

Previsão da Tenrura da Carne de Cordeiro via Redes Neurais Artificiais e Análise de Sensibilidade

Manuel Portelinha

Escola Superior Agrária, Instituto Politécnico de Bragança, Bragança, Portugal
mportelinha@ipb.pt

Paulo Cortez

Departamento de Sistemas de Informação, Universidade do Minho, Guimarães, Portugal
pcortez@dsi.uminho.pt

Sandra Rodrigues, Vasco Cadavez e Alfredo Teixeira

Escola Superior Agrária, Instituto Politécnico de Bragança, Bragança, Portugal
{srodrigues, vcadavez, Teixeira}@ipb.pt

Resumo

A avaliação da qualidade é um factor chave para a indústria da carne, onde o objectivo primordial reside na satisfação das necessidades dos consumidores. Em particular, a tenrura é considerada a mais importante característica que afecta o paladar da carne. Neste trabalho, é proposto um *Conjunto de Redes Neurais*¹, baseado na selecção de atributos via um procedimento de *Análise de Sensibilidade*, para a predição da tenrura da carne de cordeiros. Este problema foi modelado através de duas tarefas diferentes de regressão, usando medições instrumentais e um painel sensorial. Em ambos os casos, as soluções propostas apresentaram melhores resultados do que o método tradicional da *Regressão Múltipla*.

Palavras chave: Descoberta de Conhecimento; *Data Mining*; Qualidade da Carne; Redes Neurais; Regressão

1. Introdução

Um factor prioritário no sucesso da indústria da carne assenta na capacidade de fornecer especialidades que satisfaçam os gostos dos consumidores. Em particular, avaliar a qualidade é importante para as explorações de carne de cordeiro, especialmente se o objectivo for centrar-se em determinados nichos de mercado para diferenciação dos seus produtos. Assim, tem sido dedicado um elevado esforço na procura de estimadores fiáveis da qualidade.

Existem vários factores que influenciam a qualidade da carne, tal como a *suculência*, a *aparência* ou o *aroma*. De entre estas, a *tenrura* é considerado o atributo mais importante na influência da percepção alimentar e os consumidores estão mesmo dispostos a pagar preços de topo por carne tenra [Huffman *et al.* 1997]. Por outro lado, o método ideal para medir a tenrura deve ser preciso, rápido, automático e não invasivo. No passado, foram propostas duas grandes abordagens [Arvanitoyannis e Houwelingen-Koukaliaroglou 2003]: análises instrumentais e sensoriais. As primeiras são baseadas em testes objectivos, sendo o *Instron*, equipado com uma célula *Warner-Bratzler (WBS)*², o instrumento mais comumente usado. Por sua vez, os métodos sensoriais são baseados em informação subjectiva, usualmente dados por um painel de

¹ Tradução adoptada para o termo *Neural Network Ensemble*.

² Máquina ou célula de corte com características específicas, para avaliar a tenrura da carne. Mede a força necessária para cortar e esmagar uma amostra de carne com 1cm de espessura.

provedores. Ambas estas soluções requerem trabalho de laboratório, sendo caras, exigentes em termos do tempo e invasivas.

Uma alternativa passa pelo uso de medidas de análise da carcaça, que são baratas e não invasivas, podendo ser obtidas nas primeiras 24 horas após o abate, tal como leituras do pH e da cor. A aproximação clássica da ciência animal é baseada no uso de modelos de *Regressão Múltipla (RM)* [Arvanitoyannis e Houwelingen-Koukaliaroglou 2003], usando as características da carne como variáveis independentes (entradas) e a *WBS* ou a medida *sensorial* como variáveis dependentes (saída). Contudo, estes modelos lineares falham claramente quando estão presentes nos dados fortes relações não lineares. Nestes casos, uma melhor opção poderá passar pelo uso de *Redes Neurais Artificiais*³, que apresentam vantagens tais como uma aprendizagem não linear e tolerância ao ruído.

