

## Planta de Valores Utilizando Inteligência Artificial

Prof. Ms. Marco Aurélio Stumpf González <sup>1</sup>  
 Prof. Dr. Carlos Torres Formoso <sup>2</sup>

<sup>1</sup> Doutorando em Engenharia - NORIE / UFRGS  
 UNISINOS - Engenharia Civil  
 Av. Unisinos, 950  
 CEP 93022-000 - São Leopoldo - RS  
 ✉ gonzalez@euler.unisinos.br

<sup>2</sup> UFRGS / PPGEC / NORIE  
 Av. Osvaldo Aranha, 99/3º  
 Porto Alegre - RS  
 ✉ cformoso@vortex.ufrgs.br

Conteúdo	
	1. Introdução
	2. Redes Neurais Artificiais
	3. Raciocínio Baseado em Casos
	4. Considerações Finais
	5. Referências Bibliográficas

**Resumo :** As técnicas atualmente utilizadas para cálculo de valores dos imóveis, baseadas em critérios subjetivos ou mesmo em inferência estatística, enfrentam problemas referentes à deficiente consideração dos efeitos espaciais e ao desconhecimento da forma funcional, causados pela complexidade do mercado imobiliário. Como as estimativas de valor são empregadas na cobrança do IPTU, atingindo praticamente toda a população, é importante buscar alternativas de cálculo, tendo em vista que o aperfeiçoamento dos métodos implica em aumento da justiça tributária. O artigo apresenta duas técnicas de inteligência artificial, redes neurais e raciocínio baseado em casos, verificando as possibilidades de aplicação delas na determinação de plantas de valores.

**Palavras chave :** Planta de valores, avaliação de imóveis, inteligência artificial

**Abstract :** The real estate appraisal by regression analysis has some problems, like spatial correlation and unknowing functional form, reducing the precision of estimated values. Two artificial intelligence techniques, neural networks and case-based reasoning, are candidates to regression analysis substitution. In this paper, this techniques are presented, with notes of possibilities to real estate appraisal.

**Keywords :** Mass appraisal, real estate appraisal; artificial intelligence

### 1. Introdução

A determinação de valores de imóveis é pode ser realizada através de modelos microeconômicos de preços, conhecidos como modelos hedônicos, com coeficientes estimados por análise de regressão múltipla (ARM). Para tributação, geralmente aplica-se o método do custo de reprodução depreciado. A complexidade do mercado imobiliário, no qual diversas características adquirem importância, reflete-se na consideração de diversas variáveis, na tentativa de medição das influências respectivas, explicando as variações de preços dos imóveis. Muitas vezes existe dificuldade em mensurar as influências espaciais no valor das unidades (o que provoca correlação espacial) e, no caso da inferência, também é problema a forma funcional desconhecida (González, 1997).

As soluções corriqueiras não são eficientes, e são excessivamente dependentes da intervenção de especialistas. Por exemplo, a escolha do formato do modelo é uma questão geralmente resolvida empiricamente, com base na experiência do analista, assim como as tentativas de consideração dos efeitos espaciais através das técnicas convencionais envolvem variáveis proxy ou avaliações subjetivas. Esses aspectos afetam o desenvolvimento de modelos e a precisão das estimativas nas análises microeconômicas. Se o modelo não representa adequadamente o mercado, as previsões (inferências) realizadas não são válidas, ou seja, a qualidade da avaliação está prejudicada, com várias conseqüências, tais como a dificuldade de venda de unidades pelos preços previstos ou injustiças na tributação imobiliária.

A análise de regressão múltipla (ARM) é uma técnica de uso geral e está embasada em sólida teoria estatística, sendo empregada há vários anos na avaliação de imóveis. Mesmo assim, a comunidade científica da área de economia urbana não tem oferecido soluções adequadas para os problemas apontados, que persistem. Assim, há necessidade de buscar outros métodos, mais precisos, para realizar a avaliação de imóveis.

Nos últimos anos, o rápido desenvolvimento da tecnologia permitiu o efetivo emprego de técnicas avançadas, que exigem razoável capacidade de processamento, tais como as técnicas ligadas à Inteligência Artificial, especialmente as redes neurais artificiais (RNA) e o raciocínio baseado em casos (RBC). Aplicações destas técnicas, encontradas na literatura consultada, apresentam indícios de que elas também poderiam ser utilizadas para determinar valores de imóveis. Este artigo apresenta uma introdução a estas técnicas, indicando pesquisas anteriores na área de avaliação de imóveis.

### 2. Redes Neurais Artificiais


As redes neurais artificiais (RNA) são baseadas nos estudos sobre o comportamento do cérebro humano, buscando simular sua forma de processar informações. Não existe uma definição universal para redes neurais artificiais, mas é comum encontrar na

literatura da área a idéia de que uma RNA seria um conjunto de múltiplos processadores (unidades), cada qual tendo uma pequena quantidade de memória, e ligados entre si por canais de comunicação (conectores), que têm a capacidade de transportar dados numéricos, codificados em vários formatos (sinais), à semelhança dos neurônio humanos. As unidades operam apenas seus dados locais e suas entradas ocorrem pelas conexões. Uma das vantagens das RNA sobre as técnicas estatísticas convencionais (como a análise de regressão) é que as redes não exigem conhecimento prévio sobre o formato dos relacionamentos e não há requisitos especiais quanto aos dados (Kauko, 1997; Portugal e Fernandes, 1996; Rumelhart, 1995; Tay e Ho, 1994).

As RNA podem ser entendidas como mecanismos de reconhecimento de padrões, com habilidade de auto-aprendizagem. Neste sentido, atualmente são empregadas em identificação de potencialmente bons (ou maus) clientes, análise de investimentos, reconhecimento de caracteres, de imagens ou de voz, e também em avaliação de imóveis (Rossini, 1997; Tay e Ho, 1994; Worzala *et al.*, 1995).

É mais correto denominá-las de "redes neurais artificiais", para diferenciar das redes biológicas, embora alguns textos referenciem apenas "redes neurais". Nem todas as RNA são modelos de redes neurais biológicas, embora estas sejam a inspiração costumeira, na busca por mecanismos de reprodução do cérebro humano. As RNA também são chamadas de "modelos conexionistas de computação", em função da questão das conexões entre as unidades, que é fundamental no desempenho das redes (Aubin, 1996; Portugal e Fernandes, 1996).


O elemento fundamental nas redes é a unidade, denominada "neurônio artificial", que recebe os sinais provenientes das entradas ou de outras unidades, processa as informações e repassa os resultados às unidades seguintes ou às saídas. Uma unidade pode ser representada esquematicamente da seguinte forma (Figura 1):



**Figura 1** : Representação de uma unidade isolada (neurônio)  
(Adaptada de Portugal e Fernandes, 1996, p.56)

Basicamente, a unidade realiza a função de receber sinais, processá-los, através de uma função de soma S, aplicar uma função de ativação G e enviá-los aos elementos seguintes da rede. A unidade pode ter várias entradas, mas tem apenas um valor de saída, ainda que com múltiplas cópias. A "rede" mais simples é uma conjugação de duas ou mais unidades deste tipo. Havendo diversos neurônios artificiais, as possibilidades de diferentes interligações crescem. Conforme a topologia da rede, podem ser reforçadas determinadas habilidades.

