

## ESTIMATIVA DE DADOS CLIMÁTICOS UTILIZANDO REDES NEURAIS ARTIFICIAIS PARA FINS DE ZONEAMENTO BIOCLIMÁTICO DO ESTADO DE MINAS GERAIS

**Luis Enrique Zárate<sup>†</sup> (1); Willi de Barros Gonçalves (2); Eleonora Sad de Assis (3);  
Sérgio Mariano Dias<sup>\*</sup> (1)**

(1) Instituto de Informática – Pontifícia Universidade Católica de Minas Gerais, Brasil – e-mail:

[zарате@pucminas.br](mailto:zарате@pucminas.br) e [sergiomariano@gmail.com](mailto:sergiomariano@gmail.com)

(2) Departamento de Arquitetura e Urbanismo – Pontifícia Universidade Católica de Minas Gerais,  
Brasil – e-mail: [willi@pucminas.br](mailto:willi@pucminas.br)

(3) Departamento de Tecnologia da Arquitetura e do Urbanismo – Escola de Arquitetura –  
Universidade Federal de Minas Gerais, Brasil – e-mail: [elsad@ufmg.br](mailto:elsad@ufmg.br)

### RESUMO

**Proposta:** Um dos principais problemas encontrados na interpolação de dados climáticos é a baixa densidade de estações medidoras quando comparado à extensão territorial ou ao número de municípios de um estado, o que pode provocar distorções significativas nos resultados de interpolação, mesmo quando se aplicam métodos geoestatísticos. Este trabalho objetivou o aperfeiçoamento dos processos de interpolação de dados climáticos, para fins de classificação bioclimática usando as Tabelas de Mahoney. **Método de pesquisa/Abordagens:** uma rede neural artificial foi treinada com dados climáticos médios mensais e as coordenadas geográficas e de altitude de cada ponto da rede de 66 estações meteorológicas do 5º Distrito de Meteorologia (Minas Gerais) e de mais 15 estações limítrofes de outros estados, de modo que dadas as coordenadas geográficas e a altitude de um ponto qualquer no estado, o modelo fosse capaz de estimar seus dados climáticos. Foram introduzidos nesse modelo as coordenadas de 1.709 localidades do estado de Minas Gerais, sendo os dados climáticos gerados aplicados às Tabelas de Mahoney. **Resultados:** a ampliação do número de pontos sobre o território mineiro acrescidos da sua altitude permitiu observar melhor a relação entre as variáveis, quando comparado a dados anteriormente obtidos. **Contribuições/ Originalidade:** uso de redes neurais artificiais para a estimativa de dados climáticos diminuiu o tempo de processamento para a obtenção de resultados, bem como aumentou a sua confiabilidade.

Palavras-chave: estimativa de dados climáticos; redes neurais artificiais; classificação bioclimática.

### ABSTRACT

**Proposal:** One of the main problems found in interpolation of climatic data is the low density of the meteorological stations when compared to the territorial extension or the number of municipalities of a state, which can result in significant distortions in the results, even when geo-statistical methods are applied. This study aimed to improving the processes of climate data interpolation, for the purposes of bioclimatic classification using Mahoney Tables. **Methods:** an artificial neural network was trained with monthly average climatic data, the geographic coordinates and altitude of each point of the 66 meteorological stations of the 5<sup>th</sup> District of Meteorology (Minas Gerais) and 15 more stations in other neighboring states, so that given the geographical coordinates and altitude of any point in the state, the model is able to estimate its climatic data. Data from 1,709 locations in the state of Minas Gerais were introduced in this model, and the climate data generated applied to Mahoney Tables. **Findings:** the expansion of the number of points over the territory including its altitude allowed a better observation about the variables relationship, as compared to data previously obtained. **Originality/value:** use of artificial neural networks to estimate climatic data reduced the processing time to obtain results, and increased its reliability.

Keywords: climate data estimates; artificial neural network; bioclimatic classification.

## 1 INTRODUÇÃO

A perspectiva de racionalização do uso de energia no setor da construção civil, sem o risco de sacrifício das condições de conforto ambiental nos edifícios, tem sido geralmente abordada a partir da adoção do zoneamento bioclimático, que estabelece os critérios de desempenho das edificações para uma melhor adaptação ao clima local, portanto utilizando mais intensivamente os recursos naturais para o condicionamento (térmico e luminoso, principalmente) dos espaços interiores.

Nas últimas décadas, uma série de procedimentos para a geração e/ou formatação de dados climáticos para a análise termo-energética de edificações foram desenvolvidos, porém, há menos informação disponível para a orientação das etapas iniciais de concepção dos edifícios. Tais dados, quando utilizados nos índices de conforto e organizados no zoneamento bioclimático de um dado território, ajudam a obter uma série de recomendações para o projeto arquitetônico que podem ser aplicadas nessas etapas iniciais.

Entretanto, no Brasil, ainda não há uma base de dados climáticos suficientemente ampla e adequada a esse tipo de aplicação, como bem aponta Roriz (1999). Segundo a avaliação do autor, menos de 4% dos mais de 5.500 municípios brasileiros possuem dados climáticos publicados. Em Minas Gerais, uma das maiores coberturas de estações meteorológicas padrão WMO do país, de seus 853 municípios, apenas 32 (3,8%) tiveram dados publicados nas Normais Climatológicas (BRASIL, 1992). A baixa densidade de estações medidoras gera dificuldades para a correta identificação de estratégias de conforto ambiental para as condições climáticas de um dado local e/ou resultados não representativos nas análises de desempenho das edificações.

