

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

**ESTUDO COMPARATIVO ENTRE REDES NEURAS ARTIFICIAIS E ANÁLISE  
DE REGRESSÃO MÚLTIPLA NA AVALIAÇÃO DE BENS, PARA PEQUENAS  
AMOSTRAGENS**

**SCHIAVO, ELIANE HASSELMANN CAMARDELLA**

**Eng<sup>a</sup> Civil**

**CREA nº 43.985-D/RJ**

**IEL-RJ nº 854**

**Rua Uruguaiana, 55 Sala 710, Rio de Janeiro, RJ, CEP20.050-094**

**Tel. 0-xx-21-2507-3063/2509-6441/3970-0808/3970-1942**

**e-mail: [eliane@consultoria-cca.com.br](mailto:eliane@consultoria-cca.com.br)**

**AZEVEDO, MÁRCIO PACHECO**

**Eng<sup>o</sup> Civil**

**CREA nº 34.300-D/RJ**

**Rua Uruguaiana, 55 Sala 710, Rio de Janeiro, RJ, CEP20.050-094**

**Tel. 0-xx-21-2507-3063/2509-6441/3970-0808/3970-1942**

**e-mail: [marcio@consultoria-cca.com.br](mailto:marcio@consultoria-cca.com.br)**

**Resumo:** O uso de modelos de Redes Neurais Artificiais tem sido alvo de muita pesquisa, atualmente com emprego em muitas áreas de conhecimento como: controle de processos, predição de series temporais, otimização, problemas de classificação e processamento de imagens e sinais. O presente trabalho tem como objetivo o estudo comparativo entre Redes Neurais Artificiais e Análise de Regressão Múltipla aplicadas a 28 casos de Avaliações Patrimoniais - situações de mercado -, que têm como característica um reduzido número de amostras por caso em estudo.

**Abstract:** In our days, Artificial Neural Networks have been target of researchs in several knowledge areas such as: process control, temporal series predict, optimization, classification problems and image and signal processing. The goal of this paper is compare the use of Artificial Neural Network with Multiple Regression Analysis applied on 28 cases of properties valuation - real state market - wich the mainly characteristic is the small number of samples, by case in study.

## **1 - Introdução**

O uso da Metodologia Científica, isto é, Análise de Regressão Múltipla, em trabalhos Avaliatórios consagrou-se a partir de meados da década de 80, impulsionado pelo surgimento dos computadores pessoais e softwares aplicativos específicos. O objetivo está em eleger-se um modelo matemático, pela Inferência Estatística, que melhor represente o mercado imobiliário, considerando toda sua complexibilidade. Assim, tal ferramental, aplicado em sólida teoria estatística, tem hoje emprego obrigatório na busca de um maior grau de precisão na determinação do valor do Bem Avaliando.

Paralelamente, o crescente desenvolvimento tecnológico vis-à-vis o aumento da capacidade computacional, proporcionou o aparecimento de novas técnicas de modelagem, como por exemplo, modelos baseados em Redes Neurais Artificiais. O uso de sistemas de Redes Neurais Artificiais tem sido objetivo de pesquisa em várias áreas do conhecimento, tais como: controle de processos, predição de séries temporais, otimização, problemas de classificação e processamento de imagens e sinais.

O presente trabalho tem por objetivo realizar estudo comparativo do uso de RNA na avaliação patrimonial de 28 casos, cujos valores de avaliação foram obtidos através da Inferência Estatística, e cuja característica marcante é a de que as amostragens, para cada caso, não foram superiores a 15 amostras.

## **2 - Redes Neurais Artificiais**

A partir do desenvolvimento, em razão geométrica, da tecnologia da informação, a comunidade científica vem sendo estimulada a desenvolver o uso das máquinas - computadores - no desempenho de atividades de processamento de informações de maneira mais próxima ao processamento das informações pelo cérebro humano, o que difere bastante do uso do computador digital, dito convencional. A base de tal processamento - complexo, não-linear e paralelo - está na aquisição de conhecimento mediante um processo de aprendizagem, seguido de processos de tomadas de decisão com base no conhecimento adquirido. A computação tradicional, de característica procedural, mostra-se insuficiente para a solução de problemas com as características acima mencionadas. Dessa forma, as Redes Neurais Artificiais - RNA - surgem como área de conhecimento cujo objetivo está no desenvolvimento de uma forma de computação através de sistemas que, em algum nível, se aproximam da estrutura do cérebro humano.

