

# REDES NEURAIS ARTIFICIAIS PARA ESTIMATIVA DE CUSTOS DE CONSTRUÇÃO CIVIL

## **Luiz Biondi Neto**

Universidade do Estado do Rio de Janeiro  
Rua São Francisco Xavier 524 - Sala A-5036, Maracanã, 20550-900, Rio de Janeiro, RJ  
lbiondi@uerj.br

## **Eliane Gonçalves Gomes**

Embrapa Monitoramento por Satélite  
Av. Dr. Júlio Soares de Arruda 803, Parque São Quirino, 13088-300, Campinas, SP  
eliane@cnpm.embrapa.br

## **João Carlos Correia Baptista Soares de Mello**

Universidade Federal Fluminense  
Rua Passo da Pátria 156, São Domingos, 24210-240, Niterói, RJ  
jcsmello@producao.uff.br

## **Lidia Angulo Meza**

Universidade Veiga de Almeida  
Rua Ibituruna, 108, 4º andar, Maracanã, 20271-020, Rio de Janeiro, RJ, Brazil  
lidia@lab.uva.br

### **Resumo**

O custo de uma unidade imobiliária é um parâmetro importante para que agentes financiadores estimem o preço de venda e o valor do financiamento. O valor de venda da unidade a ser financiada é obtido através de tabelas que relacionam o custo unitário à tipologia do imóvel (área construída, número de cômodos ou compartimentos, acabamento etc.). Devido à enorme diversidade de tipologias não existem tabelas completas de custos dos projetos imobiliários. Métodos e técnicas convencionais de geração de valores de custo unitário desconhecidos podem gerar erros no valor final do preço de venda, pois tratam linearmente dados com comportamento não linear. Este artigo propõe o uso de uma Rede Neural Artificial (RNA) na determinação dos valores de custo/m<sup>2</sup> desconhecidos de tipologias imobiliárias para o estado do Rio de Janeiro. A RNA é treinada mapeando-se a tipologia de cada imóvel com os respectivos custos conhecidos. Na fase de execução, a RNA recebe uma massa de teste que não fez parte do treinamento e indica o valor dos custos dos projetos imobiliários de interesse. Os resultados obtidos pela RNA mostram-se vantajosos em relação às técnicas de uso corrente.

**Palavras-Chaves:** Valores ausentes; Redes neurais artificiais; MACBETH.

### **Abstract**

In order to have appropriated financing value estimation for buildings, the building cost and the actual sales prices are needed. The sales value of the unit to be financed is obtained through tables that relate the unitary cost to the typology of the property (built area, number of floors, pattern etc.). Due to the great typology diversity, full tables of the real property costs do not exist. Conventional methods and techniques of generating the non-observed unitary cost values (\$/m<sup>2</sup>) treat non-linear data as they had lineal behaviour. This could generate errors in the final sales price. In this work we use an Artificial Neural Network (ANN) in the non-observed real property \$/m<sup>2</sup> determination. The ANN generalisation capacity is explored and it is trained with the characteristics of each real property and the

respective known cost. In the execution phase, the ANN receives a test set, which was not used in the previous phase, indicating with accuracy the real property cost values. The results obtained by ANN when compared with traditional processes indicate that the use of an ANN brings advantages in comparison with the classic techniques.

**Keywords:** Missing values; Artificial neural networks; MACBETH.

## 1. INTRODUÇÃO

O custo por unidade de área (R\$/m<sup>2</sup>) de um projeto imobiliário é um parâmetro importante para a estimativa dos preços de venda dos imóveis, e serve como parâmetro para que as agências de crédito estimem o valor a ser financiado. No cálculo dos custos unitários são consideradas várias características arquitetônicas, dentre elas o número de cômodos e os padrões de acabamento.

Na década de 60 foi criado o Sistema Nacional de Pesquisa de Custos e Índices da Construção Civil (SINAPI), com o objetivo fornecer um conjunto de informações mensais sobre custos da construção civil e índices de evolução desses custos. A disponibilização dessas informações é feita pelo Instituto Brasileiro de Geografia e Estatística (IBGE).

