



UNIVERSIDADE  
ESTADUAL DE LONDRINA

---

ANA PAULA AYUB DA COSTA BARBON

**AVALIAÇÃO DO ÍNDICE DE MARMOREIO E DO TEMPO  
DE ESTOCAGEM DA CARNE COM O USO DA  
INTELIGÊNCIA COMPUTACIONAL**

---

Londrina  
2018

ANA PAULA AYUB DA COSTA BARBON

**AVALIAÇÃO DO ÍNDICE DE MARMOREIO E DO TEMPO  
DE ESTOCAGEM DA CARNE COM O USO DA  
INTELIGÊNCIA COMPUTACIONAL**

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

Orientador: Dra. Ana Maria Bridi  
Co-orientador: Sylvio Barbon Junior

Londrina  
2018

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UEL

Barbon, Ana Paula Ayub da Costa .

Avaliação do índice de marmoreio e do tempo de estocagem da carne com o uso da Inteligência Computacional / Ana Paula Ayub da Costa Barbon. - Londrina, 2018.  
76 f. : il.

Orientador: Ana Maria Bridi.

Coorientador: Sylvio Barbon Junior.

Tese (Doutorado em Ciência Animal) - Universidade Estadual de Londrina, Centro de Ciências Agrárias, Programa de Pós-Graduação em Ciência Animal, 2018.  
Inclui bibliografia.

1. Qualidade da carne - Tese. 2. Inteligência Computacional - Tese. 3. Marmoreio - Tese. 4. Tempo de estocagem - Tese. I. Bridi, Ana Maria . II. Barbon Junior, Sylvio. III. Universidade Estadual de Londrina. Centro de Ciências Agrárias. Programa de Pós-Graduação em Ciência Animal. IV. Título.

ANA PAULA AYUB DA COSTA BARBON

**AVALIAÇÃO DO ÍNDICE DE MARMOREIO E DO TEMPO DE  
ESTOCAGEM DA CARNE COM O USO DA INTELIGÊNCIA  
COMPUTACIONAL**

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

**BANCA EXAMINADORA**

---

Orientadora: Profa. Dra. Ana Maria Bridi  
Universidade Estadual de Londrina - UEL

---

Prof. Dr. Paulo Cesar Pozza  
Universidade Estadual de Maringá - UEM

---

Prof. Dr. Douglas Fernandes Barbin  
Universidade Estadual de Campinas - Unicamp

---

Profa. Dra. Adriana Lourenço Soares  
Universidade Estadual de Londrina - UEL

---

Prof. Dr. Alan Salvany Felinto  
Universidade Estadual de Londrina - UEL

Londrina, 20 de Fevereiro de 2018.

**Dedico este trabalho ao meu amado esposo e  
professor Sylvio Barbon Junior**

## AGRADECIMENTOS

Esses últimos quatro anos nos quais fiz minha pesquisa se transformaram em uma jornada árdua, de muitos desafios, aprendizado e amadurecimento. Por isso, agradeço primeiramente a Deus por sempre iluminar meu caminho e minhas escolhas.

Agradeço a minha orientadora Ana Maria Bridi não só pela orientação neste projeto, mas sobretudo pela amizade, flexibilidade, confiança e compreensão em momentos decisivos ao longo dessa caminhada. Sempre recordarei com carinho! Obrigada!

Manifesto aqui também minha gratidão aos colegas do Grupo de Pesquisa e Análise de Carne (GPAC), em particular a Louise M. Peres e a Nayara Andreo por transformar nossos dias de estudo e pesquisa mais alegres, serenos e produtivos. À Bárbara Giangarelli e Evelyn Rangel por sempre estarem presentes e carinhosamente me ajudarem. Obrigada por compartilhar momentos como estes com vocês!

Aos colegas Camila P. Rogel, Guilherme Agostinis, Fernanda Lisboa e Jéssica Vero que dividem experiência semelhante, meu muito obrigada!

A Evelyn Stivaletti que não mediu esforços para me auxiliar nos últimos anos e é uma amiga inestimável!

Gostaria de agradecer também aos professores, funcionários do Departamento de Zootecnia e da Pós-graduação em Ciência Animal que contribuíram para minha formação e sempre estiveram dispostos a ajudar.

Agradeço, em especial, ao professor Alessandro Ulrici e ao seu grupo da *Università degli studi di Modena e Reggio Emilia* (Itália) pelo acolhimento ao longo dos últimos meses e por todo ensinamento. Com certeza foi uma experiência inesquecível e que transformou meu modo de ver a pesquisa. Grazie per tutto!

À fundação CAPES pelo auxílio financeiro ao longo de minha formação.

Por fim, agradeço a minha família pelo suporte emocional e pela presença constante em minha vida e nas minhas decisões. Vocês foram essenciais em tornar este sonho uma realidade. Obrigada minha querida irmã Patricia, pela disposição em cuidar do João Elias toda vez que surgia um novo abate. Ao meu esposo e co-orientador Sylvio Barbon Junior, meus mais sinceros agradecimentos pela jornada dupla, conselhos, por acreditar em mim, por me direcionar e me dar suporte! Te amo!

BARBON, Ana Paula Ayub da Costa. **Avaliação do índice de marmoreio e do tempo de estocagem da carne com o uso da Inteligência Computacional**. 2018. 76 f. Tese (Doutorado em Ciência Animal) – Universidade Estadual de Londrina, Londrina, 2018.

## RESUMO

A Inteligência Computacional consiste em um conjunto de metodologias computacionais para auxiliar na compreensão de fenômenos do ‘mundo real’ em diversas áreas. Na Ciência dos Alimentos vem sendo aplicada como uma alternativa promissora para tratar problemas de subjetividade, tempo e custo das análises, usando abordagens baseadas na simulação do conhecimento humano por meio de inteligência artificial dos computadores. Em geral, técnicas computacionais contribuem para a oferta de produtos com qualidade, sendo aplicadas com maior precisão, velocidade e sem deterioração das amostras quando comparadas aos métodos de análises tradicionais. Na última década, a Visão Computacional têm sido uma das técnicas mais exploradas no controle de qualidade da carne. Ela se baseia no Processamento de Imagem e no Aprendizado de Máquina. Neste trabalho, a Visão Computacional foi utilizada com sucesso com a abordagem *k*-NN (*k*-Nearest Neighbors) para a avaliação do marmoreio de forma automática, rápida e objetiva podendo ser aplicada em diversos tipos de músculo animal e padrão de marmoreio. A acurácia do modelo de Visão Computacional para carne bovina foi de 81,59% e para carne suína foi de 76,14%. Paralelamente, foram testados alguns algoritmos de Aprendizado de Máquina para a predição do tempo de armazenamento da carne suína. Verificou-se a melhor performance dos algoritmos Random Forest, *k*-NN e aqueles baseados em Lógica Fuzzy em prever o tempo de armazenamento da carne suína em 0, 7 e 14 dias de forma rápida utilizando técnicas tradicionais como a capacidade de retenção de água, o pH e a cor sem a necessidade de análises mais complexas e demoradas como a avaliação da oxidação pela metodologia TBARS (Substâncias Reativas ao Ácido 2-Tiobarbitúrico). Pode-se concluir que a aplicação da Inteligência Computacional por meio das técnicas de Visão Computacional e algoritmos de Aprendizado de Máquina foram eficientes para a avaliação da qualidade da carne, podendo ser uma ferramenta útil para automatizar as tarefas relacionadas à análise de qualidade na Indústria.

**Palavras-chave:** Aprendizado de Máquina. Bovino. Qualidade. Suíno. Visão Computacional.

BARBON, Ana Paula Ayub da Costa. **Meat marbling evaluation and storage time prediction by Computational Intelligence**. 2018. 76 p. Thesis (Doctor's Degree in Animal Science) – Universidade Estadual de Londrina, Londrina, 2018.

### ABSTRACT

Computational Intelligence consists of a set of computational methodologies to aid in the understanding of 'real world' phenomena in diverse areas. In Food Science has been applied as a promising alternative to address problems of subjectivity, time and cost of analysis, using approaches based on the simulation of human knowledge through artificial intelligence. In general, computational techniques contribute to the supply of quality products, being applied with greater precision, fastness and without deterioration of the samples when compared to the traditional methods analysis. In the last decade, Computational Vision has been one of the most exploited techniques for meat quality. It is based on Image Processing and Machine Learning. In this work, the Computational Vision was successfully used with the *k*-NN (*k*-Nearest Neighbors) approach for the evaluation of marbling as an automatic, fast and objective way, and it can be applied in various muscle foods and marbling patterns. The accuracy of the Computational Vision model for beef was 81.59% and for pork was 76.14%. At the same time, some Machine Learning algorithms were tested for the prediction of pork storage time. The best performance of the Random Forest, *k*-NN and Fuzzy Logic algorithms for predicting the storage time of pork at 0, 7 and 14 days using traditional techniques such as water retention capacity, pH and color without the need for more complex and time-consuming analyzes such as the oxidation evaluation by TBARS (2-Thiobarbituric Acid Reactive Substances) methodology. It can be concluded that the application of Computational Intelligence through Computer Vision techniques and Machine Learning algorithms were efficient for evaluating the meat quality and could be a useful tool to automate the tasks related to quality analysis in the Industry.

**Keywords:** Beef. Computer Vision. Machine Learning. Pork.

## LISTA DE ILUSTRAÇÕES

<b>Figura 1:</b> Exemplo de padrão fotográfico para avaliação do marmoreio bovino (baseado no modelo americano.....	19
<b>Figura 2:</b> Exemplo de padrão fotográfico para avaliação do marmoreio na carne suína .....	19
<b>Figura 3:</b> Relação entre as áreas da computação .....	28
<b>Figura 4:</b> Representação entre os modelos neurais biológico e artificial .....	30
<b>Figura 5:</b> Exemplo geral de uma estrutura de Árvore de Decisão.....	33
<b>Figura 6:</b> Representação bidimensional de retas lineares (a) e do hiperplano (b) do algoritmo SVM. ....	34

## LISTA DE TABELAS

<b>Tabela 1:</b> Trabalhos envolvendo a aplicação de algoritmos de aprendizado de máquina na cadeia da carne desde o ano 2000. ....	39
<b>Tabela 2:</b> Trabalhos envolvendo o uso de imagens para avaliar a qualidade dos produtos na cadeia de carne e derivados desde 2008.....	46

## LISTA DE ABREVIATURAS E SIGLAS

AM	Aprendizado de Máquina
CRA	Capacidade de Retenção de Água
DFD	<i>Dark, Firm and Dry</i> (Escuro, Firme e seco)
DT	<i>Decision Tree</i> (Árvore de Decisão)
<sup>1</sup> H-NMR	Espectroscopia de protons por Ressonância Magnética
<i>k</i> -NN	<i>k-Nearest Neighbors</i> ( <i>k</i> -vizinhos próximos)
NPPC	<i>National Pork Producers Council</i>
MLP	<i>Multilayer Perceptron</i>
PCA	<i>Principal Component Analysis</i> (Análise de Componentes Principais)
PSE	<i>Pale, Soft and Exudative</i> (Pálido, mole e exsudativo)
NIR	<i>Near Infrared</i> (Espectroscopia de Infravermelho Próximo)
RGB	<i>Red, Green and Blue</i> (Vermelho, verde e azul)
RNA	Redes Neurais Artificiais
SVM	<i>Support Vector Machine</i> (Máquina de Vetor de Suporte)
SVR	<i>Support Vector Regression</i>
TBARS	Substâncias Reativas ao Ácido 2-Tiobarbitúrico
USG	Ultrassonografia
VC	Visão Computacional

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	14
<b>2</b>	<b>REVISÃO DE LITERATURA</b> .....	16
2.1	AVALIAÇÃO DA QUALIDADE DA CARNE .....	16
2.1.1	Marmoreio.....	17
2.1.2	Potencial Hidrogeniônico.....	20
2.1.2	Cor.....	22
2.1.4	Capacidade de Retenção de Água.....	25
2.1.5	Oxidação Lipídica .....	26
2.2	INTELIGÊNCIA COMPUTACIONAL .....	28
2.2.1	Aprendizado de Máquina .....	29
2.2.1.1	Redes Neurais Artificiais .....	30
2.2.1.2	Árvore de Decisão .....	32
2.2.1.3	Máquina de Vetor de Suporte .....	34
2.2.1.4	<i>Naive Bayes</i> .....	35
2.2.1.5	<i>K-Vizinhos Próximos</i> .....	36
2.2.1.6	Lógica Nebulosa .....	37
2.2.1.7	Aplicação de algoritmos de aprendizado de máquina na cadeia de carne .....	38
2.3	VISÃO COMPUTACIONAL.....	40
2.3.1	Aquisição de Imagens .....	41
2.3.2	Pré-Processamento de Imagens.....	42
2.3.3	Segmentação de Imagens .....	43
2.3.4	Extração de Características .....	43
2.3.5	Reconhecimento de Padrões .....	44
2.3.6	Decisão.....	44
2.3.7	Uso de imagens para avaliação da qualidade na cadeia de carne .....	45
	<b>REFERÊNCIAS</b> .....	47
<b>3</b>	<b>OBJETIVOS</b> .....	55
3.1	OBJETIVO GERAL .....	55
3.2	OBJETIVOS ESPECÍFICOS .....	55

<b>4</b>	<b>ARTIGO A – STORAGE TIME PREDICTION OF PORK BY COMPUTATIONAL INTELLIGENCE .....</b>	<b>56</b>
<b>5</b>	<b>ARTIGO B – DEVELOPMENT OF A FLEXIBLE COMPUTER VISION SYSTEM FOR MARBLING CLASSIFICATION.....</b>	<b>66</b>
<b>6</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>76</b>

## 1 INTRODUÇÃO

O Brasil desempenha um importante papel no processo global de produção de alimentos, resultando em grandes volumes de exportação de carne bovina, suína e de frango (ABIEC, 2017). No entanto, a investigação sobre melhores padrões e avaliações de qualidade de carne é essencial para manter esse *status* perante o mercado internacional.