Os primeiros trabalhos sobre o assunto datam de meados dos anos 40 e início dos anos 50 do século passado. Nos anos 70 a abordagem de RNA's, sofreu um adormecimento, retomando-se o interesse pela área a partir de meados da década de 80.

Em uma rede neural, os neurônios podem estar estruturados de diferentes formas, constituindo-se assim arquiteturas diferentes. Em geral, pode-se identificar três classes de arquiteturas de rede essencialmente diferentes:

### **2.1 - Redes Alimentadas Adiante com Múltiplas Camadas**

Esta arquitetura, representada na figura 1, se caracteriza pela presença de camadas de neurônios ocultos entre as camadas de entrada e saída da rede. A função destas camadas

ocultas é de aumentar a capacidade da rede de extrair informações estatísticas a partir da massa de entrada. Tal habilidade é particularmente valiosa quando a camada de entrada tem grande tamanho.

A camada de entrada fornece informações à primeira camada oculta, cujos sinais de saída servirão de entrada à segunda camada, e assim por diante. Os sinais de saída dos neurônios da última camada constituem-se na resposta global da rede para o padrão de entrada fornecido.

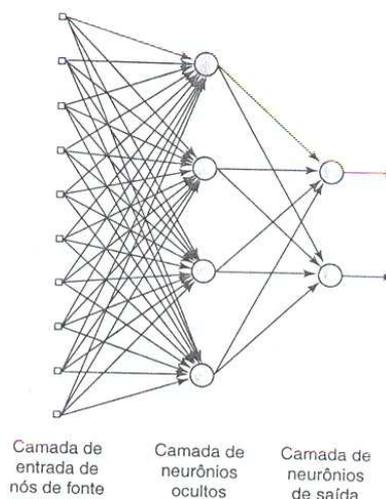


Figura 1

## 2.2. - PROCESSOS DE APRENDIZAGEM

Uma característica importante das redes neurais está na sua capacidade de aprender a partir de seu ambiente, por meio de exemplos, e com isso realizar interpolações. Uma rede neural aprende acerca de seu ambiente através de um processo iterativo de ajustes a seus pesos sinápticos. No contexto de rede neurais, pode-se definir aprendizagem como :

*Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação do ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre.*[6]

### 2.2.1 Aprendizado Supervisionado

É o método de treinamento de redes neurais mais comum. Neste método a entrada e saída desejada são fornecidas por um supervisor ( professor ) externo. O objetivo do treinamento é ajustar os pesos sinápticos, de forma a aproximar o máximo possível a resposta dada pela rede da resposta desejada, fornecida inicialmente. Assim, a resposta da rede é comparada com a resposta desejada, gerando-se um sinal de erro função da diferença entre elas. O algoritmo de treinamento da rede é uma ferramenta matemática derivada de técnicas de otimização, no caso

minimização do erro. Um dos algoritmos mais utilizados no aprendizado supervisionado é o de retropropagação ou “backpropagation”. A figura 2 ilustra o mecanismo do aprendizado supervisionado. O processo de ajustes dos pesos é feito pela correção dos erros, buscando-se minimizar a diferença entre a soma ponderada das entradas pelos pesos - correspondente à saída da rede - e a saída desejada. Fazendo-se:

$$e(t) = d(t) - y(t) \quad \text{onde:}$$

$e(t)$  - Erro no instante  $t$ , a ser minimizado.

$d(t)$  - Saída desejada no instante  $t$ .

$y(t)$  - Saída calculada no instante  $t$ .

Tem-se a forma genérica para alteração dos pesos por correção de erros :

$w_i(t+1) = w_i + \eta e(t)x_i(t)$ , onde  $\eta$  é a taxa de aprendizado e  $x_i(t)$  é a entrada para o neurônio  $i$  no tempo  $t$ .

