissional e de ética em todas as áreas da vida, pessoal e profissional. Obrigado pela amizade.

À Professora Dra. Sandra Maria Simonelli pela atenção que sempre teve comigo e valiosas considerações feitas durante a banca de qualificação.

À banca examinadora Professora Dra. Ana Paula de Souza Fortaleza Pardo pelo aceite e disposição em contribuir mais uma vez com este projeto, e especialmente ao Professor Dr. Sylvio Barbon Júnior por toda ajuda concedida durante a execução deste trabalho, muito obrigado.

A Jéssica Fernandes, que me auxiliou na execução deste trabalho com as metodologias relacionadas à área da Ciência da Computação.

Ao Grupo JBS na pessoa do colega Ivan Sebastião Junior, que proporcionou o local para a coleta dos dados deste projeto e me acompanhou durante todo o processo no frigorífico.

Ao meu querido GPAC, que contribuiu tanto com o meu apreendizado na área que se tornou a minha paixão que é a ciência da carne e principalmente ao pequeno grande grupo companheiro da pó, Amanda Barro, Barbara Giangareli, Camila Rogel, Jéssica Vero, Évelyn Rangel por estarem comigo durante os últimos anos, passando por dias não tão bons mas sempre com muita alegria e café.

À querida Sandra Regina da Silva e Helenice, que sempre estiveram disponíveis para ajudar em qualquer coisa que eu precisasse, sempre educadas e pacientes.

E à todos que contribuíram de alguma forma para a minha formação pessoal ou profissional.

“A nossa maior glória não reside no fato de nunca cairmos, mas sim em levantarmo-nos sempre depois de cada queda”

Oliver Goldsmith

FERREIRA, Guilherme Agostinis. **Utilização de visão computacional na classificação de carcaças de bovinos Nelore macho**. 2018. 66f. Dissertação (Mestrado em Ciência Animal) – Universidade Estadual de Londrina, Londrina, 2019.

RESUMO

A idade do animal determina a quantidade de tecido depositado na carcaça, seja ele ósseo, muscular ou adiposo e influencia a maciez da carne. Por este motivo, a idade é utilizada em programas de classificação e tipificação para determinar níveis de qualidade da carne a ser comercializada. No entanto, a classificação tradicional é realizada de forma subjetiva, mesmo que por painelistas treinados. A visão computacional vem sendo utilizada na área agrícola e na avaliação de alimentos com a finalidade de retirar a subjetividade da avaliação humana e produzir resultados mais concisos e precisos. Neste sentido a proposta deste estudo é comparar qual classificador resultará em um melhor modelo preditivo, utilizando k-Nearest Neighbors (k=1), Random Forest e Support Vector Machine como modelos preditivos devido à sua ampla aplicação e alto desempenho. Foram utilizadas 56 meias carcaças de bovinos Nelore não castrados, que foram divididos em três classes etárias (Precoce, Tourinho e Touro), variando de 12 a 48 meses. As imagens foram adquiridas com auxílio de câmera digital com suas funções automáticas e sem controle ambiental. O algoritmo k-NN obteve acurácia de 78,95%, tendo seu pior desempenho na classificação dos animais de idade intermediária. O resultado obtido com o algoritmo RF foi de 73,68% de acurácia e classificou quatro amostras do grupo de idade intermediária como falso positivo. O algoritmo SVM classificou uma amostra do grupo mais jovem como sendo do grupo mais velho e não conseguiu prever nenhuma amostra do grupo intermediário, gerando um modelo com 68,42% de acurácia. Há maior susceptibilidade de serem cometidos erros ou equívocos quando a avaliação é feita por painelistas treinados. Os algoritmos de classificação propostos mostraram bom desempenho e viabilidade de implantação em relação ao sistema tradicional. O algoritmo k-NN foi o que apresentou melhor desempenho e a solução mais simples entre os classificadores.

Palavras-chave: Maturidade fisiológica. Ossificação. Radom Forest. SVM

FERREIRA, Guilherme Agostinis. **Use of computational vision in the classification of Nelore bulls carcasses**. 2019. 66p. Dissertation (Master's Degree in Animal Science) – Universidade Estadual de Londrina, Londrina, 2019.

ABSTRACT

The age of the animal determines a quantity of matter deposited in the carcass, must be bone, muscular or adipose and influenced by the tenderness of the meat. For this reason, age is indicated in grading and typing programs for certain levels of meat quality to be marketed. However, a traditional classification is performed subjectively, even if by trained panels. The computational view has been used in the agricultural area and in food evaluation in order to remove the subjectivity of human evaluation and the more concise and precise results. This comparing topic with a classifier resulted in one of the best models using k-Nearest Neighbors ($k = 1$), Random Forest and Support Vector Machine. Fifty - six beds of Nelore bovine milk were used, which were divided into three age groups (Precoce, Tourinho and Taurus), ranging from 12 to 48 months. The images were acquired with the aid of a digital camera with its automatic functions and without environmental control. The k-NN algorithm obtained an accuracy of 78.95%, with its worse performance in the classification of animals of middle age. The result obtained with the RF algorithm was 73.68% accuracy and classified four samples from the middle age group as false positive. The SVM algorithm classified a sample of the younger group as being from the oldest group and could not predict a sample from the intermediate group, generating a model with a 68.42% accuracy. There is greater susceptibility to being made with errors or misconceptions when a check is made by trained panelists. The proposed classification algorithms have good performance and feasibility of implantation in relation to the traditional system. The k-NN algorithm was the one that performed the best performance and a simpler solution among the classifiers.

Key words: k-Nearest Neighbor. Ossification. Physiological maturity. Random Forest. Support Vector Machine.

LISTA DE ILUSTRAÇÕES

Figura 1 – Idade cronológica dos bovinos	23
Figura 2 – Idade fisiológica dos bovinos	24
Figura 3 – Ossificação intramembranosa	28
Figura 4 – Ossificação endocondral.....	29
Figura 5 – Exemplo do Sistema de Visão Computacional.....	30
Figura 6 – Exemplo de funcionamento do k-NN	33
Figura 7 – Exemplo de funcionamento do Random Forest.....	34
Figura 8 – Exemplo de funcionamento do SVM.....	35

ARTIGO

Figura 1 – Vértex torácicas	48
Figura 2 – Fluxograma de processamento das imagens.....	49
Figura 3 – Segmentação semântica.....	50
Figura 4 – Características de forma	51
Figura 5 – Falhas operacionais	58

LISTA DE TABELAS

Tabela 1 – Consumo global de carne	18
Tabela 2 – Indicadores de maciez de acordo com a dentição.....	22
Tabela 3 – Classificação USDA	25
Tabela 4 – Porcentagem do grau de ossificação	26
Tabela 5 – Trabalhos que utilizam Visão Computacional	32

ARTIGO

Tabela 1 – Matriz de confusão.....	48
Tabela 2 – Características utilizadas nos modelos de predição	53

LISTA DE GRÁFICOS

Gráfico 1 – Precisão dos algoritmos	54
Gráfico 2 – Grau de importância das características de forma.....	55
Gráfico 3 – Classificação das amostras.....	56

SUMÁRIO

1	INTRODUÇÃO	14
2	REVISÃO BIBLIOGRÁFICA	17
2.1	IMPORTÂNCIA DA QUALIDADE DA CARNE.....	18
2.2	IDADE E QUALIDADE DA CARÇAÇA E CARNE.....	19
2.3	MÉTODOS DE AVALIAÇÃO DA IDADE.....	21
2.4	CRESCIMENTO DO TECIDO CARTILAGINOSO E ÓSSEO	25
2.5	INTELIGÊNCIA COMPUTACIONAL.....	29
2.5.1	Aprendizado De Máquina	29
2.5.2	Visão Computacional.....	30
2.5.3	Processamento De Imagens	30
2.5.4	Algoritmos de Classificação	32
2.5.4.1	K-NN	32
2.5.4.2	Random forest	34
2.5.4.3	Support Vector Machine	35
	REFERÊNCIAS	37
3	OBJETIVOS	44
3.1	OBJETIVO GERAL	44
3.2	OBJETIVOS ESPECÍFICO.....	44
3	ARTIGO – Uso de visão computacional para identificação da idade de carcaças bovinas	45
4	CONSIDERAÇÕES FINAIS	65

1 INTRODUÇÃO

A pecuária bovina de corte possui posição de destaque no agronegócio brasileiro, tendo em vista que o Brasil possui o maior rebanho comercial do mundo com 214,7 milhões de cabeças, seguido de Estados Unidos da América e China (ABIEC, 2019). No ano de 2018 o Brasil deteve o segundo lugar no ranking mundial de abate de bovinos (15,3%), liderando o ranking Estados Unidos da América (17,2%), em terceiro China (10,3%) (IBGE, 2019).

Em 2017 foram abatidas 39,2 milhões de cabeças em território nacional, produzindo assim um volume de 9,71 milhões de toneladas equivalente carcaça (IBGE, 2018; ABIEC, 2018). Do total de carne produzida em 2017, 20% foram exportadas (2,032 milhões de toneladas equivalente carcaça) (ABIEC, 2018). A carne in natura é a maior representante das exportações brasileiras ocupando 77,4% do total exportado, tendo como líder do ranking dos países importadores da carne in natura do Brasil Hong Kong com cerca de 20%, seguido por China (18%) e Egito (11%) (ABIEC, 2018).

O Brasil é o segundo maior consumidor mundial de carne bovina (13,7%), seguido da União Europeia (13,5%) e China (13,3%), os Estados Unidos desponta em primeiro lugar com 20,2% (DEPEC, 2017). A produção de carne bovina que abasteceu o mercado interno (80%) garantiu um consumo de cerca de 37,5 quilos per capita em 2017 (ABIEC, 2018).

A raça Nelore corresponde a mais de 80% do rebanho brasileiro sendo animais puros ou cruzados (ACNB, 2016), devido a raça ter melhor adaptação ao ambiente tropical e resistência a parasitas (CUNDIFF, 2004). A carne proveniente de bovinos da raça Nelore é reconhecida no mercado internacional como uma carne muito magra e com pouca deposição de gordura intramuscular (CHARDULO et al. 2013). Entretanto, sistemas intensivos de produção aliados à um programa de seleção genética são capazes de gerar produtos de alta qualidade.

Uma forma de se garantir a produção de carcaças padronizadas e de qualidade é adotando protocolos de classificação e tipificação de carcaças. Os parâmetros utilizados no Brasil para a classificação de carcaças em unidades sob Inspeção Federal seguem um padrão estabelecido pela Normativa Nº 9 de 4 de maio de 2004 do Ministério da Agricultura, Pecuária e Abastecimento (BRASIL, 2004).

A Normativa Nº 9 considera como parâmetro a classe sexual, o peso da carcaça quente, avaliação subjetiva do grau de acabamento e a idade que deve ser avaliada

pela erupção dos dentes incisivos permanentes, estabelecendo-se as categorias dente de leite (d), dois dentes (2d), quatro dentes (4d), seis dentes (6d) ou oito dentes (8d) (BRASIL, 2004).

Na tipificação americana, ocorre a separação entre classes sexuais (touro, touros jovens, castrados, novilhas e vacas) para posteriormente classificar quanto a maturidade (AMSA, 2001). A avaliação da maturidade é feita por tipificadores treinados por meio do grau de ossificação das cartilagens das vértebras e pela cor da carne da área de olho de lombo. Dentro da maturidade podem ser classificados em 5 categorias: A (9-30 meses), B (30-42), C (42-72), D (72,96) à E (acima de 96 meses), onde A se refere as carcaças provenientes de bovinos jovens, e E as carcaças de animais de maturidade avançada. Além do gênero e maturidade, o sistema americano ainda considera o grau de marmoreio.

No modelo europeu o que prevalece é uma classificação das carcaças pela idade por meio de escores visuais, e conformação por meio de avaliação de escore de musculabilidade. Inicialmente são classificadas em 5 categorias, A – machos não-castrados com menos de dois anos, B – machos não-castrados acima de dois anos, C – machos castrados, D – fêmeas paridas e E – outras fêmeas e posteriormente classificadas quanto seu grau de conformação e gordura (CE, 2007).

O modelo australiano trabalha com selo de maciez garantida, o chamado MSA – Meat Standards Australia. Para isso um processo de rastreamento foi desenvolvido, onde se coletam informações como composição genética, peso de carcaça, uso ou não de estimulação elétrica, além da maturidade óssea, espessura de gordura, teor de marmoreio e tipo de pendura (convencional ou pélvica) (MSA, 2003).

A idade determina a quantidade de tecido depositado na carcaça, seja ele ósseo, muscular ou adiposo. A deposição dos tecidos segue uma curva de crescimento alométrico, onde o tecido ósseo é o primeiro tecido a ser depositado, seguido do muscular e por último ocorre a deposição de gordura (LUCHIARI FILHO, 2000). Além disso, possui estreita relação com a maciez, que segundo Paz e Luchiari Filho (2000) é a característica organoléptica da carne de maior influência para os consumidores. Essa relação se estabelece devido a quantidade de ligações cruzadas termoestáveis do colágeno dos músculos que é positivamente correlacionada com a idade, contribuindo para a dureza da carne (LAWRIE, 2005).

De modo geral, as avaliações relacionadas a classificação e tipificação são feitas de forma subjetiva e apresentam resultados pouco consistentes, mesmo que condicionadas por um treinamento prévio. A consistência e precisão dos resultados obtidos por meio da visão computacional permitem uma análise mais eficaz e rentável (LU, 2000).

A utilização de características visuais para a avaliação da carne é rotineira, e a utilização do sistema de visão computacional é a opção mais viável para encontrar os atributos necessários para uma classificação eficaz, sem que haja encarecimento do método, ou reduza a velocidade da análise ou até mesmo destrua a amostra (JACKMAN; SUN, 2012).

A visão computacional se mostra como uma boa alternativa para a redução de problemas de classificação por apresentar técnicas que simulam a percepção humana, sem prejuízos no tempo de análise e reduzindo a subjetividade da classificação (BROSNAN; SUN, 2002). Para que haja a simulação da percepção humana, os sistemas de visão computacional utilizam o aprendizado de máquina a partir de informações extraídas que com o auxílio ou não de um profissional treinado interpreta e estabelece parâmetros para dados ainda não avaliados quando inseridos no sistema (DU; SUN, 2006). São exemplos de técnicas de aprendizado de máquina Support Vector Machine, Random Forest, k-NN, Redes Neurais Artificiais e Lógica Fuzzy.

De modo geral, a análise de produtos cárneos se baseia em atributos que são passíveis de ser identificados por sistemas de visão computacional, como cor, textura ou forma (USDA, 2012), como é o caso da análise da idade fisiológica das carcaças bovinas, que pode ser avaliada com a utilização de uma câmera digital associada a utilização de algoritmos de aprendizado de máquina. O desafio é realizar a aquisição das imagens sem um ambiente sem o controle da luz, em que os resultados ainda sejam satisfatórios.

Por tanto este estudo visa reduzir a subjetividade do olho humano na avaliação da maturidade fisiológica de carcaças bovinas zebuínas por meio da utilização de diferentes classificadores de visão computacional.

