

A UTILIZAÇÃO DA INTELIGÊNCIA ARTIFICIAL PARA A PREDIÇÃO DOS PARÂMETROS PRODUTIVOS DA SUINOCULTURA

Luiz Fernando Sangoi

Universidade Federal de Santa Maria
Avenida Roraima 1000, prédio 7, sala 300, 97105-900, Santa Maria, Rio Grande do Sul,
Brasil
jsiluk@ufsm.br

Alexandre de Mello Kessler

Universidade Federal do Rio Grande do Sul
Av. Bento Gonçalves 7712, 91540-000, Porto Alegre, Rio Grande do Sul, Brasil
akessler@ufrgs.br

Julio Cezar Mairesse Siluk

Universidade Federal de Santa Maria
Avenida Roraima 1000, prédio 7, sala 300, 97105-900, Santa Maria, Rio Grande do Sul,
Brasil
jsiluk@ufsm.br

Andréa Machado Leal Ribeiro

Universidade Federal do Rio Grande do Sul
Av. Bento Gonçalves 7712, 91540-000, Porto Alegre, Rio Grande do Sul, Brasil
aribeiro@ufrgs.br

Alvaro Luiz Neuenfeldt Júnior

Universidade Federal de Santa Maria
Avenida Roraima 1000, prédio 7, sala 300, 97105-900, Santa Maria, Rio Grande do Sul,
Brasil
alvjr2002@hotmail.com

Marlon Soliman

Universidade Federal de Santa Maria
Avenida Roraima 1000, prédio 7, sala 300, 97105-900, Santa Maria, Rio Grande do Sul,
Brasil
marlonsoliman@gmail.com

RESUMO

Em condições similares de manejo alimentar e genética, existem grandes diferenças na produtividade final das granjas, decorrentes dos fatores inerentes do sistema de produção. Tal fato predispõe a necessidade de haver estudos focados na otimização das condições de criação das granjas, a fim de verificar quais seriam as principais limitações existentes para os produtores. Para tanto, a presente pesquisa objetiva identificar os parâmetros produtivos considerados como mais relevantes para os 107 produtores pertencentes a uma cooperativa de suínos, situados em 47 municípios da região do Vale do Taquari, no estado do Rio Grande do Sul, por meio de predições geradas a partir do auxílio das Redes Neurais Artificiais. Obteve-se como principal resultado a condição de se afirmar que o uso da metodologia das Redes Neurais Artificiais pode prever, com reduzidas margens de erro, as variáveis produtivas, Conversão Alimentar, Mortalidade e Ganho Médio Diário.

PALAVRAS CHAVE. Suinocultura, Inteligência artificial, Competitividade.

Área principal. AG&MA - PO na Agricultura e Meio Ambiente. OA - Outras aplicações em PO.

ABSTRACT

In similar conditions of food handling and genetics, there are large differences in the final productivity of farms, resulting from inherent factors of the production system. This fact predisposes the need to exist focused studies on optimizing the rearing conditions of the farms, in order to ascertain what are the main limitations existent for producers. Therefore, the present study attempts to identify the productive parameters considered most relevant to the 107 farmers belonging to a cooperative of pigs, located in 47 cities in the Taquari Valley, region of the state of Rio Grande do Sul, through predictions generated from the aid of Artificial Neural Networks. It was obtained as main result the condition to assert that the use of the methodology of Artificial Neural Networks can predict, with small margins of error, the productive variables, Feed Conversion, Mortality and Average Daily Gain.

KEYWORDS. Pig farming, Artificial intelligence, Competitiveness.

Main area. AG & MA - OR in Agriculture and Environment. OA - Other applications in OR

1. Introdução

Atualmente a carne suína é a proteína mais consumida no mundo, sendo mais da metade produzida pela China e a União Européia (USDA, 2010; ABIPECS, 2012/13). O Brasil ocupa a quarta colocação com 3% desta produção, um lugar de destaque em relação ao contexto mundial, tendo um crescimento na produção e exportação anuais, de aproximadamente 10%, se consideramos os números absolutos dos últimos dez anos (ABIPECS, 2012/2013).

Segundo o relatório de 2012/13 da Associação Brasileira da Indústria Produtora e Exportadora de Carne Suína (ABIPECS), em 2012, o comércio internacional desse setor movimentou 5,81 milhões de toneladas de carne, exportados principalmente para cinco países (Japão, Rússia, México, Coreia do Sul e Hong Kong). Mesmo com as barreiras sanitárias, com aumento dos subsídios europeus e o crescimento da concorrência internacional, o Brasil exporta 10% desse mercado (581,4 milhões de toneladas), com uma receita cambial aproximada de 1,49 bilhões de dólares.