Devido à enorme diversidade de tipologias possíveis de serem encontradas não existe uma tabela completa de custo/m<sup>2</sup> de todos os projetos imobiliários possíveis de serem negociados. Além disso, devido à não linearidade dos dados, os métodos tradicionais baseados na linearidade não se mostram adequados.

Este artigo propõe um método para determinar os valores de custo/m<sup>2</sup> das tipologias não tabeladas. Para tal é usada uma Rede Neural Artificial (RNA) que é treinada fornecendo-se os dados das tipologias conhecidas. Na fase de execução a RNA usa a capacidade de generalização para estimar os custos desconhecidos.

Os resultados foram validados a partir de informações da venda de três imóveis de custos não observados, obtidas através de um agente financiador e, portanto, com o preço de financiamento regulado pelo mercado, na mesma localidade geográfica. A técnica mostra-se mais adequada que os processos tradicionais.

## 2. BASE DE DADOS UTILIZADA

Para este estudo foram considerados os projetos do tipo PR<sub>x</sub>-yQT...z (projetos de prédios residenciais com *x* pavimentos, *y* quartos e *z* m<sup>2</sup> de área) para o Estado do Rio de Janeiro. Usou-se uma base de dados disponível no IBGE, válida para o mês de setembro de 2000. Os dados são apresentados na Tabela 1.

Cada projeto é identificado por um conjunto de variáveis, a saber, quantidade de pavimentos (PAV), se é térreo (TER) ou pilotis (PIL), número de salas (SALA), número de quartos (QUAR), número de banheiros (BANH), número de lavabos (LAV), se existe ou não circulação (CIRC), copa (COPA), cozinha (COZ), área de serviço (SERV), dependências de empregada (QWCE), padrão de acabamento (alto, normal, baixo e mínimo).

## 3. REDES NEURAIS ARTIFICIAIS

Para estimar os custos unitários desconhecidos foi modelada uma Rede Neural Artificial (RNA), treinada com os valores disponíveis e testada com as tipologias para as quais os valores de custo/m<sup>2</sup> não são conhecidos.

As RNAs são capazes de adquirir conhecimento e generaliza-lo, adaptando-se a situações que não fizeram parte do conjunto de treinamento. O conhecimento é adquirido com a apresentação de exemplos básicos em seu treinamento (Biondi, 2001).

Uma RNA é composta por unidades processadoras básicas interligadas, dispostas em camadas. Cada camada pode conter diversos elementos processadores (neurônios artificiais). A conexão entre as unidades processadoras é feita através do peso sináptico, que define a

influência entre as unidades processadoras interligadas. Os pesos são determinados durante o treinamento.

Tabela 1 - Extrato de custos dos projetos de prédios residenciais (Estado do Rio de Janeiro, setembro de 2000).

Descrição do projeto	Padrão de acabamento	Custo (R\$/m <sup>2</sup> )
PR5-2QT...2125 Prédio residencial, térreo, 5 pavimentos tipo, sala, 2 quartos, banheiro, cozinha e área de serviço	Alto	Desconhecido
PR5-2QT...2125 Prédio residencial, térreo, 5 pavimentos tipo, sala, 2 quartos, banheiro, cozinha e área de serviço	Normal	295,21
PR5-2QT...2125 Prédio residencial, térreo, 5 pavimentos tipo, sala, 2 quartos, banheiro, cozinha e área de serviço	Baixo	229,54
PR5-2QT...2125 Prédio residencial, térreo, 5 pavimentos tipo, sala, 2 quartos, banheiro, cozinha e área de serviço	Mínimo	197,25
...	...	...
PR4-3QP...2520 Prédio residencial, pilotis, 4 pavimentos tipo, sala, 3 quartos, circulação, banheiro, lavabo, cozinha, área de serviço, quarto e WC de empregada	Alto	361,13
PR4-3QP...2520 Prédio residencial, pilotis, 4 pavimentos tipo, sala, 3 quartos, circulação, banheiro, lavabo, cozinha, área de serviço, quarto e WC de empregada	Normal	312,31
PR4-3QP...2520 Prédio residencial, pilotis, 4 pavimentos tipo, sala, 3 quartos, circulação, banheiro, lavabo, cozinha, área de serviço, quarto e WC de empregada	Baixo	251,44
PR4-3QP...2520 Prédio residencial, pilotis, 4 pavimentos tipo, sala, 3 quartos, circulação, banheiro, lavabo, cozinha, área de serviço, quarto e WC de empregada	Mínimo	Desconhecido
...	...	...
PR12-2QP..3597 Prédio residencial, pilotis, 12 pavimentos tipo, sala, 2 quartos, circulação, banheiro, cozinha, área de serviço, quarto e WC de empregada	Normal	366,35
PR12-2QP..3597 Prédio residencial, pilotis, 12 pavimentos tipo, sala, 2 quartos, circulação, banheiro, cozinha, área de serviço, quarto e WC de empregada	Baixo	Desconhecido
PR12-2QP..3597 Prédio residencial, pilotis, 12 pavimentos tipo, sala, 2 quartos, circulação, banheiro, cozinha, área de serviço, quarto e WC de empregada	Mínimo	Desconhecido