2 REVISÃO BIBLIOGRÁFICA

Embora possa ser superestimado, o consumo per capita de carne tem aumentado (Tabela 1) e servido como base para orientar políticas alimentares em diversos países. Analisando apenas o consumo de carne bovina, houve aumento de mais de 12% em 28 anos. Quando se analisa o consumo total de carnes este número aumenta para mais de 60%. Isso indica que fatores além do aumento da população mundial está influenciando a demanda de proteína animal, como o aumento da renda per capita da população, principalmente, de países em desenvolvimento (MEADE; ROSEN, 2013).

Tabela 1. Consumo global de carne no período de 1990 a 2018 em milhões de toneladas.

	1990	2014	2018
Carne bovina	54,065	58,766	60,724
Carne suína	68,692	109,812	112,433
Carne de frango	40,173	85,937	93,787
Consumo total	162,93	254,515	266,944

Fonte: FAO (2014); USDA (2018)

Os países mais desenvolvidos alcançaram níveis médios de produção animal e vários autores mostraram convergência nos modelos alimentares, principalmente proteína de origem animal (SANS; COMBRIS et al., 2015), primeiro em grupos com alto poder aquisitivo (BLANDFOR, 1984; GIL; GARCIA; PEREZ, 1995; DELGADO, 2003), seguido de países com renda intermediária (DELGADO, 2003; REGMI; TAKESIMA; UNNEVEHR, 2008); com o aumento da renda, aumenta-se o gasto com alimentação. Fatores como declínio dos preços (PALMER, 2011), abertura para comércio exterior, globalização dos sistemas alimentares (DELGADO, 2003) também contribuíram fortemente para o aumento do consumo.

Além destes fatores, a transição de padrão de vida da maioria dos países de renda média está associada a uma tendência que indica aumento no consumo de gordura, açúcar, alimentos processados e proteínas animais (HENCHION, 2014). Portanto, com o evidente crescimento na demanda por proteína animal, a cadeia produtora de carne precisa estar atenta aos parâmetros qualitativos e sanitários.

2.1 IMPORTÂNCIA DA QUALIDADE DA CARNE

A ambiguidade, complexidade e amplitude que traz o termo qualidade, envolve aspectos de toda a cadeia agroindustrial, do nascimento do animal até o consumo da carne *in natura* ou produtos cárneos já processados. O consumidor ao adquirir determinado corte cárneo, deseja que ela possua aparência típica da sua espécie, seja rica em nutrientes, seja palatável, além de ser proveniente de animais saudáveis, abatidos e processados higienicamente (PETHICK, et. al., 2011).

Segundo Coutinho Filho (2006), a maior parte da carne consumida no Brasil não apresenta padrões de qualidade estabelecidos por técnicos ou especialistas, uma vez que a maioria dos produtos cárneos de origem bovina (bois, vacas, novilhas, garrotes, etc.) são agrupados e vendidos como carne de boi ou vaca. Para os padrões internacionais de qualidade da carne, o principal fator determinante de preço e preditor de palatabilidade é a quantidade de gordura depositada no músculo *longissimus thoracis et lumborum*, o comercial contrafilé (FERRAZ; FELÍCIO, 2010).

Normalmente a qualidade dos alimentos é avaliada com base em conhecimentos técnicos como medidas físicas, químicas e microbiológicas aliadas a informações provenientes de análises sensoriais que buscam encontrar diferenças entre amostras por meio de avaliações feitas por uma equipe de provadores treinada com base em escalas planejadas por especialistas (FELÍCIO, 1998). É a percepção sensorial do sabor e textura da carne que irá indicar ao consumidor determinado padrão de qualidade (HENCHION et al., 2014).

Em estudo conduzido na Europa para avaliar a preferência do consumidor relacionado a origem e sistema de alimentação dos animais, o país de origem foi a característica mais importante para a escolha da carne, seguido do tipo de sistema alimentar (REALINI et al., 2013). Para que se consiga atender os nichos de mercado que buscam altos padrões de qualidade e valor agregado, é necessário que se consiga ofertar à indústria da carne animais padronizados, principalmente, em peso, idade e grau de acabamento (JOO et al., 2013).

2.2 IDADE E QUALIDADE DA CARÇAÇA E DA CARNE

Para produzir carne de alta qualidade, é necessário entender as características e fatores determinantes da qualidade da carne para controlá-los (JOO et al., 2013). O crescimento corporal dos bovinos acontece por meio de multiplicação celular caracterizada como hiperplasia, juntamente com o aumento do tamanho celular ou hipertrofia (LUCHIARI FILHO, 2000). Segundo o autor, o aumento dos tecidos estruturais caracteriza o crescimento verdadeiro.

O processo de crescimento destes tecidos acontece ou se inicia em tempos diferentes, começando pelo tecido ósseo, muscular e por último o adiposo, que tem sua deposição acentuada após a puberdade do animal (OWENS; DUBESKI; HANSON, 1993).

A idade do animal influencia na qualidade da carcaça devido as diferentes taxas de crescimento de determinadas partes do corpo do animal, que com o passar do tempo pode causar desproporção da carcaça devido ao aumento de determinados músculos, bem como a deposição de gordura (OWENS et al., 1995). Com o avançar da idade de abate são obtidas carcaças com maiores proporções de gordura e taxa de marmoreio (OWENS et al., 1995).

A qualidade da carne é afetada pela idade em que o animal é abatido devido a variações na composição metabólica dos músculos (OSÓRIO, 2000). O teor de mioglobina presente no músculo é quem determina a cor da carne, e a sua variação é intrínseca ao músculo, variando de acordo com a idade do animal, localização anatômica do músculo, espécie e composição da dieta (LIMA JUNIOR et al., 2011).

A maciez é outra característica que sofre influência direta da idade do animal, que com o avançar da idade ocorre aumento entre as ligações cruzadas intramoleculares e intermoleculares de tropocolágeno (TANZER, 1973). Animais mais velhos apresentam maior quantidade e menor solubilidade das moléculas de colágeno, podendo chegar a ser 60% menos solúvel em animais acima de 96 meses (HERRING; CASSENS; BRISKEY, 1967).

Essas ligações conferem a molécula maior estabilidade, porém causam maior insolubilidade do colágeno devido a característica não redutível que ela passa a ter em

condições de envelhecimento, tornando a carne mais dura (BAILEY; SHIMOKOMAKI, 1971).

A evolução do tecido conjuntivo no músculo é variável e depende do estágio de desenvolvimento do animal, da posição do músculo, sua função, raça, nutrição, exercícios e lesões musculares (PURSLOW, 2005) e principalmente a idade do animal dentro de uma mesma raça (BAILEY; LIGHT, 1989).

A integridade estrutural das fibras musculares é mantida por três tipos de tecidos conectivos: o endomísio que reveste miofibrilas individualmente, o perimísio que circunda um grupo de fibras musculares e o epimísio que envolve todo o músculo (NISHIMURA, 2010). Esses tecidos são compostos de células e matriz extracelular que é composta por colágeno e suas diferentes variações (tipo I, III, IV, V, VI, XII e XIV), proteoglicanas e glicoproteínas (McCORMICK, 1999). O endomísio é composto de fibrilas de colágeno dispostas em forma de rede, diferentemente do perimísio onde a disposição é feita em lâminas. O conjunto de várias camadas de lâminas de colágeno formam o epimísio (NISHIMURA et al., 1996).

O colágeno é o maior componente do tecido conectivo intramuscular (NISHIMURA, 2010), representando de 1,5 a 10% do peso seco do músculo. Contrapondo a quantidade de elastina, exceto em músculos como o *semitendinosus* e *longissimus dorsi* que apresentam cerca de 2% do peso seco do músculo (BENDALL, 1967).

A estabilidade térmica e mecânica deste tecido aumenta de acordo com o desenvolvimento do animal (NISHIMURA, 2010). A maciez da carne tende a decrescer com o aumento da idade do animal, e os músculos ricos em colágeno mostram esse efeito mais do que aqueles com baixo teor de tecido matriz extracelular (SHORTHOSE; HARRIS, 1990). Sabe-se pouco sobre a quantidade da matriz e suas propriedades mecânicas, sendo estimada em 0,4 Mpa (SANDRIN et al., 2004).

Em estudo sobre touros da raça charolês cerca de 35% da variabilidade da maciez da carne foi explicada pelas propriedades metabólicas e características do colágeno (RENAND et al., 2001). Além disso, músculos com menores conteúdos de colágeno total e insolúvel apresentam maior atividade enzimática, maior proporção de fibras musculares oxidativas, menos proporção de fibras musculares glicolíticas e menor diâmetro de fibra (CHRIKI et al., 2012). As características sensoriais relacionadas as características musculares podem ser preditas, mas não com muita precisão (BONNY et al., 2015).

Tentando estabelecer relação entre as características musculares (tipo de fibra, conteúdo de colágeno, gordura intramuscular e atividade enzimática) e características

sensoriais da carne independente da raça, Gagaoua et al. (2016) encontrou forte associação entre o aumento da maciez e aceitação global da carne com características oxidativas e fibras de contração lenta, no entanto ainda não foi possível deixar de considerar raça, gênero e principalmente a idade dos animais.

Bovinos da raça Nelore com até quatro dentes incisivos permanentes produzem carne de maciez aceitável, com maior solubilidade do colágeno e fragmentação das fibras, além de menor conteúdo total de colágeno (Tabela 2). Animais oito dentes apresentam maior perda de água por gotejamento, maior dureza da carne e menor solubilidade das moléculas de colágeno (DUARTE et al., 2011).

Tabela 2. Médias e desvio padrão para Força de cisalhamento Warner-Bratzler (WBSF), índice de fragmentação miofibrilar (IFM), conteúdo total de colágeno (CTC) e solubilidade do colágeno (SC) da carne de acordo com o número de dentes incisivos permanentes.

	Número de dentes incisivos permanentes				P-valor
	2	4	6	8	
WBSF	4,52 ± 0,60 ^b	4,56 ± 0,33 ^b	7,39 ± 0,62 ^a	7,55 ± 0,51 ^a	<0,0001
IFM	62,43 ± 5,18 ^a	55,90 ± 2,75 ^{ab}	48,17 ± 2,74 ^b	48,71 ± 1,91 ^b	0,0119
CTC	8,92 ± 3,18	9,24 ± 2,44	10,91 ± 2,74	11,42 ± 1,88	0,0220
SC	40,52 ± 12,73 ^a	33,83 ± 10,58 ^a	30,63 ± 7,30 ^{ab}	22,21 ± 10,22 ^b	0,0002

Letras na mesma linha diferem significativamente (P<0,05)

Fonte: Adaptado de Duarte et al. (2011)

Avaliando a influência da classificação dentária na maciez e características sensoriais, Lawrence et al. (2001a) concluíram que com o aumento da classificação etária, maior são os valores obtidos para força de cisalhamento. Também concluíram que novilhas chegam a maturidade antes dos novilhos, com associação do aumento de gordura intramuscular e redução da força de cisalhamento. Perdas de água no cozimento foram associadas a aumento na força de cisalhamento.

2.3 AVALIAÇÃO DA IDADE

A idade pode ser mensurada por meio da inspeção da dentição, pelo grau de ossificação das cartilagens e pela consistência do músculo *longissimus lumborum*. Na

avaliação da dentição o animal zero dente ainda não passou por nenhuma queda ou troca da primeira dentição. O animal denominado dois dentes possui dois dentes definitivos e assim sucessivamente, até chegar ao animal 8 dentes que apresenta todos os dentes definitivos. Com o passar do tempo ocorre o desgaste e separação dos dentes, como pode-se observar na Figura 1.

Figura 1 - Fotografias de mandíbulas inferiores de carcaças bovinas demonstrando os estágios de maturação pela dentição permanente incisiva.



Dentes incisivos da primeira dentição (dentes de leite)



Primeiro dente incisivo permanente



Segundo dente incisivo permanente (1º par)



Erupção do terceiro dente incisivo permanente



Quarto dente incisivo permanente (2º par)



Erupção do quinto dente incisivo permanente



Sexto dente incisivo permanente (3º par)



Erupção do sétimo dente incisivo permanente



Oitavo dente incisivo permanente (4º par), também chamado "Boca Cheia"

Fonte: Whiting et al. (2013)

Em estudo realizado na Inglaterra para identificar inter-relações entre idade, sexo e raça no desenvolvimento dos dentes anteriores permanentes, pesquisadores concluíram que a transição etária ocorre aos 23 meses passando de zero a dois dentes; 30 meses de dois para quatro dentes; 37 meses de quatro para seis dentes e 42 meses de seis para oito dentes (WHITING et al., 2013).

Além disso também concluíram que os machos se desenvolvem, em média, 22 dias antes das fêmeas em todas as transições etárias (WHITING et al., 2013). Analisando raças europeias continentais e nativas, encontraram um maior tempo para ocorrer a transição nas raças continentais, já tidas como tardias para deposição de musculatura, em cerca de seis semanas. Analisando raças leiteiras e raças para corte encontraram menor tempo de transição das raças leiteiras de até três semanas em relação as raças de corte. E ao contrário do que ocorre nas raças de corte, as fêmeas leiteiras realizam as transições antes dos machos (WHITING et al., 2013).

Outra metodologia de avaliação é realizada por meio da ossificação das cartilagens, em que se observa o grau de ossificação e formato dos ossos. Animais jovens apresentam cartilagem no topo de todos os ossos da coluna vertebral e nos discos intervertebrais, que com o passar do tempo passa pelo processo de ossificação (Figura 2).

Na Figura 2A está representada a vértebra sacral e seu processo espinhoso quase completamente ossificados. Na Figura 2B está representada a vértebra lombar, da qual ainda há resquícios de regiões cartilagosas, com também, alto grau de ossificação. Na Figura 2C a representação da vértebra torácica também apresentando sinais de avanço na ossificação das cartilagens, indicando a representação de um animal de idade avançada.

Figura 2. Avaliação da idade fisiológica da carcaça. A) vértebra sacral. B) vértebra lombar. C) vértebra torácica.



Fonte: próprio autor.

O processo de ossificação se inicia pelas vértebras sacrais, posteriormente nas lombares e finaliza nas torácicas (Tabela 3). As características dos ossos se alteram com a maturidade dos animais, que quando jovens apresentam ossos porosos e macios, e cartilagens de cor perolada, costelas estreitas e medula vermelha.

Tabela 3. Classificação de maturidade óssea no padrão United State Department of Agriculture pela idade cronológica e descrição da ossificação nas vértebras sacrais, lombares e torácicas.

Maturidade USDA	Idade (meses)	Idade (anos)	Ossificação da coluna vertebral		
			Sacral	Lombar	Torácica
A	0-30	0-2,5	Separação visível	Não ossificada	Não ossificada
B	30-42	2,5-3,5	Completamente fusionada	Próximo da ossificação completa	Apresenta alguma ossificação
C	42-72	3,5-6	Completamente fusionada	Ossificação completa	Moderadamente ossificada
D	72-96	6-8	Completamente fusionada	Ossificação completa	Consideravelmente ossificada
E	>96	>8	Completamente fusionada	Ossificação completa	Completamente ossificada

Fonte: CONVERGENT AG MEDIA, 2015.

