

**IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE  
AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG**

**AVALIAÇÃO DE IMÓVEIS URBANOS COM UTILIZAÇÃO DE REDES NEURAIAS  
ARTIFICIAIS**

**Pelli Neto, Antônio**

Caixa Econômica Federal – Entidade Conveniada  
Pelli Sistemas de Engenharia  
Belo Horizonte - MG, Brasil  
[www.pellisistemas.com.br](http://www.pellisistemas.com.br)  
[pelli@pellisistemas.com.br](mailto:pelli@pellisistemas.com.br)

**Zárate, Luis Enrique**

Pontifical Catholic University of Minas Gerais  
Department of Computer Science,  
Laboratório de Inteligência Computacional Aplicada – LICAP  
Software Avançado de Inteligência Computacional & Sistemas - SAIC  
Belo Horizonte - MG, Brasil  
[zarate@pucminas.br](mailto:zarate@pucminas.br)

**Resumo.** *Os grandes avanços na área da computação têm colaborado com o desenvolvimento de sistemas de apoio a decisão, afim de se alcançar uma maior produtividade sem perder o foco na confiabilidade e qualidade dos serviços prestados. Na área de Engenharia de Avaliações o uso das tecnologias computacionais tem sido ainda restrita e um dos principais objetivos deste trabalho é mostrar a possibilidade do uso de sistemas computacionais – como redes neurais artificiais – no processo de avaliação de imóveis urbanos. Neste trabalho é desenvolvida uma metodologia para a estimação do valor de mercado de imóveis através do uso de Redes Neurais artificiais. Será apresentado o processo de seleção e análise dos dados para treinamento da rede neural, o pré-processamento a ser aplicado aos dados, o processo de treinamento da rede e a validação e análise dos resultados. Finalmente as conclusões e as perspectivas futuras são apontadas.*

**Palavras Chaves:** Engenharia de avaliações, Redes neurais artificiais.

# **IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG**

## **1 Introdução**

O projeto NBR 14653-2, da ABNT – Associação Brasileira de Normas Técnicas, prevê no item 8.2.1.4.3 – Tratamento Científico, em sua alínea c) a utilização de outras ferramentas, além da inferência estatística, para a indução do comportamento do mercado, citando a utilização de redes neurais artificiais como uma destas opções.

Os grandes avanços na área da computação têm colaborado com o desenvolvimento de sistemas de apoio a decisão, afim de se alcançar uma maior produtividade sem perder o foco na confiabilidade e qualidade dos serviços prestados. Na área de Engenharia de Avaliações o uso das tecnologias computacionais tem sido ainda restrita e um dos principais objetivos deste trabalho é mostrar a possibilidade do uso de sistemas computacionais – como redes neurais artificiais – no processo de avaliação de imóveis urbanos.

Neste trabalho é desenvolvida uma metodologia para a estimação do valor de mercado (venda) de imóveis através do uso de Redes Neurais artificiais. Será apresentado o processo de seleção e análise dos dados para treinamento da rede neural, o pré-processamento a ser aplicado aos dados, o processo de treinamento da rede e a validação e análise dos resultados. Finalmente as conclusões e as perspectivas futuras são apontadas.

Na maioria das vezes modelos lineares têm sido utilizados adequadamente para descrever o comportamento do mercado imobiliário. Contudo, uma grande parte destes processos, independente da sua natureza, apresenta comportamentos não lineares e que levam a modelos complexos exigindo soluções analíticas e/ou numéricas. Quando se utiliza a transformação de variáveis buscando a linearização dos valores, e principalmente quando esta prática é aplicada à variável dependente, essa complexidade restringe e dificulta o conhecimento e a análise dos próprios processos.

O processo de avaliação de imóveis envolve a estimação de diversos parâmetros populacionais referentes às variáveis selecionadas para representar o comportamento do mercado imobiliário. De forma implícita, estas variáveis – denominadas variáveis independentes – se relacionam com o valor do imóvel de forma não-linear.

É clara a necessidade de novas técnicas visando representar os processos de avaliação de imóveis e um dos objetivos deste trabalho é propor uma nova metodologia com a utilização de redes neurais artificiais.

Para o desenvolvimento deste trabalho foram elencadas diversas variáveis independentes, tendo sido utilizadas variáveis quantitativas, variáveis proxy e variáveis qualitativas, sendo a escala destas variáveis qualitativas mensurada através de processo científico. O valor de mercado do imóvel avaliando é função não linear de vários parâmetros, equação (1). Qualquer mudança no parâmetro Nível/elevador (Ne), no Setor (St), no total de vagas (Tv), área coberta (Ac), número de dormitórios (Dm), número de sanitários (Sn), equipamentos (Eq), padrão de acabamento (Pd) e conservação (Cs), utilizados em nosso modelo, causará mudança no valor do imóvel (Vu).

**IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE  
AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG**

$$Vm=f(Ne, St, Tv, Ac, Dm, Sn, Eq, Pd, Cs) \quad (1)$$

A limitação do método da regressão linear está concentrada no mapeamento de dados através de uma aproximação linear de dados de mercado. Esta aproximação linear pode não refletir o valor de mercado do imóvel avaliando, especialmente quando os dados são altamente dispersos e com características intrínsecas e extrínsecas as mais variadas.

Existe atualmente um crescente interesse na aplicação da Inteligência Artificial (IA) em diversas áreas da representação de processos. Dentro da área da IA, Redes Neurais tem sido o foco de uma grande atenção durante os últimos anos, devido a sua capacidade de representar problemas não-lineares por aprendizado e a sua capacidade de generalização [1-2].

