

Pluris 2006

Anais do

**2º CONGRESSO
LUSO BRASILEIRO PARA O
PLANEAMENTO
URBANO
REGIONAL
INTEGRADO E
SUSTENTÁVEL**

**27 a 29 de
Setembro de 2006
Braga, Portugal**

**José Fernando Gomes Mendes
Rui António Rodrigues Ramos
António Néilson Rodrigues da Silva
Léa Cristina Lucas de Souza
(Editores)**

ISBN 85-85205-67-9



9 788585 205676



pluris 2006

**PLURIS 2006, 2º Congresso Luso-Brasileiro para o
Planeamento Urbano, Regional, Integrado e Sustentável**

PROGRAMA

Universidade do Minho, em Braga, Portugal

27, 28 e 29 de Setembro de 2006

ESTRUTURA DO PROGRAMA

Dia 27, 4ª Feira

8:30 às 9:30	Recepção dos Participantes e Entrega de Documentação
9:30 às 10:00	Sessão de Abertura
10:00 às 11:00	Conferências Convidadas
11:00 às 11:30	Pausa para café
11:30 às 13:00	Sessões Paralelas 1 e 2
13:00 às 14:30	Almoço
14:30 às 16:00	Sessões Paralelas 3, 4 e 5
16:00 às 16:30	Pausa para café
16:30 às 18:45	Sessões Paralelas 6 (<i>Inclui Conferência Convidada</i>), 7 e 8
19:00 às 20:00	Verde de Honra

Dia 28, 5ª Feira

09:00 às 11:00	Sessões Paralelas 9, 10 e 11
11:00 às 11:30	Pausa para café
11:30 às 13:00	Sessões Paralelas 12, 13 e 14
13:00 às 14:30	Almoço
14:30 às 16:00	Sessões Paralelas 15, 16 e 17
16:00 às 16:30	Pausa para café
16:30 às 18:45	Sessões Paralelas 18, 19 e 20
20:00	Jantar do Congresso

Dia 29, 6ª Feira

09:00 às 11:00	Sessões Paralelas 21, 22 e 23
11:00 às 11:30	Pausa para café
11:30 às 13:00	Sessões Paralelas 24, 25 e 26
13:00 às 14:30	Almoço
14:30 às 16:30	Sessões Paralelas 27 e 28
16:30	Sessão de Encerramento

Sessões Paralelas

Qualidade do Ambiente Urbano Construído	Sessões Paralelas 1, 3, 6, 9, 18, 21, 26 e 27
Transportes e Mobilidade Sustentável	Sessões Paralelas 4, 7, 10, 13, 16, 19, 22, 25 e 28
Planeamento Urbano e Regional	Sessões Paralelas 5, 8, 11, 14, 17, 20 e 23
Planeamento Sustentável	Sessões Paralelas 2, 12, 15 e 24

(Nota: No Programa estão assinalados a negrito os autores das Comunicações Oraís inscritos como participantes)

Sessões de Posters

Qualidade do Ambiente Urbano Construído	28 de Setembro - 09:00 às 13:00 e 14:30 às 18:30
Transportes e Mobilidade Sustentável	29 de Setembro - 09:00 às 13:00
Planeamento Urbano e Regional	27 de Setembro - 14:30 às 18:30
Planeamento Sustentável	28 de Setembro - 14:30 às 18:30

(Nota: No Programa estão assinalados a negrito os autores das Comunicações tipo Poster inscritos como participantes)

PAPER254 - INTEGRAÇÃO ENTRE IMAGENS AÉREAS E BANCO DE DADOS NA ATUALIZAÇÃO CADASTRAL

A. Amorim, G. H. B. Souza, G. G. B. Souza

PAPER266 - MAPEAMENTO ECODINÂMICO NA BACIA DO RIO MONJOLINHO – SÃO CARLOS – SP – IMPLICAÇÕES TÉCNICAS E DE PLANEJAMENTO

A. Cereda Junior, **S. A. Rohm** e J. A. Lollo

PAPER371 - POSICIONAMENTO RELATIVO COM RECEPTOR GPS DE NAVEGAÇÃO

P. O. Camargo, C. Florentino, G. N. Guimarães

PAPER416 - SENSORIAMENTO REMOTO AEROTRANSPORTADO: SISTEMA DE AQUISIÇÃO E MAPEAMENTO RÁPIDO A BAIXO CUSTO

J. K. Hasegawa, N. N. Imai, **P. O. Camargo**

PAPER466 - UTILIZAÇÃO DO SISTEMA DE POSICIONAMENTO GLOBAL PARA MONITORAMENTO DE TRANSPORTE FRETADO

Camila Maria de Paiva e Silva, **Maria Teresa Françoso**

16:30 - SESSÃO 20

TEMA: PLANEAMENTO URBANO E REGIONAL

PRESIDENTE DA SESSÃO: Rui António Rodrigues Ramos

SALA: Auditório EE2

DURAÇÃO: 135 MIN.

PAPER008 - A CIDADE DIGITAL VS. A CIDADE INTELIGENTE: ESTRATÉGIAS DE DESENVOLVIMENTO SÓCIO-ECONÓMICO E/OU DE MARKETING TERRITORIAL

Ricardo Fernandes e Rui Gama

PAPER038 - GEOIDAL CHARACTERIZATION BY ARTIFICIAL NEURAL NETWORKS

M. R. Veronez, F. Dapper, A. B. Thum, T. Valles and P. C. L. Segantine

PAPER094 - ANÁLISE ESPACIAL DA GERAÇÃO DE VIAGENS NO TRANSPORTE PÚBLICO INTERMUNICIPAL DE PASSAGEIROS DO ESTADO DO CEARÁ

Carlos Eduardo Freire Araújo, Camila Henrique Soares, Francisco Gildemir Ferreira da Silva