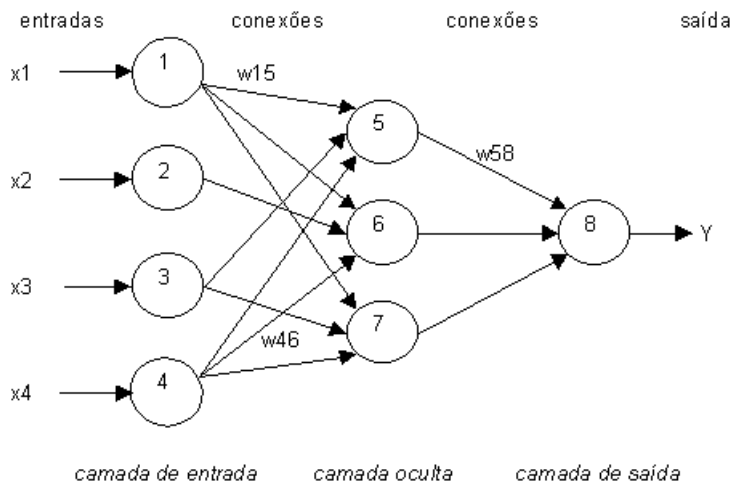
O modelo conhecido como Perceptron foi proposto por Rosenblatt, em 1957. Uma rede neural artificial deste tipo pode ser extremamente complexa, conforme a quantidade de neurônios artificiais que contenha, mas apresenta uma configuração básica que reproduz a estrutura da Figura 2, a seguir. A rede é composta de uma camada de entrada e outra de saída, interligadas por conexões



**Figura 2** : Rede neural artificial de dois níveis, sem camadas ocultas (Perceptron)  
(Adaptada de White, 1992, p.137)

As unidades de entrada (sensores) enviam sinais  $x_i$  às unidades seguintes através das conexões determinadas. Os valores transmitidos são ponderados nestas conexões, através de um vetor de pesos W. Assim, cada sinal passado de um neurônio i a um neurônio j será reforçado ou atenuado na conexão através de um peso  $w_{ij}$ . Definir um peso  $w_{ij}=0$  significa desfazer a conexão. Uma função de saída simples para a rede da Figura 2 poderia assumir uma forma equivalente a  $Y=w_{14}x_1+w_{24}x_2+w_{34}x_3$ , por exemplo.

Em um caso mais geral, podem ser observadas unidades intermediárias (chamadas de ocultas), que recebem os sinais, processando e encaminhando aos níveis seguintes. Podem existir diversos níveis ocultos, sempre com uma camada de entrada e outra de saída. Entretanto, em 1957 foi demonstrado teoricamente por Kolmogorov (através do "Teorema de Kolmogorov") que uma função contínua qualquer pode ser implementada exatamente em uma rede neural artificial de três camadas, a mais utilizada atualmente (Kauko, 1997; Kóvacs, 1996; Tay e Ho, 1994). Neste caso, a rede assume um aspecto como na Figura 3:



**Figura 3** : Rede neural artificial de três camadas, com uma camada oculta  
(Adaptada de White, 1992, p.82)

Este formato, com múltiplas camadas e contendo uma ou mais camadas ocultas, foi efetivamente implementado em 1974 por Werbos, Parker e Rumelhart, recebendo o nome de "Perceptron Multi-camadas" (Portugal e Fernandes, 1996; Tay e Ho, 1994). Neste modelo, o sinal de entrada de um neurônio oculto  $j$  é a soma das entradas ponderadas que recebe (White, 1992, p.82):

$$w_{j0} + w_{j1} * x_1 + w_{j2} * x_2 + \dots + w_{jr} * x_r = \sum w_{ji} x_i \quad (1)$$

Onde  $w_{j0}$  é um termo com função semelhante ao intercepto (constante) da equação de regressão e os pesos  $w_{ji}$  representam a ponderação para a unidade  $j$  das entradas recebidas das unidades  $i$  (que são todas as unidades conectadas à unidade  $j$ ). A unidade oculta  $j$  produz uma saída  $h_j = G(\hat{a}w_{ji}x_i)$ , onde  $G$  é uma função de ativação, de formato linear ( $y=x$ ) ou sigmóide ( $y=(1+e^{-x})^{-1}$ ), geralmente. As unidades ocultas enviam sinais às unidades de saída da mesma forma e a saída é  $Y = G(\sum w_{oj}h_j)$ , ponderando com pesos  $w_{oj}$  as entradas recebidas pela camada de saída (neurônio  $o$ ) de cada neurônio  $j$ . Assim, a saída  $Y$  será dada por (White, 1992, p.83):

$$Y = G[\sum w_{oj}G(\sum w_{ji}x_i)] = G[\sum w_{oj}h_j] \equiv f(X, W) \quad (2)$$

As conexões e pesos definem a forma da função  $f$ , que determina a resposta na unidade de saída da rede em situação de equilíbrio. A maioria das RNA tem algum tipo de mecanismo de auto-treinamento, através de ponderações nas conexões. Assim, diz-se que as redes neurais "aprendem" através de exemplos, e têm alguma capacidade de generalização, após este período. O vetor  $W$  é conhecido como "ponderação da conexão". Dada uma rede suficientemente complexa, a regra de aprendizagem deve realizar a tarefa de encontrar os pesos  $w_{ij}$  adequados para aproximar a função  $f$ , de acordo com os dados (White, 1992, p.83).

A forma mais comum de treinamento é através de exemplos  $e$ , segundo Kovács: "por este método, são apresentados exemplos de comportamento à rede ... os exemplos são repassados até que a rede aprenda o comportamento correto", ou seja, até que a rede implemente corretamente a função  $Y=f(X, W)$ , para todos os exemplos do conjunto de dados empregado para o treinamento da rede (Kovács, 1996, p.41).

O algoritmo *backpropagation* (retropropagação dos erros), embora não seja totalmente preciso, é o mais empregado. Este algoritmo determina os pesos por tentativa e erro, num processo iterativo de treinamento, a partir das evidências empíricas fornecidas. Geralmente a rede é iniciada com uma configuração mais complexa (mais conexões), sendo simplificada progressivamente, até atingir os resultados esperados (Portugal e Fernandes, 1996).

Além do Perceptron Multi-camadas, há outros formatos, tal como o de Hopfield, com múltiplas interconexões, de ajuste mais complexo, e o SOM (conhecido como "rede de Kohonen", em referência ao pesquisador que o desenvolveu), entre outros.