No processo de *Descoberta de Conhecimento em Base de Dados (DCBD)*⁴, estão envolvidas várias etapas que vão desde a selecção das bases de dados sobre as quais será realizado o processamento, até à disponibilização do conhecimento descoberto [Fayyad *et al.* 1996]. A Figura 1 mostra a sequência de etapas de um ciclo de processo de *DCBD*:

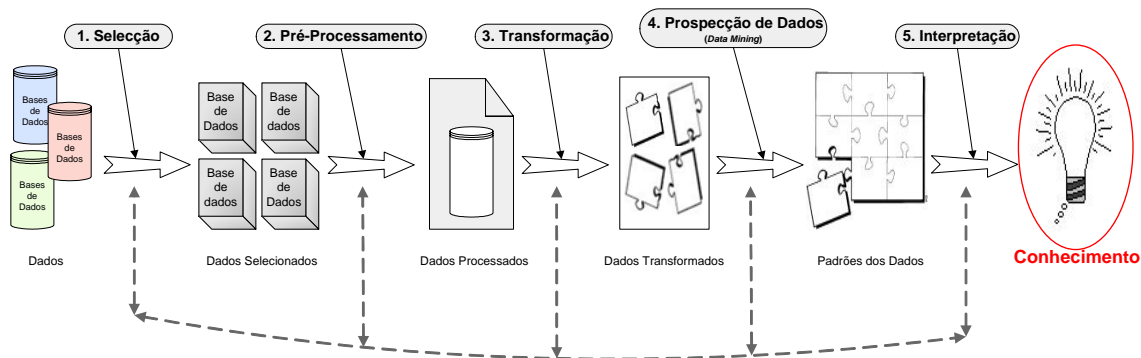


Figura 1 – Etapas do processo de *DCBD* (Adaptado de: [Fayyad *et al.* 1996])

Dentro deste enquadramento, as *Redes Neurais* estão a ganhar atenção crescente, em especial nas áreas do *Data Mining* e da *Aprendizagem Automática*⁵, devido ao seu desempenho potencial em termos de conhecimento preditivo [Mitra *et al.* 2002]. Outro tópico de investigação, que se tem revelado promissor nestas áreas, é baseado no uso de *Conjunto de Modelos*⁶, onde vários modelos são combinados de alguma maneira de modo a produzir uma única resposta [Dietterich 2001]. Este interesse surgiu devido à descoberta de que os *Conjuntos de Modelos* são em geral mais precisos do que modelos simples.

Por outro lado, em aplicações de *Data Mining*, para além de se obter uma elevada performance predictiva, é usualmente útil fornecer um conhecimento explicativo acerca do que o modelo aprendeu. Em particular, a importância de uma dada entrada é relevante no domínio da tenrura da carne. Uma vez que as medidas da carcaça são geralmente correlacionadas, no passado foi proposto o uso da *Análise de Componentes Principais* para reduzir a dimensão da entrada [Park *et al.* 2002; Arvanitoyannis e Houwelingen-Koukaliaroglou 2003]. Contudo, os componentes principais são variáveis comprimidas e não representam um significado directo para o utilizador da carne. Por conseguinte, uma alternativa reside na adopção da *Análise de Sensibilidade*

³ Doravante, designadas somente por *Redes Neurais*.

⁴ Tradução adoptada para o termo *Knowledge Discovery from Databases (KDD)*.

⁵ Do inglês *Machine Learning*.

⁶ Ou *Ensembles*.

[Kewley *et al.* 2000], que obteve melhores resultados do que outros métodos, tais como o *forward selection* ou algoritmos genéticos.

No passado, vários estudos abordaram *Redes Neurais* para avaliar a qualidade da carne (e.g. bovinos, suínos, aves ou salsichas) [Arvanitoyannis e Houwelingen-Koukaliaroglou 2003]. Contudo, no que respeita à previsão da tenrura, a literatura parece escassa, sendo principalmente orientada para a carne bovina. Em [Li *et al.* 1999], foram utilizadas redes do tipo *Perceptrão Multicamada (PMC)*⁷ para mapear imagens da textura com valores de tenrura sensorial. Em outro estudo, Hill *et al.* [2000] utilizaram redes *PMC* para a predição da força *WBS* em seis bases de dados diferentes, obtendo melhores resultados que a *Regressão Multipla*.

Neste trabalho, é proposto um *Conjunto de Redes Neurais*, em conjugação com um procedimento de selecção de atributos baseado numa *Análise de Sensibilidade*, para prever a tenrura da carne de cordeiro baseada em medidas instrumentais e sensoriais. Esta estratégia será testada em dados animais, colectados na região de *Trás-os-Montes*, no nordeste de Portugal, sendo comparado não só com a *Regressão Multipla*, mas também com outras abordagens de *Redes Neurais*.

O artigo está organizado da seguinte forma. Primeiro, é dada uma breve descrição sobre as bases de dados usadas (Secção 2). Em seguida, são introduzidos os modelos de aprendizagem: a regressão múltipla e os modelos neuronais (Secção 3). Na Secção 4 são descritas as experiências realizadas. Finalmente, são apresentadas as conclusões finais (Secção 5).