A suinocultura é um importante setor da zootecnia nacional e apresenta um dos melhores desempenhos econômicos no cenário internacional, resultado dos avanços tecnológicos e organizacionais como a reprodução, estado nutricional, manejo sanitário, qualidade genética e produtividade do plantel (COELHO et al., 2011). Mesmo assim, em condições similares de alimentação e genética, existem grandes diferenças na produtividade final das granjas, devido a fatores climáticos, gerenciais, materiais e humanos relacionados ao sistema de produção, que tornam a tarefa de prever o comportamento da suinocultura quando se deseja a otimização dos recursos alocados ao manejo dos animais algo de extrema dificuldade.

Coerente a demanda exposta Vieira et al. (2010) e Pandorfi et al. (2011) citam que a inteligência artificial, em específico as Redes Neurais Artificiais (RNA), têm sido cada vez mais utilizadas na tentativa de avaliar com maior precisão quais os fatores na criação de animais que podem contribuir significativamente para o aumento da produtividade, a fim de prever as principais limitações dos produtores cooperativados.

Em vista dos fatos, a presente pesquisa objetiva gerar previsões dos dados produtivos; conversão alimentar, ganho médio diário e taxa de mortalidade; de suínos na fase de terminação, pertencentes a uma cooperativa de criadores, a partir da utilização das variáveis de perfis dos produtores e dos resultados produtivos realizados, com o auxílio das Redes Neurais Artificiais.

2. Materiais e métodos

O desenvolvimento da pesquisa está embasado no cumprimento de dez etapas metodológicas propostas pelos autores, conforme mostra a Figura 1. Partiu-se da contextualização a respeito da suinocultura, realizado com base nos manuscritos de Beattie et al. (2000), Guivant e Miranda (2004), Gonçalves e Palmeira (2006) e Ferreira (2012), através dos quais chegou-se ao consenso de que o perfil do sistema de produção nacional está fortemente baseado em uma estrutura organizacional verticalizada, em função da vasta extensão territorial do País, da produção dos principais insumos (milho e soja) e do uso de tecnologia avançada. Como consequência, os custos de produção são inferiores aos principais concorrentes internacionais.

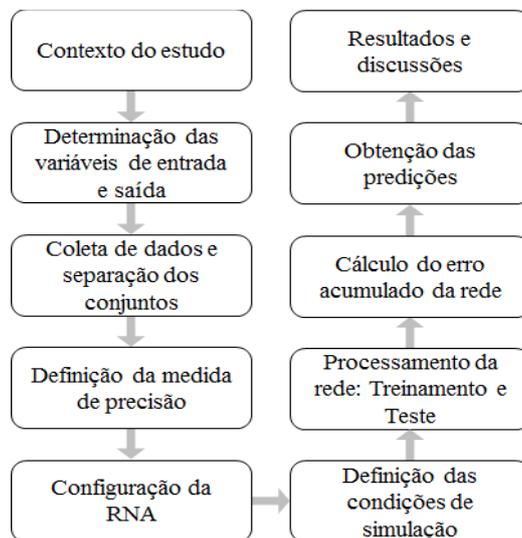


Figura 1 – Etapas metodológicas da pesquisa.

A partir dessa contextualização, determinou-se dezenove variáveis de entrada (c) para o contexto, onde cada uma é constituída de uma série de perfis (b), de forma que exista a possibilidade de se elencar individualmente todos os produtores (p) em pelo menos um perfil, sendo que as variáveis foram divididas em três grandes grupos (g), conforme mostra o Tabela 1, a fim de visualizar os resultados da predição de maneira mais fidedigna à realidade abordada, com base na literatura e na experiência prática dos pesquisadores envolvidos.

Em relação às variáveis de saída, foram selecionados três dados zootécnicos (s): Conversão alimentar (ct), Mortalidade (ms) e Ganho Médio Diário (md) ou GMD, relativos à produção de suínos correspondentes aos produtores de cada perfil.

