

Aplicação de um modelo de redes neuronais na elaboração de mapas de susceptibilidade a movimentos de vertente. Um exemplo numa área a sul de Coimbra (Portugal Central)

Luca António Dimuccio

Departamento de Ciências da Terra, Universidade de Coimbra. luca@ci.uc.pt

Rui Ferreira

Lúcio Cunha

Centro de Estudos Geográficos, Universidade de Coimbra. ruiff@ci.uc.pt; luciogeo@ci.uc.pt

Resumo Na sequência de um primeiro trabalho sobre cartografia de riscos naturais através da utilização de ferramentas SIG, para uma pequena área a Sul de Coimbra, procura-se agora aprofundar a aplicação de novas metodologias de tratamento de informação (Redes Neuronais) que permitam superar algumas debilidades evidenciadas nessa primeira abordagem. Utilizou-se uma ferramenta SIG para criar uma base de dados espacial onde foi registada a localização dos movimentos ocorridos no Inverno de 2000/2001, as características topográficas da área (declive), o uso do solo e a litologia. Depois, procedeu-se ao treino do algoritmo da rede neuronal, confrontando as matrizes representativas das variáveis utilizadas com a matriz onde estavam registados os movimentos ocorridos. O mapa de susceptibilidade obtido, comparado com os elaborados através de outras metodologias para a mesma área, mostra uma concordância muito mais acentuada entre as metodologias qualitativas e a modelação baseada na rede neuronal, o que nos parece traduzir uma maior fiabilidade desta última metodologia relativamente aos métodos estatísticos antes utilizados.

Palavras-chave: Redes Neuronais, Mapas de Susceptibilidade a Movimentos de Vertente, Sul de Coimbra.

Abstract *Use of an artificial neural network for analysis of the susceptibility to landslides. Application to a sample area located at South of Coimbra (Central of Portugal).*

After a first work on the cartography of natural risks through the use of GIS tools, that two of the authors had published in the magazine Territory n. 9 (2002), we intend now to develop a methodology to assessment landslide susceptibility based on the use of a Artificial Neural Network applied to the same study area (South of Coimbra – Central of Portugal). As the basic analysis tool, a Geographic Information System (SIG) was used for spatial data management and manipulation. Landslide locations and landslide-related factors such as slope, soil use and litology were used for analyzing landslide susceptibility. A statistic method was used to calculating the rating of the relative importance of each factor class to landslide occurrence. For calculating the weight of the relative importance of each factor to landslide occurrence, an artificial neural network method was applied. With these methods, the landslide susceptibility index was calculated using the rating and weight, and a landslide susceptibility map was produced. The comparison with the landslide susceptibility maps made with others methodologies in the same area, shows an agreement much more clear between the qualitative methodology based on a close knowledge of the study area, and the neural network methodology, what seems to translate a bigger reliability of this last methodology to model the susceptibility to landslides.

Key-words: Artificial Neural Networks, Landslides Susceptibility Maps, South of Coimbra.

1. INTRODUÇÃO

O desenvolvimento deste trabalho insere-se no quadro de um conjunto de experiências que têm vindo a ser realizadas por dois dos autores da presente comunicação na tentativa de modelar a susceptibilidade geomorfológica numa área a Sul de Coimbra. A área escolhida corresponde, grosso modo, a uma faixa de transição tanto no que se refere ao quadro geohumano, como ao quadro natural. No primeiro, corresponde a um sector peri-urbano, com características ainda marcadamente rurais,

mas onde se começam a notar já alguns efeitos da pressão expansiva da cidade, nomeadamente, em termos de edificação, densificação das vias de circulação e de tráfego ou mesmo nas alterações do uso dos solos ou simples abandono dos campos agrícolas, sujeitos, depois, aos efeitos da especulação imobiliária. No segundo, trata-se de uma área situada no contacto entre o Maciço Hespérico e a Orla Mesoceno-zóica Ocidental, oferecendo uma variedade litológica assinalável, com uma fracturação abundante, uma diversidade de declives considerável e uma matriz muito diversificada de usos do solo¹.

