



## Susceptibilidade aos incêndios florestais na Região Centro de Portugal. Utilização de ferramentas SIG e de um Modelo de Redes Neurais para ponderar os factores condicionantes

Luca Antonio Dimuccio

Centro de Estudos em Geografia e Ordenamento do Território (CEGOT) e Departamento de Ciências da Terra, Universidade de Coimbra. luca@ci.uc.pt

Rui Ferreira, Lúcio Cunha e António Campar de Almeida

Centro de Estudos em Geografia e Ordenamento do Território (CEGOT), Universidade de Coimbra. ruff@ci.uc.pt, luciogeo@ci.uc.pt, campar@ci.uc.pt

### Introdução

Os incêndios florestais são um fenómeno com fortes impactos não apenas a nível ambiental, com a devastação de amplas manchas de coberto vegetal, mas também a nível económico e social, com a destruição de recursos, bens materiais e, nalguns casos mais extremos, com a perda de vidas humanas.

Nos países do Sul da Europa, com climas marcados pela escassez de água durante uma boa parte do ano e espaços florestais desordenados, os incêndios florestais têm assumido de forma recorrente nas últimas décadas proporções alarmantes (PIÑOL *et al.*, 1998; PAUSAS, 2004; PEREIRA, 2006). Em Portugal, entre os anos de 1990 e 2007, mais de 1.000.000 ha de matos e florestas foram consumidos pelo fogo, o que equivale a mais de 10% do território continental (AFN, 2008). No período de 2003 a 2005, em Portugal, ocorreu a mais devastadora sequência de incêndios florestais de que há memória, resultando na destruição pelo fogo de uma área superior a 750.000 ha (DGF, 2006), a que acresce a perda de 38 vidas humanas. As regiões mais afectadas em 2003 foram os distritos de Castelo Branco, Portalegre e Faro, enquanto em 2005, Coimbra e Viseu, na Região Centro de Portugal, foram as áreas mais atingidas (AFN, 2008).

A evolução sócio-económica e as tendências demográficas evidenciadas ao longo das últimas quatro décadas nas regiões rurais do Centro de Portugal, têm contribuído largamente para um aumento da susceptibilidade destes territórios em relação ao fogo. Os espaços rurais têm vindo a evidenciar um decréscimo sucessivo da população residente, com o consequente abandono das áreas cultivadas, redução do número de rebanhos e de cabeças por rebanho e diminuição do consumo de matos e produtos lenhosos. Esta dinâmica traduziu-se, nos últimos anos, numa desestruturação de boa parte do território rural, com um acumular da carga combustível nas áreas votadas ao abandono (REGO, 1992). Vastas áreas com produtividade agrícola marginal, ou mesmo elevada,

foram pura e simplesmente abandonadas ou convertidas em áreas florestais não cuidadas, onde os processos naturais controlam a evolução do coberto vegetal (PAUSAS, 2004; MOUILLOT *et al.*, 2003).

De acordo com PEREIRA *et al.* (2005), em Portugal, a extensão das áreas consumidas por incêndios florestais é maioritariamente controlada por dois factores climáticos: um período seco relativamente longo no final da Primavera e início do Verão (controlo da precipitação, a longo termo) e a ocorrência de temporadas com dias extremamente quentes e secos associados a situações sinópticas específicas (controlo das ondas de calor, de curto termo). Para além destes aspectos, que poderão ser acentuados pelo processo de mudanças climática, no futuro próximo, a ocorrência de incêndios florestais e a extensão das áreas ardidas, continuará a estar fortemente dependente de factores sociais, associados às dinâmicas demográficas que afectam actualmente os territórios rurais. A mitigação dos efeitos negativos decorrentes do despovoamento passa, em grande medida, pelo estabelecimento de melhores políticas de prevenção que, partindo de uma definição, o mais rigorosa possível, das áreas mais sensíveis, implemente medidas de gestão das matas e crie estratégias eficazes para a intervenção rápida de pessoal especializado no combate aos incêndios florestais (PEREIRA *et al.*, 2005).

Uma avaliação eficaz do problema dos incêndios florestais e, conseqüentemente, uma correcta solução, só poderá ser alcançada satisfatoriamente se existir uma cartografia de susceptibilidade rigorosa e credível. A susceptibilidade é aqui entendida como a probabilidade espacial da ocorrência de incêndios florestais. Não está dependente do impacto nas actividades económicas e/ou humanas, mas antes dos factores ambientais que os condicionam e, como tal, constitui um elemento de caracterização dos territórios a montante do "risco". A análise do risco está também directamente relacionada com a vulnerabilidade do território, que permite distinguir diferentes graus de

risco, em função de uma valorização mais ou menos subjectiva da distribuição espacial de vários critérios (valor patrimonial, valor ambiental, população exposta, etc.). Neste trabalho, apenas nos debruçamos sobre a análise da susceptibilidade.

De seguida, apresenta-se um breve enquadramento da temática no quadro geográfico nacional a que se segue a apresentação dos aspectos mais relevantes relativos à construção da base de dados geográficos utilizada. Passa-se depois, para a apresentação dos procedimentos envolvidos na valorização das classes/categorias de cada um dos factores considerados e dos pesos respectivos, integrados posteriormente através do índice de susceptibilidade aos incêndios florestais. Conclui-se com a verificação e interpretação dos resultados.

### O estudo da susceptibilidade aos incêndios florestais em Portugal e a área em estudo

Em Portugal, tradicionalmente, os estudos da susceptibilidade aos incêndios florestais foram sendo realizados com base na interpretação empírica de um conjunto mais ou menos vasto de dados estatísticos e mapas temáticos onde, geralmente, se representavam as áreas ardidadas ao longo dos anos mas sem que houvesse uma verdadeira sistematização metodológica na análise espacial dos factores condicionantes (FREIRE *et al.*, 2002; ARANHA *et al.*, 2001; ARANHA e ALVES, 2001, NUNES, 2002; LOURENÇO, 2004a, 2004b). Para além da morosidade do processo, esta abordagem não está perspectivada para uma integração continua de dados recolhidos durante longos períodos.

