



UNIVERSIDADE
ESTADUAL DE LONDRINA

LOUISE MANHA PERES

**INTELIGÊNCIA COMPUTACIONAL E LÓGICA FUZZY NA
CLASSIFICAÇÃO DA QUALIDADE TECNOLÓGICA DA
CARNE SUÍNA**

Londrina

2018

LOUISE MANHA PERES

**INTELIGÊNCIA COMPUTACIONAL E LÓGICA FUZZY NA
CLASSIFICAÇÃO DA QUALIDADE TECNOLÓGICA DA
CARNE SUÍNA**

Tese apresentada ao Programa de Pós- graduação em Ciência Animal (Área de Concentração em Produção Animal) da Universidade Estadual de Londrina, como requisito parcial para a obtenção do título de doutora.

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

Co-orientador: Prof. Dr. 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

PERES, LOUISE.

INTELIGÊNCIA COMPUTACIONAL E LÓGICA FUZZY NA CLASSIFICAÇÃO DA QUALIDADE TECNOLÓGICA DA CARNE SUÍNA / LOUISE PERES. - Londrina, 2018. 72 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. Aprendizado de máquina. - Tese. 2. Árvore de decisão. - Tese. 3. Classificação da qualidade da carne suína - Tese. 4. Meta aprendizado - 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.

LOUISE MANHA PERES

**INTELIGÊNCIA COMPUTACIONAL E LÓGICA FUZZY NA
CLASSIFICAÇÃO DA QUALIDADE TECNOLÓGICA DA
CARNE SUÍNA**

BANCA EXAMINADORA

Prof^a. Dr^a. Ana Maria Bridi

Universidade Estadual de Londrina – UEL

Prof. Dr. Caio Abércio da Silva

Universidade Estadual de Londrina – UEL

Prof^a. Dr^a. Elza Iouko Ida

Universidade Estadual de Londrina – UEL

Prof^a. Dr^a. Juliana Pampana Nicolau

Universidade do Oeste Paulista – UNOESTE

Prof. Dr. Pedro Paulo da Silva Ayrosa

Universidade Estadual de Londrina – UEL

Londrina, 27 de Fevereiro de 2018.

OFEREÇO...

...aos meus pais, Odair e Eliza, pois sem o apoio e incentivo incondicional, jamais poderia chegar até aqui! Aos 17 anos saí de casa com a "simples" missão de formar em Zootecnia... acabei me apaixonando pela pesquisa, encarei o mestrado e eu queria mais, e hoje defendo a minha tese, onde nela se concretizam sonhos e finalizam 11 anos de caminhada acadêmica. Acho que chegamos mais longe do que poderíamos um dia imaginar! Obrigada por serem tão dedicados e por não medirem esforços para que eu pudesse estudar!

...hoje, além de meus mestres na vida, vocês se tornam “doutores em Ciência Animal” também, afinal, por quatro anos seguidos viveram intensamente o doutorado comigo! Amo vocês!!!!

DEDICO...

...ao meu marido, amigo, companheiro, exemplo de pessoa, incentivador e excelente membro de banca de defesa (rsrsrs), Conrado Cagliari Fioretto, que sem cessar me apoia, questiona e ensina, é incrível dividir meus dias com você!!! Parece que foi ontem (2011) que te vi sentado no canto da sala, só torcendo por mim na apresentação do TCC.. depois no estágio curricular, mestrado e enfim.. chegou o doutorado.. Obrigada por tudo e por estar sempre ao meu lado! Amo você!

AGRADECIMENTOS

Agradeço à Deus, pois mesmo me “esquecendo” de pedir a ele o que necessitava ou para agradecê-lo, sempre fui agraciada por sua proteção, Ele sabe do que precisamos na hora exata!

Aos meus pais (Odair e Eliza Manha Peres, marido (Conrado Fioretto) e sogros (pais de coração - Roberto e Ada Fioretto), os quais sempre estiveram ao meu lado nessa longa caminhada, incentivando incessantemente, questionando, concatenando hipóteses..foi incrível discutir qualidade de carne com vocês!rs Obrigada por serem meu alicerce!

À minha orientadora, Ana Maria Bridi, pelos ensinamentos nestes 11 anos de parceria. Nunca vou esquecer que nos primeiros meses de aula, eu quis desistir e voltar para casa, mas foi lá na sua antiga sala, ao fundo do corredor do departamento de Zootecnia, que você conversou comigo com tamanha atenção, me fez pensar bastante nas consequências da minha escolha... pois bem..aqui estou!!!! Foi uma parceria que deu certo: desde a minha primeira IC, NEPROCAR, GPAC, PET, TCC, Mestrado e Doutorado! Gratidão pelo carinho, amizade e orientação! Obrigada por confiar em mim nas mais diversas situações durante da minha vida acadêmica! Tenho certeza que muito do meu crescimento, tem a ver com a velha frase que você costuma dizer: "Não venha com problemas, me traga as soluções!".

Ao meu co-orientador Sylvio Barbon Jr., professor e pesquisador admirável! Obrigada por acreditar na ideia de resolver problemas de classificação qualidade de carnes com IC e fuzzy! Seu apoio foi fundamental para realização desta tese!

Ao professor Caio Abércio da Silva, exemplo de profissional, o qual admiro imensamente e tomo por exemplo. E que tive a honra de tê-lo como co-orientador no mestrado!

À professora Elza Iouko Ida, pela disponibilidade e atenção em contribuir com esta tese em função de seu extraordinário experiência na área de qualidade de carne.

À professora Juliana Pampana Nicolau, por participar deste processo tão fundamental do doutorado que é a defesa e tenho certeza que muito agregará com seu conhecimento em qualidade de carne .

Ao professor Pedro Paulo da Silva Ayrosa, que gentilmente aceitou participar de minha defesa e que muito auxiliará no que tange a área de inteligência computacional.

Aos professores Adriana Lourenço Soares, Alexandre Oba e Margarida Masami

Yamaguchi que foram incríveis na minha qualificação e que fizeram importantes considerações.

Ao Programa de Pós Graduação em Ciência Animal, a coordenadora desta, Ana Paula F. R. L. Bracarense e à Capes/PDSE, pela concessão da bolsa de estudos.

Agradeço à todos os professores do Departamento de Zootecnia da Universidade Estadual de Londrina, que contribuíram e auxiliaram minha formação acadêmica desde 2007.

À querida Sandra, secretária do Departamento de Zootecnia da Universidade Estadual de Londrina, por todo carinho, atenção e amizade! E também a Helenice, secretária da Pós Graduação em Ciência Animal, pela atenção e dedicação ao Programa.

Aos funcionários da Fazenda Escola da Universidade Estadual de Londrina, em especial ao sr. Pedro e Zé, os quais muito me ensinam e ajudam até hoje!

Aos técnicos do Laboratório de Nutrição Animal desta Universidade, Fernando Massaro e Tânia Milani.

Aos companheiros de trabalho no IRTA (Institut de Recerca i Tecnologia Agroalimentàries), onde tive a oportunidade de conviver com Maria Àngels Oliver, Isabel Díaz, Francesc Borrissier, Joel Gonzaléz, Maria Font i Furnols, Maria José Bautista Martínez, Marina Gispert, Marta Gil, Marta Gratacós, Mauro Vitale, Narcis Sais and Nuria Panella, com os quais aprendi muito! Experiência memorável!

À minha família espanhola de coração, Carlos López March, Adelaida Martín Cano e Ana Gabriela Torres, que me "adotaram" e tornaram minha passagem por Girona inesquecível. Gracias!

Aos meus amigos e companheiros de GPAC (Grupo de Pesquisa e Análise de Carcaças e Carnes)... são muitos, alguns já se formaram, não caberia o nome de todos, mas obrigada pela parceria de cada um!!! Em especial, quero dizer que foi muito bom dividir com a "galera" da pós tantos momentos de alegria e tensão desse doutorado! Obrigada Ana Paula Ayub da Costa Barbon, Barbara de Lima Giangareli, Camila Constantino, Camila Piechnicki Rogel, Évelyn Rangel dos Santos, Evelyn Stivalleti, Fernanda Lisboa, Guilherme Agostinis, Jéssica Gonçalves Vero e Marina Avena Tarsitano e Nayara Andreo.

Ao grupo REMID do departamento de Ciência da Computação, em especial a Estefânia Mayumi Fuzyi, Gabriel Filipe Centini Campos e Saulo Martiello Mastelini, que sempre foram muito solícitos inúmeras vezes!!!

Enfim, à todos amigos e familiares que torceram por mim!

“Para se ter sucesso, é necessário amar de verdade o que se faz. Caso contrário, levando em conta apenas o lado racional, você simplesmente desiste. É o que acontece com a maioria das pessoas”.

Steve Jobs

PERES, Louise Manha. **Inteligência computacional e lógica fuzzy na classificação da qualidade da carne suína**. 2018. 72 f. Tese (Doutorado em Ciência Animal) – Universidade Estadual de Londrina, Londrina. 2018.

RESUMO

A classificação da qualidade da carne suína é de extrema importância, uma vez que a partir desta podemos avaliar direta e indiretamente as ações tomadas na cadeia produtiva. Inúmeros são os padrões de classificação descritos na literatura, não havendo consenso entre eles no que se refere a quantidade de classes nem tampouco em relação aos limites entre classes. E estes limites são rígidos, ou seja, para uma amostra ser classificada ela tem que se encaixar numericamente nos limites máximo e mínimo de uma classe e por isso é comum haver amostras que não se enquadram em nenhuma classe devido aos fatores intrínsecos e extrínsecos que afetam a qualidade da carne, sendo nesta ocasião denominadas amostras não factíveis. "Qual padrão escolher para classificar a qualidade tecnológica da carne?" e "O que fazer para classificar uma amostra quando ela não se enquadra em nenhuma classe?". As soluções para esta problemática são apresentadas nos dois artigos que compõem esta tese. *ARTIGO I: "Meta-recommendation of pork quality standards"* - através da meta-recomendação, utilizando o algoritmo de árvore de decisão J48 obtivemos resultado de máximo desempenho para o meta-modelo, considerando as medidas de acurácia, coeficiente *kappa*, verdadeiro-positivo, falso-positivo, precisão, revocação e F-measure (média ponderada entre precisão e revocação). Sendo assim, é notória a contribuição destes resultados para direcionar com confiabilidade o padrão de qualidade de carne suína mais adequado a qualquer *dataset* em estudo. *ARTIGO II: "Fuzzy approach for classification of pork into quality grades: coping with unclassifiable samples"* - quando classificamos as amostras com a lógica clássica, segundo os limites rígidos dos padrões descritos, facilmente encontramos amostras não factíveis. Em função disto, muitos lotes de carne podem ser direcionadas para nichos de mercados não condizentes com suas características tecnológicas. Os resultados encontrados nesse artigo foram relevantes, pois a porcentagem de amostras não factíveis foi reduzida consideravelmente quando utilizada a lógica *fuzzy* em comparação a lógica clássica. Com este trabalho conseguimos preencher satisfatoriamente várias lacunas da classificação da qualidade da carne suína. Inicialmente fizemos a meta-recomendação do padrão mais adequado ao *dataset* e na sequência aplicamos a lógica *fuzzy* para aumentar a porcentagem de amostras classificáveis. Assim, é notória a contribuição da *lógica fuzzy* como uma ferramenta viável e

confiável para comercializar produtos cárneos estrategicamente em função de sua classe de qualidade.

PALAVRAS-CHAVE: Aprendizado de máquina. Árvore de decisão. Classes. Factíveis. Meta aprendizado. Padrões.

PERES, Louise Manha. **Computational intelligence and fuzzy logic in the pork quality classification**. 2018. 79 p. Thesis (Doctorate in Animal Science) - State University of Londrina, Londrina. 2018.

ABSTRACT

The pork quality classification is extremely important, since it allows us to directly and indirectly evaluate actions taken in the production chain. There are innumerable classification standards described in the literature, but no consensus about the quantity of classes and their threshold values. Moreover, the thresholds are inflexible, meaning that for a sample to be classified it has to fit numerically into the maximum and minimum thresholds of a class. However, it's common to have samples that do not fit in any class due to intrinsic and extrinsic factors that affect the pork quality, being in this occasion named infeasible samples. In this scenario, the questions "Which standard to choose in order to classify the pork quality?" and "What to do in order to classify a sample when it doesn't fit into any class?" arise. The solutions for these problems are presented in the two papers contained in this thesis. *PAPER I: "Meta-recommendation of pork quality standards"* - With the meta-recommendation, using the decision tree algorithm J48, we obtained maximum performance for the meta-model, considering the measures of accuracy, kappa coefficient, true-positive, false-positive, precision, recall and F-measure (weighted average between precision and recall). Thus, the contribution of these results is notorious for a reliable definition of the most adequate pork quality standard to any dataset under study. *PAPER II: "Fuzzy approach for classification of pork into quality grades: coping with unclassifiable samples"* - When we classify samples with the classical approach, according to the inflexible thresholds of the described patterns, we can easily find infeasible samples. As a consequence, many meat batches can be targeted to market niches that do not match with their technological characteristics. The results found in this article were relevant, since the percentage of infeasible samples was considerably reduced when using fuzzy logic in comparison to classical logic. Therefore, we were able to satisfactorily fill many gaps of the pork quality classification. We initially made the meta-recommendation of the most appropriate pattern to the dataset and subsequently applied the fuzzy logic to increase the percentage of classifiable samples. Hence, the contribution of the fuzzy logic is notorious as a viable and reliable tool to strategically market meat products in function of its quality class.

KEYWORDS: Class. Decision tree. Feasible. Machine learning. Meta learning. Standards.

LISTA DE FIGURAS

FIGURA 1 – Organização da revisão da tese	17
FIGURA 2 – Capacidade de retenção de água em função do pH	20
FIGURA 3 – Interconversões da mioglobina redox na superfície de carnes	21
FIGURA 4 – Áreas relacionadas à inteligência computacional	28
FIGURA 5 – Hierarquia do aprendizado de máquina	29
FIGURA 6 – Estrutura de uma árvore de decisão	31
FIGURA 7 – Processo de meta learning.....	32
FIGURA 8 – Função de pertinência a um dado conjunto <i>fuzzy</i>	34
FIGURA 9 – Representação gráfica e equação matemática sob o ponto de vista da lógica convencional (a) e da lógica <i>fuzzy</i> (b)	35
FIGURA 10 – Esquema de variável linguística e modificadores na lógica <i>fuzzy</i>	36
FIGURA 11 – Esquema de formação do raciocínio <i>fuzzy</i>	37

LISTA DE ABREVIATURAS

DE - *Dark, exudative*
PEE - *Pale, extremely exudative*
ANN - *Artificial Neural Networks*
ATP - *Trifosfato de adenosina*
CRA - *Capacidade de retenção de água*
DFD - *Dark, firm, dry*
DNE - *Dark, non-exudative*
DT - *Decison tree*
FP - *False positive*
FPW- *Filter paper wetness*
FRBS - *Fuzzy Rule-Based System*
IC - *Inteligência computacional*
IMP - *Monofosfato de iosina*
k-NN - *k-Nearest Neighbors*
ML - *Machine learning*
MtL - *Meta-learning*
NB - *Naïve Bayes*
PE - *Pale, exudative*
PFN - *Pale, firm, non-exudative*
pHu - *pH ultimate*
PNE - *Pale, non-exudative*
PSE - *Pale, soft, exudative*
RE - *Red, exudative*
REE - *Red, extremely exudative*
RF - *Random Forest*
RFN - *Red, firm, non-exudative*
RNE - *Reddish, non-exudative*
RSE - *Red, soft, exudative*
SVM - *Support Vector Machine*
TP - *True positive*
WHC - *Water holding capacity*

SUMÁRIO

1	INTRODUÇÃO	14
2	HIPÓTESE	16
3	OBJETIVOS	16
3.1	GERAL.....	16
3.2	ESPECÍFICOS.....	16
4	REVISÃO	17
4.1	QUALIDADE DE CARNE	17
4.1.1	Transformações <i>post mortem</i> e qualidade de carne.....	18
4.1.2	Classes de qualidade da carne suína.....	22
4.2	MOTIVAÇÃO PARA O ARTIGO 1: " <i>META-RECOMMENDATION FOR PORK QUALITY STANDARD</i> ".....	26
4.2.1	Inteligência Computacional.....	27
4.2.1.1	<i>Machine learning</i>	29
4.2.1.1.1	Árvore de decisão	30
4.2.1.3	<i>Meta-learning</i>	31
4.3	MOTIVAÇÃO PARA O ARTIGO 2: " <i>FUZZY APPROACH FOR CLASSIFICATION OF PORK INTO QUALITY GRADES COPING WITH UNCLASSIFIABLE SAMPLES</i> "	33
4.3.1	Lógica <i>fuzzy</i>	33
	REFERÊNCIAS	39
5	ARTIGO I - <i>Meta-recommendation for pork quality standard</i>	48
6	ARTIGO II - <i>Fuzzy approach for classification of pork into quality grades: coping with unclassifiable samples</i>	61
7	CONCLUSÃO GERAL	72

1 INTRODUÇÃO

Em 2017, o Brasil foi o quarto maior produtor e exportador de carne suína, produzindo 3.731 mil toneladas e exportando 19,6% da produção. Já o consumo *per capita* de carne suína no país foi de 14,4 kg (ABPA, 2017). Em face da importância do mercado da carne suína e do seu valor como alimento, a cadeia produtiva está cada vez mais preocupada com sua qualidade.

A qualidade da carne é dependente da interação dos fatores intrínsecos e extrínsecos aos animais (RAMOS, GOMIDE, 2007), sendo sua caracterização bastante ampla, abrangendo aspectos sensoriais (cor, suculência, sabor, odor, maciez), tecnológicos (pH, capacidade de retenção de água) e nutricionais (quantidade de gordura, perfil dos ácidos graxos, grau de oxidação, porcentagem de proteínas, vitaminas e minerais) (WARRIS et al., 1996; FAO, 2015).

Existem vários padrões de qualidade da carne suína descritos na literatura e há grande variação entre as classes, seja em quantidade e/ou limiares, os quais se apresentam fixos para cada parâmetro avaliado.

Assim, a meta-recomendação de padrões de qualidade de carne torna-se interessante, pois a escolha é fundamentada em modelo matemático, conferindo maior eficiência de classificação. A indicação do padrão mais adequado é realizado com a abordagem de *meta-learning*, apoiada pelo algoritmo de classificação árvore de decisão.

Entretanto, apesar da meta-recomendação do padrão de qualidade mais adequado, inevitavelmente constata-se a presença de amostras não factíveis (*infeasibles*), visto que a definição da qualidade tem comportamento não exato, ou seja, não apresenta limiares rígidos, o que dificulta sua classificação.

Para elucidar esse problema de amostras *infeasibles*, podemos fazer uso da lógica nebulosa (a qual será reportada neste trabalho como lógica *fuzzy*). Esta abordagem tem a capacidade de combinar a imprecisão associada aos eventos naturais, onde não existem somente respostas extremas (permitindo o meio termo, exemplo, graus de qualidade) e juntamente com a programação computacional das máquinas que permitem produzir sistemas de respostas inteligentes (COX, 1994).

Logo, a meta-recomendação e aplicação da lógica *fuzzy* para as amostras *infeasibles* podem ser consideradas como importantes ferramentas de gestão para apoiar

tomadas de decisão e/ou avaliação de processos (TRZESNIAK, 1998), principalmente por permitir uma definição mais precisa da qualidade da carne.

Com este trabalho, objetivou-se fazer a meta-recomendação do padrão de qualidade de carne suína mais adequado ao conjunto de dados em questão e para as amostras ditas *infeasibles*, aplicar a lógica *fuzzy*, tornando possível classificar maior porcentagem de amostras e com mais precisão.

2 HIPÓTESE

- ✓ A meta-recomendação é eficiente na indicação do padrão de qualidade de carne mais adequado para um determinado conjunto de dados através do algoritmo de classificação árvore de decisão (J48).
- ✓ O uso dos princípios da lógica *fuzzy* auxilia na identificação de amostras *infeasible*.

3 OBJETIVOS

3.1 GERAL

- ✓ Avaliar a eficiência de indicação do padrão de classificação de qualidade da carne suína mais adequado utilizando a meta-recomendação e classificar as amostras ditas *infeasibles* valendo-se da lógica *fuzzy*.

3.2 OBJETIVOS ESPECÍFICOS

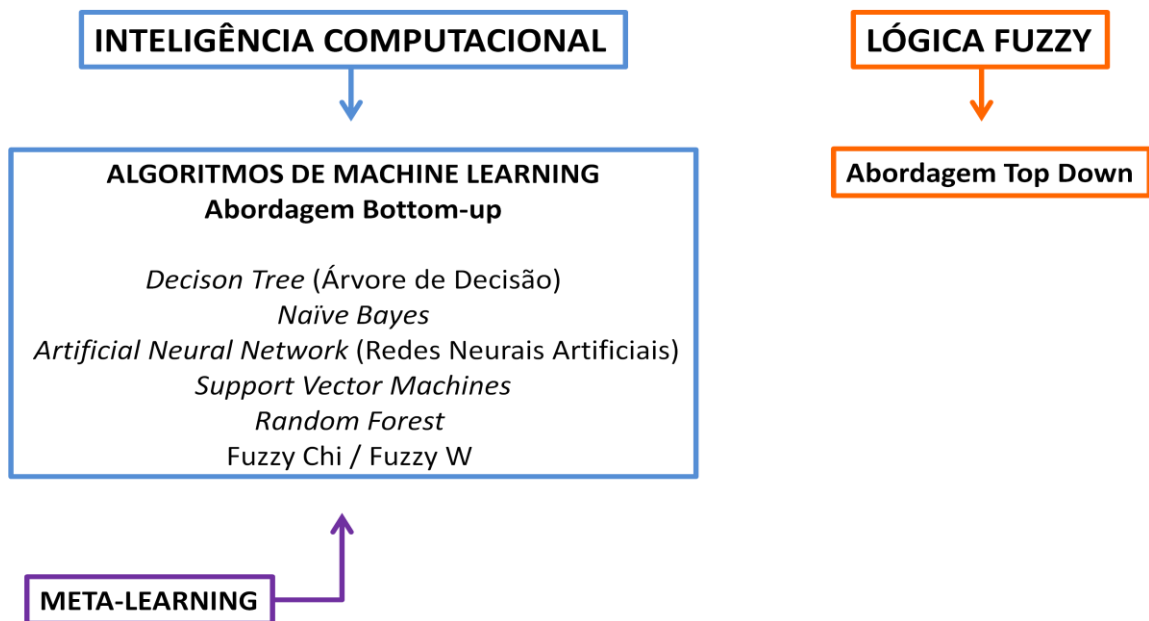
- ✓ Apurar a capacidade da meta-recomendação de identificar o padrão de qualidade de carne suína mais adequado para um *dataset* utilizando o algoritmo de classificação árvore de decisão (versão J48).
- ✓ Testar a lógica *fuzzy* com abordagem *top-down* para classificar as amostras de carne suína comparada à lógica clássica e abordagem *fuzzy bottom-up* e algoritmos de *machine learning*.

4 REVISÃO

A revisão da tese foi organizada de modo a facilitar a compreensão dos temas que norteiam os dois artigos que a compõem.

O primeiro artigo tem foco em inteligência computacional com ênfase em *meta-learning* e *machine learning*. Já o segundo artigo tem sua essência na lógica *fuzzy* e suas diferentes abordagens (*top-down* e *bottom-up*) (Figura 1)

FIGURA 1 - Organização da revisão da tese.



Fonte: O AUTOR

4.1 QUALIDADE DA CARNE

A qualidade da carne não possui uma definição única (COMA; PIQUER, 1999; FAO, 2014), por isso torna-se fundamental compreender e considerar as preferências regionais dos consumidores.

Genericamente, a percepção de qualidade ao nível do consumidor está vinculada ao preço, aparência da embalagem, cor, corte, teor de gordura e satisfação após a degustação (suculência, maciez e sabor), de modo a interferir na fidelização ou não ao produto (DAGUER, 2009).

Os fatores que resultam na qualidade estão relacionados com os atributos sensoriais (cor, sabor, odor, maciez, marmoreio), nutricionais (ácidos graxos, aminoácidos essenciais, vitaminas e minerais), higiênicos (contaminação por microrganismos patogênicos) e tecnológicos (parâmetros físico-químicos: pH, capacidade de retenção de água, oxidação lipídica, entre outros) (RODRIGUES, 2007).

Atributos sensoriais e tecnológicos são analisados em conjunto muitas vezes por estarem fortemente correlacionados, como poderemos constatar na sequência.