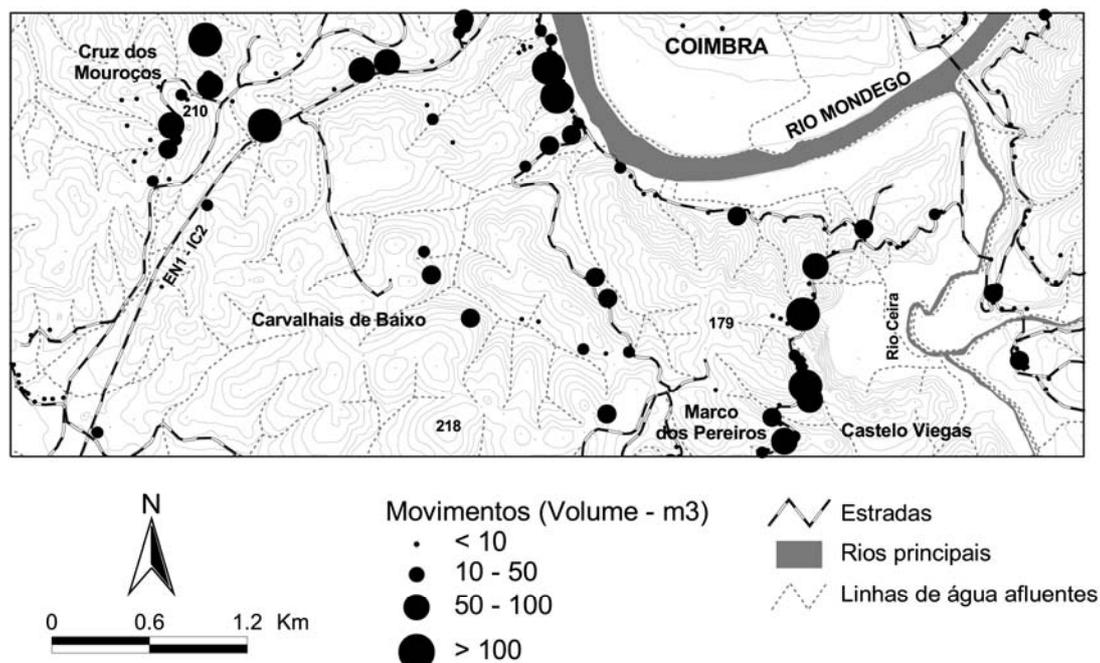


Fig. 1 – Enquadramento geográfico da área em estudo e localização dos movimentos de vertente inventariados no Inverno 2000/2001.

Estas condições geohumanas e naturais, quando conjugadas com episódios de maior pluviosidade, induzem fenómenos de instabilidade nas vertentes que se manifestam por movimentações de dimensão e tipo variáveis. No Inverno de 2000/2001 foram inventariados e georreferenciados, em 18 Km² da área em estudo, 164 movimentos, alguns deles com volumetrias consideráveis (Fig. 1).

Com base neste levantamento foram já elaborados num trabalho anterior (Cunha e Dimuccio, 2002) vários ensaios de cartografia de susceptibilidade a movimentos de vertente baseados em diferentes metodologias, qualitativas e quantitativas (Fig. 2), pretendendo-se com o presente trabalho aprofundar as potencialidades oferecidas pelas metodologias quantitativas, testando a aplicação de uma rede de neurónios artificiais – *Artificial Neural Network* – na modelação da susceptibilidade a movimentos de vertente (Lee *et al.*, 2004; Lee *et al.*, 2003a; Lee *et al.*, 2003b)².

¹ As características litológicas, geomorfológicas e de uso do solo desta pequena área a Sul de Coimbra estão descritas e representadas através diferentes mapas temáticos em Cunha e Dimuccio (2002).

² No entanto, é importante sublinhar que todas estas metodologias têm inerente um certo grau de incerteza dos resultados obtidos, devido sobretudo à necessidade de generalizar e simplificar o geossistema (todos os modelos são, por definição, uma representação esquemática da realidade devido à falta de informação e elevado número de variáveis em jogo e às dificuldades em compreender cabalmente a interacção entre todas estas variáveis).