Uma alternativa para esse problema é a interpolação de dados para alcançar uma boa estimativa das condições climáticas de uma determinada região. Há muitos procedimentos que podem ser aplicados para tal, como modelos de regressão linear (PEZZOPANE *et al.*, 2003) e não linear (RORIZ, 1999) múltipla, modelos de interpolação espacial e modelos inferenciais que incorporam procedimentos geoestatísticos, como é o caso da *krigagem* (CAMARGO, 1998).

Esse último procedimento foi o adotado em trabalho anterior (GONÇALVES *et al.*, 2003), que teve como base para a classificação de zoneamento bioclimático do estado de Minas Gerais as Tabelas de Mahoney (ONU, 1971). Foram usados dados climatológicos médios mensais das variáveis solicitadas pelas Tabelas (temperatura máxima, mínima, umidade relativa e pluviosidade) referentes a 79 localidades no estado e mais 12 localidades no seu entorno, totalizando 91 pontos com dados conhecidos. Foram elaborados, através, portanto, da interpolação por *krigagem*, mapas mensais da distribuição das quatro variáveis no território mineiro, sobre os quais lançou-se arbitrariamente uma malha de 8.400 células (100 linhas por 84 colunas), cada uma delas com 96 km<sup>2</sup> (12 km de espaçamento em longitude por 8 km de espaçamento em latitude). Para cada célula foram lidas as coordenadas geográficas e os valores interpolados das variáveis climáticas no ponto central. A base de dados assim gerada alimentou um algoritmo das Tabelas de Mahoney, desenvolvido no programa MatLab®, tendo como parâmetro de saída, para cada ponto, um vetor de 22 posições booleanas (0 – não – ou 1 – sim) correspondentes a cada uma das recomendações das Tabelas de Mahoney. Os resultados obtidos foram agrupados segundo alguns critérios apresentados adiante, gerando um mapa de zoneamento bioclimático do estado com seis zonas. Este trabalho foi considerado preliminar, pois observou-se como um dos seus maiores limites a não consideração do efeito da altitude no processo de interpolação das variáveis climáticas. Apresenta-se aqui um aperfeiçoamento daquele resultado de classificação através da aplicação de redes neurais artificiais (RNA), cujo processo de treinamento não apenas indicou a necessidade de verificação da base original de dados para corrigir eventuais erros, como também permitiu incluir a variável de altitude na estimativa dos dados climáticos, tornando o resultado de classificação bioclimática mais confiável.

### 1.1 Uso de Redes Neurais Artificiais para a estimativa de dados complexos

Nos últimos anos, as Redes Neurais Artificiais (RNA), principais representantes da área conexionista da Inteligência Artificial, têm sido aplicadas nas mais diversas áreas do conhecimento. Uma rede neural é extremamente útil para representar processos físicos quando modelos baseados na física do fenômeno podem resultar em modelos matemáticos de grande complexidade analítica e/ou numérica.

As RNA utilizam dados medidos diretamente de um processo em estudo representando o fenômeno em condições reais. São capazes de lidar com problemas não-lineares, resolver situações não vistas em seu processo de treinamento (ajuste do modelo), obter as relações entre atributos de entrada e saída como uma função entre esses parâmetros, na qual parâmetros de entrada são mapeados em parâmetros de saída. Além disso, possuem um alto desempenho computacional quando se encontram em operação.

Devido a essas características, alguns pesquisadores (KALOGIROU; PANTELIOU; DENTSORAS, 1999; KALOGIROU, 2000; ZÁRATE *et al.* 2003; ZÁRATE *et al.* 2004a e ZÁRATE *et al.* 2004b) têm discutido sua utilização na representação de sistemas de energia solar, dentre outros, envolvendo condições ambientais e meteorológicas. Já outros trabalhos procuraram estimar e predizer parâmetros climáticos utilizando as redes neurais (ZHANG; TRINMBLE, 1996; McCULLAGH, 2005).

Neste trabalho, as RNA foram utilizadas para a estimativa de dados climatológicos do estado de Minas Gerais considerando todos os parâmetros de posição (latitude, longitude e altitude), dados estes usados para aperfeiçoar os resultados da classificação de zoneamento bioclimático de seu território, com base num algoritmo anteriormente desenvolvido das Tabelas de Mahoney.

## 2 OBJETIVO

O objetivo deste artigo é apresentar os procedimentos utilizados para a representação neural: pré-processamento, treinamento e validação, mostrando os resultados de classificação bioclimática em comparação a resultados obtidos anteriormente (GONÇALVES *et al.*, 2003).

## 3 METODOLOGIA

### 3.1 Redes Neurais

Para a obtenção de um modelo neural capaz de estimar dados climáticos é necessária uma amostra de dados representativa. A base de dados das 91 estações meteorológicas teve, assim, que ser revisada, pois no treinamento preliminar da rede os desvios-padrão foram maiores do que os admitidos para cada variável. Após a revisão, foram utilizados os dados climáticos médios mensais e as coordenadas geográficas e de altitude de 66 estações meteorológicas do 5º Distrito de Meteorologia em Minas Gerais e de mais 15 estações limítrofes de outros estados, estas últimas constantes em Brasil (1992), totalizando 81 estações.