4.1.1 Transformações *post mortem* e qualidade de carne

Prontamente, após o abate dos animais, se iniciam muitas mudanças bioquímicas que ocorrem no período *post mortem* e que resultam na transformação do músculo em carne, caracterizado pelo estabelecimento do *rigor mortis* e da maturação natural da carne. Assim, o principal evento bioquímico que ocorre durante o estabelecimento do *rigor mortis* é a acidificação muscular, ou seja, alteração do pH (ZIMERMAN, 2008).

Com a morte do animal, não cessam repentinamente nos músculos todas as suas funções, por algum tempo se mantém no músculo os mesmos mecanismos aeróbicos do animal vivo (ARIMA, 2002).

Após cessar o suprimento de oxigênio, o metabolismo muscular energético torna-se anaeróbio, havendo produção de apenas 8% de ATP em comparação ao metabolismo aeróbico (ROÇA, 2015) e aumento da síntese e concentração de lactato (MORAES, 2004).

Ao se esgotar a reserva de fosfocreatina inicia-se o declínio do nível de ATP no músculo, pois as reservas de energia são degradadas rapidamente quando no metabolismo anaeróbico, exaurindo primeiro a creatinafosfato, seguida pelo glicogênio (que se degrada até ácido láctico e produz moléculas de ATP) e outros carboidratos e, finalmente o ATP (ROÇA, 2015).

Devido à glicólise e à hidrólise do ATP para obtenção de energia para manutenção da atividade muscular, geram-se íons H^+ , caracterizando a queda inicial do pH, que ocorre antes da transformação do piruvato em lactato (LAWRIE, 2005).

O pH é elementar para a qualidade da carne, apresentando influência em muitos parâmetros da qualidade, sendo que a sua velocidade de declínio e o valor final após o sacrifício dos animais afetam os parâmetros sensoriais e tecnológicos da carne (ZIMERMAN, 2008).

Alguns fatores interferem normalmente na queda do pH muscular. Dentre os fatores intrínsecos, destacam-se o tipo de fibra muscular (brancas: glicolíticas de contração rápida e anaeróbicas / vermelhas: oxidativas de contração lenta e aeróbicas), velocidade da decomposição das reservas de glicogênio, inativação das enzimas da cadeia respiratória que atuam como receptoras de hidrogênio, dentre outros; e a exemplo dos extrínsecos, o manejo pré-abate (da propriedade até o abate), temperatura de resfriamento, maturação, entre outros (ARIMA, 2002; MANTESE, 2002; MAGANHINI et al., 2007; LUDTKE, 2012).

Outro parâmetro de relevância para a qualidade da carne é a capacidade de retenção de água (CRA) e sua definição se refere à habilidade da carne em reter água durante a aplicação de força (compressão, *drip loss*, cisalhamento) ou tratamento externo (cocção, etc). Esta habilidade de reter água depende basicamente das condições em que se realiza a mudança de pH durante a transformação *post mortem* do músculo em carne, ou seja, se o pH se aproxima mais ou menos do ponto isoelétrico das proteínas (HUFF-LONERGAN, 2005; SILVA SOBRINHO et al., 2005; ROÇA, 2015). Tal parâmetro desperta o interesse de muitos estudos por influir no aspecto da carne antes do cozimento e no seu comportamento durante o processo de cocção, visto que apresenta correlação com a suculência da carne e derivados (PARDI et al., 2001).

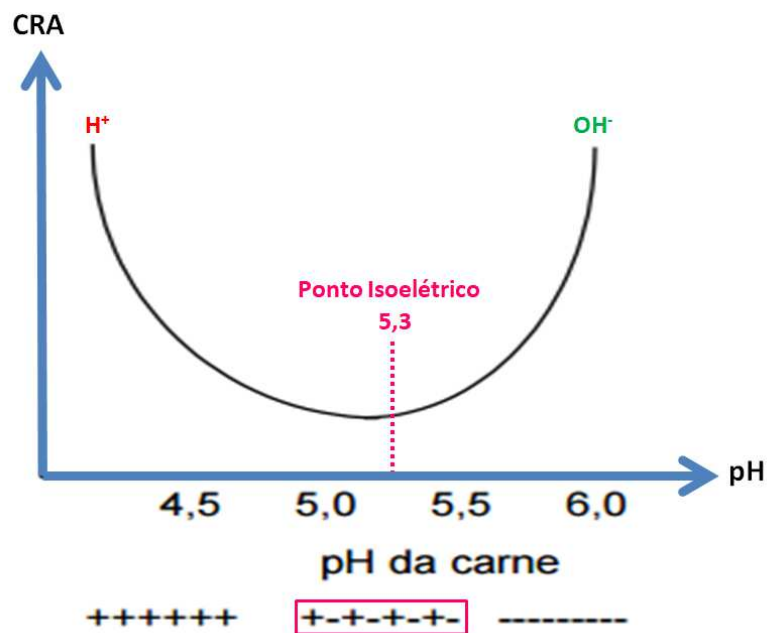
Em decorrência da queda do pH *post mortem*, há alteração da estrutura das fibras musculares, havendo desnaturação e perda de solubilidade das proteínas musculares, de maneira a influenciar na perda da capacidade de atrair água destas proteínas. E esta condição denomina-se efeito de carga neutra (ROÇA, 2015).

A água está no músculo sob três formas: imobilizada, ligada ou livre. Quando na forma imobilizada as moléculas de água se unem, perdendo a força entre suas ligações à medida que se distanciam dos grupos reativos de proteínas. Quando ligada, a molécula de água apresenta-se fortemente associada a grupos reativos de proteínas. Nestas condições, mesmo sob pressões externas, a água persiste no músculo. E, na forma livre, a ligação entre as moléculas de

água se dá por forças superficiais, sendo esta encontrada em maior porcentagem no músculo (ANNE, 2011).

A CRA é menor em pH que varia de 5,2-5,3, que corresponde ao ponto isoelétrico das proteínas miofibrilares. Todavia, quando o pH está acima do ponto isoelétrico, passa a ter excesso de cargas negativas, as quais determinam a repulsão dos filamentos, deixando maior espaço para as moléculas de água, aumentando a capacidade de retenção de água (GOMIDE; RAMOS; FONTES, 2013) (Figura 2).

FIGURA 2 - Capacidade de retenção de água em função do pH.



Fonte: Adaptado de GOMIDE; RAMOS; FONTES (2007).

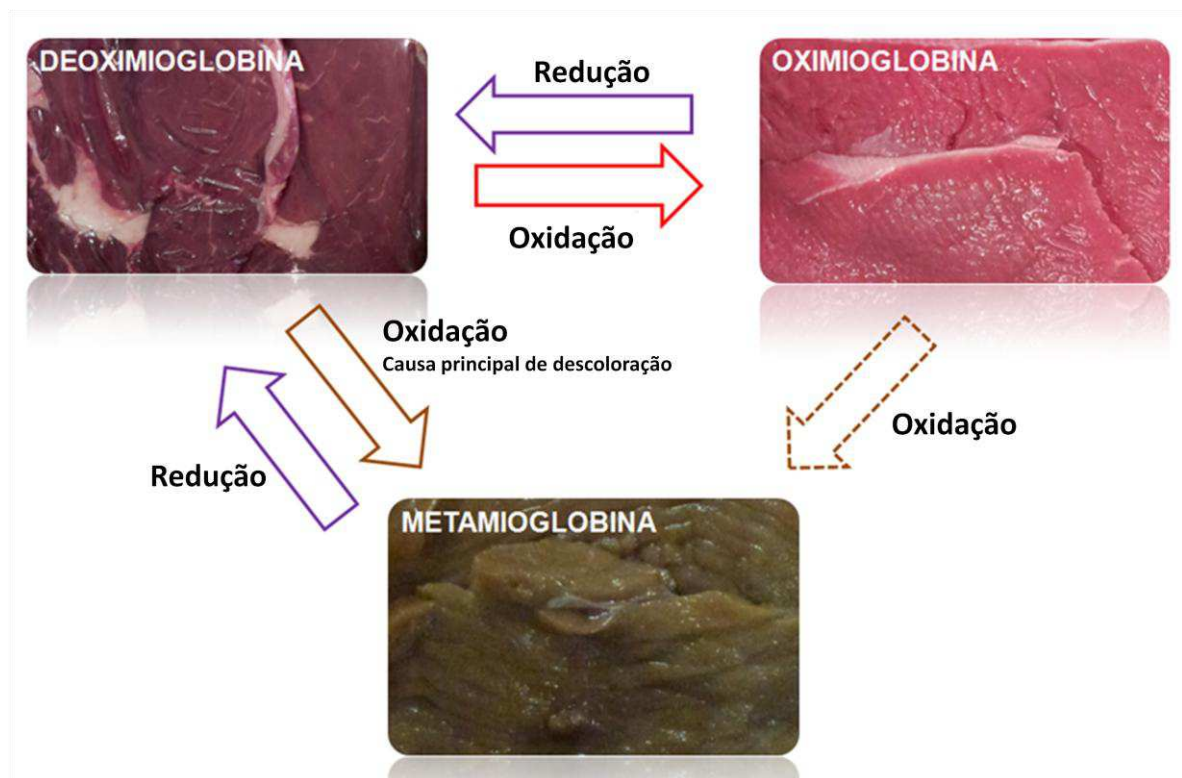
Já o atributo da cor é um dos que mais interferem na comercialização da carne, visto que a grande maioria dos consumidores considera o aspecto visual como fator preponderante para efetuar ou não a compra do produto, sendo a “medida” de qualidade mais óbvia para o consumidor (SARANTOPOULOS, PIZZINATTO, 1990).

A cor da carne está vinculada ao tipo de fibra muscular predominante, à quantidade de proteínas pigmentadas, citocromo, hemoglobina e mioglobina, sendo esta última encontrada em maior quantidade na carne e a principal responsável pela cor (MANCINI; HUNT, 2005).

A mioglobina tem um grupo heme, o qual contém uma molécula de ferro, que se liga ao oxigênio para transportá-lo ao organismo. O ferro contido no grupo heme se liga ao oxigênio, e pode assumir várias formas químicas, logo a quantidade de mioglobina e o estado de oxidação do ferro conferem a cor final da carne (RAMOS; GOMIDE, 2007).

A mioglobina pode se apresentar na forma reduzida de coloração vermelho púrpura, de oximioglobina com coloração vermelho brilhante, e metamioglobina de coloração marrom (SWATLAND, 2004) (FIGURA 3).

FIGURA 3 – Interconversões da mioglobina redox na superfície de carnes.



Fonte: Adaptado de VITALE (2015).

Além da forma da mioglobina, deve-se também considerar a capacidade de retenção de água, já que a luz é refletida não somente na camada externa da carne, mas também dentro do tecido muscular (ADZITEY; NURUL, 2011).

Muitos fatores afetam a cor da carne, além do pH e da CRA, a exemplo das condições de abate (manejo pré-abate, susceptibilidade do animal ao estresse, etc), falta de

higiene no abate e no manuseio dos cortes durante a desossa (maximizando a probabilidade de contaminação microbiana), temperatura de armazenamento, intensidade e tipo de luz nas gôndolas, dentre outros (GALLO, 2006).

Utilizando os parâmetros de pH, capacidade de retenção de água e cor, é possível caracterizar a qualidade da carne suína em classes, segundo algumas metodologias propostas. Estas classificações apesar de compartilharem da mesma ideologia, por considerarem o pH, CRA e/ou cor para classificar a qualidade da carne, apresentam falta de consenso quando referem-se aos limites e quantidade de classes.

A resultante bioquímica dessas classes é importante para a indústria da carne, pois, dependendo da classe, a comercialização deve ser diferenciada (*in natura*, elaboração de produtos - cozidos ou curados) (COMA; PIQUER, 1999).

4.1.2 Classes de qualidade da carne suína

Considerando a variabilidade da qualidade da carne suína, muitos padrões de classificação da qualidade foram propostos ao longo do tempo a fim de mensurá-la (ADORNI; BIANCHI; CAGNONI, 2001; BAUER et al., 2013)

Algumas variações independentes ocasionam uma avaliação imprecisa da qualidade da carne, embora grande parte destas possam ser explicadas pela correlação evidente entre os principais parâmetros que compõem os padrões de qualidade (pH, capacidade de retenção de água e cor) (WARRISS; BROWN, 1987; VAN LAACK et al., 1994), sendo essa uma interpretação para o fato que a maioria dos padrões descritos na literatura fazem uso destes parâmetros.

Há certa divergência entre os padrões de qualidade descritos, pois estes variam em quantidade de classes e limites (TABELA 1), como as classes RFN, PSE, RSE, PFN e DFD.

TABELA 1 – Levantamento de padrões de qualidade da carne suína e suas classes - DFD (dark, firm, dry); DE (dark, exudative); DNE (dark, non-exudative); PE (Pale, exudative); PEE; (Pale, extremely exudative); PFN (Pale, firm, non-exudative); PNE (Pale, non-exudative); PSE (Pale, soft, exudative); RE (red, exudative); REE (red, extremely exudative); RFN (red, firm, non-exudative); RNE (reddish, non-exudative) and RSE (red, soft, exudative).

ANO	REFERÊNCIA	CLASSE	pH		Perda de água		L*	
			45'	24h	DL*	FPW*	Minolta	Hunter
1993	KAUFFMAN et al.	PSE			>5,0			>58
		RSE			>5,0			52-58
		PFN			<5,0			> 58
		RFN			<5,0			52-58
		DFD			<5,0			<52
1994	SANTOS et al.	Extremely PSE	<5,9		>5,0			>53
		PSE	<5,9		>2,0			>53
		Likely PSE	<5,9		>2,0			
		Normal			<2,0			
		DFD		>6,0				
		DNE			>2,0			<47
		RNE			<2,0			>47 <56
		PNE			<2,0			>56
		DE			>2,0			<47
		RE			>2,0			47 ≤ L* ≤ 56
		REE			>5,0			47 ≤ L* ≤ 56
		PE			>2,0			>56
		PEE			>5,0			>56
1996	VAN LAACK et al.	PSE		<5,5	>5,0			>50
		RSE		<5,9	>5,0			43-49
		RFN		5,4-6,0	<5,0			43-49
		DFD		>6,0	<2,0			<43
1997	WARNER et al.	PSE		<6,0	>5,0			>50
		RSE		<6,0	>5,0			42-50
		RFN		<6,0	<5,0			42-50
		DFD		≥6,0	<5,0			<42
1999	JOO et al.	PSE			>6,0			>50
		RSE			>6,0			≤50
		RFN			≤6,0			≤50
		DFD			<6,0			<43

1999	VAN LAACK et al.	PSE	>6	>50	
		RSE	>6	<50	
		RFN	<6	<50	
2000	JOO et al.	PSE	≥6	≥50	
		RSE	≥6	≤50	
		RFN	≤6	≥43	
		DFD	≤6	≤43	
2007	MAGANHINI et al.	PSE		>53	
		Normal		45 ≤ L* ≤ 53	
		DFD		<45	
2010	FAUCITANO et al.	PSE	<6,0	≥80	>50
		PFN	<6,0	<80	>50
		RSE	<6,0	≥80	43-48
		RFN	<6,0	<80	43-48
		DFD	≥6,0	<40	<42
2012	BARBIN et al.	PSE	<6	>5	>50
		RFN	<6	<5	44-50
		DFD	≥6,0	<5	<44

*DL (% - drip loss), FPW (mg - filter paper wetness)

Diante deste cenário de classes de qualidade, é inevitável não associá-las aos termos de melhor ou pior qualidade, entretanto devemos reiterar a afirmação de BAUTISTA; RINCÓN (2010): "(...) é fundamental considerar a aptidão da carne".

Por exemplo, a matéria-prima poderá ser destinada para consumo *in natura*, elaboração de produtos cozidos ou curados, em função de suas características de qualidade, logo, tudo é uma questão de direcionamento de nichos de mercado

A classe RFN (*red, firm e non-exudative*) detém as características de qualidade desejável para a carne suína fresca, tipicamente descrita pela coloração rosa-avermelhada, de textura firme e livre de exsudato na superfície do corte cárneo. Essas características são de extrema importância no momento da compra, influenciando fortemente na decisão de compra e fidelização ao produto (BUEGE, 2001; XING et al.; 2007).

Já as classes PSE (*Pale, soft, exudative*) e DFD (*dark, firm, dry*) são exemplos extremos de qualidade da carne e, além desses extremos, existem as classes intermediárias, como PFN (*Pale, firm, non-exudative*) e RSE (*red, soft, exudative*) (SCHEIER, 2014). Essas classes resultam em carnes de aspecto pouco atrativo e por esse motivo, podem ser discriminadas no momento da compra ou como matéria-prima, no caso de elaboração de produtos (VILJOEN; KOCK; WEBB, 2002).

O fator mais comum que resulta em carnes PSE ou DFD é o estresse *ante mortem*, o qual afeta diretamente o comportamento da queda do pH muscular, influenciando o parâmetro de CRA e por consequência a coloração (SHAW; TUME, 1992).

A exposição de animais ao estresse agudo imediatamente antes do abate pode ocasionar carnes de qualidade PSE. Situações estressantes, de maneira geral, aceleram a velocidade da glicólise, aumentando além do normal a concentração de ácido láctico no músculo, resultando em pH mais baixo ($\approx <5,5$) em 45 minutos *post mortem*.

A combinação de pH baixo e elevada temperatura da carcaça, imediatamente após o abate, leva à desnaturação das proteínas musculares, assim reduzindo a capacidade de retenção de água e consequentemente torna sua coloração mais clara (HUFF-LONERGAN; SOSNICKI, 1988).

Por outro lado, quando os animais estão expostos ao estresse crônico antes do abate pode ocorrer carnes DFD, visto que o elevado gasto energético *ante mortem* minimiza consideravelmente as reservas de glicogênio. Logo, a baixa produção de ácido láctico, resulta em pH elevado ($\approx >6,0$). A carne que tem pH final alto tende a ter cor mais escura e a superfície relativamente seca (HUFF-LONERGAN; LONERGAN, 2005; MAGANHINI et al., 2007; ADZITEY; NURUL, 2011).

As carnes PSE e DFD são perfeitamente adequadas para consumo humano, apesar do aspecto menos atraente ao consumidor quando na forma *in natura*. Logo, o emprego dessas carnes para elaboração de produtos cárneos é uma questão de aptidão, segundo as características tecnológicas.

A carne PSE apresenta grande perda da capacidade de retenção de água, acarretando maior perda de peso e consequentemente menor rendimento tecnológico por ocasião da industrialização. Já a carne DFD exprime comportamento inverso, com elevada capacidade de retenção de água, sendo portanto inadequada para a elaboração de salame e presunto cru (TERRA; FRIES, 2000).

As classes intermediárias RSE e PFN foram incluídas no processo de classificação da qualidade da carne devido à inconsistência do comportamento dos parâmetros de capacidade de retenção de água e de cor em relação as carnes PSE ou DFD (VAN LAACK et al., 1996). Apesar de muitos estudos, não foi possível esclarecer os mecanismos responsáveis pela ocorrência de carne suína RSE e PFN (KAUFFMAN, 1993). Mas, ao fazer uma compilação dos resultados descritos na literatura, podemos propor algumas explicações para as classes em questão.

Ao comparar carnes PSE e PFN, verificou-se que o pH final de carnes não difere entre elas (FAUCITANO et al., 2010), entretanto carnes PFN possuem Valor de R inferior as carnes PSE (VAN LAACK et al.; 1994).

O Valor de R permite mensurar a velocidade de depleção do ATP após a primeira hora de abate por meio da relação [MONOFOSFATO DE IOSINA]/ [TRIFOSFATO DE ADENOSINA]. Quanto maior o Valor de R, maior será a depleção de ATP (Se >1,05: carne susceptível a anomalia do tipo PSE / Se <1,05 até 0,8: carne normal).

Ao comparar carnes PFN e RFN, uma possível explicação para a diferenciação entre ambas pode ser devido a maior desnaturação das proteínas miofibrilares nas carnes PFN, resultando em capacidade de retenção de água inferior em comparação a uma amostra RFN. Sob essas condições, a perda de mioglobina via exsudado é maximizada, justificando a carne PFN ser mais pálida que uma carne RFN.

XING et al. (2007), usando espectroscopia visível, verificaram menor refletância em 560 nm para amostras do grupo FN (*firm, non-exudative* - PFN e RFN) em comparação com o grupo SE (soft e exsudativa - PSE e RSE). De acordo com BRØNDUM et al. (2000) e LIU et al. (2010) a menor refletância a 560 nm pode ser explicada pela concentração de mioglobina na amostra, logo, o grupo FN parece ter maior concentração de mioglobina.

Já as carnes RSE possuem as mesmas características que a PSE, exceto pela coloração. Teoricamente, podemos presumir que a carcaça RSE foi refrigerada rapidamente após o abate, ocasionando "escurecimento" da carne (L^* inferior ao da carne PSE).

Nestas condições, a luz não é tão severamente dispersa quanto em condições mais severas (PSE), portanto, a carne RSE parece mais vermelha, apesar do nível similar de desnaturação proteica em relação as amostras PSE (FEINER, 2016).

4.2 MOTIVAÇÃO PARA O ARTIGO 1: "*META-RECOMMENDATION FOR PORK QUALITY STANDARD*"

É nítida a dificuldade de padronizar a qualidade da carne suína em função dos distintos padrões descritos em literatura, porém, sem um consenso mundial de qual seria mais adequado.

Assim, vislumbramos uma alternativa para essa problemática, inspirados nos princípios de *meta-learning* em associação com *machine learning*, ou seja, ao invés de

testar vários algoritmos e recomendar o algoritmo mais adequado para resolver o problema de classificação, optamos por utilizar diretamente o algoritmo árvore de decisão (J48), mas utilizando os *meta-features* no lugar dos parâmetros típicos de qualidade de carne (pH, CRA e L*).

4.2.1 Inteligência Computacional

"Como fazer as máquinas compreenderem as coisas?" (MINSKY, 1968).

A resposta para essa pergunta surgiu em meados de 1950, época em que se desenvolveu umas das ciências mais recentes: a Inteligência Artificial (IA). Atualmente também referida como Inteligência Computacional (IC) (GOLDSCHMIDT, 2010).

Existem muitas definições para a IC, dentre elas a descrição feita por Coppin (2004) - "... envolve o uso de métodos baseados no comportamento inteligente de humanos e outros animais para resolver problemas complexos" e Goldschmidt (2010) - "Ciência multidisciplinar que busca desenvolver e aplicar técnicas computacionais que simulem o comportamento humano em atividades específicas".

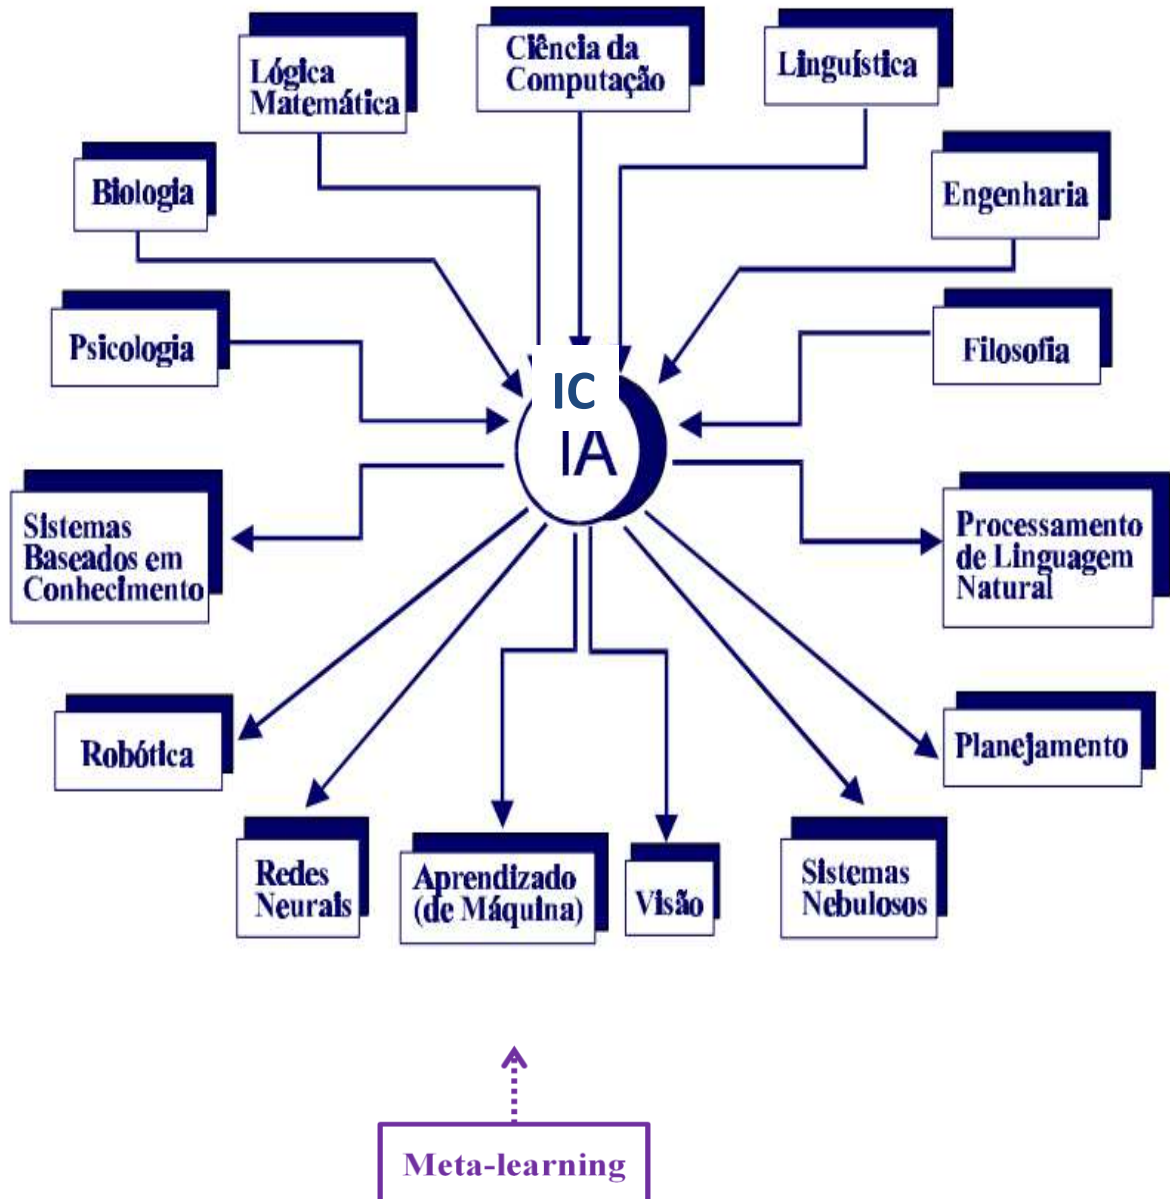
E por que é importante que as máquinas compreendam as coisas?