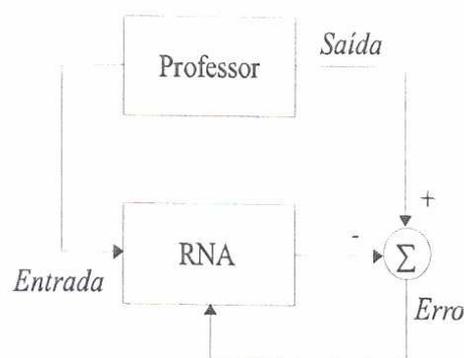


Figura 2

O treinamento de uma RNA através do algoritmo backpropagation ocorre em duas fases:

Fase forward - utilizada a saída da Rede para um dado padrão de entrada

Fase backward - utiliza a saída desejada e a saída fornecida pela rede para o ajuste dos pesos das conexões.

O objetivo do processo de aprendizagem é ajustar os parâmetros livres da rede para minimizar uma função de erro ou energia, definida pela forma dos erros quadráticos, representada por:

$$E = \frac{1}{2} \sum_p \sum_{i=1}^K (d_i(p) - Y_i(p))^2$$

Equação 01

Onde:

E - medida de erro total

$p$  - número de padrões de entrada

K - número de unidades de saída

$d_i$  - i-ésima saída desejada

$Y_i$  - i-ésima saída gerada pela rede

Estudos desenvolvidos indicam que, em uma Rede Neural Artificial de múltiplas camadas tem-se:

- Uma camada intermediária é suficiente para aproximar qualquer função contínua
- Duas camadas intermediárias são suficientes para aproximar qualquer função matemática

### 3 - Análise de Regressão Múltipla

Em Engenharia de Avaliações ficou consagrado o uso da Análise de Regressão Múltipla para estimação - predição - do valor do Bem Avaliando.

Modelos de regressão linear múltipla envolvem três ou mais variáveis, onde uma delas é chamada de variável dependente e as demais são chamadas de variáveis independentes.

O objetivo está em obter-se uma equação do modelo que relacione o valor da variável dependente  $y$ , com todas as demais variáveis independentes  $x_i$ . A equação de regressão tem a forma geral:

$$y = a + b_1x_1 + b_2x_2 + \dots + b_kx_k$$

Equação 02

onde:

$Y$  - Variável dependente

$X$  - Variáveis independentes

$a$  - Intercepto -  $Y$

$b_1$  - Coeficientes angulares

$k$  - Número de variáveis independentes

Aplicando o modelo para estimativa do valor médio de mercado tem-se:

$$\hat{y} = a + b_1x_1 + b_2x_2 + \dots + b_kx_k$$

Equação 03

Em que os parâmetros  $a, b_1, \dots, b_k$  são obtidos pela aplicação do método dos mínimos quadrados, que consiste em encontrar tais parâmetros de tal forma que o somatório dos quadrados das distâncias, medidas na vertical, entre cada ponto observado e ajustado pela curva de regressão, seja mínima. [3]

Dentre um conjunto de características que um modelo de regressão deve atender, tais como: normalidade, não auto-correlação e homocedasticidade dos resíduos, não existir nenhuma relação linear exata entre quaisquer variáveis independentes; tem-se o poder de explicação do modelo como uma característica que indica a aderência do mesmo à realidade - mercado imobiliário - que se deseja representar.

O coeficiente de determinação múltipla indica o grau de aderência do modelo, e é obtido pela razão entre a variação explicada e a variação total do modelo e é representado por:

$$R^2 = \frac{\text{VariaçãoExplicada}}{\text{VariaçãoTotal}}$$

$$R^2 = \frac{\text{VariaçãoTotal} - \text{VariaçãoNão - Explicada}}{\text{VariaçãoTotal}}$$

$$R^2 = 1 - \frac{\sum \left( Y_i - \hat{Y} \right)^2}{\sum \left( Y_i - \bar{Y} \right)^2}$$

Equação 04

#### 4 - Metodologia Adotada

Para o presente estudo foram selecionadas 28 avaliações em que se utilizou a Análise de Regressão Múltipla para estimação do valor do Bem, com o uso do software Infer Versão 3. Tais modelos foram considerados como referência para a comparação com modelos análogos obtidos através de Redes Neurais Artificiais, com o uso do Software EaSyNN8.01; calculando-se assim, a diferença percentual entre os valores obtidos com o uso de Redes Neurais e os respectivos valores obtidos com a Análise de Regressão Múltipla.