Um estudo conduzido nos Estados Unidos (LAWRENCE et al., 2001b) indicou que de 91 a 100% dos bovinos com zero dentes incisivos permanentes (<23 meses de idade), 89 a 87% dos bovinos com dois dentes incisivos permanentes (23 a 30 meses de idade), 75 a 82 % dos bovinos com quatro dentes permanentes incisivos (30 a 38 meses de idade), 64 a 72 % dos bovinos com seis dentes incisivos permanentes (38 a 45 meses de idade) foram classificados como maturidade A pelo sistema de classificação do USDA (Tabela 4).

Tabela 4. Porcentagem do grau de ossificação de vértebras torácicas de carcaças bovinas.

Maturidade USDA	Ossificação nos três últimos botões torácicos (%)
A	0-10
B	10-35
C	35-70
D	70-90
E	>90

Fonte: CONVERGENT AG MEDIA, 2015.

O estudo ainda indica que os bovinos machos eram mais propensos a serem erroneamente classificados em categorias de animais mais jovens do que fêmeas. O que sugere que avaliar a maturidade por ambas as metodologias aumenta as chances de erros devido a subjetividade que trazem ambas metodologias.

Um estudo realizado nos Estados Unidos (RAINES et al., 2008) propôs a utilização do peso da lente dos olhos das carcaças para a identificação de animais com até 20 meses de idade pela seguinte fórmula:

$$Idade (meses) = -21,79 + 17,23 (Peso da lente, g) + 0,038 (escore dentição)$$

É avaliado apenas um dos olhos devido a possíveis falhas na remoção da cabeça e devem ser avaliados logo após a remoção. Em casos de impossibilidade de avaliação imediata, devem ser mantidos congelados a -80°C até a análise. Os autores alertam para a necessidade da remoção e dissecação dos olhos para a realização da pesagem. As córneas são dessecadas para a remoção das lentes que são pesadas.

No estudo, 38% dos animais foram identificados com menos de 20 meses, enquanto que pela metodologia de maturidade óssea apenas 10% foi classificado. A metodologia também é indicada para animais de até 30 meses associadas à identificação da dentição dos animais.

2.4 CRESCIMENTO DO TECIDO CARTILAGINOSO E ÓSSEO

De forma geral a porção óssea da carcaça é composta por tecido cartilaginoso e tecido ósseo, três tipos celulares e mais de duzentos diferentes elementos esqueléticos (KARSENTY, 2003). O tecido ósseo é classificado como um tecido conjuntivo

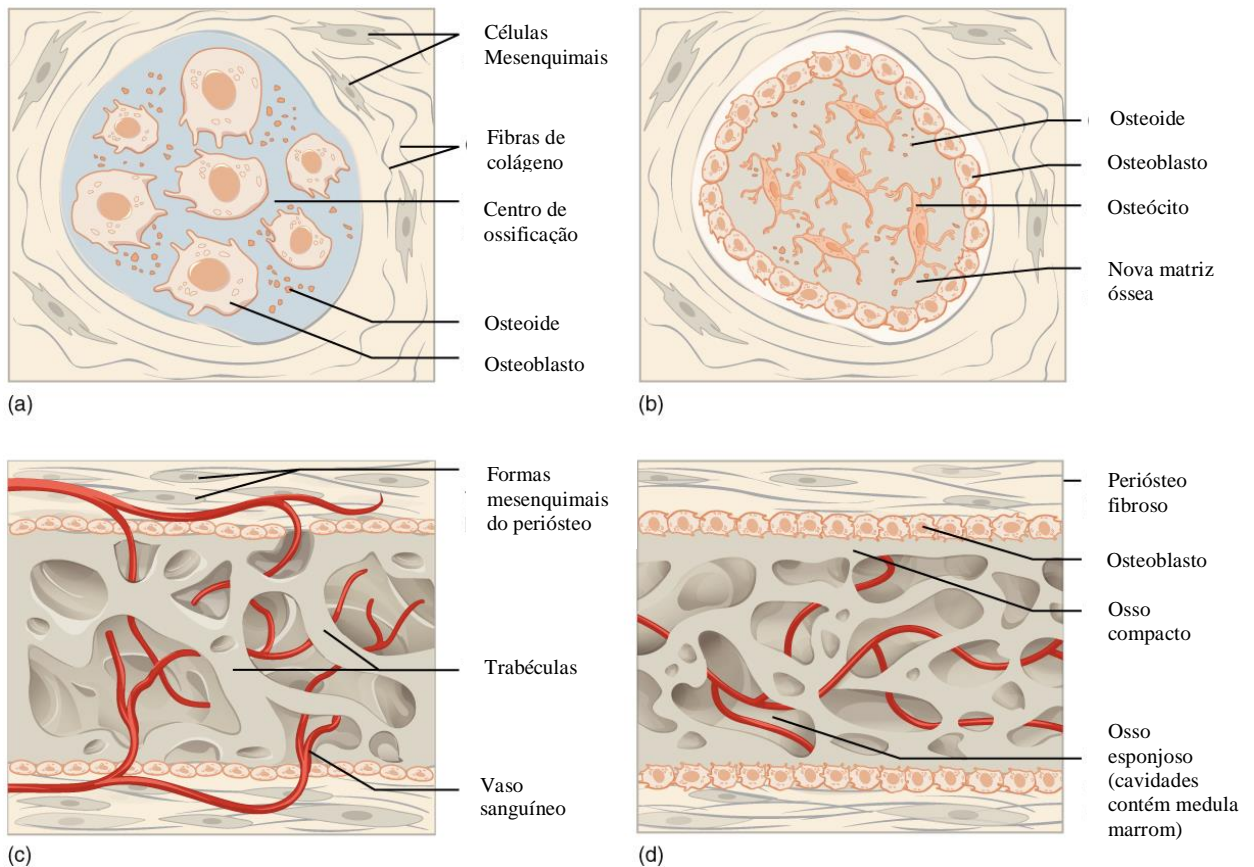
de ampla matriz extracelular, onde uma parte é inorgânica e outra orgânica constituída principalmente por colágeno tipo I, glicoproteínas, proteoglicanas e fosfoproteínas (KATCHBURIAN; ARANA-CHAVEZ, 2004).

A formação deste tecido se inicia no período embrionário por meio da diferenciação de células progenitoras e pode se dar por meio de dois mecanismos diferentes, ossificação intramembranosa e endocondral (GILBERT, 2006). Este último se inicia sobre um molde de cartilagem hialina, que gradualmente é destruído e substituído por tecido ósseo formado a partir de células do conjuntivo adjacente (JUNQUERIA; CARNEIRO, 2008).

Tanto na ossificação intramembranosa como na endocondral, é formado primeiramente um tecido primário, que aos poucos é substituído por tecido secundário ou lamelar proporcionando durante o crescimento dos ossos a visualização de áreas de tecido primário, áreas de reabsorção e áreas de tecido secundário (JUNQUERIA; CARNEIRO, 2008).

A ossificação intramembranosa (Figura 3) ocorre no interior de tecido conjuntivo e contribui para o crescimento dos ossos curtos e para o crescimento em espessura dos ossos longos (JUNQUERIA; CARNEIRO, 2008). O processo tem início pela diferenciação de células mesenquimatosas que se transformam em grupos de osteoblastos, que posteriormente irão sintetizar a matriz não mineralizada dando ao osso um aspecto esponjoso (JUNQUERIA; CARNEIRO, 2008). Entre os tecidos que se desenvolvem formam-se cavidades que são penetradas por vasos sanguíneos e células mesenquimatosas indiferenciadas que irão dar origem a medula óssea (JUNQUERIA; CARNEIRO, 2008).

Figura 3. Ossificação intramembranosa em quatro passos. (a) As células mesenquimais agrupam-se em grupos e formam-se os centros de ossificação. (b) Os osteoides secretados capturam os osteoblastos, que então se tornam osteócitos. (c) Matriz trabecular e forma de perióstio. (d) O osso compacto se desenvolve superficialmente ao osso trabecular, e vasos sanguíneos lotados se condensam na medula vermelha.



Fonte: BCcampus, 2018


Já o processo de ossificação endocondral tem início sobre uma peça de cartilagem hialina, de forma parecida à do osso que se vai formar, porém de tamanho menor (Figura 4). Primeiro, a cartilagem sofre modificações havendo hipertrofia dos condrócitos, redução da matriz cartilaginosa, seguida de sua mineralização e morte dos condrócitos por apoptose (JUNQUERIA; CARNEIRO, 2008).

Posteriormente as cavidades previamente ocupadas pelos condrócitos são invadidas por capilares sanguíneos e células osteogênicas vindas do conjuntivo adjacente diferenciam-se em osteoblastos, que depositarão matriz óssea sobre os botões de cartilagem calcificada (KRONENBERG, 2003). Desse modo, aparece tecido ósseo onde antes havia tecido cartilaginoso sem que ocorra a transformação deste tecido naquele, onde neste caso os

botões de matriz calcificada servem apenas de ponto de apoio a ossificação (OLSEN; REGINATO; WANG, 2000).

Figura 4. Ossificação endocondral em cinco etapas. (a) As células mesenquimais diferenciam-se em condrócitos. b) O modelo de cartilagem do futuro esqueleto ósseo e do pericôndrio. c) Os capilares penetram na cartilagem. O pericôndrio se transforma em periósteo. O colar periosteal se desenvolve. Centro de ossificação primário se desenvolve. (d) Cartilagem e condrócitos continuam a crescer nas extremidades do osso. (e) Os centros secundários de ossificação se desenvolvem. (f) A cartilagem permanece na placa epifisária (crescimento) e na superfície articular como cartilagem articular.

Pericôndrio



Fonte: BCcampus, 2018

O molde cartilaginoso possui uma parte média estreitada e as extremidades dilatadas, correspondendo respectivamente à diáfise e às epífises do futuro osso (JUNQUERIA; CARNEIRO, 2008). O primeiro tecido ósseo a aparecer no osso longo é formado por ossificação intramembranosa do pericôndrio que recobre a parte média da diáfise, formando o colar ósseo (JUNQUERIA; CARNEIRO, 2008). A sequência do processo de ossificação é viabilizada pela presença de um disco de tecido cartilaginoso que permanece

em determinadas regiões por meio da multiplicação de condrócitos (ASZÓDI et al., 2000). O desaparecimento destes discos indica o fim do processo de crescimento dos ossos com sua ossificação completa (ASZÓDI et al., 2000).

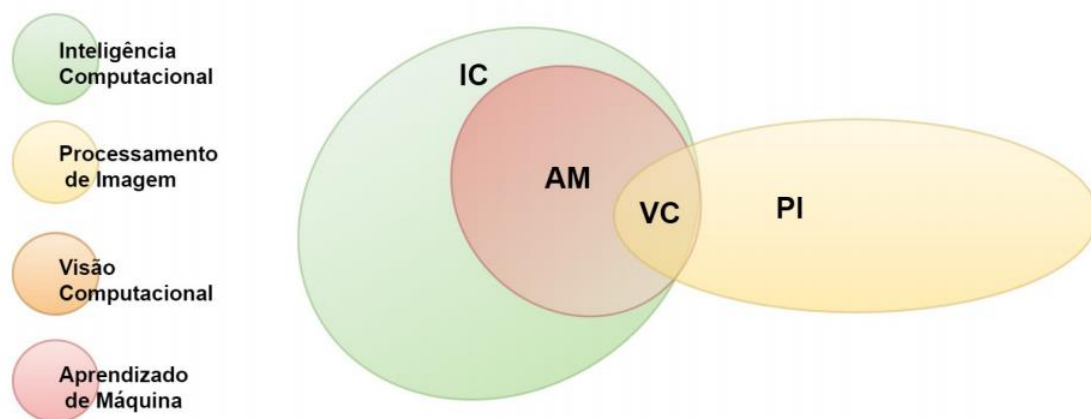
Nos cortes histológicos, distingue-se cartilagem calcificada por ser basófila, enquanto o tecido ósseo depositado sobre ela é acidófilo (JUNQUERIA; CARNEIRO, 2008).

2.5 SISTEMA DE VISÃO COMPUTACIONAL

Visão Computacional é a área da Ciência da Computação que engloba o estudo e desenvolvimento de técnicas para extração de informação em imagens ou quaisquer dados multidimensionais. O emprego de Visão Computacional aliada a técnicas de processamento de imagens permite a modelagem de sistemas para tomada de decisões e avaliação de objetos ou processos (MASTELINI et al., 2016).

A Figura 5 apresenta a organização das diferentes áreas que estão inseridas ou que se relacionam com a Inteligência Artificial atuando como uma grande área. A visão computacional é formada pela intersecção do Processamento de Imagem com o Aprendizado de Máquina.

Figura 5. Relação entre as áreas da computação.



Fonte: Barbon (2018).

2.5.1 Processamento De Imagens

O Processamento Digital de Imagens envolve uma série de procedimentos que se inter-relacionam, tendo como início a captura da imagem por meio de um sistema de

aquisição. Posterior à captura pelo processo de digitalização, a imagem precisa estar ajustada para o tratamento computacional, e para isso realiza-se o primeiro passo efetivo, também conhecido como pré-processamento, que fará a filtragem de ruídos introduzidos pelos sensores e corrigirá distorções geométricas (DE QUEIROZ; GOMES, 2006).

A imagem capturada pela câmera está sujeita a vários tipos de ruídos, e estes podem comprometer a qualidade da imagem e fornecer informações incorretas no processamento da imagem (DU; SUN, 2004). Portanto os autores indicam que para que a qualidade da imagem seja melhorada, operações devem ser realizadas para remover ou diminuir as degradações sofridas pela imagem durante a aquisição.

A segmentação objetiva a divisão da imagem em regiões que se referem ao mesmo conteúdo por meio do isolamento de pixels que não fazem parte deste objeto ou conteúdo. Uma das técnicas mais utilizadas para a segmentação de imagens desenvolvida para alimentos é a limiarização, que é uma técnica eficaz para a segmentação de imagens contendo objetos sólidos com um fundo contrastante (DU; SUN, 2004). O resultado do processo de segmentação é o isolamento das regiões de interesse, onde permanecerá na imagem apenas as áreas desejadas a fim de extrair determinadas informações.

2.5.2 Visão Computacional

A Visão Computacional trata do estudo da automatização da percepção visual, por meio de técnicas que permitem a construção de sistemas artificiais para a obtenção de informação a partir de imagens (GARCÍA et al., 2017).

É uma área que une conceitos de Aprendizado de Máquina e Processamento Digital de Imagens na tentativa de obter um sistema computadorizado capaz de interpretar características de objetos retratados em uma imagem, ao invés da imagem em si, tal como um olho humano.

Uma imagem digital é composta por uma série de pontos que se enquadram bidimensionalmente e isso possibilita o processamento das mesmas pelos computadores. Cada ponto contido na grade bidimensional é chamado de elemento de imagem, ou o mais conhecido pixel (DE QUEIROZ; GOMES, 2001).

Na Tabela 5 estão alguns trabalhos que utilizaram algum tipo de técnica de visão computacional para a resolução de algum problema, ou propor nova metodologia em relação a avaliação da qualidade da carne. Cada questão deve ser analisada e adequada à melhor metodologia disponível.