Mais recentemente, com a diversificação das fontes de informação recolhida por detecção remota, assim como de outras fontes de dados em formato digital e sua integração numa plataforma de análise comum assente nos modernos Sistemas de Informação Geográfica (SIG), criaram-se condições para o desenvolvimento de novas metodologias de análise sistematizada dos factores responsáveis pela distribuição espacial das áreas ardidadas. A incorporação dos diferentes factores (devidamente ponderados em função da sua importância relativa) num modelo analítico suportado numa plataforma SIG, tem permitido o desenvolvimento de sucessivas gerações de mapas de susceptibilidade e de risco aos incêndios florestais (CRIF, CREIF, CRCIF; IFFR<sup>1</sup>).

<sup>1</sup> CRIF - *Carta de Risco Incêndio Florestal*: projecto desenvolvido à escala municipal em parceria pela Associação Nacional de Protecção Civil e pela Direcção-Geral de Recursos Florestais, com apoio do Instituto Geográfico Português, do Instituto Geográfico do Exército e do Instituto Nacional de Estatística. O CREIF (*Carta de Risco Estrutural de Incêndio Florestal*), CRCIF (*Carta de Risco Conjuntural de Incêndio Florestal*) e o IFFR (*Índice de risco integrado de incêndio*) são instrumentos práticos criados no âmbito de uma "iniciativa sobre incêndios florestais" patrocinada pela COTEC - Associação Empresarial para a Inovação.

Contudo, na maioria dos casos, os pesos associados a cada uma das variáveis do modelo depende essencialmente da experiência dos especialistas, deixando uma margem ampla de subjectividade que pode enviesar as decisões tomadas com base nestes mapas.

Para minimizar esta subjectividade no processo de ponderação das classes e dos factores incorporados na análise da susceptibilidade podem ser utilizados vários métodos quantitativos: métodos estatísticos, métodos determinísticos, análise de frequências, etc. (CHUVIECO *et al.*, 1989, 1997; VIEGAS *et al.*, 1999; VASCONCELOS *et al.*, 2001). Recentemente, também em Portugal, no contexto da modelação de outros tipos de susceptibilidades, como por exemplo, aos movimentos em massa ou às inundações, têm vindo a ser experimentados com sucesso outros tipos de procedimentos de definição dos pesos com base na utilização de redes neuronais artificiais (DIMUCCIO *et al.*, 2006).

As experiências atrás referidas estão na base deste trabalho que procura aplicar um procedimento analítico semelhante para a construção de um mapa de susceptibilidade aos incêndios florestais na Região Centro de Portugal.

A área de estudo corresponde à NUT II - Região Centro<sup>2</sup>, correspondendo a uma superfície de cerca de 24000 Km<sup>2</sup> e um total de população na ordem do milhão e oitocentos mil habitantes, onde, nos últimos anos, o fenómeno dos incêndios florestais tem sido responsável pela destruição de vastas áreas de vegetação, em especial no interior mais montanhoso (Figura 1).

### Construção da base de dados geográfica

Há duas regras fundamentais a considerar na criação de uma base de dados referenciada espacialmente: em primeiro lugar, os dados devem ser homogéneos, isto é, devem possuir escalas e resoluções cartográficas próximas e estar integrados num mesmo sistema de coordenadas espaciais; em segundo lugar, a informação deve estar segmentada em níveis de informação monotemáticos.

Tendo em conta os objectivos definidos para o trabalho, a construção da base de dados geográfica aqui utilizada engloba apenas os factores que, estruturalmente, mais contribuem para a ocorrência de incêndios florestais à escala de análise da área em estudo (regional), não nos preocupando com variáveis de carácter conjuntural (como por exemplo, os estados de tempo). Assim, como expresso no Quadro I, foram considerados os principais aspectos relacionados com

<sup>2</sup> A utilização de um limite não actualizado prende-se com a disponibilidade dos dados vectoriais utilizados no processo de modelação.