Tabela 1 – Variáveis de entrada e seus respectivos grupos

Variável de entrada (c)	Perfis (b)
	Social/Econômico (g=1)
Atividade principal (1)	Outra (1); Avicultura (2); Bovinocultura de leite (3); Suinocultura (4)
Atividade Secundária (2)	Outra (1); Fumicultura (2); Bovinocultura de leite (3); Suinocultura (4)
Faixa idade (3)	51 a 60 anos (1); Acima 60 (2); 21 a 30 (3); 31 a 40 (4); 41 a 50 (5)
Escolaridade (4)	Fund. incompl. (1); Fund. compl. (2); Médio incompl. (3); Médio compl. (4); Sup. incompl. (5); Sup. compl. (6)
Tipo mão-de-obra (5)	Contratada (1); Familiar (2)
Quant. mão-de-obra (6)	1 (1); 2 (2); 3 (3); 4 (4); Acima 5 (5)
Descendência (7)	Portuguesa (1); Alemã (2); Polonesa (3); Italiana (4); Outra (5)
	Instalações/Equipamentos (g=2)
Suínos alojados (8)	Até 499 (1); 500 a 999 (2); Acima 1000 (3)
Galpões (9)	1 (1); 2 (2); Acima de 3 (3)
Orientação solar (10)	Outra (1); Norte/Sul (2); Leste/Oeste (3)

Cobertura (11)	Telha amianto ou similar (1); Telha convencional (2)
Piso (12)	Piso maciço (1); Piso vazado (2)
Biossegurança/Logística (g=3)	
Granja mais próxima (13)	Menor 0,5 km (1); De 0,5 a 2 km (2); De 2 a 4 km (3); Maior 4 km (4)
Densidade rebanhos (14)	Acima de 4 (1); 2 a 3 (2); 1 (3)
Distância rodovia (15)	Menor 0,5 km (1); De 0,5 a 1 km (2); Mais de 1 km (3)
Qual. isolamento (16)	Sem biossegurança (1); Com biossegurança (2)
Distribuição ração (17)	Manual (1); Automatizada-Manual (2); Automatizada (3)
Tipo bebedouro (18)	Chupeta (1); Coxinho (2)
Dist. frigorífico (19)	Mais 80 km (1); 60 a 80 Km (2); 40 a 60 Km (3); 20 a 40 Km (4); Até 20 Km (5)

A coleta dos dados foi realizada em 47 municípios da região do Vale do Taquari, estado do Rio Grande do Sul, entre Fevereiro e Março de 2012, compreendendo o universo de 120 produtores. Utilizou-se um diagnóstico com perguntas estruturadas fechadas, em conjunto com os resultados produtivos de 494 abates nos anos de 2010 e 2011. Estes dados foram separados aleatoriamente em dois conjuntos, dos quais o primeiro contém os dados necessários para o teste da rede (30% do total) e o segundo é usado para a execução do treinamento da mesma (70% do total) (Bicciato et al., 2003; Haykin, 2008 e Pandorfi et al., 2011). Vieira et al. (2010) e Pandorfi et al. (2011) sugerem que um prévio tratamento estatístico dos dados pode resultar em melhorias nas condições em que os resultados serão estabelecidos, principalmente quando a extensão da série de valores coletados não possui um tamanho relativamente alto, a fim de tornar mais confiável e rápida a convergência dos dados durante o processamento da rede neural artificial.

Para tanto, foi proposta a normalização (Nb_{cp}) dos perfis característicos b_{cp} dos produtores p , devido aos perfis estarem caracterizados por variáveis discretas, a fim de adequarmos a aplicação da rede neural artificial por meio da proposta descrita pela Equação (1), a partir da prévia identificação dos produtores em um limite superior (b_{cmax}) e inferior (b_{cmin}) para os critérios, de modo que estes são proporcionais, respectivamente, a $Nb_{cmax} = 1 * 10^{-4}$ e $Nb_{cmin} = 0,65 * 10^{-4}$, para T_c relativo ao somatório de b contidos em cada c .

$$Nb_{cp} = Nb_{cmax} - \left(\frac{Nb_{cmax} - Nb_{cmin}}{T_c - 1} \right) \left\{ \begin{array}{l} Nb_{cmax} \propto b_{cmax} = 1 * 10^{-4} \\ Nb_{cmin} \propto b_{cmin} = 0,65 * 10^{-4} \end{array} \right. \quad (1)$$

A segunda etapa foi composta pela definição da medida utilizada para a determinação do grau de precisão das diferentes possibilidades de arquiteturas da rede neural artificial, e pela verificação de suas características intrínsecas e a concepção do arranjo que se ajustou de forma mais coerente para o contexto da predição em questão. Isto foi feito através do cálculo da soma dos erros médios quadrados (Ed_s), após o processamento dos dados reais de entrada (Nb_{cp}) e as predições ($N'b_{cp}$) de saída, conforme mostra a Equação (2), onde d é o índice utilizado para identificar se o conjunto mensurado pertence ao teste ($d=1$) ou ao treinamento ($d=2$), para uma expectativa de resultados que esteja compreendida na faixa entre zero e 1,50 ($0 < Ed_s \leq 1,50$), de acordo com o contexto abordado.