Tabela 5. Trabalhos envolvendo o uso de imagens para avaliar a qualidade de produtos na cadeia da carne e derivados desde 2008.

Espécie Animal	Aplicação	Referência
Bovino	Segmentação do marmoreio por limiar obtido da observação dos painelistas em comparação com outros algoritmos.	Chen; Qin, 2008
Bovino	Método de segmentação do marmoreio da carne.	Jackman; Sun; Allen, 2009
Bovino	Predição dos escores de cor da gordura da carne bovina por meio de VC ¹ .	Chen et al., 2010
Suíno	Mensuração do L* ² por meio de imagem com o objetivo de detectar carne PSE ³ .	Chmiel; Slowinski; Dasiewicz, 2011a
Frango, Peru	Determinação da quantidade de gordura em cortes de peito e sobrecoxa de frango e Peru por meio da VC ¹ .	Chmiel; Slowinski; Dasiewicz, 2011b
Bovino, Frango, Suíno	Comparação entre as técnicas de VC ¹ e calorímetro para a avaliação da qualidade da carne utilizando painel treinado	Girolami et al., 2013
Salsichas secas	Classificação da aparência de salsichas suínas secas por VC ¹ utilizando parâmetros colorimétricos e área de gordura.	Girolami et al., 2014.
Suíno	Rastreamento de cortes individuais de carne suína por meio da VC ¹ .	Larsen et al., 2014.
Bovino	Identificação de regiões de osso e cartilagem na carcaça.	Meng et al., 2015
Frango	Deteção da síndrome do músculo pálido por meio da VC ¹ como uma ferramenta rápida e não destrutiva de avaliação.	Barbin et al., 2016
Suíno	Predição da cor da carne por meio da VC ¹ utilizando atributos de imagem.	Sun et al., 2016
Suíno	Deteção de defeitos (PSE ³ e DFD ⁴) na carne suína por meio da VC ¹ .	Chmiel; Slowinski, 2016.
Embutidos	Predição da quantidade de gordura em salame, salchichón e presunto utilizando VC ¹ a partir de imagens obtidas pelo smarthphone.	Cruz-Fernández et al., 2017

Bovino, Suíno Classificar o músculo *longissimus dorsi et lumborum* de Barbon et al., 2018
acordo com o grau de marmoreio

¹VC: Visão Computacional. ²L*: Luminosidade. ³PSE: Pale, Soft and Exudative. ⁴DFD: Dark, Firm and Dry.
Fonte: adaptado de Barbon, 2018.

2.5.3 Aprendizado De Máquina

O Aprendizado de Máquina se concentra no desenvolvimento e aplicação de algoritmos que são projetados para aprender a partir de dados (ROPODI; PANAGOU; NYCHAS, 2016). Tais dados são entradas de exemplo de aprendizagem que são usadas para construir um modelo para fazer previsões e/ou decisões (KOHAVI & PROVOST, 1998). É um subcampo da Ciência da Computação, e emprega uma gama de tarefas de computação que podem ir além da programação explícita e se sobrepõem a Inteligência Computacional (ROPODI; PANAGOU; NYCHAS, 2016). Além disso, está conectada com campos como estatísticas e matemática, que fornecem uma parte importante da teoria por trás dos modelos construídos.

Existem duas abordagens quando se opta por técnicas ou metodologias de aprendizado de máquina, a supervisionada e a não-supervisionada. De modo geral, ambos vão gerar conclusões genéricas a partir de um conjunto específico de exemplos, denominado também como princípio indutivo (LORENA; DE CARVALHO, 2007).

Na técnica de aprendizado de máquina supervisionado existe a necessidade de um especialista indicando um conjunto de exemplos rotulados ao algoritmo, que por sua vez extrai desses exemplos características que passam a ser conhecimento (HAYKIN, 1999). A partir desse conhecimento prévio, espera-se que a representação gerada seja capaz de identificar ou gerar as mesmas respostas a partir de exemplos não apresentados previamente (LORENA; DE CARVALHO, 2007). Na técnica não supervisionada não há um especialista indicando exemplos, gerando resultados por agrupamento e semelhança, sendo indicado para o reconhecimento de padrões ou tendências (LORENA; DE CARVALHO, 2007).

2.5.4 Algoritmos de Classificação

Os algoritmos de classificação são utilizados para criar modelos para realizar a identificação das características de interesse durante a análise supervisionada. Um algoritmo pode ser definido como uma sequência de instruções implementadas em linguagem de programação com o objetivo de criar uma solução (MAULIK et al., 2011). Uma prova disso

é pensar em qual é a composição do conceito de inteligência, ou as características que a englobam, como a capacidade de raciocínio, aprendizado, percepção e adaptação (GOLDSCHIMIT, 2010).

Algumas abordagens vêm sendo empregadas na criação de algoritmos de aprendizado supervisionado com diferentes abordagens teóricas. Técnicas mais simples incluem o emprego do k-vizinhos mais próximos (k-Nearest Neighbours), em que não se cria um modelo preditivo, ou metodologias com maior grau de complexidade como as Redes Neurais Artificiais (RNA), que se aproximam ao funcionamento das sinapses no cérebro humano.

2.5.4.1 k-Nearest Neighbor (k-NN)


O classificador k-vizinho mais próximo, como é chamado, é um dos algoritmos de mais fácil implementação quando se fala em nível de complexidade (O' FARREL et al., 2005), no entanto apresenta bons desempenhos em áreas distintas como a medicina (BECKONERT et al., 2003), no reconhecimento facial (CONDE et al., 2003), reconhecimento de assinaturas (DROUHARD; SABOURIN; GODBOUT2016), além da indústria de alimentos (MIGNANI, 2004).

Este método considera a similaridade entre as amostras mais próximas, em que o valor de k representa o número de vizinhos, ou amostras, mais próximos (Figura 6) que serão comparados (RASJID; SETIAWAN, 2017). A similaridade é calculada pela Distância Euclidiana entre dois pontos, X_1 (conjunto de atributos da amostra) e X_2 (conjuntos de atributos do vizinho), podendo ser representada pela seguinte fórmula:

$$dist(X_1, X_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2}$$

Para determinar o melhor valor de k, é primeiramente utilizado o valor 1 e aumentando progressivamente até que se atinja o melhor desempenho (RASJID; SETIAWAN, 2017).

Figura 6. Exemplo do espaço de busca do classificador k-NN com dois valores de k (k=3 e k=6).

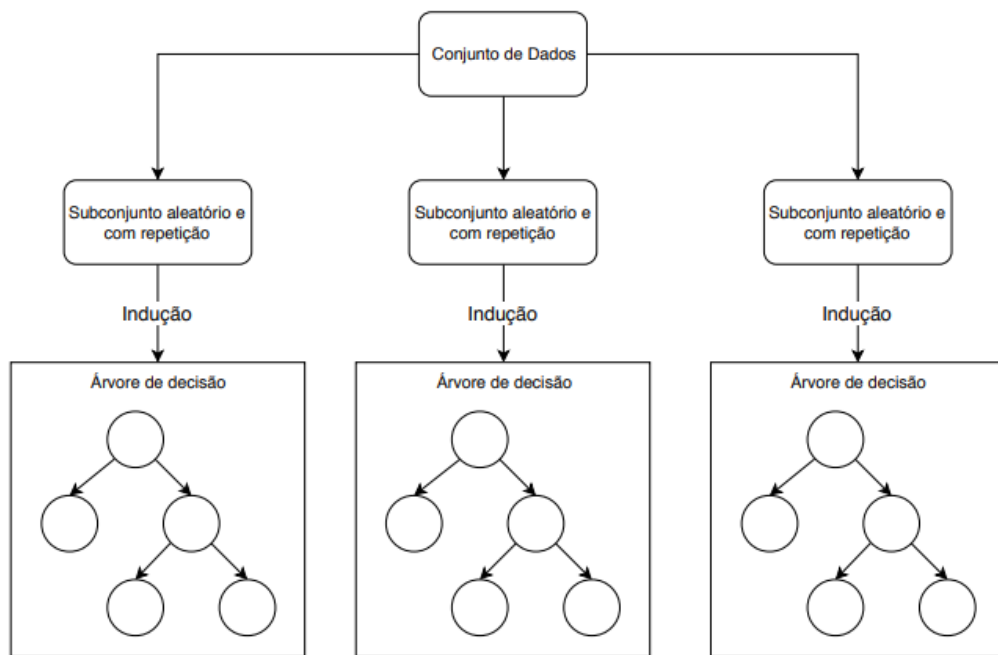


Fonte: Ramos, 2016.

2.5.4.2 Random Forest (RF)

É uma técnica de aprendizado de máquina supervisionado que a partir de um determinado dado, desenvolve uma série de critérios para classificar ou prever um atributo (SOLTANI; OMID, 2015). Este algoritmo funciona de forma binária por meio de nós terminais (Figura 6), que são projetados a partir da base da árvore (CHEN; ISHWARAN, 2012). Neste tipo de classificador, não há a utilização de todas as variáveis em todos os nós, sendo selecionado um subconjunto de características candidatas para encontrar a melhor divisão para o nó (CHEN; ISHWARAN, 2012).

Figura 7. Exemplo do funcionamento de uma Random Forest.



Fonte: Silva, 2018.

2.5.4.3 Support Vector Machine (SVM)


A Support Vector Machine (SVM) utiliza uma técnica de aprendizado supervisionado com diferentes algoritmos para estabelecimento de um modelo que pode ser de classificação ou regressão. O classificador constrói um hiperplano ou conjunto de hiperplanos em um espaço dimensional alto, com o menor erro e a margem máxima, em que a maior distância apresentada é alcançada pelo hiperplano com pontos de dados mais próximos (SOLTANI; OMID, 2015). Esta distância é denominada de Vetores de Suporte. Por buscar a maximização das fronteiras de separação entre classes com menor erro classificatório, a SVM está relacionada a resolução de problemas de otimização quadráticos.

A separação e transformação do espaço dimensional de análise é realizada por uma função Kernel, que devido a isso possui alta influência do desempenho deste classificador (ZHAO et al., 2010).

Para melhor ilustrar o objetivo da SVM, considere a Figura 7. No problema apresentado, existem duas classes representadas com formas diferentes (uma representada por círculos, e outra por X). Primeiramente, é possível perceber que o problema é linearmente solucionável, ou seja, existe uma reta (hiperplano) que é capaz de separar as duas classes do

problema. Entretanto, é fácil perceber que diferentes retas são capazes de realizar tal função. Para encontrar o hiperplano ótimo, a SVM tem como objetivo maximizar a distância da margem de decisão entre as classes utilizando as instâncias na fronteira dessa margem, demarcadas por quadrados na figura, chamadas de vetores de suporte (support vectors). O hiperplano ótimo é representado pela linha tracejada.

Figura 8. Diagrama do hiperplano ótimo encontrado por um SVM.



Fonte: SILVA, (2018)

REFERÊNCIAS

ABIEC. **BeefReport**: Perfil da pecuária no Brasil. 2019. Disponível em: <
<http://www.abiec.com.br/controle/uploads/arquivos/sumario2019portugues.pdf>>. Acesso
 em: 16 de abr de 2019.

AMERICAN MEAT SCIENCE ASSOCIATION (AMSA). **Meat Evaluation Handbook**.
 American Meat Science Association, Savoy, IL, 2001.

ANUALPEC. **Anuário Brasileiro da Pecuária**. Santa Cruz do Sul: Gazeta Santa Cruz,
 2014.

ASZÓDI, A. et al. Mammalian skeletogenesis and extracellular matrix: what can we learn
 from knockout mice? **Cell structure and function**, v. 25, n. 2, p. 73-84, 2000.

BAILEY, A. J.; SHIMOKOMAKI, M. S. Age related changes in the reducible cross-links of
 collagen. **FEBS letters**, v. 16, n. 2, p. 86-88, 1971.

BAXES, G.A. **Digital Image Processing Principles and Applications**. Wiley, New York,
 USA, 1994.

BAILEY, Allen J.; LIGHT, Nicholas D. **Connective tissue in meat and meat products**.
 Elsevier Applied Science, 1989.

BARBIN, D. F. et al. Digital image analyses as an alternative tool for chicken quality
 assessment. **Biosystems Engineering**, v. 144, p. 85-93, 2016.

BARBON, A. P. C. **Avaliação do índice de marmoreio e do tempo de estocagem da
 carne com o uso da Inteligência Computacional**. Tese (Doutorado em Ciência Animal) –
 Universidade Estadual de Londrina, Londrina, 2018.

BCCAMPUS. **Anatomy and physiology**. Disponível em: <
<https://opentextbc.ca/anatomyandphysiology/front-matter/about-this-book/>>. Acesso em: 12
 dez 2018.

BECKONERT, O. et al. NMR-based metabonomic toxicity classification: hierarchical cluster
 analysis and k-nearest-neighbour approaches. **Analytica Chimica Acta**, v. 490, n. 1-2, p. 3-
 15, 2003.

BLANDFORD, D. Changes in food consumption patterns in the OECD area. **European
 Review of Agricultural Economics**, v. 11, n. 1, p. 43-64, 1984.

BONNY, S. P. F. et al. Biochemical measurements of beef are a good predictor of untrained
 consumer sensory scores across muscles. **Animal**, v. 9, n. 1, p. 179-190, 2015.

BRASIL. Ministério da Agricultura e Abastecimento. **Instrução Normativa de Nº9, de 4 de
 maio de 2004**. Sistema de Classificação de Bovinos.

- BROSNAN, T; SUN, D. W. Inspection and grading of agricultural and food products by computer vision systems—a review. **Computers and electronics in agriculture**, v. 36, n. 2-3, p. 193-213, 2002.
- CAMPO, M. M. et al. Assessment of breed type and ageing time effects on beef meat quality using two different texture devices. **Meat Science**, v. 55, n. 4, p. 371-378, 2000.
- CHARDULO, L.A.L.; SILVEIRA, A.C.; VIANELLO, F. Analytical aspects for tropical meat quality assessment. **Food quality, safety and technology**, p. 53–62, 2013.
- CHEN, X; ISHWARAN, H. Random forests for genomic data analysis. **Genomics**, v. 99, n. 6, p. 323-329, 2012.
- CHEN, Y.; CHAO, K.; KIM, M. S. **Machine vision technology for agricultural applications**.v.36. p.173–191, 2002.
- CHEN, K.; QIN, C. Segmentation of beef marbling based on vision threshold. **Computers and Electronics in Agriculture**, v. 62, n. 2, p. 223-230, 2008.
- CHEN, K. et al. Color grading of beef fat by using computer vision and support vector machine. **Computers and Electronics in Agriculture**, v. 70, n. 1, p. 27-32, 2010.
- CHRIKI, S. et al. Cluster analysis application identifies muscle characteristics of importance for beef tenderness. **BMC biochemistry**, v. 13, n. 1, p. 29, 2012.
- CHMIEL, M.; SŁOWIŃSKI, M.; DASIEWICZ, K. Lightness of the color measured by computer image analysis as a factor for assessing the quality of pork meat. **Meat science**, v. 88, n. 3, p. 566-570, 2011a.
- CHMIEL, M.; SŁOWIŃSKI, M.; DASIEWICZ, K. Application of computer vision systems for estimation of fat content in poultry meat. **Food Control**, v. 22, n. 8, p. 1424-1427, 2011b.
- CNPC. **Exportações brasileiras de carne bovina**. 2016. Disponível em: <<http://www.abiec.com.br/estatisticas/14.pdf>>. Acesso em: 03 ago 2017.
- COMUNIDADE EUROPÉIA (CE). **Regulamento nº. 1234**. Anexo V. Grelhas Comunitárias de Classificação de Carcaças. Jornal Oficial da União Europeia. 2007.
- CONDE, Cristina; RUIZ, Antônio; CABELLO, Enrique. PCA vs low resolution images in face verification. In: **Image Analysis and Processing, 2003. Proceedings. 12th International Conference on**. IEEE, 2003. p. 63-67.
- CONVERGENT AG MEDIA. **Beef Carcass Evaluation**. 2015. Disponível em: <<https://4h.missouri.edu/doc/beef-carcass-evaluation.pdf>>. Acesso em: 22 set 2018.
- COUTINHO FILHO, J. L. V.; PERES, R.M.; JUSTO, C. L. Produção de bovinos contemporâneos, machos e fêmeas, terminados em confinamento. **Revista Brasileira de Zootecnia**, v.35, n5, p.2043-2049, 2006.