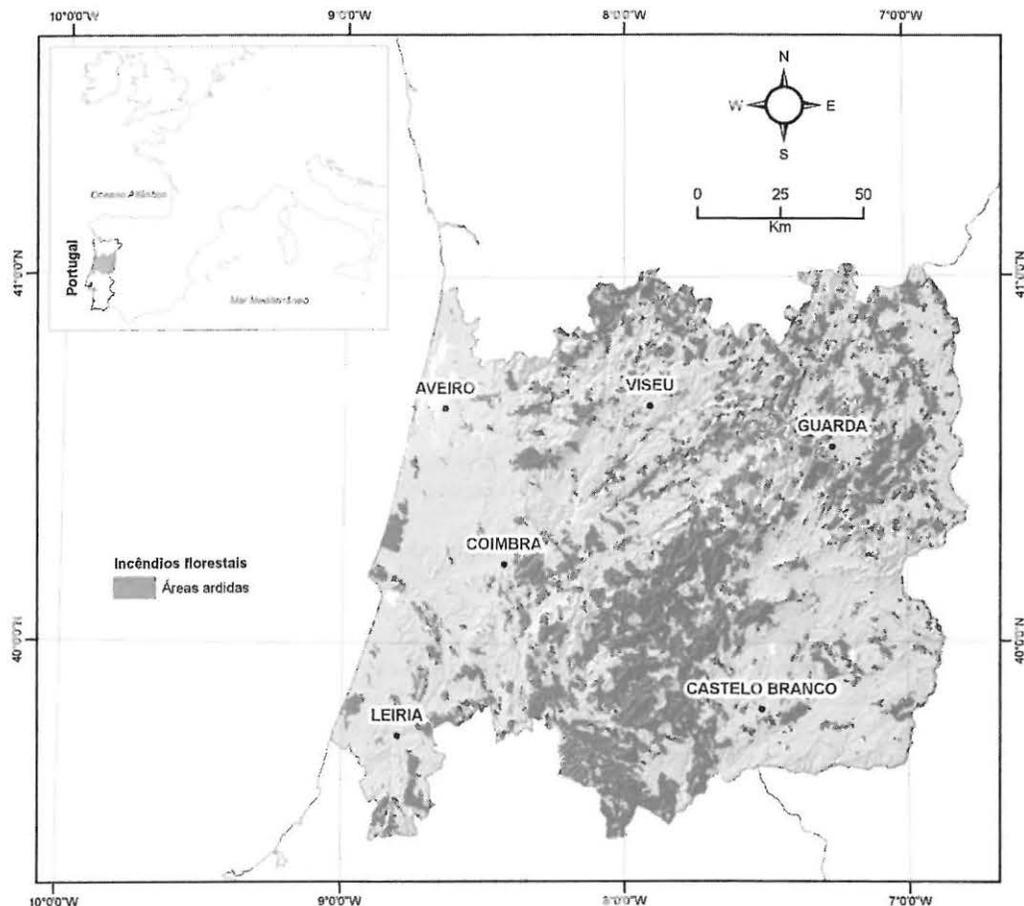


Figura 1  
Localização da área em estudo e das áreas áridas no período de 1990 a 2007.

as características fisiográficas e climáticas do território (relevo, cobertura vegetal, precipitação), factores de acessibilidade e vigilância e com a dinâmica sócio-demográfica, recolhidos a partir de diversas fontes e integrados em ambiente SIG (ArcGIS 9.3<sup>®</sup>).

Embora nesta escolha esteja presente alguma subjectividade, é nossa convicção que a introdução de um maior número de factores condicionantes no modelo de análise não se traduziria numa melhoria significativa dos resultados obtidos.

A utilização do histórico de áreas áridas constitui um elemento fundamental na aplicação dos métodos probabilísticos e da rede neuronal. As áreas áridas entre 1990 e 2007, registadas a uma escala 1:25000, foram recolhidas a partir da Autoridade Florestal Nacional (ANF) e incluem uma área total de pouco mais de 7530 Km<sup>2</sup>.

A informação topográfica foi obtida com base na

construção de um Modelo Digital de Terreno (MDT) estabelecido com base na cartografia de escala 1/25000, com uma resolução de 10 m, de onde se derivou o declive e a exposição. Os dados relativos à acessibilidade e vigilância foram derivados a partir do cálculo da densidade de vias rodoviárias principais e secundárias e das bacias de visão para cada um dos postos de vigia actualmente instalados na região. A informação sobre a ocupação do solo foi obtida a partir da conjugação de dados CORINE Land Cover, Carta de Uso do Solo, fotografias aéreas e levantamentos pontuais no campo. A partir de duas imagens Landsat 7 ETM (respectivamente, de 24 de Julho de 2000 e 20 de Julho de 2001) foi calculado o NDVI (*Normalized Difference Vegetation Index*), com base na fórmula  $NDVI = (IR - R) / (IR + R)$ , em que IR corresponde ao valor da reflectância na banda do infra-vermelho e R ao valor da reflectância na banda do vermelho (Rouse *et al.*, 1974).

Quadro I

Classificação, tipo de dados e escala ou resolução dos dados geográficos utilizados.

Classificação (Base de dados espacial)	Níveis temáticos (Factores condicionantes)	Tipo de dados SIG	Escala ou resolução	Conversão para SIG
Relevo	Declive	Linhas e pontos (vectorial)	1:25000	GRID's 100x100 m
	Exposição			
Acessibilidade e vigilância	Densidade de vias	Linhas (vectorial)	1:50000	
	Visibilidade dos postos de vigia	Pontos e polígonos (vectorial)	1:25000	
Cobertura vegetal	Ocupação do solo	GRID ( <i>raster</i> )	30x30 m	
	Índice de vegetação (NDVI)	GRID ( <i>raster</i> )	30x30 m	
Clima	Precipitação	GRID ( <i>raster</i> )	100x100 m	
Demografia	Densidade de População	Polígonos (vectorial)	1:50000	
Histórico dos Incêndios	Áreas ardidas	Polígonos (vectorial)	1:25000	

O valor de NDVI denota o grau de vigor da vegetação.

As variações nas condições climáticas regionais estão representadas através dos valores de precipitação média, derivados por interpolação a partir dos valores registados nas estações do Sistema Nacional de Informação de Recursos Hídricos (SNIRH). Os dados sobre a população foram obtidos a partir do Instituto Nacional de Estatística (INE) e associados às áreas respectivas de cada freguesia para a determinação da densidade demográfica.

Estes 8 factores condicionantes, conjuntamente com o histórico das áreas ardidas, foram convertidos para o formato GRID com uma resolução de 100x100 m, para serem, depois, classificados e ponderados através de um método probabilístico.

#### Processo de ponderação probabilística

A valoração probabilística baseia-se na relação existente entre cada variável considerada e a distribuição das áreas ardidas no período de 1990 a 2007. Com base na relação de frequência, foi calculado o valor a atribuir a cada classe/categoria da variável tendo em conta a relação existente o número de *pixels* ardidos e não ardidos em cada uma. (Quadro II).

Se este parâmetro for igual a 1 (a/b em Quadro II), isso significa que nesta classe/categoria existe uma relação de equilíbrio entre a área que já foi queimada pelo menos uma vez e aquela que nunca foi afectada por um incêndio florestal no período em consideração. Se este valor é superior a 1, isso significa que, globalmente, nesta classe/ categoria da variável, uma superfície mais extensa já foi afectada por um incêndio florestal comparativamente à área nunca ardida. Se, pelo contrário, o valor é inferior a 1, isso significa que, globalmente, uma menor área foi afectada por incêndios florestais relativamente à que nunca ardeu. Portanto, em termos gerais, os valores da relação de frequência determinados desta forma são proporcionais ao grau de susceptibilidade induzida por cada

classe/categoria da variável relativamente à ocorrência de incêndios florestais.