PAPER134 - CLASSIFICAÇÃO DOS USOS DO SOLO NO DOURO ATRAVÉS DE REDES NEURONAIS E MÉTODOS PROBABILÍSTICOS

José Miguel Matos, Delfim Fernandes, Luís Ramos, **Júlia Lourenço**

PAPER185 - DO DIGITAL AO INTELIGENTE: TÓPICOS PARA UMA ABORDAGEM GEOGRÁFICA

Rui Gama e Ricardo Fernandes

PAPER283 - MODELAÇÃO TRIDIMENSIONAL DO ESPAÇO URBANO A PARTIR DE DADOS OBTIDOS COM UM SISTEMA DE VARRIMENTO LASER 3D TERRESTRE

Adriano A. Pocinho de S. Oliveira, João Francisco de S. Vasconcelos M. Boavida

CLASSIFICAÇÃO DOS USOS DO SOLO NO DOURO ATRAVÉS DE REDES NEURONAIS E MÉTODOS PROBABILÍSTICOS

J. M. Matos, D. Fernandes, L. Ramos e J. Lourenço

RESUMO

No âmbito de um projecto mais alargado, tem vindo a ser estudada a evolução dos usos do solo partindo de informação com origem remota para uma região transmontana-duriense, com o objectivo de medir quantitativamente as mudanças em termos de usos e de acessibilidades. Assim, têm-se vindo a desenvolver um método assente em ferramentas informáticas que permita identificar e quantificar de forma automática áreas urbanas a partir de informações de origem remota. Os métodos utilizados têm sido: *i.* Redes Neurais e *ii.* Método *Maximum Likelihood*. Ambos partem de imagens de satélite e executam a identificação e classificação dos usos do solo. Alguns testes para a área urbana de Vila Real demonstraram melhores resultados para a classificação por redes neuronais. Paralelamente, tem-se desenvolvido um método de definição das características da rede, assente em experiências internacionais com bons resultados, que visam a análise das respostas do sistema à alteração de vários parâmetros intrínsecos da mesma.

1 INTRODUÇÃO

O registo da evolução dos usos do solo afigura-se essencial como ferramenta de apoio ao planeamento estratégico local e nacional, na definição de estratégias e políticas de gestão de recursos e na previsão da evolução da distribuição das classes de ocupação dos solos. A tendência actual de utilização de cartografia temática de ocupação do solo apoiada em imagens de satélite, é cada vez mais vista como uma ferramenta actualizada de apoio a diferentes níveis (regional e urbano). Torna-se por isso necessário, numa fase a montante, classificar correctamente as imagens espectrais utilizando, por exemplo, técnicas probabilísticas ou redes neuronais.

Verifica-se que têm sido desenvolvidas metodologias de tratamento de imagens de satélite, orientadas para a produção de cartografia de ocupação do solo, desde o lançamento há 30 anos do primeiro satélite. Mais concretamente, a partir da década de noventa, surgiram um conjunto de novas técnicas, no âmbito da previsão das transformações ou evolução dos usos do solo e no da classificação automática da superfície terrestre, não se podendo ainda identificar uma metodologia *standard* genericamente aceite (Caetano *et al.*, 2003). As principais famílias de métodos de classificação de imagens de satélite para uso cartográfico são a classificação de padrões espectrais ao nível do pixel, a classificação ao nível do pixel combinada com análise contextual e, por último, a análise de imagens orientada por objectos. As técnicas que estão a ser utilizadas neste estudo, *Maximum Likelihood* bem como a Rede Neuronal, fazem parte da primeira família.

Este artigo insere-se no âmbito de um projecto mais amplo que tem vindo a estudar a evolução dos usos do solo em sete municípios Durienses, partindo de informação com origem remota a que se associam, posteriormente, informações complementares. Apresenta-se nos pontos seguintes o estado da arte, a descrição das técnicas utilizadas e métodos em análise, principalmente os relativos à arquitectura da rede neuronal. Por último, exemplifica-se com um primeiro teste na cidade de Vila Real e discutem-se os resultados obtidos.

2 ESTADO ACTUAL DA DETECÇÃO REMOTA

Em Portugal, ainda se continuam a utilizar as fotografias aéreas como base de produção de cartografia temática de ocupação do solo (Santos, 2003), apesar de todas as suas desvantagens, nomeadamente a morosidade e elevado custo que representam, a impossibilidade de constante actualização dos dados e de tratamento automático por ferramentas computacionais (Lillesand, T. e Kiefer, R. J., 1994). A prazo, com o aumento da investigação na área da detecção remota e da classificação automática de imagens de satélite, a tendência de uso de fotografias aéreas deverá desaparecer (Caetano e Santos, 2001). Na verdade, o uso de imagens de satélite detém vantagens, tais como o acesso de forma sistemática e mais económica a imagens da superfície, possibilitando o arquivamento a um ritmo constante, facilitando a análise de tendências, contrariamente às fotografias aéreas que necessitam de um voo próprio e implicam mais meios e custos.

Genericamente, as imagens de satélite capturam a energia solar reflectida pelas superfícies dos objectos em várias frequências espectrais (imagens multiespectrais) ou capturam a superfície num único plano de imagem, adquirindo uma banda larga do espectro (imagem pancromática). Formam-se posteriormente bandas ou canais espectrais. O número de bandas de um satélite é a sua resolução espectral. As imagens captadas são estruturadas em matrizes regulares, em que cada quadrícula (i.e. pixel) corresponde a uma dada área do terreno. Para cada pixel é registado um vector de valores (i.e. números digitais), em que cada valor corresponde à quantidade de energia reflectida pela superfície do objecto, para as várias gamas espectrais (Santos, 2003). É a partir deste número digital que se procede ao tratamento automático (Lourenço, 2005). A escolha do tipo de imagens espaciais está condicionada pela finalidade do mapa. As imagens podem ser produzidas para escalas locais (grandes), com resoluções espaciais elevadas que podem atingir 1m (IKONOS, QUICKBIRD), para resoluções à escala regional com resoluções da entre 2.5m a 20m – SPOT e entre 30m a 120m – Landsat-TM, ou escala global (satélites meteorológicos). Alguns aspectos fundamentais são as perturbações induzidas por atmosfera, condições topográficas, curvatura da Terra e variação das assinaturas espectrais das superfícies.

