

Redes Neurais Artificiais: Aplicação na Predição da Percentagem de Carne na Carcaça Suína Resfriada.

Gery A. Dartora¹, Paulo S.S. Borges¹, Milena Tápia², Antônio Guidonni³

¹PGCC - INE, ²PGEEL – IEB, UFSC, Campus Universitário, 88040-900, Florianópolis, SC, Brasil.

³Embrapa Suínos e Aves, BR153, Km110, Vila Tamanduá, 89700-000, Concórdia, SC, Brasil.

E-mails: dartora@uncnet.br, borges@inf.ufsc.br, milena@ieb.ufsc.br, guidoni@cnpas.embrapa.br

Abstract

This paper intends to discuss and evaluate the ability of the Artificial Neural Networks (ANNs) in accomplishing accurate percentage of meat in swine carcass forecast. This variable is of great importance in the bonus rate determination used in the carcass tipification process. The study is justified due to the importance of the problem to the development of Brazilian swine culture and the low quality prediction obtained by the actual model (Multiple Regression - Least Squares Estimation). The evaluation of the model is done comparing the results obtained by the ANN with those reached by the application of the Least Squares Method. The experiments indicate that the ANN, in spite of being based on data - limiting factor in this work - presents the bigger predictive capacity.

1. Introdução

A literatura é farta em aplicações de Redes Neurais Artificiais (RNAs) a problemas de predição. Essas divergem grandemente quanto aos resultados obtidos. Há aquelas que pecam na falta de conhecimento do modelo, escolha das medidas de avaliação de desempenho ou até por distorção dos resultados obtidos. Fatores importantes sobretudo quando se trata de problemas de predição.

Os métodos estatísticos clássicos de previsão são bem-estabelecidos, porém, requerem um entendimento mais profundo do problema. Além disso, podem ter alta complexidade, dependendo do número de variáveis consideradas e na maioria das vezes exigem o cumprimento de um conjunto de pressupostos que varia conforme o método.

RNAs, ao contrário, são modelos não-paramétricos, em que não há grande necessidade de se entender o processo propriamente dito. Basta selecionar um bom conjunto de exemplos e a rede extrai automaticamente as características necessárias para representar a informação fornecida.

Esse trabalho faz parte da dissertação de mestrado do autor, e objetiva discutir e avaliar a habilidade das RNAs, em realizar previsões acuradas da percentagem

de carne na carcaça suína resfriada (PCmf). O modelo em uso, modelo de regressão linear múltipla determinado pelo método dos mínimos quadrados é capaz de explicar 77% da variação observada na PCmf. Acredita-se que uma rede neural, por ser um modelo não-linear e aprender através de exemplos, possa chegar a resultados melhores do que o modelo atual.

Além desta introdução, o trabalho compõe-se de mais três seções. A primeira tece as motivações que nos levaram a explorar a habilidade das RNAs na previsão da PCmf. A segunda sumaria os métodos utilizados: Mínimos quadrados e Redes Neurais Artificiais Diretas. E, por fim, as conclusões obtidas são apresentadas e discutidas.

2. Motivação

A tipificação de carcaças de suínos é um processo de classificação que visa entre outras coisas: a bonificação do produtor de suínos que fornece carcaças com maior rendimento e melhor qualidade de carne; a apuração das carcaças para melhor aproveitamento industrial e a padronização dos produtos segundo as exigências do mercado.

Esse processo de tipificação é essencial para que a suinocultura brasileira atinja um dos seus principais objetivos: o aumento do rendimento de carne nas carcaças.

No Brasil, a classificação é feita segundo a eq. (1).

$$Receita = Preço \times ((PCarq / RendCarq) \times Bonificação) \quad (1)$$

onde:

<i>Receita</i>	Valor recebido pelo produtor por carcaça quente tipificada no momento do abate;
<i>Preço</i>	Preço unitário do Kg de suíno vivo;
<i>PCarq</i>	Peso da carcaça quente no momento do abate;
<i>RendCarq</i>	Rendimento da carcaça quente no momento do abate (Eq.2);
<i>Bonificação</i>	Fator de ponderação que diferencia cada carcaça quente pelo critério de qualidade estabelecido. Uma Bonificação [<1] significa

penalização; [>1] premiação e [$=1$] neutro (Eq. 3).