Como as variáveis consideradas apresentam unidades distintas, foi necessário normalizar os seus valores para que pudessem ser integradas conjuntamente no modelo de análise. Depois, para facilitar a operacionalização do modelo, converteram-se os valores normalizados para uma escala uniforme (0-100) (Quadro II).

#### Determinação dos pesos de cada variável através da rede neuronal

Os modelos de redes neuronais artificiais (*Artificial Neural Network* - ANN) constituem uma técnica poderosa na resolução de problemas geográficos que envolvam análise regressiva e classificação de dados. Com um vasto domínio de aplicações, as redes neuronais oferecem grande potencial na definição das ponderações atribuídas aos factores considerados nos problemas de susceptibilidade ambiental (LEE *et al.*, 2003, 2004, 2006, 2007; ERMINI *et al.*, 2005; KANUNGO *et al.*, 2006; PRADHAN & Lee, 2007).

As redes neuronais são um instrumento de processamento de dados inspirado no funcionamento sináptico do cérebro dos mamíferos que reage aos estímulos fornecidos por dados de treino de modo a alterar o seu estado inicial. Contrariamente aos processos algorítmicos tradicionais, a grande vantagem das redes neuronais é que elas podem "aprender" (LEE, 1996; HAYKIN, 1999; FLOREANO e MATTIUSI, 2002; HAUPT *et al.*, 2009). São considerados como modelos do tipo "caixa negra" (CARRARA, 1983; KANUNGO *et al.*, 2006), pois não dependem dos aspectos físicos do problema e, como tal, não pressupõem um conhecimento conceptual deste. Contudo, em contrapartida, apresentam algumas dificuldades em termos de verificação dos resultados, sobretudo, quando não existem dados de referência aferidos instrumentalmente. Esta técnica é ideal para

Quadro II  
Valores atribuídos às diferentes classes/categorias de cada um dos factores com base no método probabilístico

Níveis temáticos (Fact. Cond.)	Classes/Categorias	Núm. pixels ardidos	Freq. pixels Ardidos (%) <sup>(a)</sup>	Núm. pixels não ardidos	Freq. Pixels não ardidos (%) <sup>(b)</sup>	Calculo índices				Índice final (R <sub>i</sub> )
						Relação de Freq. <sup>(a/b)</sup>	Média <sup>(m)</sup>	Desvio Padrão <sup>(s)</sup>	Normalização <sup>[(a/2) - (s)/4]</sup>	
Dective (°)	0-2	13965	1,85	163546	10,12	0,18	1,15	1,07	-0,90	0
	2-10	63222	8,39	403168	24,95	0,34				
	10-25	212494	28,19	566570	35,06	0,80				
	25-45	231371	30,69	301969	18,69	1,64				
	>45	232797	30,88	180597	11,18	2,76				
Exposição	Plano	8730	1,16	67351	4,17	0,28	0,86	0,35	-1,65	0
	Norte	95648	12,69	262651	16,25	0,78				
	Leste	232673	30,86	484460	29,98	1,03				
	Sul	252527	33,50	484041	29,96	1,12				
	Oeste	164271	21,79	317347	19,64	1,11				
Densidade vias (Km/Km <sup>2</sup> )	0-1	175418	23,27	69803	4,32	5,39	1,81	2,41	1,48	100
	1-2	449484	59,63	863839	53,46	1,12				
	2-3	114428	15,18	578788	35,82	0,42				
	>3	14519	1,93	103420	6,40	0,30				
Visibilidade a partir das Torres de Vigia	Oculto	71731	9,52	108354	6,71	1,42	1,16	0,27	0,96	100
	Visível de 1 P.V.	110727	14,69	175472	10,86	1,35				
	Visível de 2 e 3 P.V.	226166	30,00	471737	29,19	1,03				
	Visível de > 3 P.V.	345225	45,79	860287	53,24	0,86				
Uso do solo	Z. aquáticas e hidrófilas	400	0,05	24284	1,50	0,04	0,56	0,89	-0,59	1
	Urbano descontinuo	13786	1,83	217091	13,44	0,14				
	Infra-estruturas	433	0,06	8552	0,53	0,11				
	Urbano contínuo	0	0,00	1031	0,06	0,00				
	Z. artif. sem vegetação	264	0,04	3517	0,22	0,16				
	Agricultura	60982	8,09	504539	31,22	0,26				
	Pastagens	835	0,11	5145	0,32	0,35				
	Veg. arb. e herbácea	409010	54,26	271224	16,79	3,23				
	Z. agro-florestais	1370	0,18	26166	1,62	0,11				
	Z. verdes ordenadas	0	0,00	232	0,01	0,00				
	F. mista	56689	7,52	135186	8,37	0,90				
	F. folhosas	47968	6,36	132764	8,22	0,77				
F. resinosas	162112	21,50	286119	17,71	1,21					
Índice de vegetação (NDVI)	Sem vegetação	1415	0,19	19902	1,23	0,15	0,85	0,37	-1,88	0
	Muito pouca vegetação	433790	57,54	977846	60,52	0,95				
	Pouca vegetação	165509	21,96	296496	18,35	1,20				
	Vegetação normal	98685	13,09	193671	11,99	1,09				
	Vegetação vigorosa	41507	5,51	91547	5,67	0,97				
	Veg. muito vigorosa	12943	1,72	36388	2,25	0,76				
Precipitação (mm)	0-600	46985	6,23	132030	8,17	0,76	1,15	0,53	-0,73	4
	600-1000	259425	34,41	771873	47,77	0,72				
	1000-1600	369056	48,96	621671	38,47	1,27				
	>1600	78383	10,40	90276	5,59	1,86				
Densidade de População (Hab./Km <sup>2</sup> )	0-5	606045	80,39	887006	54,89	1,46	0,52	0,55	-0,09	26
	5-25	140433	18,63	640141	39,62	0,47				
	25-50	4238	0,56	64605	4,00	0,14				
	50-100	2527	0,34	13128	0,81	0,41				
	>100	606	0,08	10970	0,68	0,12				

(R<sub>i</sub>) corresponde ao valor normalizado da relação de frequência transformado numa escala entre 0 e 100.

modelização de problemas geográficos à escala regional ou supra-regional.