A partir desse mapeamento climatológico, a representação neural será capaz de estimar os dados climáticos a partir das coordenadas geográficas e da altitude de uma localidade qualquer no estado de Minas Gerais. Na Tabela 1 são apresentadas algumas informações estáticas dos dados utilizados no processo de treinamento, para a Latitude ( $La$ ), Longitude ( $Lo$ ), Altitude ( $Al$ ), Temperatura Mínima ( $T_{min}$ ), Temperatura Máxima ( $T_{max}$ ), Umidade Relativa ( $U$ ) e Pluviosidade ( $P$ ).

**Tabela 1** – Informações estáticas das 81 estações meteorológicas para os doze meses do ano

	$La$ (°S)	$Lo$ (°O)	$Al$ (m)	$T_{min}$ (°C)	$T_{max}$ (°C)	$U$ (%)	$P$ (mm)
Mínimo	-22,38	-51,11	3,87	4,70	20,10	20,80	1,20
Máximo	-13,16	-38,57	1296,12	22,40	34,70	88,70	454,10
Média	-18,72	-44,44	688,16	16,54	28,20	74,57	112,17
Desvio Padrão	2,37	2,54	294,55	3,18	2,63	7,79	91,69

Para a estimativa da Temperatura Mínima ( $T_{min}$ ), da Temperatura Máxima ( $T_{max}$ ), da Umidade Relativa ( $U$ ) e da Pluviosidade ( $P$ ), quatro representações neurais foram consideradas:

$$f(La, Lo, Al) \xrightarrow{RNA} T_{\min} \quad (\text{eq. 1})$$

$$f(La, Lo, Al) \xrightarrow{RNA} T_{\max} \quad (\text{eq. 2})$$

$$f(La, Lo, Al, T_{\min}, T_{\max}) \xrightarrow{RNA} U \quad (\text{eq. 3})$$

$$f(La, Lo, Al, U) \xrightarrow{RNA} P \quad (\text{eq. 4})$$

É importante notar que o modelo para estimativa da Umidade Relativa (eq. 3) utiliza os valores da Temperatura Mínima e Máxima fornecidos pelos modelos das eq. (1) e (2) respectivamente, enquanto que o modelo para estimativa da Pluviosidade (eq. 4) utiliza os valores da Umidade Relativa fornecidos pela eq. (3).

Nos modelos propostos foram utilizadas redes multicamada, *feedforward* e totalmente comentadas onde o número escolhido de neurônios na camada oculta, como sugerido por Kovacs (1996), foi  $2N+1$ , sendo  $N$  o número de entradas. Já como função de ativação, a função *log sigmóide* foi aplicada (eq. 5) e as redes foram treinadas com o algoritmo *Backpropagation*.

$$f = \frac{1}{1 + \exp^{-\sum \text{Entries} \times \text{Weights}}} \quad (\text{eq. 5})$$

### 3.1.1 Preparação dos Dados

Para facilitar a convergência dos dados durante o processo de treinamento é necessário um processo de normalização, que consiste na padronização dos dados em uma faixa de valores. Desta forma, o seguinte procedimento foi aplicado para os dados coletados, antes da utilização dos mesmos na rede neural:

- Os dados foram normalizados no intervalo de [0,2; 0,8]. Quando se utiliza a função de ativação *log sigmóide* (eq. 5), melhores valores são encontrados nesse intervalo (ALTINCAY; DEMIREKLER, 2002; TARCA; COOKE, 2005);
- Os dados foram normalizados através das seguintes fórmulas:

$$f^a(Lo) = Ln = (Lo - L\min) / (L\max - L\min) \quad (\text{eq. 6a})$$

$$f^b(Ln) = Lo = Ln * L\max + (1 - Ln) * L\min \quad (\text{eq. 6b})$$

Onde  $Ln$  é o valor normalizado,  $Lo$  é o valor para normalizar,  $L\min$  e  $L\max$  são os valores mínimo e máximo de cada variável respectivamente.

- $L\min$  e  $L\max$  foram calculados através das seguintes fórmulas:

$$L\min = (4 \times \text{LimiteInf} - \text{LimiteSup}) / 3 \quad (\text{eq. 7a})$$

$$L\max = (\text{LimiteInf} - 0,8 \times L\min) / 0,2 \quad (\text{eq. 7b})$$

As eq. (7a) e (7b) foram obtidas substituindo na eq. (6a)  $Ln = 0,2$  e  $Lo = \text{LimiteInf}$ ; e  $Ln = 0,8$  e  $Lo = \text{LimiteSup}$ , sendo *LimiteInf* e *LimiteSup* os valores mínimo e máximo, respectivamente, do conjunto de dados originais.