Apresenta-se na Tabela 1 as características das imagens de satélite actualmente disponíveis. Relewa-se que o satélite americano Landsat é o mais antigo em funções, i.e., foi lançado em 1999 um satélite Landsat 7 com os sensores *Enhanced Thematic Mapper* (ETM) e *Advanced Landsat Sensor* (ALS), tendo no entanto sofrido uma avaria importante no *Scan Line Corrector*, em Maio de 2003. Este facto comprometeu a aquisição rectificada de imagens (NASA, Landsat Programm Update: Winter/Spring 2005) e como tal não é aqui descrito. Como se pode verificar na Tabela 1, a qualidade e quantidade das bandas espectrais captadas por parte dos satélites tem vindo a melhorar com o tempo, permitindo a selecção das bandas mais apropriadas e logo uma redução do número de bandas utilizadas. No entanto, também tem aumentado o custo associado às mesmas bem como a resolução radiométrica com a conseqüente ocupação de memória virtual.

Tabela 1 Características dos diferentes satélites disponíveis

Satélite Quickbird – lançado em Outubro de 2001				Satélite IKONOS – lançado em Setembro de 1999			
Espectro electromagnético	Bandas Espectrais (μm)	Resolução Espacial (m)	Resolução Radiométrica (bytes)	Espectro electromagnético	Bandas Espectrais (μm)	Resolução Espacial (m)	Resolução Radiométrica (bytes)
1	0.45–0.52	2.44	16	1	0.45–0.52	4	11
2	0.52-0.60	2.44	16	2	0.52-0.60	4	11
3	0.63-0.69	2.44	16	3	0.63-0.69	4	11
4	0.76-0.90	2.44	16	4	0.76-0.90	4	11
Pancromático	0.45-0.90	0.60	16	Pancromático	0.45-0.90	1	11
Satélite SPOT5 – lançado em Maio 2002				Satélite Landsat TM 5 – lançado em Março de 1984			
Espectro electromagnético	Bandas Espectrais (μm)	Resolução Espacial (m)	Resolução Radiométrica (bytes)	Espectro electromagnético	Bandas Espectrais (μm)	Resolução Espacial (m)	Resolução Radiométrica (bytes)
1 – <i>green</i>	0.48-0.71	10	8	1	0.45-0.52	30	8
2 – <i>red</i>	0.50-0.59	10	8	2	0.52-0.60	30	8
3 – <i>near infrared</i>	0.61-0.68	10	8	3	0.63-0.69	30	8
4 – <i>mid infrared (MIR)</i>	0.78-0.89	20	8	4	0.76-0.90	30	8
Pancromático	1.58-1.75	2.5 ; 5.0	8	5	1.55-1.75	30	8
				6 <i>IR Thermal</i>	10.42-12.50	120	8
				7	2.08-2.35	30	8

Fonte: Fonseca, 2005; SPOT Image Technical Information (www.spotimage.com); <http://landsat.gsfc.nasa.gov/>

3 TÉCNICA PROBABILÍSTICA *MAXIMUM LIKELIHOOD*,

A classificação *Maximum-Likelihood* é uma classificação paramétrica que se baseia na função de densidade probabilística Gaussiana (*Gaussian probability density function – PDF*) para cada classe. Este método é muito preciso se as classes PDF forem na verdade gaussianas e se boas assinaturas de radiação e boas amostras de treino estiverem disponíveis, caso contrário, tem grande dificuldade de identificação da área correcta (Paola *et al.*, 1995). Muito frequentemente, o valor exacto PDF não é conhecido. Uma técnica comum para determinar esta distribuição probabilística é assumir uma forma geral de distribuição e, de seguida, usar a técnica *Maximum Likelihood* para estimar os parâmetros que descrevem essa mesma distribuição. Esta técnica é óptima se na determinação de PDF se assumiu a forma correcta de distribuição, caso contrário, a estimação dos parâmetros por parte da técnica vai fornecer um PDF da forma assumida que melhor se adequa à realidade, logo, suposições incorrectas levam a erros de classificação. Outra assumpção que é feita pela técnica *MaxLike* é a probabilidade “*a priori*” de cada classe, i.e. a probabilidade que uma entrada escolhida aleatoriamente vai ter. A necessidade de se ter um modelo probabilístico específico é uma limitação que se acumula à necessidade de se terem verdadeiros PDF, caso contrário a *performance* não satisfaz.

Cumulativamente, estes métodos utilizam a informação espectral numa base pixel a pixel, não incorporando informação contextual. Também por isto os resultados da classificação de uso/classes de solo desta técnica apresentam-se, por vezes, menos precisos do que os resultados derivados de um intérprete de imagem bem treinado. Esta técnica

tradicionalmente utilizada está a cair em desuso com o surgimento das redes neuronais, mais poderosas no processamento de informação.

4 APLICAÇÃO DE REDES NEURONAIS NA DETECÇÃO REMOTA

As redes neuronais têm vindo a ser mais utilizadas desde a década de 90. Este aumento prende-se com os avanços tecnológicos dos computadores e com a descoberta/desenvolvimento de técnicas algorítmicas que permitem avançar na capacidade, *performance* e diminuição do tempo de cálculo e treino da rede. O uso de redes neuronais é complexo devido sobretudo, aos problemas de concepção e de implementação da rede (Kavzoglu e Mather, 2003). Começa a ser genericamente aceite que as redes neuronais produzem classificações com resultados mais precisos do que os métodos probabilísticos. Porém, tal pode não se verificar se as características da rede não forem óptimas para o problema em questão, não maximizando as suas potencialidades. A partir de um número menor de amostras, as redes neuronais geram melhores resultados, têm maior capacidade de adaptação ao problema e de generalização (Paola *et al.*, 1995; Atkinson e Tatnall, 1997; Kazvoghlu e Mather, 2003).