$$Ed_s = \frac{1}{2} * \sum_{c=1}^M \sum_{p=1}^N (Nb_{cp} - N'b_{cp})^2 \rightarrow \forall c \in g; s = \{ct; ms; md\} \quad (2)$$

A terceira etapa correspondeu à determinação das características estruturais da rede neural artificial. Para tanto, a rede possui como paradigma neural o tipo *feedforward perceptron*, por não possuir um grafo cujo comportamento de processamento é cíclico e estar distribuída em múltiplas camadas (*Multilayer Perceptron*), a fim de que cada uma das variáveis de entrada seja processada nas camadas intermediárias, gerando assim as predições utilizadas para a comparação com os valores reais determinados.

Por se tratar de um modelo que visa otimizar o valor obtido no erro Ed_s , é necessário a utilização de um algoritmo capaz de conceber a aprendizagem da rede de forma supervisionada, demanda esta que refletiu na escolha, com base nos pressupostos de Haykin (2008), pelo método

denominado por *backpropagation*, que possibilita o ajuste dos pesos sinápticos e o seu respectivo nível de bias, visto a sua capacidade intrínseca de reduzir a função erro do sistema.

Quanto a topologia da rede, tem-se a definição pela utilização de um total de três tipos distintos, sendo uma de entrada, uma de saída e outra intermediária, dispostos de forma oculta não linear e preenchida com um total de quatro neurônios. Com base nos resultados de diversas simulações, é possível afirmar que a função de ativação capaz de restringir a amplitude dos valores processados que retornou a melhor precisão em relação a rede foi a *tangente hiperbólica*, tanto na camada intermediária quanto na saída, calculada a partir da Equação (3), segundo Uykan et al. (2000):

$$\gamma(Nb_{cp}) = \text{tanh}(Nb_{cp}) = \frac{(e^{Nb_{cp}} - e^{-Nb_{cp}})}{(e^{Nb_{cp}} + e^{-Nb_{cp}})} \rightarrow \gamma(Nb_{cp}) \in (-1,1) \quad (3)$$

As verificações foram separadas em três partes, a partir das variáveis de saída, de modo a possibilitar a visualização individual e a maneira com que se comportam cada uma das variáveis de entrada, obtendo-se como produto final gráficos capazes de identificar o quanto as estimativas se encontram desajustadas em relação aos valores reais fornecidos.

A quarta etapa consistiu no processamento da simulação da rede, iniciada pela fase de treinamento, considerando a submissão de 70% do universo pesquisado a repetidos estímulos oriundos dos parâmetros previamente determinados em sua arquitetura estrutural, em conjunto com um rol de pesos randomicamente determinados, de modo a observar a forma com a qual ela se comporta a partir dos dados de saída calculados. Foram relacionados como critérios balizadores para determinar o final do ciclo de processamento das interações a taxa de aprendizagem supervisionada e o erro médio quadrático para o algoritmo entre as variáveis, no caso 0,1 e 0,005, respectivamente. Em caso de não se obter o perfil desejado, haverá o reajuste dos pesos dos parâmetros até que um dos critérios de parada pré-estabelecidos seja atingido, de modo a representar que a rede se encontra em condições satisfatórias de conhecimento para aplicação prática. Com o aperfeiçoamento da rede foi possível proceder com os testes para os 30% dos dados restantes, dos quais serviram para a verificação do nível de desempenho da rede perante situações reais de utilização.

Ambos os procedimentos foram submetidos para cálculo ao *software SPSS Statistics 19*[®], em específico a sua interface denominada *Neural Networks*, pois julgou-se que esta poderia atender satisfatoriamente as demandas a cerca do problema de pesquisa abordado.

3. Resultados e discussões

3.1 Caracterização da população

Inserido ao contexto dos 120 produtores pesquisados, a cooperativa divide estes em sete regiões, tendo um técnico para o atendimento exclusivo de cada região. Em relação às características gerais dos produtores, é possível afirmar que aproximadamente 96% destes são do sexo masculino, sendo que 64% do total estão envolvidos, prioritariamente, com atividades diretamente ligadas à suinocultura, fato considerado normal por se notar que boa parte das propriedades possuem condições para se realizar múltiplas atividades produtivas.

Quanto à escolaridade, apenas 6,6% dos pesquisados estão ou possuem titulação em cursos de graduação, enquanto que 58,3% se encontram no outro extremo, dos que completaram ou não o ensino fundamental. Por fim, cerca de 56,6% dos produtores se encontram em uma faixa de idade que permeia desde os 41 até os 60 anos, sendo que a soma dos valores que se encontram nos extremos da curva (21 a 30 e acima de 61 anos) preenche apenas 25,8% do universo adotado.