Neste trabalho é apresentado uma aplicação de Redes Neurais para representar o processo de avaliação através da estimação do valor unitário de venda (Vu) de imóveis. Será apresentado o processo de seleção e análise dos dados para treinamento da rede neural, o pré-processamento que deve ser aplicado aos dados, o processo de treinamento da rede e a validação e análise dos resultados. Finalmente as conclusões e as perspectivas futuras são apontadas.

## **2 Representação Neural do Processo de Avaliação de Imóveis**

Nos últimos anos as RNA's estão sendo propostas como poderosas ferramentas computacionais devido a sua capacidade de resolver problemas não-lineares por aprendizado, a sua capacidade de associação de padrões e de generalização. (ver anexo 1 para estrutura geral de uma RNA).

A RNA utilizada neste trabalho é uma rede multicamadas, a qual se aproxima das teorias conexionistas que procuram descrever o funcionamento do cérebro humano. O tipo de aprendizado desta rede é conhecido como *aprendizado supervisionado*, baseada no sistema "retropropagação do erro". Esta rede utiliza duas ou mais camadas de neurônios de processamento. A camada de entrada recebe as entradas externas enquanto que a camada de saída é a responsável pela geração da resposta da rede. Existindo uma terceira camada entre as duas anteriores, esta recebe o nome de "camada escondida". A escolha da complexidade da rede ou seja, o número de camadas escondidas e o número de neurônios nestas camadas seguem alguns critérios empíricos. No caso do número de neurônios para a camada escondida é sugerido que seja  $2N+1$  neurônios, onde N é o número de entradas da rede [3].

Na equação (2)  $f$  é a função não linear sigmóide, escolhida neste trabalho como a função de transferência do axônio, por ser a mais consistente com a biofísica do neurônio biológico.

$$f = \frac{1}{1 + \exp^{-\sum \text{Entrada} \times \text{Pesos}}} \quad (2)$$

## IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG

Uma RNA do tipo "retropropagação do erro" é treinada por meio de um aprendizado supervisionado. O processo utiliza de um padrão de dados à entrada da rede e de uma saída desejada. Para cada conjunto padrão os pesos da rede são ajustados para minimizar a diferença entre as saídas da rede e as desejadas. O erro é minimizado utilizando a técnica do gradiente com um fator de convergência chamado "taxa de aprendizagem".

Para alimentar o processo de treinamento da RNA foram coletados dados relativos a oferta de apartamentos no mercado imobiliário de Belo Horizonte – Minas Gerais, onde foram utilizadas como variáveis independentes as citadas em parágrafo anterior e como variável dependente o valor unitário do imóvel ( $V_u$ ) Equação 3).

A rede neural considerada é uma rede de duas camadas, onde foi escolhido o número de neurônios da camada escondida igual a 19. O número de neurônios na camada de saída, igual a 1, correspondente ao número de saídas da rede.

$$f(Ne, St, Tv, Ac, Dm, Sn, Eq, Pd, Cs) \xrightarrow{RNA} V_m \quad (3)$$

Geralmente o maior esforço para o treinamento de uma rede neural encontra-se na coleta de dados e no pré-processamento deles. O pré-processamento consiste na normalização dos dados da entrada e da saída. Para o tipo de rede considerada o único requisito é que os valores das entradas e das saídas se encontrem no intervalo de 0 a 1 por compatibilidade com a função sigmóide.

Os seguintes procedimentos foram adotados para normalizar os dados das entradas associados às suas respectivas saídas, antes de usá-los no treinamento da rede neural:

**P1)** Como os valores de 0 e 1 são valores infinitos para a função sigmóide, é recomendável diminuir este intervalo para valores de 0,2 e 0,8 respectivamente, com o objetivo de facilitar a convergência durante o treinamento da rede.

**P2)** Os dados foram normalizados e desnormalizados através das seguintes expressões:

$$f^a(L_o) = L_n = (L_o - L_{mín}) / (L_{máx} - L_{mín}) \quad (4a)$$

$$f^b(L_n) = L_o = L_n * L_{máx} + (1 - L_n) * L_{mín} \quad (4b)$$

onde :  $L_n$  é o valor normalizado;  $L_o$  o valor a normalizar;  $L_{mín}$  e  $L_{máx}$  são valores mínimos e máximos dentre os valores das variáveis.

**P3)** Pelo exposto no item a) faz-se necessário a mudança de escala dos dados, para valores que proporcionem quando normalizados, valores limites entre 0,2 e 0,8. As fórmulas para calcular  $L_{mín}$  e  $L_{máx}$  são as seguintes:

$$L_{mín} = (4 \times \text{LimiteInf.} - \text{LimiteSup.}) / 3 \quad (5a)$$

$$L_{máx} = (\text{LimiteInf.} - 0,8 \times L_{mín}) / 0,2 \quad (5b)$$

As equações (5a) e (5b) são obtidas da substituição na equação (4a) de  $L_n = 0,2$  e  $L_o = \text{LimiteInf.}$  e de  $L_n = 0,8$  e  $L_o = \text{LimiteSup.}$  Onde  $\text{LimiteInf.}$  e  $\text{LimiteSup.}$  são os valores mínimos e máximos respectivamente dos conjuntos de dados originais.