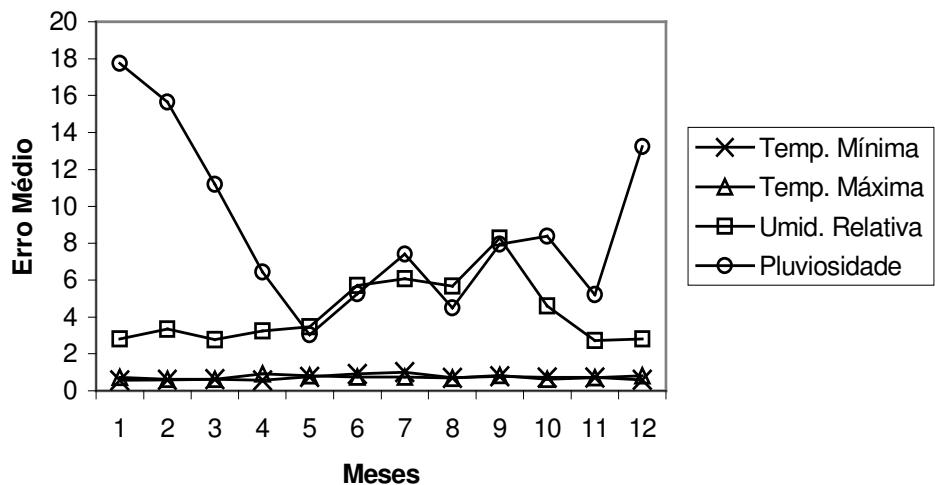
### 3.1.2 Treinamento e Validação

No processo de treinamento da rede foi admitido um erro de 1,3°C para as Temperaturas Mínima e Máxima, eq. (1) e (2) respectivamente. Já para a Umidade Relativa, eq. (3), foi admitido um erro de 4% e para a Pluviosidade, eq. (4), um erro de 46 mm<sup>1</sup>. Para cada modelo neural foram realizados 12 treinamentos, um para cada mês. Desta forma, os dados utilizados em cada treinamento apresentavam um desvio padrão menor, proporcionando, assim, dados mais estáveis para o processo de treinamento.

Na Tabela 2, o erro médio obtido nos treinamentos é apresentado. A Umidade Relativa e a Pluviosidade apresentaram um erro médio maior, pois, devido à maior variabilidade nos dados de treinamento, ocorreu um maior desvio padrão no processo de operação da RNA. Os resultados podem ser considerados satisfatórios, porém percebe-se que tendo essas duas variáveis um comportamento diferente durante o ano ao longo do território do estado, mais seco ao norte e mais chuvoso e úmido ao sul, talvez fosse possível diminuir o erro treinando a rede não apenas mês a mês, mas também por região. Em relação aos modelos responsáveis pela estimativa da Temperatura Mínima e Máxima os resultados foram excelentes, visto que o erro médio dos treinamentos ficou abaixo do erro esperado. Já na figura 1 pode-se observar o erro médio dos modelos obtido para cada mês; novamente nota-se o mesmo comportamento.

**Tabela 2** - Erro médio obtido para o processo de treinamento

Erro	$T_{min}$ (°C)	$T_{max}$ (°C)	U (%)	P (mm)
Mínimo	0,024	0,0156	0,122	0,119
Máximo	2,023	2,273	12,004	31,172
Média	0,714	0,739	4,292	8,834
Desvio Padrão	0,504	0,546	2,986	7,539



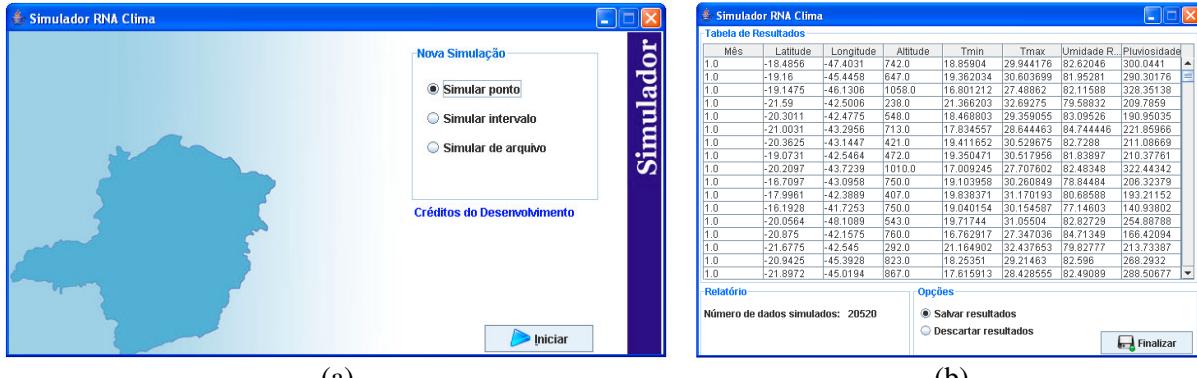
**Figura 1** – Erro obtido para cada mês

Como o objetivo da utilização das redes neurais é a realização da estimativa de dados climatológicos, optou-se pela utilização de 100% dos dados no processo de treinamento. Já para o processo de validação, foram realizadas comparações com resultados obtidos por métodos geoestatísticos, aplicados em trabalho anterior (GONÇALVES *et al.*, 2003).

<sup>1</sup> Esses valores correspondem aproximadamente à variação considerada normal:  $E = 0,5 \times DP$ , onde  $E$  é o erro admitido;  $DP$  é o desvio padrão da série de cada variável (Tabela 1).

