

Lab 6: Cartografia da impermeabilidade urbana por integração de dados laser e imagens multi-espectrais

Data limite de entrega: 23 Dezembro de 2011

(Ver 1.4/Dez-11)

1. Objectivos:

Adquirir competências na utilização de técnicas de geoprocessamento na produção de cartografia temática sobre a impermeabilidade urbana.

2. Dados¹:

São dados dois conjuntos de dados:

1. O primeiro conjunto de dados (OrtoareaLaser.rar) trata-se de orto-imagens multiespectrais de alta resolução (GSD=0.5m) com 4 bandas espectrais
2. O segundo conjunto de dados (LaserCBR.rar) trata-se de dados laser já processados contendo um Modelo Digital de Terreno (MDT) um Modelo Digital de Superfície (MDS) e de um Modelo Digital de Superfície normalizado pelo MDT (MDSn). Embora a resolução espacial inicial destes modelos seja de 1m e o formato ESRI GRID, estes são fornecidos numa geodatabase pix.

3. Tarefas a realizar

1. O objectivo principal deste trabalho consiste na caracterização das áreas impermeáveis da cidade de Coimbra com recurso à classificação de orto-imagens multi-espectrais. Tendo em conta as características dos dados será necessário definir que classes é que são importantes para caracterizar a impermeabilidade. Neste sentido é sugerido seguir um dos trabalhos citados (por exemplo o de Herold and Joseph (2002)).
2. Avaliar a exactidão da classificação utilizando a ortoimagem e áreas de teste obtidas, por exemplo, por fotointerpretação conjunta das orto-imagens e da cartografia 1:10k
3. Caso esteja interessado, pode também analisar se a integração, no processo de classificação, da informação relativa ao MDSn melhora, ou não, a exactidão da classificação temática.
4. Escrever um relatório que indique a metodologia utilizada. Utilize a seguinte estrutura para o seu relatório:
 - Introdução
 - Metodologia
 - Resultados
 - Conclusões

4. Estudo da impermeabilidade urbana

Introdução

A expansão urbana é uma das realidades nos dias de hoje, em qualquer parte do nosso planeta. O consequente aumento das superfícies impermeáveis, devido à expansão urbana, tem grandes impacto ambientais. De modo geral, os efeitos ambientais das superfícies impermeáveis podem ser divididos em seis categorias. Em primeiro lugar, no que concerne ao fluxo de água, as superfícies impermeáveis provocam o aumento do volume e velocidade de escoamento superficial, o que por sua vez aumenta o risco de cheias durante as tempestades. Em estações de seca as superfícies impermeáveis, reduzem também a recarga de águas subterrâneas conduzindo a leitos secos das linhas de água urbanas. Em segundo lugar, o aumento do volume e velocidade de escoamento superficial, provoca também erosão das áreas de construção, das linhas de água e a degradação dos referidos habitats. Em terceiro lugar, as superfícies impermeáveis são muito eficientes para o transporte de poluentes, causando poluição generalizada (i.e não-pontual) e põe em risco a qualidade da água. Em quarto lugar, as superfícies impermeáveis têm um impacto térmico sobre o fluxo de água e consequente degradação da qualidade

¹ Os dados relativos a este lab podem ser obtidos em http://www.mat.uc.pt/~gil/downloads/Lab_classifDRA.zip

deste, pelo facto das superfícies impermeáveis absorverem mais calor. Em quinto lugar, a expansão urbana provoca, em determinadas áreas, o fecho dos leitos de marisco e reduz também a biodiversidade do pantanal. Por último, vários autores indicam que o efeito da ilha de calor urbana está positivamente relacionada com a cobertura da superfície impermeável.

Na literatura, as várias técnicas desenvolvidas para a extracção de superfícies impermeáveis urbanas utilizam imagens de média resolução espacial e têm especial atenção ao problema dos pixels mistos. Ora a utilização deste tipo de imagens é útil para a cartografia temática de grandes áreas, especialmente a uma escala regional. No entanto para estudos locais, é preferível utilizar imagens de satélite de alta resolução espacial (HRSI), dado que estas contêm informação espacial mais detalhada. Com o aumento da resolução espacial, aumenta a proporção de pixels mais puros e diminui a probabilidade de pixels mistos. Consequentemente, os classificadores ao nível do sub-pixel que foram desenvolvidos para as imagens de média resolução podem não ser apropriados. Além disso, os métodos de classificação tradicionais são baseados na sua maioria na cor e tonalidade dos pixels, deixando de parte informação muito importante implícita na imagens HRSI tal como: textura, forma e contexto. Assim, vários autores são da opinião que os classificadores ao nível do pixel não são apropriados para extrair objectos das imagens HRSI.