A rede de Kohonen é baseada em auto-aprendizagem competitiva não-supervisionada, não sendo determinado, a princípio, qual o neurônio que será ativado para cada entrada. Este tipo é o mais utilizado na Finlândia e em parte da Inglaterra. O modelo de Kohonen consiste em uma rede neural de duas camadas, de treinamento não supervisionado. A rede pode apresentar qualquer formato bidimensional em sua camada de saída, tal como retangular, hexagonal, triangular, entre outros. Na fase de treinamento, os neurônios da camada de saída competem para serem os vencedores a cada nova iteração (Kauko, 1997).

É conhecido como uma técnica de mapeamento auto-organizável (self-organizing mapping - SOM), pois o resultado é apresentado

como um mapa de atributos agrupados, uma superfície onde as áreas com combinações similares de variáveis podem ser vistas como um todo, e também comparadas com áreas de diferente natureza. No algoritmo SOM, "o vencedor leva tudo", ou seja, "para uma dada entrada, somente um neurônio apresenta na sua saída um nível lógico 'um', enquanto os demais estarão em nível 'zero', segundo Melo *et al.* (1999, p.4). Ao contrário da ARM, não é preciso excluir os outliers, mas é necessário dispor de cerca de 20 observações por nó, para que os cálculos tenham relevância. (Kauko, 1997).

Em qualquer topologia, entretanto, os dados são apresentados como uma matriz, com um ou mais casos de exemplo, codificados numericamente. Geralmente exige-se uma grande quantidade de dados para o bom funcionamento da RNA. Os dados de entrada assemelham-se aos empregados em outras formas de análise, inclusive estatística inferencial. Geralmente cada informação é chamada de "caso" ou "exemplo".

Na metodologia RNA, uma amostra é dividida em dois conjuntos, um para treinamento e outro para validação ou teste da rede. O conjunto de treinamento é o conjunto de exemplos usados para aprendizagem (ajustamento dos pesos – parâmetros) e a performance da rede (capacidade de generalização) é verificada com o conjunto de validação. O conjunto de dados de treinamento traz para a rede informações de entrada  $X_t$  e de saída  $Y_t$ , referentes ao caso  $t$ . No treinamento através de *backpropagation* (BP), a rede é inicializada com um conjunto de pesos aleatórios  $W_0$ , que são (retro)ajustados progressivamente pela seguinte relação:

$$W_t = W_{t-1} + \eta \nabla f(X_t, W_{t-1}) * (Y_t - f(X_t, W_{t-1})) \quad (3)$$

Onde  $t$  indica os elementos da amostra, variando de 1 a  $n$ ,  $\eta$  é a taxa de aprendizagem e  $\nabla f$  é o gradiente de  $f$  com relação aos pesos  $W$  (vetor com as derivadas parciais). Assim, os pesos são reajustados com base nos erros de resposta [ $Y_t - f(X_t, W_{t-1})$ ]. A taxa de aprendizagem ( $\eta$ ) indica a velocidade desejada para o ajuste. Se for elevada demais, pode haver instabilidade, e eventualmente não ocorrerá a convergência dos parâmetros. Geralmente  $\eta$  é fixa, para os dados de entrada, que é a opção mais apropriada se ocorrem variações nos casos (observações). Entretanto, se há pouca variação de uma observação para outra, pode-se fazer  $\eta$  variar com  $t$  (indica-se como  $\eta_t$ , neste caso), para compensar efeitos aleatórios sobre  $Y_t$ .

Assim, durante o treinamento, o vetor de pesos é progressivamente ajustado, buscando diminuir a diferença entre as saídas estimadas e as desejadas (valores reais, da amostra), até o nível de precisão desejado. Atingido este ponto, a rede deve ser testada, empregando-se o conjunto de dados reservado para a validação. Porém, uma das principais dificuldades de uso das RNA é definir o momento de encerrar o treinamento. Se for ultrapassado o limiar ótimo, ocorre o "supertreinamento" (*overtraining*), quando a rede memoriza os dados, caso em que os resultados aplicam-se apenas ao conjunto empregado neste treinamento. Por este motivo, a utilização de um conjunto de dados de validação é fundamental. Contudo, no estágio atual de desenvolvimento desta técnica, o ajuste dos parâmetros, tais como número de nós ou de camadas ocultas ou tempo de processamento, deve ser realizado por tentativa e erro (Worzala *et al.*, 1995).

De qualquer forma, a meta da análise através de redes neurais artificiais é obter uma boa performance na explicação do comportamento de novos dados, e a verificação de erros com dados não utilizados no treinamento é fundamental. Há alguma semelhança entre alguns tipos de redes neurais com a análise de regressão convencional através de modelos generalizados. A função  $f$  tem a mesma finalidade da equação de regressão, bem como as entradas  $X_t$  são as variáveis independentes, as saídas  $Y_t$  são as variáveis dependentes e os pesos  $W$  seriam os parâmetros da equação de regressão. White (1992, p.87) entende que deve-se empregar em conjunto técnicas de inferência e redes neurais, para obter-se mais eficiência no processo de estimação.

Na literatura recente podem ser encontrados alguns exemplos de aplicações de RNA na análise de valores de imóveis. Tay e Ho (1994) investigaram a aplicação de redes neurais para avaliação em massa, usando uma amostra de 833 informações de vendas de apartamentos em Singapura para o treinamento da rede e outros 222 dados para o grupo de controle (validação). A rede foi determinada com o algoritmo de *backpropagation* (BP), com três camadas (de entrada, saída e oculta), obtendo resultados muito bons. Dos imóveis do grupo de validação, apenas 9 apresentaram erros absolutos acima de 50%, em relação ao valor real. Analisando em detalhe, eles verificaram que apenas um destes erros não podia ser explicado, sendo que, para os outros, os valores estimados eram até mais adequados que os originalmente coletados.

Evans *et al.* (1995) apresentaram uma RNA de três camadas, determinada com algoritmo BP, usando uma amostra de 45 dados de venda de residências, sendo 33 utilizados no treinamento da rede e 12 na validação, concluindo que as RNA parecem ser adequadas para a avaliação de imóveis, mesmo para um conjunto pequeno de dados, embora a precisão seja extremamente dependente do cuidado no tratamento dos dados do conjunto de treino. Dados "com ruído" ou "não apropriados" também afetam sensivelmente o nível de erro, de forma semelhante aos *outliers* na regressão.

Worzala *et al.* (1995), utilizando uma amostra de 288 informações de vendas de residências, divididas em 217 e 71 dados para treinamento e controle, respectivamente, desenvolveram uma rede de três camadas, testando também modelos com amostras parciais. Os resultados não foram considerados positivos, pois foram encontradas diferenças significativas entre os dois *softwares* utilizados, e em repetições com o mesmo *software*. O tempo de processamento também foi considerado longo, atingindo até 25h para estabilizar a rede. Em alguns casos os modelos RNA superavam os resultados da análise de regressão, mas nenhum dos *softwares* demonstrou superioridade.