### 2.1 Dados para obtenção dos conjuntos de treinamento

## IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG

Para obter os conjuntos de dados (Equação 3), para treinamento da rede neural, foram coletados 172 apartamentos de média e baixa renda, representativos do mercado imobiliário da cidade de Belo Horizonte. A Tabela I.1 do anexo apresenta um resumo da amostra coletada.

Uma das condições para obter uma representação neural satisfatória é que os dados sejam consistentes e reflitam o fenômeno a ser representado. A incorporação de subjetividades, fora dos padrões de avaliação, pode levar a uma rede neural com polarização da sua representatividade e falhar na estimativa do valor de venda do imóvel.

Outra condição a ser considerada é em relação à quantidade de conjuntos e ao número de dados de cada um a serem coletados. A quantidade dos conjuntos não é mais importante que a qualidade dos mesmos. A única condição é que o número de conjuntos e os dados de cada um contêm os dados representativos do problema. Uma condição para estabelecer a qualidade dos conjuntos é que estes não sejam extremamente dispersos. Se for considerado um conjunto (dados de um apartamento específico) muito distante dos outros conjuntos a rede neural, pode-se refletir num maior tempo computacional gasto para que a rede aprenda a associar os conjuntos. Caso exista uma falha na qualidade dos conjuntos de treinamento, também haverá uma dificuldade para representar aqueles valores mal condicionados. De forma geral, a quantidade necessária de dados e variáveis para o processamento de RNA pode ser fixada em função da mesma quantidade a ser utilizada pela Regressão Linear, no caso do mercado imobiliário.

A Figura 1 mostra os conjuntos de treinamento, considerados para este trabalho, representados pelo valor de venda por metro quadrado do imóvel. Observe que os dados apresentam uma distribuição uniforme e não-linear. Uma aproximação linear para esses conjuntos pode trazer resíduos significantes o que pode levar a estimativas falsas do valor do imóvel sendo avaliado. O objetivo deste trabalho é a representação dessa distribuição através de redes neurais artificiais.

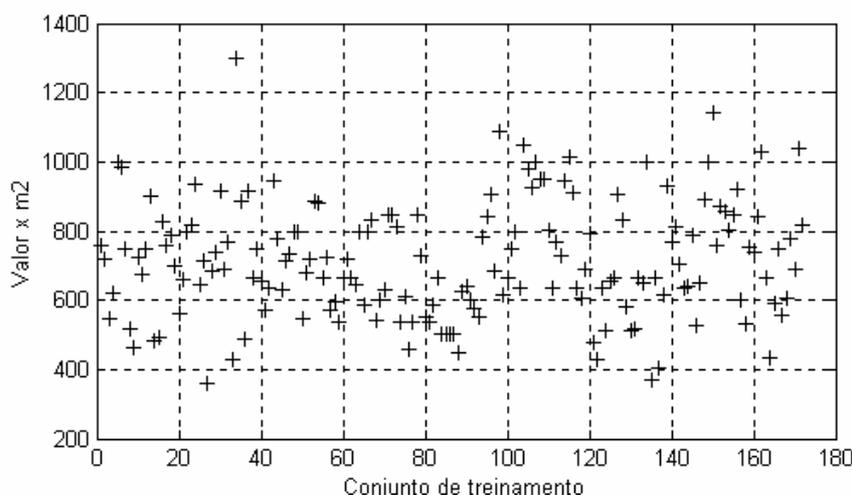


Figura 1. Conjuntos de treinamento

**IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE  
AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG**

**2.2 Processo de Treinamento da Rede**

Para o processo de treinamento da Rede foram considerados valores iniciais aleatórios, para os pesos dos neurônios, na faixa de -1,0 a +1,0. Considerando os 172 conjuntos de treinamento, mostrados na Figura 1, a taxa de aprendizado foi igual a 0,025 e a soma dos erros quadráticos das saídas foi 0,089 após 500.000 iterações de treinamento.

Os pesos finais para as camadas escondida e saída com seus pesos de polarização são dados a seguir:

$$W_{L2N}^h = \begin{bmatrix} 9.0463 & -6.4145 & 1.8808 & -0.9982 & 7.8844 & 1.7003 & -2.0808 & -0.6020 & 2.7495 \\ -4.1744 & -0.3374 & 6.0859 & 3.3370 & 6.4003 & 4.3687 & -3.4363 & 2.4093 & -9.0876 \\ -6.7016 & 5.6989 & 1.2710 & -3.1222 & 2.0993 & 8.7647 & 2.6602 & -10.1132 & 0.8228 \\ 5.3908 & -0.2072 & -11.4827 & 4.3905 & -3.1166 & 0.8878 & -2.2609 & -5.5543 & -1.5588 \\ -6.5003 & 6.5890 & -0.7794 & 3.0276 & -5.0736 & 5.4019 & 5.9176 & -2.7903 & -9.5174 \\ 1.1175 & -0.2113 & 5.5888 & -1.3882 & 3.2936 & -2.1089 & -9.4825 & -1.5957 & 5.9623 \\ 6.1456 & -1.0891 & 4.3687 & -0.6554 & -3.0697 & -1.7948 & -4.4203 & 0.1769 & 5.9647 \\ 4.1908 & -1.3898 & 9.1763 & 2.5721 & -7.2491 & 2.8300 & 2.1628 & 9.3080 & 0.0437 \\ 3.2941 & 0.7256 & 3.4734 & 2.7203 & -4.7259 & -6.7228 & 2.7764 & 4.9528 & 6.9927 \\ -7.7959 & 8.1085 & 3.3902 & -1.2763 & -0.0020 & 6.4706 & 2.1668 & -4.7379 & -5.4711 \\ -10.7223 & -8.3422 & -0.2579 & -3.6045 & 0.4904 & 9.4197 & -0.1082 & -2.4084 & 4.7493 \\ 3.6175 & -8.5118 & 3.1572 & 0.0096 & 6.3375 & 4.0498 & -7.5724 & 7.5425 & 2.5003 \\ 4.0561 & -5.1962 & -6.8320 & -2.3917 & 8.8456 & -2.1957 & 10.4738 & -5.8889 & -1.7524 \\ 6.9035 & 1.1784 & 2.7534 & 1.1111 & -5.7586 & 5.6892 & 3.2424 & 2.8648 & 2.5939 \\ 3.1956 & 1.8268 & 0.9120 & -0.2483 & -2.2492 & -1.2880 & 4.6530 & 7.8585 & 4.7112 \\ 5.0945 & 7.9608 & 1.0840 & 4.1806 & 0.5096 & 3.5001 & 5.9590 & 2.0220 & 0.6427 \\ -3.1212 & 1.6391 & -7.3256 & -0.6520 & -5.9863 & -2.4822 & 3.3746 & -9.2642 & -7.2643 \\ -7.7645 & -5.3617 & 3.6200 & -6.9228 & 2.7426 & 3.8727 & -8.4373 & 6.5043 & -1.3349 \\ -9.1236 & -5.1357 & 2.3346 & 2.7614 & -8.2563 & -3.4781 & -1.4043 & 5.7405 & -2.9526 \end{bmatrix}$$

$$W_{L2M}^o = \begin{bmatrix} 2.7410 \\ -1.0811 \\ 3.1716 \\ -1.3115 \\ 3.6740 \\ -2.6992 \\ 1.1118 \\ 3.2780 \\ -2.5310 \\ -5.7523 \\ -3.3475 \\ -3.8594 \\ -1.9485 \\ -5.0025 \\ 2.7477 \\ 3.3497 \\ -1.6715 \\ 3.1803 \\ -2.7048 \end{bmatrix}$$

$$W_{L21}^h = \begin{bmatrix} -9.5990 \\ -0.3541 \\ -6.0217 \\ 5.9871 \\ -0.3086 \\ -4.9464 \\ -4.5056 \\ -10.5947 \\ -9.9462 \\ -3.4614 \\ -3.9437 \\ -8.4272 \\ -1.6054 \\ -11.6205 \\ -13.0613 \\ -19.0302 \\ 6.7666 \\ 2.2233 \\ 7.4343 \end{bmatrix}$$

$$W_{M21}^o = [2.6969]$$

A Tabela 1, mostra os erros máximos e mínimos alcançados pelo processo de treinamento.

Tabela 1. Erros alcançados pelo processo de treinamento

Erro min	Erro min (%)	Erro max	Erro max (%)	Erro médio	Erro médio (%)
0,089	0,013	108,44	20,87	25,50	3,93

As Figuras 2 e 3 mostram visualmente o resultado do treinamento da rede neural proposta. Observe que existem pontos que a rede conseguiu mapear com erros pequenos e outros onde apresentou um erro significativo.

**IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE  
AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG**

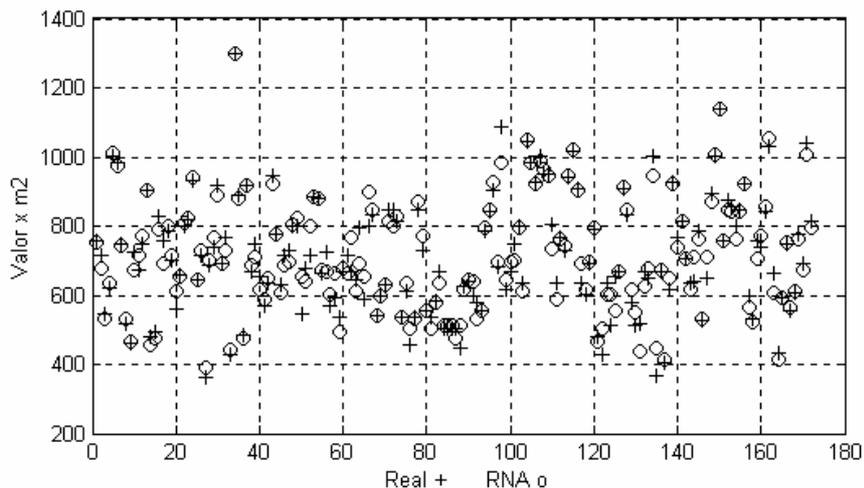


Figura 2. Resultado do treinamento da rede neural

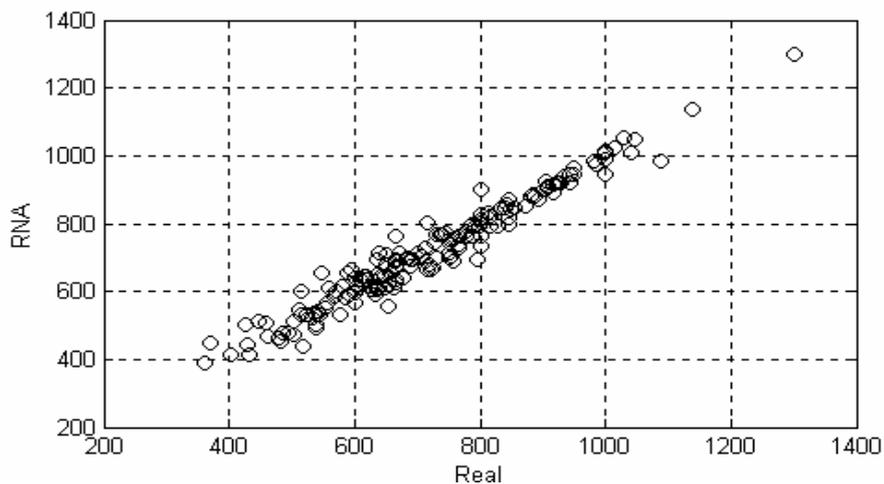


Figura 3. Valores Observados x Valores Calculados RNA

### 2.3 Validação da representação proposta

Para validação dos resultados obtidos, além de um conjunto de dados selecionados para estimação pela RNA (Tabela 2), foi elaborado um modelo de regressão linear múltipla, através do aplicativo **SisRen Windows – Sistema de Rede Neurais**, cujo poder de predição pode ser visualizado no gráfico da figura 4.

A Tabela 2, mostra os conjuntos de dados considerados para validação da rede treinada

Bairro	NE	St	Tv	Ác	Dm	Sn	Eq	Pd	Cs	Vu - Reg. L	Vu Oferta	Vu RNA
Sag. Família	8	500	100	85	3	2	1	300	600	707,31	764,71	720,33
Sta Efigênia	8	500	50	44	2	1	1	180	600	770,59	863,63	720,20
Dom Cabral	20	650	100	73	2	1	26	220	480	784,63	767,12	766,09
Castelo	6	400	100	60	3	2	8	300	600	862,85	816,66	819,95
C. Eucar.	7	700	100	75	2	2	21	300	450	871,64	880,00	880,86

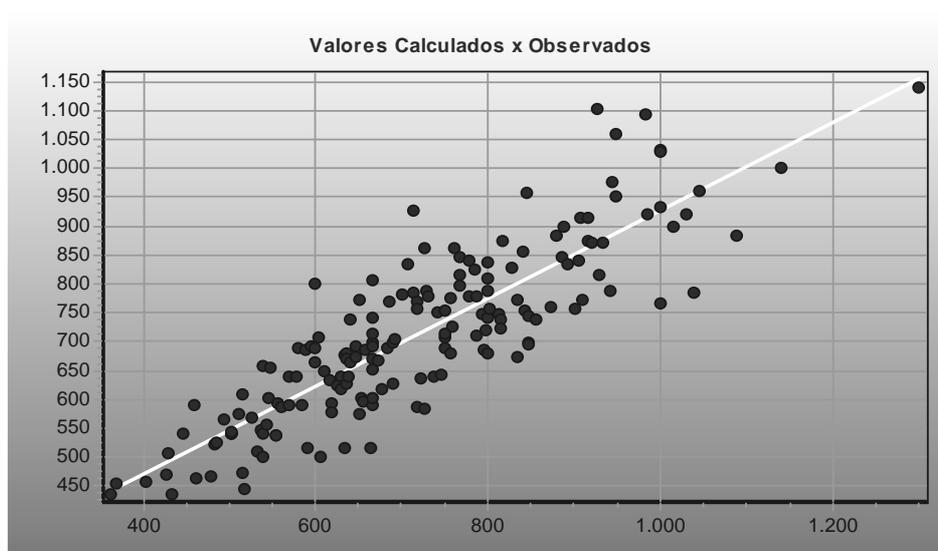


Figura 4. Valores Observados x Valores Calculados RNA

### 3 Discussão dos Resultados

#### Conclusões

Neste trabalho foi discutida a possibilidade de utilização de Redes Neurais para a estimação de valores de mercado de imóveis urbanos. Os valores estimados pela RNA foram bem aproximados dos valores estimados pela regressão linear, conforme pode ser observado na Tabela 2.

No caso do imóvel situado no bairro Santa Efigênia, os valores estimados pela Regressão Linear, pela RNA e o preço ofertado foram:

Regressão Linear Múltipla: R\$ 770,59.

Rede Neural artificial: R\$ 720,20.

Oferta do Imóvel no mercado local: R\$ 863,63.

Este tipo de imóvel normalmente é ofertado neste mercado imobiliário com um elevado fator de oferta/transação, por tratar-se de imóvel destinado a baixa renda. O principal argumento de venda é a prestação mensal oriunda do financiamento em agente financeiro da habitação, onde o cliente decide pela aquisição apenas comparando o aluguel de imóvel semelhante com o valor da prestação, sem aferir o valor venal do imóvel. Neste caso a RNA conseguiu mapear esta situação e o valor obtido por ela se mostrou mais aderente aos dados do que aquele obtido pela Regressão Linear Múltipla.

Outro resultado importante na comparação dos processos pela RNA e Regressão Linear Múltipla, na estimação de valores de mercado, pode ser obtido verificando os gráficos de Valores Observados  $\times$  Valores Calculados. No caso da RNA (figura 3) o poder de predição do modelo é superior ao da Regressão Linear Múltipla (figura 4).

**IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE  
AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG**

Para que a RNA possa ser definitivamente utilizada na Engenharia de Avaliações, no estágio atual de estudos, é fundamental que os pressupostos básicos relacionadas no anexo A do projeto de Norma 14653-2 sejam atendidos. Porém, alguns destes pressupostos somente podem ser alcançados ainda se utilizados os modelos de regressão linear. Cabe ressaltar que a modelagem através de redes neurais tem apresentado muitos avanços, principalmente quanto à validação estatística de seus resultados, o que nos leva a acreditar que em um futuro próximo este estudo estará completo.