Os humanos são influenciados por elementos externos, sujeito a emoções, pressões, dentre outros fatores, interferindo diretamente a execução das tarefas, sendo assim, se houver uma "ferramenta" que não sofra influência do meio, certamente será mais precisa e amplamente aplicada. E este é o caso da IC, que se defronta com o conhecimento de forma consistente e permanente, sem interferência externa, mas permitindo a interação máquina-homem ou máquina-ambiente (GOLDSCHMIDT, 2010). Por essa razão, independente dos campos de aplicação da IC (agropecuária, hospitais, indústrias, frigoríficos, transporte, etc) é notória sua crescente utilização (LANZILLOTTI; LANZILLOTTI, 1999; STATHAKIS; VASILAKOS, 2006; VENDITE; ALONSO, 2007; WANG, 2010; VÁSQUEZ VILLALOBOS et al., 2015; KAMRUZZAMAN et al., 2016).

A maneira eficiente com que as implementações de IC auxiliam ou até substituem o homem em tarefas de aprendizagem, diagnóstico, predições, reconhecimento de padrões, automação de processos, controle de qualidade, dentre outros que contribuem para o cenário descrito acima (QUAGLINI et al., 1998).

A IC se divide em várias subáreas (FIGURA 4), entretanto, neste trabalho, iremos apenas abordar *machine learning*, *meta learning* e *lógica fuzzy*.

FIGURA 4 - Áreas relacionadas a inteligência computacional.



Fonte: Adaptado de MONARD; BARANAUSKAS (2000).

4.2.1.1 Machine learning

O aprendizado de máquina (do inglês, *machine learning* - ML) visa elucidar problemas do mundo real através do desenvolvimento de modelos matemáticos, os quais são gerados a partir de diversos algoritmos e técnicas computacionais (ROZA, 2016).

Esses modelos devem permitir que o computador adquira conhecimento de forma automática a partir de exemplos históricos, aperfeiçoando seu desempenho em determinada tarefa. Chamamos de exemplo histórico um conjunto de dados de determinadas características (parâmetros), o qual deve descrever o problema em questão (GOLDSCHIMIDT, 2010).

O aprendizado computacional pode ser feito de algumas maneiras, uma delas é a indução, onde, o aprendiz aprende a partir dos exemplos externos fornecidos a ele. Pode-se denominar de aprendiz um algoritmo de aprendizado, que por sua vez, estão divididos em supervisionado e não supervisionado (FIGURA 5).

FIGURA 5 - Hierarquia do aprendizado de máquina



Fonte: VOLPI (2015)

Aprendizado não supervisionado: onde os dados são classificados por similaridade entre si, ou seja, se agrupam em um mesmo grupo (*cluster*) e quando diferentes, organizam-se em grupos distintos (DUDA; HART, STORK, 2001).

Aprendizado supervisionado: trabalha-se com o registro dos valores das variáveis de saída, sendo estas as variáveis que se deseja prever a partir dos dados existentes, de modo que representem a resposta para algum problema (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2007).

Dentre os algoritmos de aprendizado supervisionado, podemos destacar *Decision Tree* (Árvore de Decisão), *Naïve Bayes*, *Artificial Neural Network* (Redes Neurais Artificiais), *Support Vector Machines* (SVM), *Random Forest* (RF), entre outros (BREIMAN, 2001; KAVZOGLU; COLKESEN, 2009; GOKGOZ; SUBASI, 2015; TARAVAT et al., 2015; LIU et al., 2016).

4.2.1.1.1 Árvore de decisão

As árvores de decisão são extensamente utilizadas como algoritmo de classificação, visto que a representação do conhecimento é simples, através da construção de classificadores, facilitando a compreensão dos resultados (KINGSFORD; SALZBERG, 2018). Estas são representações simples do conhecimento e, correspondem a um meio eficiente de construir classificadores que preveem classes baseadas nos valores de parâmetros de um conjunto de dados (GOLDSCHMIDT, 2010).

A construção do modelo de classificação inicia-se analisando um conjunto de exemplos de treinamento para os quais os rótulos das classes são conhecidos. Posteriormente, estes são aplicados para classificar exemplos anteriormente não vistos. Vale ressaltar que quanto maior for a qualidade dos dados de treinamento, mais precisa será a precisão da tomada de decisão ao selecionar a classe (KINGSFORD; SALZBERG, 2018).

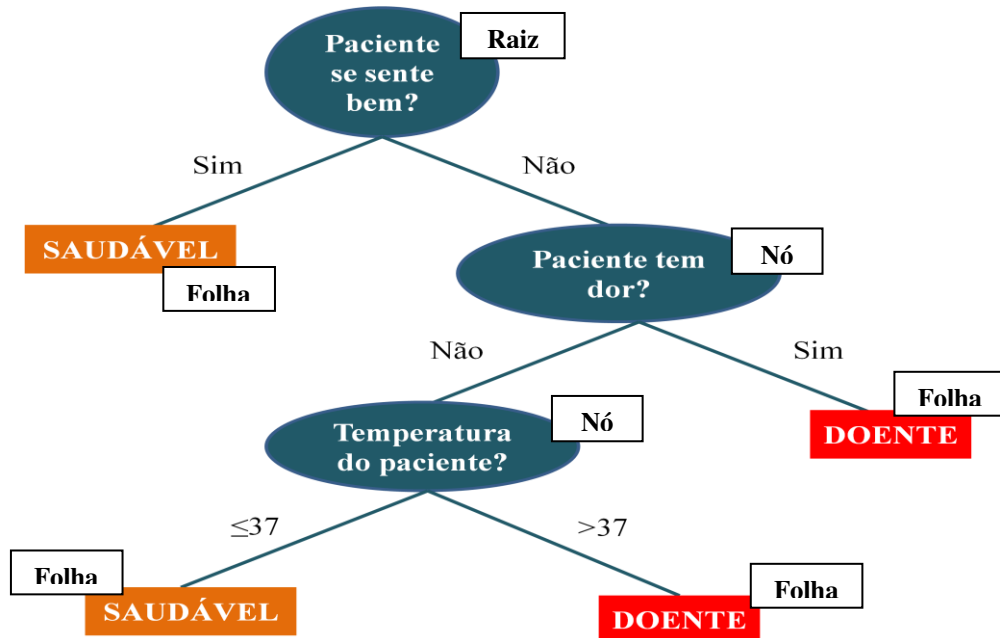
Constroem-se as árvores de decisão a partir de uma sequência ordenada de perguntas, e as perguntas subsequentes, dependem das respostas das perguntas anteriores e esta sequência de perguntas termina quando há previsão de uma classe.

A árvore de decisão é composta por raiz, nó interno (nó de decisão), ramo e folha (FIGURA 6).

A raiz é o conjunto total dos dados a serem classificados, após segue o nó interno (nó de decisão), que testa um atributo, seguido pelo ramo descendente que coincide com o possível valor do parâmetro e, por fim, a folha, que representa a classe do parâmetro (SONG;

YING, 2015). Logo, a regra de classificação de um parâmetro é dada pelo caminho percorrido da raiz até a folha.

FIGURA 6 – Estrutura de uma árvore de decisão



Fonte: Adaptado de MONARD; BARANAUSKAS (2003)

4.2.1.2 Meta-learning

Pensando em recomendação de sistemas, por exemplo, classificar a qualidade da carne através de algoritmo de classificação, remete a dúvida que foi enunciada por Rice (1976): "Qual é o algoritmo que mais provavelmente tem o melhor desempenho para o meu problema?"

Uma alternativa seria avaliar isoladamente cada um dos algoritmos disponíveis, analisar os resultados e por fim recomendar o algoritmo que obteve melhor desempenho. Todavia, essa é uma abordagem cara, em relação ao gasto de tempo e recursos computacionais. Mas existe uma outra alternativa para tal tarefa, uma solução automática para seleção de algoritmos e que supera as desvantagens citadas acima e que se denomina *meta-learning* (MtL) (CUNHA; SOARES; CARVALHO, 2018).

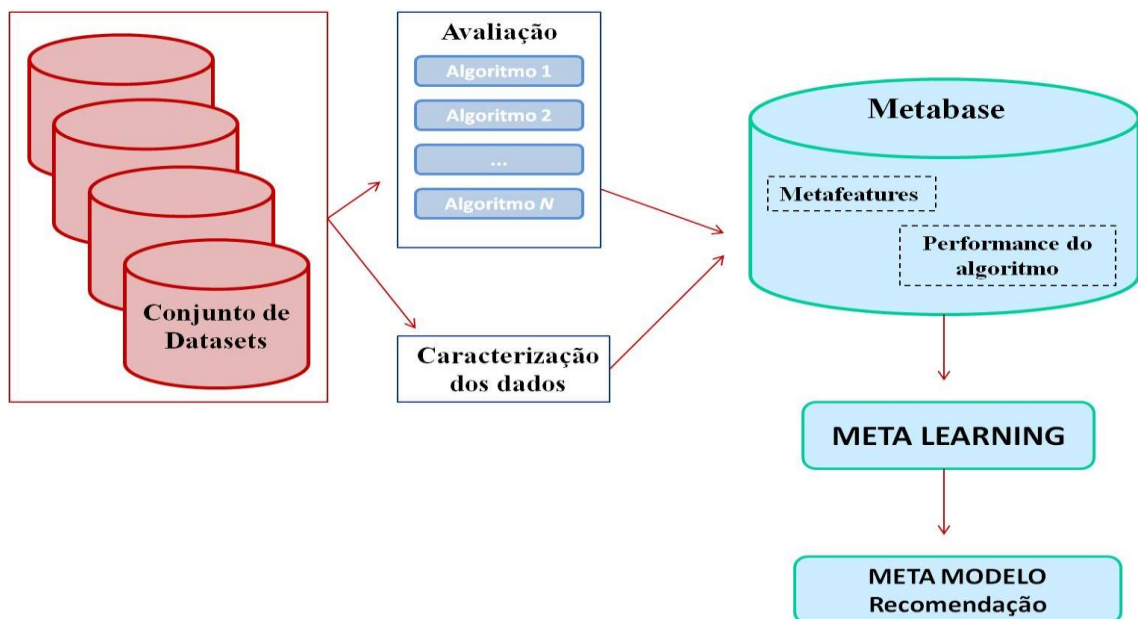
O MtL produz um meta modelo, que pode ser visto como um meta conhecimento, capaz de explicar porque certos algoritmos podem ser melhores que outros em *datasets* com características específicas, sendo assim, o meta modelo pode ser usado para prever o algoritmo mais adequado para resolver uma tarefa de um novo *dataset* (SERBAN et al., 2013) (FIGURA 7). E a obtenção do meta-modelo pode ser descrita em 3 passos:

1º - Aquisição dos dados para formação dos *datasets*.

2º - A partir dos *datasets* faz-se a extração dos *meta-features* utilizando meta-descritores, já descritos em literatura (MANTOVANI et al., 2015) e cada *dataset* passa a representar uma instância, que por sua vez é composta pelos *meta-features* (Exemplo: valores máximos e mínimos, Kurtosis, Skewness, entre outros).

3º - O conjunto de instâncias representa a meta-base, que após utilizar alguns dos algoritmos disponíveis, gera o meta-modelo, capaz de fazer as previsões/recomendações para dada tarefa/problema.

FIGURA 7 – Processo de *meta-learning*



Fonte: Adaptado de CUNHA; SOARES; CARVALHO (2018)

4.3 MOTIVAÇÃO PARA O ARTIGO 2: "FUZZY APPROACH FOR CLASSIFICATION OF PORK INTO QUALITY GRADES COPING WITH UNCLASSIFIABLE SAMPLES"

Após a recomendação do padrão mais adequado para classificar a qualidade da carne, passamos a uma segunda instância de resolução de problemas, que são as amostras que não se enquadram em nenhuma classe, denominadas de não factíveis (*infeasible*). E o caminho para solucionar este problema é a lógica *fuzzy*.

4.3.1 LÓGICA FUZZY

A identificação precisa dos "defeitos" de qualidade é fundamental para classificar corretamente a matéria-prima e destiná-la ao mercado mais adequado para seu uso final (XING et al., 2007; CHMIEL; SŁOWIŃSKI, 2016).

Mas, apesar da criação de novas classes para tentar solucionar o problema de amostras ditas não factíveis, o mesmo ainda persiste, pois os intervalos dos parâmetros são estabelecidos por conjuntos rígidos (*crisp*), o que torna difícil a classificação de amostras que não se encaixam perfeitamente no intervalo esperado do parâmetro, sendo uma transição abrupta entre uma classe e outra.

Neste caso, muitas vezes para solucionar problemas que se mostram imprecisos e com dualidades se faz necessária a utilização de sistemas complexos. Baseado neste raciocínio, juntamente com a lógica clássica, desenvolvida por Aristóteles, Lofti Asker Zadeh criou em 1965 o conceito *Fuzzy Sets* e publicou o artigo intitulado *Fuzzy Sets* no *Journal Information and Control*, o qual foi responsável por tornar a lógica *fuzzy* (nebulosa) conhecida mundialmente (AGUADO; CANTANHEDE, 2010; RIGNEL et al., 2011, SANT'ANNA, 2015).

Segundo Cox (1995), a lógica *fuzzy* é capaz de combinar a imprecisão associada aos eventos naturais e o poder computacional das máquinas para produzir sistemas de resposta inteligentes, robustos e flexíveis.

Devido ao desenvolvimento e as inúmeras possibilidades práticas dos sistemas "fuzzy", além do grande sucesso comercial de suas aplicações, a lógica "fuzzy" é

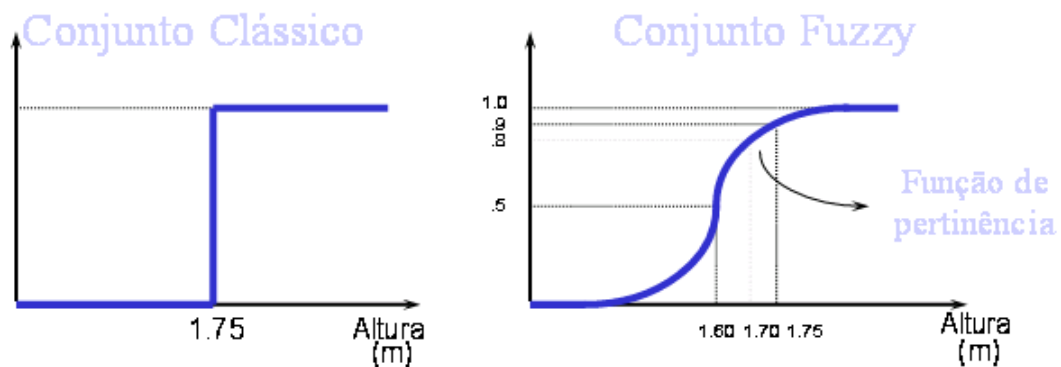
considerada hoje uma técnica “standard” e tem uma ampla aceitação na área de controle de processos industriais (ABAR, 2004).

Existe uma gama de atividades empresariais em que é possível a aplicação de lógica *fuzzy*, dentre elas está o controle de qualidade e a classificação de produtos (VON ALTROCK, 1996).

A lógica *fuzzy* permite o desenvolvimento de sistemas que representam decisões humanas, onde a lógica clássica (booleana) e a matemática convencional são insuficientes ou ineficientes nas tomadas de decisão (VON ALTROCK, 1996).

A principal diferença entre a lógica clássica (*crisp*) e a lógica *fuzzy* está no intervalo que cada uma delas tem como valores verdadeiros ou valores respostas, enquanto a lógica clássica propõe que esses valores sejam verdadeiros ou falsos, a lógica *fuzzy* propõe que isso seja uma questão de grau (grau de pertinência), de forma que somente a resposta *contido* ou *não contido* não satisfaz, então se busca saber o *quão contido* ou o *quão não contido* está determinado elemento (KLIR, 1995) (FIGURA 8).

FIGURA 8 – Função de pertinência a um dado conjunto *fuzzy*.

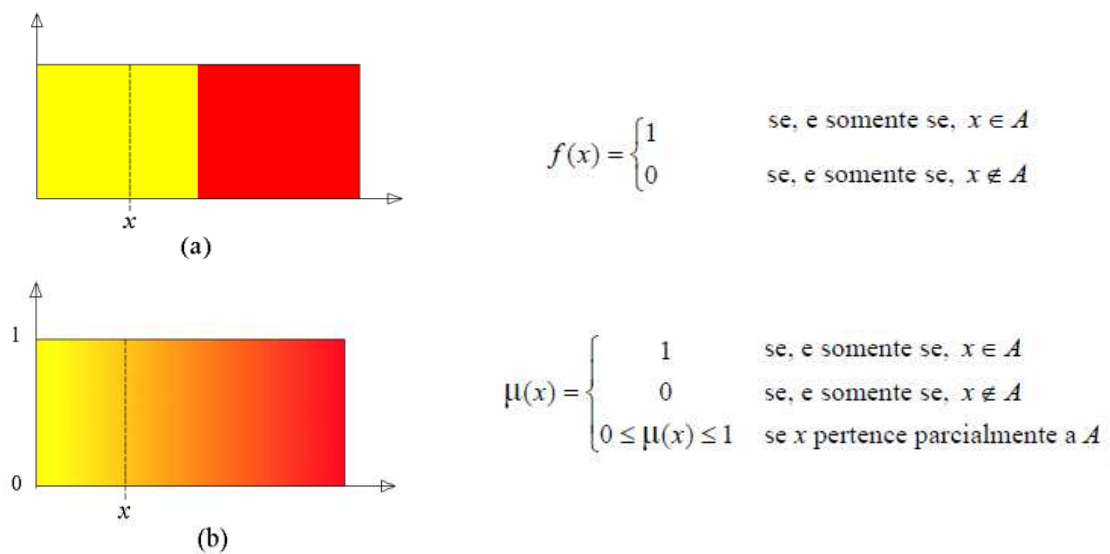


Fonte: SALOMÃO (2007)

Conforme Marro et al. (2010), pode-se considerar a lógica *fuzzy* como um conjunto de princípios matemáticos para a representação do conhecimento baseado no grau de pertinência dos termos (graus de verdade) e estes conjuntos *fuzzy* que classificam os elementos de um dado universo, são menos rígidos do que aqueles utilizados na teoria clássica, visto que eles admitem graus parciais de pertinência.

A compreensão do que é o grau de pertinência, pode ser observada pela expressão da Figura 9. Na expressão (b), o intervalo de pertinência é $[0,1]$, onde 0 significa que um elemento não pertence a um determinado conjunto, 1 significa completa pertinência ao conjunto, e valores entre 0 e 1 representam graus parciais de pertinências, logo, um elemento pertence a um conjunto com um certo grau de pertinência, fazendo com que uma determinada sentença possa ser parcialmente verdadeira e parcialmente falsa (MARRO et al., 2010).

FIGURA 9 – Representação gráfica e equação matemática sob o ponto de vista da lógica clássica (a) e da lógica *fuzzy* (b).



Fonte: SANCHEZ (2009); MARRO et al. (2010).

Na lógica *fuzzy* utilizam variáveis linguísticas, cujos valores são nomes de conjuntos *fuzzy*, cuja principal função é fornecer de uma maneira sistemática a caracterização aproximada de fenômenos complexos ou mal definidos (BRITO, 2015), como exemplo, idade, qualidade, altura, etc.

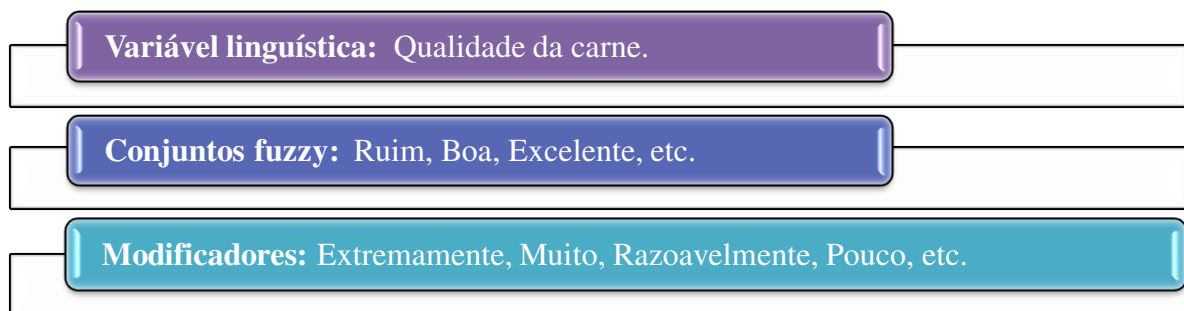
Os valores das variáveis linguísticas são obtidos por intermédio de uma linguagem específica, construídas a partir de termos primários (alto, baixo, pequeno, médio, grande, zero, por exemplo), conectivos lógicos (e; ou), delimitadores (como parênteses) e modificadores (“sinônimo” de qualificadores do conjunto *fuzzy*), a fim de alterar a intensidade em que certo elemento que faça parte de um determinado conjunto, ou seja, “atuam” na

modelagem de sistemas *fuzzy* da mesma forma que advérbios e adjetivos atuam em uma sentença (GANGA et al., 2011; BRITO, 2015).

Os modificadores, também referidos como *hedges*, podem ser: intensificadores - muito, extremamente, diluidores - pouco, mais ou menos e aproximadores - em torno, aproximadamente, quase, etc.

Assim, o uso das variáveis linguísticas e dos modificadores faz com que a modelagem do sistema *fuzzy* pode apresentar algo muito mais próximo do mundo real (MORAES, 2015) (FIGURA 10).

FIGURA 10 – Esquema de variável linguística e modificadores na lógica *fuzzy*



Fonte: O AUTOR

E as etapas para modelar um sistema lógico *fuzzy* são a fuzzificação do conjunto de entrada de dados *crisp*, inferência e defuzzificação/agregação para saída de dados *crisp* (FIGURA 11).