3.2 Aplicação das Redes Neurais Artificiais

Primeiramente, se propôs a utilização da rede do tipo Multilayer Perceptron (MLP), que possui como pressuposto básico a possibilidade de se definir previamente a maneira com que os parâmetros da modelagem se dispõem para a simulação. Com essas definições estabelecidas, houve a realização do processamento das redes, nas quais o primeiro resultado observado foi a

maneira com que ocorreu a sumarização do universo de dados disponibilizados, a fim de verificar se o perfil de divisão estabelecido na etapa metodológica foi processado corretamente, gerando os resultados estabelecidos pela Tabela 2.

Tabela 2 – Processo sumário dos casos.

Processos	Conversão alimentar		Mortalidade		GMD	
	N	%	N	%	N	%
Treinamento	88	75,2	86	71,7	80	67,2
Teste	29	24,8	34	28,3	39	32,7
Validação	117	100	120	100	119	100
Excluídos	3		0		1	
Total	120		120		120	

O treinamento foi concebido por meio da utilização de aproximadamente 70% do universo considerado, havendo, três exclusões para a Conversão Alimentar e uma relativa ao Ganho Médio Diário (GMD), a partir das diretrizes estabelecidas anteriormente. Essa e outras variações encontradas podem ser creditadas aos diferentes momentos em que o processamento das redes foi executado. Para as três exclusões a repetição consecutiva do erro médio quadrado ($<0,005$) se estabeleceu como critério responsável por induzir a parada do ciclo de interações propostas pela *backpropagation*.

Às predições, para a conversão alimentar, ficaram no intervalo entre 2.30 e 2.34, conforme mostram as Figuras 2 e 3, foi possível observar que os erros quadrados podem ser considerados de baixa significância, para o teste ($E1_{ct} = 0,126$) e para o treinamento ($E2_{ct} = 0,126$), com uma polarização dos dados que se estendem majoritariamente (70,8%) aos quadrantes localizados na parte superior em relação à curva de tendência traçada pela equação $y_{ct}(Nb_{cp}) = 0,5 * Nb_{cp} + 1,3$, concentradas em sua maioria na região central do gráfico.