Uma rede de neurónios é composta por um determinado número de neurónios que trabalham paralelamente para transformar um dado de entrada numa classe de saída. Geralmente, é adoptado um procedimento de retroalimentação com múltiplas camadas: uma *layer* de entrada, uma *layer* de saída e, entre elas, diversas *layers* escondidas (PAOLA e SCHOWENGERDT, 1995).

Cada *layer* possui um número variável de neurónios, dependendo da aplicação específica. Os neurónios de uma *layer* estão conectados aos neurónios das *layers* seguinte e cada conexão acarreta uma ponderação (ATKINSON e TATNALL, 1997). A *layer* de entrada recebe os dados a partir de fontes diversas (ex. níveis de dados temáticos - os factores do Quadro I). Deste modo, o número de neurónios na *layer* de entrada depende do número de fontes de dados. As *layers* escondidas e de saída processam activamente os dados, sendo que o número de *layers* escondidas e a rede de neurónios que as compõem são frequentemente determinadas por tentativa e erro (GONG, 1996).

O resultado de cada *layer* intermédia constitui o valor de entrada para as *layers* seguintes (LEE *et al.*, 2004). Cada *layer* possui uma matriz de pesos  $W$ , um vector de desvio e um vector de saída. Cada elemento do vector de entrada está conectado com cada um dos neurónios de entrada através da matriz  $W$ . Cada neurónio possui um somatório que reúne os valores de entrada ponderados e os valores de desvio de acordo com uma função específica para formar o valor respectivo de saída. A *layer* de neurónios final produz um vector definindo os pesos relativos de cada factor introduzido no modelo (WANG e RAHMAN, 1999).

Antes de executar o modelo de rede neuronal, foram definidas áreas de treino e teste, correspondendo, respectivamente, a 70% e 30% da área total de estudo. Assim, com recurso às ferramentas SIG, todos os níveis temáticos incluídos no Quadro I foram divididos de acordo com esta proporção. O mesmo aconteceu com o nível temático representativo das áreas ardidas (atribuindo-se o valor 1 às áreas ardidas e -1 às áreas não ardidas), definindo-se assim as áreas objectivo de treino e de teste.

Para incluir os dados relativos aos factores condicionantes e aos objectivos no modelo de redes neuronais foi necessário converter os ficheiros em formato GRID para ficheiros ASCII que, através de *scripts* específicos permitiram gerar 4 matrizes numéricas de entrada: uma Matriz  $X_{tr}$  de treino relativa aos factores, uma Matriz  $Y_{tr}$  de treino relativa aos objectivos, uma Matriz  $X_{te}$  de teste relativa aos factores e uma Matriz  $Y_{te}$  de teste relativa aos objectivos.

Depois de várias experiências, chegou-se à conclusão

que a rede mais ajustada para o problema em questão deveria ser constituída por uma estrutura de neurónios organizada em 3 níveis compostos, respectivamente por  $8 \times 25 \times 1$  neurónios. A razão de aprendizagem (*learning rate*) foi estabelecida em 0,01 e os pesos iniciais foram escolhidos aleatoriamente. Foi utilizado o método de *back-propagation* para minimizar os erros entre os valores de saída previstos (objectivos) e os valores calculados pela rede, recorrendo-se ao algoritmo de Levenberg-Marquardt como função de treino (*TRAINLM function*) da rede. O algoritmo processa a informação propagando os erros para trás e iterativamente ajusta os pesos considerados (cfr. HAGAN e MENHAJ, 1994; HAGAN *et al.*, 1996; HINES, 1997; DEMUTH e BEALE, 2001). Considerou-se um número de iterações máximo de 1000 e um erro médio quadrático (RMSE) de 0,01, como o critério para parar o processamento de informação. A maioria das operações de processamento na fase de treino da rede alcançaram o objectivo definido através do RMSE. Quando isso não aconteceu o processamento parou quando atingiu o número máximo de iterações definido (nestes casos o máximo valor de RMSE obtido foi de 0,44).

Os pesos finais associados a cada factor utilizado na definição do grau de susceptibilidade do território aos incêndios florestais são apresentados no Quadro III. Aplicou-se um processo de normalização para facilitar a interpretação dos pesos ( $W_j$ ).

#### Mapa de susceptibilidade aos incêndios florestais

O modelo de análise aqui utilizado compreende 3 grandes fases: 1) determinação dos pesos a atribuir a cada uma das classes/categorias de cada factor condicionante, através de um método probabilístico de frequência; 2) determinação dos pesos a associar a cada um dos factores através de um modelo de rede de neurónios artificiais; 3) integração dos resultados obtidos nestas duas fases através de ferramentas SIG para construir um Mapa de Susceptibilidade aos Incêndios Florestais.

A integração dos índices e dos pesos obtidos através das duas metodologias anteriores foi feita com a aplicação da seguinte fórmula:

$$ISIF = \sum_{j=1}^t [R_j \times W_j]$$

em que, ISIF= Índice de Susceptibilidade aos Incêndios Florestais;  $R_j$  = pesos das classes obtidos através do método probabilístico;  $W_j$  = pesos de cada um dos factores considerados, obtidos através do modelo de rede de neurónios artificiais.

Os valores do ISIF foram classificados em cinco classes para uma mais fácil interpretação gráfica (Figura 2).

Quadro III

Determinação dos pesos de cada factor considerado através da Rede de Neurónios Artificiais.