No entanto, as sombras provocadas pelos edifícios e pelas árvores e o deslocamento da imagem provocado pela altura dos objectos cria grandes problemas à extracção das superfícies impermeáveis. Um outro aspecto que merece particular atenção é grande variação espectral para a mesma classe de coberto, em imagens HRSI.

Procedimento de classificação

O processo de classificação tem por finalidade atribuir aos pixels de uma imagem um número finito de classes. Se um determinado pixel satisfaz um dado conjunto de critérios então é-lhe atribuído uma dada classe a qual corresponde a esse conjunto de critérios. A classificação supervisionada da imagem é feita geralmente em três etapas: i) o operador define o número e natureza das classes e adquire para cada classe zonas de treino suficientes e representativas; ii) com base nestas zonas estima os necessários parâmetros estatísticos (assinaturas espectrais) iii) utiliza regras de decisão apropriadas para realizar a classificação da imagem.

O processo de classificação pode incluir uma variedade de informação tal como: a informação espectral, a textura, o contexto e a altura normalizada dos objectos. O objectivo da classificação é fornecer um mapa temático de ocupação do solo preciso e detalhado que permita a análise das estruturas urbanas na modelação de cheias urbanas. Assim, a definição de classes de ocupação do solo (land cover classes) deve ser baseada nas classes de ocupação principais: solo nu (bare soil), água, vegetação, vegetação não fotossintética e áreas edificadas. As áreas edificadas são representadas por várias classes individuais: para uma análise da estrutura urbana espacial é importante separar os edifícios de outras classes, tais como vias, parques de estacionamento e piscinas. Devido à variabilidade espectral das coberturas dos edifícios, serão atribuídas na classificação diferentes tipos de coberturas. As coberturas comerciais claras, representam coberturas metálicas e asfaltadas e encontram-se principalmente em áreas comerciais e industriais. As coberturas residenciais claras incluem as telhas de compósito de madeira (light composite shingle) as coberturas de telha e as coberturas planas de gravilha. As coberturas residenciais escuras representam ripas escuras de compósitos de madeira, coberturas de madeira e de mosaico. As coberturas com telha vermelha formam uma classe individual devido ao seu espectro específico.

As características espectrais das classes estão representadas na figura 1. As outras classes, especialmente as áreas edificadas (ou povoadas) têm formas espectrais semelhantes e o seu contraste espectral é devido principalmente a diferenças de brilho. Isto mostra as limitações dos dados Ikonos na separação dessas classes importantes tendo em conta apenas a informação espectral. Assim, o processo de classificação deverá ter em conta informação espacial e contextual adicional a fim de se avaliar a sua contribuição.