Sendo que,

$$RendCarq = PCarq / PVivo \quad (2)$$

$$Bonificação = 23,600 + 0,286 - PCarq + PCmf \quad (3)$$

onde:

Pvivo Peso do suíno vivo no momento do abate;

PCmf Percentagem de carne na carcaça resfriada.

Uma vez que é impraticável e impossível dissecar todos os suínos a serem processados para mensurar o *PCmf*, este é predito com base nos valores da Espessura de toucinho (*Esp/mm*), Profundidade de músculo (*Mus/mm*) e do Peso da carcaça quente (*PCarq/kg*). Segundo a literatura, a *PCmf* é a variável primordial na determinação do índice de bonificação e por isso importantíssima na tipificação de carcaças.

Sendo assim, quanto melhor a predição realizada, maior a confiabilidade no índice de bonificação e mais justa a tipificação de carcaça.

3. Material e Métodos

Os dados utilizados neste trabalho provêm de levantamentos efetivados por técnicos da Sadia Concórdia S.A. Ind. e Com. No levantamento, uma amostra de cem suínos foi selecionada e as seguintes variáveis foram mensuradas: Peso da carcaça quente – *PCarq* (kg), Espessura de toucinho avaliada entre a última e penúltima costela – *Esp* (mm) e Profundidade de músculo avaliada entre a última e penúltima costela – *Mus* (mm). Após, esses cem suínos foram dissecados e a Percentagem de carne na carcaça resfriada (*PCmf*) foi avaliada.

As figuras 1 a 4, mostram o comportamento das variáveis em função do número de animais amostrados.




Figura 1: Variável explicativa (Peso da carcaça quente (Kg)).




Figura 2: Variável explicativa (Espessura do toucinho(mm)).

A fig. 1 mostra que a variável *PCarq* tende a crescer na amostra selecionada. Isso deve-se ao processo de amostragem no qual procurou-se selecionar uma amostra significativa da população. A variável *Esp* (fig. 2) variou entre 8 mm a 34 mm, na amostra estudada, independente do peso do animal.




Figura 3: Variável explicativa (Profundidade do músculo (mm)).




Figura 4: Variável de resposta (Percentagem de carne na carcaça resfriada (kg)).

Observando a variável *Mus* (fig. 3) nota-se que essa tende a aumentar, mesmo que muito pouco, conforme o peso do animal. É possível observar também, picos e reduções de largura oscilatória. A variável a ser predita - *PCmf* (fig. 4) - apresenta sinais indicativos dos três padrões encontrados nas outras variáveis.

Tabela 1: Matriz de correlação entre as variáveis.

	PCarq	Esp	Mus	PCmf
PCarq	1	0,216191	0,237874	-0,24562
Esp	0,216191	1	-0,09361	-0,86386
Mus	0,237874	-0,09361	1	0,216036
PCmf	-0,24562	-0,86386	0,216036	1




Figura 5: Correlação entre as variáveis.

Examinando a correlação entre cada par de variáveis incluídas no modelo, observamos que a correlação entre PCarq e Esp é igual a 0,216 e PCarq e Mus é igual a 0,238 indicando uma fraca associação positiva entre as variáveis. Podemos ver também que a correlação entre PCarq e PCmf é de -0,246, indicando uma correlação negativa fraca entre as variáveis. Além disso notamos que não existe praticamente correlação entre as variáveis explicativas Esp e Mus (-0,094) e a variável Esp apresenta uma correlação negativa forte com a variável de resposta (-0,864).

Essa fraca associação entre as variáveis explicativas e a variável resposta é um forte indicativo de que o padrão composto nos dados não é linear, e sim não-linear. A maioria dos métodos estatística para predição pressupõe a linearidade entre as variáveis.

3.1. Regressão Múltipla

Os principais pressupostos para se executar uma análise de regressão são:

- *Normalidade*
requer que os valores de Y sejam normalmente distribuídos para cada valor de X;
- *homocedasticidade*
requer que as variações em torno da linha de regressão sejam constantes para todos os valores de X;
- *independência de erros*
requer que o erro (diferença residual entre valores observados e previstos de Y) deva ser independente para cada valor de X;
- *linearidade*
requer que a relação entre as variáveis seja linear.