Cada unidade processadora executa uma operação simples sobre a informação recebida da entrada ou de outro processador. O resultado é então transmitido para outros processadores que, por sua vez, repetem a operação. O processo de atualização dinâmica dos pesos é feito paralelamente e distribuído por toda a rede. Quando as saídas diferem dos alvos (que neste caso são os custos/m<sup>2</sup> disponíveis dos imóveis) por um valor inferior à tolerância de erro, está concluído o processo de aprendizagem. Nesse ponto pode-se dizer que a rede está devidamente treinada e a matriz de pesos, que será usada na fase de execução, retém o conhecimento que a rede foi capaz de absorver durante a fase de aprendizado (Biondi, 2001).

A Figura 1 mostra a arquitetura de uma rede neural genérica com uma camada, onde  $p_{1,2,3,\dots,R}$  representam os elementos do vetor de treinamento  $P$  da rede. O bloco somatório realiza a soma ponderada dos pesos  $W_{ij}$  com as entradas  $p_{1,2,3,\dots,R}$ , normalmente conhecida sob a forma matricial como  $NET = W \cdot P$ . A saída  $a = F(NET)$  é o resultado da aplicação da soma ponderada  $NET$  na função de ativação  $F$ , que pode ser linear ou não (Biondi, 2001).




Figura 1 - Arquitetura genérica de uma RNA.

A regra de Widrow-Hoff (Haykin, 1994) é a base fundamental dos diversos métodos de treinamento das RNAs. Ela avalia o erro médio quadrático a cada iteração através da derivada parcial do erro quadrático em relação ao peso  $W$  e ao limiar  $b$  (bias), mostrados na Figura 1. Sabendo-se que  $t$  representa o vetor alvo a ser atingido no treinamento,  $p$  representa o vetor de treinamento apresentado à rede,  $R$  representa o número de elementos do vetor de treinamento, e analisando-se o neurônio  $j$  na  $n$ -ésima iteração, para  $j = 1, \dots, R$ , têm-se as

relações apresentadas em (1), onde  $Wp^{(n)} = \sum_{j=1}^R W_{1j} P_j^{(n)}$ ;  $\frac{\partial e^{(n)}}{\partial W_{1j}} = -P_j^{(n)}$ ;  $\frac{\partial e^{(n)}}{\partial b} = -1$ .

$$\begin{aligned} \frac{\partial e^{2(n)}}{\partial W_{1j}} &= 2e^{(n)} \frac{\partial e^{(n)}}{\partial W_{1j}} \\ \frac{\partial e^{2(n)}}{\partial b} &= 2e^{(n)} \frac{\partial e^{(n)}}{\partial b} \\ \frac{\partial e^{(n)}}{\partial W_{1j}} &= \frac{\partial [t^{(n)} - a^{(n)}]}{\partial W_{1j}} = \frac{\partial}{\partial W_{1j}} [t^{(n)} - (Wp^{(n)} + b)] \end{aligned} \quad (1)$$

É mostrado em (2) a variação  $\Delta W$  do peso e  $\Delta b$  do limiar, bem como o método numérico usado no processo adaptativo de atualização dos parâmetros internos da rede.