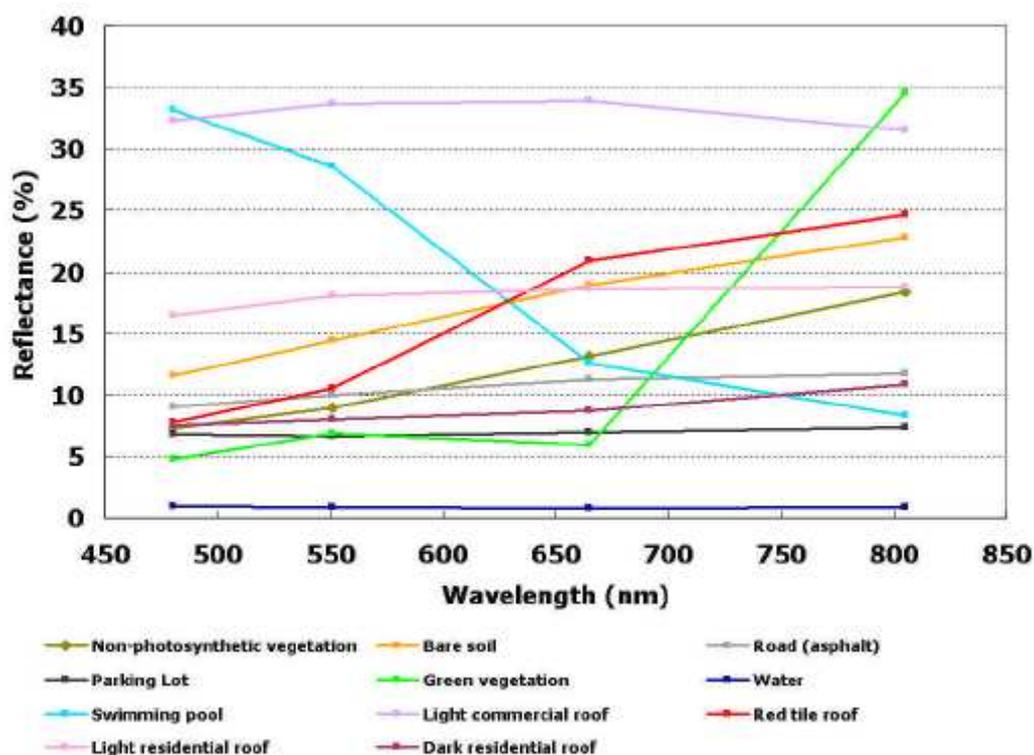


Figura 1: Exemplos da reflectância média espectral para 11 diferentes tipos de cobertura do solo utilizados na classificação (adaptado de Herold and Günther)

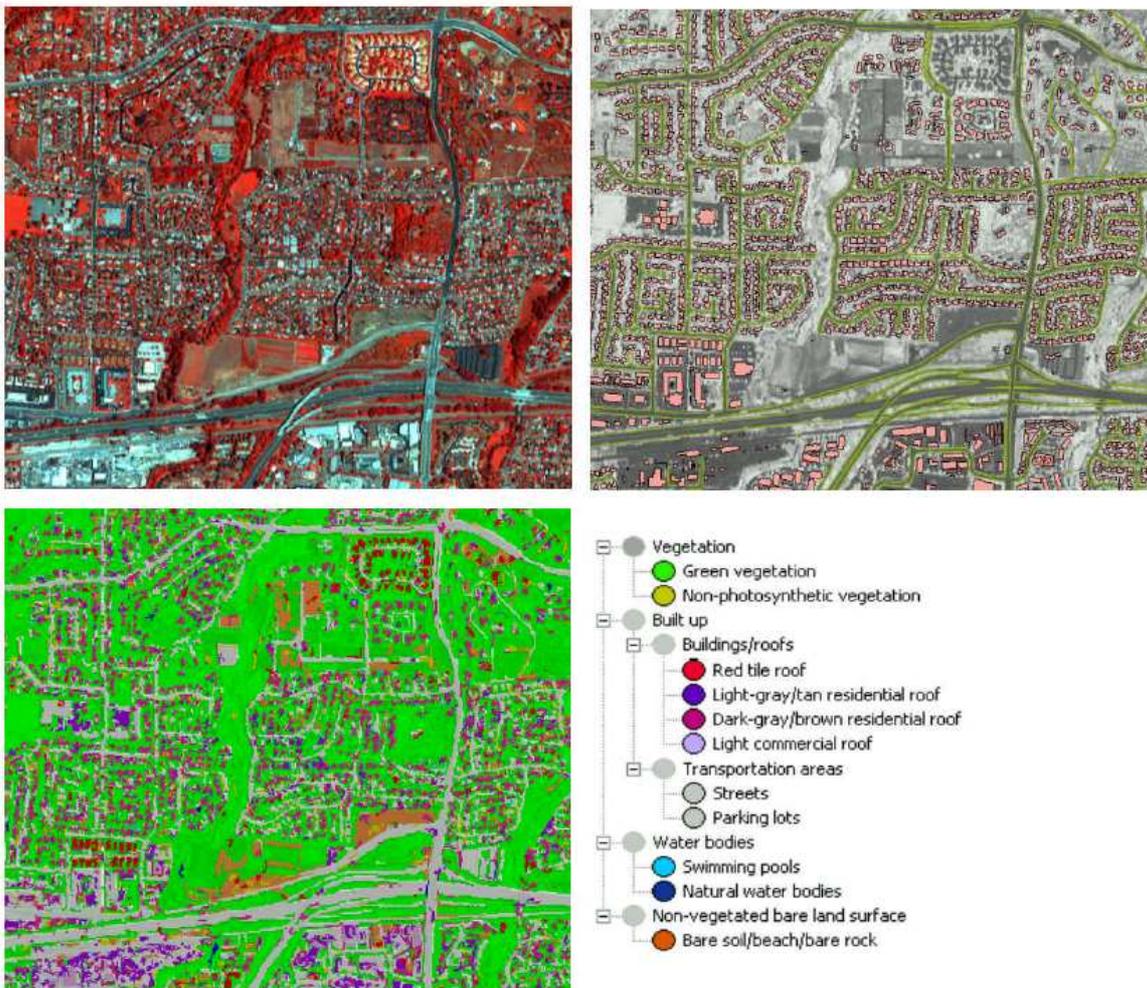
O esquema de classificação que iremos utilizar é dividido em três diferentes níveis (Herod et al. 2003). O primeiro e segundo nível representam as categorias funcionais e as classes de ocupação do solo relevantes para a caracterização da superfície urbana. O terceiro nível é dividido tematicamente pelas propriedades da superfície e pode ser extensível de forma a incluir diferentes tipos funcionais de coberturas.