Sabe-se que o controle de qualidade na indústria de alimentos é de extrema importância em todas as fases produtivas, desde o recebimento da matéria-prima até o seu armazenamento e é um requisito substancial para a aceitabilidade do consumidor (TRINDERUP et al., 2015).

As avaliações de qualidade da carne compreendem vários processos que se baseiam em tecnologias robustas que requerem equipamentos sofisticados, complexos e dispendiosos. Em geral, requerem muito tempo para avaliação, necessitam de profissionais qualificados e produtos químicos que degradam as amostras (TAO; PENG, 2014).

O marmoreio (gordura intramuscular visível) e a coloração da carne estão entre os principais atributos da carne que impactam no momento inicial da escolha pelo consumidor, uma vez que o marmoreio influencia no sabor, textura e maciez da carne e a cor por sua vez, traduz o estado geral de conservação do produto correlacionado ao seu tempo de armazenamento (KILLINGER et al., 2004).

As metodologias para a avaliação da qualidade da carne são dependentes da subjetividade profissional, tediosa, custosa e em alguns casos, como a avaliação da oxidação lipídica pela metodologia TBARS (Substâncias Reativas ao Ácido 2-Tiobarbitúrico), são difíceis de serem aplicadas em larga escala devido a complexidade da análise. A indústria necessita de métodos adequados e precisos para avaliar a qualidade e em contrapartida, as autoridades de fiscalização precisam de métodos confiáveis e menos subjetivos para o controle da qualidade do produto. Isto tem motivado o desenvolvimento de métodos alternativos utilizando soluções automáticas e computacionais, como o uso de Inteligência Computacional (CHEN et al., 2010; WU e SUN, 2013a; XIONG et al., 2014).

Nos últimos anos, vários estudos têm abordado a possibilidade da avaliação da qualidade da carne com base em técnicas de Visão Computacional e também abordagens de Aprendizado de Máquina (CHEN e QUIN, 2008; JACKMAN et al., 2009; SHARIFZADEH et al., 2014; LIU et al., 2014).

A Visão Computacional (VC) é uma alternativa promissora para resolver os problemas relacionados a subjetividade, tempo de análise e deterioração da amostra usando

abordagens baseadas na simulação da percepção humana (BROSNAN & SUN, 2002; JACKMAN et al., 2010). Essa abordagem assegura a oferta de produtos de qualidade, sendo aplicada com maior precisão e velocidade em comparação com os métodos de análise tradicionais (LIU et al., 2014).

Para complementar as técnicas de VC, em geral se utiliza métodos de Aprendizado de Máquina (AM) com o intuito de simular o conhecimento humano a partir das informações extraídas da VC. Dessa forma, as técnicas de AM podem ser empregadas para aprender relações significativas ou não-triviais por meio de um conjunto de dados obtidos pela VC e generalizar o problema para conseguir interpretar novos dados ainda não vistos, quando inseridos no sistema (DU; SUN, 2006).

O AM está inserido na área da Inteligência Computacional, uma das recentes áreas da Ciência da Computação. Ela engloba também técnicas como Redes Neurais Artificiais, Lógica Fuzzy e Algoritmos Genéticos. De uma forma geral, o uso da Inteligência Computacional acompanha a evolução da Computação, uma vez que hoje existe uma infinidade de dispositivos e máquinas capazes de armazenar e processar um grande volume de dados, como as imagens (GOLDSCHMIDT, 2010).

Diante deste cenário, a área da Ciência Animal e dos Alimentos vêm usufruindo da utilização destas técnicas como uma forma de minimizar a falta de precisão, o tempo gasto e o alto custo de algumas análises para a avaliação da qualidade dos alimentos e principalmente com o objetivo de implantar soluções de tempo real na indústria (PENA et al., 2013; AGHBASHLO et al., 2014; HONG et al., 2014; LIU et al., 2014; CHENG et al., 2015; MUÑOZ et al., 2015; BENALIA et al., 2016; CHMIEL e SLOWINSKI, 2016; OLIVEIRA et al., 2016; CRUZ-FERNÁNDEZ et.al, 2017).

Neste trabalho, a abordagem da utilização da Inteligência Computacional teve como objetivo a classificação dos índices de marmoreio da carne, independente do músculo animal utilizado, e a predição do tempo de estocagem da carne suína por meio de algoritmos de aprendizado de máquina.

## 2 REVISÃO DE LITERATURA

### 2.1 AVALIAÇÃO DA QUALIDADE DA CARNE

O padrão de qualidade de um produto depende diretamente das exigências dos seus consumidores, do país importador e de seus padrões de normatização e, dessa forma, constitui a chave para o sucesso em um mercado altamente competitivo.

Considerando os consumidores da carne, a indústria deve possuir análises e informações consistentes de normalização e certificação, pois estes são extremamente seletivos, preocupados com a saúde e com o animal; e classificam os ingredientes-chave do sistema de controle de qualidade em segurança do alimento, bem-estar animal e qualidades sensoriais da carne (WOOD et al., 1998).

O termo “Qualidade” envolve diversos processos que se iniciam desde a criação dos animais até o momento do preparo para o consumo do alimento *in natura*. Segundo Nardone e Valfrè (1999) após a década de 90, o termo “Qualidade Total” na indústria de alimentos ganhou espaço e engloba alguns conceitos como:

- ✓ Qualidade higiênica: ausência de perigos físicos, químicos e biológicos;
- ✓ Qualidade composicional: água, proteína, gordura, etc;
- ✓ Qualidade nutricional: composição das proteínas e lipídeos, ausência de alergênicos, etc;
- ✓ Qualidade sensorial: cor, sabor, suculência, maciez, etc;
- ✓ Qualidade tecnológica: parâmetros derivados do processamento, armazenamento e distribuição.

Além desses conceitos, a qualidade da carne também pode ser avaliada por aspectos éticos relacionados ao bem-estar animal e aspectos de preservação do meio-ambiente relacionados a sustentabilidade na produção da carne (VELARDE et al., 2015).

Dentre os atributos de qualidade, cor e marmoreio são facilmente visíveis pelos consumidores e, dessa forma, constituem os primeiros parâmetros de escolha no momento da compra. Contudo, outros atributos não avaliados diretamente pelos consumidores como pH, capacidade de retenção de água, maciez e grau de oxidação também podem ser mensurados para se determinar a qualidade da carne (KILLINGER et al., 2004).

A transformação do músculo em carne é um processo que envolve alterações bioquímicas e estruturais importantes na qualidade final. Há um esgotamento do glicogênio muscular, que leva a um acúmulo de ácido lático e, conseqüentemente, a uma queda no pH, que irá determinar o *rigor mortis*. Por fim, essas alterações podem influenciar os parâmetros

da qualidade da carne como o pH, cor, capacidade de retenção de água, maciez, odor e sabor (FELÍCIO, 1997).

A avaliação tradicional desses parâmetros de qualidade da carne, em geral, é realizada por meio de equipamentos e mão-de-obra especializada. São avaliações que demandam tempo, conhecimento e reagentes; além de em grande parte, destruir as amostras e ser um potencial poluidor do meio-ambiente. Dessa forma, buscam-se alternativas de avaliação que possam minimizar esses problemas, e dentre as alternativas, existem aquelas que utilizam processos computacionais (SHARIFZADEH et al., 2014; LIU et al., 2014).

### 2.1.1 Marmoreio

A marmorização é um termo utilizado na Indústria da Carne para se referir a quantidade de gordura intramuscular visível presente entre os feixes das fibras musculares, após o corte transversal (SADKOWSKI et al., 2014).

A formação inicial de gordura intramuscular parece ser impulsionada pelo desenvolvimento de adipócitos em combinação com o declínio do crescimento muscular. Tem sido demonstrado que o marmoreio está negativamente correlacionado com o teor de proteínas no músculo. Além disso, o desenvolvimento de tecidos adiposos no músculo com alto nível de marmoreio aparece para desorganizar a estrutura do tecido conjuntivo intramuscular durante o crescimento. Isso sugere que pode haver uma interação entre o desenvolvimento de gordura e a estrutura do colágeno no músculo, contribuindo para a maciez da carne (LEE et al., 2010).

Sabe-se que o tecido adiposo correspondente à gordura intramuscular é a última a ser depositada e a primeira a ser utilizada pelo animal na falta de reservas energéticas; e um nível mínimo de 2-2,5% presente entre as fibras é necessário para uma desejável qualidade no momento da ingestão (ŠPEHAR; VINCEK; ŽGUR, 2008).

Quimicamente, a gordura intramuscular abrange a soma de fosfolipídios (encontrado principalmente na membrana celular), triglicerídeos e colesterol. Entre as raças dos animais existem diferenças não somente entre as quantidades de gordura, mas também entre a estrutura e distribuição da marmorização nos músculos (HOCQUETTE et al., 2010).


A gordura intramuscular possui uma forte correlação com a força de cisalhamento e interfere na suculência, sabor e aroma da carne, tornando-se um dos mais importantes parâmetros sensoriais perceptíveis pelo consumidor. Também confere valor nutritivo, como fonte de energia, de ácidos graxos essenciais e de vitaminas lipossolúveis (PRZYBYLAK et al., 2016).

Essa característica sensorial da gordura também foi relatada por Špehar, Vincek e Žgur (2008), sendo por esse motivo a análise principal utilizada pela indústria dos Estados Unidos para prever a qualidade da carne. Nos Estados Unidos, a classificação da qualidade e tipificação de carcaças são derivadas do grau de marmoreio e maturidade da carcaça sendo essa classificação a forma de remuneração dos produtores. Nesse mesmo trabalho, o autor descreve que apesar da influência indireta do marmoreio sobre a maciez, esta contribui para a qualidade final da carne quando associada a gordura geral da carcaça.

A quantidade de gordura intramuscular pode ser quantificada de diversas formas: pela extração Soxhlet (Extrato Etéreo), tomografia computadorizada, <sup>1</sup>H-NMR ou pela espectroscopia de infravermelho (FAUCITANO et al., 2005).

Já a atribuição de uma nota de marmoreio é tradicionalmente realizada utilizando um padrão fotográfico conhecido (Figuras 1 e 2), na qual possui baixa precisão por ser uma análise subjetiva, além de ser específico para cada tipo de animal avaliado (suíno, bovino ou ovino) ou genética. Por exemplo, para bovinos, há padrão fotográfico para atribuição da nota de marmoreio conforme a origem do animal: australiano, japonês (Wagyu), americano, etc.

**Figura 1:** Exemplo de padrão fotográfico para avaliação do marmoreio bovino (baseado no modelo americano).



Fonte: AMSA, 2001.

Para suínos, em geral, se utiliza a metodologia descrita pela NPPC (AMSA, 2001), onde são atribuídas notas de 1 a 10 (1 = traços de marmoreio e 10 = marmoreio abundante).

**Figura 2:** Exemplo de padrão fotográfico para avaliação de marmoreio na carne suína



Fonte: AMSA, 2001.

Outra forma conhecida de avaliação do marmoreio é por meio da ultrassonografia (USG) com o animal ainda vivo (FAUCITANO et al., 2005). A tecnologia por USG permite a obtenção de imagens digitais e conseqüentemente, informações gráficas para identificar o grau de marmoreio. Contudo, é comum que a qualidade e presença de ruído nas imagens geradas levem a uma maior dificuldade de interpretação dos dados, sendo necessário um trabalho especializado. Somado a isso, a avaliação dos especialistas possui um pequeno nível de repetição dos resultados pela falta de imparcialidade na avaliação, consumindo muito tempo e elevando o custo (PRZYBYLAK et al., 2016).

Jackman e Sun (2012) consideram que as metodologias tradicionais de avaliação da qualidade da carne são demoradas, causam danos ao produto e possuem alto custo. A avaliação visual gera inconsistências na padronização da qualidade da carne em diferentes empresas, aumenta os custos do trabalho, tem baixa repetibilidade e é facilmente influenciada por fatores ambientais e humanos sendo necessária a busca por alternativas de avaliação (MUÑOZ et al., 2015).

O sistema de Visão Computacional vem sendo cada vez mais utilizado na indústria de alimentos como uma ferramenta alternativa de avaliação da qualidade por ser um processo rápido, com baixo custo, não destrutivo e preciso. Avaliações tradicionais como cor, marmoreio, textura e morfologia são passíveis de classificação por VC. Em muitos casos, os parâmetros a serem julgados, não necessitam de técnicas robustas de captação de imagens, evitando os custos de hardware excessivos (JACKMAN e SUN, 2012).

Para a análise de marmoreio, a VC aplica processos de segmentação pelo isolamento das camadas musculares e adiposas. Estudos prévios, tais como realizado por Pang et al. (2014), tiveram como objetivo facilitar a segmentação do marmoreio com altos níveis de gordura, mas eles não testaram níveis baixos de marmoreio que são frequentemente encontrados no mercado brasileiro.

### 2.1.2 Potencial Hidrogeniônico

O Potencial Hidrogeniônico (pH) está entre os principais parâmetros de avaliação da qualidade da carne, e a sua combinação com a temperatura no período *post mortem* influencia a qualidade final, uma vez que ele está ligado a capacidade de retenção de água, cor e maciez (HAMOEN et al., 2013).