Classificação	Níveis temáticos (Factores)	Pesos derivados pela ANN <sup>(a)</sup>	Pesos Normalizados <sup>(b)</sup>	Pesos finais (W <sub>j</sub> )
Relevo	Declive	1,59	-0,39	9
	Exposição	0,17	-0,65	1
Acessibilidade e vigilância	Densidade de vias	4,57	0,14	27
	Visibilidade dos postos de vigia	-0,03	-0,68	0
Cobertura vegetal	Ocupação do solo	16,96	2,35	100
	Índice de vegetação (NDVI)	0,57	-0,58	4
Clima	Precipitação	4,36	0,10	26
Demografia	Densidade População	2,17	-0,29	13

(a) Metodologia de interpretação de acordo com GUHA *et al.* (2005).

(b) Normalização utilizando a equação do método probabilístico (ver Quadro II).

(W<sub>j</sub>) corresponde ao valor normalizado dos pesos transformados numa escala de 0 a 100.

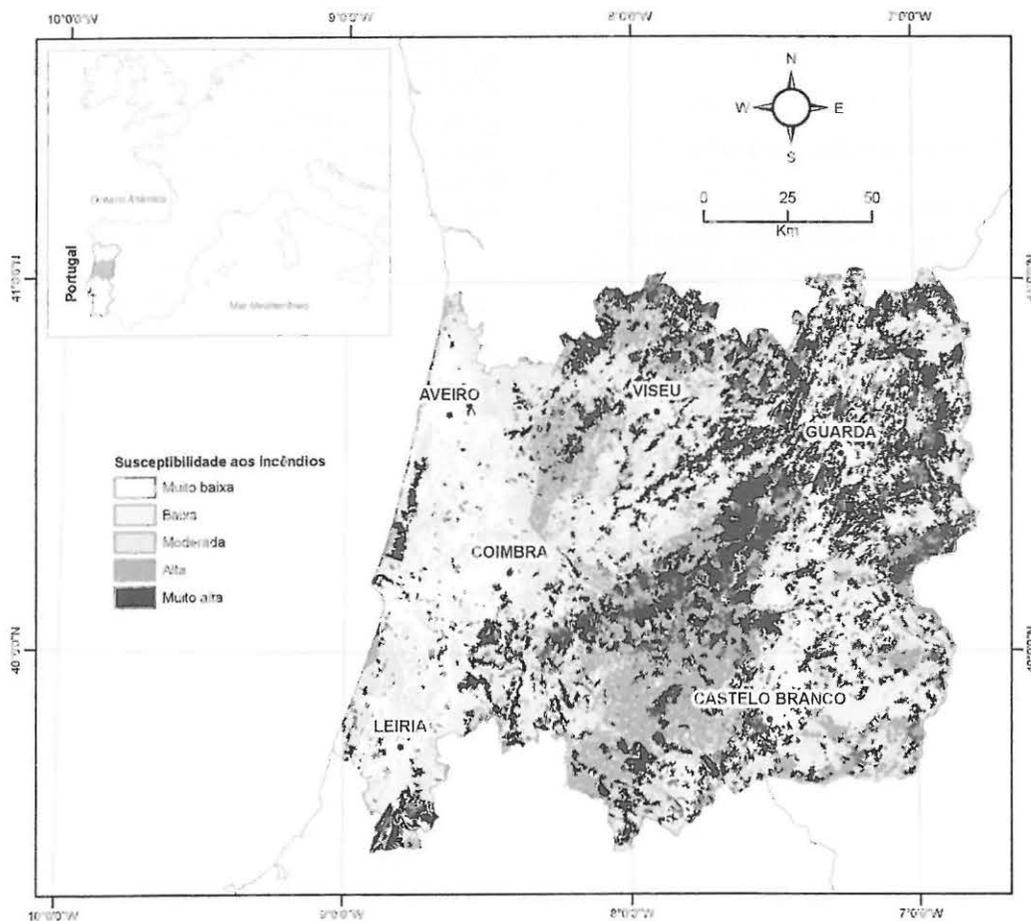


Figura 2  
 Mapa de susceptibilidade aos incêndios florestais na Região Centro.

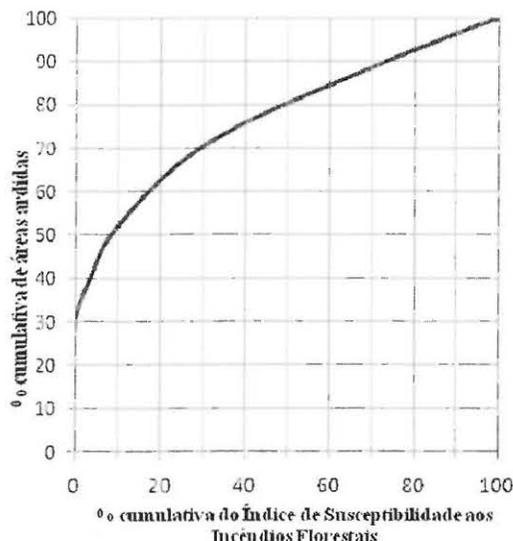


Figura 3  
Mapa de susceptibilidade aos incêndios florestais na Região Centro.

### Verificação e leitura breve dos resultados

A susceptibilidade aos incêndios florestais foi verificada através da comparação com as áreas ardidas no período compreendido entre 1990 e 2007. Na Figura 3 está representada a curva que define esta relação, permitindo facilmente verificar o grau de sucesso dos resultados obtidos. Com base nesta relação entre os resultados definidos pelo modelo de análise em termos de susceptibilidade aos incêndios florestais e as áreas efectivamente ardidas no período considerado, concluiu-se que os resultados do modelo se ajustavam à realidade em cerca de 78% da área total analisada.

Já as manchas de susceptibilidade elevada que ocorrem junto do litoral têm que ver, essencialmente, com a ocupação do solo, particularmente com as vastas e pujantes matas mono-específicas de pinheiro que, de modo quase contínuo preenchem este espaço.