2. Dados da Carne de Cordeiro

Este estudo considerará cordeiros com certificado de *Denominação de Origem Protegida (DOP)*, da região nordeste de Portugal, conhecida como Nordeste Transmontano. Os dados foram recolhidos durante o período de um ano, compreendido entre Novembro/2002 e Novembro /2003. Cada registo ou instância da base de dados contem as leituras obtidas por cada animal abatido. A base de dados é de dimensão reduzida, contendo um total de 81 exemplos. Isto deve-se ao facto de que cada animal representa custos elevados, cerca de 6€/kg por carcaça no produtor, mais custos de laboratório.

<i>Atributo</i>	<i>Descrição</i>	<i>Domínio</i>
Raça	Raça do animal	{1, 2} ^a
Sexo	Sexo do animal	{1, 2} ^b
PCQ	Peso da carcaça Quente (kg)	[4.1, 14.8]
EGE2	Espessura da Gordura Esternal ao nível da 2ª esternebra (mm)	[6.0, 27.8]
C	Espessura da gordura subcutânea acima do músculo longissimus (mm)	[0.3, 5.1]
pH1	pH medido 1 hora após abate	[5.5, 6.8]
pH24	pH medido 24 horas após abate	[5.5, 5.9]
a*	Índice de vermelho	[11.5, 22.2]
b*	Índice de amarelo	[6.5, 12.5]
dE	Diferença de cor total (engloba L, a* e b*)	[46.5, 60.9]
dL	Diferencial de luminosidade quando comparado com um padrão	[-56.1, -39.1]
db*	Diferencial do índice de amarelo	[15.3, 22.5]
WBS	<i>Warner-Bratzler Shear force</i> (kg/cm ²) – Força de corte	[9.5, 57.0]
PAS	Painel de Análise Sensorial	[0.7, . . . , 7.1]

^a 1 - Churra Galega Bragançana, 2 - Churra Galega Mirandesa; ^b 1 - Macho, 2 - Fêmea

Tabela 1 – Atributos dos dados da carne de cordeiro

⁷ Na terminologia anglo-saxónica é utilizado o termo *Multilayer Perceptron (MLP)*.

A Tabela 1 apresenta a descrição dos atributos considerados. O **PCQ** é obtido uma hora após o abate, exfoliação e evisceração. Os primeiros dois atributos (**Raça** e **Sexo**) são também registados no matadouro, sendo os restantes medidos em laboratório. Devido à sua natureza visual, os atributos da cor (**a***, **b***, **dE**, **dL** e **db***) têm um elevado impacto no consumidor. Na maioria das situações, estes são os únicos atributos que o consumidor comum pode julgar.

No que diz respeito às variáveis de saída, a força de corte **WBS** é o índice de maior objectividade para medir a tenrura da carne. Apenas pode ser obtida em laboratório, usualmente em carne cozinhada, não antes de 72 horas após o abate e requer o uso de um aparelho especial, chamado *Instron*, sendo um método invasivo. A força de corte **WBS** regista a força (em kg) requerida para cortar uma amostra de carne com 1cm de espessura. Os valores mais baixos sugerem carne tenra enquanto leituras elevadas sugerem dureza.

Por outro lado, foi idealizado um esquema mais elaborado para obter os valores sensoriais (**PAS**). No início, foi seleccionado um painel de 12 indivíduos treinados, do *Instituto Politécnico de Bragança*. Depois, foram colhidas e descongeladas, a 4º Celsius numa estufa refrigeradora, amostras de carne do músculo *longissimus thoracis*. De seguida, as amostras foram codificadas aleatoriamente com números de 3 dígitos, sendo envolvidas em papel de alumínio e colocadas num forno até atingirem a temperatura de 100°C. Depois, cada membro do painel foi localizado num compartimento individual, sob condições similares, realizando uma prova “cega” das amostras seleccionadas aleatoriamente. Entre cada prova, as bocas foram limpas, utilizando-se neste processo água mineral e comendo pequenos pedaços de maçã do tipo *golden*. Cada amostra foi então avaliada numa escala de 0 (a mais tenra) a 10 (a mais dura). Finalmente, o atributo **PAS** foi medido como a média dos valores do painel.