Tabela 1: Esquema hierárquico de classificação

Nível 1	Nível 2	Nível 3
Edificado	Edifícios/coberturas	Coberturas de compósitos de madeira
		Coberturas de telha/mosaico
		Coberturas de metal
		Coberturas betuminosas
	Áreas de transporte	Vias asfaltadas
		Vias de betão
		Vias de gravilha
Parques de estacionamento		
Infra-estruturas desportivas	Campos de ténis de tartã	
Vegetação	Vegetação vigorosa	
	Vegetação não-vigorosa	
Corpos de água	Piscinas	
	Corpos de água naturais	
Terreno natural sem vegetação	Solo nu/ praias/ rochas	
	Solo agrícola	
Outra		

Embora possamos adaptar este esquema de classificação ao nosso problema particular, existem outras alternativas publicadas na literatura. Um primeiro exemplo é o trabalho de Lu and Weng (2009), onde são comparados diferentes métodos para a extracção de superfícies impermeáveis num contexto urbano. Um segundo exemplo de outra nomenclatura de classes é a que poderemos encontrar em (Sabo, 2006).

A qualidade das zonas de treino deverá ser feita por análise duma das medidas de separabilidade das assinaturas espectrais que o software dispõe (distância de Bhattacharrya e divergência transformada). Ambas medidas dão valores compreendidos no intervalo $[0,2]$ com o seguinte significado: i) >1.9 excelente; ii) $[1.7,1.9]$ boa; iii) <1.7 fraca separabilidade. O valor 0 indica uma sobreposição completa das classes e o valor 2 uma separação completa.



Depois de realizada a classificação é necessário efectuar a análise da exactidão da classificação. Neste trabalho essa análise deverá ser feita utilizando a matriz de erro a qual será calculada utilizando um conjunto de pontos de verificação classificados manualmente através da interpretação visual da ortoimagem.

Classificação da máxima verosimilhança

No contexto da classificação (ou do reconhecimento) de padrões em imagens digitais um padrão é um vector de características que descreve um dado objecto. Este padrão é constituído por medições de um conjunto de características chamado espaço das características. O método da máxima verosimilhança é um classificador paramétrico na medida em que este associa à assinatura espectral uma distribuição estatística conhecida, ou seja a lei normal ou multinormal. Esta associação fornece a possibilidade de afectar a cada pixel uma probabilidade de pertença a uma dada classe. Note-se que a densidade de probabilidade multinormal para variáveis discretas escreve-se na forma matricial

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{N/2} |\Sigma|^{1/2}} e^{-\frac{1}{2}[(\mathbf{x}-\mathbf{m})' \Sigma^{-1}(\mathbf{x}-\mathbf{m})]} \quad (0.1)$$

onde

- \mathbf{x} é um vector de dimensão N
- \mathbf{m} é o vector médio
- Σ a matriz de variancia-covariancia

Formulada uma lei propabilista, o pixel é atribuido à classe que oferece a probabilidade mais elevada através de uma regra de decisão do tipo

$$\mathbf{x} \in C_i \text{ se } p(C_i|\mathbf{x}) > p(C_j|\mathbf{x}), \quad \forall j \neq i \quad (0.2)$$

onde $p(C_i|\mathbf{x})$ é a probabilidade condicional (ou a posteriori) do pixel \mathbf{x} pertencer à classe C_i .

No entanto como $p(C_i|\mathbf{x})$ é desconhecida recorre-se ao teorema de Bayes para se definir a relação

$$p(C_i|\mathbf{x}) = \frac{p(\mathbf{x}|C_i)p(C_i)}{p(\mathbf{x})} \quad (0.3)$$

onde:

- $p(\mathbf{x})$ é a probabilidade anónimo \mathbf{x} , do qual se conhecem as suas propriedades espectrais, de pertencer à classe C_i
- $p(\mathbf{x}|C_i)$ é a probabilidade condicional da classe C_i para o pixel \mathbf{x}
- $p(C_i) = \frac{\# \text{ pixels_da_classe_i}}{\# \text{ pixels_da_imagem}}$ é a probabilidade a priori de ocorrência da classe C_i .