### Conclusões

Em jeito de síntese conclusiva, o ensaio metodológico que acaba de ser apresentado revela, por um lado, a facilidade da sua utilização em termos práticos, e, por outro lado, uma boa adequação ao problema em análise, ou seja à construção de mapas de susceptibilidade a incêndios florestais.

Os resultados obtidos vão, de facto, ao encontro daquele que é o conhecimento geral do comportamento

dos incêndios florestais na Região Centro de Portugal, bem demonstrado pela cartografia das áreas ardidas nos últimos 17 anos.

Quando comparamos a aplicação das redes de neurónios artificiais com métodos mais tradicionais para análise de susceptibilidades, verificamos que estes requerem um conhecimento prévio das regras que gerem as relações entre os dados de entrada e de saída. Nestes modelos, o rigor dos resultados depende, essencialmente, da precisão das variáveis de entrada. No caso das redes de neurónios artificiais, pelo contrário, não existe a necessidade de conhecer as regras que gerem os dados, pois estas serão aprendidas através do raciocínio indutivo que suporta o método. Neste último caso, a rede pode funcionar mesmo com dados de entrada por vezes imprecisos e/ou incompletos.

Claro que se colocam ainda outros problemas metodológicos, quer na selecção dos factores condicionantes, nomeadamente ao nível de possíveis redundâncias interpretativas, quer na ponderação que lhes foi atribuída automaticamente através do método de análise das redes de neurónios artificiais. Também a integração de dados recolhidos a diferentes escalas coloca alguns problemas de integração. Por outro lado, a variação dos valores encontrados em diferentes processos iterativos, na dependência do número de iterações, neurónios e *layers*, recomenda um estudo mais aprofundado na escolha da arquitectura da rede neuronal a utilizar.

O mapa construído reflecte, necessariamente, alguns dos problemas metodológicos acima referidos, nomeadamente o problema das escalas de origem dos dados. Uma análise rápida do mapa sugere a existência de uma base topográfica, nomeadamente de um modelo digital de terreno que suporta as manchas de diferentes susceptibilidades. Esse efeito resulta da pulverização em manchas minúsculas dos resultados do exercício cartográfico realizado, pelo que numa fase sequente, procurar-se-á um método automático de generalização para a agregação das manchas, ajustado com a escala de saída da informação e aferido pela cartografia dos factores condicionantes mais importantes, no caso, o uso do solo.

Finalmente, refira-se que a realização de mapas de susceptibilidade aos incêndios florestais é um instrumento fundamental no processo de prevenção e combate aos incêndios nas áreas rurais. Os resultados alcançados neste trabalho podem ajudar as autoridades interessadas na gestão da floresta, particularmente no combate e mitigação dos efeitos dos incêndios florestais. No entanto, deve ter-se sempre em conta a escala a que os modelos são construídos, pelo que, neste caso, não poderão ser inferidos resultados, nem ser feitas propostas que não à escala regional que serviu de base ao presente exercício.