Convém referir que a base de dados original continha 2 valores em falta na variável **WBS** e 10 valores na variável **PAS**. Assim, foram criadas duas novas bases de dados, retirando os registos com valores desconhecidos. A primeira contém 79 linhas e será usada para prever os valores de **WBS**, enquanto a segunda tem 71 exemplos, sendo usada para a previsão sensorial (**PAS**).

3. Modelos de Aprendizagem

Seja D uma base de dados de regressão com $k \in \{1, \dots, N\}$ exemplos, cada um correspondendo um vector de entrada (x_1^k, \dots, x_l^k) com um dado objectivo y_k . O erro, para um determinado k , é então dado por: $e_k = y_k - \hat{y}_k$, onde \hat{y}_k , representa o valor previsto para o padrão de entrada k . O desempenho de uma regressão é calculado por métrica global, nomeadamente: *Erro Absoluto Médio (EAM)*, *Erro Absoluto Médio Relativo (EAMR)*, *Raiz da Média do Quadrado dos Erros (RMQE)* ou *RMQE Relativo (RMQER)*. Estes podem ser calculados de acordo com as equações:

$$\begin{aligned}
 EAM &= 1/N \times \sum_{i=1}^N |y_i - \hat{y}_i| \\
 EAMR &= 1/N \times EAM / \sum_{i=1}^N |y_i - \bar{y}_i| \times 100(\%) \\
 RMQE &= \sqrt{\sum_{i=1}^N (y_i - \hat{y}_i)^2 / N} \\
 RMQER &= RMQE / \sqrt{\sum_{i=1}^N (y_i - \bar{y}_i)^2 / N} \times 100(\%)
 \end{aligned}
 \tag{1}$$

Em todos estes erros, valores mais baixos correspondem a melhores modelos preditivos. As medidas *EAMR* e *RMQER* têm a vantagem de serem independentes da escala, onde 100% significa que o método de regressão tem desempenho similar a uma previsão simples via a média dos valores.

Um modelo de *Regressão Múltipla* é definido pela equação [Hastie *et al.* 2001]:

$$\hat{y} = \beta_0 + \sum_{i=1}^I \beta_i x_i \quad (2)$$

onde $\{x_1, \dots, x_I\}$ denota o conjunto das variáveis de entrada (quando $I = 1$ é conhecida como *Regressão Linear*) e $\{\beta_0, \dots, \beta_1\}$ o conjunto de parâmetros a ser ajustado, usualmente aplicando o algoritmo dos mínimos quadrados. Devido à sua natureza aditiva, este modelo é fácil de interpretar e tem sido largamente utilizado em aplicações de regressão.

Por outro lado, as *Redes Neurais* denotam um conjunto de modelos conexionistas inspirados no comportamento do sistema nervoso central dos seres vivos. Em particular, o *Perceptron Multi-camada* é a arquitetura mais popular, onde os neurónios são agrupados em camadas e apenas existem conexões unidireccionais [Haykin 1999]. Neste estudo, serão utilizadas redes deste tipo com conexões de *bias*, uma camada intermédia com H unidades de processamento (ou neurónios) e funções de activação logísticas. Para o único neurónio de saída foi adoptada a função de activação linear, uma solução que é comum em tarefas de regressão, uma vez que a variável de saída pode ter valores fora do contradomínio da função logística ($[0, 1]$) [Hastie *et al.* 2001]. Assim, cada tarefa de regressão (**WBS** e **PAS**) será modelada por uma rede diferente, sendo o modelo geral dado pela equação:

$$\hat{y} = w_{o,0} + \sum_{j=1}^{o-1} f\left(\sum_{i=1}^I x_i w_{j,i} + w_{j,0}\right) w_{o,i} \quad (3)$$

onde $w_{i,j}$ denota o peso da conexão desde o neurónio j até à unidade i (se $j=0$ então é uma conexão *bias*), o corresponde à unidade de saída, f à função logística $\left(\frac{1}{1 + e^{-x}}\right)$, e I ao número de neurónios de entrada. A Figura 2 descreve a arquitectura neuronal escolhida.