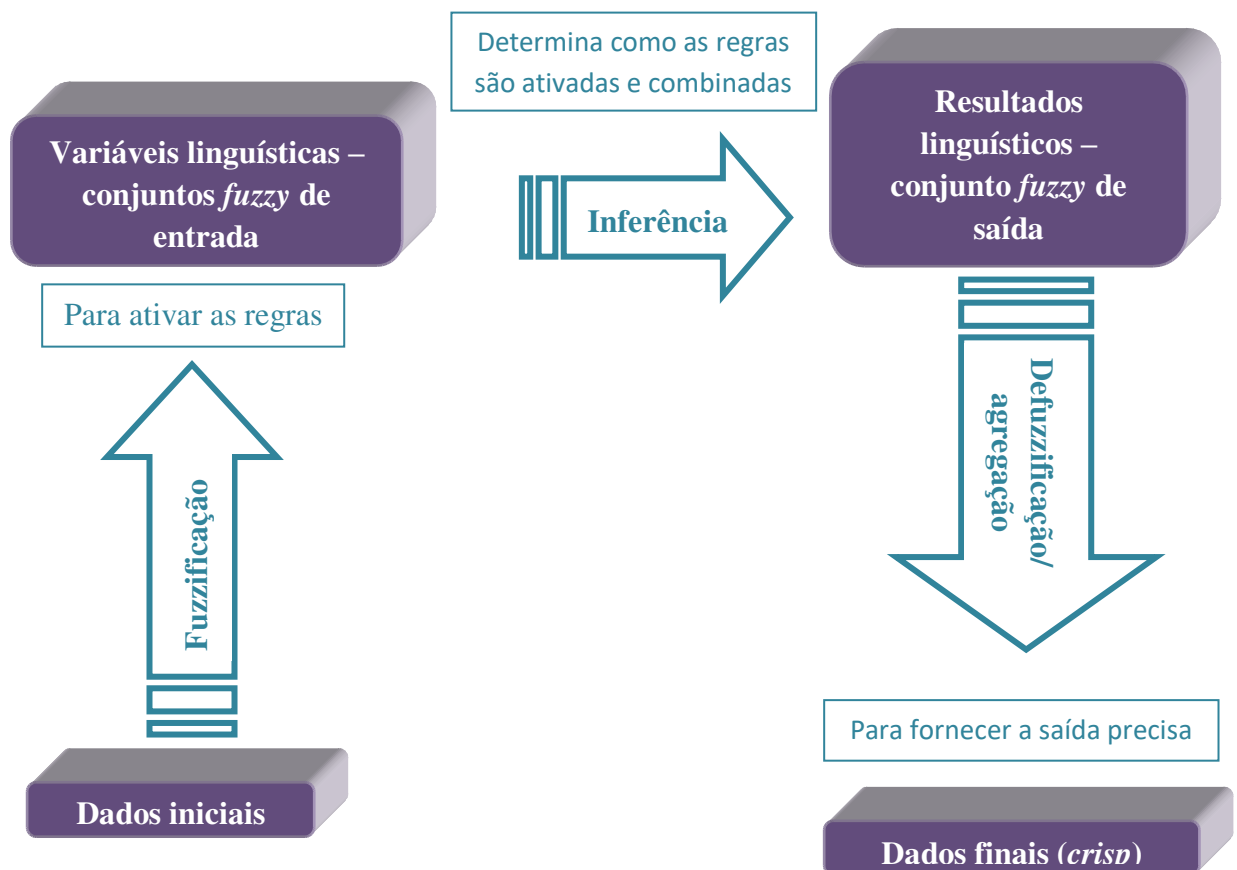
Após apresentar as entradas exatas, a primeira etapa é a fuzzificação, onde os números reais de entrada serão transformados em valores *fuzzy*, que corresponde à transformação dos dados de entrada iniciais em suas respectivas variáveis linguísticas e relata também de especialistas da área em questão para atribuição de valores relacionados aos graus de pertinência para cada uma das variáveis em estudo, contribuindo assim para maior precisão nos resultados (PINHO, 1999; JANÉ, 2004).

Em seguida, na etapa da inferência *fuzzy* fazendo uso das regras pré-estabelecidas, as quais geralmente são fornecidas por especialista, relacionará as possíveis variáveis entre si, determinando os valores de saída em resultados linguísticos. O processo de inferência é formado pelo conjunto de regras **Se-Então**, que são os dois componentes: de agregação (se) e de composição (então) (VON ALTROCK, 1996; ABREU, 2014).

Por fim, a defuzzificação compreende ao processo de conversão de um conjunto *fuzzy* em uma única saída *crisp* (COX, 1995) e é essa saída que dirá o que é mais pertinente, exemplo a indicação de uma classe de qualidade de carne.

Mas para que se obtenha essa única saída *crisp* é preciso realizar a agregação, ou seja, combinar todas os resultados das regras aplicadas anteriormente. Existem diversos métodos para encontrar essa combinação de resultados, dentre os métodos, podemos destacar o centro de gravidade, média do valor máximo e média ponderada dos máximos.

FIGURA 11 – Esquema de formação do raciocínio *Fuzzy*.



Fonte: Adaptado de COX (1995), TANSCHKEIT (2015).

As vantagens da lógica *fuzzy* comparada à abordagem *crisp* (conjuntos nítidos, bem definidos) são que a naturalidade de sua abordagem a torna conceitualmente fácil de ser entendida, a flexibilidade e tolerância a dados imprecisos, pode ser construída com base na experiência de um especialista, simplificar a solução de um problema e aquisição da base

de conhecimento, proporciona um rápido protótipo dos sistemas e é baseada em linguagem natural, base da comunicação humana (JANG; GULLEY, 1997).

Adicionalmente, sistemas baseados em lógica *fuzzy* são mais fáceis de entender, manter e testar, são robustos e operam com falta de regras ou com regras defeituosas. A utilização da lógica nebulosa proporciona um rápido protótipo dos sistemas (SILVA, 2008).

Em contrapartida, a lógica *fuzzy* possui algumas desvantagens, como necessidade de muita simulação/teste para o ajuste fino destas funções, pois a especificação das funções de pertinência é trabalhosa, não há uma definição matemática precisa, tem grande dificuldade no estabelecimento de regras consistentes, pois, para tal há a necessidade da captura do conhecimento de um especialista e/ou de dados históricos, além de sua natureza heurística, a potencial explosão combinatória de regras e antecedentes e incapacidade de aprendizado (SILVA et al., 2008, DEMASI; CRUZ, 2002).

A lógica *fuzzy* tem tido aplicabilidade nas mais diversas áreas do conhecimento como ferramenta para tomada de decisão, avaliação e classificação. Muitos trabalhos já foram reportados na literatura, como exemplo: CADENAS et al. (2004) e BRACARENSE (2013) para otimização da dieta de animais, PONCIANO et al. (2012) para avaliação do desempenho de animais, FERREIRA et al. (2007) prevêm o estro de vacas leiteiras, FERREIRA et al. (2010) para prever a temperatura retal de frangos de corte, OLIVEIRA et al. (2005), PERISSINOTO et al. (2009) e NASCIMENTO et al. (2011) estimam as condições conforto térmico de animais por meio de índice, PONCIANO et al. (2011), ABREU et al (2014) avaliação do ambiente de animais de produção, DAVIDSON et al. (1998), LANZILLOTTI; LANZILLOTTI (1999) e TAN et al. (1999), JAYA et al. (2003), LAZIM; SURIANI (2009) avaliação sensorial de alimentos e bebidas, VÁSQUEZ-VILLALOBOS (2015) determinação de vida útil sensorial de produtos, ALFONSO (2013) estudo de preferência de consumidores de carne, RAPTIS et al. (2000) classificam a idade de vinhos, ALONSO et al. (2007) criam um índice para predizer o risco de malignidade de tumores de ovário, BENINI et al. (2011) previsão da compactação do solo e VIDAL et al. (2012), controle de plantas industriais, etc.

REFERÊNCIAS

- ABAR, C. **O conceito "Fuzzy"**. 2004. Disponível em: <<http://www.pucsp.br/~logica/Fuzzy.htm>>. Acesso em: 19 nov. 2015.
- ABPA - ASSOCIAÇÃO BRASILEIRA DE PROTEÍNA ANIMAL. **Relatório Anual de 2017**. Disponível em: <<http://abpa-br.com.br/setores/suinocultura>>. Acesso em: 15 jan. 2018.
- ABREU, L. H. P. **Modelagem fuzzy do desempenho de frangos de corte, criados de 1 a 21 dias, submetidos a estresse térmico**. 2014. 59 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Lavras, Lavras, 2014.
- ADORNI, G.; BIANCHI, D.; CAGNONI, S. Learning *fuzzy* decision trees for ham quality control. **Trans.** v. 1, p. 259-264, 2001.
- ADZITEY, F.; NURUL, H. Pale soft exudative (PSE) and dark firm dry (DFD) meats: causes and measures to reduce these incidences-a mini review. **International Food Research Journal**, v. 18, n. 1, 2011.
- AGUADO, A. G.; CANTANHEDE, M. A. **Lógica Fuzzy**. 2010. Disponível em: <http://www.ft.unicamp.br/liag/wp/monografias/monografias/2010_IA_FT_UNICAMP_logicaFuzzi.pdf>. Acesso em: 19 nov. 2015.
- ALFONSO, L. A technical note on the use of choquet integral to analyze consumer preferences: application to meat consumption. **Journal of Sensory Studies**, v. 28, n. 6, p. 467-473, 2013.
- ALONSO, A. C. R.; VENDITE, L. L. Aplicação da teoria dos conjuntos *Fuzzy* para prever o risco de malignidade de tumores de ovário. In: XXX Congresso de Matemática Aplicada e Computacional, 30., 2007, Florianópolis. **Anais...** Florianópolis, 2007.
- ANNE, A. **Fundamentals of Water Holding Capacity (WHC) of meat**. Disponível em: <http://qpc.adm.slu.se/6_Fundamentals_of_WHC/index.htm>. Acesso em: 21 jul. 2015.
- ARIMA, H. K. A maciez da carne, da criação à maturação. In: Curso sobre a maciez da carne bovina. 2002, Campinas. **Anais...** Campinas: CTC/ITAL, 2002. p. 1-17.
- BARBIN, D. et al. Near-infrared hyperspectral imaging for grading and classification of pork. **Meat Science**, v. 90, n. 1, p. 259-268, 2012.
- BARBUT, S.; ZHANG, L.; MARCONE, M. Effects of Pale, normal, and dark chicken breast meat on microstructure, extractable proteins, and cooking of marinated fillets. **Poultry science**, v. 84, n. 5, p. 797-802, 2005.
- BAUER, A., et al. Towards an online assessment of meat quality in pork. In: 59th International Congress of Meat Science and Technology, 59., 2013, Izmir. **Anais...** Izmir, 2013. p. 18-23.

BAUTISTA, J. H.; RINCÓN, F. G. R. ¿Calidad de la carne o carne de calidad?. **Revista Nacameh**, v. 4, n. 1, p. 1-10, 2010.

BENINI, L. C.; SILVA, I. N. Previsão da compactação do solo usando sistema *fuzzy*. In: Conferência Brasileira de Dinâmica, Controle e Aplicações, 10., 2011, **Anais...** 2011. p. 639-642.

BRACARENSE, J. C.; SANTOS, C. V.; MAYERLE, S. F. Tomada de decisão sob condições de risco e incerteza: uma aplicação da lógica *fuzzy* à bovinocultura de corte da região Serrana de Santa Catarina. **Teoria e Evidência Econômica**, n. 41, p. 73-101, 2013.

BREIMAN, L. Random forests. **Machine learning**, v. 45, n. 1, p. 5-32, 2001.

BRITO, R. **IA: Sistemas Fuzzy I**. 2015. Disponível em: <http://www.ufpi.br/subsiteFiles/rbritto/arquivos/files/Aula21_Sistemas%20Fuzzy%20I.pdf>. Acesso em: 1 dez. 2015.

BRØNDUM, J. et al. Prediction of water-holding capacity and composition of porcine meat by comparative spectroscopy. **Meat Science**, v. 55, n. 2, p. 177-185, 2000.

BUEGE, D. **Variation in pork lean quality**. Facts: Pork Quality. National Pork Board, v. 4522, 2001.

CADENAS, J. M. Application of *Fuzzy* optimization to diet problems in Argentinean farms. **European Journal of Operational Research**, v. 158, n.1, p. 218-228, 2004.

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.

COMA, J.; PIQUER, J. **Calidad de carne en porcino: efecto de la nutrición**. 1999. Disponível em: <<http://fundacionfedna.org/sites/default/files/99CAP8.pdf>>. Acesso em: 20 jul. 2015.

COPPIN, B. **Artificial Intelligence Illuminated**. Jones and Bartlett Learning, 2004. 768 p.

COX, E. **The fuzzy systems handbook: a practitioner's guide to building, using, and maintaining fuzzy systems**. New York: AP Professional, 1994.

COX, E. **Fuzzy logic for business and industry**. Massachusetts: Charles River Media Inc, 1995.

CUNHA, T.; SOARES, C.; CARVALHO, A. C. P. L. F. Metalearning and Recommender Systems: A literature review and empirical study on the algorithm selection problem for Collaborative Filtering. **Information Sciences**, v. 423, p. 128-144, 2018.

DAGUER, H. **Efeitos da injeção de ingredientes não cárneos nas características físico-químicas e sensoriais do lombo suíno**. 2009. 187 f. Tese (Doutorado em Tecnologia de Alimentos) - Universidade Federal do Paraná, Curitiba, 2009.

DAVIDSON, V.J.; SUN, W. A linguistic method for sensory assessment. **Journal of Sensory Studies**, v. 13, p. 315-330, 1998.

DEMASI, P.; CRUZ, A. J. O. **Modelagem Fuzzy para um Jogo de Naves Espaciais**. 2002. Disponível em: <http://www.nce.ufrj.br/labic/downloads/wjogos_fuzzy_2002.pdf>. Acesso em: 19 nov. 2015.

DUDA, R. O.; HART, P. E.; STORK, D. G. Unsupervised learning and clustering. **Pattern Classification**, p. 517-601, 2001.

FAO-FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. **Meat Quality**. 2014. Disponível em: <http://www.fao.org/ag/againfo/themes/en/meat/quality_meat.html>. Acesso em: 17 jul. 2015.

FAO-FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. **World Agriculture: Towards 2015/2030, an FAO perspective**. 2015. Disponível: <<http://www.fao.org/docrep/005/y4252e/y4252e05b.htm>>. Acesso em: 26 nov. 2015.

FAUCITANO, L. et al. Shelf life of pork from five different quality classes. **Meat Science**, v. 84, n. 3, p. 466-469, 2010.

FEINER, G. **Meat products handbook: Practical science and technology**. Elsevier, 2006. 672 p.

FERREIRA, L. et al. Desenvolvimento de uma rede neuro-fuzzy para predição da temperatura retal de frangos de corte. **Revista de Informática Teórica e Aplicada**, Porto Alegre, v.17, n.2, p.221-233, 2010.

FERREIRA, L. et al. Development of algorithm using fuzzy logic to predict estrus in dairy cows: Part I. **Agricultural Engineering International: The CIGR Ejournal**, Beijing, v.9, p.1-16, 2007.

GALLO, S. B. **Entendendo os significados da cor da carne**. 2006. Disponível em: <<http://m.farmpoint.com.br/radares-tecnicos/qualidade/entendendo-os-significados-da-cor-da-carne-31679n.aspx>>. Acesso em: 9 set. 2015.

GANGA, G. M. D.; CARPINETTI, L. C. R.; POLITANO, P. R. Gestão do desempenho em cadeias de suprimentos usando lógica fuzzy. **Gestão & Produção**, São Carlos, v. 18, n. 4, p. 755-774, 2011.

GOKGOZ, E.; SUBASI, A. Comparison of decision tree algorithms for EMG signal classification using DWT. **Biomedical Signal Processing and Control**, v. 18, p. 138-144, 2015.

GOLDSCHMIDT, R. R. **Uma Introdução à Inteligência Computacional: fundamentos, ferramentas e aplicações.** 2010. Disponível em: <www.boente.eti.br/boente2012/fuzzy/ebook/ebook-fuzzy-goldschmidt.pdf>. Acesso em 28 set. 2015.

GOMIDE, L. A. M.; RAMOS, E. M.; FONTES, P. R. **Ciência e qualidade da carne: fundamentos.** Viçosa: Editora UFV, 2013. 197 p.

HEINZ, G.; HAUTZINGER, P. **Meat processing technology for small to medium scale producers.** Bangkok: Food and Agriculture Organization of the United Nations, 2007. 50 p.

HUFF-LONERGAN, E. LONERGAN, S. M. Mechanisms of water-holding capacity of meat: The role of postmortem biochemical and structural changes. **Meat Science**, n. 71, p. 194–204, 2005.

JANG, J.S.R.; GULLEY, N. **MATLAB – Fuzzy Logic Toolbox User’s Guide.** The Math Works Inc., Natick, MA, U.S.A. Accordingly, application of the hydroacoustic technique and *fuzzy*. 1997.

JANÉ, D. de A. **Uma introdução ao estudo da lógica fuzzy.** Hórus, v. 2, p. 1-16, 2004.

JAYA, S.; DAS, H. Sensory evaluation of mango drinks using *fuzzy* logic. **Journal of Sensory Studies**, v. 18, p. 163-176, 2003.

JOO, S. T. et al. The relationship of sarcoplasmic and myofibrillar protein solubility to colour and water-holding capacity in porcine longissimus muscle. **Meat Science**, v. 52 p. 291-297, 1999.

JOO, S. T. et al. Objectively predicting ultimate quality of post-rigor pork musculature: I. Initial comparison of techniques. **Asian-Australasian Journal of Animal Sciences**, v. 13, n. 1, p. 68-76, 2000.

KAMRUZZAMAN, M.; MAKINO, Y.; OSHITA, S. Rapid and non-destructive detection of chicken adulteration in minced beef using visible near-infrared hyperspectral imaging and *machine learning*. **Journal of Food Engineering**, v. 170, p. 8-15, 2016.

KAUFFMAN, R. G. et al. The effectiveness of examining early post-mortem musculature to predict ultimate pork quality. **Meat Science**, v. 34, n. 3, p. 283-300, 1993.

KAVZOGLU, T.; COLKESEN, I. A kernel functions analysis for support vector machines for land cover classification. **International Journal of Applied Earth Observation and Geoinformation**, v. 11, n. 5, p. 352-359, 2009.

KINGSFORD, C.; SALZBERG, S. L. What are decision trees?. **Nature biotechnology**, v. 26, n. 9, p. 1011-1013, 2008.

KLIR, G. J.; YUAN, B. **Fuzzy Sets and Fuzzy Logic: Theory and Applications.** New Jersey: Prentice Hall PTR, 1995. 588 p.

KOTSIANTIS, S. B.; ZAHARAKIS, I.; PINTELAS, P. Supervised *machine learning*: A review of classification techniques. **Informática**, v.31, p. 249-268, 2007.

LANZILLOTTI, R. S.; LANZILLOTTI, H. S. Análise sensorial sob o enfoque da decisão *fuzzy*. **Revista de Nutrição**, Campinas, v. 12, n. 2, p. 145-157, maio. 1999.

LAWRIE, R. A. **Ciência da carne**. Tradução de Jane Maria Rubensan. Porto Alegre: Artmed, 2005. 384 p. Tradução de: Meat Science.

LAZIM, M. A.; SURIANI, M. Sensory evaluation of the selected coffee products using *fuzzy* approach. **World Academy of Science, Engineering and Technology**, v. 50, p. 717-720, 2009.

LIU, L. et al. Categorization of pork quality using Gabor filter-based hyperspectral imaging technology. **Journal of Food Engineering**, v. 99, n. 3, p. 284-293, 2010.

LIU, X. et al. Privacy-preserving patient-centric clinical decision support system on naive Bayesian classification. **IEEE journal of biomedical and health informatics**, v. 20, n. 2, p. 655-668, mar. 2016.

LUDTKE, C. B. et al. Bem-estar animal no manejo pré-abate e a influência na qualidade da carne suína e nos parâmetros fisiológicos do estresse. **Ciência Rural**, Santa Maria, v. 42, n. 3, p. 532-537, mar. 2012.

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**, Campinas, v. 27, p. 69-72, ago. 2007.

MANCINI, R. A.; HUNT, M. C. Current research in meat color. **Meat Science**. v. 71, p. 100-121, 2005.

MANTOVANI, R. G. et al. *Meta-learning* recommendation of default hyper-parameter values for SVMs in classifications tasks. In: European Conference on *Machine learning* and Principles and Practice of Knowledge Discovery in Databases; International Workshop on *Meta-learning* and Algorithm Selection. 2015, **Anais...** University of Porto, 2015.

MARRO, A. A. et al. **Lógica Fuzzy**: Conceitos e aplicações. 2010. Disponível em: <http://aquilesburlamaqui.wdfiles.com/local--files/logica-aplicada-a-computacao/texto_fuzzy.pdf>. Acesso em: 19 nov. 2015.

MATENSE, F. D. G. **Transformação do músculo em carne**. 2002. Disponível em: <<http://www6.ufrgs.br/favet/lacvet/restrito/pdf/carne.pdf>>. Acesso em: 22 jul. 2015.

MINSKY, M. **Semantic information processing**. Cambridge: The MIT Press, 1968.

MORAES, M. **Maturação da carne bovina**. Monografia (especialização) - Universidade de Brasília, Brasília, 2004.

NASCIMENTO, G. R. et al. Índice *fuzzy* de conforto térmico para frangos de corte. **Engenharia Agrícola**, Jaboticabal, v.31, n.2, p.219-229, 2011.

OLIVEIRA, L. H.; AMENDOLA, M.; NÄÄS, I. A. Estimativa das condições de conforto térmico para avicultura de postura usando a teoria dos conjuntos *Fuzzy*. **Engenharia Agrícola**, Jaboticabal, v.25, n.2, p.300-307, 2005.

PARDI, M.C. et al. **Ciência, higiene e tecnologia da carne**. 2.ed. Goiânia: UFG, 2001. 623p

PERISSINOTO, M. et al. Thermal comfort on Subtropical and Mediterranean climate analyzing some physiological data through *fuzzy* theory. **Ciência Rural**, Santa Maria, v.39, n.5, p.1.492-1.498, 2009.

PINHO, A. F. **Uma contribuição para a resolução de problemas de programação de operações em sistemas de produção intermitentes flow-shop: A consideração de incertezas**. 1999. Dissertação (Mestrado em Engenharia) – Universidade Federal de Itajubá, Itajubá, 1999.

PONCIANO, P. F. et al. Análise do ambiente para frangos por meio da lógica *fuzzy*: uma revisão. **Archivos de Zootecnia**, v. 60, p. 1-13, 2011.

PONCIANO, P. F. et al. Sistema *fuzzy* para predição do desempenho produtivo de frangos de corte de 1 a 21 dias de idade. **Engenharia Agrícola**, Jaboticabal, v.32, n.3, p. 446-458, maio/jun. 2012.

QUAGLINI, S. Supporting tools for guideline development and dissemination. **Artificial Intelligence in Medicine**. v. 14, p. 119-137, 1998.

RAMOS, E. M.; GOMIDE, L. A. M. **Avaliação da qualidade de carnes: fundamentos e metodologias**. 5. ed. Viçosa: UFV, 2007. 599 p.

RAPTIS, C. G. et al. Classification of aged wine distillates using *fuzzy* and neural network systems. **Journal Food and Engineering**, v. 46, p. 267-275, 2000.

RICE, J. R. The algorithm selection problem. **Advances in Computers**, v. 15, p. 65-118, 1976.

RIGNEL, D. G. S.; CHENCI, G. P.; LUCAS, C. A. Uma introdução a lógica *fuzzy*. **Revista Eletrônica de Sistemas de Informação e Gestão Tecnológica**, v. 1, n. 1, p. 17-28, 2011.

ROÇA, R. O. **Modificações post-mortem**. Disponível em: <<http://200.132.139.11/aulas/Zootecnia/A7%20-%20Setimo%20Semestre/Avalia%C3%A7%C3%A3o%20de%20Carca%C3%A7as/MODIFICA%C3%87%C3%95ES%20POST-MORTEM.pdf>>. Acesso em: 21 jul. 2015.

RODRIGUES, C. R. **Espectrofotometria por infravermelho**. 2012. Disponível em: <http://www.academia.edu/5328536/ESPECTROFOTOMETRIA_POR_INFRAVERMELHO>. Acesso em: 22 out. 2015.

ROZA, F. S. **Aprendizagem de máquina para apoio à tomada de decisão em vendas do varejo utilizando registros de vendas**. 2016. 62 f. Trabalho de Conclusão de Curso

(Graduação em Engenharia de Controle e Automação) – Universidade Federal de Santa Catarina, Florianópolis, 2016.

SANCHEZ, E. C. M. **Controle por aprendizado acelerado e neuro-fuzzy de sistema servo-hidráulicos de alta frequência**. Dissertação (Mestrado em Engenharia Mecânica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2009.

SANT'ANNA, A. P. **Probabilistic composition of preferences, theory and applications**. Niterói: Springer, 2015. 139 p.

SANTOS, C. et al. Incidence of different pork quality categories in a Portuguese slaughterhouse: A survey. **Meat Science**, v. 38, n. 2, p. 279-287, 1994.

SARANTOPOULOS, C.I.G.L.; PIZZINATTO, A. Fatores que afetam a cor das carnes. **Coletânea do ITAL**, Campinas, v.20, n.1, p.1-12, 1990.