As redes neuronais são de natureza não-paramétrica, não assumindo uma abordagem “*a priori*” particularmente quanto à frequência da distribuição da informação, ao contrário da abordagem *Maximum-Likelihood*. O modelo de rede neuronal mais utilizado tem sido o *Multilayer Perceptron* MLP, com três camadas (*input* ou entrada, que é geralmente única, *hidden* ou intermédia com número variável e *output* ou saída que também é única), comportando um número variável de elementos de processamento - EP. Estes estão interconectados, exceptuando os elementos de processamento da mesma camada. É um modelo do tipo *feedforward*, ou seja, a informação é introduzida na camada de entrada, processada na camada intermédia e apresentada na camada de saída. As redes neuronais ou modelos conexionistas são sistemas que consistem num grande número de unidades muito simples mas altamente conectadas. A informação não é processada em série ou linearmente, permitindo que o sistema opere em ambientes com “ruído” ou com informações degradadas ou incompletas. Um EP pode ser considerado como um simples processador com muitas entradas derivadas de outras unidades de processamento. A cada conexão da rede está associado um peso (Bischof *et al.*, 1992). MLP é uma rede neuronal supervisionada, não sendo completamente autónoma, necessitando de ajuda de terceiros, nomeadamente os supervisores que “ajudam” a rede a aprender as características da informação base. Desta forma, um algoritmo de aprendizagem é nuclear. O algoritmo mais popular e que melhores resultados tem apresentado é o *Backpropagation Algorithm*.

5 PROCEDIMENTO DE DEFINIÇÃO DA ARQUITECTURA DA REDE E DOS PARÂMETROS DE APRENDIZAGEM

Para desenvolver um método ou técnica que consiga interpretar automaticamente, informações com origem remota torna-se necessário definir a arquitectura da rede neuronal. Este aspecto é fundamental para que a rede seja eficaz e para a maximização da precisão dos resultados, interferindo na capacidade de aprendizagem e de generalização. Provas da vulnerabilidade da precisão de rede neuronal se esta não for bem determinada, foram obtidas por Kazvoghlu e Mather (2003) que apresentaram resultados de redes neuronais 10% inferiores ao resultado obtido a partir da classificação pela técnica *Maximum-Likelihood*, enquanto que uma rede bem delineada obteve resultados 10% superiores. Tendo em vista facilitar o processo de definição da arquitectura da rede

neuronal, vai-se proceder a uma análise do estado da arte nesta matéria. Avaliam-se os efeitos da *performance* da rede através da precisão da classificação global e do coeficiente Kappa, relativamente às variações na disposição da rede quanto ao número de elementos de processamento (EP), parâmetros de aprendizagem, número e tamanho das amostras de treino, critério de paragem e código de saída.

5.1 Definição dos números de EP de entrada e de saída

O número de elementos de processamento EP da entrada é geralmente igual ao número de características que serão introduzidas na rede e a partir das quais a classificação se baseará. No caso presente em que a informação base consiste em imagens de satélite com informação espectral, é aconselhável indicar um EP para cada canal ou banda espectral. O número de elementos na camada de entrada define a complexidade do problema. O tamanho desta camada também é influenciado pelo código da informação utilizada (quantos mais bytes tiver um pixel, maior será o número de EP na entrada). Na procura de melhorar o tempo de cálculo da rede, Kavzoglu e Mather (2003) propuseram técnicas de identificação e selecção das bandas mais relevantes para a identificação de áreas urbanas a partir de detecção remota. A análise passa pela definição do número de iterações, relacionando-se no final o número de bandas com a precisão da rede experimental. Um teste cego de 5 até 24 bandas com 5, 10 e 15 mil iterações, obtiveram as melhores classificações para um número de 23 bandas com qualquer nível iterativo e para 10 bandas a 5000 iterações. No entanto, os autores não revelam quais as bandas objecto de estudo.

O número de EP da camada de saída tem correspondência com o número de classes que se pretende obter, determinando a complexidade da rede neuronal, sendo que quanto maior o número de elementos de saída, maior a dificuldade do problema, já que maior é a necessidade de separação das características espaciais. A técnica de codificação da saída é determinante na definição do número de elementos saída. A forma convencional de se representarem as classes de saída na rede neuronal consiste em disponibilizar para cada classe um EP de saída e atribuir valor 1 ao EP que corresponde à classe seleccionada e 0 aos EP's que representam outras classes. A vantagem desta abordagem é a de que o nível de activação dos EP de saída é, de certa forma, análogo à probabilidade (*a posteriori*) de pertença a determinada classe, apesar de não ser verdadeira probabilidade (Kavzoglu e Mather, 2003). No caso do número de EP de entrada igualar o número de EP de saída, a rede diz-se auto-associativa.

5.2 Definição da camada intermédia: número e elementos de processamento

É nesta camada, que pode ser unitária ou múltipla, que reside a grande dúvida na definição da arquitectura da rede e a maior dificuldade. Não existe ainda consenso na comunidade científica quanto ao método mais eficaz de definição do número de camadas e do número de EP em cada camada. Essencialmente, o número de EP na camada intermédia define a complexidade e o poder da rede neuronal em estabelecer conexões e relações entre e com a informação contida nos objectos de estudo. A composição desta camada tem considerável influência na precisão da classificação, no tempo de treino e na quantidade de cálculos necessários. O número de camadas e de elementos de processamento influenciam a precisão da rede na medida em que é nesta camada que se desenvolve a representação do problema ou a sua generalização. Assim, o poder da rede neuronal, ou a sua capacidade de generalização depende acentuadamente desta camada (Kavzoglu e Mather, 2003). Deve-se ter grande atenção para se garantir que a rede não fica demasiado reduzida, produzindo

soluções que não identificam a estrutura interna do problema (*underfitting*), nem demasiado grande, potenciando uma diminuição da capacidade de generalização da rede (*overfitting*). Neste último caso, este tipo de rede tem um bom desempenho para a informação de treino, mas falha na classificação de informação que desconhece, fora da informação de treino, conduzindo a menores precisões e a tempos de cálculo mais elevados.