$$\begin{aligned} \Delta w^{(n)} &= -2\eta e^{(n)} \frac{\partial e^{(n)}}{\partial W} \\ \Delta b^{(n)} &= -2\eta e^{(n)} \frac{\partial e^{(n)}}{\partial b} \\ W^{(n+1)} &= W^{(n)} + \Delta w^{(n)} = W^{(n)} + 2\eta e^{(n)} P^{(n)} \\ b^{(n+1)} &= b^{(n)} + \Delta b^{(n)} = b^{(n)} + 2\eta e^{(n)} \end{aligned} \quad (2)$$

Em (2), o termo  $\eta$  representa a taxa de aprendizado, que define a velocidade de convergência do método. Assim, se  $\eta$  for muito grande o treinamento é feito muito rapidamente, porém existe a possibilidade de oscilação. Por outro lado, se  $\eta$  for muito pequeno o treinamento é lento e é possível que seja atingido um mínimo local em vez do mínimo absoluto (Biondi, 2001).

Após o treinamento, a rede está pronta para uso. Nessa fase são fornecidos à RNA novos padrões, denominados padrões de teste, e a rede responde de acordo com o que lhe foi imposto durante o treinamento. No presente caso, a rede recebe as tipificações cujos custos são desconhecidos, respondendo com o valor do custo/m<sup>2</sup> do imóvel tipificado.

#### 4. PRÉ-PROCESSAMENTO DOS DADOS

As variáveis quantitativas referem-se aos valores correspondentes ao número de compartimentos de cada tipologia. Para as variáveis do tipo “existe ou não existe”, o valor foi substituído por uma variável binária: 1 para a existência do compartimento, 0 caso contrário.

Para os padrões qualitativos (alto, médio, normal e baixo) foi construída uma escala quantitativa obtida através do julgamento de valor por especialistas sobre as diferenças de atratividade entre eles. Utilizou-se nessa etapa a metodologia MACBETH (Bana e Costa & Vansnick, 1997), que constrói uma escala de valor cardinal sobre o conjunto de alternativas, a partir de juízos pareados das diferenças de atratividade entre elas.

Com o uso da abordagem MACBETH, a escala quantitativa para a variável “padrão de acabamento” é apresentada na Tabela 2.

Tabela 2 - Escala quantitativa para a variável “padrão de acabamento”.

<b>Padrão</b>	<b>Escala quantitativa</b>
Alto	10,00
Normal	6,92
Baixo	3,85
Mínimo	2,31

Foi feita uma análise de correlações, com o objetivo de verificar a existência de variáveis de entrada altamente correlacionadas entre si, e de variáveis de entrada não correlacionadas com o custo/m<sup>2</sup> do imóvel. Foi verificado que as variáveis COZ e SERV apresentam valores iguais a um para todas as tipologias dos projetos e, assim, foram retiradas da análise. As variáveis TER e PIL têm coeficiente de correlação igual a -1 e, assim, a variável TER será descartada. As variáveis CIRC e QWCE têm coeficiente de correlação igual a 1 e uma delas poderia ser descartada. Entretanto, ambas foram mantidas já que é possível que seja incluída futuramente uma tipologia que, por exemplo, apresente circulação e não tenha dependências de empregadas. Todas as variáveis restantes correlacionam-se com o alvo custo/m<sup>2</sup> do imóvel.

Como existe uma grande quantidade de variáveis binárias, a função de ativação usada na RNA é do tipo *logsig*, função não linear com derivadas em todo o domínio e que varia entre zero e um. A função *logsig* é apresentada em (3), onde  $\lambda$  é um escalar positivo que representa a inclinação da função. Para seu uso correto, as variáveis que não são binárias devem ser normalizadas.

$$F(NET) = \frac{1}{1 + \exp(-\lambda NET)} \quad (3)$$

A Tabela 3 apresenta um extrato dos dados “tratados” e prontos para serem usados no processamento neural, com tipologias identificadas por números (de 1 a 52). Nessa tabela, os valores encontram-se normalizados. Pode-se verificar que para algumas tipologias de projetos não há valor de custo/m<sup>2</sup> calculado, que será estimado pela abordagem aqui proposta.