O número de amostras para cada um dos 28 casos estudados variou entre 7 e 14, e o número de variáveis independentes variou entre 2 e 4, e foram adotados os seguintes atributos para tais variáveis:

Área  
 Localização  
 Idade  
 Vaga de Garagem  
 Dependência de Empregada  
 Padrão Construtivo  
 Infra-Estrutura de Lazer  
 Estado de Conservação  
 Concepção Arquitetônica  
 Vocação de Uso  
 Número de Unidades por Andar  
 Vista para o Mar  
 Testada  
 Topografia  
 Intensidade de Tráfego

Tais variáveis foram do tipo contínuo, proxy ou dicotômicas, e para a variável dependente foram utilizados valores unitários em 27 modelos e valor total em 1 modelo.

Os modelos de Redes Neurais Artificiais utilizados são do tipo Multicamadas Alimentadas Adiante, usando-se o algoritmo “backpropagation” para treinamento da Rede. A camada de entrada é constituída dos atributos correspondentes às variáveis independentes dos respectivos modelos de regressão. A camada de saída está constituída de apenas um neurônio que corresponde ao valor predito - variável dependente dos respectivos modelos de Regressão. Todas as RNA’s estavam constituídas de apenas uma camada oculta com o número de neurônios variando entre o mínimo de 3 e o máximo de 6.

## 5 - Resultados Obtidos

A tabela 1 e a figura 3, indicam os resultados obtidos para os 28 casos estudados. Da análise desses resultados observa-se que 20 casos apresentaram diferenças inferiores a 10%, em valores absolutos; 4 casos apresentaram diferenças, em valores absolutos, entre 10% e 15% e os casos restantes apresentaram diferenças entre 15% e 26,37%, também em valores absolutos.

Tabela 1

Referência	Nº de	Nº Variáveis	Regressão	Rede	Diferença %
	Amostras	Independentes		Neural	
Lau016.03	12	4	5.394,44	5.401,19	0,13%
Lau006.03	10	3	6.415,38	6.453,76	0,60%
Lau033.02	8	2	13.500,00	13.407,00	-0,69%
Lau022.03	11	3	2.044,50	2.028,71	-0,77%
Lau008.03	13	3	2.170,43	2.150,63	-0,91%
Lau003.01	13	3	645,39	651,74	0,98%
Lau024.03	11	3	1.182,59	1.167,10	-1,31%
Lau010.03	14	3	1.291,13	1.264,10	-2,09%
Lau012.03	12	4	5.600,23	5.479,36	-2,16%
Lau015.01	10	3	2.015,39	1.968,65	-2,32%
Lau010.01	7	3	375,13	388,03	3,44%
Lau007.03	8	3	2.822,58	2.967,08	5,12%
Lau017.03	11	3	162,89	172,10	5,65%
Lau042.02	9	2	57,48	54,21	-5,69%
Lau021.03	10	3	2.079,73	1.960,61	-5,73%
Lau014.03	8	3	2.909,84	2.741,96	-5,77%
Lau009.01	8	3	224,35	237,76	5,98%
Lau027.03	8	3	2.188,60	2.349,41	7,35%
Lau038.02	13	3	58,92	54,43	-7,62%
Lau018.03	11	3	1.971,96	1.791,50	-9,15%
Lau037.02	11	4	991,86	1.094,33	10,33%
Lau029.03	13	4	139,10	122,02	-12,28%
Lau031.02	12	4	2.315,12	2.003,52	-13,46%
Lau003.03	9	2	28,76	24,57	-14,57%
Lau006.01	10	3	6,27	7,27	15,95%
Lau032.02	12	4	2.871,50	3.359,37	16,99%
Lau004.01	9	3	654.190,96	490.006,66	-25,10%
Lau013.03	10	3	5.678,71	7.176,09	26,37%