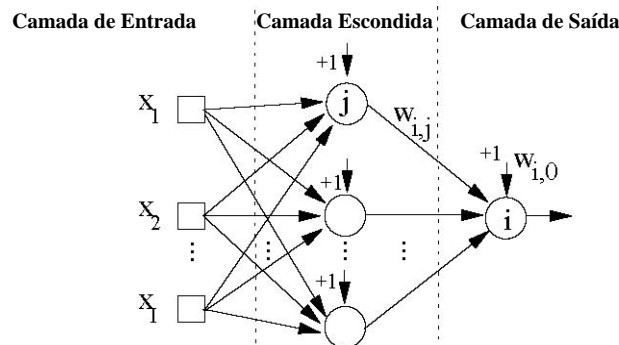


Figura 2 – Um *Perceptron Multi-Camada* genérico com uma camada intermédia

A aprendizagem supervisionada é alcançada por um ajustamento iterativo dos pesos das conexões da rede (o algoritmo de *treino*), de modo a minimizar uma função de erro (tipicamente a soma dos erros quadrados), calculada sobre os *exemplos de treino* (ou *casos*). Antes de alimentar as *Redes Neurais*, os dados necessitam de ser pré-processados. Neste estudo, todos os atributos foram padronizados para uma média “zero” e desvio padrão “um”, aplicando a normalização:

$$z = \frac{x - \bar{x}}{s_x} \quad (4)$$

onde \bar{x} denota a media da variável no conjunto de treino e s_x o desvio padrão correspondente.

A arquitetura neuronal precisa de ser estabelecida *a priori*, antes do treino. Por conseguinte, o desempenho será sensível a esta escolha: uma pequena rede fornecerá capacidades limitadas de aprendizagem, enquanto que uma rede de elevada dimensão grande tenderá a sobre-ajustar⁸ os dados, perdendo capacidade de generalização. Para resolver este obstáculo, é comum usar um elevado número de neurónios intermédios (H), sendo a *Rede Neuronal* treinada com uma *constante de decaimento*⁹ [Hastie *et al.* 2001]. Trata-se de um procedimento de regularização, onde um valor constante (λ) funciona como uma penalização que reduz os valores dos pesos da rede. Em particular, os pesos mais baixos tenderão a aproximar-se do valo nulo. Sob este esquema, o parâmetro crucial é a escolha do valor de λ , que permite controlar a complexidade da rede. Neste trabalho, este hiper-parâmetro será ajustado de modo automático por um procedimento de *procura em grelha*¹⁰.

Para uma determinada rede, os pesos iniciais serão estabelecidos aleatoriamente dentro do intervalo $[-0,7, +0,7]$ [Hastie *et al.* 2001]. A seguir, procede-se ao treino da rede, sendo este parado quando o declive do erro de treino estiver perto de zero ou após um máximo de Max_{it} iterações¹¹. Após o treino, a saída é desnormalizada, aplicando o inverso da Equação 4. Depois, é realizada a *Análise de Sensibilidade*, sendo medida como a variância (V_a) produzida na saída (\hat{y}) quando o atributo de entrada (a) é movido através da sua amplitude total [Kewley *et al.* 2000]:

$$V_a = \sum_{i=1}^L (\hat{y}_i - \bar{\hat{y}}) / (L - 1) \quad (5)$$

$$R_a = V_a / \sum_{j=1}^I V_j \times 100(\%)$$

onde I denota o número de atributos de entrada e R_a a importância relativa do atributo. A saída \hat{y}_i é obtida mantendo todas as variáveis de entrada nos seus valores médios. A exceção é x_a , que varia ao longo da sua escala de valores possíveis, com L níveis. Neste trabalho, L foi estabelecido em 2 para os atributos binários e 7 para as entradas contínuas.

Uma vez que a função de erro da *Rede Neuronal* é não convexa, podem existir diversos mínimos locais, pelo que a qualidade da rede treinada dependerá da escolha dos pesos iniciais. Uma forma de contornar este problema, consiste em aplicar R execuções do algoritmo de treino para cada configuração neuronal, sendo esta inicializada de modo aleatório. No final deste processo, é escolhida a rede com o menor erro penalizado. Esta configuração será designada de *Rede Neuronal Múltipla (RNM)*. Outra opção consiste em usar um *Conjunto de Redes Neuronais (CRN)*, onde R redes também são treinadas a partir de pesos aleatórios iniciais. No entanto, a previsão final passa a ser dada pela média das previsões individuais de cada rede. De realçar que este método de construção de *Conjuntos de Modelos* é conhecido pelo termo *Injecting Randomness* [Dietterich 2000].

4. Resultados

Todas as experiências deste trabalho foram conduzidas usando o ambiente estatístico R [R Development Core Team 2004]. Relativamente à configuração da *Rede Neuronal*, o ambiente R usa o algoritmo de treino *BFGS*, da família do método *quasi-Newton*. Após algumas

⁸ Tradução adoptada para o termo *Overfit*.

⁹ Tradução do inglês *Decay*.