Hamoen et al. (2013) descreveram ainda em seu trabalho que a capacidade de retenção de água aumenta conforme o pH diminui, isto em um intervalo de pH final de 5,2 a 5,7; demonstrando a dependência linear inversa entre esses dois parâmetros de qualidade.

Em condições normais, o pH do músculo vivo está próximo a 7,0 e seu decréscimo ocorre logo após o abate onde o glicogênio muscular é consumido e há um aumento do ácido láctico durante o processo de glicólise. A variação na taxa e velocidade desse consumo é responsável por diferentes características da carne e influencia diretamente no seu frescor (NACHE et al., 2016).

Logo após o *post mortem*, o nível de ATP é mantido pela conversão de ADP em ATP com a utilização de fosfocreatina ( $ADP + \text{fosfocreatina} \Leftrightarrow ATP + \text{creatina}$ ). Quando a fosfocreatina se esgota, há a diminuição de ATP, rico em energia. Assim, os prótons que são produzidos durante a glicólise e durante a hidrólise do ATP causam a diminuição do pH intracelular (ALVES et al., 2005).

O pH 24 horas, em suínos, se aproxima de 5,3 a 5,7 e, em bovinos esse valor cai mais lentamente chegando a 5,5 - 5,9 após 24 horas do abate. Quando o pH atinge níveis abaixo de 5,8 em 45 minutos após o abate, é possível observar a presença do defeito PSE (*Pale, Soft, Exudative*) na carne. Em geral, essa rápida velocidade no processo da glicólise é observada em suínos susceptíveis ao estresse ou que tenham sido expostos ao estresse antes do abate. Contudo, quando há deficiência do glicogênio antes mesmo de ocorrer o abate, o pH da carne após 24 horas ainda está alto, acima de 6,0, o que resulta na presença do defeito DFD (*Dark, Firm, Dry*). Essa condição ocorre tanto em bovinos quanto em suínos que possivelmente apresentavam exaustão física decorrente do mau manejo antes do abate, esgotando suas reservas de glicogênio (ROÇA, 2001).

A forma mais conhecida de mensuração do pH da carne é pela introdução de um potenciômetro com sonda de penetração, apesar de Nache et al. (2016) descreverem inúmeras desvantagens desta metodologia como: invasiva, lenta, que promove perigo de contaminação cruzada, exige calibração constante, está propensa a erros e normalmente só é utilizada pela Indústria em cortes de alta qualidade. Os autores propuseram a utilização da Espectroscopia Raman como uma nova metodologia de mensuração do pH. Trata-se de uma técnica fotônica de alta resolução que identifica informações químicas e estruturais.

### 2.1.3 Cor

De uma forma geral, a cor corresponde a uma resposta perceptiva mental a um espectro de luz visível refletida ou emitida a partir de um objeto. No olho, este sinal de resposta interage com a retina e passa a ser transmitido para o cérebro por meio do nervo óptico, o que faz o ser humano atribuir cores a este sinal. Assim, pode-se concluir que a cor não é um atributo intrínseco do objeto, ela varia de acordo com a alteração da fonte de luz (WU; SUN, 2013a).

A cor corresponde a um dos atributos de qualidade da carne que mais influenciam no momento da escolha pelo consumidor, que associa a cor com o frescor e, para isso, considera que tanto a carne bovina quanto a suína devem apresentar uma coloração avermelhada homogênea (CHEN et al., 2010).

Contudo, a cor final percebida pelo consumidor não é um processo trivial e pode ser influenciada por diversos fatores: espécie, genética, mudanças no músculo durante o processo de *post mortem* (principalmente pH e queda na temperatura), condições de armazenamento, crescimento microbiano, dentre outros. A iluminação do ambiente, características do olho e cérebro e, por sua vez, dos ângulos de iluminação e visualização também exercem efeito na percepção da cor (HUNT et al., 2012).

A mioglobina é uma proteína solúvel em água, responsável pela cor primária da carne. A sua concentração na carne e seu estado de oxigenação ou oxidação irá ditar essa cor. Ela possui quatro formas químicas, representadas por: desoximioglobina, oximioglobina, carboximioglobina e metamioglobina.

A desoximioglobina resulta em uma cor vermelho-púrpura presente no interior da carne fresca (logo após o abate). Se esta carne fica exposta por 30-40 minutos ocorrerá a oxigenação da mioglobina (oximioglobina) e a carne tende a ficar com coloração vermelho brilhante, atrativa ao consumidor. Para manter esta cor vermelho brilhante, pode-se adicionar monóxido de carbono a uma atmosfera controlada formando o pigmento carboximioglobina. Já a metamioglobina é formada a baixa pressão de oxigênio, o que resulta em uma cor marrom, indesejável ao consumidor que associa esta cor a um longo período de estocagem da carne (VENTURINI et al., 2009).

A mensuração da cor da carne pode ser realizada de forma subjetiva pela inspeção visual utilizando padrões fotográficos. Contudo, esta forma de avaliação não é a desejável devido a sua grande variação. Dessa forma, avaliações por meio de equipamentos de mensuração de cor como colorímetros e espectrofotômetros constituem a forma mais tradicional de avaliação. E nos últimos anos, alguns autores têm sugerido a utilização de VC

para a mensuração da cor (WU; SUN, 2013a; BARBIN et al., 2016; CHMIEL; SLOWINSKI, 2016; SUN et al., 2016).

O colorímetro mede os valores *tristimulus* ( $L^*a^*b^*$ ) no espaço de cor conhecido como CIELab. De uma forma geral, este aparelho mede as coordenadas de cor da carne e as expressam em valores numéricos, sendo  $L^*$  correspondente a Luminosidade (branco-preto),  $a^*$  corresponde a coordenada vermelho (positivo) - verde (negativo) e  $b^*$  a coordenada amarelo (positivo) - azul (negativo). Por sua vez, o espectrofotômetro é um equipamento mais sofisticado que fornece uma análise espectral no intervalo de 1-10 nm calculando matematicamente os valores *tristimulus* (HUNT et al., 2012).

O colorímetro frequentemente avalia um único "ponto" (com uma superfície de cerca de 10-30 mm<sup>2</sup>), sendo, portanto, incapaz de medir a cor da superfície total da amostra em uma única medição (KANG, 2008).

O alargamento da área onde a cor é medida pode fornecer uma ampla gama de valores, reduzindo assim o erro na determinação da cor. Por outro lado, o alargamento da área de medição com o colorímetro, possivelmente, inclui tecido adiposo e conjuntivo, obtendo-se medidas não confiáveis (GIROLAMI et al., 2013). Assim, este método requer um conjunto substancial de medições para fornecer um valor confiável para a caracterização da qualidade da carne, e, por conseguinte, não é aplicável ao setor industrial de carne altamente crescente.

Dessa forma, recentes trabalhos propuseram uma alternativa ao colorímetro por meio do uso de imagens. A vantagem da avaliação da cor por imagem é a possibilidade de englobar toda superfície da amostra, diferente do colorímetro que só avalia uma superfície de 10-30 mm<sup>2</sup>. Outras restrições ao colorímetro também foram citadas por Barbin et al. (2016). Por exemplo, quando se utiliza o colorímetro são necessárias, no mínimo, três medições para englobar o máximo da superfície da amostra, sendo que se essa medição for realizada por uma pessoa não treinada pode ocorrer a mensuração no mesmo local da amostra ou até mesmo mensurar algum outro ponto que não representa de forma coesa a amostra, como uma faixa de gordura.

Outros trabalhos também citaram a importância da mensuração da cor por meio de imagens, tornando-se uma metodologia mais precisa por englobar toda a superfície da amostra e passível de implantação em uma indústria (WU; SUN, 2013a; CHMIEL; SLOWINSKI, 2016; SUN et al., 2016; TARLAK, OZDEMIR; MELIKOGLU, 2016).

Em plantas de processamento de carne, os alimentos são produzidos em alta velocidade e, ao mesmo tempo, com pequena tolerância a determinados ingredientes que se

distanciam dos protocolos tradicionais de avaliação humana durante a inspeção, tornando a VC uma técnica de grande interesse do setor. Dessa forma, Valous et al. (2009) utilizaram imagens digitais para investigar a qualidade relacionada a cor e atributos de composição de fatias de presunto.

Girolami et al. (2014) utilizaram a VC para avaliar a aparência de salames italianos (coloração e relação de gordura visível) produzidos com matérias-primas de diferentes origens com o intuito de verificar a padronização dos produtos.

Ainda utilizando imagens para avaliar a qualidade de embutidos, Ulrici et al. (2012) avaliaram um defeito conhecido como “pele vermelha” presentes no presunto cru utilizando como parâmetro informações relacionadas a cor de imagens RGB codificada por meio de sinais unidimensionais conhecidos como *colourgrams*, transformando a classificação em um processo automático.

Rodríguez-Pulido et al. (2013) propôs um novo método para estimar a relação entre cor, aparência e composição química de diferentes grupos alimentares, simulando o olho humano por meio da avaliação das imagens.

Outra alternativa utilizando técnicas de avaliação por imagens é a detecção de defeitos na carne como PSE e DFD. Como destacado no item 2.1.2 a carne PSE está associada a um estresse intenso próximo ao abate que proporcionam a decomposição acelerada do glicogênio e uma rápida queda do pH enquanto o músculo ainda apresenta temperaturas próximas ao estado fisiológico do animal, resultando em uma desnaturação protéica e em uma carne pálida, mole e exsudativa. Já a carne DFD está associada a um estresse mais prolongado onde há o consumo das reservas de glicogênio resultando em uma lentidão da glicólise e permanência de um pH alto mesmo após horas de abate, levando a maior retenção de água no interior das células resultando em uma carne firme com coloração escura (MAGANHINI et al., 2007).

Chmiel, Slowinski & Dasiewicz (2011a) utilizaram imagens do músculo *longissimus dorsi* suíno e extraiu informações da cor como a Luminosidade ( $L^*$ ) e associaram a outros parâmetros de qualidade para determinar carne PSE. Anos após, Chmiel e Słowiński (2016) propuseram a utilização de VC para avaliar outro defeito da carne suína conhecido como DFD (*Dark, Firm, Dry*).

Vale ressaltar que a cor mensurada pelo sistema de VC, pelo colorímetro e espectrofotômetro estão no espectro eletromagnético visível, ou seja, dentro da capacidade de visão dos olhos humanos. Contudo, já existem equipamentos hiperespectrais que são mais

complexos e mensuram a cor em espectro não visível sendo possível extrair maiores informações da imagem (KAMRUZZAMAN et al., 2016b).

#### 2.1.4 Capacidade De Retenção de Água

A capacidade de retenção de água (CRA) é definida como a capacidade da carne fresca em reter líquido durante seu processamento, armazenamento e cozimento. Em geral, ela pode influenciar o aspecto da carne antes do seu cozimento, no momento do cozimento e a suculência durante a mastigação, sendo portanto, um atributo importante para a descrição da qualidade da carne e principalmente para seus derivados como os embutidos (LAWRIE; LEDWARD, 2006).

A CRA sempre foi um parâmetro de interesse na Ciência da Carne, uma vez que a água é um dos mais importantes constituintes naturais ou adicionais aos alimentos. Contudo, a estrutura da carne é complexa. O sistema das miofibrilas realiza movimentos específicos muito rápidos e repetitivos e a água, por sua vez, deve acompanhar esse fluxo lubrificando a fibra muscular e auxiliando no transporte de metabólitos dentro da fibra. Dessa forma, não se deve esperar que as proteínas miofibrilares siga apenas um modelo de retenção de água, pontuando este parâmetro como um dos mais estudados na Ciência da Carne (PUOLANNE; HALONEN, 2010).

Existem algumas metodologias para a mensuração da CRA, sendo as mais adotadas: por pressão utilizando um filtro de papel, a metodologia gravitacional ou perda de água por gotejamento (*drip loss*) e a perda de água durante a cocção (PREVOLNIK et al., 2010).

A perda de água por pressão é realizada utilizando-se 2 g da amostra disposta entre dois papéis de filtro e prensada entre duas placas de acrílico, com auxílio de um peso de 10kg durante cinco minutos. Após a prensagem, a amostra é pesada e calcula-se a perda de água da amostra (BARBUT, 1996).

Na avaliação de perda de água por gotejamento as amostras devem ser pesadas e suspensas em um gancho de arame galvanizado em forma de “S” para que uma extremidade sustente a carne e a outra fique presa nas grades do refrigerador. As amostras devem ser colocadas dentro de sacos de polietileno que, por sua vez, devem ser colocados dentro de outro saco, formando paredes duplas para evitar a desidratação das amostras. Essas amostras devem permanecer por 48 horas sob refrigeração a 4 °C e após, serem pesadas novamente (BOCCARD et al., 1981).

Por fim, a avaliação da perda de água por cocção consiste em pesar a amostra descongelada e em seguida cozê-la em forno elétrico, por exemplo, e pesá-la novamente. A diferença entre os pesos indica a perda durante o processo de cozimento (BRIDI; SILVA, 2009).

Atualmente, alguns autores propuseram uma nova ferramenta para a avaliação da CRA utilizando imagens hiperespectrais como uma alternativa não destrutiva da amostra selecionando conjuntos de comprimentos de onda mais representativos e utilizando, por exemplo, modelos de regressão e Aprendizado de Máquina (ELMASRY et al., 2011; WU e SUN, 2013b; HE et al., 2014; KAMRUZZAMAN et al., 2016a).

### 2.1.5 Oxidação Lipídica

A oxidação lipídica corresponde a uma das mais importantes deteriorações relacionadas a carne, uma vez que gera produtos indesejáveis que podem restringir a vida útil e além disso, destruir vitaminas lipossolúveis e ácidos graxos essenciais (OSAWA et al., 2005).