A proposta final deste trabalho enfatiza a necessidade da utilização paralela de um sistema computacional onde seja possível estimarmos o valor de mercado através da RNA e da Regressão Linear Múltipla, a fim de estabelecermos intervalos de confiança para os resultados obtidos pelo método dos mínimos quadrados. Se for verificado que os valores estimados pela RNA estão dentro deste intervalo, porém mais aderentes aos dados, então a conclusão pelo valor deve ser a favor da RNA, e justificado no laudo descritivo.

**IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE  
AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG**

**Referências**

- Zárate, L.E.; Song, M. e Helman H. b. "Algoritmo para Linearização de Processos via redes neurais e sua análise de comportamento assintótico". V Simpósio Brasileiro de Redes Neurais, Dez. Belo Horizonte, Brasil, pp.199-204, 1998.
- Zárate, L.E.; Helman H. e Gálvez, J.M. c. "Um Método para Linearização de Modelos Utilizando Redes Neurais e sua Aplicação em Processos de Laminação". VIII Congresso Latinoamericano de Control Automático", Vol. II, pp.709-714 - Nov. 9-13, Viña del Mar, Chile, 1998.
- Kovács, Z.L. Cap 5, Edição Acadêmica São Paulo, Redes Neurais Artificiais, pp.75-76, São Paulo, Brasil, 1996.
- Champness, P. (TEGOVA) – “Normas Europeas Aprobadas sobre Tasación de Bienes Inmuebles”, CSCAE/ATASA, 1998;
- Dantas, Rubens A. – “Engenharia de Avaliações - Uma Introdução à Metodologia Científica”, Pini, 1998;
- Gujarati, D. – “Econometria Básica” – Makron Books, 2000;
- Henderson e Quandt – “Teoria Microeconômica - Uma abordagem matemática”, McGrawHill, 1994;
- Horngren, C. T., G. Foster, e S. M. Datar – “Cost Accounting: a Managerial Emphasis”, Prentice Hall, 1999;
- International Valuation Standards Committee – “International Valuation Standards 2000”, IVSC, 2000;
- Johnston, J. – “Métodos Econométricos”, Atlas, 1974;
- Kmenta, J. – “Elementos de Econometria” – Atlas, 1978;
- Law, A., Kelton, W.D. – “Simulation Modeling and Analysis”, McGrawHill, 1991;
- Maddala, G.S. – “Econometrics”, McGraw-Hill, 1977;
- Netter, J. e Wasserman, W. – “Applied Linear Statistical Models” – Richard D. Irwin, 1974;
- Simonsen, M.H. - Teoria Microeconômica, FGV, 1979;
- Smith, H., Tschappat, C. e Racster, R. – “Real Estate and Urban Development”, Irwin, 1977;
- Van Horne, J.C.- “Financial Management and Policy”, Prentice Hall, 1998;
- Wonnacott, R. e Wonnacott, T., “Fundamentos de Estatística”, Livros Técnicos e Científicos Editora, 1985.

**Anexo I - Rede Neural Perceptron Multicamadas**

A topologia da rede multicamadas considerada neste trabalho corresponde a uma rede de duas camadas de neurônios, com N entradas na camada entrada; L neurônios na camada escondida e M neurônios na camada de saída. É também considerado que os neurônios possuem entradas de polarização cada um. A função não linear sigmóide foi escolhida neste trabalho como a função de transferência do axônio, por ser a mais consistente com a biofísica do neurônio biológico. A Figura I.1 mostra a topologia da rede usada neste trabalho.

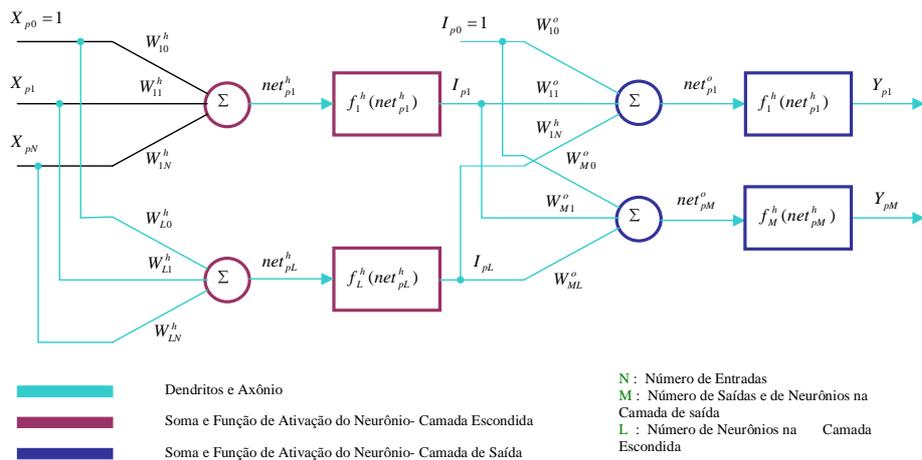


Fig. I.1 – Topologia da rede neural multicamadas

Seja o conjunto de treinamento mostrado na Eq.(I.1), onde  $X_i, i = 1, \dots, P$  são as entradas normalizadas e  $Y_i, i = 1, \dots, P$  são as saídas desejadas da rede normalizadas pela função sigmóide, segue-se abaixo a descrição das etapas e equações matemáticas necessárias no algoritmo seqüencial para o treinamento da rede neural multicamadas.