Garson (1998) é da opinião que uma camada intermédia é suficiente para a maioria dos problemas, especialmente para problemas de classificação. Porém, outros como Hand (1997), Kanellopoulos e Wilkinson (1997) afirmam que caso a camada intermédia comporte um elevado número de EP ou caso na camada saída existam mais de 20 unidades de saída uma segunda camada intermédia deverá ser implementada para diminuir os tempos de treino e cálculo e facilitar as interacções entre elementos de processamento.

Sarle (2000) reconhece que o problema de determinar o número óptimo de EP intermédios não é fácil, pois depende numa forma complexa do número de unidades de entrada e saída, do número de amostras de treino, da complexidade da classificação a ser apreendida pela rede, do nível de ruído da informação, da arquitectura da rede, da natureza da função de activação do EP intermédio e do algoritmo de treino (Kavzoglu e Mather, 2003). Huang e Huang (1991) afirmam que o número de EP intermédios deve ser muito inferior ao número de amostras de treino, de forma a não haver memorização das amostras pela rede, o que pode levar a falhas na classificação de informação desconhecida. O tamanho e a natureza das amostras de treino também são relevantes na determinação da quantidade de EP intermédios. Se a informação base contiver elevada quantidade de ruído, então maior o número de elementos de processamento que serão necessários. Outro aspecto a ter-se em conta é a estratégia de paragem da rede. Se adoptando uma estratégia de paragem rápida necessitaremos de um maior número de EP para não se correrem riscos de *underfitting* ou encontrar um solução que não corresponda ao mínimo global, mas ao mínimo local da função erro (Sarle, 2000).

Existem várias abordagens e nenhuma é reconhecida como a ideal. No entanto, todas determinam o número de EP da camada intermédia em função do número de entrada EP e saída EP. Para se investigar na prática o efeito o número de EP da camada intermédia deve-se realizar uma experiência que relacione o número de EP com a precisão da rede neuronal. Para tal, define-se uma rede experimental onde o número de EP de entrada e saída são constantes, variando apenas o número de EP da camada intermédia. Define-se o intervalo de valores iniciais dos pesos e a taxa de aprendizagem. Este procedimento não responde à determinação exacta do número de EP da camada intermédia, mas ajuda a estabelecer um ponto de partida na procura do número ideal. Genericamente aceita-se a teoria de Hush (1989) que afirma que a eficácia da rede é sensível a arquitecturas pequenas e insensível a arquitecturas grandes, sendo que os resultados de Kavzoglu e Mather (2003) facilmente comprovaram o mesmo nível de precisão de 4 EP até 24 EP intermédios.

5.3 Taxa de aprendizagem e *momentum*

Esta taxa determina o número de passos do processo de treino na procura do mínimo global da função erro (Kavzoglu e Mather, 2003). É um dos elementos chave na rede neuronal, pois controla a velocidade e a eficácia do processo de aprendizagem. Se a taxa for de valor elevado, serão necessários muitos passos para chegar ao mínimo global, instabilizando a rede e falhando na convergência. Se, pelo contrário, o número de passos

for pequeno, então necessitar-se-á de mais tempo de treino e cálculo e a rede pode ficar presa num mínimo local da função erro. A taxa de aprendizagem é usada para actualizar os pesos das ligações entre camadas, com ou sem *momentum*. O *momentum* usa a configuração prévia do erro para determinar em que direcção a procura do mínimo global se deve efectuar. É necessária uma selecção cuidadosa destes parâmetros para assegurar uma convergência suave para o mínimo global.

Para se investigar a taxa de aprendizagem e o valor de *momentum* mais eficazes tem de se proceder à elaboração de uma rede neuronal experimental, treinada através do algoritmo *backpropagation*, definindo-se à partida os valores iniciais dos pesos. Podem-se testar estes parâmetros de duas formas: *i.* o valor de taxa de aprendizagem, mantendo o valor de *momentum* constante *ii.* introduzindo o par taxa de aprendizagem/*momentum* mais eficaz, verificando-se a precisão da rede para ambos os casos. Aparentemente, valores mais pequenos da taxa de aprendizagem (e.g. taxa de aprendizagem = 0.2) correspondem a maiores precisões. Cumulativamente, Kavzoglu e Mather, 2003 verificaram que se se dispuser de taxas de aprendizagem elevadas aliadas a valores de *momentum* elevados gerar-se-á um fenómeno de aumento do efeito oscilatório. A inclusão do *momentum* proporcionou um abrandamento do tempo de treino e cálculo, mas com melhoria da precisão.