¹⁰ Na terminologia anglo-saxónica *Grid-Search*.

¹¹ Tradução adoptada para o termo *Epoch*.

experiências preliminares, o número máximo de *iterações* de treino foi estabelecido em $Max_{it} = 10$. Valores mais elevados aumentaram o esforço computacional sem aumento no desempenho. Uma vez que o número de neurónios intermédios não é um factor crítico, este foi fixado no valor de $H = 24$ (duas vezes o número de atributos de entrada). Quanto ao número de *Execuções/Conjunto de Modelos*, foi estabelecido o valor de $R = 5$.

O parâmetro mais importante (λ) será ajustado através de uma *procura em grelha* em dois níveis. Embora o λ possa variar teoricamente dentro do intervalo $[0.0, 1.0]$, na prática é usual apresentar valores próximos do zero. Assim, o primeiro nível da rede procura todos os valores discretos dentro da amplitude $\{0.00, 0.01, \dots, 0.20\}$, sendo seleccionada a configuração com o erro de previsão mais baixo (λ_1). Depois, prossegue o segundo nível com uma afinação mais fina, dentro da gama $\lambda_2 \in \{\lambda_1 - 0.005, \dots, \lambda_1 - 0.001, \lambda_1 + 0.001, \dots, \lambda_1 + 0.004\} \wedge \lambda_2 \geq 0$. Assim, o número de procuras é igual a $21 + 9 = 30$ (ou $21 + 5 = 26$ se $\lambda_1 = 0$).

Para estimar a qualidade da previsão da *Rede Neuronal* para a *procura em grelha*, será adoptada uma *validação cruzada com 10-desdobramentos*¹² [Kohavi 1995], onde o conjunto de treino é dividido em 10 subconjuntos de igual tamanho. Sequencialmente, será testado um subconjunto diferente (com 10% dos dados), sendo os restantes dados usados para ajustar os pesos da rede. No final dos 10 treinos, o modelo foi testado em todos os dados de treino, sendo a estimativa dada pelo *RMQE* (Equação 1) médio calculado ao longo dos 10 conjuntos de testes. A Figura 3 esquematiza um exemplo da evolução do erro numa *procura em grelha* de dois níveis, para a tarefa **WBS**. Neste caso, a *constante de decaimento* com melhor qualidade ($RMQE = 6,75$) foi encontrada para $\lambda = 0,097$. Convém referir que após a obtenção da melhor *constante de decaimento*, as *Redes Neurais* são novamente treinadas com todos os dados do conjunto de treino.




Figura 3 – Exemplo de uma *procura em grelha* para a *constante de decaimento* (eixo do x) e do *RMQE* (eixo y), valores para o primeiro nível (esquerda) e segundo nível (direita)

A um nível superior, e para comparar os diferentes modelos de aprendizagem, foram realizadas 5 *execuções* de uma *validação cruzada 10-desdobrável* (calculada sobre todos os dados disponíveis). Isto significa que em cada uma destas 50 experiências, 90% dos dados são usados para aprendizagem e 10% para teste. Os resultados são mostrados na Tabela 2, em termos da média dos erros de teste obtidos sobre as 50 experiências.

Os resultados da *Regressão Múltipla (RM)* são pobres, apresentando valores de *EAMR* e *RMQER* maiores do que 100%, para ambas as tarefas. Assim, a *RM* é pior do que a previsão trivial via a média dos valores. As diferenças entre os métodos da *RM* e das *Redes Neurais* sugerem que ambas as tarefas apresentam uma não linearidade. A abordagem *RNM* funciona

¹² Na terminologia anglo-saxónica *10-fold cross validation*.

melhor do que a *RM*, embora seja pior do que a *CRN*. De facto, existe uma vantagem no uso de *Conjuntos de Modelos*, uma vez que a melhoria apresentada pelo *CRN* é de 3.5% (3.9%) em termos dos valores do *EAMR* (*ERMQR*) para a tarefa **WBS**, e é ainda maior para a tarefa **PAS** (7.5% e 7.4%). Para este último conjunto de dados, o desempenho do método *RNM* é pior, sem melhoria sobre a previsão simples da média de valores. Dado que ambas as estratégias (*RNM* e *CRN*) requerem o mesmo esforço computacional, a última será privilegiada neste estudo.