$$( \underline{X}_1, \underline{Y}_1 ), \dots, ( \underline{X}_p, \underline{Y}_p ) \quad (I.1)$$

I. Aplicar o conjunto “p” representado pela Eq.(I.2), onde N é o número de entradas.

$$\underline{X}_p = (X_{p1}, \dots, X_{pN})^T \quad (I.2)$$

II. Calcular a saída linear da camada escondida de acordo com a Eq.(I.3), onde  $net_{pj}^h$  é produto dos pesos pelas entradas e  $W_{ij}^h$  contém o peso do neurônio i e entrada j para a camada escondida.

$$net_{pj}^h = \sum_{i=0}^N W_{ji}^h X_{pi} \quad j = 1, \dots, L \quad (I.3)$$

III. Calcular a saída da camada escondida através da Eq.(I.4), onde  $I_{kj}$  contém as respostas da função sigmóide  $f_j^h (net_{pj}^h)$  para a camada escondida.

**IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE  
AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG**

$$I_{pj} = f_j^h(\text{net}_{pj}^h) \quad j = 1, \dots, L \quad (\text{I.4})$$

IV. Calcular a saída linear da camada de saída de acordo com a Eq.(I.5), onde  $\text{net}_{pk}^h$  é produto dos pesos pelas entradas e  $W_{kj}^o$  contém o peso do neurônio  $i$  e entrada  $j$  para a camada de saída:

$$\text{net}_{pk}^o = \sum_{j=0}^L W_{kj}^o I_{pj} \quad k = 1, \dots, M \quad (\text{I.5})$$

V. Calcular a saída da rede através da Eq.(I.6), onde  $Y_{kj}$  contém as respostas da função sigmóide  $f_k^o(\text{net}_{pk}^o)$  para a camada de saída.

$$Y_{pj} = f_k^o(\text{net}_{pk}^o) \quad k = 1, \dots, M \quad (\text{I.6})$$

VI. Calcular o erro da camada de saída através da Eq.(I.7), onde  $\Gamma_{pk}^o$  contém os erros calculados da camada de saída.

$$\Gamma_{pk}^o = (\psi_{pk} - Y_{pk}) f_k^{o'}(\text{net}_{pk}^o) \quad k = 1, \dots, M \quad (\text{I.7})$$

VII. Calcular o erro na camada escondida através da Eq.(I.7), onde  $\Gamma_{pk}^h$  contém os erros calculados da camada escondida.

$$\Gamma_{pk}^h = f_j^{h'}(\text{net}_{pj}^h) \sum_{k=1}^M \Gamma_{pk}^o W_{kj}^o \quad j = 1, \dots, L \quad (\text{I.8})$$

VIII. Atualizar os pesos da camada de saída de acordo com a Eq.(I.9), onde  $\mu$  é o fator de ajuste.

$$W_{kj}^o(t+1) = W_{kj}^o(t) + \mu \Gamma_{pk}^o I_{pj} \quad k = 1, \dots, M \text{ e } j = 0, \dots, L \quad (\text{I.9})$$

IX. Atualizar os pesos da camada escondida de acordo com a Eq.(I.10).

$$W_{ji}^h(t+1) = W_{ji}^h(t) + \mu \Gamma_{pj}^h X_{pi} \quad j = 1, \dots, L \text{ e } i = 0, \dots, N \quad (\text{I.10})$$

X. Verificar a tolerância através da Eq.(I.11), onde  $E_p$  é o erro global e  $\delta$  é o erro médio.

$$E_p = \frac{1}{2} \sum_{k=1}^M \delta_{pk}^2 < \text{tolerância} \quad (\text{I.11})$$

Neste trabalho foi escolhida a função sigmóide, que é representada no algoritmo de treinamento pelas equações Eq.(I.12) e Eq.(I.13).

$$f_k^o(\text{net}_{pk}^o) = \frac{1}{1 + \exp^{-\text{net}_{pk}^o}} \quad (\text{I.12})$$

**IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE  
AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG**

$$f_k^{o'}(net_{pk}^o) = Y_{pk}(1 - Y_{pk}) \quad (I.13)$$

**Anexo II – Resumo dos dados coletados para Avaliação de Apartamentos da cidade de Belo Horizonte**

Bairro	NE	St	Tv	Ác	Dm	Sn	Eq	Pd	Cs	Vu
Jardim América	7	500	70	62	3	1	9	180	600	758,06
Colegio Batista	7	550	100	110	3	2	7	300	340	545,45
Centro	13	650	0	105	3	1	3	360	460	619,04
Sion	9	850	100	60	2	1	10	260	420	1.000,00
Carlos Prates	8	550	100	70	3	2	15	300	600	985,71
Funcionários	7	650	0	80	3	2	9	260	400	750,00
Barroca/Grajaú	9	600	140	75	3	2	8	240	420	826,66
Nova Suíça	9	550	100	86	3	2	15	300	480	755,81
Castelo	6	400	100	60	3	2	8	300	600	816,66
Calafate	12	550	100	60	2	1	11	320	600	933,33
São João Batista	14	300	80	70	2	1	16	120	300	428,57
Santo Agostinho	22	650	0	50	2	1	21	540	480	1.300,00
Barro Preto	17	650	0	62	3	1	13	400	480	887,09
Barroca	9	650	70	103	3	1	8	130	380	485,43
Prado	28	550	100	60	2	1	18	300	480	916,66
Liberdade	9	450	40	60	3	1	8	180	600	666,66
Santa Amélia	7	450	50	51	2	1	1	180	480	637,25
Palmares	15	500	200	72	3	2	11	260	600	944,44
Dona Clara	7	450	100	45	2	1	9	180	600	777,77
Santa Branca	7	400	100	70	3	1	2	240	600	628,57
Campo Alegre	9	350	50	42	2	1	10	180	600	714,28
Heliópolis	8	350	100	65	3	2	9	180	580	800,00
Vila Cloris	8	300	50	42	2	1	1	120	600	547,61
Dona Clara	9	450	50	60	3	1	8	300	600	716,66
Coração	7	700	100	75	2	2	21	300	450	880,00
Alípio de Melo	9	400	50	60	3	1	8	160	600	665,00
Santa Terezinha	9	400	100	64	3	1	8	180	600	593,75
Santa Inês	7	400	100	60	3	2	9	180	600	800,00