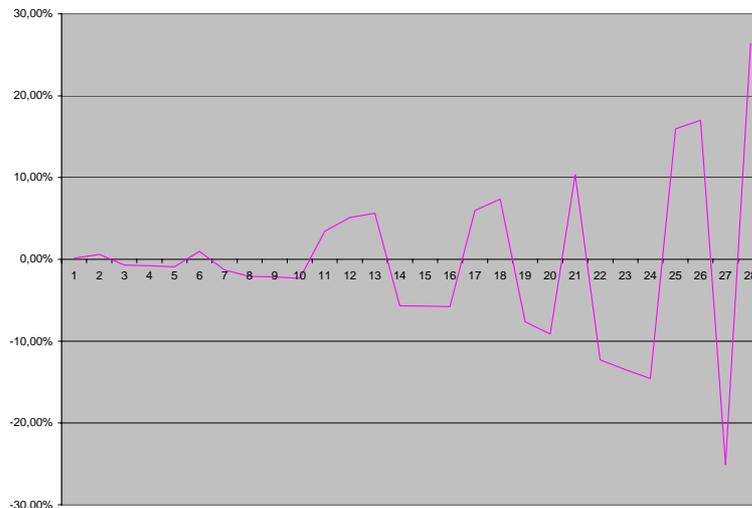


Figura 3

Para os 2 casos que apresentaram diferenças mais discrepantes -25,10% e 26,37% foram calculados os coeficientes de determinação para ambos os modelos, como forma de aferir os respectivos graus de aderência. Os valores obtidos estão indicados na tabela 2.

Tabela 2

CASO	Diferença (%)	Coeficiente de Determinação	
		Regressão	RNA
Lau004.01	-25,10	0,8800	0,965799
Lau013.03	26,37	0,9513	0,966805

## 6 - Conclusão

Pelos resultados obtidos no presente estudo, verificou-se que o uso de Redes Neurais Artificiais, para o caso de pequenas amostragens, apresenta um desempenho muito bom comparado com os respectivos modelos de Regressão Linear Múltipla, tendo a maioria dos casos apresentado diferenças pequenas entre os valores preditos pelos modelos em comparação.

Nos dois casos em que ocorreram diferenças mais discrepantes, os modelos obtidos com RNA apresentaram um grau de aderência superior ao respectivo modelo obtido pela Análise de Regressão Múltipla.

Modelos de RNA's apresentam como principais vantagens a independência de outros parâmetros, além dos dados de entrada, para validação do Resultado; e elevado grau de aderência, uma vez que o algoritmo de treinamento está baseado na minimização do erro quadrático médio que implica minimizar a variação não-explicada, elevando o poder de explicação do modelo. A principal desvantagem está em se apresentar como modelo do tipo "Caixa-preta", sem uma representação matemática não complexa.

Assim, pelo presente estudo, conclui-se que modelos de Redes Neurais Artificiais constituem-se ferramentas com bom desempenho na Engenharia de Avaliação, apresentando-se como uma técnica complementar à Análise de Regressão Múltipla.

## 7 – Bibliografia

- [1] AZEVEDO, F., M., BRASIL, L., M., OLIVEIRA, R.,C.,L., *Redes Neurais com Aplicações em Controle e em Sistemas Especialistas*, 1ª Edição, Florianópolis, Bookstore, 2000.
- [2] BRAGA, A. , P., CARVALHO, A. , C., P., L. F., LUDEMIR, T., B., *Redes Neurais Artificiais Teoria e Prática*, 1ª Edição, Rio de Janeiro, LTC Editora, 2000.
- [3] DANTAS, R., A., *Engenharia de Avaliações – Uma Introdução à Metodologia Científica*, 1ª Edição, São Paulo, Pini, 1998.
- [4] FAUSETT, L., V., *Fundamentals of Neural Network : architectures, algorithms, and application*, 1ª Edição, New Jersey, Prentice Hall, 1994.
- [5] GONZÁLEZ, M., A., S., *Planta de Valores Utilizando Inteligência Artificial*, COBRAC 2000, Congresso Brasileiro de Cadastro Técnico Multifinalitário, UFSC Florianópolis, 2000.
- [6] HAYKIN, S., *Redes Neurais Princípios e Prática*, 2ª Edição, Porto Alegre, Bookman, 2001.
- [7] STEVENSON, W., J., *Estatística Aplicada à Administração*, 1ª Edição, São Paulo, Harper & Row do Brasil, 1981.
- [8] PUPPIO, R., P., *Redes Neurales Aplicadas al Avalúo Inmobiliario*, SOITAVE, Sociedad de Ingeniería de Tasación de Venezuela, [www.precisão.eng.br/jornal/redes.htm](http://www.precisão.eng.br/jornal/redes.htm).