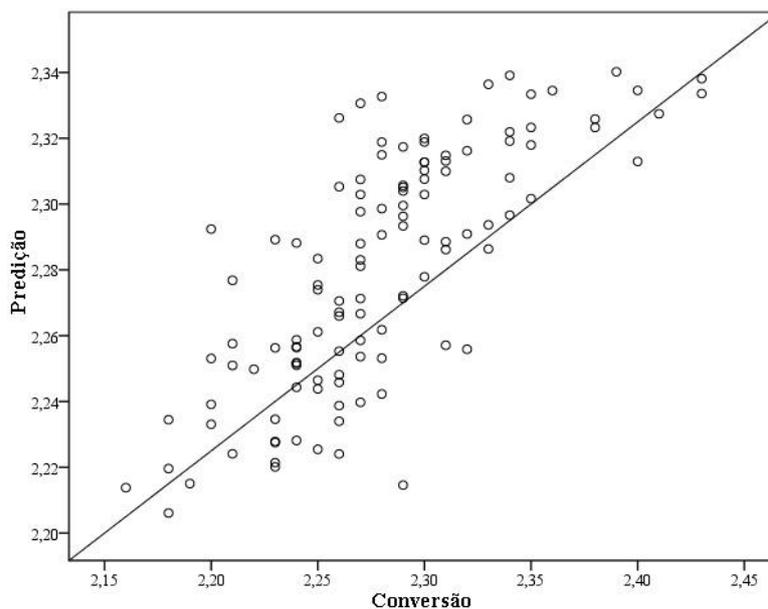


Figura 2 - Predições para a conversão alimentar

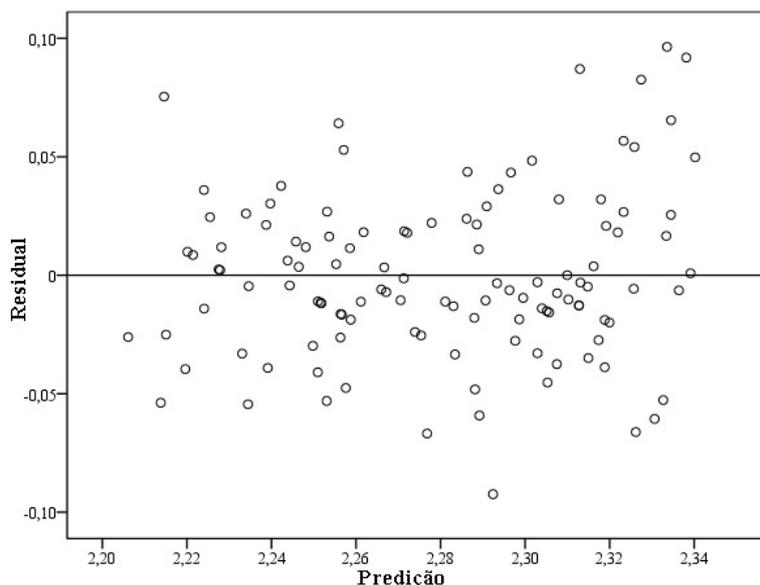


Figura 3 - Residuais para a conversão alimentar

O resultado residual se mostra equivalente quanto à aproximação do eixo horizontal de origem (zero), para um deslocamento dos valores que pode ser considerado homogêneo, sem que haja uma preponderância negativa (55%) ou positiva (45%) significativa. Quanto ao grau de distorções, percebe-se que os resultados dos valores que se encontram mais próximos do limite 2,34 são os que possuem as maiores imprecisões para o montante superior (+0,11), enquanto que para o inferior os valores de maior imprecisão estão estabelecido na faixa intermediária entre 2,28 e 2,30 (-0,095).

Em relação a mortalidade, às predições ficaram no intervalo entre 1,5% e 2,45%, de acordo com as Figuras 4 e 5, pode-se perceber uma polarização na distribuição dos dados localizada nos quadrantes inferior esquerdo e superior direito se considerada a curva de tendência $y_{md}(Nb_{cp}) = 0,5 * Nb_{cp} + 1,3$, havendo uma maior concentração de valores na primeira (61,7%) em comparação à segunda (20,0%), consolidando assim uma tendência dos critérios estabelecidos influenciarem mais fortemente algum destes dois extremos.

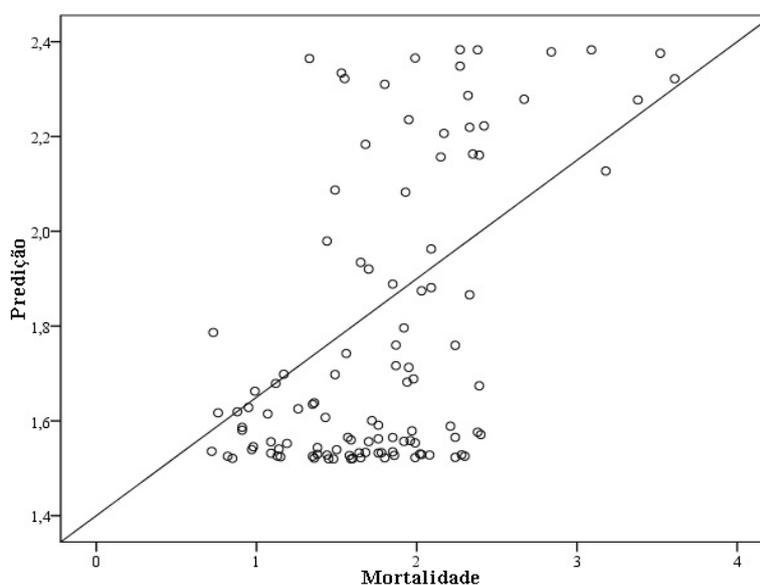


Figura 4 - Predições para a mortalidade.

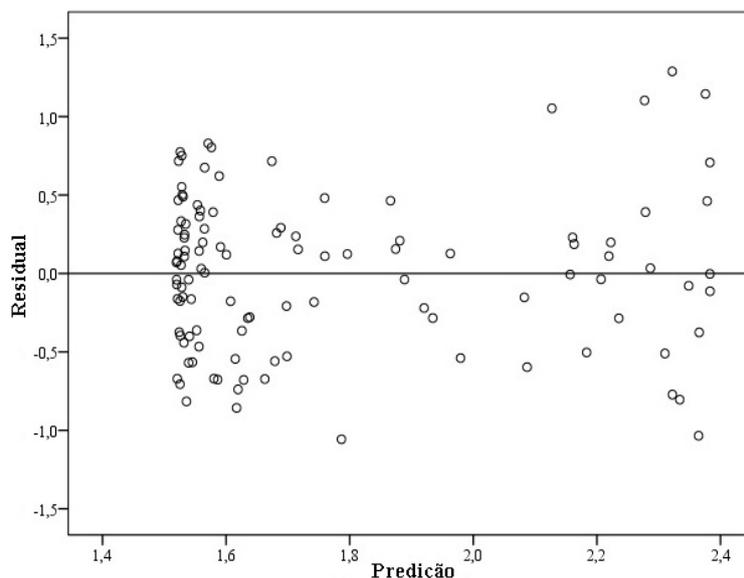


Figura 5 - Residuais para a mortalidade.