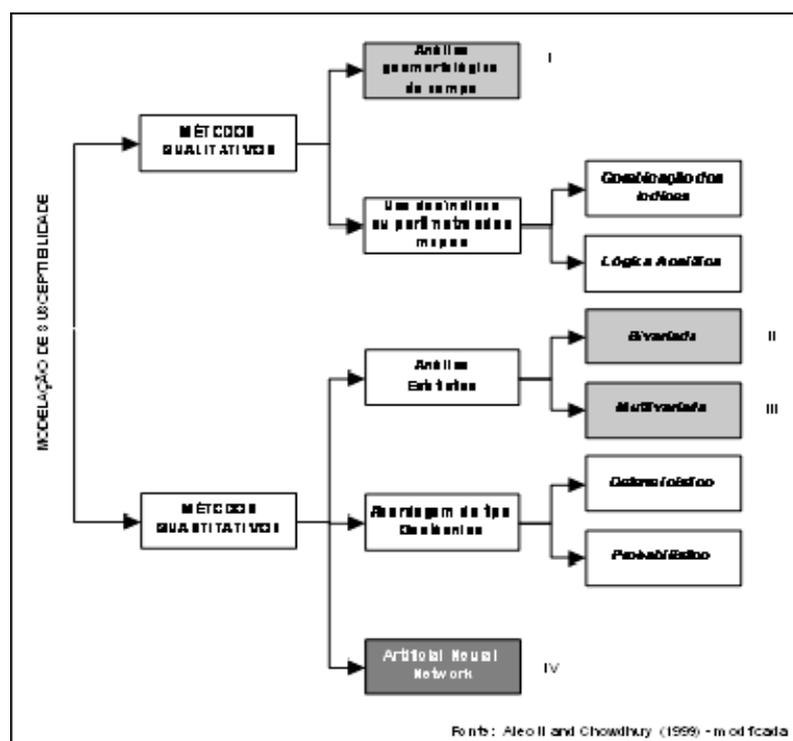


Fig. 2 – Esquema das diferentes metodologias que podem ser adoptadas para a elaboração de mapas de susceptibilidade aos movimentos de vertente (I, II e III foram utilizadas no trabalho anterior de Cunha e Dimuccio - 2002).

Para testar os vários métodos de avaliação da susceptibilidade e de forma a manter o modelo mais ou menos controlável do ponto de vista da compreensão do papel desempenhado por cada factor na explicação da distribuição espacial dos movimentos registados, foram utilizados apenas três factores ou variáveis de entrada, considerados mais relevantes no contexto da área em estudo: a litologia, os declives e os modos de uso do solo.

2. DETERMINAÇÃO DO VALOR DE CADA CLASSE DOS FACTORES CONSIDERADOS

O principal problema para a cartografia automática da susceptibilidade prende-se com a arbitrariedade das valorações associadas a cada classe e a cada factor considerados, pelo que se tentou recorrer a uma metodologia que permitisse minimizar as subjectividades intrínsecas ao processo de definição das relações matemáticas entre os vários factores, as classes neles definidas e o número, e respectiva localização, dos movimentos ocorridos.

Uma das primeiras questões a ultrapassar resulta das interdependências que se estabelecem entre os factores de entrada. As que de forma mais saliente se evidenciam são as relativas ao declive. Os declives determinam as condições de energia potencial e cinética para os movimentos; estão na dependência da estrutura (litologia e tectónica) e das condições de evolução geomorfológica; por sua vez, vão condicionar a própria litologia ao ditarem os locais de acumulação dos depósitos superficiais, condicionam os modos de ocupação do solo e assumem um papel fundamental na explicação dos movimentos ocorridos em áreas de forte intervenção humana (que, no sector em estudo, assumem grande preponderância).

Para além destes aspectos, os declives surgem também como o factor que melhor se correlaciona com os movimentos de vertente sendo, por isso, considerados como a variável mais importante para a sua explicação.

Assim, em função desta constatação, neste processo de modelação da susceptibilidade aos movimentos de vertente, começou-se por calcular o peso dos declives na explicação da distribuição dos movimentos registados, aplicando-se para o efeito um modelo estatístico de regressão linear. Para tentar isolar a influência dos outros dois factores, foi retirado o peso já explicado pelo factor declive nos índices que relacionavam a distribuição do número de movimentos em cada classe litológica e de uso do solo com o número total de movimentos registado para o conjunto da área, determinan-se assim a valoração atribuída a cada classe de factor considerado³ (Fig. 3).

		A	B	C	D	E	F	G	H	
		D=C/Tot C			F = 1,507E - 9,1716		G=C - F		H=G/Tot G	
FACTOR	CLASSE	Área (Km ²)	Nº Mov.	Mov/Km ²	Índice relativo	Declive médio	Infl. Declives Mov/Km ²	Diferença Mov/Km ²	ÍNDICE	NORMALIZAÇÃO ÍNDICE
Litologia	Calc + Calc dolom.	4,35	10	2,30	0,25	10,00	5,90	-3,60	-1,28	0,0
	Xistos	0,81	14	17,28	1,88	18,00	17,96	-0,67	-0,24	2,5
	Calc. Marg. + Margas	0,97	12	12,37	1,35	9,00	4,39	7,98	2,83	10,0
	Grés consol.	6,74	92	13,65	1,49	13,10	10,57	3,08	1,09	5,8
	Dep. Gres. não cons.	5,00	36	7,20	0,78	5,80	-0,43	7,63	2,70	9,7
	Total:	17,90	164	9,18			6,35	3,00		
Uso do solo	Uso Florestal	6,63	62	9,35	1,04	13,20	10,72	-1,37	-0,47	0,0
	Cob. Arbust. e Herb.	0,73	6	8,22	0,91	10,50	6,65	1,57	0,53	3,4
	Uso Agrícola	8,00	64	8,00	0,89	7,90	2,74	5,26	1,80	7,7
	Uso Urbano	2,53	32	12,65	1,41	9,70	5,45	7,20	2,46	10,0
		Total:	17,90	164	9,18			6,24	3,00	
Declive	< 5°	6,20	31	5,00	0,56				0,56	0,0
	5-15°	7,47	43	5,76	0,64				0,64	0,2
	15-30°	3,81	71	18,64	2,07				2,07	3,1
	>30°	0,39	19	48,72	5,41				5,41	10,0
		Total:	17,90	164	9,18					