Rossini (1997) desenvolveu um estudo comparativo entre ARM e RNA, com um conjunto total de 334 informações, testando modelos com 223 elementos e outros com menor quantidade de dados, para simular uma "avaliação comercial". Também empregou uma rede neural de três camadas. Seus resultados indicaram superioridade da ARM. O autor relatou duas dificuldades com as RNA: o tempo de processamento e a instabilidade dos resultados. Para a amostra de 233 casos e 42 variáveis o processamento superou 23h, embora o sistema tenha sido rápido para amostras pequenas, com tempos da ordem de um minuto. Os modelos estimados com análise de regressão foram bastante consistentes, mas os resultados com as RNA foram ora excelentes, ora pobres. Porém, Rossini lembra que a ARM é uma técnica antiga, enquanto que as RNA têm um grande campo de desenvolvimento, em termos de utilização e de disponibilidade de softwares.

Kauko (1997) apresentou um estudo usando o mapa de Kohonen, utilizando dados de imóveis da Finlândia, nacionais e da região metropolitana de Helsinki. Para ele, a RNA é meramente uma extensão não linear da ARM, enquanto que o SOM gera um mapa, representando graficamente o fenômeno em análise. Contudo, afirma que a intuição é enfatizada e que não há regras claras para o uso deste método.

Porém, como afirma Watson (1997, p.48), a desvantagem das RNA é que são um sistema do tipo "caixa preta". A resposta é uma função ponderada dos vetores, sem uma explicação ou justificativa para o resultado. Por isto, as RNA não podem ser utilizadas em muitos domínios. Na Europa, por exemplo, as instituições financeiras não podem utilizar RNA na análise de crédito, pois há exigências legais de justificativa para eventuais negativas.

### 3. Raciocínio Baseado em Casos

O Raciocínio Baseado em Casos (RBC, ou case-based reasoning-CBR) é uma técnica de solução de problemas baseada em conhecimento, fundamentada na reutilização de experiências prévias (sintetizadas em "casos"). Ao contrário de outras técnicas baseadas em conhecimento, que resolvem problemas a partir de uma base de conhecimentos gerais, o RBC preocupa-se com experiências específicas, representadas pelos casos contidos na base de dados. As premissas do RBC são de que (a) problemas similares têm soluções similares, e (b) a reutilização de soluções de casos anteriores é mais adequada do que uma solução baseada na generalização de regras (Althoff e Bartsch-Spörl, 1996; Kolodner, 1993; Reategui *et al.*, 1995).

Algumas das vantagens do RBC são que este método não depende de um modelo explícito para a solução do problema, pode trabalhar com grandes quantidades de dados e aprender com novos casos, sendo fácil manter atualizado o sistema (Watson, 1997).

A técnica de RBC é ligada a uma área relativamente recente da Inteligência Artificial. Podem ser encontrados alguns elementos relacionados com RBC desde as pesquisas filosóficas de Wittgenstein, em 1953, mas grandes avanços foram obtidos em 1977, com estudos de Schank e Abelson, e em 1982, com trabalhos de Schank sobre memória dinâmica e outros modelos de memória. O primeiro sistema, denominado Cyrus, foi desenvolvido por Kolodner, logo após, como uma implementação do modelo de Roger Schank (Aamodt e Plaza, 1994; Kolodner, 1993; Marir e Watson, 1994; Watson, 1997).

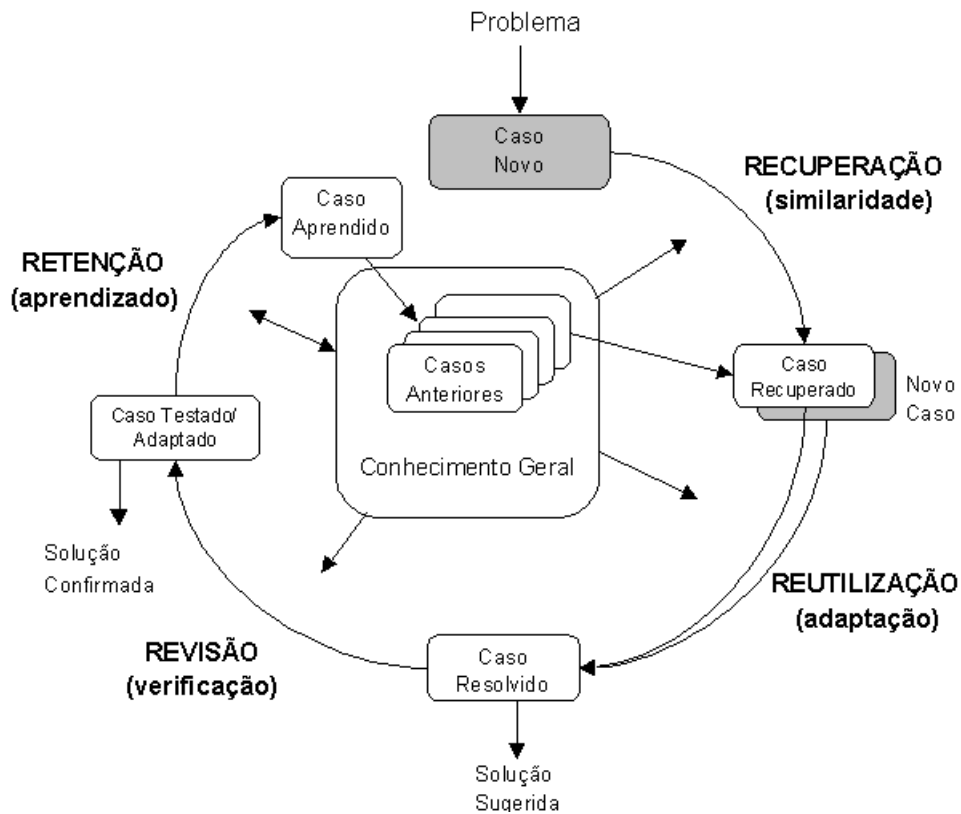
Segundo Aamodt e Plaza (1994), diversas pesquisas em psicologia cognitiva têm demonstrado evidências da utilização de regras de situações anteriores na resolução de problemas, mesmo no caso de especialistas. Para Althoff e Bartsch-Spörl (1996), o RBC pode ser considerado uma abordagem cognitiva de modelagem da forma humana de solução de problemas, em domínios onde a experiência é importante. Eles apontam os elementos-chave para o sucesso de um sistema de raciocínio baseado em casos:

1. deve ser obtida uma quantidade representativa de casos na área de aplicação;
2. os casos devem estar representados em um formato acessível pelo *software* utilizado;
3. os índices de busca devem ser eficientes;
4. a rotina que avalia a similaridade dos casos tem de ser precisa e robusta;
5. se há necessidade de adaptação, o sistema RBC tem de ser apto para isto;
6. se o sistema é implantado em conjunto com outras mudanças organizacionais, como acontece geralmente, é necessário que seja bem aceito pelos usuários;

A principal parte do conhecimento nos sistemas RBC está no adequado tratamento dos casos conhecidos. A representação dos casos é uma tarefa complexa e importante para o sucesso do sistema RBC. Um caso pode ser entendido como a abstração de uma experiência descrita em termos de seu conteúdo e contexto, podendo assumir diferentes formas de representação. Não existe consenso, na literatura especializada, sobre as informações que devem ser consideradas na descrição de um caso, mas podem ser enunciadas duas regras básicas: a funcionalidade do sistema e a facilidade de aquisição das informações, segundo Watson (1997). O conhecimento, neste nível de abrangência, pode ser interpretado como sendo um conjunto de métodos que modelam um conhecimento especializado para disponibilizá-lo em um sistema inteligente (Aamodt e Plaza, 1994).