## **Eliane Hasselmann Camardella Schiavo**

### ***Formação***

- ❖ **Graduação em Engenharia Civil**
- ❖ **Pós-graduação em Engenharia de Segurança do Trabalho**
- ❖ **Pós-graduação em Engenharia - Econômica**
- ❖ **Professora de cursos de Avaliação Imobiliária**
- ❖ **Mestranda em Tecnologia pelo CEFET**

### ***Experiência***

- ❖ 24 anos de vivência em análise de investimentos de empresas de médio e grande porte.
- ❖ Analista de projetos Econômico-Financeiros, visando a solicitação de financiamentos junto a órgãos gestores federais.
- ❖ Grande experiência na elaboração de estudos de mercado, orçamentos, cronogramas físico-financeiros e análise de custos industriais.
- ❖ Domínio da técnica de avaliação de imóveis (shopping-centers, imóveis residenciais, comerciais, industriais e rurais), máquinas e equipamentos, hotéis, supermercados e bens móveis (plataformas “off-shore”), para fins de investimentos, seguros e garantias de operações de financiamento e de risco, desde 1979.
- ❖ Experiência em ministrar cursos de treinamento de avaliação de bens para prefeituras de diversos estados, órgãos públicos e universidades.
- ❖ Prática na realização de Perícias Judiciais.

### ***Atuação***

- ❖ **Diretora da Câmara de Consultores Associados S/C Ltda**
- ❖ **1º lugar no concurso público de Engenharia de Avaliações, realizado na Telerj.**
- ❖ **Professora de Avaliação Imobiliária do IBAM**
- ❖ **Consultora de empresas.**
- ❖ **Analista de empresas em Banco de Desenvolvimento e Agência Estadual.**
- ❖ **Conselheira do Instituto de Engenharia Legal – IEL e do Clube de Engenharia**
- ❖ **Conselheira da FEBRAE, representando o IBAPE - Instituto Brasileiro de Avaliações e Perícias de Engenharia.**
- ❖ **Consultora e Instrutora do SEBRAE**

## ***Formação***

- ❖ **Graduação em Engenharia Civil - Universidade Gama Filho - 1976;**
- ❖ **Pós-Graduação em Análise e Projeto de Sistemas - IBAM - 1988;**
- ❖ **Mestrando em Tecnologia pelo CEFET.**

## ***Experiência***

- ❖ 25 anos de experiência em Engenharia de Avaliações. Com participação em avaliações de imóveis de toda natureza, destacando-se: Shopping-Centers, Complexos Industriais, Complexos Turísticos, Glebas Urbanizáveis, Estaleiros, Supermercados e Imóveis comerciais e residenciais;
- ❖ 12 anos de experiência em Desenvolvimento de Sistemas;
- ❖ 14 anos de experiência Docente;
- ❖ Implantação de Programa de Gestão pela Qualidade Total;
- ❖ Desenvolvimento de rotinas de consolidação de informações gerenciais;
- ❖ Desenvolvimento e implantação de rotinas de automação de processos administrativos;
- ❖ Estudo de viabilidade de projetos de investimento;
- ❖ Docência das disciplinas: Introdução à Informática, Lógica de Programação, Programação estruturada, Pascal, Delphi, Visual Basic, VBScript e Tecnologia ASP;
- ❖ Coordenação Técnica de desenvolvimento e implantação de sistemas comerciais e de automação bancária;
- ❖ Coordenação Técnica de desenvolvimento e implantação de aplicação de comércio eletrônico - Livraria Virtual;
- ❖ Experiência com as Linguagens: Delphi, Visual Basic, Pascal, C, Clipper, Javascript, VBScript e HTML;
- ❖ Conhecimento das Tecnologias CGI e ASP;
- ❖ Banco de Dados: SQL Server e Oracle;

## ***Atuação***

- ❖ **Diretor da Câmara de Consultores Associados S/C Ltda**
- ❖ **Professor Auxiliar da Universidade Estácio de Sá**
- ❖ **Consultor de empresas**