CRUZ-FERNÁNDEZ, M. et al. Smartphone determination of fat in cured meat products. **Microchemical Journal**, v. 132, p. 8-14, 2017.

CUNDIFF, L.V. Beef cattle: breeds and genetics. In: Pond WG, Bell AW (eds) **Encyclopedia of animal science**. Cornell University, Ithaca, p. 800–830, 2004.

CUTLER, A.; STEVENS, J. R. Random forests for microarrays. **Methods in enzymology**, v. 411, p. 422-432, 2006.

DEPEC. **Departamento de Pesquisas e Estudos Econômicos – Carne Bovina 2017**.

Disponível em:<

https://www.economiaemdia.com.br/EconomiaEmDia/pdf/infset_carne_bovina.pdf>. Acesso em 13 set. 2018.

DUARTE, M. S. et al. Influence of dental carcass maturity on carcass traits and meat quality of Nellore bulls. **Meat Science**, v. 88, n. 3, p. 441-446, 2011.

DU. C.; SUN D. Recent developments in the applications of image processing techniques for food quality evaluation. **Trends in Food Science & Technology**. p. 230–249, 2004.

DU, C. J.; SUN, D. W. Learning techniques used in computer vision for food quality evaluation: a review. **Journal of food engineering**, v. 72, n. 1, p. 39-55, 2006.

DE QUEIROZ, J. E. R; GOMES, H. M. Introdução ao Processamento Digital de Imagens. **RITA**, v. 13, n. 2, p. 11-42, 2006.

DELGADO, C. L. Rising consumption of meat and milk in developing countries has created a new food revolution. **The Journal of nutrition**, v. 133, n. 11, p. 3907S-3910S, 2003.

DROUHARD, J.-P.; SABOURIN, Robert; GODBOUT, Mario. A neural network approach to off-line signature verification using directional PDF. **Pattern Recognition**, v. 29, n. 3, p. 415-424, 1996.

FAO. Food and Agriculture Organization of the United Nations. **Food Supply - Livestock and Fish Primary Equivalent**. Disponível em: <<http://faostat.fao.org/site/610/DesktopDefault.aspx?PageID=610#ancorFAO>>. Acesso em: 19 dez 2018.

FELÍCIO, P. E. DE. **Avaliação da qualidade da carne bovina**. n. 1972, p. 1–7, 1998.

FELÍCIO, P. E. DE. **Qualidade da carne bovina: características físicas e organolépticas**. p. 1–11, 1999.

FERRAZ, J. B. S.; FELÍCIO, P. E. D. Production systems - an example from Brazil. **Meat Science**, v. 84, n. 2, p. 238-243, 2010.

FUNDEPEC. Disponível em: < <http://www.fundepecgo.org.br/home/category/tecnica/>>. Acesso em: 13 set 2018.

- FUNDEPECGO. **USDA: Confirma relatório sobre o mercado de carnes.** Disponível em:< <http://www.fundepecgo.org.br/home/2017/10/23/usda-confirma-relatorio-sobre-o-mercado-de-carnes/>>. Acesso em: 13 set. 2018.
- GAGAOUA, M. et al. Sensory quality of meat from eight different types of cattle in relation with their biochemical characteristics. **Journal of Integrative Agriculture**, v. 15, n. 7, p. 1550-1563, 2016.
- GARCÍA, C. G. et al. Midgar: Detection of people through computer vision in the Internet of Things scenarios to improve the security in Smart Cities, Smart Towns, and Smart Homes. **Future Generation Computer Systems**, v. 76, p. 301-313, 2017.
- JUNQUEIRA, L. C.; CARNEIRO, J. **Histologia básica**. 11^a edição. Rio de Janeiro, 2008.
- GIL, J. M.; GRACIA, A.; PÉREZ, L. Pérez Y. Food consumption and economic development in the European Union. **European Review of Agricultural Economics**, v. 22, n. 3, p. 385-399, 1995.
- GILBERT, S. F. **Developmental biology**. ed. Sunderland, MA, 2006.
- GIROLAMI, A. et al. Measurement of meat color using a computer vision system. **Meat science**, v. 93, n. 1, p. 111-118, 2013.
- GIROLAMI, A. et al. Image analysis with the computer vision system and the consumer test in evaluating the appearance of Lucanian dry sausage. **Meat science**, v. 96, n. 1, p. 610-616, 2014
- HASSANIEN, A. E.; AL-SHAMMARI, E. T.; GHALI, N. I. Computational intelligence techniques in bioinformatics. **Computational biology and chemistry**, v. 47, p. 37-47, 2013.
- HAYKIN, S. **Neural Networks - A Comprehensive Foundation**. Prentice-Hall PTR, 1999.
- HENCHION, Maeve et al. Meat consumption: Trends and quality matters. **Meat science**, v. 98, n. 3, p. 561-568, 2014.
- HERRING, H. K.; CASSENS, R. G.; BRISKEY, E. J. Factors affecting collagen solubility in bovine muscles. **Journal of Food Science**, v. 32, n. 5, p. 534-538, 1967.
- HOFFMANN, A. et al. Beef cattle production in pasture-supplement system in dry season. **Nativa: Pesquisas Agrárias e Ambientais**, v. 2, n. 2, p. 119-130, 2014.
- JACKMAN, P.; SUN, D. W.; ALLEN, P. Automatic segmentation of beef longissimus dorsi muscle and marbling by an adaptable algorithm. **Meat Science**, v. 83, n. 2, p. 187-194, 2009.
- JACKMAN, P.; SUN, D.W. Computer vision in the fresh and processed meat industries. In: **Computer Vision Technology in the Food and Beverage Industries**. Woodhead Publishing, 2012. p. 255-276.
- JOO, S. T. et al. Control of fresh meat quality through manipulation of muscle fiber characteristics. **Meat science**, v. 95, n. 4, p. 828-836, 2013.

- KARSENTY, G. The complexities of skeletal biology. **Nature**, v. 423, n. 6937, p. 316, 2003.
- KATCHBURIAN, E; ARANA CHAVEZ, V. E. **Histologia e embriologia oral**: texto, atlas, correlações clínicas. 2004.
- KOEHRSEN, W. **Random Forest simple explanation**. 2017. Disponível em: <<https://medium.com/@williamkoehrsen/random-forest-simple-explanation-377895a60d2d>>. Acesso em: 15 jan 2019.
- KOHAVI, R; PROVOST, F. Glossary of terms. **Special issue on applications of machine learning and the knowledge discovery process**, v. 30, n. 271, p. 127-132, 1998.
- KRONENBERG, H. M. Developmental regulation of the growth plate. **Nature**, v. 423, n. 6937, p. 332, 2003.
- LARSEN, A. B. L. et al. Vision-based method for tracking meat cuts in slaughterhouses. **Meat science**, v. 96, n. 1, p. 366-372, 2014.
- LAWRENCE, T. E. et al. Influence of dental carcass maturity classification on carcass traits and tenderness of longissimus steaks from commercially fed cattle. **Journal of Animal Science**, v. 79, n. 8, p. 2092-2096, 2001a.
- LAWRENCE, T. E. et al. A comparison of the USDA ossification-based maturity system to a system based on dentition. **Journal of animal science**, v. 79, n. 7, p. 1683-1690, 2001b.
- LAWRIE, R. A. **Ciência da Carne**. 6. ed. Porto Alegre, 2005. 384p
- LIMA JÚNIOR, D. M. DE; RANGEL, A. H. D. N.; URBANHO, S. A.; MACIEL, M. D. V.; AMARO, L. P. D. A. Alguns aspectos qualitativos da carne bovina: uma revisão. **Acta Veterinaria Brasilica**, v. 5, n. 4, p. 351–358, 2011.
- LORENA, A. C.; DE CARVALHO, A. C. P. L. F. Uma introdução às support vector machines. **Revista de informática Teórica e Aplicada**, v. 14, n. 2, p. 43-67, 2007.
- LUCHIARI FILHO, A. F. **Pecuária da carne bovina**. São Paulo, 2000. 134p.
- LUCHIARI FILHO A. Produção de carne bovina no Brasil, qualidade, quantidade ou ambas? In: SIMBOI. Simpósio sobre Desafios e Novas Tecnologias na Bovinocultura de Corte, 2, 2006, Brasília, DF. **Anais ...** Brasília, DF: SIMBOI, 2006.
- LU, J., TAN, J., SHATADAL, P., GERRARD, D.E., 2000. Evaluation of pork color by using computer vision. **Meat Science**. 56, 57_/60.
- MA, T.; YAN, Q.; LIU, W.; GUAN, D.; LEE, S. Grid task scheduling: algorithm review. **IETE Technical Review**, v. 28, n. 2, p. 158-167, 2011.
- MAULIK, Ujjwal; BANDYOPADHYAY, Sanghamitra; WANG, Jason T. **Computational intelligence and pattern analysis in biology informatics**. John Wiley & Sons, 2011.

- MEADE, B.; ROSEN, S. International Food Security Assessment, 2013–2023, GFA-24, U.S. **Department of Agriculture**. Economic Research Service, Jun 2013.
- MARTHA JR., G. B. et al. Land-saving approaches and beef production growth in Brazil. **Agricultural Systems**. Essex, v.110, n.1, p. 173-177, jul. 2012.
- MASTELINI, S. M. et al. Marbling Grading Framework Applied on Meat Boutique Environment. In: **Proceedings of the XII Brazilian Symposium on Information Systems on Brazilian Symposium on Information Systems: Information Systems in the Cloud Computing Era-Volume 1**. Brazilian Computer Society, 2016. p. 71.
- MCCORMICK, R. J. Extracellular modifications to muscle collagen: implications for meat quality. **Poultry science**, v. 78, n. 5, p. 785-791, 1999.
- MEAT STANDARDS AUSTRALIA (MSA). **User's guide to Australian Meat**. 3rd ed. Brisbane. AUS-MEAT LIMITED. 2003, 84p.
- MIGNANI, A. G. et al. Spectral nephelometry for the geographic classification of Italian extra virgin olive oils. **Sensors and Actuators B: Chemical**, v. 111, p. 363-369, 2005.
- MINOLTA. Precise color communication. **Minolta co.**, p. 1–62, 2007.
- MUCHENJE, V.; DZAMA, K.; CHIMONYO, M.; STRYDOM, P. E.; HUGO, A.; RAATS, J. G. 2009. Some biochemical aspects pertaining to beef eating quality and consumer health: A review. **Food Chemistry**, p. 112:279–289.
- NISHIMURA, T.; HATTORI, A.; TAKAHASHI, K. Relationship between degradation of proteoglycans and weakening of the intramuscular connective tissue during post-mortem ageing of beef. **Meat Science**, v. 42, n. 3, p. 251-260, 1996.
- NISHIMURA, T. The role of intramuscular connective tissue in meat texture. **Animal science journal**, v. 81, n. 1, p. 21-27, 2010.
- OLSEN, B. R.; REGINATO, A. M.; WANG, W. Bone development. **Annual review of cell and developmental biology**, v. 16, n. 1, p. 191-220, 2000.
- OSÓRIO, M.T.; OSÓRIO, J.C.; OLIVEIRA, N.M. et al. Study on pH variation from meat of Corriedale male lambs raised three nutritional systems. In: **INTERNATIONAL CONGRESS OF MEAT SCIENCE AND TECHNOLOGY**, 46, 2000, Buenos Aires. **Anais...** Buenos Aires: 2000. v.1, p.190-191.
- OWENS, F. NELLORE; DUBESKI, P.; HANSON, C. F. Factors that alter the growth and development of ruminants. **Journal of animal science**, v. 71, n. 11, p. 3138-3150, 1993.
- OWENS, Fredric N. et al. Review of some aspects of growth and development of feedlot cattle. **Journal of animal science**, v. 73, n. 10, p. 3152-3172, 1995.

PAZ, C. C. P.; LUCHIARI FILHO, A. Melhoramento genético e diferenças de raças com relação à qualidade da carne bovina. **Pecuária de corte**, v. 101, p. 58-63, 2000.

PALMER, C. M. The demand for meat and patterns of consumption: An introductory guide. **Nutrition and Climate Change: Major Issues Confronting the Meat Industry**, v. 13, p. 139, 2011.

PETHICK, D. W. et al. Current and future issues facing red meat quality in a competitive market and how to manage continuous improvement. **Animal Production Science**, v. 51, n. 1, p. 13-18, 2011.

PURSLOW, Peter P. Intramuscular connective tissue and its role in meat quality. **Meat science**, v. 70, n. 3, p. 435-447, 2005.

RAINES, C. R. et al. Predicting cattle age from eye lens weight and nitrogen content, dentition, and United States Department of Agriculture maturity score. **Journal of animal science**, v. 86, n. 12, p. 3557-3567, 2008.

RAMOS, J. L. C.; GOMES, A. S. **Uma abordagem preditiva da evasão na educação a distância a partir dos construtos da distância transacional**. 2016. Disponível em: <https://www.researchgate.net/figure/Figura-10-Exemplo-da-classificacao-do-kNN-para-dois-valores-de-k_fig7_312605379>. Acesso em: 15 jan 2019.

RASJID, Z. E.; SETIAWAN, R. Performance Comparison and Optimization of Text Document Classification using k-NN and Naïve Bayes Classification Techniques. **Procedia Computer Science**, v. 116, p. 107-112, 2017.

REALINI, C. E., FONT I FURNOLS, M., SANUDO, C., MONTOSSI, F., OLIVER, M. A.; GUERRERO, L. (2013). Spanish, French and British consumers' acceptability of Uruguayan beef, and consumers' beef choice associated with country of origin, finishing diet and meat price. **Meat Science**, 95 (2013), 14-21.

REGMI, Anita et al. Convergence in food demand and delivery: Do middle-income countries follow high-income trends? **Journal of Food Distribution Research**, v. 39, n. 1, p. 116, 2008.