5.4 Valores iniciais dos pesos das conexões entre elementos de processamento

Kolen e Pollack (1990) demonstraram a extrema sensibilidade do algoritmo *backpropagation* à configuração inicial dos pesos. No início, a rede define para a primeira iteração quais os pesos iniciais das conexões entre EP de camadas diferentes. Estes pesos são posteriormente corrigidos pelo algoritmo *backpropagation*. No entanto, a ordem de grandeza dos valores iniciais tem alguma importância, sobretudo no processo de aprendizagem, ora facilitando-o, ora tornando-o mais moroso no tempo de treino e diminuindo a precisão da classificação. Os pesos iniciais definem o ponto de partida na determinação dos melhores pesos e, logo, melhores conexões entre os EP. O objectivo é definirem-se logo à partida valores que, de forma esperada, não fujam muito dos pesos mais convenientes. Cada iniciação dos pesos define um caminho diferente para se atingir o mínimo global da função erro. Quando são introduzidos valores iniciais elevados potencia-se a saturação dos EP e o processo de aprendizagem abranda. Para pesos iniciais pequenos, o algoritmo *backpropagation* começa a operar numa zona *flat*, estagnando, não chegando ao mínimo global, mas a um mínimo local da função erro. Os pesos também podem ser inicializados aleatoriamente, dentro de um intervalo predefinido. No entanto, isso poderá tornar impossível a repetição do processo de aprendizagem, visto que os pesos nunca serão iguais, logo a cada repetição corresponderá uma diferente taxa de precisão final. Mas este facto pode ser aproveitado de uma forma positiva, já que o processo de aprendizagem pode ser repetido várias vezes com valores iniciais diferentes, mas da mesma ordem de grandeza ou do mesmo tipo. A cada valor inicial corresponderá um caminho diferente ao encontro do mínimo global da função erro o que possibilita identificar-se o melhor caminho dentro do mesmo tipo de valores.

Não existe, até ao momento, nenhum método globalmente aceite para determinar o valor inicial. A determinação do intervalo mais apropriado está relacionado com diversos factores, incluindo o tamanho da rede, o número de amostras de treino e as taxas de aprendizagem e *momentum*. Para se estabelecer qual o intervalo de valores mais conveniente começa-se por elaborar uma rede neuronal experimental, definindo-se a taxa

de aprendizagem inicial, *momentum*, o número de iterações e os intervalos de valores a testar. Segundo Kavzoglu e Mather (2003), os intervalos mais adequados situam-se entre $[-0.15, 0.15]$ e $[-0.25, 0.25]$.

5.5 Número de amostras de treino

O número de amostras de treino tem impacto significativo na *performance* do modelo e da rede neuronal. A rede aprende as características do problema a partir da informação que lhe é fornecida na fase de treino. Poucas amostras podem ser insuficientes para que a aprendizagem das características das classes a classificar, enquanto que um excesso de amostras pode provocar *overfit* ou sobrecarga de informação e leva a maiores tempos de treino. No entanto, é preferível o excesso de amostras do que a escassez das mesmas.

A questão essencial passa por definir quantas amostras de treino são necessárias para se maximizar a precisão da classificação. A resposta depende essencialmente da dificuldade do problema, das características do treino e da estrutura da rede. Para uma rede de tamanho fixo, o erro diminui exponencialmente com o aumento do tamanho das amostras e o número de padrões a classificar, para alcançar uma *performance* estável, aumenta linearmente com o aumento do tamanho da rede (Kavzoglu e Mather, 2003).

Para se verificar qual o número ideal de amostras procede-se à elaboração de uma rede neuronal experimental, definindo-se a taxa de aprendizagem e o *momentum*, o intervalo de valores iniciais dos pesos e o número de iterações. Varia-se o número de amostras de treino e verifica-se a correspondente precisão da rede através do coeficiente Kappa e da estimativa de precisão total de classificação. Os autores anteriores não revelam o tamanho das amostras com que trabalharam mas afirmam que a variação da precisão da rede abrandava a partir de 1000 amostras para 10000 iterações. Outra questão relevante é a ordem pela qual as amostras são apresentadas à rede. A maioria dos especialistas indica que estas devem ser introduzidas de forma aleatória para que a rede não se concentre em apenas um grupo de amostras referente a uma categoria de uso/classe do solo.

5.6 Critério de paragem

O critério de paragem representa outra dificuldade no uso das redes neuronais. Consiste em determinar até que ponto se deve prosseguir com o processo de aprendizagem da rede antes do fenómeno *overfitting* e depois do *underfitting*. Existem várias abordagens: *i.* tendo prévio conhecimento de como se comportam as redes e como é expectável que evolua o erro, o treino termina quando o erro estimado se encontra abaixo de um valor de referência introduzido pelo supervisor ou após um número de iterações fornecido exteriormente; *ii.* outra técnica é a *cross validation* que é mais directa. Nesta técnica existem dois tipos de dados: treino e validação. Assume-se que a rede testada com amostras de validação se comportará da mesma forma do que para amostras desconhecidas. Durante o processo de aprendizagem, a *performance* da rede tende a melhorar sobre as amostras de treino enquanto que a *performance* da rede sobre a validação tende a melhorar até ao ponto em que a mesma começa a saturar e a entrar em *overfitting*, esgotando a capacidade de generalização. O processo de aprendizagem termina quando o erro estimado para as amostras de validação tende a aumentar. A principal vantagem deste método é que não sofre dos efeitos do tamanho da rede nem da escolha dos parâmetros de aprendizagem. Tem, no entanto, algumas desvantagens: *i.* é computacionalmente mais exigente e requer mais tempo de treino; *ii.* necessita de mais dados, o que pode ser problemático para áreas

com número limitado de amostras; *iii.* há o perigo da rede parar num local mínimo da função de erro, pois podem ocorrer aumentos locais de erro da série de dados da validação.

Deve-se proceder à análise das técnicas de paragem descritas, começando por definir as amostras de treino e de validação, a arquitectura da rede neuronal experimental, os valores dos pesos e da taxa de aprendizagem. Todas as amostras devem ser escolhidas aleatoriamente. A técnica *cross validation*, recomendada por Kavzoglu e Mather (2003) é a mais avançada mas não é de aplicação linear.

6 ESTUDO DE CASO NO DOURO

A região objecto de estudo situa-se na parte central do Norte de Portugal, compreendendo 7 municípios: Alijó, Mesão-Frio, Murça, Peso da Régua, Sabrosa, Santa Marta de Penaguião e Vila Real, com um total de 1202,7 km². É uma sub-região intermédia que faz a transição entre a sub-região litoral mais desenvolvida e o interior norte, onde as cidades de Vila Real, Régua e Lamego actuam como um eixo de desenvolvimento sub-regional, atraindo investimentos e concentrando populações.