### 3.1.3 Simulador Climático

Para proporcionar uma fácil utilização dos modelos neurais construídos foi desenvolvido um simulador climático denominado *RNAClima* (figura 2). O simulador, implementado segundo o paradigma de orientação por objetos, proporciona uma fácil manipulação para estimar valores dos dados climáticos para o estado de Minas Gerais.



**Figura 2** – (a) Opções de simulação; (b) Tela de exemplo de resultado de uma simulação (para o mês de janeiro)

## 3.2 Classificação

Uma vez treinada a rede, a próxima etapa consistiu no levantamento, junto ao poder público do estado, de todas as localidades mineiras que possuíam coordenadas geográficas de posição e altitude. Obteve-se 1.628 pontos distribuídos não homogeneamente pelo território do estado que, somados aos dados das 81 localidades usadas no treinamento da rede, perfazem um total de 1.709 pontos.

Os dados de latitude, longitude e altitude dos 1.709 pontos foram organizados numa planilha lida pelo simulador climático, que calculou, para cada mês, os dados de Temperatura Máxima e Mínima, Umidade Relativa e Pluviosidade em cada ponto. Esta nova base de dados climáticos (os estimados pelo simulador mais as 81 localidades com dados medidos) foi utilizada no algoritmo das Tabelas de Mahoney anteriormente desenvolvido no programa MatLab®. Obteve-se, assim, para cada ponto, um vetor com as 22 posições correspondentes às recomendações arquitetônicas do método de Mahoney, como mostra a Tabela 3 a seguir.

Os pontos com vetores idênticos foram agrupados com pontos com vetores considerados semelhantes, de acordo com os mesmos critérios adotados no trabalho anterior, para permitir a comparação entre os resultados, a saber:

- Os resultados das recomendações arquitetônicas na comparação para reagrupamento não podem ser contraditórios, especialmente no que diz respeito a: dimensões das aberturas (9, 10, 11, 12 e 13); tipo de paredes (18 e 19) e coberturas (20, 21 e 22);
- Recomendações para tipo de coberturas com isolamento térmico (21) ou com câmara de ar e superfície refletora (20) foram consideradas semelhantes

Ainda para permitir a comparação com o resultado da classificação anterior, foi utilizado o método *nearest neighbour* do programa Surfer® para espacializar o resultado dos 1.709 pontos na malha anteriormente adotada de 100 linhas por 84 colunas sobre o território do estado. Esse método não faz interpolação, propaga o valor do ponto para os seus vizinhos mais próximos, considerando a "área de influência" de cada ponto, em relação aos demais.

**Tabela 3 – Recomendações arquitetônicas das Tabelas de Mahoney**

Categoría	Recomendação
Planta de situação:	1 Construções orientadas segundo eixo longitudinal leste-oeste a fim de diminuir a exposição ao sol; 2 Plantas compactas com pátios internos;
Espaçamento entre construções:	3 Grandes espaçamentos para favorecer a penetração do vento; 4 Como anterior, mas com proteção contra vento quente ou frio; 5 Distribuição compacta;
Circulação de ar:	6 Construções com orientação simples, aberturas que permitam circulação de ar permanente; 7 Construções com orientação dupla, circulação de ar cruzada, aberturas de ar controláveis; 8 Basta renovação higiênica do ar;
Dimensões das aberturas:	9 Grandes: 40% a 80% das fachadas norte e sul; 10 Médias: 25% a 35% da superfície das paredes; 11 Pequenas: 15% a 25% da superfície das paredes; 12 Muito pequenas: 10 a 20% das paredes; 13 Médias: 25% a 35% da superfície das paredes (com indicador A3)
Posição das aberturas:	14 Aberturas nas paredes norte e sul, à altura do corpo humano, do lado exposto ao vento; 15 Como anterior, mas também aberturas nas paredes internas;
Proteção das aberturas:	16 Proteger da insolação direta; 17 Proteger da chuva;
Paredes e pisos:	18 Construções leves, baixa inércia térmica; 19 Construções maciças, atraso térmico superior a 8 horas;
Cobertura:	20 Leve (pouca inércia), superfície refletora, uso de câmara de ar; 21 Leve e bem isolada; 22 Maciça, tempo de transmissão térmica superior a 8 horas.