Como $p(\mathbf{x})$ não depende de nenhuma classe espectral a regra de decisão 1.2 pode ser reescrita tendo em conta 1.3 na forma

$$\mathbf{x} \in C_i \text{ se } p(\mathbf{x}|C_i)p(C_i) > p(\mathbf{x}|C_j)p(C_j), \quad \forall j \neq i$$

Admitindo agora que a probabilidade condicional $p(\mathbf{x}|C_i)$ segue uma distribuição normal, ou multinormal no caso de uma imagem multibanda, e recorrendo a 1.1 teremos

$$p(\mathbf{x}|C_i) = \frac{1}{(2\pi)^{N/2} |\Sigma|^{1/2}} e^{-\frac{1}{2}[(\mathbf{x}-\mathbf{m}_i)' \Sigma^{-1}(\mathbf{x}-\mathbf{m}_i)]} \quad (0.4)$$

Na prática, a equação anterior pode ser simplificada se a logaritimizarmos:

$$\ln[p(\mathbf{x}|C_i)] = -\frac{N}{2} \ln(2\pi) - \frac{1}{2} \ln(C_i) - \frac{1}{2} M \quad (0.5)$$

onde $M = (\mathbf{x}-\mathbf{m}_i)' \Sigma_i^{-1}(\mathbf{x}-\mathbf{m}_i)$ é a distancia de Mahalanobis. Mais ainda, como o termo $-\frac{N}{2} \ln(2\pi)$ é constante para todas as classes pode ser retirado da expressão anterior; por outro lado multiplicando a equação anterior pela constante -2 teremos:

$$\bar{p}(\mathbf{x}|C_i) = \ln(C_i) - M \quad (0.6)$$

É evidente que maximizar a expressão 1.4 é equivalente a minimizar a expressão 1.6. Assim, $\bar{p}(\mathbf{x}|C_i)$ é calculado para cada pixel e para cada classe. Depois de normalizarmos estes valores obtemos uma imagem classificada que corresponde a $\bar{p}(\mathbf{x}|C_i)$ mínimo.

Neste trabalho iremos averiguar a possibilidade da fusão de dados imagem com dados laser para a cartografia de zonas impermeáveis.

Integração de informação adicional relativa ao MDSn

Neste trabalho iremos também averiguar a possibilidade da fusão de dados imagem com dados laser para a cartografia de zonas impermeáveis. Na literatura são descritas várias metodologias possíveis que integram os dados multi-espectrais com os dados LiDAR (Kyle et al 2011, Hodgson et al 2003). No entanto, a opção mais simples consiste em executar o processo de classificação com o MDSn considerado como mais uma banda adicional (ou dimensão) do espaço espectral. No caso desta metodologia não melhorar substancialmente a exactidão da classificação das superfícies impermeáveis podemos então utilizar uma nova metodologia que consiste em integrar esta banda, antes ou depois do processo de classificação, para separarmos os diferentes tipos de vegetação, do edificado, etc.

Bibliografia

Herold, M and Scepan Joseph. 2002. Object-oriented mapping and analysis of urban land use/cover using Ikonos data.

Lu, D. and Weng, Q., 2009. Extraction of urban impervious surfaces from IKONOS imagery. *International Journal of Remote Sensing*, 30 (5), 1297-1311.

Lu, D., Hetrick, S., Moran, E., 2010. Impervious surface mapping with QuickBird imagery. *International Journal of Remote Sensing*. doi:10.1080/01431161003698393.

Kyle A. Hartfield, Katheryn I. Landau, Willem J. D. van Leeuwen, 2011. Fusion of High Resolution Aerial Multispectral and LiDAR Data: Land Cover in the Context of Urban Mosquito Habitat. *Remote Sensing*, Vol. 3, No. 11, pp. 2364-2383. Disponível em www.mdpi.com/2072-4292/3/11/2364/pdf

Hodgson, M.E., J.R. Jensen, J.A. Tullis, K.D. Riordan and C.M. Archer, 2003. Synergistic use of LIDAR and color aerial photography for mapping urban parcel imperviousness. *Photogrammetric Engineering and Remote Sensing*, 69(9); 973-980.

Sabo, Leticia, 2006. Análise da incerteza na representação de classes temáticas resultantes da aplicação de uma rede neural artificial. Tese de Mestrado. FCTUEP. Disponível em:

http://www.livrosgratis.com.br/arquivos_livros/cp036230.pdf