Neste contexto, foi dada prioridade à análise da evolução da área urbana da Cidade de Vila Real, actualmente (2003) com 10,90km² para testar as possíveis relações causa-efeito decorrentes da implementação do eixo rodoviário IP4 entre os anos 1985 e 2005, especialmente no que concerne à dinâmica de evolução temporal do centro urbano, ao acesso à cidade e às alterações dos usos do solo. Esta análise justifica-se na medida em que a rede de infra-estruturas que suporta o transporte de pessoas e bens está intimamente relacionada com a estrutura espacial, afectando a sua organização, pelo que quaisquer mudanças, físicas ou temporais, introduzem alterações nessa mesma organização espacial (Fernandes *et al.*, 2006). Para tal, é necessário numa fase anterior obter mapas da zona de estudo que sirvam de base ao objectivo apresentado. O intervalo de 20 anos afigura-se como um período de estudo adequado para detectar a evolução da área urbana. É maior do que os intervalos utilizados por Pontius e Malanson (2005) – 14 anos, e Pijanowski *et al.* (2005) – 7 e 15 anos, em modelos de previsão de alterações do tecido urbano.

Utilizaram-se redes neuronais para a classificação automática do solo, através de uma imagem aérea de 1985 e imagens de satélite (SPOT5) de 1985/86, 1995 e de Setembro de 2003 com as bandas *red*, *infrared* e *medium infrared*, com 19 805 786 pixels, devidamente corrigidos geométrica e radiometricamente. As classes a delimitar foram: pinheiros, pomares, zonas industriais urbanas, áreas não cultivadas, vinha, áreas alteradas artificialmente e equipamentos, e posteriormente em duas classes somente: áreas urbanas *i.* contínuas e *ii.* descontínuas (Fernandes *et al.*, 2006). Adicionalmente, utilizaram-se informações auxiliares, tais como a Carta de Ocupação do Solo de 1995 e informações estatísticas relativas ao número de edifícios e da população. A informação base é do satélite SPOT5, com resolução de 10m*10m (3 bandas). Poderia ser mais indicado, no plano teórico, trabalhar a escalas mais largas como a 2.44m do satélite IKONOS, mas tal é computacionalmente mais exigente, como tal mais moroso e ainda dispendioso face à área da região de estudo e ao custo associado de aquisição de imagens, tal como atesta a Tabela 2.

Tabela 2 Comparação do custo de aquisição de imagens de satélite

Satélite	Custo unitário (€/100km ²) Valores extremos	Custo total para área de estudo (€)
Quickbird	1319.17 (a) – 2061.21 (c)	15870.0 (a) – 24796.0 (c)
IKONOS	1319.17 (a) – 8821.98 (c)	15870.0 (a) – 106128.0 (c)
SPOT5	52.78 (a) – 247.22 (c)	635.0 (a) – 2974.0 (c)
Landsat TM 5	0.63 (b) – 1.34 (a)- 4.74 (c)	8.0 (b) – 57.0 (c)

Fonte: TELSAT – Programme, actualizado em 17/01/2006

Nota: (a)imagens de arquivo; (b) imagens de arquivo (1975 a 1993); (c) imagens actuais

A metodologia desenvolvida passa pelo pré-processamento da imagem de satélite e da informação auxiliar, a classificação da imagem, a identificação de *clusters*, aplicação de regras e modelos e, no final, a validação dos resultados (Fernandes *et al.*, 2006). Poder-se-á ainda aperfeiçoar o desempenho da rede neuronal de classificação desta área piloto segundo o procedimento atrás referido no ponto 5. Uma arquitectura possível é a que comporta 7 EP ou 2 EP de saída, visto pretender-se obter sete ou duas classificações. O número de EP's de entrada terá de ser em número suficiente para as duas bandas espectrais e as informações adicionais a introduzir como auxiliaadoras da classificação. A camada intermédia pode-se definir iterativamente analisando as variações da precisão da rede. O número de amostras, o tamanho, a representatividade dos mesmos e a ordem de apresentação à rede serão importantes no desempenho e na avaliação do mesmo.

Paralelamente poder-se-ão desenvolver outras informações auxiliares de classificação, sendo que as mesmas poderão auxiliar, numa fase posterior, à realização de modelos preditivos, avaliando, à escala da unidade fundamental – UF (pixel ou célula), a adequabilidade das características presentes no mesmo. Informação quanto à mobilidade, pode revelar-se importante, na medida em que representa o potencial de acessibilidade de cada UF, que pode ser caracterizável pela definição de linhas isócronas que relacionem espaço-tempo a partir de um ponto notável que interfira na evolução do tecido urbano, como as saídas da auto-estrada ou o centro urbano. Para cada UF estima-se o tempo necessário até ao ponto notável. A utilização de linhas isócronas pode ser mais vantajosa do que a medição da distância absoluta utilizada por Pijanowski *et al.* (2005) de cada UF que implicaria recorrerem-se a curvas de nível, já que o terreno objecto de estudo apresenta relevo extremamente acidentado. O relevo é um outro factor importante na localização da malha urbana e na sua expansão, pelo que a utilização de um ficheiro com a informação de variação topográfica à volta de cada UF seria outro indicador relevante (Pijanowski *et al.*, 2005; Dietzel *et al.*, 2005). A análise de zonas de exclusão como parques, zonas já urbanizadas, recursos hídricos, reservas naturais e agrícolas é outro indicador relevante, pois assinala zonas condicionadas ou excluídas que não comportam variação do uso actual (Pijanowski *et al.*, 2005).

Todos estes factores podem ser muito relevantes aquando da introdução de informação auxiliar na rede neuronal e noutra fase, mais a jusante, que passa pela realização de modelos preditivos da evolução da malha urbana.