Em geral, essa não é uma condição desejada pelos consumidores uma vez que a oxidação lipídica gera odores e sabores característicos de ranço (*off odors* e *off flavors*). E esse processo é decorrente da grande quantidade de triglicerídeos e fosfolipídeos derivados dos ácidos graxos insaturados e presentes na carne que sofrem oxidação após o abate (LIMA JÚNIOR et al., 2013).

Os mecanismos de oxidação lipídica geram radicais livres que reagem com o ácido graxo insaturado de cadeia hidrocarbonada formando um peróxido. Por sua vez, esse peróxido reage sobre outra cadeia hidrocarbonada originando um novo peróxido e assim sucessivamente (WHEATLEY, 2000).

Atualmente, várias alternativas têm sido propostas para minimizar esse efeito oxidante na carne e conseqüentemente aumentar a útil. Dentre elas estão a utilização de antioxidantes naturais frente aos antioxidantes químicos. Por exemplo, ervas e especiarias como orégano, sálvia e alecrim sendo administrados na maior parte em forma de óleos essenciais na dieta dos animais que possuem compostos como terpenos e derivados oxigenados (álcoois, aldeídos, cetonas, fenóis, éteres, etc.) com propriedades antioxidantes (SAMPAIO et al., 2012).

Outras tecnologias também vêm sendo aplicadas com o objetivo de reduzir a oxidação e com isso aumentar a vida útil da carne como a utilização de embalagens a vácuo e atmosfera modificada (LIMA JÚNIOR et al., 2013).

O teste de TBA (ácido 2-tiobarbitúrico) ou mais conhecido como TBARS (substâncias reativas ao ácido 2-tiobarbitúrico), atualmente tem sido o método de avaliação mais tradicional da oxidação lipídica na carne. O TBARS quantifica o malonaldeído que é formado durante o processo de oxidação, sendo um produto da decomposição de hidroperóxidos dos ácidos graxos poliinsaturados. O composto resultante desta reação possui coloração avermelhada quando medido no espectrofotômetro a 532 nm de comprimento de onda (OSAWA et al., 2005).

Contudo, esta metodologia possui algumas restrições como a dificuldade de execução necessitando de pessoal qualificado, tempo longo de análise, custo com reagentes, metodologia destrutiva e que utiliza solventes perigosos. Dessa forma, outras metodologias mais rápidas, menos destrutivas e com alta acurácia vem sendo investigada, como o uso de imagens hiperespectrais. Wu et al. (2016) propuseram o mapeamento do TBARS utilizando a tecnologia de imagens hiperespectrais para avaliar a possível oxidação durante os ciclos de congelamento-descongelamento de carne suína. Os autores concluíram que é possível utilizar a metodologia de hiperespectroscopia aliada ao processamento de imagem para monitorar a distribuição de TBARS na carne suína, podendo ser utilizada em tempo real na Indústria.


## 2.2 INTELIGÊNCIA COMPUTACIONAL

A Inteligência Computacional é uma ciência sucessora da Inteligência Artificial que integra elementos de aprendizagem, adaptação, evolução e sistemas de lógica que são capazes de aprender e tratar situações novas. O objetivo dessa ciência é desenvolver máquinas ou algoritmos que pensam como os seres humanos como as técnicas de Aprendizado de Máquina. Um algoritmo consiste em uma sequência de instruções implementadas em linguagem de programação com o objetivo de criar uma solução de software (MAULIK et al., 2011).

Para Goldschmidt (2010) a Inteligência Computacional é uma Ciência Multidisciplinar que busca desenvolver e aplicar técnicas computacionais que simulem o comportamento humano ou da natureza em tarefas específicas. Para Hassanien et al. (2013) trata-se de uma metodologia que envolve mecanismos adaptativos e que possuem habilidade de aprender com maior facilidade comportamentos inteligentes em ambientes complexos e que possuem grandes modificações.

A Figura 3 demonstra a aderência entre as áreas de Inteligência Computacional, Processamento de Imagem, VC e AM. Nota-se que a Inteligência Computacional é a grande área onde a VC está inserida e o AM faz a ligação entre essas duas áreas.

**Figura 3:** Relação entre as áreas da computação



Fonte: Do autor, 2018.

### 2.2.1 Aprendizado de Máquina (AM)

Segundo Ropodi et al. (2016) o Aprendizado de Máquina (*Machine Learning*) pode empregar uma variedade de tarefas computacionais que vão além da programação explícita utilizando a Inteligência Computacional. Além disso, está conectado a ferramentas matemáticas e estatísticas que fornecem uma parcela importante da teoria por trás dos modelos construídos. Com isso, se transforma em uma ferramenta para análise de dados exploratórios e tem sido a base de várias aplicações que envolvem a VC.

O AM tem por finalidade adquirir conhecimento de determinada característica por meio de exemplos fornecidos e posteriormente tomar decisões a partir deste aprendizado. Por isso, durante o período de construção dos modelos de aprendizado, a qualidade dos atributos fornecidos é essencial para a eficácia desta etapa e conseqüentemente, para a generalização do problema e do conhecimento de possíveis novos exemplos que serão adquiridos (GOLDSCHMIDT, 2010).

Quanto maior a capacidade de generalização do aprendizado no modelo construído, mais útil para a aplicação em situações reais. Dessa forma, os algoritmos de AM podem aprender basicamente de duas formas: supervisionada ou não supervisionada. A primeira consiste na construção de um modelo na qual são fornecidos exemplos com seus respectivos significados (“rótulos”) tanto para o aprendizado quanto para a validação. Já no modelo não supervisionado são fornecidos apenas os atributos (características) dos exemplos sem nenhum rótulo para o aprendizado, sendo que a validação ocorre por meio da similaridade. Essa última é utilizada principalmente com objetivo de encontrar padrões ou tendências que auxiliem no entendimento do problema (LORENA e CARVALHO, 2007).

Algumas aplicações de modelos supervisionados são: Classificação e Regressão. Um modelo de regressão tem como objetivo a obtenção de valores contínuos que tenham o menor erro preditivo possível. Já a classificação denota a indicação em classes dos diversos objetos obtidos. Para a Classificação é possível avaliar problemas binários (duas classes), Multi-classes, Multi-rótulo e Hierárquico, com o objetivo de prever um comportamento, padrão ou tipo para novas amostras desconhecidas. Já para modelos de Regressão é possível prever valores contínuos para uma dada amostra, tratando problemas rótulo único (*single-target*) e vários rótulos (*multi-target*). Para modelos não supervisionados, encontram-se aqueles relacionados ao agrupamento de dados como a clusterização com o método *K-means* (FACELI et al., 2011).


De acordo com Du e Sun (2006) as técnicas de Aprendizado são essenciais para a avaliação da qualidade dos alimentos de forma automática, principalmente quando se

utiliza a VC. São exemplos de técnicas de Aprendizado de Máquina: Redes Neurais Artificiais, Árvore de Decisão (*Decision Tree*), Máquina de Vetor de Suporte (*Support Vector Machine-SVM*), *Naïve Bayes*, *k-Nearest Neighbors (k-NN)* e a Lógica Fuzzy.

#### 2.2.1.1 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) foram desenvolvidas como modelos matemáticos baseados nos Sistemas Nervosos Biológicos constituídos pelo neurônio, unidade mais simples. Os neurônios artificiais simulam os processos que ocorrem nos neurônios naturais, uma vez que o cérebro humano pode aprender e tomar decisões baseadas na aprendizagem. Goldschmidt (2010) representou essa comparação conforme a Figura 4.

**Figura 4:** Representação entre os modelos neurais biológico e artificial



Fonte: Goldschmidt (2010).

Na Figura 4, as sinapses são representadas pela camada de entrada ligada diretamente aos pesos (atributos a serem aprendidos a cada exemplo); que por sua vez são computados pela propagação ( $\Sigma$ ). A quantidade de atributos e pesos correspondem a quantidade de dendritos. Os pesos ( $w_1, w_2$  e  $w_3$ ) estão ligados ao corpo somático que representa as funções realizadas na etapa de propagação e ativação, ou seja a indução do conhecimento. Por fim, a capacidade de aprendizado do neurônio artificial é possível pelo ajuste de pesos de acordo com o método de aprendizado escolhido (HASSANIEN et al., 2013).

Durante a fase de treinamento os pesos sinápticos ponderam cada um dos atributos de entrada, quantificando as suas relevâncias em relação à funcionalidade do respectivo neurônio. Após a fase de treinamento, com todos os pesos definidos, os atributos

de entrada a serem avaliados sofrem atuação dos pesos sinápticos e produzem um valor de potencial de ativação ( $f$ ). O resultado é uma função de ativação ( $f$ ) que produzirá o valor de saída conforme o aprendizado da rede (HUANG et al., 2007; SILVA et al., 2010).

As RNAs realizam funções simples, baseadas na coleta de informações destinadas às suas entradas e depois, agregá-los de acordo com sua função operacional produzindo uma resposta de saída (MITCHELL, 1997). Elas representam um conjunto de interdependências, e em teoria, podem incorporar qualquer grau de não-linearidade apresentado pelo problema. Para avaliação da qualidade dos alimentos, algumas funções gerais podem ser modeladas para transformar propriedades físicas em fatores de qualidade. Os diversos algoritmos de RNA podem ser aplicados em tarefas de inspeção de alimentos que envolvam cor, conteúdo, forma e textura com uma performance semelhante àquela realizada por humanos podendo ter sucesso no passo de decisão para resolução dos problemas (DU; SUN, 2006).

Um exemplo que poderia elucidar o uso de RNA aplicada em alimentos é a classificação entre uma amostra Normal (N) e DFD (*Dry, Firm, Dark*). Os valores de entrada fornecidos ao modelo de RNA seriam caracterizados pelos pH, cor e CRA. A saída da RNA seria a classificação em N ou DFD representado. Pode-se interpretar as entradas fornecidas à RNA como sendo os parâmetros que descrevem uma dada amostra. Assim, poderíamos utilizar várias amostras N e DFD caracterizadas pelos valores de pH, cor e CRA. A definição do tipo de saída pela RNA é dada pela combinação dos atributos de entrada e os pesos sinápticos ( $w$ ). Após o processo de treinamento (indução) seria possível utilizar os pesos sinápticos encontrados no processo de treinamento para calcular o valor de saída para uma nova amostra, desconhecida, e assim obter a sua classificação entre N ou DFD.

As arquiteturas das RNAs são escolhidas de acordo com a complexidade exigida para solucionar um dado problema. A RNA *Perceptron*, por exemplo, é utilizada para solucionar problemas simples como o caso anterior da classificação de novas amostras entre N e DFD.

No entanto, problemas mais complexos que exigem soluções não lineares tem como requisitos arquiteturas mais robustas como as *Perceptrons de Múltiplas Camadas (Multilayer Perceptron - MLP)*. Esta arquitetura utiliza o método de aprendizado de retro-propagação, adequada para problemas não triviais (KASHANINEJAD et al., 2009).

Uma outra característica importante no tocante as RNAs são as topologias possíveis. A topologia diz respeito a quantidade de neurônios envolvidos na resolução de um dado problema. Para alcançar mais precisão em um problema complexo deve-se ter como

requisito um número maior de neurônios e por ventura, camadas. Tal característica está contemplada na arquitetura MLP, sendo esta a arquitetura mais encontrada na solução dos problemas envolvendo carne (CHANDRARATNE et al., 2006, 2007; KODOGIANNIS et al., 2014; GOSUKONDA et al., 2015; BARBON et al., 2016).

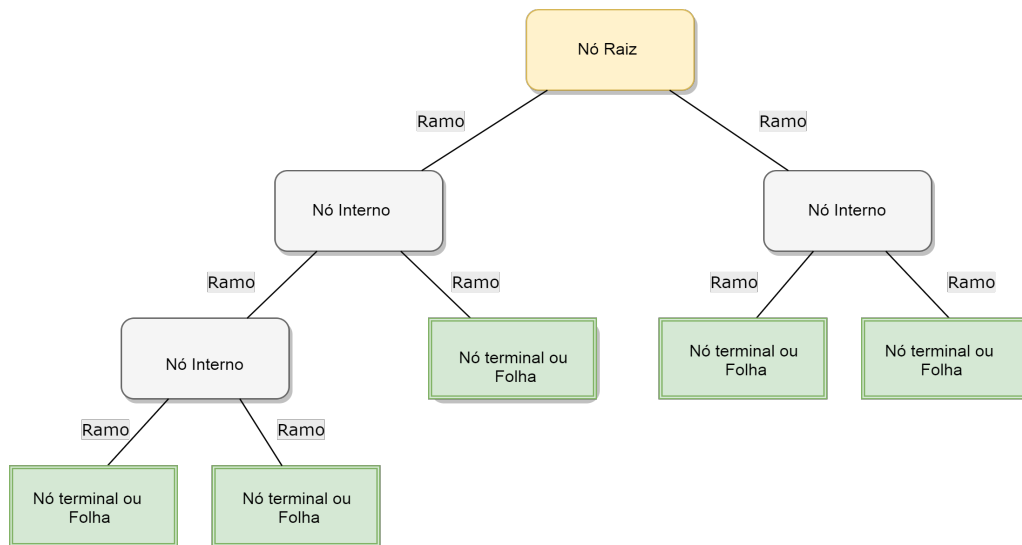
#### 2.2.1.2 Árvore de decisão

A *Decision Tree* (DT) conhecida como Árvore de Decisão (AD) é uma classe de algoritmos da família do AM supervisionado que utiliza informações associadas a correlação entre um atributo e o rótulo da amostra para a modelagem de uma árvore lógica. A idéia principal é decompor um problema complexo em sub-problemas, aplicando os mesmos critérios recursivamente nos subproblemas até que um critério de parada seja satisfeito (FACELI et al., 2011).