Tarefa	Modelo	EAM	EAMR	RMQE	RMQER
WBS	RM	9.17	134.7%	11.64	130.4%
	RNM	6.14	90.1%	8.14	91.2%
	CRN	5.89	86.6%	7.79	87.3%
	CRNAS	5.54	81.4%	7.46	83.7%
PAS	RM	1.64	119.3%	2.13	131.7%
	RNM	1.37	99.9%	1.68	104.1%
	CRN	1.27	92.4%	1.56	96.7%
	CRNAS	1.17	84.9%	1.45	89.5%

RM – Regressão Múltipla; RNM – Rede Neuronal Múltipla; CRN – Conjunto de Redes Neuronais;

CRNAS – Conjunto de Redes Neuronais na Análise de Sensibilidade.

Tabela 2 – Os resultados de regressão para a carne de cordeiro

Para a análise das características dos atributos, foi decidido seleccionar os atributos de entrada com uma importância relativa maior ou igual a 3%. A Tabela 3 mostra a importância relativa média (Equação 5) das características das entradas para a abordagem *CRN*. A regra $\geq 3\%$ permite uma redução das entradas para cerca de metade. De facto, 7 atributos contribuem para 93.1% da influência da saída **WBS** e 6 entradas afectam a saída **PAS** com uma importância de 82%. Apesar da diferença dos valores percentuais, as características seleccionadas são bastante similares para ambos os problemas. As excepções são a não inclusão do **pH1** no caso da **WBS** e do **PCQ** e **dL** na tarefa **PAS**. É também interessante notar que o atributo **Sexo** é o factor menos relevante, com influências de 0,08% (**WBS**) e 1,48% (**PAS**). Aparentemente, isto contrasta com o conhecimento de que o sexo afecta a tenrura. Contudo, as fêmeas geralmente apresentam um maior peso e estado de engorda, assim, a informação sobre o sexo pode ser indirectamente representada nas variáveis **PCQ** e **EGE2**.

Tarefa	Modelo	Atributos							
		Raça	PCQ	EGE2	pH1	a*	dE	dL	Db*
WBS	CRN	4.3	5.8	7.6		50.3	11.1	5.5	8.5
	CRNAS	2.8	21.4	7.7		41.7	11.7	6.2	8.5
PAS	CRN	41.0		5.1	6.6	22.6	2.9		3.8
	CRNAS	36.8		20.1	9.3	22.4	9.7		1.7

Tabela 3 – Importância relativa das variáveis de entrada (valores percentuais)

Uma vez que entradas não relevantes podem afectar o desempenho da *RN*, foi criado outro conjunto de dados, considerando apenas as entradas mais importantes da Tabela 3. Esta configuração será designada de *Conjunto de Redes Neuronais baseado na Análise de Sensibilidade* (*CRNAS*). Este novo modelo conseguiu obter melhores resultados (Tabela 2), quando comparado com o modelo *CRN*, especialmente para a tarefa **PAS**. Na Tabela 3, os valores de sensibilidade são também apresentados para este último modelo. Para a previsão do

WBS, o índice de vermelho (**a***) parece ser o atributo mais importante, seguido pelo peso (**PCQ**) e o diferencial da cor total (**dE**). Relativamente ao problema **PAS**, as características mais relevantes são a **Raça**, o índice de vermelho (**a***) e a espessura da gordura esternal (**EGE2**). As diferenças obtidas entre as duas tarefas podem ser explicadas por factores psicológicos. Por exemplo, a importância da **Raça** aumentou de 2,8% (**WBS**) para 36,8% (**PAS**). Após este estudo, foram contactados alguns peritos do painel, tendo-se concluído que os cordeiros *Mirandeses* eram menos fibrosos e tinham odor mais intenso do que os cordeiros *Bragançanos*. Isto pode ser justificado pelo stress dos animais durante o abate, embora seja necessária mais investigação sobre este assunto. Como exemplo da importância e da qualidade da solução obtida, a Figura 4 compara os valores previstos com os valores observados para a tarefa **WBS**. Nos gráficos apresentados, a linha diagonal denota a previsão perfeita. A aproximação *CRNAS* (direita) apresenta claramente mais previsões ao longo da linha do que o método da *Regressão Múltipla* (*RM*) (esquerda).