SCHEIER, R. **Early postmortem determination of porcine meat quality using Raman spectroscopy**. 2014. 134 f. Tese (Doutorado em Ciências) – Universität Bayreuth, Bayreuth, 2014.

SERBAN, F. et al. A survey of intelligent assistants for data analysis. **ACM Computing Surveys**, v. 45, n. 3, p. 31, 2013.

SHAW, F. D.; TUME, R. K. The assessment of pre-slaughter and slaughter treatments of livestock by measurement of plasma constituents - a review of recent work. **Meat Science**, v. 32, n. 3, p. 311-329, 1992.

SILVA, M. A. **Aplicação de Lógica Nebulosa para Previsão do Risco de Escorregamentos de Taludes em Solo Residual**. 2008. 150 f. Dissertação (Mestrado em Engenharia Civil) – Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2008.

SILVA SOBRINHO, A. G. et al. Características de qualidade da carne de ovinos de diferentes genótipos e idades ao abate. **Revista Brasileira de Zootecnia**, Viçosa, v. 34, n. 3, p. 1070-1078, 2005.

SONG, Y.; YING, L. U. Decision tree methods: applications for classification and prediction. **Shanghai Archives of Psychiatry**, v. 27, n. 2, p. 130, 2015.

SOSNICKI, A. et al. Is there a cost-effective way to produce high quality pork. In: **51st Reciprocal Meat Conf. Am. Meat Sci. Assoc.**, Savoy, IL., p. 19-27, 1998

STATHAKIS, D.; VASILAKOS, A. Comparison of computational intelligence based classification techniques for remotely sensed optical image classification. **IEEE Transactions on Geoscience and remote Sensing**, v. 44, n. 8, p. 2305-2318, 2006.

SWATLAND, H. J. Progress in understanding the Paleness of meat with a low pH. **South African Journal of Animal Science**, v. 34, p. 1-7, 2004.

TAN, J.; GAO, X.; GERRARD, D. E. Application of *fuzzy* sets and neural networks in sensory analysis. **Journal Sensory Studies**, v. 14, p. 119-138, 1999.

TARAVAT, A. et al. Neural networks and support vector machine algorithms for automatic cloud classification of whole-sky ground-based images. **IEEE Geoscience and remote sensing letters**, v. 12, n. 3, p. 666-670, 2015.

TERRA, N. N.; FRIES, L. L. M. A qualidade da carne suína e sua industrialização. In: Conferência Virtual Internacional sobre Qualidade de Carne Suína, 1., 2000, Concórdia. **Anais...** Concórdia, 2000. p. 147-151.

TRZESNIAK, Piotr. Indicadores quantitativos: reflexões que antecedem seu estabelecimento. **Ciência da Informação**, v. 27, n. 2, 1998.

VAN LAACK, R. L. J. M. et al. Is colour brightness (L-value) a reliable indicator of water-holding capacity in porcine muscle?. **Meat Science**, v. 38, n. 2, p. 193-201, 1994.

VAN LAACK, R. L. J. M. et al. A comparison of procedures for measurement of pigment concentration in pork. **Journal of Muscle Foods**, v. 7, n. 2, p. 149-163, 1996.

VAN LAACK, R. L.; KAUFFMAN, Robert G. Glycolytic potential of red, soft, exudative pork longissimus muscle. **Journal of Animal Science**, v. 77, n. 11, p. 2971-2973, 1999.

VÁSQUEZ-VILLALOBOS, V; VASQUEZ ANGULO, J.; MENDEZ, E. R. New method for determining sensory shelf life using *fuzzy* logic: canned marinated artichoke hearts (*Cynara scolymus* L.) case. **Scientia Agropecuaria**, v.6, n.2, p. 99-109, 2015.

VENDITE, L. L.; ALONSO, A. C. R. Aplicação da Teoria dos Conjuntos *Fuzzy* para prever o risco de malignidade de tumores de ovário. In: XXX CNMAC – Congresso Nacional de Matemática Aplicada e Computacional, 30., 2007, Florianópolis. **Anais...** Florianópolis, 2007. p. 1-6.

VIDAL, L. C.; LANDIM, W. C. A.; COSTA, A. P. Aplicação de Lógica *Fuzzy* no Controle de Plantas Industriais. In: IX Simpósio de excelência em gestão e tecnologia, 9., 2012, Resende. **Anais...** Resende, 2012. p. 1-15.

VILJOEN, H. F.; DE KOCK, H. L.; WEBB, E. C. Consumer acceptability of dark, firm and dry (DFD) and normal pH beef steaks. **Meat Science**, v. 61, n. 2, p. 181-185, 2002.

VON ALTROCK, C. **Fuzzy logic and neuroFuzzy applications in business and finance**. New Jersey: Prentice Hall PTR, 1996.

WANG, F. Parallel control and management for intelligent transportation systems: Concepts, architectures, and applications. **IEEE Transactions on Intelligent Transportation Systems**, v. 11, n. 3, p. 630-638, 2010.

WARRIS, P. D. et al. The quality of pork from traditional pig breeds. **Meat Focus International**, v. 5, n. 5/6, p. 179-182, 1996.

WARNER, R. D.; KAUFFMAN, R. G.; GREASER, M. L. Muscle protein changes post mortem in relation to pork quality traits. **Meat Science**, v. 45, n. 3, p. 339-352, 1997.

WARRISS, P. D.; BROWN, S. N. The relationships between initial pH, reflectance and exudation in pig muscle. **Meat Science**, v. 20, n. 1, p. 65-74, 1987.

XING, J. et al. Use of visible spectroscopy for quality classification of intact pork meat. *Journal of Food Engineering*, v. 82, n. 2, p. 135-141, 2007.

ZIMERMAN, M. pH de la carne y los factores que lo afectan. In: SAÑUDO, C.; GONZÁLEZ, C. **Aspectos estratégicos para obtener carne ovina de calidad en el cono sur americano**. Buenos Aires: Universidad Nacional del Centro de la Provincia de Buenos Aires, 2008. p.141-152.

5 ARTIGO I***META-RECOMMENDATION OF PORK QUALITY STANDARDS***

Redigido segundo as normas da revista:

Meat Science

Meta-recommendation of pork technological quality standards

Louise Manha Peres^{a,*}, Sylvio Barbon Jr.^c, Ana Maria Bridi^a, Estefânia Mayumi Fuzyi^b,
Ana Paula A. C. Barbon^a, Nayara Andreo^a, Joel Gonzalez Armangué^d

^aDepartment of Animal Science, Londrina State University (UEL), Londrina 86057-970, Brazil

^bDepartment of Inf., Pontifícia Univ. Católica do Paraná (PUCPR), Curitiba 80215-901, Brazil

^cDepartment of Computer Science, Londrina State University (UEL), Londrina 86057-970, Brazil

^dDepartment of Product Quality, Institut de Recerca i Tecnologia Agroalimentàries (IRTA), Monells 17121, Spain

Abstract

Pork quality classification could be supported by different reference standards widely reported in the literature. However, the decision for a standard suitable to a collected dataset remains a challenge. In order to automatically recommend a proper standard among the current ones toward outlining a good classification, it is proposed a meta-learning approach for recommending. Meta-learning has emerged from machine learning research field to solve the algorithm selection problem, and now, fashioned to deal with pork quality standard in a straightforward way. Using the J48 Decision Tree (DT) algorithm to build the meta-recommender, we exposed the applicability and advantages from the usage of a suitable standard for classifying pork quality.

Keywords: Classification; Computational intelligence, Decision tree, Machine learning, Meta-learning

1. Introduction

Meat quality evaluation is essential for the food industry, mainly due to consumers demand to owe superior quality of meat and its products (Elmasry et al., 2012). Furthermore, determining the meat quality is fundamental to allow it to be correctly targeted to specific market niches (Sosnicki et al., 2003). In this scenario, meat quality is a term used to describe several meat properties resulting from the interaction between the ante-mortem and post-mortem muscle metabolism (Maltin et al., 2003; Durkin et al., 2009; Sima et al., 2015). Among them, water holding capacity, colour, lipid composition, oxidative stability, nutritional value, taste, texture and safety has been the most explored (Osório and Osório,

*Corresponding author

Email addresses: louise.mperes@gmail.com (Louise Manha Peres), barbon@uel.br (Sylvio Barbon Jr.), ambridi@uel.br (Ana Maria Bridi), emfuzyi@ppgia.pucpr.br (Estefânia Mayumi Fuzyi), apbarbon@gmail.com (Ana Paula A. C. Barbon), nayarandreo@hotmail.com (Nayara Andreo), joel.gonzalez@irta.cat (Joel Gonzalez Armangué)

21 2000; Andersen et al., 2005). However, some of them are based on subjective evaluation by
22 a specialist (Hofmann, 1994).

23 Some few parameters have the capability to describe and carry meaningful importance
24 to define and evaluate meat quality, such as *pH*, *drip loss* and *color* (Lee et al., 2000).
25 Indeed, Channon et al. (2001) suggested that, in addition to ultimate *pH*, other meat quality
26 attributes may be required to provide a useful model for the industry concerning sort out
27 pork into different classes of eating quality. For this reason, most of the meat quality
28 standards described in the literature use a combination of just these three parameters.

29 There is no consensus about the criteria used to measure the pork quality (Cazedey et al.,
30 2016). The literature regarding pork quality standards addresses three, four or five classes
31 with different thresholds. (Kušec et al., 2007) exposed a plurality of criteria to classify
32 pork quality and the literature related to pork quality standards are manifold, for instance:
33 Kauffman et al. (1993); Santos et al. (1994); Van Laack et al. (1996); Warner et al. (1997);
34 Flores et al. (1999); Van Laack and Kauffman (1999); Channon et al. (2000); Joo et al.
35 (2000); Du and Sun (2006); Maganhini et al. (2007); Faucitano et al. (2010); Barbin et al.
36 (2012); Bauer et al. (2013); Tomovic et al. (2014).

37 This multitude of grading models reflects a lack of standardization, where a given sample
38 could be classified differently depending on the chosen pork quality standard Cazedey et al.
39 (2016). Furthermore, a sample could not be feasible according to a specific standard, once
40 its features do not match the proposed attribute threshold.

41 The pork quality is a key to the modern food industry and for the competitive market
42 (Du and Sun, 2006). In this way, considering the regional variations of pork standards, a
43 question arises: “What is the adequate technological quality standard to classify a given
44 pork sample?”.

45 An answer to this question may come from Machine Learning (*ML*). The *ML* algorithms
46 are able to build a classification model supported by the knowledge extracted from the
47 dataset example. In other words, it is possible to comprehend and recommend a suitable
48 solution for a specific problem. This type of solution has been widely applied in food research
49 area (Kodogiannis et al., 2014; Liu et al., 2015; Barbon et al., 2016b,a; Caballero et al., 2016;
50 Kamruzzaman et al., 2016; Mohareb et al., 2016; Sanz et al., 2016).

51 To recommend an adequate pork quality standard for classification requires depth knowl-
52 edge about the dataset and the available standards. Meta-learning has recently emerged from
53 machine learning research field to solve the selection problem assessing the data with the
54 most profitable solution Campos et al. (2016). Initially supporting classification tasks, the
55 Meta-learning follow the premise that an algorithm can be superior to another in a dataset
56 while inferior to this competitor in another dataset (Wong, 2016). Thus meta-learning ap-
57 proach is a tool that typically tries to predict the applicability of different classification
58 algorithms on a dataset (Reif et al., 2012), suggesting which algorithm to use in certain
59 cases to achieve better results (de Souza et al., 2001). By making an analogy to the prin-
60 ciples of meta-learning, we propose the use of meta-recommendation of the most suitable
61 pork quality standard through the decision tree algorithm (*DT*).

62 The *DT* classification algorithm has been chosen because they are among the most
63 traditional and powerful *ML* methods (Marsland, 2015) presenting some advantages such as

64 low computational cost, can deal with missing values and irrelevant features (Harrington,
 65 2012). Also, the model obtained from *DT* algorithm is easily understandable unlike many
 66 ‘black-box’ solutions such as the ANN (Barbon et al., 2016b).

67 The main objective of this paper is to provide a model capable of recommending a
 68 suitable standard to qualify pork among (XXX) based on meta-learning. With an adequate
 69 model, the number of classified samples is maximized, the demand of parameters to perform
 70 a test is checked and the confidence of classification result enhanced.

71 2. Materials and Methods

72 Meta-learning have been applied to recommend (Soares et al., 2004; Soares and Brazdil,
 73 2006; Campos et al., 2016), or optimize ML algorithms parameters. Meta-learning methods
 74 are grounded in modelling the knowledge and experience previously acquired on different
 75 problems to recommend one solution for a new problem Campos et al. (2016). The *meta-*
 76 *knowledge* is represented by a *meta-model*, in our case a DT, that captures the relation be-
 77 tween a set of characteristics (also called *meta-features*) from these datasets. When a meta-
 78 learning solution is applied to a recommendation problem, we build a meta-recommendation
 79 model. In this sense, to create a meta-recommender to classification standard for a new
 80 dataset of pork samples, it was followed the steps presented in Figure 1.




Figure 1: Overview of meta-learning approach to build a meta-recommendation system

81 The first step is to group several different datasets owing to describe the vast possibility
 82 of samples types according to all standards. In our work, this step is depth described in
 83 Section 2.1. Considering the dataset, the second step is extracting meta-features from these
 84 original datasets composed of the traditional quality parameters. The meta-features are
 85 features based on Information Theory and Statistics as described in Section 2.3. The *meta-*
 86 *dataset* is obtained from *meta-features* and used to induce a machine learning algorithm; we
 87 employ a DT. This induction is described in Section 2.4.

88 After these step, the meta-model could be used with a new dataset for recommending a
 89 suitable standard owing to reduce the number of unclassifiable samples automatically and
 90 further classification enhancements.

91 2.1. Pork Quality Standards

92 Pork samples were obtained from ten different slaughters, amounting to 1301 *longissimus*
 93 *dorsi at lumborum* muscle. The parameters such as *pH* (*pHu*), water holding capacity

94 (*WHC*) and color (lightness - L^* value) of each sample were measured 24 hours after the
95 slaughter.

96 The *pHu* was measured 24 hours *post mortem* using a Testo 205 pH-meter. The *WHC*
97 was obtained by the Pressing Method (*PM*) proposed by Hamm (1960) and adapted by
98 Wilhelm et al. (2010) and the L^* value was determined with a Minolta R portable colorime-
99 ter (model CR-10 colorimeter with illuminant D65 and 8° angle of inclination - Tokyo, JP)
100 after blooming for 30 minutes (CIELab, 1976).

101 We used different methodologies to measure *WHC* and L^* values when compared to
102 Kauffman et al. (1993) - and Faucitano et al. (2010) standards. Thus, the parameters
103 values were standardized by means of mathematical transformations and it made possible
104 the comparison among the pork quality standards.

105 Where *DL* and *FPW* are drip loss and filter-paper wetness methodologies, respectively.

$$DL = 0.100707 \cdot PM \quad (1)$$

$$DL = -0.36 + 0.064 \cdot FPW \quad (2)$$

$$H(L) = 10\sqrt{Y} \quad (3)$$

$$H(a) = 17.5 \cdot \frac{(1.02 \cdot X) - Y}{\sqrt{Y}} \quad (4)$$

$$H(b) = 7 \cdot \frac{Y - (0.847 \cdot Z)}{\sqrt{Y}} \quad (5)$$

106 2.2. Original Datasets

107 In this work, we used real and synthetic datasets. The real-life dataset was composed of
108 1,301 samples from ten different acquisitions. Unfortunately, this dataset does not include
109 examples able to match into all the classes described in the pork quality standards due to
110 the variability of meat quality as intrinsic and extrinsic factors (Joo et al., 2013). Real-life
111 datasets could not present samples concerning each class proposed by the literature, further
112 present a great difference of their number causing an imbalance learning problem. The
113 imbalanced learning problem compromises the performance the most learning algorithms
114 because most of them assume or expect a distribution of balanced classes in the training
115 set. Thus, these algorithms fail to represent the distributional characteristics of the data
116 correctly and, hence, provide unfavourable class accuracy (He and Garcia, 2009).

117 A possible solution to this problem of dataset imbalance would be collecting more data,
118 but this would not guarantee we would get samples of all classes. To overcome this drawback,
119 it was created an additional synthetic dataset supported by literature to explore a vast
120 variety of samples setup balancing the examples amount from each class.

121 The synthetic dataset was created executing 130 random generation, where each one was
122 composed of 1000 samples grounded by the intervals of six different standards (Kauffman

123 et al., 1993; Van Laack et al., 1996; Warner et al., 1997; Van Laack and Kauffman, 1999;
 124 Faucitano et al., 2010; Barbin et al., 2012) (Table 1). The real-life and synthetic dataset are
 125 available online¹.

Table 1: Standards and parameters for classification of pork quality

Standard	Class	pH _u	WHC		L*	
			FPW	DL	CieLab	HunterLab
Kauffman et al. (1993)	PSE	-	-	>5.0	-	>58
	RSE	-	-	>5.0	-	52-58
	PFN	-	-	<5.0	-	>58
	RFN	-	-	<5.0	-	52-58
	DFD	-	-	<5.0	-	<52
Van Laack et al. (1996)	PSE	<5.5	-	>5.0	>50	-
	RSE	<5.9	-	>5.0	43-49	-
	RFN	5.4-6.0	-	<5.0	43-49	-
	DFD	>6.0	-	<2.0	<43	-
Warner et al. (1997)	PSE	<6.0	-	>5.0	>50	-
	RSE	<6.0	-	>5.0	42-50	-
	RFN	<6.0	-	<5.0	42-50	-
	DFD	≥6.0	-	<5.0	<42	-
Van Laack; Kauffman (1999)	PSE	-	-	>6.0	>50	-
	RSE	-	-	>6.0	<50	-
	RFN	-	-	<6.0	<50	-
Faucitano et al. (2010)	PSE	<6.0	≥80	≥4.76	>50	-
	PFN	<6.0	<80	<4.76	>50	-
	RSE	<6.0	≥80	≥4.76	43-48	-
	RFN	<6.0	<80	<4.76	43-48	-
	DFD	≥6.0	<40	<2.2	<42	-
Barbin et al. (2012)	PSE	5.45 ± 0.08	-	7.0 ± 1.5	53.1 ± 1.7	-
	RFN	5.59 ± 0.15	-	3.8 ± 0.6	47.2 ± 2.8	-
	DFD	6.11 ± 0.19	-	0.6 ± 0.2	39.2 ± 1.9	-

DL (drip loss); *FPW* (filter-paper wetness); - DFD (dark, firm, dry); PFN (pale, firm, non-exudative); PSE (pale, soft, exudative); RFN (red, firm, non-exudative); RSE (red, soft, exudative)

¹<http://www.uel.br/grupo-pesquisa/remid>

126 *2.3. Meta-dataset and Meta-features*

127 Meta-dataset is the repository used to support the induction of a meta-model (or pre-
 128 predictor). This repository is composed of meta-features and a target related to their best
 129 match. Thus, each dataset (real-life or synthetic) had their meta-features extracted and
 130 assessed to the best pork quality standard among six possibilities (exposed in Table 1. The
 131 identification of most adequate standard was performed observing the greatest number of
 132 classified samples with minimal bias when compared all the standards over a given dataset.
 133 In Figure 2 is possible to observe the creation of the meta-dataset from original datasets.

134 For instance, a dataset N with 1,000 samples, classified with Kauffman et al. (1993) had
 135 376 hits, Van Laack et al. (1996) - 378, Warner et al. (1997) - 385, Van Laack and Kauffman
 136 (1999) - 339, Faucitano et al. (2010) - 341 and Barbin et al. (2012) - 400, so, the dataset was
 137 labeled as Barbin et al. (2012), indicating Barbin et al. (2012) is the most suitable standard
 138 to classify the dataset observed. And this process was made to label all the datasets.

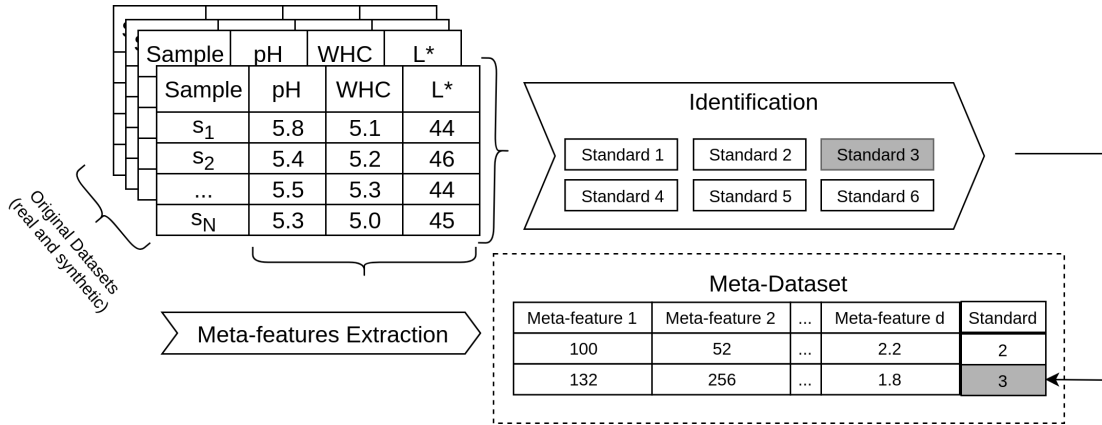


Figure 2: Meta-dataset construction with identification of best standard and meta-features

139 The meta-features extracted was grounded in statistical moments (mean, standard devi-
 140 ation, skewness and kurtosis), information theory (entropy) and simple descriptive informa-
 141 tion (maximum and minimum values) of original parameters (pH , WHC , L^*) as suggested
 142 in literature Mantovani et al. (2015); Campos et al. (2016).

143 The meta-dataset was composed of 140 instances (one from each dataset), 21 meta-
 144 features and the suitable dataset according to the identification process. The next step was
 145 to induce the meta-model to perform the predict a standard from a new dataset.

146 *2.4. Meta-model*

147 J48 Decision Tree (Quinlan, 1993) was selected to build the meta-model. This algorithm
 148 was chosen due generate a user-friendly model supporting an ease comprehension. A DT
 149 model is characterized by branches related to a given feature and threshold started from a
 150 root node, and each leaf node represents a class label (e.g. pork quality standard). The
 151 first division of the DT occurs from the root node and the choice of the meta-feature that
 152 represents this is the one that presents the highest gain of information and this occurs

153 because of the higher the gain of information, the more efficient the division (Quinlan, 2014).
 154 The path from root node to leaf represent classification rules. An important advantage
 155 of J48 is related to the determination of hierarchical relationship from the meta-features,
 156 automatically selecting the ones that best explain the problem.

157 The environment used to create the meta-model was WEKA 3.8 (Witten and Frank,
 158 2000). It was used the standard hyper-parameters in the algorithm considering the full
 159 training set as classifier model.

160 3. Results and Discussion

161 The obtained meta-model to meta-recommend the adequate pork quality standard was
 162 able to perform its task with a high level of performance. The accuracy of 100% showed hit of
 163 all suitable standards for real and synthetic datasets. The coefficient of agreement (Kappa)
 164 presented maximum value, demonstrating the trustworthiness of the model performance and
 165 validating the interpretation of the result as legitimate and not by chance (Cohen, 1960).
 166 The 140 instances were correctly classified and confirm the robustness and precision of the
 167 meta-recommendation model generated. Furthermore, the meta-features selected were able
 168 to distinguish each standard in the literature to perform the recommendation.

169 Another important achievement was a concise *DT* as possible to see in Figure 3. The ob-
 170 tained *DT* was not complex, since based on only 4 meta-features it is possible to recommend
 171 a pork quality standard.