A estrutura da AD é construída com base no Nó Raiz composto pelo atributo principal do problema, que apresenta o maior ganho de informação para este problema, sendo que o ganho de informação é calculado por meio da entropia entre os atributos e rótulos. A entropia, por sua vez, é caracterizada pela im(pureza) dos dados, isto é, a entropia representa a falta de homogeneidade dos dados de entrada em relação a sua classificação. Em seguida, através dos Ramos (valores limiares) é possível determinar o Nó Interno caracterizado por atributos secundários. Por fim, o Nó Terminal ou Folha é caracterizado pela classe do problema (SONG et al., 2002).

O critério para determinar o ‘ponto’ de decomposição do problema é, por exemplo, os intervalos do atributo para a classificação. Um dos critérios para determinar este ponto é também o ganho de informação, ou seja, o maior ganho de informação representa o quanto um atributo pode contribuir para a decisão de determinado nó da árvore. A Figura 5 corresponde a representação de uma AD (FACELI et al., 2011).

**Figura 5:** Exemplo geral de uma estrutura de Árvore de Decisão.



**Fonte:** Do autor, 2017.

A *Random Forest* por sua vez é um conjunto (*ensemble*) de Árvores de Decisão independentes sendo que em cada árvore há um conjunto de treinamento, ou seja, ela pode ser entendida como uma técnica sofisticada baseada nas DTs. O número de atributos e de árvores que comporão a *Random Forest* é definido de acordo com o usuário (BREIMAN, 2001).

Soltani e Omid (2015) utilizaram algumas técnicas de Aprendizado de Máquina como Redes Neurais Artificiais, Máquina de Vetor de Suporte (*Support Vector Machine*), *Bayesian Network* e DT para prever o frescor de ovos de galinhas. O objetivo era prever a classe de frescor desses ovos de forma não destrutiva. Dentre os algoritmos de DT utilizados (LMT, J48 e *REPtrree*), o LMT obteve melhor precisão (87,5%) quando comparado aos outros algoritmos.

Um outro exemplo do uso de DT aplicado a qualidade de alimentos foi apresentado no trabalho de Coelho et al. (2016) no qual o objetivo foi classificar automaticamente o parasita *Edotea magellanica* que infecta um marisco muito consumido no Chile e desta forma deve ser extraído para manter a qualidade do alimento. Atualmente, essa extração é feita subjetivamente pelo reconhecimento humano e o objetivo do trabalho foi automatizar essa operação. O protótipo apresentado utilizou um Sistema de Visão de Máquina aliado a um algoritmo de DT e obteve 98% de precisão.

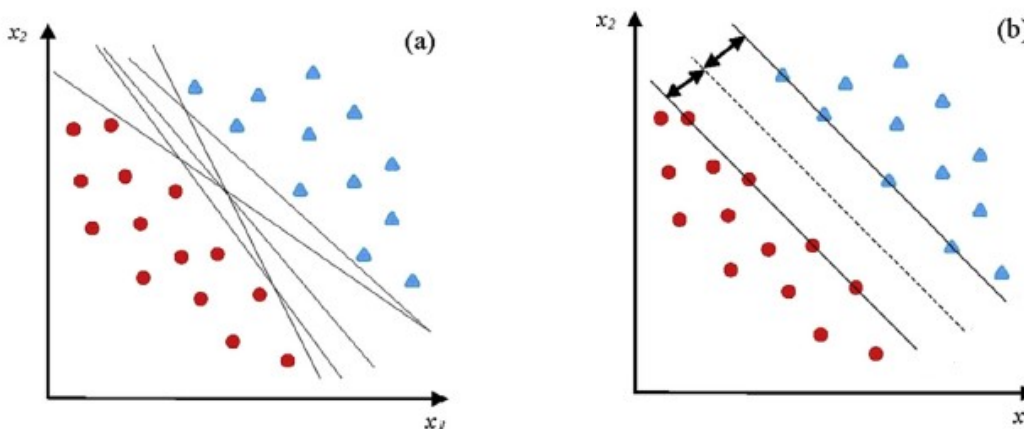
Um estudo de caso sobre a importância da intensidade da coloração verde em salada de rúcula foi apresentado por Cavallo et al. (2017). A coloração está associada ao frescor e teor de clorofila presente nas folhas verdes que são medidas por técnicas químicas

destrutivas e/ou medidores de clorofila não destrutivos, porém de menor confiabilidade. Dessa forma, foi aplicado um modelo de VC usando uma *Random Forest* com o intuito de apresentar uma nova abordagem automática para prever de forma não destrutiva e com maior confiabilidade o teor total de clorofila. O modelo calibrado apresentou um coeficiente de determinação ( $R^2 = 0.9$ ) superior ao apresentado pelo medidor de clorofila ( $R^2 = 0.79$ ).

### 2.2.1.3 Máquina de vetor de suporte

A SVM (*Support Vector Machine*), conhecida como Máquina de Vetor de Suporte também utiliza o aprendizado supervisionado. Ela constrói um hiperplano (limite ótimo) ou conjunto de hiperplanos em um espaço de alta dimensão com o menor erro e a melhor margem máxima, isto é; uma boa separação é obtida pelo hiperplano que tem a maior distância com os dados de treinamento mais próximos (SOLTANI ; OMID, 2015). A Figura 6 representa como uma SVM pode ser construída. O gráfico (a) indica os possíveis hiperplanos que podem separar as duas classes do problema, sem indicar qual a melhor hiperplano. Já no gráfico (b) é possível observar a construção do hiperplano (reta pontilhada) que indica a função ideal (maior distância entre os pontos) para separar as duas classes.

**Figura 6:** Representação bidimensional de retas lineares (a) e do hiperplano (b) da SVM.



Fonte: Bona et al., 2017.

Apesar de ser mais utilizado para problemas que envolvam classificação, também pode ser aplicado para problemas de regressão, neste caso, conhecido como *Support Vector Regression* (SVR) e nos últimos anos vêm sendo um dos algoritmos de AM mais empregados devido a sua performance em resolver problemas não lineares, por apresentar um

bom poder de generalização e conseguir lidar com conjunto de dados diferentes (FARIDI et al., 2012; ZHENG et al., 2014; DI ROSA et al., 2017).

Olgun et al. (2016) utilizaram o algoritmo SVM para propor um sistema automático capaz de classificar os grãos de trigo em tempo real utilizando imagens extraídas a partir de histogramas. Neste estudo, os autores encontraram 88,33% de precisão na classificação do método proposto.

Com o objetivo de detectar precocemente problemas na curva de produção de ovos comerciais, Morales et al. (2016) utilizaram uma SVM onde esta foi capaz de prever com 1 dia de antecedência possíveis problemas com precisão de 98%. Outros autores também utilizaram a SVM na cadeia de produção de frango. Faridi et al. (2012) propuseram, nesse caso, uma SVR e uma RNA para prever características corporais e de carcaça de duas linhagens de frango diferentes. Porém, a SVR obteve melhor desempenho e poder de generalização que a RNA.

Bona et al. (2017) propuseram uma metodologia de classificação geográfica de diferentes genótipos de café arábica usando NIR e uma SVM. Com o uso dessa proposta foi possível classificar todas as amostras de café com 100% de sensibilidade e especificidade demonstrando a potencialidade da técnica proposta.

#### 2.2.1.4 *Naïve Bayes*

Os classificadores *Naïve Bayes* são uma família de classificadores probabilísticos baseados na aplicação do teorema de *Bayes*. São considerados modelos estatísticos e utilizam o aprendizado supervisionado (MITCHELL, 1997).

Este classificador ficou conhecido como ingênuo (*naïve*) por descrever que seus atributos são condicionalmente independentes, ou seja, um evento não informa sobre o outro. Possui a capacidade de integrar diferentes tipos de fontes de dados, por exemplo, o conhecimento de um especialista e dados de mensuração (BOUZEMBRAK et al., 2017).

Em resumo, cada atributo ( $X_n$ ) está condicionalmente independente dos demais atributos que compõem o rótulo da classe, ou seja  $X_1$  é independente de  $X_2$ , que é independente de  $X_3$  e assim sucessivamente. A classe do problema, por sua vez, é a única que apresenta uma relação de dependência com cada um dos atributos (PERNKOPF, 2005).

Em geral são algoritmos muito utilizados em problemas de classificação por serem simples e eficazes. Já foram relatados em diversos cenários de aprendizado que envolvem imagens, detecção de fraudes em alimentos, classificação de textos, dentre outros (ARAR e AYAN, 2017; BOUZEMBRAK et al., 2017). Contudo, em muitas situações reais,

o pressuposto de independência entre os atributos não é aplicado, limitando a aplicação do algoritmo.

Uma de suas vantagens é que requer apenas uma pequena quantidade de dados de treinamento para prever a classe desejada. Em muitos tipos de problemas, esse cenário se encaixa muito bem, principalmente quando se tem poucos exemplos ou amostras para realizar o aprendizado (YANG et al., 2017).

#### 2.2.1.5 $k$ -Vizinhos Próximos

$k$ -Vizinhos Próximos ou *k-Nearest Neighbors* ( $k$ -NN) é um algoritmo simples de classificação supervisionado que faz sua seleção pela maioria de votos de seus vizinhos “ $k$  mais próximos”, ou seja, a proximidade indica propriedades similares; sendo possível atribuir ou classificar a categoria de uma nova amostra inserida no sistema. Dessa forma, o parâmetro  $k$  tem um grande impacto no desempenho da classificação (ZHENG et al., 2014).

Os classificadores  $k$ -NN já foram utilizados em diversas áreas como em medicina; em reconhecimento facial e de assinatura; e na indústria dos alimentos. Também já foram utilizados com sucesso em dados espectrais extraídos de sensor baseado em fibra óptica com o objetivo de monitorar a qualidade de hambúrgueres e frango *en croûte* durante o cozimento (O’FARREL et al., 2005).

Com o objetivo de avaliar a relação entre os parâmetros de observação e a escolha de um produto pelo consumidor e após, gerar um modelo de previsão, Gere et al. (2016) utilizaram um olho rastreador para registrar o comportamento de observação de 59 participantes sobre a escolha de 6 diferentes grupos alimentares (maçãs, saladas, sopas instantâneas, salsichas, refrigerantes e cervejas). Para criar os modelos de previsão, ele testou alguns algoritmos, entre eles o  $k$ -NN, que obteve a melhor performance, principalmente durante a separação entre os grupos alimentares.

Concina et al. (2009) propuseram o uso de nariz eletrônico para avaliar a presença microbiana em amostras de tomates processados e como forma de classificar a presença ou ausência de contaminação utilizaram o algoritmo  $k$ -NN, obtendo uma boa performance (83% de acurácia).

#### 2.2.1.6 Lógica nebulosa

A lógica nebulosa ou lógica *Fuzzy* é uma técnica utilizada para resolver problemas que apresentam incertezas e falta de exatidão tornando-se uma ferramenta poderosa por manipular de maneira conveniente o conhecimento. A implementação de sistemas de controle *Fuzzy* pode reduzir a complexidade de um problema que anteriormente era intratável e passam agora a ser solúveis (GOMIDE et al., 1995). Em outras palavras, a lógica *Fuzzy* simula a experiência humana em tomar decisões complexas usando informações incertas e aproximadas baseadas em funções de pertinência, fazendo com que a base do conhecimento seja construída de forma mais natural (DU e SUN, 2006).

Segundo Natarajan et al. (2016) princípios de Inteligência Artificial e *Soft Computing* vem sendo utilizado em agricultura de precisão como uma alternativa às avaliações realizadas pelos humanos. Neste contexto, surge a lógica *Fuzzy*, que segundo os autores, trata-se de uma técnica flexível e adaptativa ao problema onde o conhecimento é incerto, possui habilidade para executar a modelagem do problema de forma rápida e muito próxima ao raciocínio humano. Dessa forma, a técnica *Fuzzy* tornou-se popular e encontrou aplicabilidade em diversas áreas.

A incorporação da Lógica *Fuzzy* em modelos de tomada de decisão pode produzir resultados mais realistas, uma vez que visam transformar o conhecimento humano incerto em uma fórmula matemática. Para a caracterização do problema pode-se basear em estimativas lingüísticas, em vez de valores numéricos (BANAEIAN et al., 2016) .

Um exemplo dessa aplicação pode ser encontrado em Wang, Yue e Zhou (2017) na qual aplicaram a Lógica *Fuzzy* e uma RNA para garantir uma metodologia mais confiável de rastreabilidade dos alimentos. *Fuzzy* foi utilizada para avaliar a qualidade dos produtos fornecidos em cada estágio da cadeia de suprimento, enquanto a RNA foi adotada para classificar a determinação final do grau de qualidade dos alimentos de acordo com todas as avaliações realizadas em cada estágio. Em resumo, este trabalho indicou o potencial das técnicas de Inteligência Computacional para a melhoria das informações da cadeia de suprimentos de alimentos melhorando a sua rastreabilidade e confiança dos consumidores.

A restrição da abordagem *Fuzzy* é que seu desempenho depende de quão bem o sistema foi ajustado, podendo tornar-se ineficiente para lidar com problemas multidimensionais (VITHU; MOSES, 2016).

#### 2.2.1.7. Aplicação de algoritmos de aprendizado de máquina na cadeia de carne

Na Tabela 1 é possível observar alguns artigos publicados nos últimos anos (quase duas décadas) referentes ao uso de AM aplicado a qualidade da carne. Na maioria dos exemplos, os algoritmos foram utilizados com o objetivo de classificação/predição ou regressão.