## Bibliografia

- AFN (2008) - *Estatísticas*. Autoridade Florestal Nacional, Lisboa: <http://www.afn.min-agricultura.pt>
- ARANHA, J.; ALVES, G. e LOPES, D. (2001) - "Burnt areas identification and analysis by means of remotely sensed images classification. A case study in Northern Portugal". *Proceeding of the RSPS 2001, Geomatics, Earth Observation and the Information Society*, London, pp. 629-641.
- ARANHA, J. e ALVES, G. (2001) - "Criação de um Índice de Perigo de Incêndios para o Vale do Alto Tâmega". *Proceedings of ESIG'2001, VI encontro de utilizadores de Informação geográfica*, Oeiras, Portugal, pp. 14-15.
- ATKINSON, P. M. e TATNALL, A. R., (1997) - "Neural networks in remote sensing". *International Journal of Remote Sensing*, V. 18, pp. 699-709.
- CARRARA, A. (1983) - "Multivariate methods for landslides hazards evaluation". *Mathematical Geol.*, V. 15, pp. 403-426.
- CHUMECO, E. e CONGALTON, R. G., (1989) - "Application of Remote Sensing and Geographic Information Systems to Forest Fire Hazard Mapping". *Remote Sensing of Environment*, V. 29, pp. 147-159.
- CHUMECO, E.; SALAS, F. e VEGA, C. (1997) - "Remote Sensing and G.I.S. for Long-Term Fire Risk mapping". *Megafires project ENV-CT96-0256*, Alcalá de Henares, pp. 91-108.
- DEWUTH, H e BEALE, M. (2001) - *Neural Network Toolbox. For Use with MATLAB, User's Guide, Version 4*, MathWorks Inc.
- DIMUCCIO, L. A.; FERREIRA, R. e CUNHA, L. (2006) - "Aplicação de um modelo de redes neurais na elaboração de mapas de susceptibilidade a movimentos de vertente. Um exemplo numa área a Sul de Coimbra (Portugal central)". In: APGeom, Vol. 3, Coimbra, pp. 281-289.
- DGF (2006) - *Incêndios florestais: Relatórios*. Direção-Geral dos Recursos Florestais, Lisboa.
- EPANI, L.; CATANI, F. e CASAGLI, N. (2005) - "Artificial Neural Networks applied to landslide susceptibility assessment". *Geomorphology*, V. 66, pp. 327-343.
- FLORIANO, D. e MATTIUSI, C. (2002) - *Manuale sulle reti neurali*. Il Mulino (Ed.), 2ª edizione.
- FREIRE, S.; CARNEIRO, H. e CAETANO, M. R. (2002) - "Produção de cartografia de Risco de Incêndios Florestal com recursos a Imagens de Satélite e dados auxiliares". *Igeo: www.igeo.pt*.
- GONG, P. (1996) - "Integrated analysis of spatial data for multiple sources: using evidential reasoning and artificial neural network techniques for geological mapping". *Photogram. Eng. Remote Sensing*, V. 62, pp. 513-523.
- GUHA, R.; STANTON, D. T. e JURIS, P. C. (2005) - "Interpreting Computational Neural Network Quantitative Structure Activity Relationship Models: a detailed interpretation of the Weights and Biases". *Jour. Chem. Inf. Model.*, V. 45(4), pp. 1109-1121.
- HAGAN, M. T. e MENHAJ, M. (1994) - "Training feedforward network with the Marquardt algorithm". *IEEE Transaction on Neural Network*, V. 5(6), pp. 989-993.
- HAGAN, M. T.; DEWUTH, H. B. e BEALE, M. H. (1996) - *Neural Network Design*. PWS Publishing, Boston, MA.
- HAYKIN, S. (1999) - *Neural Networks: a comprehensive foundation, second edition*. Prentice Hall, New Jersey.
- HAUPT, S. E.; PASINI, A. e MARZBAN, C. (2009) - *Artificial Intelligence methods in the environmental sciences*. Springer edition.
- HINES, J. W. (1997) - *Fuzzy and Neural Approaches in Engineering. Matlab Supplement*. John Wiles and Sons, New York.
- KANUNGO, D. P.; AORA, M. K.; SARKAR, S. e GRUPTA, R. P. (2006) - "A comparative study of conventional, ANN black box, fuzzy and combined neural and fuzzy weighting procedures for landslide susceptibility zonation in Darjeeling Himalayas". *Eng. Geology*, V. 85, pp. 347-366.
- LEE, B. G. (1996) - "Neural networks applications in the geosciences: an introduction". *Computer and geosciences*, V. 22, pp. 955-957.
- LEE, S.; RYU, J.; MIN, K. e WON, J. (2003) - "Landslide susceptibility analysis using GIS and artificial neural network". *Earth Surface Processes and Landforms*, V. 28, pp. 1361-1376.
- LEE, S.; RYU, J.; WON, J. e PARK, H. (2004) - "Determination and application of the weights for landslide susceptibility mapping using an artificial neural network". *Eng. Geol.*, V. 71, pp. 289-302.
- LEE, S.; RYU, J.; LEE, M. J. e WON, J. (2006) - "The application of Artificial Neural Networks to landslide susceptibility mapping at Janghung, Korea". *Mathematical Geology*, V. 38(2), pp. 199-220.
- LEE, S.; RYU, J. e KW, LI-SOO (2007) - "Landslide susceptibility analysis and its verification using likelihood ratio, logistic regression, and artificial neural network models: case study of Youngin, Korea". *Landslide*, V. 4, pp. 327-338.
- LOURENÇO, L. (2004a) - *Risco Dendrocaustológico em mapas*. NICIF/FLUC, Coimbra.
- LOURENÇO, L. (2004b) - *Manifestações do Risco Dendrocaustológico*. NICIF/FLUC, Coimbra.
- MOUILLOT, F.; RATTE, J.-P.; JOFFRE, R.; MORENO, J. M. e RAMBAL, S. (2003) - "Some determinants of the spatio-temporal fire cycle in a Mediterranean landscape (Corsica, France)". *Landscape Ecology*, V. 18, pp. 665-674.
- NUNES, A. (2002) - "Região Centro de Portugal: duas décadas de incêndios florestais". *Territorium*, nº 9, Minerva, Coimbra, pp. 135-148.
- PAOLA, J. D. e SCHWENGERDT, R. A. (1995) - "A review and analysis of backpropagation neural networks for classification of remotely sensed multi-spectral imagery". *International Journal of Remote Sensing*, V. 16, pp. 3033-3058.
- PAUSAS, J. (2004) - "Changes in fire and climate in the Eastern Iberian Peninsula (Mediterranean Basin)". *Climate Change*, V. 63, pp. 337-350.
- PEREIRA, J. S. (2006) - *Incêndios florestais em Portugal: caracterização, impactos e prevenção*. Instituto Superior de Agronomia, Lisboa.
- PEREIRA, M. G.; TRIGO, R. M.; CAMARA, C. C.; PEREIRA, J. M. C. e LEITE, S. M. (2005) - "Synoptic patterns associated with large summer forest fires in Portugal". *Agricultural and Forest Meteorology*, V. 129, pp. 11-25.

- PIÑOL, J.; TERRADAS, J. e LORET, F. (1998) - "Climate warming, wildfire hazard, and wildfire occurrence in coastal eastern Spain". *Climatic Change*, V. 38, pp. 345-357.
- PRADHAN, B. e LEE, S., (2007) - "Utilization of Optical Remote Sensing Data and GIS Tools for Regional Landslide Hazard Analysis Using an Artificial Neural Network Model". *Earth Science Frontiers*, V. 14, Issue 6, pp. 143-152.
- REGO, F. C. (1992) - "Land use changes and wildfire". In: TELLER, A.; MARTY, P. e JEFFERS, J. N. R. (Eds.) - *Responses of Forest Ecosystems to Environmental Changes*. Elsevier Applied Science, London, pp. 367-373.
- ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A. e DEERING, D. W. (1974) - "Monitoring vegetation systems in the great plains with ERTS". *Proceeding 3<sup>rd</sup> Earth Resource Technology Satellite (ERTS) Symposium*, V. 1, pp. 48-62.
- VIEGAS, D. X.; BOVIO, G.; FERREIRA, A.; NOSENZO, A. e SOL, B. (1999) - "Comparative study of various methods of fire danger evaluation in southern Europe". *International Journal of Wildland Fire*, V. 9(4), pp. 235-246.
- VASCONCELOS, M. J. P.; SILVA, S.; TOMÉ, M.; ALVIM, M. e PEREIRA, J. M. C. (2001) - Spatial prediction of fire ignition probabilities: comparing logistic regression and neural network". *Photogrammetric Engineering & Remote Sensing*, V. 67(1), pp. 73-81.
- WANG, J. e RAHMAN, M. S. (1999) - "A neural network model for liquefaction-induced horizontal ground displacement". *Soil Dynamics and Earth-quake Engineering*, V. 18, pp. 555-568.