Fig. 3 – Valores (índice) associados a cada classe para cada uma das variáveis consideradas. Aplicação de um modelo de regressão linear que permitiu isolar a importância de cada um das classes de factores considerados na explicação dos movimentos de vertente, reduzindo-se assim o efeito de interdependência inerente.

3. MODELAÇÃO ATRAVÉS DA UTILIZAÇÃO DE UMA REDE DE NEURÓNIOS ARTIFICIAIS

De uma forma simplista podemos definir uma Rede de Neurónios Artificiais como um mecanismo computacional capaz de adquirir, representar e computar o traçado de um espaço multivariado entre tipos de informações diferentes, através de uma base de dados onde estão armazenadas as variáveis que representam aquele traçado (Garrett, 1994). Trata-se de uma estrutura computacional inspirada nas teorias que explicam o funcionamento biológico do cérebro humano, composta por elementos processadores não lineares densamente interligados e operando em paralelo (os neurónios). A Rede de Neurónios Artificiais é “*treinada*” através de uma base de dados, comparando **dados de entrada** ou de *input* (variáveis do problema) e de **saída** ou *output* (soluções possíveis ou desejadas). Através da Rede de Neurónios Artificiais pode construir-se um modelo de processamento de dados que permita que a rede consiga generalizar e prever saídas a partir de valores de entrada exteriores à área de aprendizagem utilizada para o seu “*treino*” (Paola e Schoweugardt, 1995).

³ A valoração (peso) a atribuir a cada factor (litologia, declive e uso do solo) vai ser calculado através a aplicação da rede neuronal.

As redes neuronais podem ser estruturalmente muito complexas contudo, de uma maneira genérica, a sua estruturação consiste na definição de uma *Layer* de entrada, uma *Layer* de saída e uma ou mais *Layers* intermédias, designadas por *Layers* escondidas (*Neuron Hidden Layer* – Paola e Schoweugerdt, 1995). Em cada uma destas *Layers* pode existir um número variável de “neurónios” que, basicamente, executam somas ponderadas dos valores que lhes chegam pelos canais de interligação com outros neurónios e calculam os valores de saída através de uma função não linear (Fig. 4 – Wang e Raham, 1999; Atkinson e Tatnall, 1997)⁴.