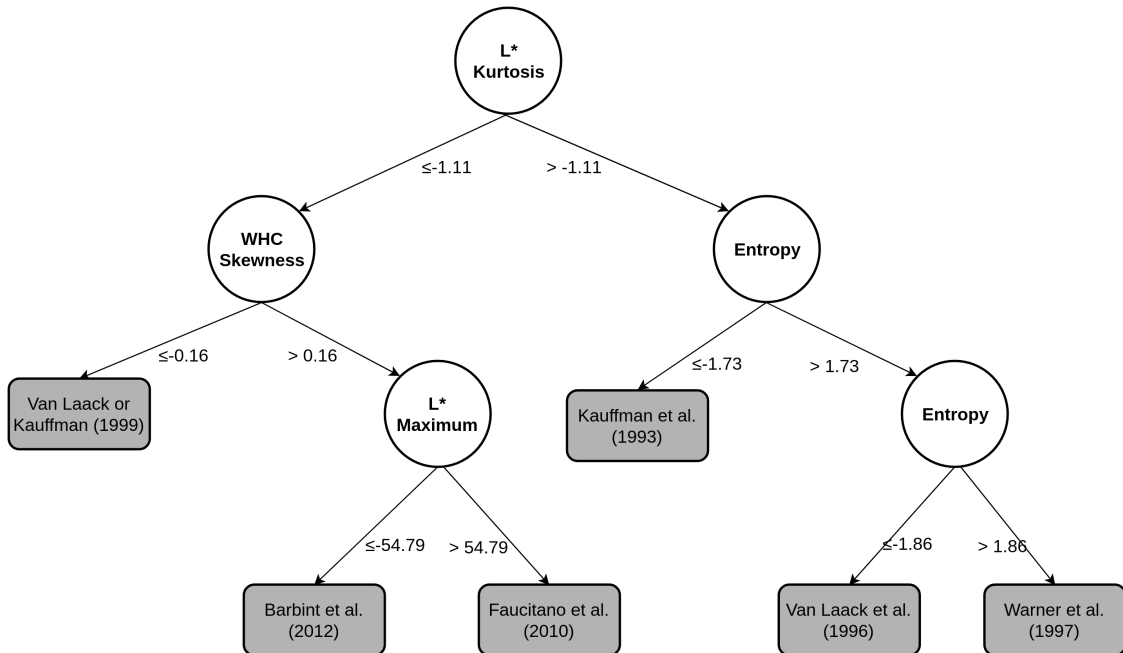


Figure 3: Decision Tree (J48) to indicate the most suitable pork quality standard

172 We verified that the root node was represented by the meta-feature L^* Kurtosis, fol-
 173 lowed by the intermediary nodes (WHC Skewness, Entropy and L^* Maximum) and each

174 leaf presented the most appropriate standard to classify the pork quality for the dataset in
175 this study.

176 The choice of the L^* parameter may be surprising at first, since the determination of
177 meat quality is usually associated with the sum of all meat quality characteristics, such as
178 *WHC* and color, which are directly affected by muscle pH (Pearce et al., 2011). But if we
179 look at Table 1, some standards do not use pH to classify pork quality, using only *WHC*
180 and L^* .

181 Possible explanations for *pH* not be chosen as the most important meta-feature of *DT*
182 is that it does not appear as a parameter of the quality classification in all standards.

183 There is also the idea of cause and consequence, due to the fact there is high correlation
184 between *pH* and L^* (Boler et al., 2010; Wyrwicz et al., 2012; Kim et al., 2016).

185 Considering a hypothetical situation in which the *pH* decreases during postmortem
186 metabolism, the *WHC* will be smaller, since the *pH* condition of the meat approaching
187 the isoelectric point of the myofibrillar proteins provides a situation of neutralization of the
188 positive and negative charges, reducing the intracellular space, resulting in greater amount
189 of exudate on the surface of the meat (Lawrie, 2006; Bowker and Zhuang, 2015). This alter-
190 ation of the myofibrillar structure affects the light scattering properties and the pork gets
191 lighter (Hughes et al., 2014). Moreover, the opposite is also true.

192 Some insights about the pork standard behaviour were obtained observing the *DT* struc-
193 ture. The most recent standards (Barbin et al. (2012) and Faucitano et al. (2010)) are
194 differentiable with a split of L^* maximum, concerning only the L^* defined threshold. On
195 the other hand, the former standards (Kauffman et al. (1993); Van Laack et al. (1996); ?)
196 could be identified observing just the entropy meta-feature of a given dataset.

197 Therefore, *DT* main advantages in meta-recommending the most suitable pork quality
198 standard are: easy interpretation of the results, robustness (even in the presence of noise),
199 standardization for the choice of pork quality classification (Tan et al., 2005).

200 4. Conclusion

201 Meat quality evaluation is essential for the food industry. However, a question arises:
202 “What is the adequate technological quality standard to classify a given pork sample?”. This
203 question could be answered by the use of a meta-recommendation solution from Machine
204 Learning.

205 Using meta-features extracted from the original datasets of samples quality evaluation
206 we could build a *DT* meta-model capable of addressing in all experimental cases a right one
207 standard among six pork quality standards. Furthermore, some peculiarities and assump-
208 tions of the current literature models could be made. Thus, our proposal contributes to the
209 choice of the most suitable standard towards presenting more reliable results concerning the
210 majority classification of the samples.

211 5. Acknowledgments

212 The authors would like to thank CAPES (National Council for the Improvement of Higher
213 Education) and CNPq (National Council for the Scientific and Technological Development)

214 (Brazilian Agencies) for their financial support.

215 References

- 216 Andersen, H. J., Oksbjerg, N., Young, J. F., Therkildsen, M., 2005. Feeding and meat quality—a future
217 approach. *Meat science* 70 (3), 543–554.
- 218 Barbin, D., Elmasry, G., Sun, D.-W., Allen, P., 2012. Near-infrared hyperspectral imaging for grading and
219 classification of pork. *Meat Science* 90 (1), 259–268.
- 220 Barbon, A. P. A., Barbon, S., Mantovani, R. G., Fuzyi, E. M., Peres, L. M., Bridi, A. M., 2016a. Storage
221 time prediction of pork by computational intelligence. *Computers and Electronics in Agriculture* 127,
222 368–375.
- 223 Barbon, A. P. A., Jr., S. B., Mantovani, R. G., Fuzyi, E. M., Peres, L. M., Bridi, A. M., 2016b. Storage time
224 prediction of pork by computational intelligence. *Computers and Electronics in Agriculture* 127, 368 –
225 375.
- 226 Bauer, A., Petzet, A., Schwagele, F., Scheier, R., Schmidt, H., August 2013. Towards an online assessment
227 of meat quality in pork. 59th International Congress of Meat Science and Technology.
- 228 Boler, D., Dilger, A., Bidner, B., Carr, S., Eggert, J., Day, J., Ellis, M., McKeith, F., Killefer, J., 2010.
229 Ultimate pH explains variation in pork quality traits. *Journal of muscle foods* 21 (1), 119–130.
- 230 Bowker, B., Zhuang, H., 2015. Relationship between water-holding capacity and protein denaturation in
231 broiler breast meat. *Poultry science* 94 (7), 1657–1664.
- 232 Caballero, D., Caro, A., Rodríguez, P. G., Durán, M. L., del Mar Ávila, M., Palacios, R., Antequera, T.,
233 Pérez-Palacios, T., 2016. Modeling salt diffusion in iberian ham by applying MRI and data mining. *Journal*
234 *of Food Engineering*.
- 235 Campos, G. F., Barbon, S., Mantovani, R. G., 2016. A meta-learning approach for recommendation of
236 image segmentation algorithms. In: *Graphics, Patterns and Images (SIBGRAPI)*, 2016 29th SIBGRAPI
237 Conference on. IEEE, pp. 370–377.
- 238 Cazedey, H. P., Torres Filho, R. d. A., Fontes, P. R., Ramos, A. d. L. S., Ramos, E. M., 2016. Comparison
239 of different criteria used to categorize technological quality of pork. *Ciência Rural (AHEAD)*, 0–0.
- 240 Channon, H., Payne, A., Kerr, M., Meredith, P., Weston, P., Baud, S., Walker, P., 2001. Ultimate pH is a
241 poor predictor of pork eating quality. *Manipulating Pig Production VII.*(Ed. PD Cranwell). Australasian
242 Pig Science Association, Werribee, Australia, 85.
- 243 Channon, H., Payne, A., Warner, R., 2000. Halothane genotype, pre-slaughter handling and stunning method
244 all influence pork quality. *Meat Science* 56 (3), 291–299.
- 245 CIELab, 1976. Recommendations on uniform color spaces, color differences, equations. *psychometric color*
246 *terms* (15).
- 247 Cohen, J., 1960. A coefficient of agreement for nominal scales. *Educational and psychological measurement*
248 20 (1), 37–46.
- 249 de Souza, B. F., Prudêncio, R. B., de Carvalho, A., 2001. Meta-aprendizado para recomendação de algorit-
250 mos. *Jornadas de atualização em Informática*, 159–208.
- 251 Du, C.-J., Sun, D.-W., 2006. Learning techniques used in computer vision for food quality evaluation: a
252 review. *Journal of food engineering* 72 (1), 39–55.
- 253 Durkin, I., Margeta, V., Margeta, P., Kralik, G., Kušec, G., et al., 2009. Preliminary investigations on
254 relationship between polymorphism at CAST locus and the quality of pork. *Poljoprivreda* 15 (2), 53–58.
- 255 Elmasry, G., Barbin, D. F., Sun, D.-W., Allen, P., 2012. Meat quality evaluation by hyperspectral imaging
256 technique: an overview. *Critical reviews in food science and nutrition* 52 (8), 689–711.
- 257 Faucitano, L., Ielo, M., Ster, C., Fiego, D. L., Methot, S., Saucier, L., 2010. Shelf life of pork from five
258 different quality classes. *Meat science* 84 (3), 466–469.
- 259 Flores, M., Armero, E., Aristoy, M.-C., Toldra, F., 1999. Sensory characteristics of cooked pork loin as
260 affected by nucleotide content and post-mortem meat quality. *Meat Science* 51 (1), 53–59.
- 261 Hamm, R., 1960. Biochemistry of meat hydration. *Advances in food research* 10, 355–463.
- 262 Harrington, P., 2012. *Machine learning in action*. Vol. 5. Manning Greenwich, CT.

- 263 He, H., Garcia, E. A., 2009. Learning from imbalanced data. *IEEE Transactions on knowledge and data*
264 *engineering* 21 (9), 1263–1284.
- 265 Hofmann, K., 1994. What is quality? definition, measurement and evaluation of meat quality. *Meat Focus*
266 *International* (United Kingdom).
- 267 Hughes, J., Oiseth, S., Purslow, P., Warner, R., 2014. A structural approach to understanding the interac-
268 tions between colour, water-holding capacity and tenderness. *Meat science* 98 (3), 520–532.
- 269 Joo, S., Kauffman, R., Warner, R., Borggaard, C., Stevenson-Barry, J., Rhee, M.-S., Park, G., Kim, B.-C.,
270 2000. Objectively predicting ultimate quality of post-rigor pork musculature. *Asian-Australasian Journal*
271 *of Animal Sciences* 13 (1), 77–85.
- 272 Joo, S., Kim, G., Hwang, Y., Ryu, Y., 2013. Control of fresh meat quality through manipulation of muscle
273 fiber characteristics. *Meat science* 95 (4), 828–836.
- 274 Kamruzzaman, M., Makino, Y., Oshita, S., 2016. Rapid and non-destructive detection of chicken adulter-
275 ation in minced beef using visible near-infrared hyperspectral imaging and machine learning. *Journal of*
276 *Food Engineering* 170, 8–15.
- 277 Kauffman, R., Sybesma, W., Smulders, F., Eikelenboom, G., Engel, B., Van Laack, R., Hoving-Bolink, A.,
278 Sterrenburg, P., Nordheim, E., Walstra, P., et al., 1993. The effectiveness of examining early post-mortem
279 musculature to predict ultimate pork quality. *Meat Science* 34 (3), 283–300.
- 280 Kim, T. W., Kim, C. W., Yang, M. R., No, G. R., Kim, S. W., Kim, I.-S., 2016. Pork quality traits
281 according to postmortem pH and temperature in berkshire. *Korean journal for food science of animal*
282 *resources* 36 (1), 29.
- 283 Kodogiannis, V. S., Pachidis, T., Kontogianni, E., 2014. An intelligent based decision support system for
284 the detection of meat spoilage. *Engineering Applications of Artificial Intelligence* 34, 23–36.
- 285 Kušec, G., Kralik, G., Durkin, Ivona and Petričević, Antun and Hanžekl, Danica, 2007. Factors discrimi-
286 nating between different pork quality conditions. *POLJOPRIVREDA* 13 (1), 66–69.
- 287 Lawrie, R., 2006. *Lawrie’s meat science*. Cambridge: Woodhead Publishing Limited.
- 288 Lee, S., Norman, J., Gunasekaran, S., Van Laack, R., Kim, B., Kauffman, R., 2000. Use of electrical
289 conductivity to predict water-holding capacity in post-rigor pork. *Meat Science* 55 (4), 385–389.
- 290 Liu, C., Yang, S. X., Deng, L., 2015. Determination of internal qualities of newhall navel oranges based on
291 nir spectroscopy using machine learning. *Journal of Food Engineering* 161, 16–23.
- 292 Maganhini, M. B., Mariano, B., Soares, A. L., Guarnieri, P. D., Shimokomaki, M., Ida, E. I., 2007. Carnes
293 pse (pale, soft, exudative) e dfd (dark, firm, dry) em lombo suíno numa linha de abate industrial. *Ciência*
294 *e Tecnologia de Alimentos* 27 (suppl 1), 69–72.
- 295 Maltin, C., Balcerzak, D., Tilley, R., Delday, M., 2003. Determinants of meat quality: tenderness. *Proceed-*
296 *ings of the Nutrition Society* 62 (02), 337–347.
- 297 Mantovani, R. G., Rossi, A. L., Vanschoren, J., Carvalho, A. C. P. d. L., et al., 2015. Meta-learning recom-
298 mendation of default hyper-parameter values for svms in classifications tasks. In: *European Conference*
299 *on Machine Learning and Principles and Practice of Knowledge Discovery in Databases; International*
300 *Workshop on Meta-Learning and Algorithm Selection*. University of Porto.
- 301 Marsland, S., 2015. *Machine learning: an algorithmic perspective*. CRC press.
- 302 Mohareb, F., Papadopoulou, O., Panagou, E., Nychas, G.-J., Bessant, C., 2016. Ensemble-based support
303 vector machine classifiers as an efficient tool for quality assessment of beef fillets from electronic nose
304 data. *Analytical Methods* 8 (18), 3711–3721.
- 305 Osório, M., Osório, J., 2000. Condições de abate e qualidade de carne. *EMBRAPA*. Curso de qualidade de
306 carne e dos produtos cárneos. Bagé/RS: EMBRAPA 4, 77–128.
- 307 Pearce, K. L., Rosenvold, K., Andersen, H. J., Hopkins, D. L., 2011. Water distribution and mobility in meat
308 during the conversion of muscle to meat and ageing and the impacts on fresh meat quality attributes—a
309 review. *Meat science* 89 (2), 111–124.
- 310 Quinlan, J. R., 1993. *C4.5: Programs for Machine Learning*. Morgan Kaufmann Publishers Inc., San Fran-
311 cisco, CA, USA.
- 312 Quinlan, J. R., 2014. *C4. 5: programs for machine learning*. Elsevier.
- 313 Reif, M., Shafait, F., Dengel, A., 2012. Meta-learning for evolutionary parameter optimization of classifiers.

314 Machine learning 87 (3), 357–380.

315 Santos, C., Roseiro, L., Goncalves, H., Melo, R., 1994. Incidence of different pork quality categories in a
316 portuguese slaughterhouse: A survey. *Meat science* 38 (2), 279–287.

317 Sanz, J. A., Fernandes, A. M., Barrenechea, E., Silva, S., Santos, V., Gonçalves, N., Paternain, D., Jurio, A.,
318 Melo-Pinto, P., 2016. Lamb muscle discrimination using hyperspectral imaging: Comparison of various
319 machine learning algorithms. *Journal of Food Engineering* 174, 92–100.

320 Sima, C., Heres, L., Klont, R., Mireşan, V., 2015. The effect of pre-slaughter resting time on the quality of
321 pork meat. *Bulletin of University of Agricultural Sciences and Veterinary Medicine Cluj-Napoca. Animal
322 Science and Biotechnologies* 72 (1), 81–84.

323 Soares, C., Brazdil, P. B., 2006. Selecting parameters of svm using meta-learning and kernel matrix-based
324 meta-features. In: *Proceedings of the 2006 ACM symposium on Applied computing. SAC’06*. ACM Press,
325 pp. 564–568.

326 Soares, C., Brazdil, P. B., Kuba, P., 2004. A meta-learning method to select the kernel width in support
327 vector regression. *Machine Learning* 54 (3), 195–209.

328 Sosnicki, A., Pommier, S., Klont, R., Newman, S., Plastow, G., 2003. Best-cost production of high quality
329 pork: bridging the gap between pig genetics, muscle biology/meat science and consumer trends. In:
330 *Proceedings of manitoba pork seminar*.

331 Tan, P.-N., Steinbach, M., Kumar, V., 2005. *Introduction to data mining*. 1st.

332 Tomovic, V. M., Zlender, B. A., Jakanović, M. R., Tomovic, M. S., Sojic, B. V., Skaljic, S. B., Tasic,
333 T. A., Ikonc, P. M., Soso, M. M., Hromis, N. M., 2014. Technological quality and composition of the m.
334 semimembranosus and m. longissimus dorsi from large white and landrace pigs. *Agricultural and Food
335 Science* 23 (1), 9–18.

336 Van Laack, R., Kauffman, R. G., 1999. Glycolytic potential of red, soft, exudative pork longissimus muscle.
337 *Journal of Animal Science* 77 (11), 2971–2973.

338 Van Laack, R., Solomon, M., Warner, R., Kauffman, R., 1996. A comparison of procedures for measurement
339 of pigment concentration in pork. *Journal of Muscle Foods* 7 (2), 149–163.

340 Warner, R., Kauffman, R., Greaser, M., 1997. Muscle protein changes post mortem in relation to pork
341 quality traits. *Meat science* 45 (3), 339–352.

342 Wilhelm, A. E., Maganhini, M. B., Hernández-Blazquez, F. J., Ida, E. I., Shimokomaki, M., 2010. Protease
343 activity and the ultrastructure of broiler chicken pse (pale, soft, exudative) meat. *Food Chemistry* 119 (3),
344 1201–1204.

345 Witten, I. H., Frank, E., 2000. *Weka. Machine Learning Algorithms in Java*, 265–320.


346 Wong, T.-T., 2016. Parametric methods for comparing the performance of two classification algorithms
347 evaluated by k-fold cross validation on multiple data sets. *Pattern Recognition*.

348 Wyrwisz, J., Pótorak, A., Zalewska, M., Zaremba, R., Wierzbicka, A., 2012. Analysis of relationship between
349 basic composition, pH, and physical properties of selected bovine muscles. *Bulletin of the Veterinary
350 Institute in Pulawy* 56 (3), 403–409.

6 ARTIGO II***FUZZY APPROACH FOR CLASSIFICATION OF PORK INTO
QUALITY GRADES: COPING WITH UNCLASSIFIABLE
SAMPLES***

Redigido segundo as normas da revista:

Computers and Electronics in Agriculture



Fuzzy approach for classification of pork into quality grades: coping with unclassifiable samples



Louise Manha Peres^a, Sylvio Barbon Jr.^{b,*}, Estefânia Mayumi Fuzyi^c, Ana Paula A.C. Barbon^a, Douglas Fernandes Barbin^d, Priscila Tiemi Maeda Saito^e, Nayara Andreo^a, Ana Maria Bridi^a

^a Department of Animal Science, Londrina State University (UEL), Londrina 86057-970, Brazil

^b Department of Computer Science, Londrina State University (UEL), Londrina 86057-970, Brazil

^c Department of Inf., Pontifícia Univ. Católica do Paraná (PUCPR), Curitiba 80215-901, Brazil

^d Department of Food Engineering, Campinas State University (UNICAMP), Campinas 13083-862, Brazil

^e Department of Computing, Fed. Univ. of Tecn. - Parana (UTFPR), Cornélio Procópio 86300-000, Brazil

ARTICLE INFO

Keywords:

Classical logic
Classification
Computational intelligence
Fuzzy Logic
Meat
Pattern recognition

ABSTRACT

Meat classification methods are commonly based on quality parameters standardized by numeric ranges. However, some animal samples from different production chains do not match the current grades proposed. These unclassifiable samples are not capable to fit into a standard created by crisp range of values due to being infeasible toward its definition. An alternative to handle this kind of sample classification is the fuzzy logic, which could deal with uncertainty and ambiguity degree like human reasoning. In this work, we compare the traditional classification method and fuzzy approaches with the objective to handle the infeasible samples. This was compared to traditional pork standards using eleven real-life datasets with a total of 1798 samples described by *pH*, water holding capacity and/or *L** value. The results demonstrated that traditional classification could not predict the unclassifiable samples. On the other hand, the fuzzy approaches improve significantly the number of classified samples. Performance of the fuzzy approaches were compared with several machine learning algorithms, but no significant statistical difference was observed. Finally, a real-life study case was explored, highlighting some advantages and further achievements of the fuzzy modeling.

1. Introduction

Meat quality has been increasingly important as a large supply chain, and it raises concerns of demanding consumers (We glarz, 2010; Campos et al., 2014).

The widely used parameters concerning pork quality are *pH*, water holding capacity (*WHC*), color and firmness. These parameters are determined according to standards, which differ from each other as a combination of subjective and objective measurements that vary according to the markets (USA, 2003). The *pH* is one of the most important factors in the conversion from muscle to meat (Dutson, 1983). *WHC* refers to the meat ability to retain water during the application of force (compression, drip loss, shear) or external treatment (Huff-Lonergan and Lonergan, 2005; Silva Sobrinho et al., 2005) and influence meat succulence. And meat visual aspect, e.g. color intensity, also covers important features for quality evaluation as it is related to initial product choice and acceptability. Hence, color feature has a straightforward relation to consumer perceptions (Fletcher, 1999). There is a

high variation in pork quality (Bauer et al., 2013), since variations have been observed between quality parameters. Thus, some experiments led to an inaccurate evaluation of the pork quality (Warriss and Brown, 1987; Van Laack et al., 1994).

Several quality standards have been proposed to evaluate pork in the industry: Barbin et al. (2012) and Tomovic et al. (2014) include three classes of pork quality, Warner et al. (1997) and Joo et al. (2000) propose four classes, Kauffman et al. (1993) and Fautitano et al. (2010) propose five classes, while Bauer et al. (2013) suggests 8 classes. The main classes described in the literature are *PSE* (pale, soft, exudative), *PFN* (Pale, firm, non-exudative), *RSE* (red, soft, exudative), *RFN* (red, firm, non-exudative) and *DFD* (dark, firm, dry), resulting from the combination of *pH*, *WHC* and/or *L** value.

However, even with several classification standards proposed, pork meat classification remains a challenge due to the strict values (Crispness) of each quality parameter. For example, in the study of Fautitano et al. (2010), 14% of loins evaluated could not be classified according to the quality criteria used, being considered infeasible samples, because

* Corresponding author.

E-mail addresses: barbon@uel.br (S. Barbon Jr), emfuzyi@ppgia.pucpr.br (E.M. Fuzyi), dfbarbin@unicamp.br (D.F. Barbin), psaito@utfpr.edu.br (P.T. Maeda Saito), ambridi@uel.br (A.M. Bridi).

<https://doi.org/10.1016/j.compag.2018.05.009>

Received 30 August 2017; Received in revised form 21 February 2018; Accepted 7 May 2018
0168-1699/© 2018 Elsevier B.V. All rights reserved.

these did not match the standard's parameters. Infeasible samples could be simply discarded, or manually converted, when possible (Chen and Li, 2010).

The problem persists even for new standards proposed (Adorni et al., 2001). All the proposed classifications are formed by rigid thresholds that are different from each standard, and use classical logic to deal with the pork samples. In other words, if a pork sample does not match a given quality class, it cannot be classified, becoming an infeasible sample. This fact increases the difficulty to classify a sample that does not adjust in the expected parameter interval.

Classical set theory establishes crisp limits. Therefore, an element may or may not belong to a determined set. In fuzzy sets, there is a membership degree of each item to a determined set, that makes a gradual transition between full membership and no membership (Jensen and Shen, 2008; Coutinho et al., 2015).

There have been several approaches to deal with this issue. The most prominent are using the fuzzy logic (Moore and Lodwick, 2003), that has been a valuable tool in the study of various physical and biological phenomena (Sunita and Deo, 2012). The fuzzy logic kernel is capable of modeling the uncertainty, handling quantitative data with ambiguity degree like human reasoning (Lodwick, 2002; Vásquez-Villalobos et al., 2015). Much of the research to date has been in the use of interval mathematics in fuzzy set theory, in particular, fuzzy arithmetic and fuzzy interval analysis (Lodwick, 2002).

Nowadays, one of the most used implementations of fuzzy algorithms is Fuzzy Rule-Based System (FRBS) package from R. This solution was applied with success for storage time prediction of pork meat in comparison to sophisticated machine learning (ML) solutions as Random Forest (RF), Artificial Neural Networks (ANN) and Support Vector Machine (SVM) and the results showed that, although RF was the best one, FRBS also presented significant performance, reaching 93.93% of accuracy (Barbon et al., 2016).

In the current study, we propose to evaluate three different implementations of four pork quality grading standards according to Kauffman et al. (1993), Warner et al. (1997), Joo et al. (2000) and Fautitano et al. (2010). These standards are based on pH, WHC and L^* value. The fuzzy models were built for each grade, and the classification results compared against the classical logic aiming to improve the capability of the pork quality standard to handle the infeasible samples.