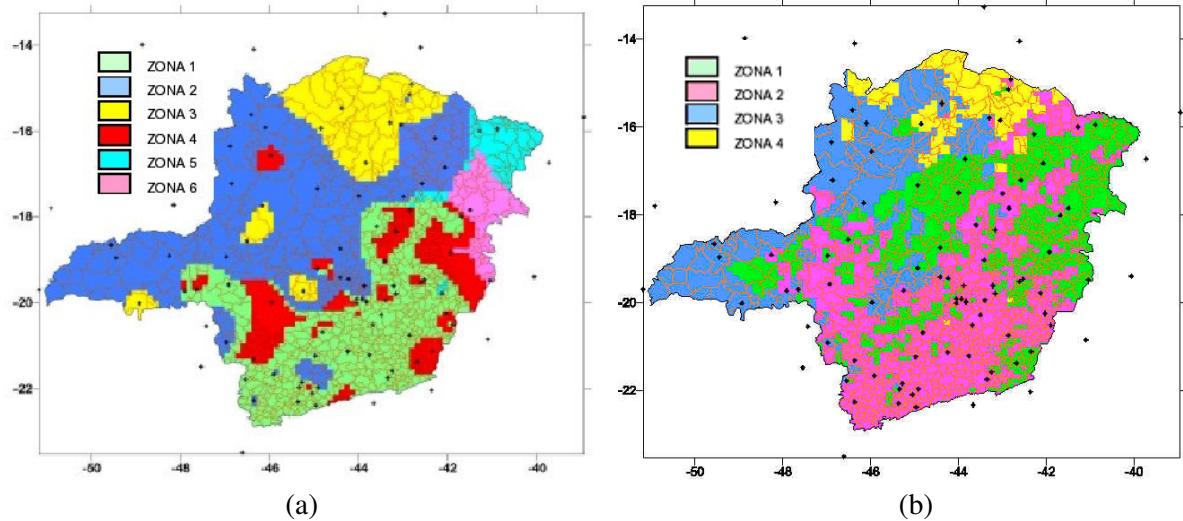
#### 4 ANÁLISE DE RESULTADOS

Após aplicar as Tabelas de Mahoney para os 1.709 pontos do território mineiro, verificou-se a ocorrência de 16 grupos de vetores onde as 22 recomendações resultaram iguais. Sendo este número de grupos considerado excessivo para definir o zoneamento bioclimático, os pontos foram, então, reagrupados, através da comparação entre as características dos grupos, resultando em 4 grupos (ou seja, zonas bioclimáticas), como mostra a figura 3.

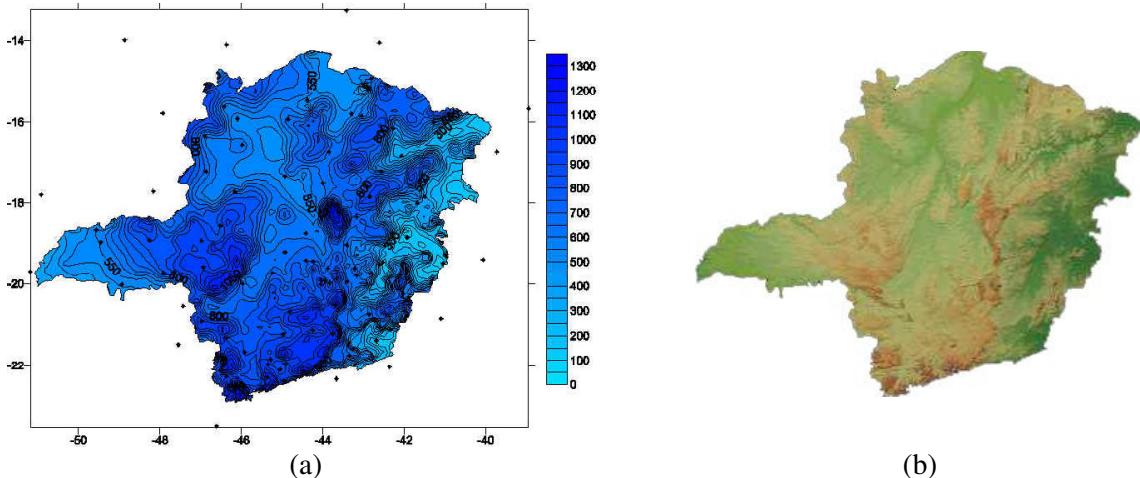
ZONA	GRUPO	RECOMENDAÇÕES ARQUITETÔNICAS																						TOTAL EM 1712	SUBTOT %	TOTAL %
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22			
1	1	1	0	0	1	0	1	0	0	0	1	0	0	0	1	0	0	1	0	1	0	0	0	194	11,33%	30,72%
	9	1	0	1	0	0	1	0	0	0	1	0	0	0	1	0	0	1	0	1	0	0	0	87	5,08%	
	3	1	0	0	1	0	1	0	0	0	1	0	0	0	1	0	0	0	1	0	1	0	0	90	5,26%	
	10	1	0	0	1	0	1	0	0	0	1	0	0	0	1	0	0	1	0	1	0	0	0	1	0,06%	
	4	1	0	1	0	0	1	0	0	0	1	0	0	0	1	0	0	0	1	0	1	0	0	135	7,89%	
	7	1	0	1	0	0	1	0	0	0	1	0	0	0	1	0	1	0	1	0	1	0	0	19	1,11%	
2	5	1	0	0	1	0	1	0	0	0	1	0	0	0	1	0	0	0	1	0	0	1	0	78	4,56%	51,52%
	2	1	0	0	1	0	1	0	0	0	1	0	0	0	1	0	0	1	1	0	0	1	0	800	46,73%	
	12	1	0	0	0	1	1	0	0	0	1	0	0	1	0	0	1	1	0	0	1	0	0	4	0,23%	
3	6	1	0	0	1	0	1	0	0	0	1	0	0	0	1	0	0	1	0	1	0	1	0	216	12,62%	12,79%
	15	1	0	0	0	1	1	0	0	0	1	0	0	0	1	0	0	1	0	1	0	1	0	1	0,06%	
	16	1	0	0	1	0	1	0	0	0	1	0	0	0	1	0	1	1	0	1	0	1	0	2	0,12%	
4	8	1	0	0	1	0	1	0	0	0	1	0	0	0	1	0	0	0	1	0	1	0	0	77	4,50%	4,96%
	13	1	0	0	1	0	1	0	0	0	1	0	0	0	1	0	0	1	0	1	0	1	0	6	0,35%	
	14	1	0	0	1	0	1	0	0	0	0	1	0	0	1	0	0	0	1	0	0	1	0	1	0,06%	
	11	1	0	0	1	0	1	0	0	0	0	1	0	0	1	0	0	1	0	1	0	0	1	1	0,06%	