Com os pressupostos acima atendidos pelos dados, o modelo de regressão linear múltipla, para dados com três variáveis explicativas, pode ser escrito como:

$$\hat{Y}_i = b_0 + b_1 X_{1i} + b_2 X_{2i} + b_3 X_{3i} \quad (4)$$

Utilizando-se o método dos Mínimos Quadrados¹, os valores calculados dos três coeficientes de regressão de amostras encontrados são:

$$b_0 = 64,03709$$

$$b_1 = -0,04555$$

$$b_2 = -0,62368$$

$$b_3 = 0,132051$$

onde o coeficiente de determinação (R²) é igual a 0,769129, ou seja, 77% da variação da percentagem de carne na carcaça resfriada podem ser explicados a partir do modelo atual.

Portanto, a equação de regressão múltipla para predição da PCmf pode ser expressa como:

$$\hat{Y}_i = 64,03709 - 0,04555 X_{1i} - 0,62368 X_{2i} + 0,132051 X_{3i} \quad (5)$$

sendo que:

$\hat{Y}_i$ - Percentagem de carne da carcaça resfriada do animal;

X_{1i} - peso da carcaça quente do animal;

X_{2i} - espessura do toucinho do animal;

X_{3i} - profundidade de músculo do animal.

A interseção de $\hat{Y}$ com b_0 , calculada como 64,037, estima a percentagem de carne da carcaça resfriada, quando as outras três variáveis (PCarq, Esp e Mus) forem nulas. A inclinação do PCarq, em relação ao PCmf ($b_1 = -0,045$), significa que, para um animal com uma dada Esp e Mus, estima-se que a PCmf decresça em 0,045, para cada kg a mais de carne na carcaça (PCarq). A inclinação de Esp, em relação ao PCmf ($b_2 = -0,623$), significa que, para um animal com uma dada PCarq e Mus estima-se que a PCmf decresça em 0,624, para cada mm a mais de espessura no toucinho (Esp). A inclinação do Mus, em relação ao PCmf ($b_3 = 0,132$) significa que, para um animal com uma dada PCarq e Esp a PCmf cresça em 0,132, para cada mm a mais de profundidade do músculo (Mus).

A análise de regressão foi feita utilizando-se o Sistema Computacional para Análise Estatística de Dados – STATISTICATM, versão 5.0.

¹ Técnica matemática que minimiza as diferenças entre os valores reais e os valores que seriam previstos pela linha de regressão ajustada.

3.2. Modelo Conexcionista

A arquitetura de rede que obteve os melhores resultados na realização dos prognósticos da percentagem de carne na carcaça resfriada é mostrada na fig. 6.




Figura 6: Arquitetura da RNA proposta.

O modelo é uma rede neural direta multicamada completamente conectada. A rede tem três neurônios na camada de entrada (PCarq, Esp e Mus), dois na camada interna, e um na camada de saída (PCmf).

Uma rede direta, totalmente conectada, foi escolhida, devido ao grande sucesso desta em problemas de predição. Exemplos podem ser encontrados em FERNANDES et al. (1995), CORRÊA & PORTUGAL (1995), BRAGA et al. (1996), TAMARI et al. (1996), VALENÇA (1997) e TÁPIA (2000), entre outros.

A função de transferência utilizada foi a mesma para todos os neurônios (tangente hiperbólica) e sua escolha deve-se ao fato de esta ser uma função simétrica que apresenta um bom comportamento matemático.

Devido à grande variação de grandeza na magnitude dos dados, a função logaritmo foi aplicada a estes. Além disso, os dados foram padronizados entre [-1 e 1], devido aos limites da função de transferência utilizada, e divididos em dois conjuntos distintos: treinamento (83,34%) e teste (16,66%).

O treinamento foi feito utilizando-se o algoritmo de retropropagação do erro (*Backpropagation*) com momento, a partir dos seguintes parâmetros:

- Inicialização aleatória dos pesos entre [-1 1];
- Número de épocas: 20000
- Constante de aprendizado (α): 0.1(constante);
- Termo de momento (β): 0.3;
- Função de erro: MSE (Erro Quadrático Médio);
- Erro Máximo admissível: $1e^{-2}$.

As simulações foram feitas utilizando-se a toolbox de RNA do programa MATLAB, versão 6.3.

Arquiteturas de [2 a 8] neurônios na camada interna foram testadas. Assim como, variações na taxa de aprendizado [0.01, 0.05, 0.1 e 0.2], termo de momento [0.2, 0.3, 0.4, 0.9] e número de épocas [18000, 20000, 25000, 30000].