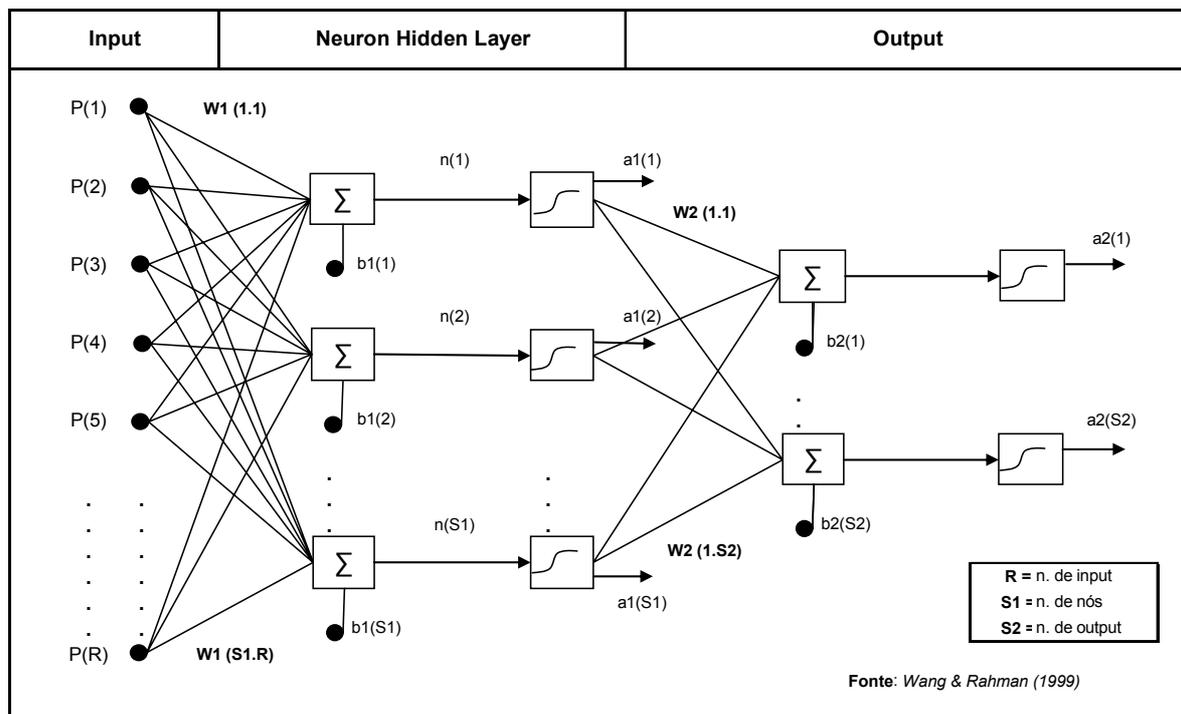


Fig. 4 – Esquema geral de uma rede neuronal.

3.1. Processo de preparação dos dados em ambiente SIG⁵

Depois de definida a área em estudo, utilizou-se o software SIG (ArcView 3.2) para criar três temas matriciais contendo cada célula os valores espacializados correspondentes a cada variável a integrar no modelo.

Cada tema foi, depois, exportado em formato ASCII para poder ser integrado no programa MatLab, onde será implementado o modelo neuronal. Para isso, foi necessário criar um *script* que permitisse integrar os três temas produzidos em ArcView 3.2 numa única matriz de entrada, sendo que

⁴ Existem duas etapas fundamentais na aplicação de um sistema de redes neuronais na representação e classificação de um espaço de tipo multivariado: o “treino” e a avaliação (ou “teste”). O algoritmo frequentemente utilizado nestes casos, para o treino, é o *back-propagation* com uma estrutura de tipo *feed-forward* (Paola e Schoweugerdt, 1995; Hines, 1997). Na figura 4 as saídas (*output*) de cada *layer* representam as entradas (*input*) do *layer* seguinte. Cada *layer* tem uma matriz de pesos **W**, um vector de erro **b** e um vector de saída **a**. Cada elemento do vector de entrada **p** está conectado a cada neurónio de entrada através a matriz de pesos **W**.

⁵ Para poder utilizar um sistema de redes neuronais juntamente com uma ferramenta SIG, os dados espaciais de entrada do SIG têm de ser convertidos para poderem ser carregados no software que permite construir o sistema neuronal e, posteriormente, os resultados têm de ser convertidos novamente num formato que seja aceite pelo SIG. A implementação de um modelo neuronal exige recursos computacionais acima da média que possibilitem tempos de processamento da informação razoáveis. Apesar disso, os modelos suportados por uma Rede de Neurónios Artificiais são facilmente adaptáveis e oferecem um grande poder de generalização (Lee *et al.*, 2003a); podem também utilizar dados imperfeitos ou incompletos e, ainda assim, conseguir capturar as complexas e não lineares interações entre as variáveis do sistema.

cada linha da matriz continha os valores de cada um dos temas anteriores. Esta matriz foi designada por **X (dados de entrada)**.

Paralelamente, foi também integrado pelo mesmo processo o tema onde estavam representadas as localizações dos movimentos, sendo que, neste caso, a matriz de entrada continha apenas uma única linha, com valores de 1 para as células onde se localizavam movimentos e -1, para as restantes. Esta matriz foi designada por **Y (matriz de soluções)**⁶.

3.2. Processo de construção e implementação do modelo neuronal

A fase seguinte do processo, realizada em ambiente MatLab, corresponde à normalização dos dados de entrada e das saídas desejadas e à definição da arquitectura da rede que, no nosso caso, era constituída por uma *Layer* de entrada com três diferentes *inputs*, uma *Layer* escondida com 15 neurónios e uma *Layer* de saída composta por um único neurónio, portanto com uma estrutura geral de tipo 3 x 15 x 1.

A seguir, para uma área mais restrita (70 % da área total), procedeu-se à **fase de “treino”** do algoritmo da rede neuronal, confrontando as matrizes representativas das variáveis utilizadas com a matriz onde estavam registados os movimentos ocorridos, sendo definido o número de iterações a executar pelo programa (no nosso caso 5000), bem como o “*Goal*” (0.01)⁷.