Os casos têm três partes a serem descritas: o problema (contextualizado), a solução aplicada e o resultado final. Podem ser representados de várias formas, tais como simples vetores de características ou objetos estruturados, com descrições simbólicas ou com informação multimídia (Althoff e Bartsch-Spörl, 1996). Neste sentido, em Oliveira *et al.* (1997) e Watson e Oliveira (1998), foram apresentadas aplicações de realidade virtual na representação dos casos. Segundo os autores, a interface com o usuário é importante, e a realidade virtual permite apresentar melhor o caso para os usuários, pois é um meio "ativo", no sentido de que o usuário pode interagir com o caso.

O raciocínio baseado em casos é um processo cíclico. O ciclo RBC é composto por quatro fases, basicamente: recuperação de casos similares, reutilização das informações como proposta de solução, revisão da solução e retenção da experiência para utilização futura (Aamodt e Plaza, 1994). Este ciclo pode ser representado como na Figura 4, a seguir:



**Figura 4 : Ciclo RBC**  
 (Adaptada de Aamodt e Plaza, 1994, p.45)

A tarefa de recuperação inicia com uma descrição parcial do problema, e termina quando um caso similar é encontrado. As sub-tarefas são "identificar características", "realizar busca inicial", "procurar" e "selecionar", nesta ordem. A identificação trata de ajustar um conjunto de descritores relevantes, para que a busca possa encontrar casos suficientemente similares, dado um limiar de similaridade (Aamodt e Plaza, 1994).

A indexação facilita a recuperação dos casos de interesse na solução do problema. Os índices devem ser preditivos, indicando os propósitos do caso, sendo abstratos o suficiente para abranger o uso na base e, por outro lado, concretos o bastante para serem reconhecidos no futuro (Watson, 1997).

A busca também pode ser realizada de várias formas. A mais simples é a seqüencial, que não é recomendada para sistemas que possuam um grande número de casos, por causa do tempo consumido. Sistemas mais complexos requerem um ou mais índices. Como os casos não coincidem exatamente, em geral, deve ser utilizado um algoritmo (mecanismo) de busca que permita esta recuperação. Para cada caso "candidato" encontrado, deve ser determinada uma medida de similaridade em relação ao caso que se pretende resolver, ordenando-se os casos recuperados em ordem decrescente de similaridade (Althoff e Bartsch-Spörl, 1996).

Os algoritmos mais conhecidos são: vizinhança próxima, indução, indução guiada pelo conhecimento e recuperação segundo um modelo, empregados isoladamente ou em conjunto (Kolodner, 1993; Watson, 1997). Em alguns casos, podem ser empregadas redes neurais como auxiliares ao sistema RBC, na tarefa de busca de casos similares ou desenvolvimento de índices (Reategui *et al.*, 1995).

No mecanismo de vizinhança próxima, a similaridade é indicada por uma soma ponderada das características. Naturalmente, o problema é determinar o peso das características. O tempo de busca cresce linearmente com o tamanho da base (número de casos), sendo mais indicado para bases pequenas (Kolodner, 1993; Watson, 1997).

Na indução simples, o algoritmo determina quais características trazem a melhor solução na escolha de casos e gera uma árvore de decisão organizando os casos na memória. É mais adequado para os casos em que se requer um único caso como solução, e quando as características do caso dependem de outras características. A indução guiada pelo conhecimento aplica informações fornecidas pelo usuário para a recuperação, através da seleção prévia das características que são reconhecidas como principais (Watson, 1997).

Por outro lado, a recuperação utilizando um formato retorna apenas os casos que se ajustam a certos parâmetros (limites). Pode ser utilizada antes dos outros métodos, para selecionar um grupo relevante de casos (Watson e Marir, 1994).

A reutilização de casos está ligada com a adaptação dos casos passados. A adaptação é a fase da escolha entre a solução passada diretamente ou o método que construiu esta solução. No primeiro caso, a solução é adaptada através de "operadores de transformação", aplicados à solução. A segunda forma é conhecida como "utilização derivada", buscando refazer o caminho da solução, sob o novo contexto. A atividade de adaptação pode ser tão simples quanto substituir apenas um componente do caso recuperado ou tão complexa quanto modificar a estrutura geral da solução (Aamodt e Plaza, 1994; Kolodner, 1993; Watson e Marir, 1994).

A fase de revisão consiste em avaliar a solução gerada. Se bem sucedida, o caso pode ser retido como aprendizado. Se não, a solução deve ser revista, usando conhecimentos específicos ou a intervenção do usuário ou de um especialista. Geralmente é uma etapa externa ao sistema informatizado, pois envolve a aplicação da solução ao mundo real. Encerrando o ciclo, a etapa de retenção (aprendizagem do sistema) tem a finalidade de preparar os casos para uso futuro (Aamodt e Plaza, 1994).

Em síntese, a partir de um problema dado, o sistema RBC deve recuperar um caso similar relevante e avaliar como este caso encaixa-se na nova situação. Se forem detectadas diferenças significativas, o sistema adapta o caso para a nova situação e retorna ao início da rotina de avaliação. O sistema aprende lembrando sucessos e falhas como novos casos (Watson, 1997).

O RBC adapta-se a um grande número de aplicações. Althoff e Bartsch-Spörl (1996) afirmam que a maior parte dos problemas comerciais refere-se a tarefas "analíticas", compreendendo análise da situação, classificação e obtenção de um diagnóstico ou sugestão de uma solução. São aplicações deste tipo a análise de alternativas de investimentos, de compra de imóveis ou de compra de novos equipamentos para uma empresa. Um outro tipo de problema é o que pertence à categoria denominada por eles de tarefas "sintéticas", nas quais é necessário gerar construções ou planos complexos, em aplicações como logística de transportes e planejamento da produção.