There are several methods to fuzzy logic modeling (Hüllermeier, 2015). We investigated three model constructions: classical logic, fuzzy top-down and fuzzy bottom-up approaches. Classical logic is based on the grade's rule composed of crisp limits. Top-down is a manual fuzzy classification model designed by human experts, where the limits and degrees need to be designed by adapting the crisp limits. Bottom-up is the fuzzy classification model induced by a ML supervised approach, also called as data-driven. In this last method, the relationships, limits and degrees between dependent and independent parameters are obtained automatically based on labeled datasets.

Therefore, we introduced the fuzzy modeling to pork quality assessment capable of enhancing the number of samples classified. This was accomplished through fuzzy classification of the infeasible samples obtained from crisp grade.

2. Materials and methods

2.1. Pork quality standards

Our classification experiments were based in four standards already described in the literature: Kauffman et al. (1993), Warner et al. (1997), Joo et al. (2000) and Fautitano et al. (2010), using the pH, WHC and/or lightness (L^* value) parameters (Table 1).

Pork samples ($n = 1798$) were collected and pH, WHC and lightness (L^*) parameters were measured in the *longissimus dorsi at lumborum* muscle, between the penultimate and last ribs of the left half of cooled carcasses ($2 \pm 2^\circ\text{C}$) 24 h after slaughter.

Table 1

Pork quality standards used in the experiments PSE (pale, soft, exudative); PFN (pale, firm, non-exudative); RSE (red, soft, exudative); RFN (red, firm, non-exudative); DFD (dark, firm, dry).

Standard	Class	pHu	WHC	L^*
Kauffman et al. (1993)	PSE	–	> 5	> 58
	RSE	–	> 5	52–58
	PFN	–	< 5	> 58
	RFN	–	< 5	52–58
	DFD	–	< 5	< 52
Warner et al. (1997)	PSE	< 6	> 5	> 50
	RSE	< 6	> 5	42–50
	RFN	< 6	< 5	42–50
	DFD	≥ 6	< 5	< 42
	Joo et al. (2000)	PSE	–	≥ 6
RSE	–	–	≥ 6	≤ 50
RFN	–	–	≤ 6	≥ 43
DFD	–	–	≤ 6	≤ 43
Fautitano et al. (2010)	PSE	< 6	≥ 4.76	> 50
	PFN	< 6	< 4.76	> 50
	RSE	< 6	≥ 4.76	43–48
	RFN	< 6	< 4.76	43–48
	DFD	≥ 6	< 2.2	< 42

Ultimate pHu was measured 24 h *post mortem* using a Testo 205 pH-meter; WHC was measured by pressing method (PM) proposed by Hamm (1960) and adapted by Wilhelm et al. (2010), while L^* value (lightness) was acquired with a Minolta R portable colorimeter (model CR-10 colorimeter with illuminant D65 and 8° angle of inclination - Tokyo, JP) after blooming for 30 min (CIE, 1978).

Some quality standards consider different methodologies for WHC and L^* . Hence, WHC was also converted, as Kauffman's and Fautitano's standard used pressing method (PM) and filter paper wetness (FPW), respectively. This conversion was carried out in order to compare results from different classification standards. Normalized drip loss (DL) parameter was performed using Eqs. (1) and (2) as proposed by Peres et al. (2011). L^* was converted from HunterLab to CIELab* for Kauffman's standard as exposed in Eqs. (3)–(5). In these equations, Y represents the luminance, X and Z are the chromatic values (Billmeyer and Hammond, 1990).

$$DL = 0.100707 \cdot PM \quad (1)$$

$$DL = -0.36 + 0.064 \cdot FPW \quad (2)$$

$$H(L) = 10 \sqrt{Y} \quad (3)$$

$$H(a) = 17.5 \cdot \frac{(1.02 \cdot X) - Y}{\sqrt{Y}} \quad (4)$$

$$H(b) = 7 \cdot \frac{Y - (0.847 \cdot Z)}{\sqrt{Y}} \quad (5)$$

2.2. Organization of the experiments and datasets

Three classification approaches were performed (Fig. 1): classical logic (Experiment 1), top-down considering fuzzy logic (Experiment 2) and fuzzy bottom-up and ML algorithms (Experiment 3). Experiment 1 was performed to obtain the classification and the number of unclassified samples. Experiment 2 was carried out to observe the behavior of fuzzy top-down approaches (designed by a specialist) for classifying all real-life datasets, mainly the unclassified samples observed in Experiment 1. Finally, Experiment 3 was carried out to observe the capacity to deal with the infeasible samples using ML algorithms.

For the three aforementioned experiments, we considered two dataset profiles: eleven real-life and four synthetic datasets. In total there were fifteen datasets, eleven real-life and four synthetic datasets

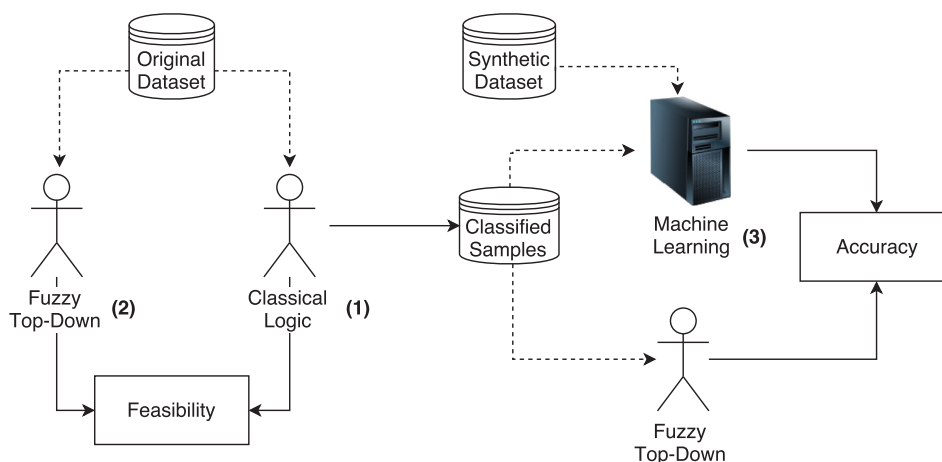


Fig. 1. Methodology overview for evaluating the contribution of the fuzzy approach.

Table 2
Statistical descriptions (average and standard deviation) of the real and synthetic datasets.

Dataset	Total	pH		WHC		L*	
		Avg	Sd	Avg	Sd	Avg	Sd
Real-life							
D1	73	5.56	0.15	3.34	0.35	52.92	3.35
D2	306	5.78	0.36	2.88	0.54	53.80	3.21
D3	405	5.68	0.16	2.71	0.44	52.44	2.62
D4	117	5.52	0.13	3.17	0.43	50.39	2.56
D5	54	5.86	0.24	2.94	0.59	50.36	2.31
D6	44	5.74	0.09	4.99	2.41	55.09	2.83
D7	48	5.56	0.13	4.97	2.15	56.44	4.63
D8	144	5.58	0.11	3.30	0.38	54.45	3.35
D9	70	5.86	0.06	3.62	1.50	52.12	2.33
D10	40	5.54	0.15	3.45	0.42	52.20	3.66
D11 - Study case	497	5.75	0.22	3.74	2.23	47.35	3.82
Total	1798						
Synthetic							
D12 - Falcitano	1000	4.17	2.96	6.45	4.30	49.22	12.86
D13 - Joo	1000	-	-	6.20	4.19	45.54	14.72
D14 - Kauffman	1000	-	-	5.57	4.12	54.70	11.22
D15 - Warner	1000	4.50	3.13	6.02	4.17	45.69	11.36
Total	4000						

(Table 2).

The real-life samples were obtained from pigs slaughtered in commercial slaughterhouses and then analyzed in laboratory to obtain the information of *pHu*, *WHC* and *L** value. These datasets needed to be labeled in order to induce the *ML* algorithms and further analysis. In this way, the feasible samples of the real datasets were labeled by classical logic from Experiment 1.

The meat quality has an association with handling pre and post-slaughter factors. Thus, it is expected that the real-life dataset is imbalanced, once it does not include the same number of samples for each class, neither instances of all the classes considered.

The imbalance can significantly compromise the performance of the *ML* algorithms, providing an unsatisfactory classification accuracy (He and Garcia, 2009).

A possible solution to this problem would be to collect more samples, but as previously mentioned, we cannot control or guarantee that samples of all classes will be obtained. As an alternative, we create synthetic datasets for each grading standard.

We randomly generate samples, defining their feature values within

the thresholds established by each grading standard, as well as covering all classes and with a balanced number of samples for each class (Table 2).

2.2.1. Classical logic

In Experiment 1, it was applied the conventional algorithm based on IF-THEN conditions by implementing ranges of standards. These algorithms were used only over the real-datasets for each standard, according to the particular parameter limits. For instance, the Algorithm 1 is the implementation of Warner’s grading standard.

Algorithm 1. Warner’s grading algorithm implemented by classical logic approach

```

1: forDatasetdo
2:   if pH < 6 and L* > 50 and WHC > 5then
3:     class ← PSE
4:   else
5:     ifpH < 6 and (L* ≥ 42 and L* ≤ 50) and
      WHC > 5then
6:       class ← RSE
7:     else
8:       ifpH < 6 and (L* ≥ 42 and L* ≤ 50) and
          WHC < 5then
9:         class ← RFN
10:      else
11:        ifpH ≥ 6 and L* < 42 and WHC < 5then
12:          class ← DFD
13:        else
14:          class ← FALSE
15:        end if
16:      end if
17:    end if
18:  end if
19: end for
    
```

In this approach, an element is true or false, so there is no intermediate situation (Goldschmidt, 2010). The sets and rules are rigid, which for real-life scenarios could be a disadvantage.

The main objective of Experiment 1 was to classify the samples in order to create the golden model and identify infeasible samples for further analysis. Those unclassified samples were used in Experiment 2 toward evaluating the prediction of fuzzy approaches and exposing their advantages over the classical logic ones.

2.2.2. Fuzzy top-down

Experiment 2 was designed to evaluate the fuzzy top-down approach over infeasible samples, whose model is built by a human specialist (Müller, 2015). Thus, we created four fuzzy models (from each standard) and perform the classification of the real-life datasets. We aimed at comparing the classified samples focusing on golden model matching and infeasible handled capability of fuzzy modeling.

Fuzzy top-down was implemented in R environment,¹ supported by *FRBS* package from R. We manually designed the parameters, linguistic terms, membership function (*MF*) and rules from each standard. On the other hand, it would be possible to build the model using the *ML* approach, which was done as described in Section 2.2.3 to the fuzzy bottom-up approach.

The settings defined for the fuzzy top-down approaches are available in Table 3. The inference model adopted was MANDANI due to the straightforward creation of IF-THEN rules in comparison to TSK-type. This approach requires linear representations of rules based on a matrix modeling. The *FRBS* method offers alternatives as first, last and mean of maxima in addition to the Modified Centre of Gravity (COG). As fuzzy intersection operators, which are usually referred to as T-norm, we apply the minimum T-norm (MIN). This definition follows the statement of the real unit interval [0, 1] for the system of true values, changing the classical logic (0 or 1) to a degree of pertinence. The fuzzy union norm (S-norm) was defined as maximum S-norm (MAX). This parameter indicates a mapping between fuzzy *MF* in the interval [0, 1]. Finally, we defined the defuzzification method as Weighted Average Method (WAM) owing to best fit to our standard. The defuzzification process aggregates all fuzzy outputs and extracts a single value as the entire system output (Shaw, 2013).

The *MF* was designed considering the range of values described in each standard for any single parameter. Fig. 2 shows an example of *MF* designed from Warner's standard for the parameters: *pH*, *WHC*, *L** and the class for defuzzification. Each color in the Fig. 2 corresponds to a *MF* toward representing a fuzzy level. The IF-THEN rules (Table 4) were established based on the restrictions proposed by the Warner's grading standard. The designed *MF* illustrates the advantage of fuzzy logic system concerning the ability to capture the partial membership in a set and associate it as a rule. This is not possible with classical logic method (Bezdek, 2014).

However, this approach has some drawbacks, such as the need for parametrization to fine-tune models, requiring expert knowledge and/or historical data (da Silva, 2008). To deal with these disadvantages and apply the most recent classification techniques based on *ML* algorithms, including fuzzy modeling by *ML*, we performed Experiment 3.

2.2.3. Fuzzy bottom-up and machine learning

In Experiment 3, we evaluated the fuzzy bottom-up approach where several *ML* algorithms with R environment (similarly to Experiment 2), were used to induce models for each grading standard from the synthetic dataset. We used the synthetic dataset due to the requirement of supervised *ML* approach that demands at least some samples from each class of a given problem. Our real-life dataset did not comply with this requirements.

The algorithms and corresponding packages used to implement each *ML* algorithm are summarized in Table 5.

3. Results and discussion

Experiment 1 (Section 3.1) presents the performance of the classical logic. Experiment 2 (Section 3.2) reports the top-down approach modelled by a human specialist. On the other hand, the models built in Experiment 3 (Section 3.3) were used to evaluate the performance between fuzzy and other *ML*.

Table 3

Configuration of the inference parameters to design the fuzzy top-down models.

Parameter	Value
Model	MAMDANI
T-norm	MIN
S-norm	MAX
Defuzzification	WAM

3.1. Experiment 1: Classical logic

The total number of samples and the percentage of samples classified by classical logic over the real-life datasets (D1-D10) are presented in Table 6. In decreasing order, the grading standard that obtained better percentage of classified samples was Joo et al. (2000), followed by Kauffman et al. (1993), Faucitano et al. (2010) and Warner et al. (1997).

Joo et al. (2000) and Kauffman et al. (1993) use only *WHC* and *L** parameters, while Faucitano et al. (2010) and Warner et al. (1997) involve all three parameters (*pH*, *WHC* and *L**). Once few parameters are analyzed, the proposed grading standard turn to be simple, obtaining less infeasible samples. However, the classification could be imprecise.

Although, the standards with only two parameters (*WHC* and *L**) classified more samples and presented high classification results, we still consider that the *pH* parameter is also relevant. The *pH* is an important predictor of meat quality that influences *WHC* and *L** parameters (Sabow et al., 2015), thus being correlated.

Another relevant question is the range of parameters for the classes defined by each standard. Joo's standard (Joo et al., 2000) considered four quality classes and classified 100% of the samples. Notwithstanding, Warner et al. (1997) proposed the same 4 classes, but achieved fewer classified samples. The difference between these authors is the range of parameter values.

Joo's standard (Joo et al., 2000) covers a wide boundary for the values of the parameters, differently from that observed for other grading standards investigated. For example, regarding the parameter *L** in Warner et al. (1997), *PSE* class is within the range $L^* > 50$, *RSE* and *RFN* classes are in the range $42 > L^* > 50$, and *DFD* class between $L^* < 42$. Thus, *L** values such as 50 and 42 would not be assigned, but could occur in real samples. This fact occurs for other Warner's standard parameters. Moreover, it can be observed in Kauffman et al. (1993) for the parameters *WHC* and *L** and in the standard proposed by Faucitano et al. (2010) for the parameter *L**.

In this sense, it is possible to justify the lower percentage of samples classified by those grading standard in comparison to Joo et al. (2000). It is known that a standard is created by the observation and measurement of quality parameters considering some peculiarities such as consumer and industry demands. In this way, there is not a best or worst standard, but rather, a standard developed for a specific scenario.

3.2. Experiment 2: Top-down

In the top-down approach built by the use of fuzzy logic, as described in Section 2.2.2, Joo et al. (2000) presented the lowest number of infeasible samples (i.e. achieved 100% of classified samples for all real-life datasets considered). However, the percentage of classified samples improved significantly for Faucitano et al. (2010) (99.02%), Kauffman et al. (1993) (98.57%) and Warner et al. (1997) (68.75%) when compared to the classical approach. These results could be observed in Tables 6 and 7.

We evaluated the fuzzy logic (top-down) accuracy over the feasible samples obtained from classical logic (Table 8) and Warner's standard reached 100% for all datasets, but it is important to consider the number

¹ <https://www.r-project.org/>.

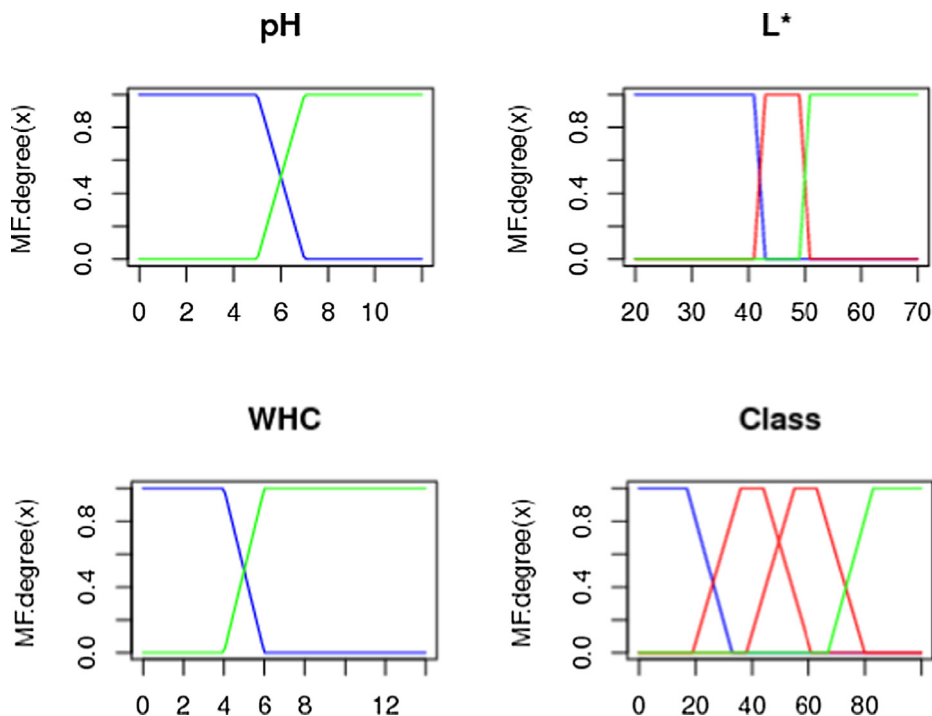


Fig. 2. Membership functions considering the Warner’s grading standard for the parameters: pH, WHC, L* value and the class for defuzzification.

Table 4
IF-THEN rules for Warner’s grading standard.

1	IF	pH	is	low	AND	WHC	is	high	AND	L*	is	high	THEN	Class	is	PSE
2	IF	pH	is	low	AND	WHC	is	high	AND	L*	is	medium	THEN	Class	is	RSE
3	IF	pH	is	low	AND	WHC	is	low	AND	L*	is	medium	THEN	Class	is	RFN
4	IF	pH	is	high	AND	WHC	is	low	AND	L*	is	low	THEN	Class	is	DFD

Table 5
Machine learning algorithms used in the experiments and corresponding R packages.

Algorithm	Description	R package
Decision Tree (J48)	A Decision Tree widely applied to represent series of rules that lead to a class or value (Medeiros et al., 2014; Sharma and Jain, 2013).	RWeka
Naïve Bayes (NB)	Classification method based on probability and statistic used in several real-life scenarios (Ma et al., 2016; Manikandan and Ramyachitra, 2014).	naivebayes
Random Forest (RF)	Combination of decision tree predictors that provides more accurate predictions (Breiman, 2001; Scornet et al., 2015).	RandomForest
Support Vector Machine (SVM)	A statistical learning theory algorithm, very popular in supervised ML and food quality solutions (Kavzoglu and Colkesen, 2009; Wang, 2005).	e1071
Fuzzy-RBS Chi (Chi)	A well known method of soft computing, based on fuzzy concepts and Chi’s technique (Riza et al., 2015)	frbs
Fuzzy-RBS W (Ishibuchi)	Ishibuchi’s technique using weight factor which allows the development of systems that represent human decisions (Riza et al., 2015)	frbs

Table 6
Samples classified by classical logic (%).

	Total	Faucitano (%)	Joo (%)	Kauffman (%)	Warner (%)
D1	73	84.93	100.00	100.00	12.33
D2	306	75.16	100.00	100.00	5.88
D3	405	85.19	100.00	100.00	16.05
D4	117	72.65	100.00	100.00	44.44
D5	54	70.37	100.00	100.00	24.07
D6	44	97.73	100.00	97.73	31.82
D7	48	95.83	100.00	97.92	47.92
D8	144	93.75	100.00	100.00	6.94
D9	70	87.14	100.00	91.43	30.00
D10	40	77.50	100.00	100.00	30.00

Table 7
Percentage of classified samples by the top-down approach.

	Total	Faucitano (%)	Joo (%)	Kauffman (%)	Warner (%)
D1	73	98.63	100.00	100.00	24.66
D2	306	99.02	100.00	100.00	18.30
D3	405	100.00	100.00	100.00	29.14
D4	117	100.00	100.00	100.00	59.83
D5	54	100.00	100.00	100.00	55.56
D6	44	100.00	100.00	97.73	65.91
D7	48	100.00	100.00	100.00	68.75
D8	144	100.00	100.00	100.00	18.75
D9	70	100.00	100.00	98.57	57.14
D10	40	100.00	100.00	100.00	40.00

Table 8
Accuracies and total of classified samples (in the brackets) using the top-down approach for each grading standard.

	Faucitano (%)	Joo (%)	Kauffman (%)	Warner (%)
D1	100.00 (62)	100.00 (73)	97.26 (73)	100.00 (9)
D2	100.00 (230)	100.00 (306)	92.48 (306)	100.00 (18)
D3	99.71 (345)	100.00 (405)	98.52 (405)	100.00 (65)
D4	100.00 (85)	100.00 (117)	99.15 (117)	100.00 (52)
D5	100.00 (38)	100.00 (54)	98.15 (54)	100.00 (13)
D6	72.09 (43)	93.18 (44)	65.12 (43)	100.00 (14)
D7	100.00 (46)	95.83 (48)	78.72 (47)	100.00 (23)
D8	100.00 (135)	100.00 (144)	84.03 (144)	100.00 (10)
D9	83.61 (61)	97.14 (70)	90.62 (64)	100.00 (21)
D10	100.00 (31)	100.00 (40)	92.50 (40)	100.00 (12)

of samples classified. The standards proposed by Joo et al. (2000) and Faucitano et al. (2010) predicted 7 datasets with 100% of accuracies and the lowest performance were 93.18% and 72.09%, respectively. The worst prediction was obtained by Kauffman et al. (1993) with a maximum accuracy of 99.15% and minimum of 65.12%.

It is observed that the top-down modeling overcomes the classical logic for all standards and datasets (Fig. 3). We did not represent graphically the Joo’s standard, once both approaches obtained a complete sample classification.

Even with an important improvement by the use of fuzzy logic, there are still infeasible samples. These samples could indicate the occurrence of extrinsic factors from samples, like measurement errors, problems in acquisition technique or device calibration.

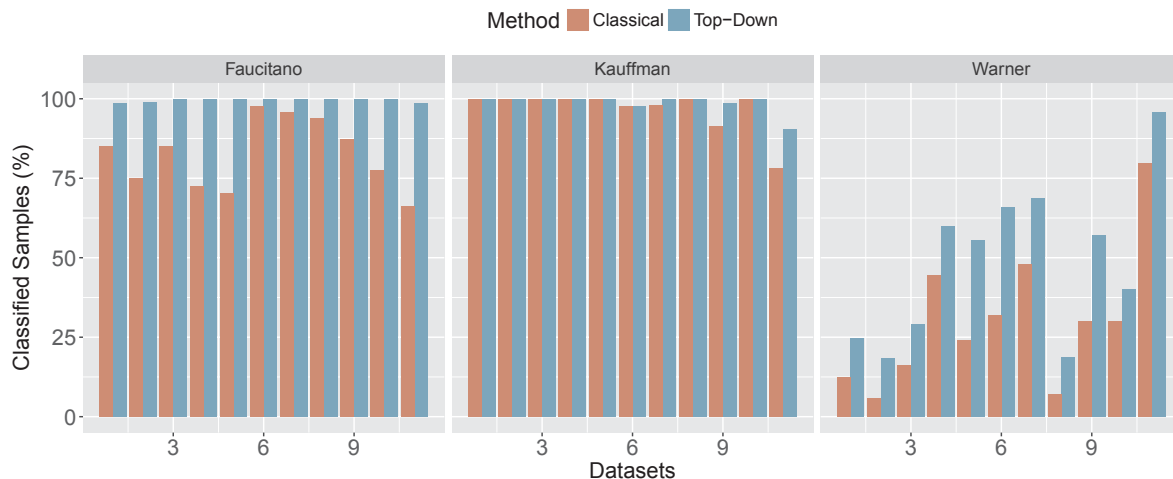


Fig. 3. Classified samples by the classical and the top-down approaches using the grading standards proposed by Faucitano, Kauffman and Warner over the 10 real-life datasets (D1–D10).