Colocado o modelo em execução, pode ocorrer uma de duas situações: se o limiar máximo de erro é alcançado dentro do número de iterações definido, obtém-se uma matriz de pesos (**w**) associados a cada um dos factores; se, o modelo é executado o número de vezes definido e o “*Goal*” não é atingido, é necessário voltar a redefinir a estrutura do modelo, alterando os pesos de partida ou modificando o número de “neurónios”. Por uma questão de eficiência, deve procurar-se utilizar o menor número possível de neurónios.

Ajustados os parâmetros do modelo neuronal, passou-se à **fase de avaliação** utilizando para o efeito uma nova área de “**teste**”, desconhecida pelo modelo de treino, e correspondente aos restantes 30 % da área total em estudo.

No nosso caso, depois de várias tentativas bastante demoradas, foi possível obter resultados válidos com o modelo apresentado anteriormente (3 x 15 x 1), pelo que se passou à **fase de interpretação dos pesos**. De seguida procedeu-se à integração dos pesos no modelo cartográfico construído em SIG para o conjunto da área em análise e, dessa forma, obteve-se o **IS** (Índice de Susceptibilidade = $\Sigma[\mathbf{w} * \mathbf{Vc}]$)⁸ traduzido no mapa seguinte (Fig. 5).

4. DISCUSSÃO E CONCLUSÕES

Numa primeira observação, sobretudo ao nível das áreas classificadas como mais susceptíveis na figura 5, parece haver uma boa correspondência com o registo de movimentos, tendo sido definidas manchas mais circunscritas que evidenciam uma boa correspondência com a distribuição espacial da localização de movimentos ocorridos no Inverno de 2000/2001.

Fazendo uma análise mais substantiva, comparando o total de área em cada um dos graus de susceptibilidade considerados nas três metodologias testadas em Cunha e Dimuccio (2002) com esta que recorre à Rede de Neurónios Artificiais (Fig. 6), verifica-se uma boa correspondência entre as

⁶ As matrizes de entrada (X) e de saídas desejadas (Y) foram posteriormente divididas numa matriz X de treino e X de teste, bem como numa matriz Y de treino e Y de teste, respectivas. As matrizes de treino correspondem ao 70 % da área em estudo e as de teste aos restantes 30 %.

⁷ Isto é, o limiar máximo de erro aceitável entre os resultados produzidos pela execução iterativa do modelo e a matriz de soluções utilizada (matriz de localização dos movimentos registados na área de treino no Inverno de 2000/2001). No nosso caso foi utilizado como medida de referência o Erro Médio Quadrático.

⁸ **Vc** representa o valor de cada classe para o factor considerado (Fig. 3) e **w** o peso de cada factor retirado da matriz de pesos elaborada da rede neuronal.

áreas obtidas para cada classe através da utilização do modelo neuronal e as áreas obtidas através do método empírico, fundado num conhecimento próximo da área em estudo. Contrariamente ao que acontece nos dois restante métodos, onde se nota uma certa tendência para a definição maioritária de áreas medianamente susceptíveis.

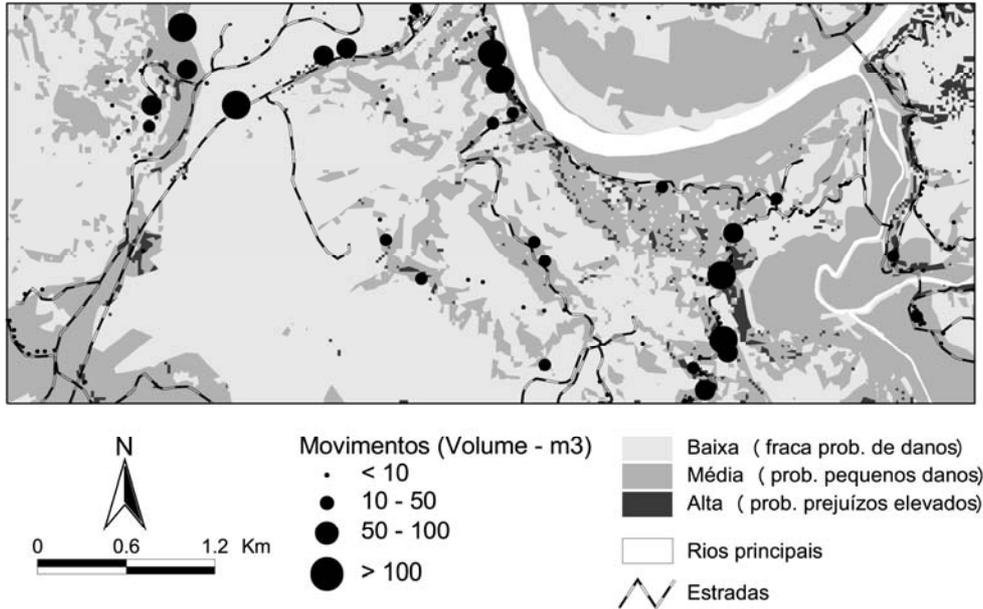


Fig. 5 – Modelação da susceptibilidade dos movimentos de vertente através uma rede de Neurónios Artificiais.