**Figura 3 – Reagrupamento dos 16 grupos obtidos pela aplicação das Tabelas de Mahoney à base de dados climáticos gerados pelo simulador RNA Clima; a antepenúltima coluna informa o número de células em cada grupo e a última coluna o percentual do território classificado na zona**

A figura 4 mostra uma comparação entre os resultados de classificação obtidos no trabalho anterior (a) e neste (b), onde se pode observar que a classificação resultante dos dados simulados pela RNA parece captar melhor a influência da altitude (figura 5) na definição das zonas semelhantes.



**Figura 4** – Em (a) resultado preliminar de zoneamento bioclimático com base nas Tabelas de Mahoney e na interpolação de dados climáticos por *krigagem*, sem considerar a altitude. Em (b) o resultado com base nos dados climáticos estimados pelo simulador RNA Clima.



**Figura 5** – Em (a) mapa resultante da interpolação dos dados de altitude dos 1.709 pontos e em (b) mapa de relevo, elaborado pela EMBRAPA usando imagens de satélite, mostrando que há bastante concordância entre eles. Imagem disponível em <http://www.relevobr.cnpm.embrapa.br>

Com relação às recomendações obtidas, nota-se em todo o território a necessidade de diminuir a exposição das edificações ao sol na implantação no terreno, bem como de grandes espaçamentos entre as edificações para favorecer a penetração do vento, porém com proteção contra situações em que possa provocar desconforto por estresse térmico de calor ou frio. Isso indica não apenas a necessidade de aprofundamento na identificação de aspectos climáticos locais, mas também deve trazer repercussões às leis municipais de parcelamento e de uso e ocupação do solo, uma vez que a orientação solar e aos ventos das edificações é fortemente influenciada pelo tamanho e orientação do lote.

As aberturas devem ser de tamanho médio (25 a 35% da superfície das paredes), à altura do corpo humano, havendo a indicação de circulação de ar permanente. Entretanto, considerando que ocorrem situações de estresse térmico de frio durante o inverno em muitas regiões, a recomendação mais

adequada deveria ser a de ventilação cruzada com aberturas de ar controláveis. As maiores diferenças entre as zonas ocorrem com relação ao desempenho das envoltórias, sendo que em 82,2% dos casos ocorreu a recomendação de construções leves, com baixa inércia térmica. A recomendação de paredes e pisos com características maciças e tempo de transmissão térmica superior a 8 horas ocorreu em apenas 17,8% dos casos, correspondendo às zonas 3 e 4, que necessitam de algum aquecimento no inverno através da inércia térmica da construção, porém têm verões quentes, de modo que a cobertura, parte da construção mais exposta à trajetória aparente do sol, deve ser isolada. De fato, em 69,2% dos casos as coberturas devem ser leves e bem isoladas. A Tabela 4 mostra as recomendações aplicáveis a cada zona.

**Tabela 4 –** Recomendações arquitetônicas aplicáveis em cada zona bioclimática

Zona	Recomendações aplicáveis
1	1, 4*, 6, 10, 14, 17*, 18, 20
2	1, 4, 6, 10, 14, 16, 17*, 18, 21
3	1, 4, 6, 10, 14, 17, 19, 21
4	1, 4, 6, 10* ou 11*, 14, 16, 19, 21* ou 22*

(\*) requer análise dos dados locais pois não se aplica a uma pequena porção da área da zona.

Um resultado discrepante, além do número de zonas encontradas, com relação à classificação anterior é que nela em todas as zonas ocorreu a recomendação de proteger as aberturas contra a insolação direta (16), o que agora ocorreu apenas na zona 2, embora abranja mais de 50% do território.

## 5 CONSIDERAÇÕES FINAIS

A utilização das RNA para a estimativa de dados climáticos diminuiu o tempo de processamento para a obtenção de resultados, bem como aumentou a confiabilidade dos dados utilizados. Os modelos neurais construídos demonstram ser capazes de representar adequadamente o fenômeno climático quando comparados com os métodos anteriormente adotados.

Através do simulador *RNAClima* desenvolvido foi possível a fácil manipulação dos dados, criando condições para a análise dos resultados fornecidos pelo modelo neural e comparando-o com os resultados fornecidos por métodos geoestatísticos para a interpolação de dados, que não consideram o parâmetro de altitude, de grande influência no caso de dados climáticos.

Quanto à classificação bioclimática com base nas Tabelas de Mahoney, Assis (2001) já observara que apesar do método ter a vantagem de gerar recomendações específicas para a concepção arquitetônica, o ideal seria, dada a sua generalidade, cruzar as informações obtidas com os resultados de índices de conforto validados para as diversas regiões do estado de Minas Gerais, o que, entretanto, ainda não há. Além disso, o processo de agrupamento dos pontos pode ainda ser bastante aperfeiçoado com a aplicação de algum método estatístico de agrupamento.