Sabe-se que cada problema deve ser modelado de acordo com a sua complexidade e a escolha do melhor algoritmo deriva dessa premissa. Contudo, apesar do surgimento de diversos algoritmos ao longo dos anos com o poder de lidar com a não-linearidade do problema, os algoritmos RNA e SVM continuam sendo os mais utilizados obtendo boas performances. Em diversos exemplos é possível notar também o uso de imagem aliado ao AM, participando da fase de reconhecimento de padrões do Sistema de VC.

**Tabela 1:** Trabalhos envolvendo a aplicação de algoritmos de aprendizado de máquina na cadeia da carne desde o ano 2000.

<b>Animal</b>	<b>Aprendizado de máquina</b>	<b>Aplicação</b>	<b>Referência</b>
<b>Bovino</b>	<i>K</i> -NN	Classificar a carne bovina segundo a raça, idade e músculo por meio de análise de textura da imagem.	Basset et al., 2000.
<b>Bovino</b>	DT	Prever o rendimento e marmoreio da carne, antes do abate, por imagens obtidas via ultrassom.	Song et al., 2002.
<b>Bovino, Frango</b>	<i>K</i> -NN, RNA	Classificar dados espectrais extraídos de sensor baseado em fibra óptica para o controle de qualidade.	O'Farrell et al., 2005.
<b>Cordeiro</b>	RNA	Prever a sensibilidade da textura em carne cozida.	Chandraratne et al., 2006.
<b>Suínos</b>	SVM	Classificar em três classes distintas de qualidade: Frescas, semi-frescas e estragadas.	Papadopoulou et al., 2011.
<b>Bovino, Suíno</b>	DT	Classificar a microflora de carne moída proveniente de supermercados.	Paulsen et al., 2011.
<b>Frango</b>	SVM, RNA	Prever características corporais e de carcaça de duas linhagens de frango diferentes.	Faridi et al., 2012.
<b>Bovino</b>	RNA, Fuzzy	Classificar a classe de qualidade e prever população microbiológica.	Kodogiannis et al., 2014.
<b>Suíno (Linguiças)</b>	<i>K</i> -NN, RNA	Reconhecer e prever as classes (artesanal e inspecionada) de linguiças suínas.	Matera et al., 2014.
<b>Bovino</b>	RNA	Prever a inativação da <i>E.coli</i> na superfície da carne utilizando voltagem de baixa tensão.	Gosukonda et al., 2015.
<b>Bovino, Cavalo</b>	<i>Naïve Bayes</i>	Classificar a carne bovina e de cavalo com base na composição dos triglicerídeos.	Jakes et al., 2015.
<b>Frango</b>	RNA	Prever a frescura e contagem bacteriana presente na carne utilizando nariz eletrônico portátil.	Timsorn et al., 2016
<b>Cordeiro</b>	RNA, SVM, CentreNN*	Discriminar os músculos utilizando algoritmos de aprendizado de máquina e imagem hiperespectral	Sanz et al., 2016.
<b>Cordeiro, Bovino, Suíno</b>	SVM	Selecionar os comprimentos de onda ideais para compor um sistema multiespectral <i>online</i> para monitorar a cor da carne.	Kamruzzaman et al., 2016b.

\*CentreNN: Algoritmo que utiliza os princípios do *K*-NN, contudo considera o centróide (média) durante a classificação.

Fonte: Do autor, 2018.

### 2.3 VISÃO COMPUTACIONAL

A visão Computacional (VC) busca integrar as áreas de Processamento Digital de Imagens e a Inteligência Computacional tendo como objetivo a obtenção de algoritmos capazes de interpretar o conteúdo de imagens. Suas aplicações estão presentes em diversos segmentos tecnológicos que envolvem análise de imagens, reconhecimento de padrões e controle inteligente; abrangendo múltiplas áreas do conhecimento, tornando-se uma área multidisciplinar com muitas aplicações práticas (NEVES et al., 2012).

Em geral, a VC utiliza dispositivos ópticos de aquisição para receber e interpretar a imagem de um objeto com o intuito de processar as imagens e obter informações com auxílio de softwares e algoritmos inteligentes. Tem sido amplamente utilizada para examinar, controlar e monitorar processos científicos, comerciais, industriais, militares e até biomédicos (CAPITÁN-VALLVEY et al., 2015).

Segundo Rios (2011), a VC foi teorizada há bastante tempo, porém sendo empregada na prática recentemente, quando os computadores se tornaram capazes de processar grandes quantidades de dados como as imagens de alta resolução. Ainda assim, não há formulação ou soluções-padrão para “o problema da visão computacional”. Em outras palavras, cada aplicação de CV exige configurações particulares, por vezes a construção completa e específica para a obtenção de resultados adequados.

Pode-se dizer que a VC tem o objetivo de simular a visão humana possuindo como entrada uma imagem e como saída a interpretação dela como um todo ou apenas parcialmente (MARENGONI; STRINGHINI, 2009). Essa metodologia extrai automaticamente informações úteis sobre um objeto ou cena a partir de uma imagem digital, um conjunto ou uma sequência de imagens (GUNASEKARAN, 1996).

A visão é o mais avançado dos sentidos, fazendo com que as imagens exerçam um papel importante na percepção humana. No entanto, diferente da visão humana, os aparelhos de processamento de imagens conseguem englobar todo o Espectro Eletromagnético, variando de ondas gama a ondas de rádio como ultrassom, microscopia eletrônica e imagens geradas por computador (GONZALEZ; WOODS, 2010).

Várias áreas já utilizam a VC para automatizar seus processos. Desde a década de 90 o sistema de VC tem sido utilizado na indústria dos alimentos a fim de averiguar a qualidade do produto em tempo real substituindo inspetores humanos. Essa tecnologia fornece um alto nível de repetitividade e flexibilidade a baixo custo sem comprometer a precisão (GUNASEKARAN, 1996). Ela é uma alternativa rápida, não invasiva e com baixo

custo ao considerar as tecnologias que envolvem análise de imagem para avaliação de alimentos (MOHEBBI et al., 2009).

Segundo Abdullah (2012) o sistema de VC é ideal para inspeções de rotina da qualidade de alimentos e bebidas simulando o conhecimento humano por meio de ferramentas de imagens e aprendizado de máquina. Aplicações para a avaliação de qualidade, controle de segurança como inspeção de objetos estranhos e aplicações gerais de processamento na linha de produção foram relatadas (TORRENCE et al., 2004; BORAH et al., 2005; ACEVEDO et al., 2009; MEDINA et al., 2013).

Imagens obtidas por câmeras de monitoramento e webcams foram utilizadas para a detecção e quantificação do total de polifenóis presentes no vinho tinto, com resultados comparáveis aos obtidos pelo método padrão (ALIMELLI et al., 2007; SANTOS e PEREIRA-FILHO, 2013).

Kashiha et al. (2014) descrevem um procedimento de segmentação de imagens para avaliar a qualidade alimentar dos suínos estimando seu peso. Já Hong et al. (2014) descreveram a importância da utilização de VC para avaliar externamente a qualidade de produtos aquáticos (peixes e frutos do mar). Neste artigo eles elencam as vantagens e limitações do processo e acima de tudo, a relatam como uma ferramenta não destrutiva diferente da metodologia convencional que se faz manualmente.

Segundo Gonzalez & Woods (2010) a VC pode ser dividida em 6 etapas: Aquisição, Pré-processamento, Segmentação, Extração de Características, Reconhecimento de Padrões e Decisão.

### 2.3.1 Aquisição de Imagens

A aquisição consiste na captura de uma imagem por sensores que respondem aos estímulos de luz refletida pelos objetos. A imagem neste caso é um sinal contínuo de duas dimensões relacionados a cor, onde o domínio é o plano e o contradomínio é o espaço de cor (MARQUES FILHO e NETO, 1999).

Para elucidar melhor essa descrição, é necessária a compreensão sobre a teoria de imagem digital. Uma imagem digital é constituída por um conjunto de elementos de imagem ou pixels (*picture elements*), arranjados em forma de matriz numérica. Os valores dessa matriz podem ser obtidos pela função  $f(x,y)$ , onde os valores de  $f$  são resultantes da intensidade (brilho) dos materiais da área correspondente ao pixel de coordenada  $x$  (largura) e  $y$  (altura) (ALCAIM; OLIVEIRA, 2011).

Deste modo, cada pixel está associado a um valor numérico que indica a intensidade da luz absorvida pelo sensor. Em imagens monocromáticas a intensidade está associada às tonalidades de cinza que variam do preto (nível mínimo = 0) ao branco (nível máximo = 255).

A etapa de aquisição é passível de problemas relacionados ao volume de dados adquiridos. O armazenamento ou transmissão dos dados obtidos necessitam de uma grande capacidade de memória, sendo inevitável a codificação ou compressão dessas imagens com o intuito de reduzir o número de bits/pixel necessário para representá-las (ALCAIM e OLIVEIRA, 2011).

Além disso, para que ocorra um processo de aquisição adequado é essencial cuidados com a iluminação do ambiente para evitar ruídos na imagem. Tal procedimento facilitará os passos subsequentes, uma vez que, ocorrerá menor tratamento durante o pré-processamento desta imagem (DU; SUN, 2006; CONCI et al., 2008).

Os principais equipamentos de aquisição de imagem para alimentos são: câmeras digitais, câmeras multiespectrais e hiperespectrais, câmera térmica, scanners, raio-X, ultrassom, dentre outras (ABDULLAH et al., 2012).

### 2.3.2 Pré-Processamento de Imagens

Em geral, o Pré-processamento engloba a etapa na qual a imagem adquirida precisa ser ajustada para a extração das informações necessárias, podendo ser apenas uma mudança no formato, tamanho da imagem, remoção de um ruído, melhoria de contraste ou deterioração. Basicamente, a função do pré-processamento é melhorar a qualidade da imagem adquirida para facilitar as etapas seguintes (MARQUES FILHO e NETO, 1999).

Os ruídos podem surgir de diversas fontes, por exemplo, o tipo de sensor utilizado, a iluminação do ambiente, as condições climáticas no momento da aquisição da imagem ou a posição relativa entre o objeto de interesse e a câmera. Todos esses fatores fazem com que o ruído apareça e dificulte a interpretação ou reconhecimento dos objetos na imagem. Nestes casos, se faz necessário o uso de filtros para remover os ruídos das imagens (MARENGONI e STRINGHINI, 2009).

Existem vários tipos de filtros para a remoção de ruídos e formação de máscaras para a posterior segmentação de imagens. Esses filtros podem ser divididos em espaciais ou no domínio da frequência. Contudo, o primeiro é o mais utilizado para as operações que envolvem alimentos. Em geral, se refere ao filtro como um *Kernel*, pois ele

utiliza o pixel central como referência, define um peso e multiplica a intensidade com os pixels vizinhos (PÉREZ; PASCAU, 2013).

### 2.3.3 Segmentação de Imagens

O processo de Segmentação consiste em particionar uma imagem em regiões que são de interesse. Em geral, os objetos precisam ser separados de seu plano de fundo (*background*) para a extração das informações necessárias. Se os objetos forem facilmente destacados do seu fundo, essa operação se torna simples; mas geralmente esta etapa é uma das mais difíceis de se implementar (QUEIROZ; GOMES, 2006).

Os algoritmos de segmentação de imagens monocromáticas executam sua tarefa de duas formas, essencialmente: por descontinuidade e por similaridade dos tons de cinza. Na execução por descontinuidade observa-se uma mudança brusca nos níveis de cinza, como em bordas de imagens. Já por similaridade é importante destacar a limiarização e crescimento de regiões (QUEIROZ; GOMES, 2006).

A Limiarização ou *Thresholding* é um dos processos mais importantes durante a etapa de segmentação, uma vez que torna possível a extração de objetos por meio da definição de um limiar. Contudo, o desafio dessa abordagem é determinar o limiar ideal de valor de pixel para a separação dos objetos. A limiarização pelo método de *Otsu* é um exemplo de técnica clássica e usual pela simplicidade deste algoritmo (CONCI et al., 2008).

### 2.3.4 Extração de Características

Após as imagens segmentadas torna-se possível obter dados relevantes a partir das regiões destacadas. Os atributos extraídos mais comuns são: número total de objetos, informações relacionadas a dimensão, geometria (área, perímetro e largura), forma (circularidade e concavidade), propriedades de luminosidade e textura da imagem (CONCI et al., 2008).

Com os atributos extraídos é possível, por exemplo, induzir um modelo de regressão ou classificação para auxiliar em decisões automáticas. Vale lembrar que, nesta etapa, a entrada no sistema é ainda uma imagem, mas a saída é um conjunto de dados correspondentes à imagem que podem ser organizados, por exemplo, em uma planilha do excel (MARQUES FILHO e NETO, 1999).

### 2.3.5 Reconhecimento de Padrões

É nesta etapa que a decisão baseada no conhecimento humano é simulada pelo uso de algoritmos. Por exemplo, em um problema de distinção de objetos em uma cena, o Reconhecimento de Padrões dá suporte para a identificação dos objetos na imagem por meio de um modelo. Este modelo é construído utilizando as informações contidas na imagem, isto é, a partir dos parâmetros extraídos da etapa anterior. É considerada uma das fases de mais alto nível, na qual visa reconhecer, verificar ou inferir a identidade dos objetos automaticamente (QUEIROZ; GOMES, 2006).

Neste contexto, o uso de vários exemplos permitem a generalização de um modelo para a predição de novas amostras, em dois tipos de tarefas, regressão ou classificação como exemplificado no item 2.1.1. Em geral, vários atributos são necessários para uma correta predição, porém quanto mais atributos, mais complexo se torna o processo.