Uma das aplicações mais comuns do RBC atualmente é nos serviços de atendimento a clientes. Watson (1997, p.61-65) elencou mais de 130 sistemas de RBC, dentre os quais cerca de 80 eram de help-desk. Segundo ele, esta área é essencial para as empresas, que estão envolvidas em uma acirrada disputa pela manutenção de clientes, tarefa vital em mercados competitivos e globalizados. Nos serviços de help-desk, os problemas apresentados pelos clientes exigiam uma grande equipe de funcionários, com custos elevados de salários, treinamento e atualização constante desta equipe. Com o uso de RBC, a maior parte das consultas pode ser resolvida por atendentes através da recuperação de casos anteriores semelhantes. A necessidade da intervenção de especialistas torna-se reduzida, apenas em casos raros, que podem em seguida ser incorporados à base.

Outro campo de utilização corrente é na área jurídica, como ocorre, por exemplo, nos Estados Unidos. O raciocínio legal no direito anglo-saxão segue a chamada "regra do precedente", e os casos jurídicos são resolvidos com a busca de situações similares e adaptação das soluções anteriores, mais importantes que o direito positivo (as leis) e tanto advogados quanto juizes precisam dispor de um sistema que organize e recupere facilmente a imensa quantidade de casos disponíveis para consulta. A utilização de RBC é uma opção natural e existem diversas aplicações, tais como as relacionadas por Watson (1997, p.266). No Brasil, também existem pesquisas, demonstrando a aplicabilidade para o sistema jurídico local (Bueno *et al.*, 1999; Weber-Lee; 1998; Weber-Lee *et al.*, 1997).

Há aplicações em diversas outras áreas, devido à flexibilidade do RBC. Sycara (1988) apresentou um estudo sobre RBC aplicado à organização de propostas para acordos trabalhistas. Ela descreve como utilizar o sistema para sugerir formas de adaptação de acordos anteriores para uma nova situação, sujeita a metas distintas. O sistema também é capaz de ajustar a proposta inicial, caso não seja aceita pelas partes.

Em dois trabalhos, de Althoff *et al.* (1999a) e de Nick e Tautz (1999), foi indicada a utilização de sistemas RBC para construir e manter uma base de "experiências de fábrica" (know-how) sobre o desenvolvimento de produtos, com a finalidade de disponibilizar esta experiência de forma simplificada.

Weber-Lee *et al.* (1995) apresentaram um trabalho sobre previsão de fluxo de caixa, utilizando lógica difusa (fuzzy) associada ao RBC. Para eles, em ambientes com incerteza, o RBC é mais adequado do que outras técnicas, como a análise de time series, porque não assume a continuidade do comportamento, mas apenas a possível repetição de padrões.

Também são comuns as aplicações em projeto, planejamento e diagnósticos. Há sistemas para diagnósticos, na área médica (com aplicações em audição e cardiologia, por exemplo), e na construção civil (trabalhando com patologias em edificações), entre outras (Watson, 1997).

Contudo, não são comuns aplicações com resultados numéricos. Na área de mercado imobiliário ou avaliação de imóveis, são raras as aplicações. Em detalhado levantamento bibliográfico, Watson (1997, p.216-281) não relacionou nenhum trabalho neste setor. Da mesma forma, dentre dezenas de artigos sobre RBC publicados em recentes encontros nacionais e internacionais (ver Althoff *et al.*, 1999; Borges e Carvalho, 1999; Leake e Plaza, 1997; Smith e Faltings, 1996; Smyth e Cunningham, 1998), foi apresentado apenas um trabalho nesta área de pesquisa (McSherry, 1998). Além deste, foram encontrados apenas outros dois estudos, de González e Laureano-Ortiz (1992) e Ribeiro (1999).

Ribeiro (1999) descreveu, em linhas gerais, a relação entre RBC e sistemas multi-agentes, formando um sistema voltado para a avaliação de imóveis. Entretanto, é uma proposta, sem o efetivo desenvolvimento. Ele entende que, na avaliação do valor de uma propriedade, o avaliador utiliza mecanismos de analogia para encontrar as relações entre o avaliando e as propriedades similares utilizadas como amostra do comportamento do mercado. Desta forma, a abordagem em sistemas RBC seria adequada.

Uma aplicação prática foi apresentada por González e Laureano-Ortiz (1992). Neste estudo, os autores desenvolveram um modelo para avaliação de imóveis seguindo RBC, sob um formato simplificado utilizado nas avaliações comerciais no Estados Unidos, que fundamenta-se em apenas três informações de transações. Entretanto, o sistema proposto exige forte intervenção de especialistas, na definição de fatores de ajuste, aplicados na fase de revisão.

González e Laureano-Ortiz (1992) afirmam que as técnicas usuais para avaliação de imóveis por comparação de dados não capturam o conhecimento heurístico, o que poderia ser realizado por RBC. Eles entendem que o RBC parece ser mais adequado para processos que decorrem do comportamento psicológico (humano), como o mercado imobiliário. O protótipo desenvolvido por eles recupera os dez casos mais similares ao avaliando. O grau de similaridade depende da importância relativa das características consideradas. A adaptação é realizada ajustando o valor de venda de cada caso selecionado, através de um método chamado "aplicação crítica", que utiliza parâmetros de ajuste obtidos de um especialista. Por fim, a solução decorre da aplicação dos ajustes determinados, que são adicionados ou subtraídos ao valor de venda de cada propriedade recuperada do arquivo. Após este ajuste, o protótipo seleciona as três melhores, do conjunto inicial de dez.

Este formato, modelado pelos autores, segue uma sistemática de avaliação comum entre os avaliadores americanos, que utiliza uma média ajustada de três imóveis para a avaliação. O sistema poderia ser alterado facilmente para considerar um número maior de informações. Contudo, a deficiência do sistema proposto é a exigência de intervenção de especialista, definindo as características mais importantes e os valores do ajuste (que correspondem aos preços hedônicos, ou coeficientes da equação, na ARM). Desta forma, o protótipo realiza apenas a função de seleção (match) dos casos, com a tarefa principal sendo realizada através de intervenção humana (González e Laureano-Ortiz, 1992).

Outro trabalho, de McSherry (1998), descreve uma forma alternativa de adaptação, que foi implementada em um sistema RBC, no qual o conceito de "caso dominante" é fundamental, na adaptação e na manutenção da consistência da base de casos. Um caso é dominante a outro se todos os seus atributos são iguais ou superiores. Assume-se que os valores dos atributos dos casos podem ser organizados em ordem crescente. Assim, a heurística de adaptação segue regras simples: dado um caso para o qual se deseja determinar o valor, denominado C1, o sistema busca um caso que seja diferente deste apenas em um atributo (C2). Em seguida, busca outros dois casos, C3 e C4, que também são distintos apenas neste atributo, de tal forma que C3 tem valor igual a C1 para o atributo em questão, bem como C2 e C4 conferem. Então, calcula-se o valor de C1 por:  $est(C1) = est(C2) + est(C3) - est(C4)$ . Entretanto, esta forma é adequada para sistemas em que o valor seja determinado por uma função linear e aditiva, o que pode não ocorrer em muitas situações. Ademais, encontrar vários casos em que apenas um atributo seja distinto também não é tarefa fácil, diante da heterogeneidade dos imóveis.