Testou-se também a inserção de mais uma camada interna a rede, porém, esta não melhorou os resultados alcançados e em muitos ensaios até piorou os resultados.

4. Resultados e Conclusões

As previsões obtidas pelas RNAs, foram comparadas com as provenientes do modelo de regressão, através dos seguintes indicadores: Erro Médio (ME), Erro Absoluto Médio (MAE), Erro Quadrado Médio (MSE), Erro Percentual Absoluto Médio (MAPE) e o coeficiente de desigualdade (U_2) de Theil.

Os resultados obtidos, podem ser visualizados na tabela 2.

Tabela 2: Comparação dos resultados obtidos.

Medida de exatidão	RNA	MQ
ME	-0,097	-0,173
MAE	0,097	0,173
MSE	1,500e-001	4,806e-001
NRMSE	0,035	0,063
MAPE(%)	0,206	0,369
U_2	0,161	0,198

Como pode-se observar, os erros cometidos pela RNA foram menores que os cometidos pelo método dos mínimos quadrados em todas as medidas de erro. A medida MAPE da RNA ficou em torno de 0,21%, enquanto a dos mínimos quadrados ficou em torno de 0,37%. A estatística U_2 de Theil da rede, considerada a melhor medida para seleção do método de previsão mais preciso, foi de 0,161 comprovando a superioridade da RNA.




Figura 7: Desempenho da rede (treinamento/teste).




Figura 8: Comparação do desempenho da RNA com o método dos mínimos quadrados.

As figuras 7 e 8, mostram o desempenho da rede no conjunto de treinamento, teste, e quando comparado com o método dos mínimos quadrados.




Figura 9: Análise de regressão dos valores previstos pelo método dos mínimos quadrados para os dezesseis animais do conjunto de teste e os respectivos valores desejados.




Figura 10: Análise de regressão dos valores previstos pela RNA para os dezesseis animais do conjunto de teste e os respectivos valores desejados.

As figuras 9 e 10 comprovam a superioridade da RNA para predição da porcentagem de carne na carcaça resfriada. O coeficiente de determinação (R^2) do método dos mínimos quadrados é de 0,769129, enquanto o da RNA é de 0,850084. Ou seja, enquanto o método em uso explica 76,91% da variação na porcentagem de carne na carcaça resfriada, a RNA pode explicar 85% desta variação.

Apesar da rede ter superado o modelo atual de predição da porcentagem de carne na carcaça resfriada, acredita-se que esta poderia ter obtido resultados melhores se o conjunto de dados disponível para treinamento da rede fosse maior.

RNA's são modelos extremamente baseados em dados. É do conjunto de dados apresentado que esta extrai as características representativas dos dados. Todavia, devido à dificuldade em se obter mais dados, trabalhou-se com apenas cem amostras.

Um fator positivo das RNAs neste trabalho foi à flexibilidade. A rede permitiu o uso de conhecimento intuitivo do especialista como também de informações geradas por modelos estatísticos formais na montagem do conjunto de treinamento. Por exemplo, a plotagem da variável explicativa PCarq, nos fez perceber que a montagem do conjunto de treinamento e teste da rede deveria ser randômica, de modo a eliminar a tendência observada na fig.1, que é uma característica do processo de amostragem e não dos dados.

Isso mostra também, que um conhecimento prévio dos dados é essencial para o bom desempenho das redes neurais artificiais.

Outro fator positivo do modelo conexionista é que, diferente da maioria dos métodos estatísticos, este não especifica condições sobre os parâmetros da população da qual se extraiu a amostra. Nem sempre todas as condições impostas pelos métodos estatísticos são possíveis de serem atendidas.

Outro tipo de rede muito utilizada para predição é a rede RBF (*Radial Basis Function*). Porém, esta não foi utilizada neste trabalho porque, apesar de convergir mais rápido que uma rede direta multicamadas para uma solução ótima, a rede RBF perde em termos de capacidade de generalização (DE OLIVEIRA, 1999) (BRAGA et al., 2000). Este tipo de rede seria ótimo para problemas em que um treinamento on-line é necessário, não para um problema como o aqui exposto, onde se busca um modelo estático, e prima-se por uma boa capacidade de generalização.