A etapa de Reconhecimento de Padrões é muito complexa e existem várias formas de realizá-la. As metodologias mais simples implicam em processos de agrupamento estatístico, para os quais a decisão humana é fundamental. Já as mais sofisticadas permitem ao computador reconhecer diferentes objetos através de técnicas de Inteligência Computacional com pouca ou nenhuma intervenção humana, como técnicas de AM. Aqueles que possuem intervenção humana são conhecidos como método supervisionado (SCURI, 1999), como visto anteriormente no item 2.1.1.

### 2.3.6 Decisão

O objetivo da VC é tomar decisões a partir da extração de informações do mundo real por meio das imagens. Isso pode ser feito com o auxílio de computadores por parâmetros extraídos dos objetos processados por algoritmos de Inteligência Computacional que já foram descritos no item 2.1.

Em alimentos, essa decisão fica nítida quando o objetivo é a busca pelos padrões de qualidade. Por exemplo, para decidir qual a taxa de marmoreio de uma base de amostras de carne por meio de VC, é necessário passar pela fase de aquisição das imagens do músculo *longissimus dorsi et thoracis*, depois extrair a região de interesse (ROI) composta pela gordura visível presente entre o músculo e para isso, possivelmente se utiliza a fase anterior de pré-processamento pelo uso de filtros ou mudança de canais de cor no histograma. Após a segmentação da ROI e extração de atributos como quantidade de pixel que representa a gordura (Jackman et al., 2009), é possível decidir qual o nível de marmoreio das amostras por meio de algoritmos de classificação ou de Aprendizado de Máquina.

Um outro exemplo do processo de decisão pode ser encontrado em Barbin et al. (2016), onde a fase de pré-processamento foi crucial para avaliar a cor da carne de frango utilizando imagens RGB (*Red, Green e Blue*). As imagens foram adquiridas do músculo *pectoralis major* com uma câmera RGB. Na etapa de pré-processamento foi realizada a normalização da iluminação e transformação dos canais de cor (CIELab para RGB). A etapa de segmentação isolou apenas o músculo, eliminando o fundo da imagem. A partir deste ponto foi possível encontrar a ROI e extrair os atributos de cor. Por fim, na etapa de Decisão foi possível classificar se a amostra pertencia a classe de carne que sofria ou não com a síndrome da carne pálida por meio dos coeficientes de determinação encontrados ( $R^2$ ).

### 2.3.7 Uso de imagens para avaliação da qualidade na cadeia de carne

Na Tabela 2 é possível observar exemplos da aplicação de imagens e VC como alternativa às avaliações tradicionais de qualidade da carne nos últimos anos (desde 2008). Nota-se que um dos parâmetros da qualidade mais pesquisado é a cor, assim como os defeitos no alimento a ela correlacionados, por exemplo PSE e DFD. Esse cenário demonstra a importância desse atributo para a cadeia de alimentos.

Outro parâmetro de qualidade frequentemente avaliado durante o levantamento é a gordura, tanto para estimar a sua quantidade como para avaliar a presença de marmoreio. A maioria dos trabalhos estudados obtiveram sucesso com o uso de imagens para a avaliação dos parâmetros de qualidade, contudo Chmiel, Slowinski e Dasiewicz (2011b) não alcançaram o mesmo sucesso quando avaliaram a possibilidade de mensurar a gordura da carne de frango por VC. Nesse trabalho, eles avaliaram peito e sobrecoxa de frango, junto às amostras de sobrecoxa de peru. Os resultados demonstraram que é possível utilizar a VC para mensurar apenas a gordura da sobrecoxa de peru pelo maior contraste de cor entre a gordura e o tecido muscular assim como a maior percentagem de gordura quando comparada com a carne de frango.

**Tabela 2:** Trabalhos envolvendo o uso de imagens para avaliar a qualidade dos produtos na cadeia da carne e derivados desde 2008.

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

**Fonte:** Do autor, 2018.

## REFERÊNCIAS

- ABDULLAH, M. Z. Computer vision and infrared techniques for image acquisition in the food and beverage industries. **Computer Vision Technology in the Food and Beverage Industries**, p. 1, 2012.
- ABIEC. Associação Brasileira das Indústrias Exportadoras de Carne. 2017. Disponível em: <<http://www.abiec.com.br/Exportacoes.aspx>>. Acesso em: 28 set. 2017.
- AGHBASHLO, M.; HOSSEINPOUR, S.; GHASEMI-VARNAMKHASTI. Computer vision technology for real-time food quality assurance during drying process. **Trends in food science & technology**, v. 39, n. 1, p. 76-84, 2014.
- ALCAIM, A; OLIVEIRA, C. **Fundamentos do processamento de sinais de voz e imagem**. Rio de Janeiro: Editora Interciência, v. 66, n. 68, p. 70-0, 2011.
- ALVES, D. D. et al. Maciez da carne bovina. **Ciência Animal Brasileira**, v. 6, n. 3, p. 135-149, 2005.
- AMERICAN MEAT SCIENCE ASSOCIATION (AMSA). **Meat evaluation handbook**. American Meat Science Association, 2001.161p.
- ARAR, Ö. F; AYAN, K. A Feature Dependent Naive Bayes Approach and Its Application to the Software Defect Prediction Problem. **Applied Soft Computing**, 2017.
- BANAEIAN, N. et al. Green supplier selection using fuzzy group decision making methods: a case study from the agri-food industry. **Computers & Operations Research**, 2016.
- BARBIN, D. F. et al. Digital image analyses as an alternative tool for chicken quality assessment. **Biosystems Engineering**, v. 144, p. 85-93, 2016.
- BARBUT, S. Estimates and detection of the PSE problem in young turkey breast meat. **Canadian Journal of Animal Science**, v. 76, n. 3, p. 455-457, 1996.
- BASSET, O. et al. Application of texture image analysis for the classification of bovine meat. **Food Chemistry**, v. 69, n. 4, p. 437-445, 2000.
- BENALIA, S. et al. Computer vision for automatic quality inspection of dried figs (*Ficus carica* L.) in real-time. **Computers and Electronics in Agriculture**, v. 120, p. 17-25, 2016.
- BOCCARD, R. et al. Procedures for measuring meat quality characteristics in beef production experiments. Report of a working group in the commission of the European communities'(CEC) beef production research programme. **Livestock Production Science**, v. 8, n. 5, p. 385-397, 1981.
- BONA, E. et al. Support vector machines in tandem with infrared spectroscopy for geographical classification of green arabica coffee. **LWT-Food Science and Technology**, v. 76, p. 330-336, 2017.

- BOUZEMBRAK, Y. et al. Application of Bayesian Networks in the development of herbs and spices sampling monitoring system. **Food Control**, 2017.
- BREIMAN, L. Random forests. **Machine learning**, v. 45, n. 1, p. 5-32, 2001.
- BRIDI, A. M.; SILVA, C. A. **Avaliação da carne suína**. Londrina: Midiograf, 2009.
- 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, p. 193-213, 2002.
- CAPITÁN-VALLVEY, L. F. et al. Recent developments in computer vision-based analytical chemistry: A tutorial review. **Analytica chimica acta**, v. 899, p. 23-56, 2015.
- CAVALLO, D. P. et al. Contactless and non-destructive chlorophyll content prediction by random forest regression: A case study on fresh-cut rocket leaves. **Computers and Electronics in Agriculture**, v. 140, p. 303-310, 2017.
- CHANDRARATNE, M. R. et al. Prediction of lamb tenderness using image surface texture features. **Journal of Food Engineering**, v. 77, n. 3, p. 492-499, 2006.
- 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.
- CHENG, W. et al. Marbling Analysis for Evaluating Meat Quality: Methods and Techniques. **Comprehensive Reviews in Food Science and Food Safety**, v. 14, n. 5, p. 523-535, 2015.
- 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.
- CHMIEL, M.; SŁOWIŃSKI, M. The use of computer vision system to detect pork defects. **LWT-Food Science and Technology**, v. 73, p. 473-480, 2016.
- CONCI, A.; AZEVEDO, E.; LETA, F. R. **Computação gráfica**. 2 ed. Rio de Janeiro: Elsevier, 2008.
- COELHO, P. A. et al. A machine vision system for automatic detection of parasites *Edotea magellanica* in shell-off cooked clam *Mulinia edulis*. **Journal of Food Engineering**, v. 181, p. 84-91, 2016.
- CONCINA, I. et al. Early detection of microbial contamination in processed tomatoes by electronic nose. **Food Control**, v. 20, n. 10, p. 873-880, 2009.

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

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.

ELMASRY, G.; SUN, D. W.; ALLEN, P. Non-destructive determination of water-holding capacity in fresh beef by using NIR hyperspectral imaging. **Food Research International**, v. 44, n. 9, p. 2624-2633, 2011.

FACELI, K. et al. **Inteligência Artificial: Uma abordagem de aprendizado de máquina**. Rio de Janeiro: LTC, v. 2, p. 192, 2011.

FARIDI, A. et al. Predicting body and carcass characteristics of 2 broiler chicken strains using support vector regression and neural network models. **Poultry science**, v. 91, n. 12, p. 3286-3294, 2012.

FAUCITANO, L. et al. Application of computer image analysis to measure pork marbling characteristics. **Meat Science**, v. 69, n. 3, p. 537-543, 2005.

FELÍCIO, P. E. de. Fatores ante e post mortem que influenciam na qualidade da carne bovina. 1997.

GERE, A. et al. Visual attention accompanying food decision process: an alternative approach to choose the best models. **Food Quality and Preference**, v. 51, p. 1-7, 2016.

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.

GOMIDE, F.; GUDWIN, R. R.; TANSCHKEIT, R.. **Conceitos fundamentais da teoria de conjuntos fuzzy, lógica fuzzy e aplicações**. In: Proc. 6 th IFSA Congress-Tutorials. 1995. p. 1-38.

GOSUKONDA, Ramana et al. Application of artificial neural network to predict Escherichia coli O157: H7 inactivation on beef surfaces. **Food Control**, v. 47, p. 606-614, 2015.

GOLDSCHMIDT, R. R. (2010). Uma Introdução à Inteligência Computacional: fundamentos, ferramentas e aplicações. Rio de Janeiro Brasil: IST-Rio.

GONZALEZ, R. C.; WOODS, R. E. (2010). Processamento digital de imagens. tradução: Cristina Yamagami e Leonardo Piamonte. 3.ed: São Paulo: Pearson Prentice Hall.

GUNASEKARAN, S. Computer vision technology for food quality assurance. **Trends in Food Science & Technology**, v. 7, n. 8, p. 245-256, 1996

- HAMOEN, J. R.; VOLLEBREGT, H. M.; VAN DER SMAN, R. G. M. Prediction of the time evolution of pH in meat. **Food chemistry**, v. 141, n. 3, p. 2363-2372, 2013.
- 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.
- HOCQUETTE, J. F. et al. Intramuscular fat content in meat-producing animals: development, genetic and nutritional control, and identification of putative markers. **Animal**, v. 4, n. 2, p. 303-319, 2010.
- HONG, H. et al. Visual quality detection of aquatic products using machine vision. **Aquacultural Engineering**, v. 63, p. 62-71, 2014.
- HUNT, M. C. et al. AMSA meat color measurement guidelines. **American Meat Science Association**, Champaign, Illinois USA, v. 61820, p. 1-135, 2012.
- JACKMAN, P. et al. Computer vision in the fresh and processed meat industries. **Computer Vision Technology in the Food and Beverage Industries**, v. 255, 2012.
- JACKMAN, P.; SUN, D.W.; ALLEN, P.; BRANDON, K.; WHITE, A. M Correlation of consumer assessment of longissimus dorsi beef palatability with image colour, marbling and surface texture features. **Meat science**, v. 84, n. 3, p. 564-568, 2010.
- 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.
- JAKES, W. et al. Authentication of beef versus horse meat using 60MHz <sup>1</sup>H NMR spectroscopy. **Food chemistry**, v. 175, p. 1-9, 2015.
- KASHANINEJAD, M.; DEHGHANI, A. A.; KASHIRI, M. Modeling of wheat soaking using two artificial neural networks (MLP and RBF). **Journal of Food Engineering**, v. 91, n. 4, p. 602-607, 2009.
- KAMRUZZAMAN, M.; MAKINO, Y.; OSHITA, S. Hyperspectral imaging for real-time monitoring of water holding capacity in red meat. **LWT-Food Science and Technology**, v. 66, p. 685-691, 2016a.
- KAMRUZZAMAN, M.; MAKINO, Y.; OSHITA, S. Online monitoring of red meat color using hyperspectral imaging. **Meat science**, v. 116, p. 110-117, 2016b.
- KILLINGER, K. M. et al. Consumer sensory acceptance and value for beef steaks of similar tenderness, but differing in marbling level. **Journal of Animal Science**, v. 82, n. 11, p. 3294-3301, 2004.
- KODOGIANNIS, V. S.; KONTOGIANNI, E.; LYGOURAS, J. N. Neural network based identification of meat spoilage using Fourier-transform infrared spectra. **Journal of Food Engineering**, v. 142, p. 118-131, 2014.
- 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.