Na medida do erro médio, observou-se que os valores para o teste ($E1_{ms} = 1,187$), diferentemente do treinamento ($E2_{ms} = 0,357$), não se aproximaram tão fortemente de zero, mas ainda estão compreendidos na faixa de valores considerada como aceitável para o contexto. Para os resíduos, novamente houve uma maior dispersão para os pontos localizados nas predições de mortalidade mais afastadas de zero, ou seja, as menos recomendadas aos produtores, onde tanto a mais inferior (-1,2) quanto a superior (+1,4) estão contidos em $2,2 < ms < 2,4$, sendo possível afirmar que os piores desempenhos são os que possuem as maiores imprecisões.

Em relação às predições do Ganho Médio Diário (GMD), estas ficaram no intervalo entre 0.855 g e 0.903 g, segundo mostram as Figuras 6 e 7, de modo que 85% dos valores se encontram concentrados acima da curva de tendência $y_{ms}(Nb_{cp}) = 0,3 * Nb_{cp} + 0,61$, denotando uma forte tendência dos produtores possuírem um desempenho aproximadamente uniforme, fato esse que se confirma com a baixa variação tanto dos dados reais (0,04) quanto das predições (0,10) para a distribuição normal da série. Ainda, é possível afirmar que os critérios não exercem uma predominância significativa para a melhora ou não da produção de suínos nas granjas, a partir de erros médios equivalentes a $E1_{md} = 0,634$ e $E2_{md} = 0,151$ coerentes ao intervalo considerado ideal.

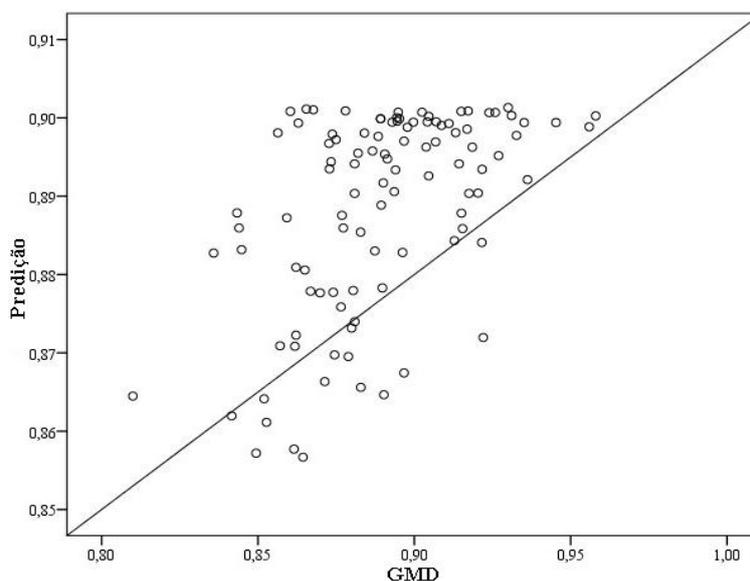


Figura 6 - Predições para a GMD.

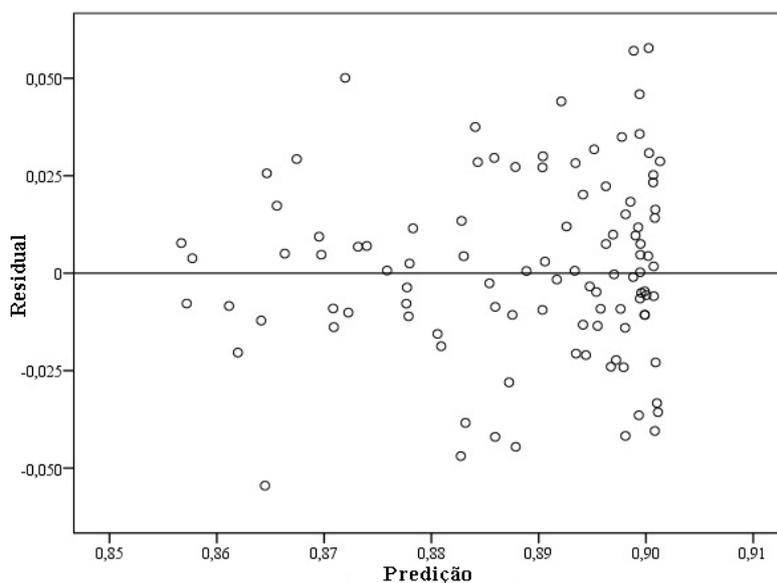


Figura 7 - Residuais para a GMD.