#### 5. PRÉ-PROCESSAMENTO DOS DADOS

O modelo da RNA adotado para o caso investigado é representado pela Figura 2. A RNA recebe como entradas as variáveis PAV, PIL, SAL, QUA, BANH, LAB, CIRC, COPA, QWCE e PADRÃO. Na fase de treinamento, com os 31 padrões conhecidos é fornecido igualmente o custo unitário de cada tipologia. Na fase de execução essa variável será calculada pela RNA.

Tabela 3 - Dados tratados para o processamento neural.

Projeto	PAV	PIL	SALA	QUAR	BANH	LAV	CIRC	COPA	QWCE	Padrão	Custo (R\$/m <sup>2</sup> )
1	0,278	0,000	0,500	0,500	0,500	0,000	0,000	0,000	0,000	1,000	Não Observado
2	0,278	0,000	0,500	0,500	0,500	0,000	0,000	0,000	0,000	0,692	0,682
3	0,278	0,000	0,500	0,500	0,500	0,000	0,000	0,000	0,000	0,385	0,530
.....											
10	0,222	0,000	0,500	0,750	0,500	1,000	1,000	0,000	1,000	0,692	0,787
11	0,222	0,000	0,500	0,750	0,500	1,000	1,000	0,000	1,000	0,385	0,630
12	0,222	0,000	0,500	0,750	0,500	1,000	1,000	0,000	1,000	0,231	Não Observado
13	0,222	1,000	0,500	0,500	0,500	0,000	1,000	0,000	1,000	1,000	0,901
.....											
49	1,000	1,000	0,500	1,000	1,000	1,000	1,000	1,000	1,000	1,000	0,789
50	1,000	1,000	0,500	1,000	1,000	1,000	1,000	1,000	1,000	0,692	0,686
51	1,000	1,000	0,500	1,000	1,000	1,000	1,000	1,000	1,000	0,385	Não Observado
52	1,000	1,000	0,500	1,000	1,000	1,000	1,000	1,000	1,000	0,231	Não Observado

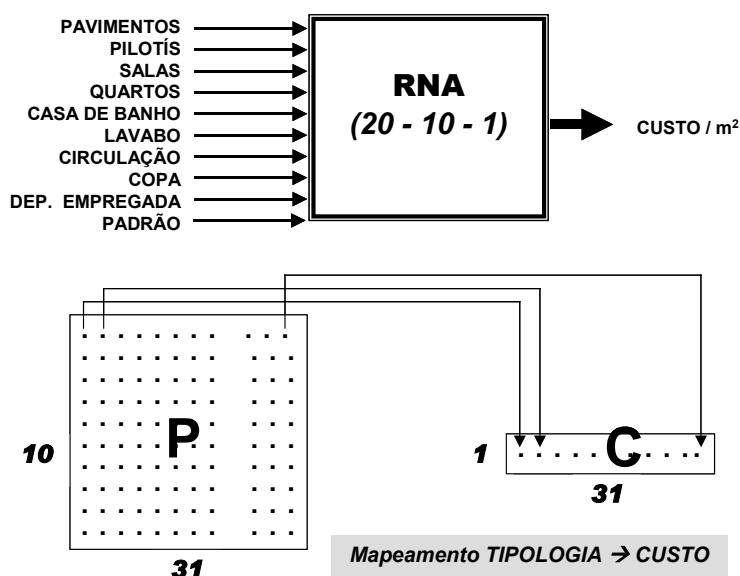


Figura 2 - Esquema da modelagem da RNA para o caso em estudo.

Para alcançar a melhor generalização, diversas configurações foram testadas variando-se a quantidade de camadas intermediárias, bem como o número de neurônios por camada. A que apresentou o melhor desempenho foi a RNA com 20 neurônios na primeira camada intermediária, 10 neurônios na segunda camada intermediária e 1 neurônio na camada de saída. Visando ainda melhorar a generalização, a rede (20-10-1) foi treinada com a adição de ruído durante o treinamento. O treinamento adicionando-se ruído foi feito de forma contínua.