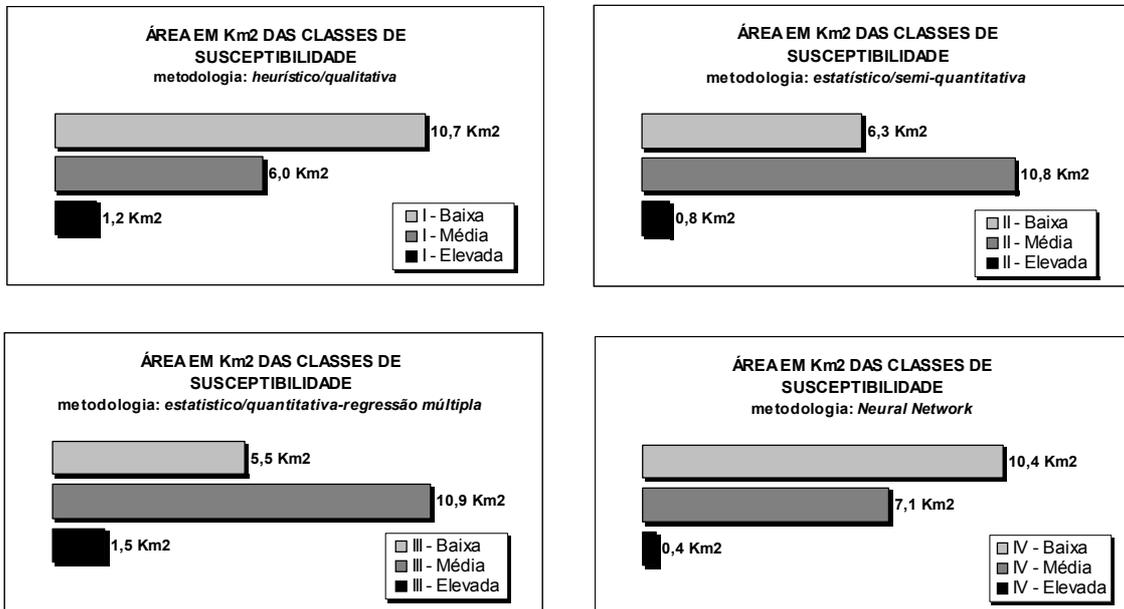


Fig. 6 – Confronto entre os mapas de susceptibilidade obtidas através as três metodologias do trabalho anterior e aquele através a Rede de Neurónios Artificiais.

Quando comparamos o número de movimentos registado por quilómetro quadrado em cada uma das classes de susceptibilidade, para cada um dos modelos (Fig. 7), voltamos a notar um bom desempenho do modelo suportado pela rede de neurónios artificiais. Destaca-se a classe de susceptibilidade mais elevada, que evidencia o valor mais alto (50 Mov/Km²), isto é, as áreas definidas como de elevada probabilidade de ocorrência dos movimentos, foram aquelas em que, no Inverno de

2000/2001, se verificou, efectivamente, um maior número de movimentos em vertentes, por Km². Nas restantes classes, as discrepâncias entre os valores registados através dos vários métodos são muito menos acentuadas.