Para os resíduos, tem-se um comportamento relativamente semelhante ao descrito no caso da mortalidade, onde os pontos imprecisos estão localizados aproximadamente em 0,90, porém, havendo uma exceção para o *outlier* inferior que se encontra entre 0,86 e 0,87 (-0,051).

4. Conclusão

De acordo com os resultados obtidos, podemos afirmar que, o uso da inteligência artificial, em específico as redes neurais artificiais, foram considerados viáveis, para predição dos índices zootécnicos: Conversão alimentar, Mortalidade e Ganho Médio Diário (GMD) da suinocultura, pois os resultados obtidos através da soma dos erros médios quadrados, convergiram para valores aproximados a zero, a partir dos critérios de entrada e variáveis de saída previamente delimitados ao estudo.

As redes neurais artificiais, através de critérios científicos, permitiram prever dados produtivos, realizar simulações e medir o quanto cada variável explica cada fenômeno. Serviram ainda de suporte para as tomadas de decisões dos gestores da cadeia de suinocultura.

Para futuros estudos, espera-se aplicar ao mesmo universo de produtores outras técnicas de predição, como os modelos Autoregressive Integrated Moving Average (ARIMA), Autoregressive Conditional Heteroskedasticity (ARCH) e Generalized Autoregressive Conditional Heteroskedasticity (GARCH), a fim de notar se os resultados destes em relação às redes neurais artificiais possuem convergência ou não.

Referências

ABIPECS, Associação Brasileira da Indústria Produtora e Exportadora de Carne Suína. Relatório ABIPECS 2012/2013. Disponível em: <<http://www.abipecs.org.br/pt/documentos.html>>. Acesso em: 18 jun. 2013.

Beattie, V. E., O'Connell, N. E. e Moss, B. W. (2000), Influence of environmental enrichment on the behavior, performance and meat quality of domestic pigs, *Livestock Prod. Sc.*, 65, 71-79.

Bicciato, S., Pandin, M., Didone, G. e Di Bello, C. (2003), Pattern identification and classification in gene expression data using an auto associative neural networks model, *Biotechnology Bioengineering*, 81, 5, 594-606.

Coelho, L. A. F, Léga, E., Martins, J. R., Marques, P. A., Silveira, A. L. G e Menezes, M. C. (2011), Avaliação espermática e dosagem sérica do cortisol em dois suínos em diferentes períodos do dia, *Nucleus Animalium*, 3, 1, 17-30.

Ferreira, R. A., Suinocultura Manual Prático de Criação, Aprenda Fácil, Viçosa, 2012.

- Gonçalves, R. G. e Palmeira, E. M.** (2006), Suinocultura brasileira. Revista Acadêmica de Economia, n. 71.
- Guivant J. S. e Miranda, C. R.**, Desafios para o desenvolvimento sustentável da suinocultura, Editora Argos, Chapecó, 2004.
- Haykin, S. O.**, Neural Networks and Learning Machines, Prentice Hall, Upper Saddle River, 2008.
- Pandorfi, H., Silva, I. J. O., Sarnighausen, V. C. R., Vieira, F. M. C., Nascimento, S. T. e Guiselini, C.** (2011), Uso de redes neurais artificiais para predição de índices zootécnicos nas fases de gestação e maternidade na suinocultura, *Revista Brasileira de Zootecnia*, 40, 3, 676-681.
- USDA**, United States Department of Agriculture, 2010, Anual report USDA, disponível em: <http://usdasearch.usda.gov/search?utf8=%E2%9C%93&affiliate=usda&query=Annual+report+2010&x=20&y=8&commit=Search>, acesso em 20 jun. 2013.
- Uykan, Z., Guzelis, C., Çelebi, M. E. e Koivo, H. N.** (2000), Analysis of input-output clustering for determining centers of RBFN, *IEEE Transactionson Neural Networks*, 11, 851-858.
- Vieira, F. M. C., Silva, I. J. O., Filho, J. A. D. B. e Vieira, A. M. C.** (2010), Productive losses on broiler preslaughter operations: effects of the distance from farms to abattoirs and of lairage time in a climatized holding area, *Revista Brasileira de Zootecnia*, 39, 2471-2476.