Diversos algoritmos e métodos numéricos foram empregados com vistas a descobrir qual o que melhor se adapta ao processo de atualização dos pesos e limiares (bias) referentes à RNA modelada para resolver este caso. Foram testadas as abordagens de Gradiente Decrescente (Rumelhart et al., 1986), Gradiente conjugado (Bazaraa et al., 1993), Fletcher-Reeves (Bertsekas, 1999), Polak-Ribière (Skapura, 1996), Quasi-Newton (Bazaraa et al., 1993) e Levenberg-Marquardt (Skapura, 1996, Bazaraa et al., 1993).

Aplicando-se estes métodos ao caso em estudo, verifica-se que as variações obtidas não permitem destacar nenhum deles quanto à exactidão dos resultados. Entretanto, quanto à velocidade de convergência o método de Levenberg-Marquardt foi o que apresentou melhores resultados.

Por apresentar boa performance, aliada à facilidade de implementação, foi escolhido o Método do Gradiente Decrescente, com taxa de aprendizado adaptativa, isto é, variação

inversa com a inclinação da curva de custo e coeficiente de momento, que mantém o sistema estável mesmo com elevadas taxas de aprendizado (Zurada, 1992; Haykin, 1994).

## 6. RESULTADOS

Os resultados obtidos pela RNA foram comparados com os resultados obtidos pela aplicação de regressão linear múltipla ao mesmo conjunto de dados para os quais o custo é conhecido. Verificou-se que os resultados obtidos pela RNA estão mais próximos dos custos conhecidos.

A Figura 3 representa a curva de percentagem de erro da RNA e da Regressão em relação ao valor conhecido do custo. Constata-se que enquanto a regressão atinge um erro percentual máximo de cerca de 8%, a RNA não passa de cerca de 1,5%.

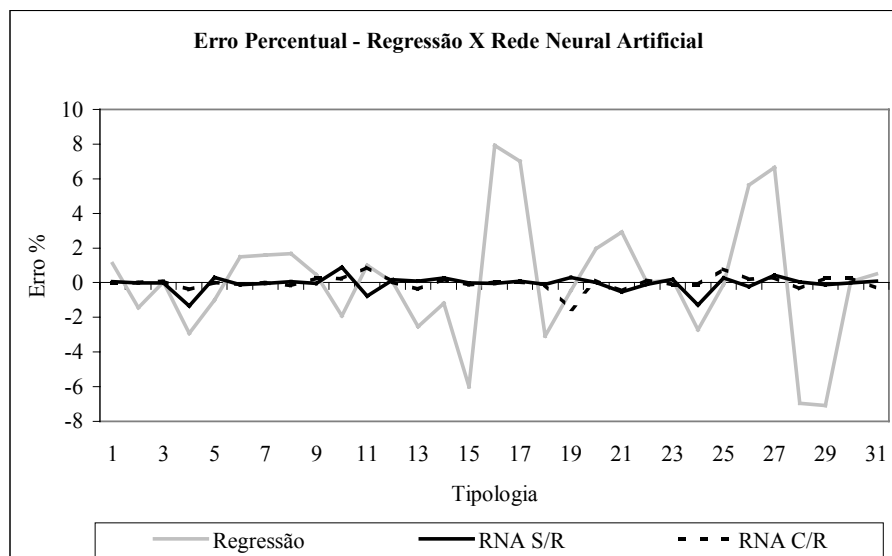


Figura 3 - Erro percentual referente aos resultados da RNA x Regressão.

Foram incorporados às medidas outros dois métodos de preenchimento de valores ausentes. Inicialmente foi utilizada a técnica da média simples, na qual o valor não observado é completado com a média entre o valor anterior e o posterior a ele na distribuição dos dados, quando existir. No caso em estudo tem-se um valor ausente no projeto 1 e que não apresenta valor anterior, e dois valores ausentes referentes aos projectos 51 e 52, que não apresentam valor anterior e são duplos e, conseqüentemente, completados com um mesmo valor. Foram usados para completar estes valores ausentes o valor anterior ou o valor posterior, repetido ou não, dependendo da multiplicidade da ausência.

A segunda técnica empregada foi o preenchimento dos valores não observado com o valor anterior ou posterior a ele na distribuição, quando existir, repetindo ou não o valor adotado em função da multiplicidade da ausência.