A dificuldade de adaptação é um problema corrente na área, mas que pode ser contornado com o uso de outras técnicas. Uma destas é a lógica difusa (fuzzy logic), que pode ser empregada na verificação de similaridade e no estabelecimento de regras de adaptação, conforme sugerido por Sovat e Carvalho (1999). Dubois *et al.* (1997) e Weber-Lee (1995) também apresentaram trabalhos com a participação da lógica difusa em sistemas de RBC. No mesmo sentido, Yager (1997) afirma que a lógica difusa deve ser utilizada em ambientes em que soluções numéricas sejam requeridas.

#### 4. Considerações Finais

A análise de valores dos imóveis, da forma como é atualmente realizada, enfrenta problemas que diminuem a precisão das estimativas, especialmente o desconhecimento da forma funcional e a dificuldade de estimação dos valores relativos à distribuição espacial dos imóveis. Evans *et al.* (1995), por exemplo, afirmam que, embora os cálculos envolvidos sejam complexos, a análise de regressão tem atingido resultados com limitado grau de sucesso.

A aplicação das redes neurais artificiais em avaliação de imóveis, embora com boas perspectivas, a princípio, indicou conclusões conflitantes. Algumas pesquisas obtiveram excelentes resultados, enquanto que outras apontam problemas e desempenhos sofríveis. Um dos problemas apontados, o tempo de processamento, pode ser superado facilmente, através do emprego de hardware mais poderoso disponível atualmente, uma vez que a evolução das máquinas tem sido grande, nos últimos anos. Por outro lado, os resultados opostos indicam que falta desenvolvimento teórico ou dos softwares da área. Faltam também a definição de critérios de parada e outros detalhes, que ainda dependem excessivamente do pesquisador.

Entretanto, Watson (1997) entende que as RNA são melhores para áreas onde os dados não podem ser representados simbolicamente, enquanto que o RBC é melhor com dados simbólicos complexos e estruturados. Por outro lado, há indicações de que, com o apoio de outras técnicas (tal como a lógica difusa), o RBC pode ser utilizado em aplicações numéricas, compensando as dificuldades nas tarefas de recuperação e adaptação de casos (Dubois *et al.*, 1997; Sovat e Carvalho, 1999; Yager, 1997; Weber-Lee, 1995). Assim, o RBC poderá ser empregado para recuperação de casos (especialmente na avaliação de massa), para busca de similaridades especiais (muitas vezes descritas simbolicamente, como por nomes de ruas ou de bairros) e para determinação de valores, com apoio de regras heurísticas ou funções numéricas baseadas em lógica fuzzy ou mesmo em inferência estatística.

Como a determinação do valor é empregada em um grande número de situações, inclusive para tributação, os eventuais erros cometidos podem afetar expressiva parcela da população. Assim, verifica-se a necessidade de pesquisar técnicas alternativas, de forma a aprimorar o processo de análise.

#### 5. Referências Bibliográficas

1. AAMODT, Agnar e PLAZA, Enric. Case-based reasoning: Foundational issues, methodological variations, and system approaches. **AI Communications**, v.7, n.1, p.39-59, Mar. 1994.
2. ALTHOFF, Klaus-Dieter e BARTSCH-SPÖRL, Brigitte. Decision support for case-based applications. **Wirtschaftsinformatik**, n.38, v.1, p.6-14, 1996.
3. ALTHOFF, Klaus-Dieter; BERGMANN, Ralph; BRANTING, L. Karl (Eds.). Case-based reasoning research and development. **Third International Conference on Case-Based Reasoning, ICCBR-99 (Seon Monastery, Germany) – Proceedings**. Berlin: Springer, 1999.
4. ALTHOFF, Klaus-Dieter; NICK, M.; TAUTZ, C. CBR-PEB: An application implementing reuse concepts of the experience factory for the transfer of CBR system know-how. In: **Proceedings of the 7th German Workshop on Case-Based Reasoning**, Mar. 1999a.
5. AUBIN, Jean-Pierre. **Neural networks and qualitative physics**. A viability approach. Cambridge: Cambridge University, 1996.
6. BORGES, Dívio Leandro e RIZZONI, Ariadne M.B. (Eds.). Educação e aprendizagem na sociedade da informação. **XIX Congresso Nacional da Sociedade Brasileira de Computação (SBC) – Anais**. v.4. Rio de Janeiro: Entrelugar, 1999.