RENAND, G. et al. Relationships between muscle characteristics and meat quality traits of young Charolais bulls. **Meat science**, v. 59, n. 1, p. 49-60, 2001.

ROPODI, A. I.; PANAGOUE, E. Z.; NYCHAS, G.-JE. Data mining derived from food analyses using non-invasive/non-destructive analytical techniques; determination of food authenticity, quality & safety in tandem with computer science disciplines. **Trends in Food Science & Technology**, v. 50, p. 11-25, 2016.

SANDRIN, A. et al. Modeling changes with ageing in the mechanical properties of beef connective tissue. In: **Proceedings 50th international congress of meat science and technology**. p. 271-273, 2004.

SANS, P.; COMBRIS, P. World meat consumption patterns: An overview of the last fifty years (1961–2011). **Meat science**, v. 109, p. 106-111, 2015.

SHORTHOSE, W. R.; HARRIS, P. V. Effect of animal age on the tenderness of selected beef muscles. **Journal of Food Science**, v. 55, n. 1, p. 1-8, 1990.

SILVA, J. A. P. R. **Detecção de insultos em mídias de redes sociais através de aprendizado de máquina**. Trabalho de conclusão de curso (Bacharel em Ciência da Computação) – Universidade Estadual de Londrina, Londrina, 2018.

SOLTANI, M.; OMID, M. Detection of poultry egg freshness by dielectric spectroscopy and machine learning techniques. **LWT-Food Science and Technology**, v. 62, n. 2, p. 1034-1042, 2015.

SUN, D. W. Inspecting pizza topping percentage and distribution by a computer vision method. **Journal of food engineering**, v. 44, n. 4, p. 245-249, 2000.

SUN, X. et al. Prediction of pork color attributes using computer vision system. **Meat science**, v. 113, p. 62-64, 2016.

TANZER, M. L. Cross-linking of collagen. **Science**, v. 180, n. 4086, p. 561-566, 1973.

TIMMERMANS, A.J.M., Computer vision system for on-line sorting of pot plants based on learning techniques. **Acta Horticulture**. 1998. 421, 91_/98.

USDA. **Agricultural Marketing Service Grading, Certification and Verification: USDA Quality Standards**. Washington, DC: USDA. 2012.

WHITING, K. J. et al. The anterior tooth development of cattle presented for slaughter: an analysis of age, sex and breed. **animal**, v. 7, n. 8, p. 1323-1331, 2013.

ZHAO, Jiewen et al. Identification of egg's freshness using NIR and support vector data description. **Journal of food Engineering**, v. 98, n. 4, p. 408-414, 2010.

3 OBJETIVOS

3.1 OBJETIVO GERAL


Avaliar se a idade fisiológica de carcaças bovinas pode ser identificada por meio de visão computacional.

3.2 OBJETIVOS ESPECÍFICOS

- Comparar o desempenho dos classificadores de aprendizagem de máquina supervisionada k-NN, RF e SVM para a predição de classes etárias de carcaças.
- Identificar quais características de interesse são mais importantes para a análise de predição das classes etárias das carcaças.

4 ARTIGO

PHYSIOLOGICAL AGE CLASSES OF NELORE BULLS CAN BE IDENTIFIED BY CARTILAGE OSSIFICATION USING COMPUTATIONAL VISION



O artigo encontra-se parcialmente nas normas do periódico Food Research International, faltando a tradução para língua inglesa.

Qualis CAPES: A1 – Medicina Veterinária

Endereço: <https://www.elsevier.com/journals/food-research-international/09639969/guide-for-authors>

ISSN: 0963-9969

RESUMO

1
2 A idade do animal determina a quantidade de tecido depositado na carcaça, seja ele ósseo,
3 muscular ou adiposo e influencia a maciez da carne. Por este motivo, a idade é utilizada em
4 programas de classificação e tipificação para determinar níveis de qualidade da carne a ser
5 comercializada. No entanto, a classificação tradicional é realizada de forma subjetiva, mesmo
6 que por painelistas treinados. A visão computacional vem sendo utilizada na área agrícola e
7 na avaliação de alimentos com a finalidade de retirar a subjetividade da avaliação humana e
8 produzir resultados mais concisos e precisos. Neste sentido, a proposta deste estudo é
9 comparar qual classificador resultará em um melhor modelo preditivo, utilizando k-Nearest
10 Neighbors (k=1), Random Forest e Support Vector Machine como modelos preditivos devido
11 à sua ampla aplicação e alto desempenho. Foram utilizadas 56 meias carcaças de bovinos
12 Nelore não castrados, que foram divididos em três classes etárias (Precoce, Tourinho e
13 Touro), variando de 12 a 48 meses. As imagens foram adquiridas com auxílio de câmera
14 digital com suas funções automáticas e sem controle ambiental. O algoritmo k-NN obteve
15 acurácia de 78,95%, tendo seu pior desempenho na classificação dos animais de idade
16 intermediária. O resultado obtido com o algoritmo RF foi de 73,68% de acurácia e classificou
17 quatro amostras do grupo de idade intermediária como falso positivo. O algoritmo SVM
18 classificou uma amostra do grupo mais jovem como sendo do grupo mais velho e não
19 conseguiu prever nenhuma amostra do grupo intermediário, gerando um modelo com
20 68,42% de acurácia. Os algoritmos de classificação propostos mostraram bom desempenho e
21 viabilidade de implantação em relação ao sistema tradicional. O algoritmo k-NN foi o que
22 apresentou melhor desempenho e a solução mais simples entre os classificadores.

23

24 **Key words:** k-Nearest Neighbor. Ossification. Physiological maturity. Random Forest.

25 Skeletal Maturity. Support Vector Machine.

26 1. Introdução

27

28 A idade do animal determina a quantidade de tecido depositado na carcaça, seja ele ósseo,
29 muscular ou adiposo e influencia a maciez da carne. Por este motivo, a idade é utilizada em
30 programas de classificação e tipificação para determinar níveis de qualidade da carne a ser
31 comercializada. No Brasil a idade é avaliada por meio da erupção dos dentes permanentes
32 incisivos no momento do abate dos animais (BRASIL, 2004) levando em consideração apenas
33 a idade cronológica, diferente de países como Estados Unidos e Austrália que realizam a
34 identificação por meio da avaliação subjetiva da ossificação das cartilagens (AMSA, 2001;
35 MSA, 2003) considerando a idade fisiológica dos animais.

36 A criação de um sistema de classificação tem como objetivo facilitar a comercialização de
37 produtos com qualidade padronizada e que atendam as expectativas do consumidor (HATEM;
38 TAN; GERRARD, 2003). No entanto, quando a classificação é realizada de forma subjetiva,
39 abrem-se precedentes para entregar produtos de qualidade variada, uma vez que estes sistemas
40 se baseiam na avaliação por classificadores treinados que estão sujeitos a percepção variada
41 do ser humano. A diferença entre os observadores acontece devido à diferença de
42 sensibilidade dos olhos dos indivíduos, que, além disso, passa por alterações durante a vida e
43 provoca resultados diferentes (MINOLTA, 2007).

44 Além disso, estes padrões de classificação se baseiam em animais de raças taurinas que
45 apresentam certa discrepância em relação à animais zebuínos que são considerados mais
46 tardios em relação aos bovinos britânicos e mais precoces que os continentais (NOGUEIRA,
47 2004; MALTIN et al., 2003), podendo contribuir ainda mais para a variação dos resultados da
48 classificação.

49 A Visão Computacional vem sendo utilizada na área agrícola e na avaliação de alimentos com
50 a finalidade de retirar a subjetividade da avaliação humana e produzir resultados mais

51 concisos e precisos, seja na avaliação da carne de frango (BARBIN, et. al., 2016; TIMSORN,
52 et al., 2016; FARIDI, et al., 2012) ou para predizer o amadurecimento de frutas (PEREIRA,
53 et. al. 2018), ou ainda avaliar parâmetros que indicam a qualidade da carne de bovinos, ovinos
54 e suínos (BARBON, et al., 2017; KAMRUZZAMAN, et al., 2016; JAKES, et al, 2015;
55 MATERA, et al., 2014). A consistência e precisão dos resultados obtidos por meio da Visão
56 Computacional permitem uma análise mais eficaz e rentável (LU, 2000). Sendo assim,
57 objetivou-se com o presente estudo determinar a idade de carcaças de bovinos zebuínos
58 utilizando visão computacional.

59

60

61

62

63

64

65

66

67

68

69

70

71

72

73

74

75

76 **2. Materiais e Métodos**

77

78 2.1 Aquisição das imagens

79

80 Para a aquisição das imagens digitais foram utilizadas 56 meias-carcaças bovinas
 81 provenientes de machos da raça Nelore, não castrados com níveis de maturidade cronológica
 82 variando de 12 a 48 meses de idade. A idade cronológica foi mensurada pela data de
 83 nascimento dos animais que foram registrados no Ministério da Agricultura, Pecuária e
 84 Abastecimento por meio do sistema de rastreabilidade SISBOV (BRASIL, 2018).

85 Foram estabelecidos três grupos para a identificação das faixas de idade (Tabela 1), sendo
 86 eles: Precoce (animais de 12 a 18 meses), Tourinho (animais de 19 a 29 meses) e Touro
 87 (animais de 30 a 48 meses), e os conjuntos de treino e teste foram separados aleatoriamente.

88

89 **Tabela 1.** Número de meias-carcaças consideradas em cada classe etária para as análises de
 90 treinamento e teste dos classificadores.

Classe etária	Nº de animais	
	Treino	Teste
Precoce (animais de 12 a 18 meses)	19	9
Tourinho (animais de 19 a 29 meses)	9	5
Touro (animais de 30 a 48 meses)	9	5

91

92 As imagens foram coletadas em frigorífico comercial sob Inspeção Federal (BRASIL, 2017)
 93 com o auxílio de uma câmera digital com definição automática, posicionada a 40 cm da meia-
 94 carcaça, sustentada manualmente e sem controle de iluminação. Após a maturação sanitária,
 95 a partir de cada meia-carcaça esquerda foi obtida uma imagem da décima primeira à décima
 96 terceira vértebra torácica acompanhada de seus processos espinhosos (Figura 1).

97

98

Figura1. Vértèbras torácicas de meia-carcaça bovina.



99

100

101 2.2 Análise das imagens e extração de características

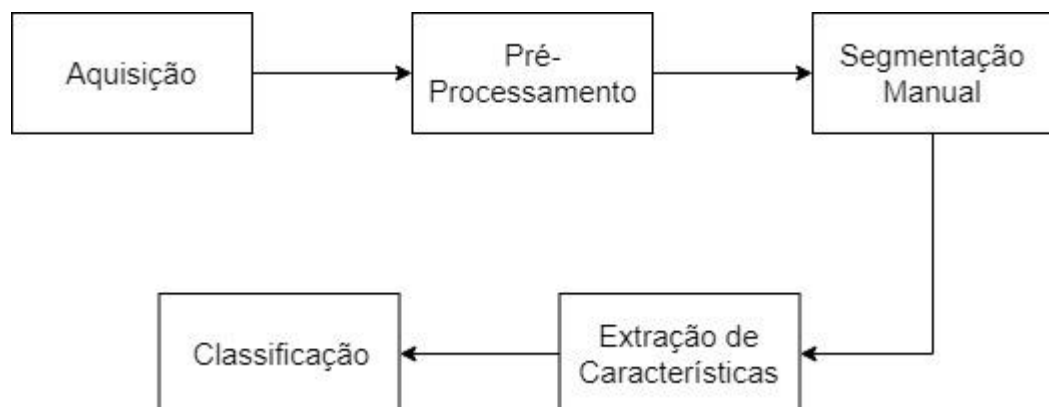
102

103 A estrutura de processamento das imagens segue o fluxo como mostra a Figura 2. Depois da
104 aquisição feita no frigorífico as imagens foram pré-processadas manualmente para a
105 identificação e extração das características de interesse para posteriormente seguirem para os
106 testes com os classificadores.

107

108

Figura 2. Fluxograma do processamento e análise das imagens.




109

110 No pré-processamento ocorreu a identificação das regiões de interesse que foram detectadas
111 por meio de segmentação semântica com a ferramenta LabelMe em ambiente PYTHON –
112 versão 2.7.15 (PSF, 2018) como mostra a Figura 3. As áreas de cartilagem e osso foram
113 demarcadas separadamente, para posteriormente formarem uma única imagem para dar
114 sequência a análise.

115

116 Figura 3. Segmentação manual das imagens e obtenção das regiões de interesse.



117
118

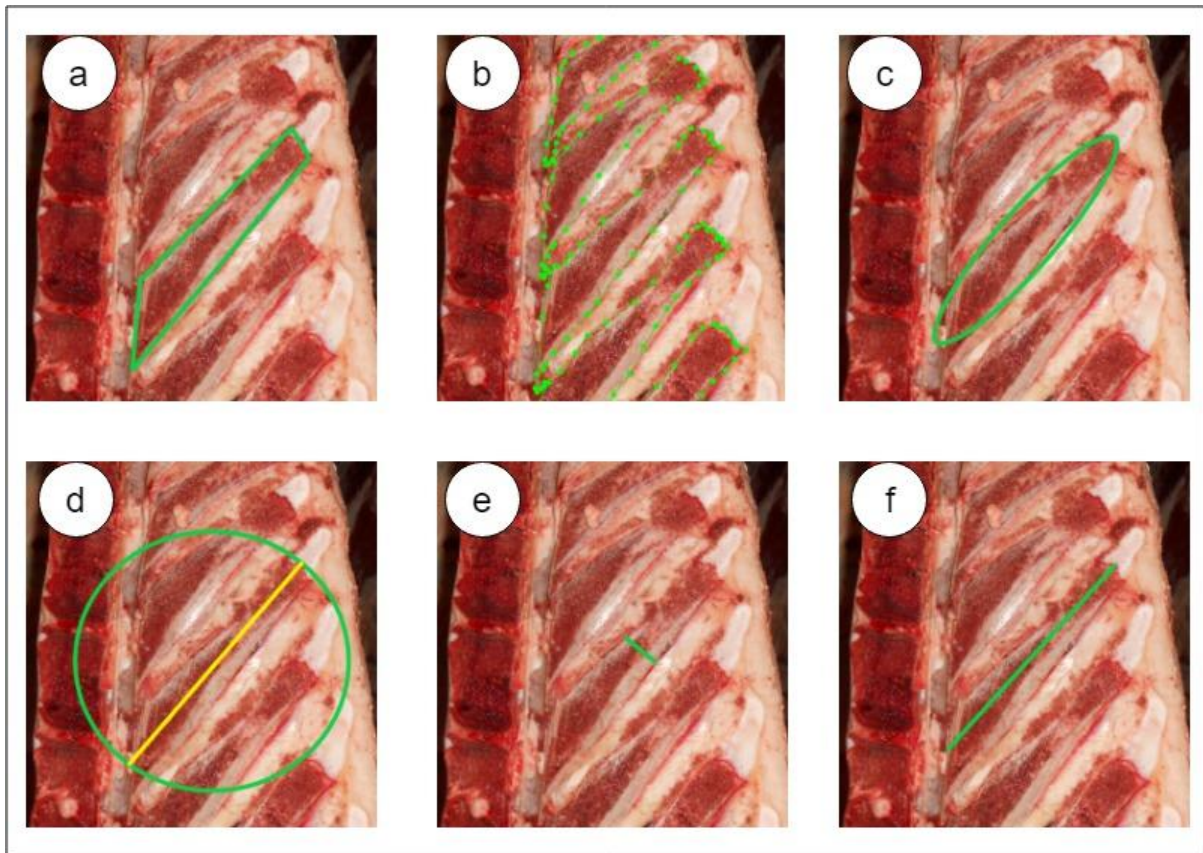
119 Após a segmentação das regiões de interesse, um arquivo com extensão JSON foi criado e
120 processado utilizando MATLAB R2018b - versão 9.5 (MATHWORKS, 2018) para que fosse
121 possível realizar a leitura do arquivo JSON, que era composto por pontos das regiões
122 distintas. Por meio desse arquivo foi possível determinar o *shape* de cada região com
123 polígonos, com a extração das seguintes características de forma (Figura 4): área média de
124 osso (a) e cartilagem, perímetro médio de osso (b) e cartilagem, excentricidade de osso (c) e
125 cartilagem, diâmetro equivalente (d), comprimento médio menor (e) e maior (f) de osso e
126 cartilagem.