Floresta	9	500	50	62	2	1	7	180	380	629,03
Guarani	13	300	50	59	3	1	8	240	480	610,16
Florammar	6	350	50	48	2	1	8	120	300	458,33
Planalto	7	400	50	65	2	1	6	300	600	538,46
Sagrada Família	7	500	170	88	3	2	13	300	600	784,09
Santa Efigênia	7	450	100	55	3	2	9	180	600	1.089,09
Milionários	8	250	50	63	3	1	9	180	600	617,46
Santa Helena	7	350	100	75	3	2	9	240	600	666,66
Cardoso	7	300	100	60	3	2	9	180	600	750,00
Santa Tereza	8	400	100	50	2	1	15	200	380	798,00
Buritis	7	500	200	58	2	2	11	180	600	948,27
Santa Cruz	7	300	50	60	3	1	2	130	380	633,33
Padre Eustáquio	7	550	100	55	2	1	7	300	600	727,27
Caiçara	8	500	50	53	2	1	23	120	480	603,77
Industrial	8	200	0	48	2	1	1	120	300	479,16
Santa Mônica	6	300	50	70	3	1	18	300	480	514,28
Barreiro	8	400	100	65	3	2	4	280	480	1.000,00
Tirol	7	250	200	90	3	2	2	300	600	666,66
Diamante	6	350	50	65	3	2	2	200	480	615,38
Silveira	7	550	70	45	2	1	9	120	600	893,33
União	19	500	200	48,	2	1	9	180	600	1.139,89
Cidade Nova	18	650	100	75	3	2	21	180	420	760,00
da Graça	8	550	100	60,	2	2	9	200	600	921,50
Fernão Dias	7	400	0	45	2	1	9	120	500	600,00
Cachoeirinha	12	350	100	70	3	2	17	180	600	842,85
Nova Granada	9	350	170	60	2	1	8	180	600	750,00
Copacabana	6	350	0	38	2	1	0	120	360	605,26
Céu Azul	7	250	70	42	2	1	8	120	600	690,47
Ana Lúcia	7	400	100	50	2	1	8	300	480	1.040,00

**IBAPE – XII COBREAP – CONGRESSO BRASILEIRO DE ENGENHARIA DE  
AVALIAÇÕES E PERÍCIAS, BELO HORIZONTE/MG**

**Curriculum Vitae:**

**Nome:** Antônio Pelli Neto

**Formação:** Engenharia civil e mecânica

**Graduação:** Universidade Federal de Minas Gerais

**Data:** Dezembro/82

- *Principais participações em congressos*

- Apresentação de Trabalho no XI COBREAPE – Congresso Brasileiro de Engenharia de Avaliações e Perícias.
- Apresentação de Trabalho no CIVYT – 1º. Congresso Internacional de Valoración e Tasación - **Informatización de Evaluación Económica de Emprendimientos.**
- Participação no CIVYT – 1º. Congresso Internacional de Valoración e Tasación.

- *Atividades profissionais*

**Empresa - Caixa Econômica Federal (a partir de 1982)**

- Divisão de Processamento de Dados.
- Desenvolvimento de Programas - Analista de Sistemas.
- Concurso Público - Engenheiro Mecânico e Civil.
- Participação do Grupo de Trabalho de Avaliação dos Imóveis Funcionais da União.
- Desenvolvimento do *Sistema de apoio a Avaliação Imobiliária – SAAI*
- Desenvolvimento do *Sistema de Avaliações Imobiliárias – SIM.*
- Designado Instrutor de Avaliação de Imóveis – Avaliar Bens, tendo ministrado diversos cursos de Avaliação de Imóveis no âmbito da Caixa Econômica Federal.

**Empresa – Pelli Sistemas Ltda. (a partir de 1986)**

- Desenvolvimento do Programa **SisDat** – Banco de Dados Imobiliário.
- Desenvolvimento do Programa **SisReg** – Sistema de Regressão Linear Múltipla aplicada a Avaliações de Imóveis.
- Desenvolvimento do Programa **SisValue** – Sistema de Avaliações Econômicas.
- Consultoria para diversas empresas da Administração Pública e Privada, com foco nas Avaliações Comparativas e Avaliações Econômicas.
- Treinamento de diversas turmas para empresas da Administração Pública e Privada, referente à Avaliação de Imóveis com uso de Inferência Estatística e Regressão Linear Múltipla.
- Desenvolvimento do Sistema de Apoio ao Desenvolvimento de Planta de Valores – **SisPlanV.**