Os resultados foram validados a partir de informações da venda de três imóveis, cujas tipologias não têm o custo unitário conhecido e localizados no estado do Rio de Janeiro.

A Tabela 4 mostra o custo/m<sup>2</sup> dos três imóveis negociados e a estimativa desse custo obtida pelos métodos da RNA, Regressão, Média, Repetição de um valor vizinho, e ainda os erros percentuais de cada estimativa. A análise dessa tabela mostra que o erro encontrado usando a estimativa da RNA é inferior ao encontrado pelo uso dos outros métodos.

Tabela 4 - Comparação entre o custo definido pelo mercado e pelas técnicas abordadas.

Projeto	Tipologia	Custo/m <sup>2</sup>					Erro percentual			
		RNA	REG	MED	RU/A	MERC	RNA	REG	MED	RU/A
20	PR4-3QP...2520 Pilotis, 4 pav., sala,	245,94	207,45	279,53	307,62	247,13	-0,48	-16,06	13,11	24,48

	3 quartos, circ., banh., lavabo, cozinha, área de serviço, quarto e WC de emp., padrão mínimo.									
<b>47</b>	<b>PR12-4QP..4050</b> Pilotis, 12 pav., sala, 4 quartos, circ., 2 banh., lavabo, copa- cozinha, área de serviço, quarto e WC de emp., padrão baixo.	278,67	205,89	320,36	341,40	275,32	1,22	-25,22	16,36	24,00
<b>48</b>	<b>PR12-4QP..4050</b> Pilotis, 12 pav., sala, 4 quartos, circ., 2 banh., lavabo, copa- cozinha, área de serviço, quarto e WC de emp., padrão mínimo.	276,87	176,99	320,36	341,40	280,17	-1,18	-36,83	14,35	21,85

## 7. CONCLUSÕES

Os resultados encontrados para os valores Desconhecidos de custo/m<sup>2</sup> dos projetos imobiliários mostram que os erros percentuais médios do custo/m<sup>2</sup> dos projetos obtidos pela RNA são sempre bem menores do que os obtidos por outros processos.

A superioridade dos resultados do custo/m<sup>2</sup> obtidos pela RNA, explica-se pela alta não linearidade do caso estudado. As técnicas estatísticas de uso corrente poderiam fornecer resultados de igual qualidade caso fosse escolhida uma função não linear, que de fato ajustasse-se bem aos dados. O tempo para a pesquisa de tal função seria, certamente, muito superior ao tempo necessário para implementar o algoritmo com RNA.



## 8. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] BANA E COSTA, C.A., VANSNICK, J.C. (1997) - Thoughts on a theoretical framework for measuring attractiveness by categorical based evaluation technique (MACBETH). In: Clímaco, J. (ed.) Multicriteria Analysis. Springer-Verlag. Berlin.
  
- [2] BAZARAA, M.S., SHERALI, H.D., SHETTY, C.M. (1993) - Nonlinear Programming Theory and Algorithms. John Wiley & Sons Inc.. New York.
  
- [3] BERTSEKAS, D.P. (1999) - Nonlinear Programming. Athena Scientific Publisher's. Belmont.
  
- [4] BIONDI, L.N. (2001) - Neuro-DEA: Nova Metodologia para Determinação da Eficiência Relativa de Unidades Tomadoras de Decisão. Tese de Doutorado. Programa de Engenharia de Produção, COPPE/UFRJ. Rio de Janeiro.
  
- [5] HAYKIN, S. (1994) - Neural Networks a Comprehensive Foundation. Macmillan College Publishing Co.. London.
  
- [6] RUMELHART, D.E., HINTON, G.E., WILLIAN, R.J. (1986) - Learning Internal Representation by Error Propagation. In: Rumelhart, D.E., McClelland, J.L. (eds.) Parallel Distributed Processing. MIT Press. Cambridge.
  
- [7] SKAPURA, D.M. (1996) - Building Neural Networks. Addison-Wesley Publishing Company. New York.
  
- [8] ZURADA, J.M. (1992) - Introduction to Artificial Neural Systems. West Publishing Company. London.