127

128

129

130

131 **Figura 4.** Extração das características de forma de imagens de meia-carcaça bovina.

132

133

134 2.3 Classificação e métrica

135

136 Para avaliar a classificação e os modelos gerados pelos algoritmos as amostras foram
137 organizadas em dois conjuntos de dados, calibração e teste de previsão. O conjunto de
138 calibração, composto por 37 imagens, foi utilizado para induzir os modelos e ajustar os
139 parâmetros dos algoritmos, enquanto o conjunto de testes de previsão, composto por 19
140 imagens, foi utilizado para avaliar o desempenho de classificação de cada algoritmo.

141 A classificação e os modelos preditivos foram induzidos utilizando k-Nearest Neighbors
142 ($k=1$), Random Forest e Support Vector Machine, devido à sua ampla aplicação e alto
143 desempenho. Os classificadores foram implementados em linguagem R v.3.3.1, ambiente R

144 Studio v.1.1.463 utilizando os pacotes Rweka (k-NN), random Forest (RF), e1071 (SVM)
145 com hiperparâmetros padrão. A acurácia foi mensurada segundo a fórmula:

$$Acurácia = \frac{Verdadeiros\ Precoce + Verdadeiros\ Tourinho + Verdadeiros\ Touro}{Total}$$

146 e mostra relação entre o número de acertos de cada modelo e a idade real de cada carcaça. A
147 precisão indica o número de amostras que efetivamente são corretamente classificadas e pode
148 ser descrita pela seguinte equação:

$$Precisão = \frac{Verdadeiros}{Verdadeiros + Falsos}$$

149

150 Os resultados obtidos nos modelos de classificação foram representados em matriz de
151 confusão que fornece informação sobre a capacidade dos modelos de prever a idade das
152 carcaças. Além disso, é possível avaliar o desempenho geral, precisão, sensibilidade e
153 especificidade de cada modelo permitindo a identificação de amostras erroneamente
154 classificadas e os resultados de cada classe.

155

156

157

158

159

160

161

162

163

164

165

166 **3. Resultados**

167

168 O desempenho dos classificadores k-NN, Random Forest e Support Vector Machine pode ser
 169 avaliado na Tabela 2, que também mostra a precisão e o número de amostras correta e
 170 incorretamente classificadas.

171

172 **Tabela 2.** Matriz de confusão gerada pelos classificadores k-NN, Random Forest (RF) e
 173 Support Vector Machine (SVM) com valores de precisão e acurácia de classificação de
 174 diferentes faixas de idade de carcaças bovinas.

k-NN				
	Touro	Tourinho	Precoce	Precisão
Touro	5	0	0	1,00
Tourinho	1	2	2	0,40
Precoce	1	0	8	0,89
Acurácia	78,95%			
RF				
	Touro	Tourinho	Precoce	Precisão
Touro	5	0	0	1,00
Tourinho	1	1	3	0,20
Precoce	0	1	8	0,89
Acurácia	73,68%			
SVM				
	Touro	Tourinho	Precoce	Precisão
Touro	5	0	0	1,00
Tourinho	1	0	4	0,00
Precoce	1	0	8	0,89
Acurácia	68,42%			

175

176 O algoritmo k-NN obteve uma acurácia de 78,95%, tendo seu pior desempenho na
 177 classificação dos animais de idade intermediária onde classificou três amostras erradas de um
 178 total de cinco. Um resultado parecido foi obtido com o algoritmo RF que obteve 73,68% de
 179 acurácia e classificou quatro amostras do grupo de idade intermediária como falso positivo.

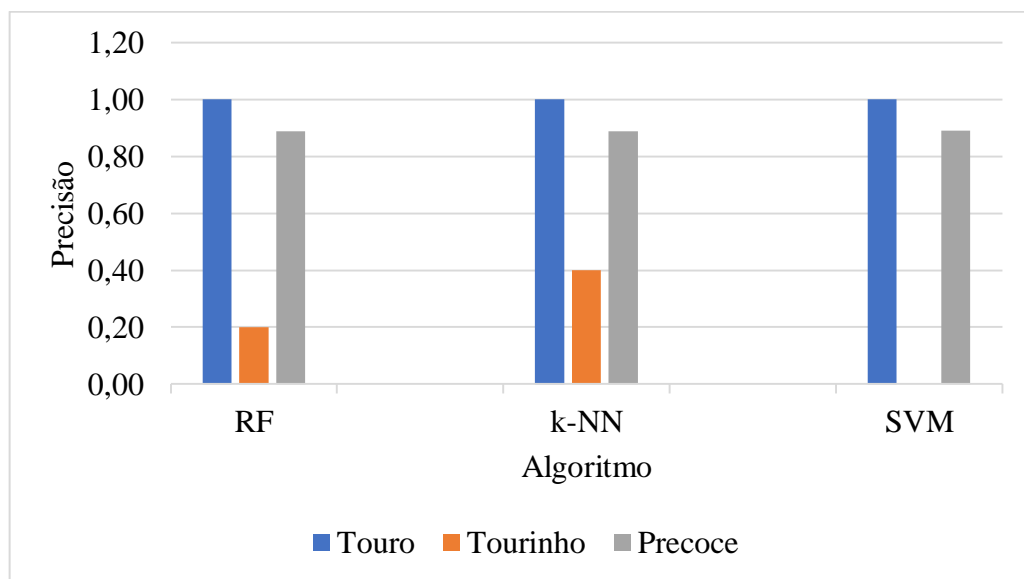
180 No entanto, classificando animais do grupo mais jovem identificou uma amostra como
181 intermediária, enquanto que o algoritmo k-NN a alocou no grupo de maior idade.

182 O modelo criado pelo SVM classificou uma amostra do grupo mais jovem como sendo do
183 grupo mais velho e não conseguiu prever nenhuma amostra do grupo intermediário,
184 apresentando cinco amostras falso positivo de um total de cinco, gerando um modelo com
185 68,42% de acurácia.

186 Para avaliar a faixa de idade com melhor padrão de identificação, os valores de precisão
187 foram apresentados no Gráfico 1.

188

189 **Gráfico 1.** Valores de precisão de diferentes algoritmos para a classificação de três faixas de
190 idade de carcaças bovinas.



191

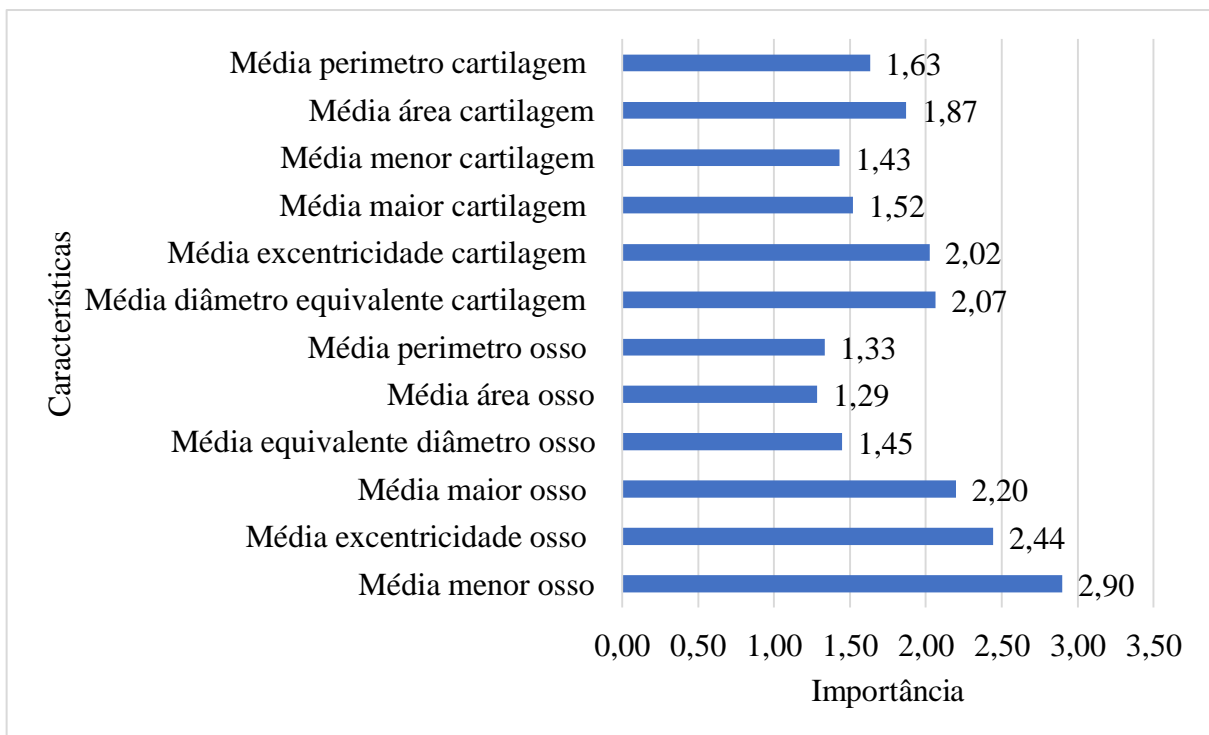
192

193 Os três algoritmos obtiveram precisão máxima na classificação das amostras do grupo de
194 maior idade e próxima de 0,90 na classificação das amostras do grupo de menor idade. O
195 grupo de idade intermediária foi o que gerou os piores desempenhos em ambos
196 classificadores, tendo como pior o SVM, seguido do RF e k-NN.

197 Neste estudo foi utilizado o valor de *RF importance* para avaliar o impacto de cada
 198 característica de forma extraída na previsão das classes etárias. As características apresentadas
 199 no Gráfico 2 foram incluídas nos modelos com diferentes graus de importância.

200

201 **Gráfico 2.** Características extraídas apresentadas em grau de importância de acordo com o RF
 202 *importance*.



203

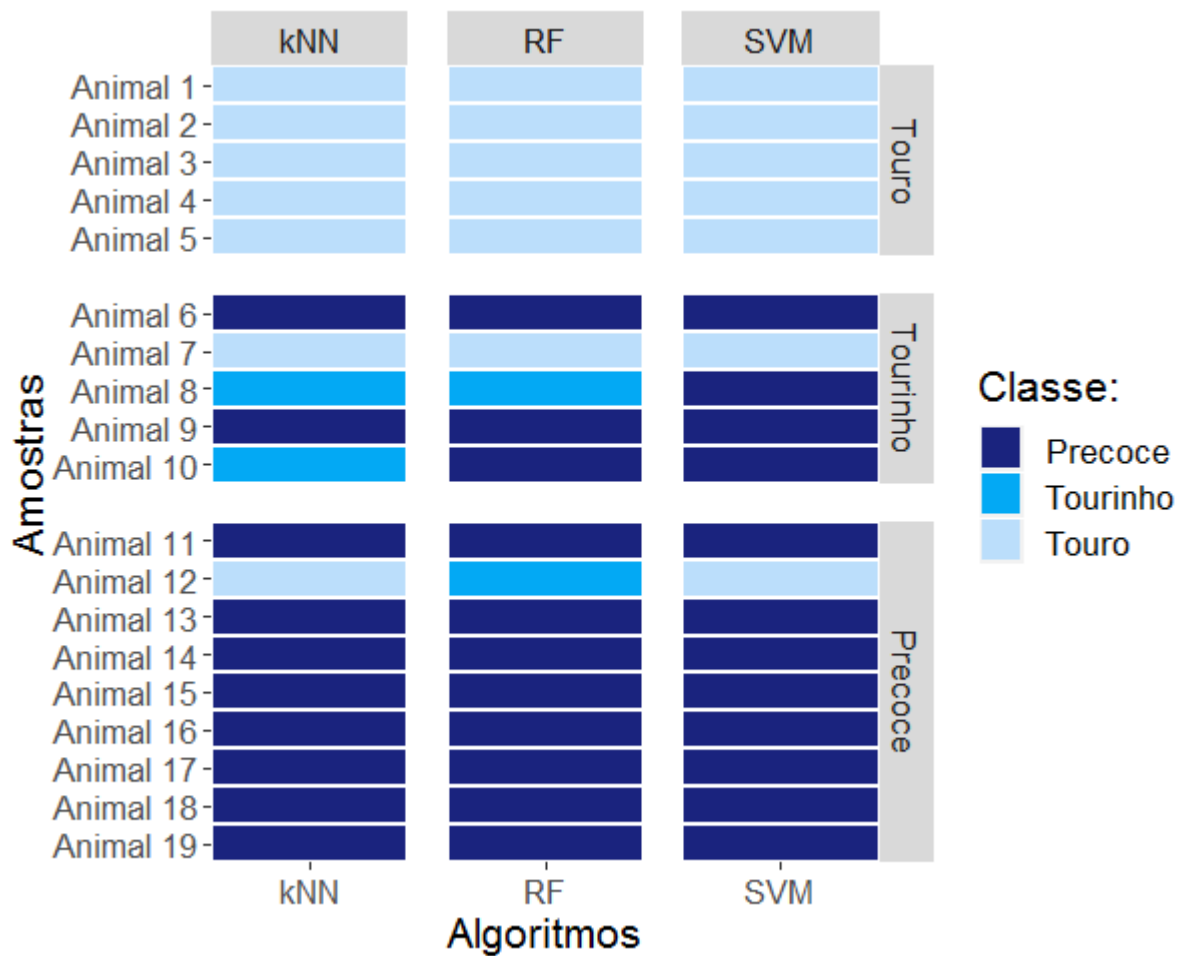
204

205 É possível identificar maiores picos nas características de forma relacionadas ao osso do que a
 206 cartilagem. A de maior importância foi a média do comprimento menor do osso, seguida da
 207 excentricidade média do osso, média do comprimento maior do osso, diâmetro médio
 208 equivalente, excentricidade e área média, perímetro, comprimento médio da maior
 209 cartilagem, diâmetro médio equivalente do osso, comprimento médio menor da cartilagem,
 210 perímetro médio e área média do osso, sendo importante salientar que na composição do
 211 modelo todas exercem função de importância, uma vez que os valores obtidos são muito
 212 próximos.