## 6 REFERÊNCIAS

ALTINÇAY, H.; DEMIREKLER, M. Why does output normalization create problems in multiple classifier systems? In: INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION, 16<sup>th</sup>, August 2002, Quebec, Canada. **Proc. ICPR**, vol. 2. Quebec: IEEE Express, 2002, p. 775-778.

ASSIS, E. S. Método integrado para análise climática em arquitetura aplicado à cidade de Belo

- Horizonte, MG. In: ENCONTRO NACIONAL DE CONFORTO NO AMBIENTE CONSTRUÍDO, 6º, 2001, S. Pedro. **Anais...** Campinas: ANTAC, Roriz, M. e Labaki, L. C, (ed.), 2001, 8 p. CD-ROM
- BRASIL, Ministério da Agricultura e Reforma Agrária. **Normais Climatológicas 1961-1990.** Brasília: Dep. Nacional de Meteorologia, 1992.
- CAMARGO, E. C. G. Geoestatística: fundamentos e aplicações. In: INSTITUTO de Pesquisas Espaciais. **Geoprocessamento para Projetos Ambientais.** 2ª ed., São José dos Campos: INPE, 1998, p. 5.1-5.36.
- GONÇALVES, W. B.; RIBEIRO, M. A.; ASSIS, E. S. et al. Estudo de zoneamento bioclimático para o estado de Minas Gerais com base nas Tabelas de Mahoney - considerações sobre a metodologia e resultados preliminares. In: ENCONTRO NACIONAL DE CONFORTO NO AMBIENTE CONSTRUÍDO, 7º, 2003, Curitiba. **Anais...** São Paulo: ANTAC/PUC-PR, 2003, p. 241-248. CD-ROM
- KALOGIROU, S. A.; PANTELIOU S.; DENTSORAS, A. Modeling solar domestic water heating systems using ANN, **Solar Energy**, vol. 68, nº 6, 1999, p. 335-342.
- KOVACS, Z. L. **Redes Neurais Artificiais.** [Cap. 5], São Paulo: Edição Acadêmica, 1996, p. 75-76.
- McCULLAGH, J. A modular neural network architecture for rainfall estimation, **Artificial Intelligence and Applications**, Innsbruck, Austria, 2005, p. 767-772.
- ORGANIZAÇÃO das Nações Unidas (ONU). **Climate and House Design: Design of Low-cost Housing and Community Facilities.** New York: United Nations, vol. 1, 1971.
- PEZZOPANE, J. E. M.; SANTOS, E. A.; ELEUTÉRIO, M. M. et al. Espacialização de temperatura do ar no estado do Espírito Santo, **Rev. Bras. Agrometeorologia**, vol. 12, nº 1, 2004, p. 151-158.
- RORIZ, M. Um método para a interpolação de dados climáticos. In: ENCONTRO NACIONAL DE CONFORTO NO AMBIENTE CONSTRUÍDO, 5º, Fortaleza, 1999. **Anais...** São Paulo: ANTAC, 1999, 10 p. CD-ROM
- TARCA, A. L.; COOKE, J. E. A robust neural network approach for spatial and intensity-dependent normalization of cDNA microarray data, **Bioinformatics**, vol. 21, nº 11, 2005, p. 2674-2683.
- ZÁRATE, L. E.; PEREIRA, E. M.; SILVA, J. P.; VIMIEIRO R.; DINIZ, A. S. A.; PIRES, S. Representation of a solar collector via artificial neural networks. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND APPLICATIONS, September 2003, Benalmádena, Spain. Hamza, M. H. (ed.) **International Conference on Artificial Intelligence and Applications**, IASTED: ACTA Press, 2003, p. 517-522.
- ZÁRATE, L. E.; PEREIRA, E. M.; VIMIEIRO, R.; SILVA, J. P.; SOARES, D. A. Neural representation of a solar collector with statistical optimization of the training sets. In: IEA/AIE, ACM INTERNATIONAL CONFERENCE ON INDUSTRIAL AND ENGINEERING APPLICATIONS OF ARTIFICIAL INTELLIGENCE AND EXPERTS SYSTEMS, 17<sup>th</sup>, 2004, Ottawa, Canada. **Otawa Lecture Notes in Computer Science (LNCS/LNIAI)**, Springer-Verlag, vol. 1, 2004a, p. 87-96.
- ZÁRATE, L. E.; PEREIRA, E. M.; VIMIEIRO, R.; SILVA, J. P.; SOARES, D. A. Optimization of neural network's training sets via clustering: application in solar collector representation. In: INTERNATIONAL CONFERENCE ON ENTERPRISE INFORMATION SYSTEMS, 6<sup>th</sup>, 2004, Porto, Portugal. **Proceedings...**, vol. 2. Porto: ACM/AAAI, 2004b, p. 104-109.
- ZHANG, E.; TRINMBLE, P. Predicting effects of climate fluctuations for water management by applying neural networks, **World Resource Review**, vol. 8, nº 3, 1996, p. 1-18.

## 7 AGRADECIMENTOS

Os autores gostariam de agradecer à FAPEMIG, pelo apoio financeiro através do convênio EDT2168, bem como ao 5º DISME/INMET pela cessão dos dados climáticos não publicados de algumas de suas estações meteorológicas.