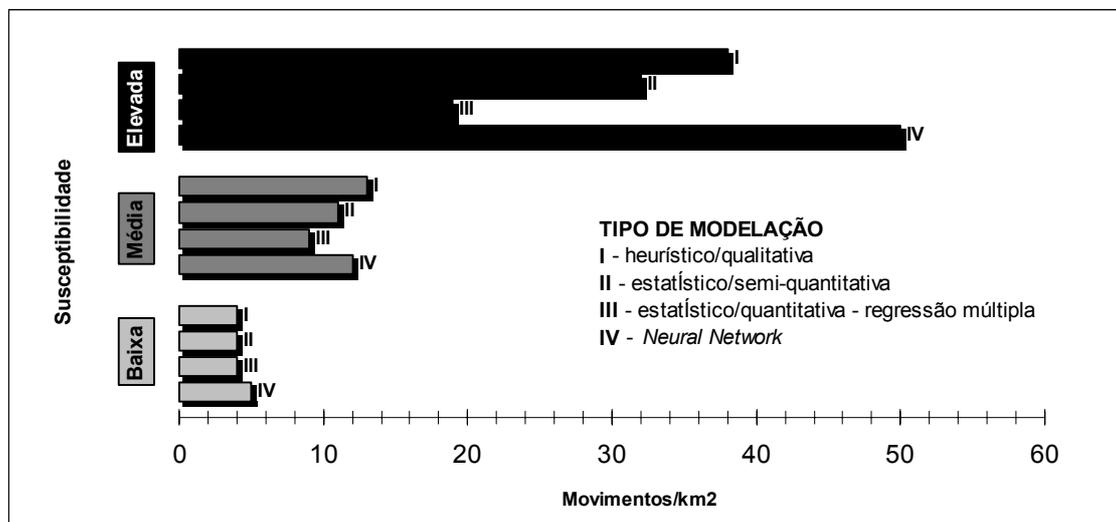


Fig. 7 – Confronto entre os números de movimentos registados por quilómetros quadro em cada uma das classes de susceptibilidade das diferentes metodologias utilizadas para a mesma área.

As conclusões a retirar desta experiência podem ser assim sistematizadas: **1)** possibilidade e interesse de utilização das *Redes de Neurónios Artificiais* para a cartografia automática de susceptibilidade a movimentos de vertente, apesar da dificuldade em cartografar as alterações impostas pela mão humana; **2)** o confronto de diferentes metodologias permite verificar a concordância dos modelos para a maior parte das áreas cartografadas. Verifica-se, no entanto, uma concordância muito mais acentuada entre metodologias qualitativas e a modelação baseada na *Rede de Neurónios Artificiais*, o que nos parece traduzir uma maior fiabilidade desta última metodologia relativamente aos métodos estatísticos; **3)** possibilidade de ultrapassar uma parte significativa da subjectividade inerente à atribuição dos pesos para cada variável que se considera na modelação da susceptibilidade; **4)** o método baseado nas *Redes de Neurónios Artificiais* permite a generalização dos pesos associados a cada factor para áreas relativamente extensas, desde que apresentando características naturais e antrópicas não muito diferentes da área “de treino” da rede. Os resultados do modelo serão tanto mais próximos da realidade quanto maior for o número de entradas definidas no sistema neuronal (os factores condicionantes); **5)** a implementação de um modelo mais complexo, que pretenda simular de uma forma mais realista a imensidão de interrelações geossistémicas, implica necessidades de Hardware e tempos de processamento muito elevados, traduzindo-se, portanto, em custos consideráveis.

Agradecimentos

Ao Eng. Norberto Pires e à Eng. Bernardete Ribeiro, do Dep. de Eng. Mecânica e Informática da UC, respectivamente, pelos seus endereçamentos e apoio na construção e tratamento informático da rede neuronal.

BIBLIOGRAFIA

- Aleotti, P. e Chowdhury (1999) – “Landslide hazard assessment: summary review and new perspectives”. *Bull. Eng. Geol. Env.*, 58, p. 21-44.
- Atkinson, P. M. e Tatnall, A. R. (1997) – “Neural networks in remote sensing”. *International Journal of Remote Sensing*, 18, p. 699-709.
- Cunha, L. e Dimuccio, L. A. (2002) – “Considerações sobre riscos naturais num espaço de transição. Exercícios cartográficos numa área a Sul de Coimbra”. *Territorium*, 9, p. 37-51, Coimbra.
- Garret, J. (1994) – “Where and why artificial neural networks are applicable in civil engineering”. *Journal of Computing Civil Engineering*, 8(2), p. 129-130.
- Hines, J. W. (1997) – “Fuzzy and Neural Network Approaches in Engineering”. Wiley, New York, 210 pp.
- Lee, S.; Ryu, J. H.; Won, J. e Park, H. (2004) – “Determination and application of the weights for landslide susceptibility mapping using an artificial neural network”. *Engineering Geology*, 71, p. 289-302.
- Lee, S.; Ryu, J. H.; Lee, M. e Won, J. (2003a) – “Use of an artificial neural network for analysis of the susceptibility to landslides at Boun, Korea”. *Environmental Geology*, 44, p. 820-833.
- Lee, S.; Ryu, J. H.; Min, K. e Won, J. (2003b) – “Landslide susceptibility analysis using Gis and artificial neural network”. *Earth Surface Processes and Landforms*, 28, p. 1361-1376.
- Paola, J. D. e Schowengerdt, R. A. (1995) – “A review and analysis of backpropagation neural networks for classification of remotely sensed multi-spectral imagery”. *International Journal of Remote Sensing*, 16, p. 3033-3058.
- WANG, J. e Rahman M. S. (1999) – “A neural network model for liquefaction-induced horizontal ground displacement”. *Soil Dynamics and Earth-quake Engineering*, 18, p. 555-568.