- LAWRIE, R. A.; LEDWARD, D. A. (2006). **Lawrie's meat science**. Cambridge: Woodhead Publishing Limited.
- LEE, S. H. et al. Use of a bovine genome array to identify new biological pathways for beef marbling in Hanwoo (Korean Cattle). **BMC genomics**, v. 11, n. 1, p. 623, 2010.
- LIMA JÚNIOR, D. M. de. et al. Oxidação lipídica e qualidade da carne ovina. **Acta Veterinaria Brasilica**, v. 7, n. 1, p. 14-28, 2013.
- LIU, D. et al. Combination of spectra and texture data of hyperspectral imaging for prediction of pH in salted meat. **Food chemistry**, v. 160, p. 330-337, 2014.
- 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.
- MAGANHINI, M. B. et al. Carnes PSE (Pale, Soft, Exudative) e DFD (Dark, Firm, Dry) em lombo suíno numa linha de abate industrial. **Ciência e Tecnologia de Alimentos**, v. 27, n.1, p. 69-72, 2007.
- MARENGONI, M.; STRINGHINI, S. Tutorial: Introdução à visão computacional usando opencv. **Revista de Informática Teórica e Aplicada**, v. 16, n. 1, p. 125-160, 2009.
- MARQUES FILHO, O.; NETO, H. V. (1999). **Processamento digital de imagens**. Rio de Janeiro: Brasport.
- MATERA, J. A. et al. Discrimination of Brazilian artisanal and inspected pork sausages: application of unsupervised, linear and non-linear supervised chemometric methods. **Food Research International**, v. 64, p. 380-386, 2014.
- MAULIK, U.; BANDYOPADHYAY, S.; WANG, J. T. **Computational Intelligence and Pattern Analysis in Biology Informatics**. John Wiley & Sons, v.20, 2011.
- MITCHELL, T. M. **Machine learning**. 1997. Burr Ridge, IL: McGraw Hill, v. 45, n. 37, p. 870-877, 1997.
- MOHEBBI, M. et al. Computer vision systems (CVS) for moisture content estimation in dehydrated shrimp. **Computers and Electronics in Agriculture**, v. 69, n. 2, p. 128-134, 2009.
- MORALES, I. R. et al. Early warning in egg production curves from commercial hens: A SVM approach. **Computers and Electronics in Agriculture**, v. 121, p. 169-179, 2016.
- MUÑOZ, I. et al. Computer image analysis as a tool for classifying marbling: A case study in dry-cured ham. **Journal of Food Engineering**, v. 166, p. 148-155, 2015.
- NACHE, M. et al. Prediction of the pH as indicator of porcine meat quality using Raman spectroscopy and metaheuristics. **Chemometrics and Intelligent Laboratory Systems**, v. 154, p. 45-51, 2016.

- NARDONE, A.; VALFRÈ, F. Effects of changing production methods on quality of meat, milk and eggs. **Livestock Production Science**, v. 59, n. 2, p. 165-182, 1999.
- NATARAJAN, R.; SUBRAMANIAN, J.; PAPAGEORGIU, E. I. Hybrid learning of fuzzy cognitive maps for sugarcane yield classification. **Computers and Electronics in Agriculture**, v. 127, p. 147-157, 2016.
- NEVES, L. A. P.; VIEIRA NETO, H.; GONZAGA, A. Avanços em visão computacional. **Curitiba, PR: Omnipax Editora Ltda**, 2012.
- O'FARRELL, M. et al. Comparison of k-NN and neural network methods in the classification of spectral data from an optical fibre-based sensor system used for quality control in the food industry. **Sensors and Actuators B: Chemical**, v. 111, p. 354-362, 2005.
- OLGUN, M. et al. Wheat grain classification by using dense SIFT features with SVM classifier. **Computers and Electronics in Agriculture**, v. 122, p. 185-190, 2016.
- OLIVEIRA, E. M. de. et al. A computer vision system for coffee beans classification based on computational intelligence techniques. **Journal of Food Engineering**, v. 171, p. 22-27, 2016.
- OSAWA, C. C. et al. Teste de TBA aplicado a carnes e derivados: métodos tradicionais, modificados e alternativos. **Química Nova**, v.28, n.4, p. 655-, 2005.
- PAPADOPOULOU, O. S. et al. Rapid assessment of meat quality by means of an electronic nose and support vector machines. **Procedia Food Science**, v. 1, p. 2003-2006, 2011.
- PAULSEN, P. et al. Application of Classification and Regression Tree (CART) analysis on the microflora of minced meat for classification according to Reg.(EC) 2073/2005. **Meat science**, v. 88, n. 3, p. 531-534, 2011.
- PENA, F. et al. Marbling in the longissimus thoracis muscle from lean cattle breeds. Computer image analysis of fresh versus stained meat samples. **Meat science**, v. 95, n. 3, p. 512-519, 2013.
- PÉREZ, J. M. M.; PASCAU, J. **Image processing with ImageJ**. Packt Publishing Ltd, 2013.
- PERNKOPF, F. Bayesian network classifiers versus selective k-NN classifier. **Pattern Recognition**, v. 38, n. 1, p. 1-10, 2005.
- PREVOLNIK, M.; ČANDEK-POTOKAR, M.; ŠKORJANC, D. Predicting pork water-holding capacity with NIR spectroscopy in relation to different reference methods. **Journal of Food Engineering**, v. 98, n. 3, p. 347-352, 2010.
- PUOLANNE, E.; HALONEN, M. Theoretical aspects of water-holding in meat. **Meat Science**, v. 86, n. 1, p. 151-165, 2010.
- PRZYBYLAK, A. et al. Estimation of intramuscular level of marbling among Whiteheaded Mutton Sheep lambs. **Journal of Food Engineering**, v. 168, p. 199-204, 2016.

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

RIOS, L. R. S. Visão computacional. **Universidade Federal da Bahia, Salvador, BA**, 2011.

ROÇA, R. O. **Modificações post-mortem**. Botucatu: Laboratório de Tecnologia dos Produtos de Origem Animal, 2001. Disponível em:< <http://www.fca.unesp.br>>. Acesso em: set, 2016.

DI ROSA, A. R. et al. Fusion of electronic nose, electronic tongue and computer vision for animal source food authentication and quality assessment—A review. **Journal of Food Engineering**, v. 210, p. 62-75, 2017.

SADKOWSKI, T. et al. Transcriptional background of beef marbling—novel genes implicated in intramuscular fat deposition. **Meat science**, v. 97, n. 1, p. 32-41, 2014.

SAMPAIO, G. R. et al. Effect of natural antioxidant combinations on lipid oxidation in cooked chicken meat during refrigerated storage. **Food Chemistry**, v. 135, n. 3, p. 1383-1390, 2012.

SANZ, J. A. et al. Lamb muscle discrimination using hyperspectral imaging: Comparison of various machine learning algorithms. **Journal of Food Engineering**, v. 174, p. 92-100, 2016.

SHARIFZADEH, S. et al. Supervised feature selection for linear and non-linear regression of  $L^* a^* b^*$  color from multispectral images of meat. **Engineering Applications of Artificial Intelligence**, v. 27, p. 211-227, 2014.

SOLTANI, M.; OMID, Ma. 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.

SONG, Y. H.; KIM, S. J.; LEE, S. K. Evaluation of ultrasound for prediction of carcass meat yield and meat quality in Korean native cattle (Hanwoo). **Asian Australasian Journal of Animal Sciences**, v. 15, n. 4, p. 591-595, 2002.

SCURI, A. E. Fundamentos da imagem digital. Pontifícia Universidade Católica do Rio de Janeiro, 1999.

ŠPEHAR, M., VINCEK, D., & ŽGUR, S. (2008). Beef quality: factors affecting tenderness and marbling. **Stočarstvo**, 62(6), 463-478.

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

TAO, F.; PENG, Y. A method for nondestructive prediction of pork meat quality and safety attributes by hyperspectral imaging technique. **Journal of Food Engineering**, v. 126, p. 98-106, 2014.

TARLAK, F.; OZDEMIR, M.; MELIKOGLU, M. Computer vision system approach in colour measurements of foods: Part I. development of methodology. **Food Science and Technology (Campinas)**, v. 36, n. 2, p. 382-388, 2016.

- TIMSORN, K. et al. Evaluation of bacterial population on chicken meats using a briefcase electronic nose. **Biosystems Engineering**, v. 151, p. 116-125, 2016.
- TRINDERUP, C. H. et al. Comparison of a multispectral vision system and a colorimeter for the assessment of meat color. **Meat science**, v. 102, p. 1-7, 2015.
- ULRICI, A. et al. Automated identification and visualization of food defects using RGB imaging: Application to the detection of red skin defect of raw hams. **Innovative Food Science & Emerging Technologies**, v. 16, p. 417-426, 2012.
- VALOUS, N. A. et al. Colour calibration of a laboratory computer vision system for quality evaluation of pre-sliced hams. **Meat science**, v. 81, n. 1, p. 132-141, 2009.
- VELARDE, A. et al. Animal welfare towards sustainability in pork meat production. **Meat science**, v. 109, p. 13-17, 2015.
- VENTURINI, A. C. et al. A review: modified atmosphere packaging systems for fresh beef. **Brazilian Journal of Food Technology**, v. 12, n. 1/4, p. 128-137, 2009.
- VITHU, P.; MOSES, J. A. Machine vision system for food grain quality evaluation: A review. **Trends in Food Science & Technology**, v. 56, p. 13-20, 2016.
- WANG, J.; YUE, H.; ZHOU, Z. An improved traceability system for food quality assurance and evaluation based on fuzzy classification and neural network. **Food Control**, v. 79, p. 363-370, 2017.
- WU, D.; SUN, D.W. Colour measurements by computer vision for food quality control—A review. **Trends in Food Science & Technology**, v. 29, n. 1, p. 5-20, 2013a.
- WU, D.; SUN, D. W. Application of visible and near infrared hyperspectral imaging for non-invasively measuring distribution of water-holding capacity in salmon flesh. **Talanta**, v. 116, p. 266-276, 2013b.
- WU, Xiang et al. Mapping of TBARS distribution in frozen–thawed pork using NIR hyperspectral imaging. **Meat science**, v. 113, p. 92-96, 2016.
- WHEATLEY, R. A. Some recent trends in the analytical chemistry of lipid peroxidation. **TrAC Trends in Analytical Chemistry**, v. 19, n. 10, p. 617-628, 2000.
- WOOD, J. D.; HOLDER, J. S.; MAIN, D. C. J. Quality assurance schemes. **Meat Science**, v. 49, p. S191-S203, 1998.
- XIONG, Z.; SUN, D. W.; ZENG, X. A.; XIE, A. Recent developments of hyperspectral imaging systems and their applications in detecting quality attributes of red meats: A review. **Journal of food engineering**, v. 132, p. 1-13, 2014.
- YANG, C. C.; SOH, C. S.; YAP, V. V. A non-intrusive appliance load monitoring for efficient energy consumption based on Naive Bayes classifier. **Sustainable Computing: Informatics and Systems**, v. 14, p. 34-42, 2017.
- ZHENG, W.; FU, X.; YING, Y. Spectroscopy-based food classification with extreme learning machine. **Chemometrics and Intelligent Laboratory Systems**, v. 139, p. 42-47, 2014.

### 3 OBJETIVOS

#### 3.1 OBJETIVO GERAL

Utilizar a Inteligência Computacional como uma ferramenta rápida, automática e objetiva para avaliar o tempo de estocagem da carne suína e o índice de marmoreio das carnes.

#### 3.2 OBJETIVOS ESPECÍFICOS

- a) Verificar quais os atributos de qualidade da carne suína melhor descrevem o tempo de estocagem da carne em 0, 7 e 14 dias, por meio de algoritmos de AM;
- b) Investigar quais os melhores algoritmos de AM em prever o tempo de estocagem da carne suína em 0, 7 e 14 dias;
- c) Prever rapidamente (minutos) o tempo de armazenamento da carne suína utilizando parâmetros com menor tempo de aquisição como cor, pH e capacidade de retenção de água;
- d) Classificar de forma automática os níveis de marmoreio da carne independente do tipo de músculo animal avaliado utilizando algoritmos de Aprendizado de Máquina;

**4 ARTIGO A**

**STORAGE TIME PREDICTION OF PORK BY COMPUTATIONAL  
INTELLIGENCE<sup>1</sup>**

---

<sup>1</sup>Publicado na revista *Computers and Electronics in Agriculture* 127 (2016) 368–375

**5 ARTIGO B**

**DEVELOPMENT OF A FLEXIBLE COMPUTER VISION SYSTEM FOR  
MARBLING CLASSIFICATION<sup>2</sup>**

---

<sup>2</sup>Publicado na revista *Computers and Eletronics in Agriculture* 142 (2017) 536–544

## 6 CONSIDERAÇÕES FINAIS

A utilização da Inteligência Computacional vêm ganhando espaço na avaliação rápida e objetiva da qualidade dos alimentos. Neste trabalho, foi possível utilizar esta Ciência como uma ferramenta para avaliar a qualidade das carnes suína e bovina.

Os algoritmos de aprendizado de máquina são úteis para a classificação ou predição rápida de problemas não triviais como o tempo de armazenamento da carne suína. Dessa forma, foi possível prever o tempo de armazenamento da carne em 0, 7 e 14 dias utilizando apenas parâmetros tradicionais de avaliação que possuem um menor tempo de aquisição como cor, pH e capacidade de retenção de água. Dentre os oito algoritmos testados a Random Forest (*ensemble* árvore de decisão) obteve o melhor desempenho.

Já com o auxílio da Visão Computacional pode-se classificar de forma automática os níveis de marmoreio da carne suína e bovina independente do tipo de músculo avaliado utilizando poucas amostras para a fase de treinamento do algoritmo *K*-NN.

Em resumo, conclui-se que a Inteligência Computacional pode ser uma ferramenta de potencial auxílio para a avaliação da qualidade da carne *in loco* na Indústria. E como trabalho futuro, propõe-se verificar a independência do tipo de dispositivo de aquisição, utilizando diferentes câmeras e smartphones.