7. BUENO, Tânia C.D.; WANGENHEIM, Christiane Von; HOESCHL, Hugo C.; MATTOS, Eduardo; BARCIA, Ricardo M. Uso da teoria jurídica para recuperação em amplas bases de textos jurídicos. In: BORGES, Dívio Leandro e RIZZONI, Ariadne M.B. (Eds.). Educação e aprendizagem na sociedade da informação. **XIX Congresso Nacional da Sociedade Brasileira de Computação (SBC) – Anais**. v.4, p.107-120. Rio de Janeiro: EntreLugar, 1999.
8. DUBOIS, Didier; ESTEVA, Francesc; GARCIA, Pere; GODO, Lluís; MÀNTARAS, Ramon L. De; PRADE, Henri. *Fuzzy modelling of case-based reasoning and decision*. In: LEAKE, David B. e PLAZA, Enric (Eds.). Case-based reasoning research and development. **Second International Conference on Case-Based Reasoning, ICCBR-97 (Providence, USA) – Proceedings**, p.599-610. Berlin: Springer, 1997.
9. EVANS, Alec; JAMES, Howard; COLLINS, Alan. Artificial neural networks: An application to residential valuation in UK. **Journal of Property Tax Assessment & Administration**, v.1, n.3, p.78-92, May 1995.
10. GONZÁLEZ, Avelino J. e LAUREANO-ORTIZ, Raymond. A case-based reasoning approach to real estate property appraisal. **Expert System With Applications**, v.4, p.229-246, 1992.
11. GONZÁLEZ, Marco Aurélio Stumpf. **A Engenharia de Avaliações na visão inferencial**. São Leopoldo: Editora da UNISINOS, 1997.
12. KASKI, Samuel; KANGAS, Jari; KOHONEN, Teuvo. Bibliography of self-organizing map (SOM) papers: 1981-1997. **Neural Computing Surveys**, v.1, p.102-350, 1998.
13. KAUKO, Tom. Exploring the prices of residential apartments and locality features within an artificial neural network approach – Evidence from Finland. **AREUEA International Conference**. UCLA: Berkeley, June 1997.
14. KOLODNER, Janet. **Case-based reasoning**. San Mateo (USA): Morgan Kaufmann, 1993.
15. KOVÁCS, Zsolt László. **Redes neurais artificiais: Fundamentos e aplicações**. 2ed. São Paulo: Collegium Cognitio/Acadêmica, 1996.
16. LEAKE, David B. e PLAZA, Enric (Eds.). Case-based reasoning research and development. **Second International Conference on Case-Based Reasoning, ICCBR-97 (Providence, USA) – Proceedings**. Berlin: Springer, 1997. (Lecture Notes in Artificial Intelligence, v.1266).
17. MARIR, Farhi e WATSON, Ian. Case-based reasoning: A categorised bibliography. **The Knowledge Engineering Review**. v.9, n.3, 1994.
18. McSHERRY, David. *An adaptation heuristic for case-based estimation*. In: SMYTH, Barry e CUNNINGHAM, Pádraig (Eds.). Advances in case-based reasoning. **4th European Workshop, EWCBR-98 (Dublin, Ireland) – Proceedings**, p.184-195. Berlin: Springer, 1998.
19. Saul Luiz de; CALOBA, Luiz Pereira; NADAL, Jurandir. *Classificação de batimentos cardíacos utilizando rede neural com treinamento competitivo supervisionado*. In: BORGES, Dívio Leandro e RIZZONI, Ariadne M.B. (Eds.). Educação e aprendizagem na sociedade da informação. **XIX Congresso Nacional da Sociedade Brasileira de Computação (SBC) – Anais**. v.4, p.1-12. Rio de Janeiro: EntreLugar, 1999.
20. M. e TAUTZ, C. Practical Evaluation of an Organizational Memory using the Goal-Question-Metric Technique. In: **Proceedings of the 5th German Conference on Knowledge-Based Systems (XPS-99)**, Mar. 1999.
21. OLIVEIRA, Leonardo R. de; RETIK, A.; WATSON, Ian. The integration of VR and CBR to visually represent past experiences. In: HEINISUO, M. (Ed.). **Application of artificial intelligence in structural engineering - IV**, p.105-116, Oct. 1997.
22. PORTUGAL, Marcelo S.; FERNANDES, Luiz Gustavo L. Redes neurais artificiais e previsão de séries econômicas: Uma introdução. **Nova Economia**, v.6, n.1, p.51-74, jul. 1996.
23. REATEGUI, Eliseo; CAMPBELL, John A.; BORGHETTI, Shirley. Using neural network to learn general knowledge in a case-based system. **Case-Based Reasoning Research and Development**, 1995.
24. RIBEIRO, Francisco Loforte. Using multiagent systems technology and case-based reasoning in the valuation of residential and office properties. In: **COBRA 1999**, p.33-44. London: RICS (Royal Institution on Chartered Surveyors), 1999.
25. ROSSINI, Peter. Application of artificial neural networks to the valuation of residential property. **Third Annual Pacific-Rim Real Estate Society Conference**. Palmerston North, New Zealand, Jan. 1997.
26. RUMELHART, David. E. e MACCLELLAND, James. L. **Parallel distributed processing: Explorations in the microstructure of cognition**. Cambridge: MIT, 1995.
27. SMITH, Ian e FALTINGS, Boi (Eds.). Advances in case-based reasoning. **Third European Workshop, EWCBR-96 (Lausanne, Switzerland) – Proceedings**. Berlin: Springer, 1996.
28. SMYTH, Barry e CUNNINGHAM, Pádraig (Eds.). Advances in case-based reasoning. **4th European Workshop, EWCBR-98 (Dublin, Ireland) – Proceedings**. Berlin: Springer, 1998. (Lecture Notes in Artificial Intelligence, v.1488).
29. SOVAT, Ricardo B. e CARVALHO, André C.P.L.F. de. *Um ambiente para desenvolvimento de sistemas de raciocínio baseado em casos*. In: BORGES, Dívio Leandro e RIZZONI, Ariadne M.B. (Eds.). Educação e aprendizagem na sociedade da informação. **XIX Congresso Nacional da Sociedade Brasileira de Computação (SBC) – Anais**. v.4, p.133-148. Rio de Janeiro: EntreLugar, 1999.
30. SYCARA, Katia. Using case-based reasoning for plan adaptation e repair. **Proceedings of the DARPA Case-Based Reasoning Workshop**, 1988.
31. Danny. P. H. e HO, David K. H. Intelligent mass appraisal. **Journal of Property Tax Assessment & Administration**, v.1, n.1, p.5-25, Sept. 1994.
32. WATSON, Ian. **Applying case-base reasoning: Techniques for enterprise systems**. San Francisco (USA): Morgan Kaufmann, 1997.
33. WATSON, Ian e MARIR, Farhi. Case-based reasoning: A review. **The Knowledge Engineering Review**, v.9, n.4, 1994.
34. WATSON, Ian e OLIVEIRA, Leonardo. *Virtual reality as an environment for CBR*. In: SMYTH, Barry e CUNNINGHAM, Pádraig (Eds.). Advances in case-based reasoning. **4th European Workshop, EWCBR-98 (Dublin, Ireland) – Proceedings**, p.448-459. Berlin: Springer, 1998.
35. WEBER-LEE, Rosina. **Pesquisa jurisprudencial inteligente**. Florianópolis: UFSC, 1998. Tese (Doutorado em Engenharia).
36. WEBER-LEE, Rosina; BARCIA, Ricardo Miranda; COSTA, Márcio C. da; RODRIGUES FILHO, Ilson W.; HOESCHL, Hugo C.; BUENO, Tania C. D'Agostini; MARTINS, Alejandro; PACHECO, Roberto C. *A large case-based reasoner for legal cases*. In: LEAKE, David B. e PLAZA, Enric (Eds.). Case-based reasoning research and development. **Second International Conference on Case-Based Reasoning, ICCBR-97 (Providence, USA) – Proceedings**, p.190-199. Berlin: Springer, 1997.
37. WEBER-LEE, Rosina; BARCIA, Ricardo Miranda; KHATOR, Suresh K. *Case-base reasoning for cash flow forecasting using fuzzy retrieval*. In: VELOSO, Manuela e AAMODT, Agnar (Eds.). Case-Based Reasoning Research e Development. **First International Conference on Case-Based Reasoning, ICCBR-95 (Sesimbra, Portugal) – Proceedings**, p.510-519. Berlin: Springer, 1995.
38. WHITE, Halbert. **Artificial neural networks**. Approximation and learning theory. Cambridge (USA): Blackwell, 1992.
39. WORZALA, Elaine; LENK, Margarita; SILVA, Ana. An exploration of neural networks and its application to real estate valuation. **The Journal of Real Estate Research**, v.10, n.2, p.185-201, 1995.
40. YAGER, Ronald R. *Case based reasoning, fuzzy systems modelling and solution composition*. In: LEAKE, David B. e PLAZA, Enric (Eds.). Case-based reasoning research and development. **Second International Conference on Case-Based Reasoning, ICCBR-97 (Providence, USA) – Proceedings**, p.633-642. Berlin: Springer, 1997.