Figura 4 – Exemplo de gráficos de regressão dos valores previstos (eixo x) e observados (eixo y) para a *RM* (esquerda) e a abordagem proposta (direita)

5. Conclusões

Neste trabalho, é proposto um *Conjunto de Redes Neurais baseado numa Análise de Sensibilidade (CRNAS)*, com o objectivo de prever uma tarefa do mundo real. Foram consideradas duas abordagens para medir a tenrura da carne de cordeiro: uma objectiva, baseada numa máquina de corte *Warner-Bratzler (WBS)*, e outra subjectiva, baseada num *Painel de Análise Sensorial (PAS)*. Para ambas as tarefas de regressão, a estratégia *CRNAS* obteve melhores resultados do que outras *Redes Neurais* e a *Regressão Múltipla*. Além disto, a solução neuronal final é mais simples, requerendo apenas metade do número de entradas (7/6 em vez das 12). Mais ainda, o método proposto é não invasivo, sendo mais barato do que os procedimentos *WBS* ou *PAS*, podendo ser calculado 24 horas após o abate. Por conseguinte, a metodologia proposta reveste-se de um enorme potencial, quando comparada com os métodos clássicos para medir a qualidade da carne, abrindo espaço para o desenvolvimento de ferramentas automáticas para o suporte à decisão.

Uma desvantagem pode ser a precisão obtida, que actualmente é somente 20% melhor quando comparada com a previsão simples da média de valores. Contudo, como referido por Díez e seus colaboradores [Díez *et al.* 2004], a modelação de preferências de aprendizagem, e em particular a análise de dados sensoriais, é considerada uma tarefa de regressão muito difícil. Pelo que se conhece, esta é a primeira vez que a tenrura da carne de cordeiro é aproximada por modelos de regressão neuronais, sendo ainda necessário uma investigação mais aprofundada. Assim, no futuro pretende-se enriquecer as bases de dados, colectando mais amostras. Para além disso,

serão também testadas outras técnicas não lineares, tais como as *Support Vector Machines* [Cortes e Vapnik. 1995].

6. Referências

- Arvanitoyannis, I. e M. Houwelingen-Koukaliaroglou, "Implementation of chemometrics for quality control and authentication of meat and meat products", *Critical Reviews in Food Science and Nutrition*, 43, 2 (2003) 173-218.
- Cortes, C. e V. Vapnik, "Support vector networks", *Machine learning*, 20, 3 (1995) 273-297.
- Dietterich, T., "Ensemble methods in machine learning", *Lecture Notes in Computer Science*, 1857 (2001) 1-15.
- Diéz, J. G. Bayón J. Quevedo J. Coz O. Luaces J. Alonso e A. Bahamonde, "Discovering relevancies in very difficult regression problems: applications to sensory data analysis", Proc. of the European Conf. on AI (ECAI 04), 993-994, 2004.
- Fayyad, U. G. Piattetsky-Shapiro P. Smyth e R. Uthurusamy, *Advances in knowledge discovery and data mining*, AAAI Press, 1996.
- Hastie, T. R. Tibshirani e J. Friedman, *The elements of statistical learning: data Mining, inference, and prediction*. Springer-Verlag, 2001.
- Haykin, S., *Neural networks: A comprehensive foundation*. Prentice-Hall, 1999.
- Hill, B. S. Jones W Robertson e I. Major, "Neural network modeling of carcass measurements to predict beef tenderness". *Canadian Journal. of Animal Science*, 80 (2000) 311-318.
- Huffman, K. M. Miller L. Hoover C. Wu H. Brittin e C. Ramsey, "Effect of beef tenderness on consumer satisfaction with steaks consumed in the home and restaurant", *Journal of Animal Science*, 80 (1997) 91-97.
- Kewley, R. M. Embrechts e C. Breneman, "Data strip mining for the virtual design of pharmaceuticals with neural networks", *IEEE Transactions. on Neural Networks*, 11, 3, (2000) 668-679.
- Kohavi, R., "A study of cross-validation and bootstrap for accuracy estimation and model selection", In Proc. of the Int. Joint Conf. on Artificial Intelligence (IJCAI), 1995.
- Li, J. J. Tan F. Martz e H. Heymann, "Image texture features as indicators of beef tenderness", *Meat Science*, 53, 1 (1999) 17-22.
- Mitra, S. S. Pal e P. Mitra [2002]. Data Mining in Soft Computing Framework: A Survey. *IEEE Trans. on Neural Networks*, 13, 1 (2002) 3-14.
- Park, B. Y. Chen W. Hruschka S. Shackelford e M. Koohmaraie, "Principal component regression of near-infrared Reflectance spectra for beef tenderness prediction", *Transactions of the ASAE*, 44, 3 (2002) 609-615.
- R Development Core Team, *R: A language and environment for statistical computing*. R foundation for statistical computing, Vienna, Austria, 2004.