7 CONCLUSÃO

A extracção de informação é a principal fase do processamento e classificação das imagens de satélite. Pretendeu-se testar na área urbana de Vila Real isso mesmo, partindo de imagens do satélite SPOT 5, que também fornece as imagens de base para a região de

estudo com 1203km². Estas imagens são significativamente mais económicas (3% do custo de imagens IKONOS) do que as demais (excepto Landsat) e não apresentam significativas diferenças na qualidade. A escala de resolução é de 10m, adequando-se à análise em questão justificando-se pelos menores custos de aquisição da informação.

Para a extracção de informação têm sido utilizadas ferramentas que têm sido desenvolvidas na última década – as redes neuronais e a técnica *Maximum Likelihood* (mais antiga), estudando-se aqui um ponto essencial para a primeira – definição da arquitectura da rede, não havendo no contexto internacional um método genericamente aceite. Deste modo, pretendeu-se descrever um conjunto de regras simples de utilizar que facilitam a definição da arquitectura para a resolução de um determinado problema. Porém, tal objectivo é de momento difícil de atingir devido ao elevado número de variáveis que a definição da rede obriga a analisar e, ainda, pela implicação em cada uma dessas variáveis de um outro conjunto de incógnitas relativas à natureza do problema, informação base, quantidade e tamanho da informação base, etc. Com este trabalho articulou-se o conhecimento e as técnicas de computação com os conteúdos geográficos, isto é, foi possível melhorar matematicamente o desempenho da rede pela implementação do procedimento descrito no ponto 5, avaliando o seu grau de precisão global. Cumulativamente, estão em fase de avaliação extensiva as saídas da rede em termos geográficos, verificando se a mesma produziu classificações que podem representar erros diminutos do ponto de vista percentual, mas que são graves geograficamente, (e.g. a não classificação de uma pequena localidade). Os resultados apresentam-se até ao momento animadores, com erros inferiores a 10%, pelo que se espera com o potencial melhoramento do desempenho, que estes venham a ser ainda melhores para o conjunto dos sete municípios transmontanos.

AGRADECIMENTOS

Os autores gostariam de agradecer o suporte da Fundação para a Ciência e Tecnologia (FCT) no âmbito do Projecto de investigação POCTI – CIVIL 49495.

REFERÊNCIAS

Atkinson, P. M., e Tatnall, A. R. L. (1997) Neural networks in remote sensing, **International Journal of Remote Sensing**, 18, 699–709.

Bischof, H; Schneider; e Pinz A.J. (1992) Multispectral classification of Landsat images using neural networks, **IEEE Transactions on Geoscience and Remote Sensing**, 30, 3.

Caetano, M. e Santos, T. (2001) Updating land cover maps with satellite images, **Proceedings of IGARSS'2001**, Sydney.

Caetano, M.; Santos, T. e Gonçalves, L. (2003) **Cartografia De Ocupação Do Solo Com Imagens De Satélite: Estado Da Arte**, CNIG.

Dietzel, C.; Herold, M; Hemphill, J.J.; and Clarke, K.C. (2005) Spatio-temporal dynamics in California's Central Valley: Empirical links to urban theory, **International Journal of Geographical Information Science**, 19 (2), 175–195.

Fernandes, D e Ramos, L e Lourenço, J.M. (2006) The Impact of a Main Road (IP4) on the Development of Urban Soil Use in Municipality of Vila Real, **25th Urban Data Management Symposium** (CD-ROM).

Fonseca, A. M. (2005) **Exploração de imagens de alta resolução**, LNEC.

Garson, G. D. (1998) **Neural Networks: An Introductory Guide for Social Scientists**, Sage, London.

Hand, D. J. (1997) **Construction e Assessment of Classification Rules**, John Wiley, NY.

Huang, S. C., e Huang, Y. F. (1991) Bounds on the number of hidden neurons in multilayer perceptrons. **IEEE Transactions on Neural Networks**, 2, 47–55.

Hush, D. R. (1989) Classification with neural networks: a performance analysis. **Proceedings of IEEE International Conference on Systems Engineering**, 277–280.

Kanellopoulos, I., e Wilkinson, G. G. (1997) Strategies e best practice for neural network image classification, **International Journal of Remote Sensing**, 18, 711–725.

Kavzoglu, T. e Mather, P.M. (2003) The use of back propagating artificial neural networks in land cover classification, **International Journal of Remote Sensing**, 24(23).

Kolen, J. F. e Pollack, J. B. (1990) Back propagation is sensitive to initial conditions, **Complex Systems**, 4, 269–280.

Lillesand, T. e Kiefer, R. J. (1994) **Remote Sensing e Image Interpretation**, Wiley & Sons, 3^a Edição, Londres.

Lourenço, J.M., Ramos, L. Ramos, R. Santos, H. e Fernandes, D. (2005) Urban Areas Identification through Clustering Trials and Neural Networks, **14TH European Colloquium on Theoretical and Quantitative Geography**, (CD-ROM).

NASA (2005) **Landsat Programm Update: Winter/Spring**.

Paola, J. e Schowengerdt, A. (1995) A Detailed Comparison of Backpropagation Neural Network e Maximum-Likelihood Classifiers for Urban Land Use Classification, **IEEE Transactions On Geoscience E Remote Sensing**, 3-4.

Pijanowski, Bryan C.; Pithadia, Snehal; Shellito, Bradley A.; Alexandridis, Konstantinos (2005) Calibrating A Neural Network-Based Urban Change Model for Two Metropolitan Areas of the Upper Midwest of the United States, **International Journal Of Geographical Information Science**, 19 (2), 197–215.

Pontius, Gil R.; Malanson, Jeffrey (2005) Comparison of the Structure and Accuracy of Two Land Change Models, **International Journal Of Geographical Information Science**, 19(2), 243–265.

Santos, T. (2003) **Actualização de Cartografia Temática com Imagens de Satélite**, Dissertação de Mestrado, IST, Lisboa.

Sarle, W. S. (2000) **Neural network FAQ** (<ftp://ftp.sas.com/pub/neural/FAQ.html>).