Um fator importante a ser analisado é que nem sempre a arquitetura que alcançou o menor erro no processo de treinamento, é a melhor. Neste trabalho todas as outras arquiteturas testadas, arquiteturas com 3, 4, 5, 6, 7 e 8 neurônios na camada interna, apresentaram um erro menor durante o treinamento. Porém, em termos de capacidade de generalização a rede com dois neurônios na camada interna é que apresentou os melhores resultados. O que pode ter acontecido com a rede com oito neurônios na camada interna, a que alcançou um

menor erro no treinamento, foi um supertreinamento. A rede acabou decorando os dados apresentados, perdendo a capacidade de generalizar.

Outro fator importante a ser analisado quando o problema a ser tratado é de predição, são as medidas de erro que serão utilizadas para avaliar o desempenho dos métodos em avaliação. Dependendo da medida de erro utilizada os resultados podem divergir. Uma solução para este problema, segundo MAKRIDAKIS et al. (1998), seria o uso da maioria das medidas padrão de erros, como utilizado neste trabalho.

Por fim, o modelo conexcionista resultante deste trabalho, mostrou-se superior ao modelo utilizado atualmente na predição da percentagem de carne na carcaça resfriada. Assim, podemos dizer que o objetivo maior do trabalho foi atendido.

Vale ressaltar que os resultados aqui publicados são válidos na comparação do modelo conexcionista com o modelo de regressão linear múltipla, modelo este utilizado atualmente nas empresas para o cálculo do índice de bonificação.

Referências

- [1] BRAGA, A.P.; CARVALHO, A.P.L.; LUDERMIR, T.B. *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro: Livros Técnicos e Científicos, 2000.
- [2] BRAGA, M.J.; RESENDE, M.A. *Comparação entre o uso de redes neurais e metodologia de Box & Jenkins na previsão de preços agrícolas: Um exercício empírico*. In: Congresso da Sociedade Brasileira de Economia e Sociologia Rural, 34, 1996, Aracaju. Anais... Aracaju: SOBER, 1996. V.II, p. 1130-1148.
- [3] CORRÊA, W.R; PORTUGAL, M.S. *Previsão de Séries de tempo na presença de mudança estrutural: Redes neurais artificiais e modelos estruturais*. Trabalho apresentado ao XVIII International Symposium on Forecasting, Edinburgh, Escócia, 1995.
- [4] DE OLIVEIRA, C.M. *Um modelo de rede neural artificial para previsão automática da carga ativa nodal de curto prazo em sistemas de transmissão e distribuição de energia elétrica com supervisão e controle automatizados*. Florianópolis, 1999. Dissertação (Mestrado em Engenharia) – Engenharia de Produção de Sistemas, Universidade Federal de Santa Catarina.
- [5] FERNANDES, L.G.L. *Utilização de Redes Neurais na Análise e Previsão de Séries Temporais*. Porto Alegre, 1995. Dissertação (Mestrado em Ciências da Computação) – Curso de Pós-graduação em Ciências da Computação, Universidade Federal do Rio Grande do Sul.
- [6] LEVINE, D. M.; BERENSON, M. L; STEPHAN, D. *Estatística: Teoria e Aplicações*. Rio de Janeiro: Livros Técnicos e Científicos, 2000.
- [7] MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. *Forecasting – Methods and applications*. Ed. 3. New York: John Wiley & Sons, Inc., 1998.
- [8] TAMARI, S.; RUIZ-SUDREZ, J.C; WÖSTEN, J.H.M. *Testing an artificial neural network for predicting soil hydraulic conductivity*. In: Sixth International Conference on Computers in Agriculture (1996: Cancun). Anais. Cancun: American Society of Agricultural Engineers, 1996. p. 913-919.
- [9] TÁPIA, M. *Redes Neurais Artificiais: Uma Aplicação na Previsão de Preços de Ovos*. Florianópolis, 2000. 105f. Dissertação (Mestrado em Ciências da Computação) – Curso de Pós-Graduação em Ciências da Computação, Universidade Federal de Santa Catarina.
- [10] VALENÇA, M.J.S. *Redes Neurais e Regressão Múltipla na previsão de vazões médias mensais*. In: Simpósio Brasileiro de Redes Neurais (IV.: Dez/97: Goiânia). Anais... Goiânia, 1997, p. 55-57