213 No Gráfico 3 são apresentadas todas as amostras utilizadas na fase de teste e suas respectivas
 214 classificações obtidas em cada classificador, ficando evidente a complexidade da classificação
 215 da classe intermediária.

216

217 **Gráfico 3.** Amostras de carcaças bovinas classificadas correta e incorretamente pelos
 218 classificadores k-NN, RF e SVM de acordo com sua classe etária.



219

220

221

222

223

224

225

226

227

228

229

230 4. Discussão

231

232 Com base nos valores de desempenho geral dos três classificadores (Tabela 2), a identificação
233 das três classes de idade foi realizada com um bom desempenho, tendo como melhor
234 classificador o algoritmo k-NN com 78,63% de acurácia. A precisão foi de 100% para a classe
235 dos touros, 89% para a classe dos precoces e 40% para os tourinhos.

236 O classificador Random Forest obteve um desempenho muito próximo, diferindo apenas na
237 identificação da classe intermediária de idade. Levando em consideração a classificação de
238 um animal pertencente ao grupo Precoce no grupo Touro, este algoritmo também indica
239 melhor desempenho, tendo que melhorar a identificação do grupo intermediário.

240 Como evidenciado no Gráfico 1, as classes de idade mais alta e baixa, ou seja, das
241 extremidades apresentaram maior precisão em todos os testes de predição. Isso porque
242 apresentam padrões mais definidos em relação as características que são extraídas de cada
243 imagem. Em outras palavras apresentam maior definição em relação as proporções de osso e
244 cartilagem, devido ao próprio desenvolvimento corporal do animal (OWENS; DUBESKI;
245 HANSON, 1993). Uma alternativa para melhorar esse desempenho seria aumentar a
246 estratificação das classes de idade afim de evidenciar as características das regiões de
247 interesse das imagens e aumentar a homogeneidade das amostras por estarem mais próximas
248 das extremidades.

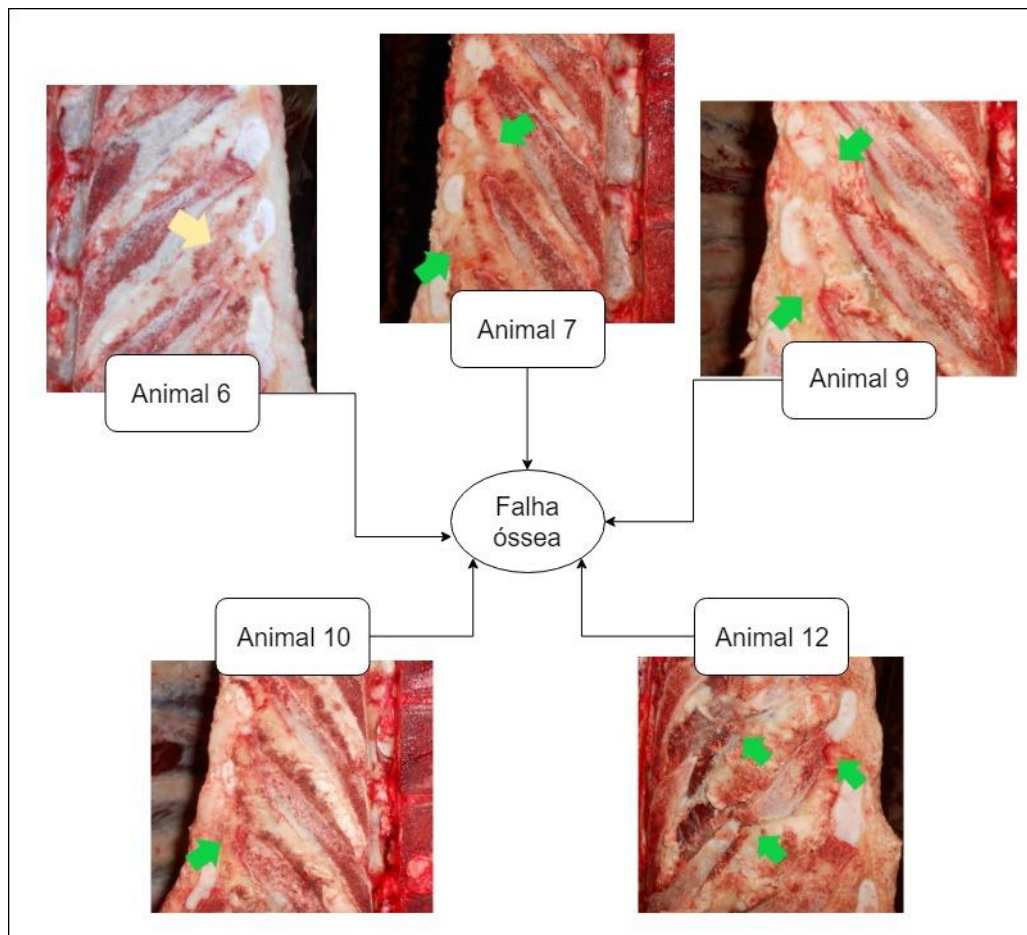
249 Como mostra o Gráfico 3 cinco amostras foram incorretamente classificadas por pelo menos
250 dois dos três classificadores escolhidos. Destas, quatro pertenciam a classe etária
251 intermediária que possui traços de similaridade com as idades extremas das classes
252 adjacentes. Além disso, as cinco imagens apresentaram falhas ósseas como pode ser
253 evidenciado na Figura 5.

254 Considerando o grau de importância das características de forma, falhas ósseas comprometem
 255 o desempenho dos classificadores nos testes de predição. Com a ausência de porções ósseas
 256 que afetam as mensurações poligonais dos descritores, os valores corretos são mascarados e
 257 acabam sendo subestimados evidenciando as características relacionadas a cartilagem, que
 258 possuem menor peso nos modelos desenvolvidos.

259 As falhas ósseas operacionais e também cartilagosas comprometem o desempenho dos
 260 classificadores, que utilizam características relacionadas ao osso e a cartilagem para gerar os
 261 respectivos modelos preditivos. Como as características que apresentaram maior importância
 262 estão relacionadas ao osso (Tabela 2), a falta da parte óssea ou cartilaginosa provoca uma
 263 distorção nos resultados, uma vez que o algoritmo classifica por similaridade.

264

265 Figura 5. Falhas operacionais causadas pelo processamento das carcaças bovinas durante o
 266 abate.



267

268

269 Diferenças de luminosidade durante a aquisição das imagens também podem ter afetado os
270 classificadores durante a predição (DU; SUN, 2004). Como a intenção deste estudo foi
271 adequar um modelo a realidade industrial, que alocam as carcaças em câmaras frias com
272 diferentes gruas de iluminação, não trabalhamos com este tipo de controle no ambiente.

273 Trabalhando com Redes Neurais Hopfield com base na distância Euclidiana mínima para
274 resolução da subjetividade do grau de ossificação da cartilagem das vértebras torácicas,
275 Meng, Ren e Pan (2015) obtiveram acurácia de 92,75% para reconhecimento das áreas de
276 cartilagem e 87,68% para reconhecimento das áreas de osso, com erro de classificação em
277 14,49%. A segmentação das imagens foi realizada por cor em espaço RGB e textura. A
278 previsão automática média de maturidade se fixou em 86%.

279 Utilizando também Rede Neural para prever os graus de maturidade de carne bovina do
280 USDA a partir de imagens, Hatem, Tan e Gerrard (2003) definiram uma curva para
281 caracterizar as variações de cor das regiões de cartilagem e osso. Sistemas RGB e HSL foram
282 utilizados para derivar recursos de imagem. Obtiveram 75% de precisão na predição dos
283 grupos de maturidade.

284 No entanto, a utilização de Redes Neurais Artificiais apresentam desvantagens em relação aos
285 classificadores utilizados neste estudo, como processo de treinamento mais lento (SAKI et al.,
286 2013), a exigência de diversos parâmetros que, em caso de mal fornecidos, levam a uma
287 solução ruim, e ainda, devido ao tamanho do conjunto de amostras, poderíamos causar ajuste
288 excessivo do modelo a base de dados.

289

290

291

292

293

294

295

296

297 **5. Conclusão**

298

299 Os modelos de classificação propostos mostraram bom desempenho e viabilidade de
300 implantação da visão computacional para avaliar classes de idade fisiológica de carcaças
301 bovinas. A redução da subjetividade causada pela avaliação da idade cronológica, ou pela
302 utilização de painelistas treinados para a identificação da idade fisiológica traz ao sistema de
303 classificação de carcaças bovinas maior confiabilidade.

304 Avaliando os algoritmos utilizados neste estudo, o algoritmo k-NN foi o que apresentou o
305 modelo melhor e a solução mais simples entre os classificadores. É necessário, no entanto,
306 melhorar a base de dados para aumentar sua precisão em relação a identificação de grupos
307 intermediários. As características consideradas mais importantes para o estabelecimento do
308 sistema de classificação são as relacionadas ao osso, sendo necessário ainda, contornar as
309 falhas ósseas ocorridas no processamento das carcaças para abranger um número maior de
310 amostras corretamente classificadas.

311

312 **6. Agradecimentos**

313 À CAPES pela concessão de bolsa de estudos que possibilitou a condução deste trabalho.

314

315

316

317

318

319

320

321

322 **Referências**

323

324 American Meat Science Association, 2001. Meat Evaluation Handbook. American Meat
325 Science Association, Savoy, IL.

326

327 Barbin, D. F., Mastelini, S. M., Barbon, S., Campos, G. F. C., Barbon, A. P. A. C.;
328 Shimokomaki, M. Digital image analyses as an alternative tool for chicken quality
329 assessment. Biosystems Engineering, 144, 85-93.

330

331 Barbon, A. P. A., Barbon Jr, S., Mantovani, R. G., Fuzyi, E. M., Peres, L. M., Bridi, A.
332 M, 2016. Storage time prediction of pork by computational intelligence. Computers and
333 Electronics in Agriculture, 127, 368-375.

334

335 Brasil. Ministério da Agricultura e Abastecimento. Instrução Normativa de N°9, de 4 de maio
336 de 2004. Aprova o Sistema Brasileiro de Classificação de Carcaças de Bovinos, em todo o
337 território nacional, e a classificação dos bovinos abatidos nos estabelecimentos sob o controle
338 do Serviço de Inspeção Federal (SIF), conforme consta do Anexo desta Instrução Normativa.
339 Diário Oficial da União: seção 1, Brasília. 2004.

340

341 Brasil. Decreto nº 9.013, de 29 de março de 2017. Regulamenta a Lei nº 1.283, de 18 de
342 dezembro de 1950, e a Lei nº 7.889, de 23 de novembro de 1989, que dispõem sobre a

- 343 inspeção industrial e sanitária de produtos de origem animal. Diário Oficial da União: seção 1,
344 Brasília. 2017
- 345
- 346 Brasil. Ministério da Agricultura e Abastecimento. Instrução normativa nº 51, de 1 de outubro
347 de 2018. Institui o Sistema Brasileiro de Identificação Individual de Bovinos e Búfalos -
348 SISBOV na forma desta Instrução Normativa e dos Anexos I a III. Diário Oficial da União:
349 seção 1, Brasília, ed. 194, p. 15. 2018
- 350
- 351 Du, C. J., Sun, D. W, 2004. Recent developments in the applications of image processing
352 techniques for food quality evaluation. Trends in food science & technology, 15(5), 230-249.
- 353
- 354 Faridi, A., Sakomura, N. K., Golian, A., Marcato, S. M., 2012. Predicting body and carcass
355 characteristics of 2 broiler chicken strains using support vector regression and neural network
356 models. Poultry science, 91(12), 3286-3294.
- 357
- 358 Hatem, I., Tan, J., Gerrard, D. E, 2003. Determination of animal skeletal maturity by image
359 processing. Meat science, 65(3), 999-1004.
- 360
- 361 Jakes, W., Gerdova, A., Defernez, M., Watson, A. D., McCallum, C., Limer, E., Colquhoun,
362 I. J., Williamson, D. C., Kemsley, E. K., 2015. Authentication of beef versus horse meat using
363 60 MHz 1H NMR spectroscopy. Food Chemistry, 175, 1-9.
- 364
- 365 Kamruzzaman, M., Makino, Y., Oshita, S., 2016. Online monitoring of red meat color using
366 hyperspectral imaging. Meat science, 116, 110-117.
- 367

- 368 Lu, J., Tan, J., Shatadal, P., Gerrard, D. E, 2000. Evaluation of pork color by using computer
369 vision. *Meat Science*, 56(1), 57-60.
370
- 371 Maltin, C., Balcerzak, D., Tilley, R., Delday, M, 2003. Determinants of meat quality:
372 tenderness. *Proceedings of the Nutrition Society*, 62(2), 337-347.
373
- 374 Matera, J. A., Cruz, A. G., Raices, R. S. L., Silva, M. C., Nogueira, L. C., Quitério, S. L.,
375 Cavalcanti, R. N., Freiras, M. Q., Júnior, C. C, 2014. Discrimination of Brazilian artisanal and
376 inspected pork sausages: application of unsupervised, linear and non-linear supervised
377 chemometric methods. *Food Research International*, 64, 380-386.
378
- 379 Meng, X., Ren, Y., Pan, H., 2015. Research on Beef Skeletal Maturity Determination Based
380 on Shape Description and Neural Network. *Telkomnika*, 13(2).
381
- 382 Meat Standards Australia, 2003. User's guide to Australian Meat. 3rd ed. Brisbane aus-meat
383 limited. 84.
384
- 385 Minolta, 2007. Precise color communication. Minolta Co. 64.
386
- 387 Nogueira, G. P., 2004. Puberty in south american bos indicus (Zebu) cattle. *Animal*
388 *reproduction science*, 82, 361-372.
389
- 390 Owens, F. N., Dubeski, P., Hanson, C. F., 1993. Factors that alter the growth and
391 development of ruminants. *Journal of animal science*, 71(11), 3138-3150.
392

- 393 Pereira, L. F. S., Barbon Jr, S., Valous, N. A., & Barbin, D. F., 2018. Predicting the ripening
394 of papaya fruit with digital imaging and random forests. *Computers and Electronics in*
395 *Agriculture*, 145, 76-82.
- 396
- 397 Saki, F., Tahmasbi, A., Soltanian-Zadeh, H., & Shokouhi, S. B., 2013. Fast opposite weight
398 learning rules with application in breast cancer diagnosis. *Computers in biology and*
399 *medicine*, 43(1), 32-41.
- 400
- 401 Timsorn, K., Thoopboochagorn, T., Lertwattanasakul, N., Wongchoosuk, C, 2016).
402 Evaluation of bacterial population on chicken meats using a briefcase electronic nose.
403 *Biosystems Engineering*, 151, 116-125.
- 404

6 CONSIDERAÇÕES FINAIS

Sob condições de rotina industrial identificamos com cerca de 79% de acurácia o grau de ossificação de carcaças de machos não castrados da raça Nelore, contribuindo para o avanço do sistema de rastreabilidade da cadeia da carne bovina, uma vez que a tecnologia utilizada neste estudo para avaliação não é subjetiva como as metodologias utilizadas atualmente.