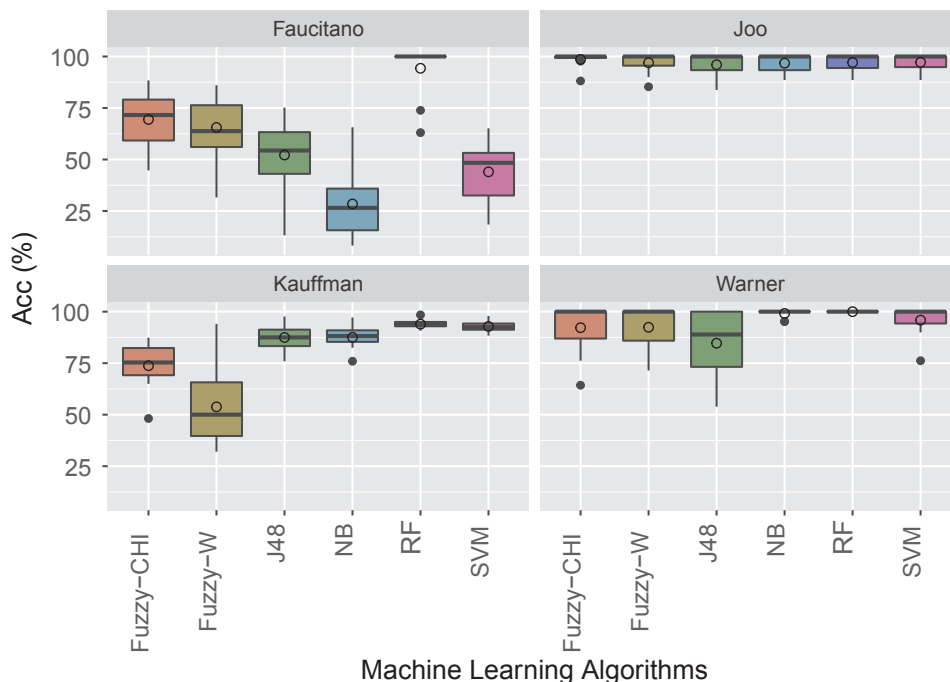


Fig. 4. Accuracies for the bottom-up approach using the machine learning algorithms (*Fuzzy-CHI*, *Fuzzy-W*, *J48*, *NB*, *RF* and *SVM*) for each grading standard.

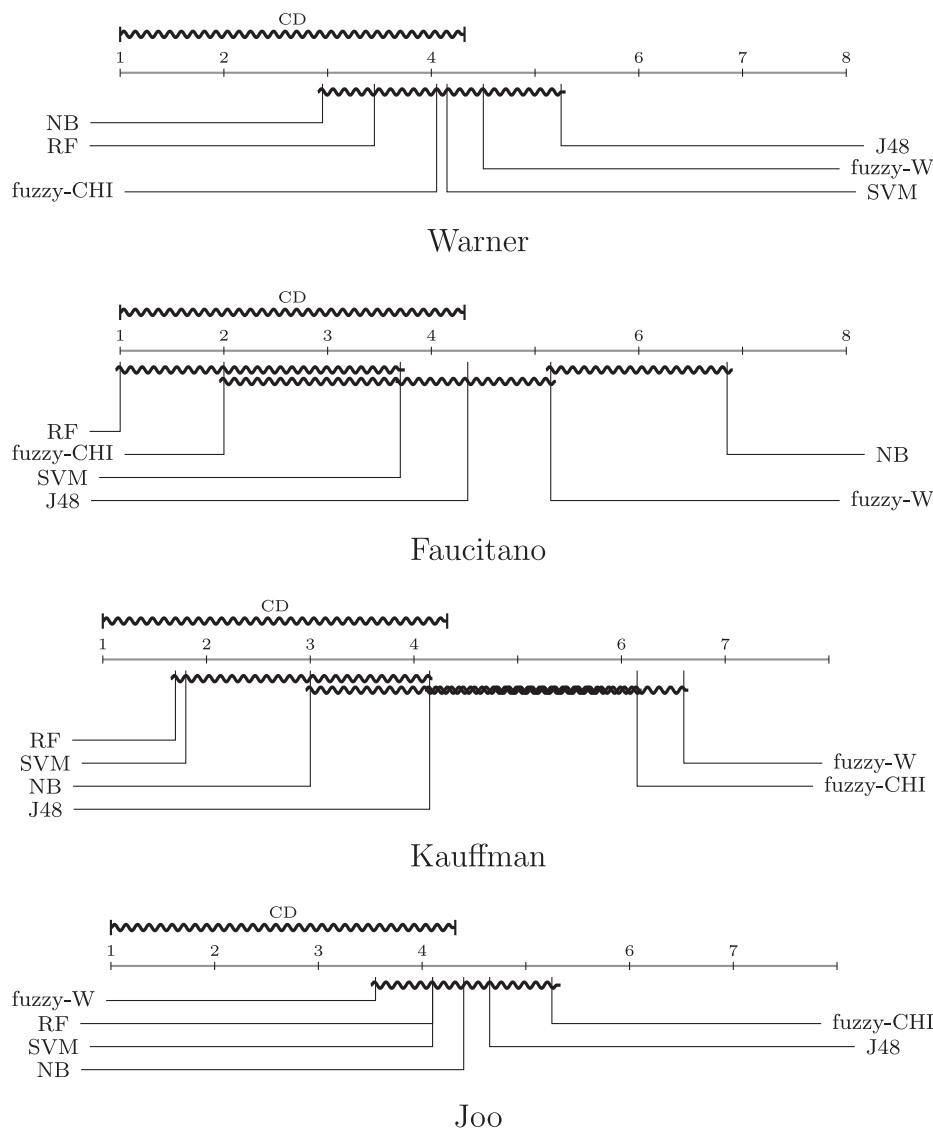


Fig. 5. Comparison of the average accuracy per dataset values using the machine learning algorithms (Fuzzy-CHI, Fuzzy-W, J48, NB, RF and SVM) according to the Nemenyi test. Algorithms that are not significantly different ($\alpha = 0.05$) are connected.

3.3. Experiment 3: Bottom-up

In Experiment 3, we apply some traditional ML algorithms in comparison to fuzzy bottom-up approaches. It was calculated their classification performance from the labeling obtained in Experiment 1 (by the classical logic approach). Before that, we considered a synthetic dataset capable to deal with supervised ML algorithms, as described in Section 2.2.3. In order to analyze the accuracies, Fig. 4 shows the boxplots using the ML algorithms (Fuzzy-CHI, Fuzzy-W, J48, NB, RF and SVM) for each grading standard. As we can see, there is no ML algorithm that outperforms the other ones. Each algorithm can provide significant performance for a specific grading standard. Although the RF algorithm appeared to obtain a superior accuracy, this fact was not corroborated by the statistical analysis.

The accuracy allows us to compare the algorithms by applying the Friedman’s statistical test with significance level at $\alpha = 0.05$. The null hypothesis here states that the performances of the classification model are equivalent regarding the accuracy per algorithm. Any time the null hypothesis is rejected, the Nemenyi posthoc test is applied, stating the performance of two different models are significantly different whether the corresponding average ranks differ by at least a Critical Difference (CD) value, as previously proposed in Demšar (2006).

Different algorithms are connected when significance difference is not observed between them ($\alpha = 0.05$ and $CD = 4.31$) (Fig. 5). Lower rank values indicate the best performance, while higher values indicate the opposite.

Thus, according to the results, no significant differences were observed when comparing J48, NB, RF, SVM and fuzzy approaches. This suggests there is no best algorithm to induce a predictor in our scenario when considering accuracy. In this case, we could employ any algorithm or consider alternatives to select an option based on ML.

It was possible to observe the improvement of the classification task by the use of the fuzzy top-down (Experiment 2) and bottom-up (Experiment 3) approaches. Both techniques tackle the infeasibility issue successfully, but some features need to be considered when select top-down or bottom-up approaches.

Top-down approach requires a specialist and spend more time on creation, considering that it is a manual design of ML and rules. On the other hand, this approach demands only the parameters, intervals and related classes of a standard.

Bottom-up approaches, based on modeling a dataset by the ML algorithms, require few seconds to go through the design without a fuzzy specialist (or other algorithms). However, it is based on a labeled dataset composed of all classes. This fact demands a high-quality




Fig. 6. Membership function degree for infeasible samples.

Table 9
Faucitano’s fuzzy top-down unlabeled samples attributes and their membership degree values.

pH	WHC	L*	pH.low	pH.high	WHC.low	WHC.medium	WHC.high	L*.low	L*.medium	L*.high
6.03	3.50	41.79	0.48	0.52	0	1.00	0	1	0	0
6.24	3.68	41.10	0.38	0.62	0	1.00	0	1	0	0
5.71	4.76	41.68	0.64	0.36	0	0.50	0.50	1	0	0
6.04	5.72	41.39	0.48	0.52	0	0.02	0.98	1	0	0
6.00	4.76	41.42	0.50	0.50	0	0.50	0.50	1	0	0
5.96	3.50	41.79	0.52	0.48	0	1.00	0	1	0	0
6.29	3.56	40.01	0.36	0.64	0	1.00	0	1	0	0

dataset already classified (tagged) to cope with the supervised requirement of these ML approaches. Beyond that, real-life datasets commonly do not comprehend all classifications established by the standards, failing with this bottom-up requisite.

In this way, we recommend the use of the top-down approach, once its drawbacks could be minimized by the use of frameworks from Matlab,² R and other fuzzy sites. It is possible to download the modeling of the standards proposed by Kauffman et al. (1993), Warner et al. (1997), Joo et al. (2000) and Faucitano et al. (2010) which is implemented in R (as described in Section 2.2.2 and is hosted in our public repository).³

3.4. Faucitano’s standard study case

As described in the Section 1, Faucitano et al. (2010) reports that 14% of the samples were infeasible. In ownership of the original dataset from Faucitano et al. (2010) (Table 2 - D11), we perform the classification task of the 497 samples through the classical logic and fuzzy logic (top-down) approach (Experiments 1 and 2, respectively).

By predicting the samples with fuzzy logic we reached an expressive result, where only 7 samples (1.40%) remained unclassified.

Analyzing the heat map in Fig. 6, it is possible to verify the MF degree of the unclassified samples by classical logic. When drawn by red or white lines it is possible to observe a high confidence, positive or

negative, respectively. Contrarily, the reddish colors represent a low confidence in the parameter for that sample. The pH parameter was the less confident parameter for classification. WHC and L* value parameters were as majority to define the sample class.

Even based on the MF degree of the parameters, it was not possible to classify 7 samples, which are presented in Table 9.

In order to define the meat quality class, we must consider the intrinsic and extrinsic factors to the animals and their influences on the main quality characterization parameters (pH, WHC and L* value). However, in general, when a meat sample presents a high final pH, and therefore is above the isoelectric point of myofibrillar proteins it configures a higher WHC due to the natural spacing of these proteins (Beringues, 1999).

As a consequence of the higher WHC, occurs a large retention of intracellular water. When a beam of light is placed on it, less light reflects and a darker flesh obtains lower (L*). The light scattering from meat surface is probably due to differences in refractive indices of the sarcoplasm and myofibrils (Adzitey and Nurul, 2011). And when the pH of meat approaches the isoelectric point of myofibrillar proteins, the WHC reduces and the L* value increases, leaving the meat with lighter coloration.

By studying the pH, WHC and L* value parameters of each infeasible sample, we recognize abnormal behaviors for muscle biochemistry. The biochemical inconsistencies may be the result of a failure during the extraction of the parameters. In this case, even the fuzzy approach did not cope with the classification of some samples, but this fact is not considered a fail, but rather samples compromised that should be put

² <https://www.mathworks.com/>.

³ <http://www.uel.br/grupo-pesquisa/remid/>.

apart from the experiment.

4. Conclusions

There are many methodologies for assessment of pork quality, all of them using parameters established by rigid thresholds. In this way, when the grading is performed some samples are not classified with the combinations of ranges proposed for each parameter. These samples cannot be classified, and traditionally are discarded.

In order to address these issues, we proposed the use of fuzzy logic due to the capability to deal with uncertainty and ambiguity degree like human reasoning. We perform two kinds of modeling: top-down (by human design) and bottom-up (built by ML).

Considering the grading infeasibility, even though it was recommended the top-down approach, the question: “Hence, which class could we assume?” could be answered by both approaches. In practice, the fuzzy model provides better conditions for the industry, addressing the pork for fresh consumption (different niche markets) or elaboration of products (dried, fresh, cured, fermented, cooked and emulsified) by improving the classification of the samples. Codes are available for download from the research group webpage.⁴

For future works, it is expected to merge several grading standards in a “fuzzy machine” to enhance the advantages of each method. Our hypothesis is based on the confidence of each parameter, adjusting the membership function (boundaries and format) from the lesser reliable by data fusion using different standards.

Acknowledgments

The authors would like to thank CAPES (National Council for the Improvement of Higher Education), FAPESP (Sao Paulo Research Foundation) process 2015/24351-2 and CNPq (National Council for the Scientific and Technological Development) (Brazilian Agencies) for their financial support and the researcher Luigi Fauticano, who kindly made available the original database of the publication Fauticano (2000), allowing to finalize the case study of this paper.

Appendix A. Supplementary material

Supplementary data associated with this article can be found, in the online version, at <http://dx.doi.org/10.1016/j.compag.2018.05.009>.

References

- Adorni, G., Bianchi, D., Cagnoni, S., 2001. Learning fuzzy decision trees for ham quality control. *Trans. QCAV2001* 259–264.
- Adzitey, F., Nurul, H., 2011. Pale soft exudative (pse) and dark firm dry (dfd) meats: causes and measures to reduce these incidences—a mini review. *Int. Food Res. J.* 18 (1), 11–20.
- Barbin, D., Elmasry, G., Sun, D.-W., Allen, P., 2012. Near-infrared hyperspectral imaging for grading and classification of pork. *Meat Sci.* 90 (1), 259–268.
- Barbon, A.P.A., Jr., S.B., Mantovani, R.G., Fuzyi, E.M., Peres, L.M., Bridi, A.M., 2016. Storage time prediction of pork by computational intelligence. *Comp. Electron. Agricult.* 127, 368–375.
- Bauer, A., Petzet, A., Schwagele, F., Scheier, R., Schmidt, H., August 2013. Towards an online assessment of meat quality in pork. In: 59th International Congress of Meat Science and Technology.
- Beringues, J.C., 1999. Sorption Isotherms and Water Diffusivity in Muscles of Pork Ham at Different NaCl Contents. *Universitat Politècnica de Catalunya*.
- Bezděk, V., 2014. Using fuzzy logic in business. *Proc. - Soc. Behav. Sci.* 124, 371–380 (Challenges and Innovations in Management and Leadership 12th International Symposium in Management).
- Billmeyer, F.W., Hammond, H.K., 1990. Astm standards on color-difference measurements. *Color Res. Appl.* 15 (4), 206–209.
- Breiman, L., 2001. Random forests. *Mach. Learn.* 45 (1), 5–32.
- Campos, P.F., Gomide, A.P.C., Bruno Andreatta Scottá, C.C.B., Soares, M.H., 2014. Impactos da seleção genética na qualidade da carne suína. *PUBVET* 8 (2).
- Chen, J.C., Li, C.P., 2010. Tone reservation using near-optimal peak reduction tone set selection algorithm for paper reduction in of dm systems. *IEEE Sig. Process. Lett.* 17 (11), 933–936.
- CIE, 1978. Recommendations on Uniform Color Spaces, Color Difference Equations, and Psychometric Terms. Bureau Central de la CIE (Supplement No. 2 to CIE publication No. 15).
- Coutinho, K.M.V., Rizol, P.M.S.R., Nascimento, L.F.C., Medeiros, A.P.P. d., 2015. Fuzzy model approach for estimating time of hospitalization due to cardiovascular diseases. *Ciência & saúde coletiva* 20 (8), 2585–2590.
- da Silva, M.A., 2008. Aplicação de lógica nebulosa para previsões do risco de escorregamentos de taludes em solo residual.
- Demšar, J., 2006. Statistical comparisons of classifiers over multiple data sets. *J. Mach. Learn. Res.* 7, 1–30.
- Dutton, T., 1983. The measurement of pH in muscle and its importance to meat quality. In: *Proceedings Annual Reciprocal Meat Conference*.
- Fauticano, L., 2000. Efeitos do manuseio pré-abate sobre o bem-estar e sua influência sobre a qualidade de carne. In: *i conferência virtual internacional sobre qualidade de carne suína*, vol. 16.
- Fauticano, L., Ielo, M., Ster, C., Fiego, D.L., Methot, S., Saucier, L., 2010. Shelf life of pork from five different quality classes. *Meat Sci.* 84 (3), 466–469.
- Fletcher, D.L., 1999. Broiler breast meat color variation, pH and texture. *Reason. Nam. Syst.* 78, 1323–1327.
- Goldschmidt, R.R., 2010. Uma introdução à inteligência computacional: fundamentos, ferramentas e aplicações. IST-Rio, Rio de Janeiro Brasil.
- Hamm, R., 1960. Biochemistry of meat hydration. *Adv. Food Res.* 10, 355–463.
- He, H., Garcia, E.A., 2009. Learning from imbalanced data. *IEEE Trans. Knowl. Data Eng.* 21 (9), 1263–1284.
- Hüllermeier, E., 2015. Does machine learning need fuzzy logic? *Fuzzy Sets Syst.* 281, 292–299 (special Issue Celebrating the 50th Anniversary of Fuzzy Sets).
- Huff-Lonerger, E., Lonergan, S.M., 2005. Mechanisms of water-holding capacity of meat: the role of postmortem biochemical and structural changes. *Meat Sci.* 71 (1), 194–204 (51st International Congress of Meat Science and Technology ICoMST).
- Jensen, R., Shen, Q., 2008. Computational Intelligence and Feature Selection: Rough and Fuzzy Approaches, vol. 8 John Wiley & Sons.
- Joo, S., Kauffman, R., Warner, R., Borggaard, C., Stevenson-Barry, J., Rhee, M.-S., Park, G., Kim, B.-C., 2000. Objectively predicting ultimate quality of post-rigor pork musculature. *Asian-Austral. J. Anim. Sci.* 13 (1), 77–85.
- Kauffman, R., Sybesma, W., Smulders, F., Eikelenboom, G., Engel, B., Van Laack, R., Hoving-Bolink, A., Sterrenburg, P., Nordheim, E., Walstra, P., et al., 1993. The effectiveness of examining early post-mortem musculature to predict ultimate pork quality. *Meat Sci.* 34 (3), 283–300.
- Kavzoglu, T., Colkesen, I., 2009. A kernel functions analysis for support vector machines for land cover classification. *Int. J. Appl. Earth Observ. Geoinf.* 11 (5), 352–359.
- Lodwick, W.A., 2002. Reliable computing: special issue on the linkages between interval mathematics and fuzzy set theory. *Reliab. Comput.* 8 (1), 93–95.
- Ma, Y., Liang, S., Chen, X., Jia, C., 2016. The approach to detect abnormal access behavior based on naive bayes algorithm. In: *10th International Conference on Innovative Mobile and Internet Services in Ubiquitous Computing (IMIS)*, 2016. IEEE, pp. 313–315.
- Manikandan, P., Ramyachitra, D., 2014. Naive bayes classification technique for analysis of ecoli imbalance dataset. *Int. J. Comput. Intell. Inform.*, July & August 4.
- Medeiros, A.R.C., Araújo, Y.B. d., Vianna, R.P. d. T., Moraes, R.M. d., 2014. Modelo de suporte à decisão aplicado à identificação de indivíduos não aderentes ao tratamento anti-hipertensivo. *Saúde debate* 38 (100), 104–118.
- Moore, R., Lodwick, W., 2003. Interfaces between fuzzy set theory and interval analysis and fuzzy set theory. *Fuzzy Sets Syst.* 135 (1), 5–9.
- Müller, V., 2015. *Computing and Philosophy: Selected Papers from Synthese Library*. Springer International Publishing.
- Peres, L.M., de Oliveira, E.R., de Lucio, et al, C.L., 2011. Análise comparativa de metodologias de determinação da capacidade de retenção de água. In: *XXI Congresso Brasileiro de Zootecnia*.
- Riza, L.S., Bergmeir, C.N., Herrera, F., Benítez Sánchez, J.M., 2015. frbs: Fuzzy rule-based systems for classification and regression in R. *American Statistical Association*.
- Sabow, A.B., Sazili, A.Q., Zulkifli, I., Goh, Y.M., Kadir, M.Z.A.A., Adeyemi, K.D., 2015. Physico-chemical characteristics of longissimus lumborum muscle in goats subjected to halal slaughter and anesthesia (halothane) pre-slaughter. *Anim. Sci. J.* 86 (12), 981–991. <http://dx.doi.org/10.1111/asj.12385>.
- Scornet, E., Biau, G., Vert, J.-P., et al., 2015. Consistency of random forests. *Ann. Statist.* 43 (4), 1716–1741.
- Sharma, T.C., Jain, M., 2013. Weka approach for comparative study of classification algorithm. *Int. J. Adv. Res. Comp. Commun. Eng.* 2 (4), 1925–1931.
- Shaw, I.S., 2013. *Fuzzy Control of Industrial Systems: Theory and Applications*, vol. 457 Springer.
- Silva Sobrinho, A.G.d., Purchas, R.W., Kadim, I.T., Yamamoto, S.M., 2005. Meat quality in lambs of different genotypes and ages at slaughter. *Revista Brasileira de Zootecnia* 34 (3), 1070–1078.
- Sunita, Deo, A., 2012. Fuzzy logic systems design for engineering and applications. In: *First International Conference On Advances In Computer, Electronics And Electrical Engineering - CEEE*, pp. 34–40.
- Tomovic, V.M., Zlender, B.A., Jokanović, M.R., Tomovic, M.S., Sojic, B.V., Skaljic, S.B., Tasic, T.A., Ikoncic, P.M., Soso, M.M., Hromis, N.M., 2014. Technological quality and composition of the m. semimembranosus and m. longissimus dorsi from large white and landrace pigs. *Agricult. Food Sci.* 23 (1), 9–18.
- USA, P., 2003. *Meat Quality: Understanding Industry Measurements and Guidelines* < <http://kaslobay.ca/downloads/techupdate/meatquality.pdf> > (accessed: 2015-12-26).
- Van Laack, R.L.J., Kauffman, R.G., Sybesma, W., Smulders, F.J.M., Eikelenboom, G., Pinheiro, J.C., 1994. Is colour brightness (L-value) a reliable indicator of water-

⁴ <http://www.uel.br/grupo-pesquisa/remid>.

- holding capacity in porcine muscle? *Meat Sci.* 38, 193–201.
- Vásquez-Villalobos, V., Vásquez Angulo, J., Méndez Reyna, E., 2015. Nuevo método para determinar vida útil sensorial utilizando lógica difusa: caso corazones de alcachofa (*cynara scolymus* L.) marinadas en conserva. *Sci. Agropec.* 6 (2), 99–109.
- Wang, L., 2005. *Support Vector Machines: Theory and Applications*, vol. 177 Springer Science & Business Media.
- Warner, R.D., Kauffman, R.G., Greaser, M.L., 1997. Muscle protein changes post mortem in relation to pork quality traits. *Meat Sci.* 45 (3), 339–352.
- Warriss, P.D., Brown, S.N., 1987. The relationship between initial pH, reflectance and exudation in pig muscle. *Meat Sci.* 20, 65–74.
- We,glarz, A., 2010. Meat quality defined based on pH and colour depending on cattle category and slaughter season. *Czech J. Anim. Sci.* 55 (12), 548–556.
- Wilhelm, A.E., Magalhães, M.B., Hernández-Blázquez, F.J., Ida, E.I., Shimokomaki, M., 2010. Protease activity and the ultrastructure of broiler chicken PSE (pale, soft, exudative) meat. *Food Chem.* 119 (3), 1201–1204.

7 CONCLUSÃO GERAL

Ao finalizar esta tese, podemos visualizá-la como uma ferramenta de apoio ao monitoramento e desenvolvimento da qualidade da carne suína, em função da meta-recomendação do padrão de classificação de carne suína mais adequado e redução na quantidade de carnes *infeasible*.

Os resultados oferecidos por estas ferramentas (meta-recomendação e lógica *fuzzy*) permitem informar com precisão os índices de qualidade para os interessados (órgãos de pesquisa, propriedades, frigoríficos e centros de distribuição), possibilitando rastrear onde estão as falhas no sistema e assim viabiliza a busca por soluções eficientes para garantir a qualidade da carne suína do começo ao final da cadeia produtiva.