

## COMPARAÇÃO DE CLASSIFICAÇÕES DA COBERTURA URBANA USANDO REDES NEURAIS A PARTIR DE CENAS WORLDVIEW-2 E WORLDVIEW-3

Paulo Roberto da Silva Ruiz<sup>1</sup>, Cláudia Maria de Almeida<sup>2</sup>, Camila Souza dos Anjos Lacerda<sup>3</sup>

<sup>1</sup>Faculdade de Tecnologia - FATEC de Adamantina, Rua Paraná, 400 – 17800-000 – Adamantina – SP, paulo.ruiz2@fatec.sp.gov.br; <sup>2</sup>Instituto Nacional de Pesquisas Espaciais – INPE, Caixa Postal 515 – 12227-010 – São José dos Campos - SP, claudia.almeida@inpe.br; <sup>3</sup>Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais – IFSULDEMINAS, Praça Tiradentes, 416 – 37576-000 – Inconfidentes – MG, camila.lacerda@ifsuldeminas.edu.br

### RESUMO

Este estudo tem como objetivo comparar classificações de cobertura do solo urbano de sensores orbitais com diferentes resoluções espaciais e espectrais. Um deles é o WorldView-2 (WV-2), com 0,5 m de resolução espacial e 8 bandas multiespectrais, e o outro é o WorldView-3 (WV-3), que possui 16 bandas multiespectrais e resolução espacial de 0,31 m. As classificações foram realizadas em duas cenas, cobrindo um transecto dentro do campus da Universidade Estadual de Campinas, São Paulo. Para cada conjunto de dados, foram realizadas classificações aplicando o algoritmo *Multilayer Perceptron*, definindo-se 38 e 42 classes de cobertura do solo, respectivamente para o WV-2 e WV-3. As classificações obtiveram acurácias muito semelhantes, apresentando índice Kappa superiores a 0,77 e exatidão global acima de 75%, com os melhores índices pertencendo ao WV-3. Dessa forma, conclui-se que o melhor refinamento espacial e espectral do WV-3 contribuiu para a obtenção de melhores resultados.

**Palavras-chave** — mineração de dados, redes neurais, classificação da cobertura urbana.

### ABSTRACT

*This study aims to compare urban land cover classifications from orbital sensors with different spatial and spectral resolutions. One of them is WorldView-2 (WV-2), with 0.5 m of spatial resolution and 8 multispectral bands, and the other one is WorldView-3 (WV-3), which has 16 multispectral bands and 0.31 m of spatial resolution. The classifications were performed in two scenes, extending over a transect inside the campus of the State University of Campinas, São Paulo. For each data set, classifications were performed by applying the Multilayer Perceptron algorithm, comprising 38 and 42 land cover classes, respectively for WV-2 and WV-3. The classifications obtained very similar accuracies, with Kappa index above 0.77 and overall accuracy higher than 75%, with the best indices belonging to the WV-3. Thus, we conclude that the better spatial and spectral refinement of the WV-3 contributed to obtain the best results.*

**Key words** — data mining, neural networks, urban land cover classification.

### 1. INTRODUÇÃO

Atualmente, o Sensoriamento Remoto conhece um momento de expressivo aumento na aquisição de dados cada vez mais

detalhados da superfície terrestre. Diversos satélites equipados com sensores de alta resolução espacial e espectral imageiam a Terra, aumentando as possibilidades de estudos dos fenômenos naturais e humanos. Estudos que norteiam diversas intervenções do poder público no espaço urbano necessitam de produtos detalhados desse ambiente. Nesse sentido, o refinamento das resoluções dos sensores aliado a algoritmos de mineração de dados são altamente requisitados para contribuir com a administração do meio urbano [1].

A resolução espacial especifica o tamanho do pixel da imagem e ajuda a adquirir informações detalhadas e de qualidade sobre a superfície terrestre. Por outro lado, a resolução espectral descreve a capacidade de um sensor para definir intervalos de comprimento de onda, sendo que quanto mais fino, mais estreito é o comprimento de onda para um canal ou banda em particular [2]. Essas características são importantes para a tarefa de classificação de imagens, sobretudo em áreas urbanas. Os satélites WV-2 e WV-3 são precissamente indicados para essa aplicação, por possuírem resoluções espaciais abaixo de 0,5 m, além 8 e 16 bandas multiespectrais, respectivamente.

Ter à disposição fontes de dados aprimoradas em suas resoluções não significa que a tarefa de classificação do solo urbano está resolvida. São necessárias avaliações sobre a qualidade dos dados, a utilização de algoritmos de mineração de dados e recursos computacionais adequados para processar esse massivo volume de dados [3]. Nesse sentido, o presente trabalho objetiva comparar as potencialidades e limitações dos sensores WV-2 e WV-3 para a classificação de alvos urbanos utilizando redes neurais artificiais.

### 2. MATERIAL E MÉTODOS

A área de estudo corresponde a um transecto do campus da Universidade Estadual de Campinas (UNICAMP) em Campinas, São Paulo. Esta escolha foi feita em razão de a área possuir grande diversidade de alvos urbanos, acessibilidade aos edifícios e disponibilidade de dados (Figura 1).

A primeira imagem utilizada é oriunda do satélite WorldView-2, adquirida em 02 de julho de 2010. No modo pancromático, possui resolução espacial no nadir de 0,46 m e 1,84 m no multiespectral. Possui 8 bandas multiespectrais: azul costeiro (400-450 nm), azul (450-510 nm), verde (510-580 nm), amarelo (585-625 nm), vermelho (630-690 nm), vermelho limítrofe (705-745 nm), infravermelho próximo 1

(750-745 nm) e infravermelho próximo 2 (860-1040 nm) (DigitalGlobe, 2009). Já a segunda imagem é do satélite WorldView-3, adquirida em 24 de julho de 2015. Possui resolução espacial de até 0,31 m em sua banda pancromática, 1,24 m em suas bandas multiespectrais e 3,7 m em suas bandas de infravermelho de ondas curtas (SWIR). Além das bandas multiespectrais presentes em seu antecessor, possui 8 novas bandas na região do SWIR.

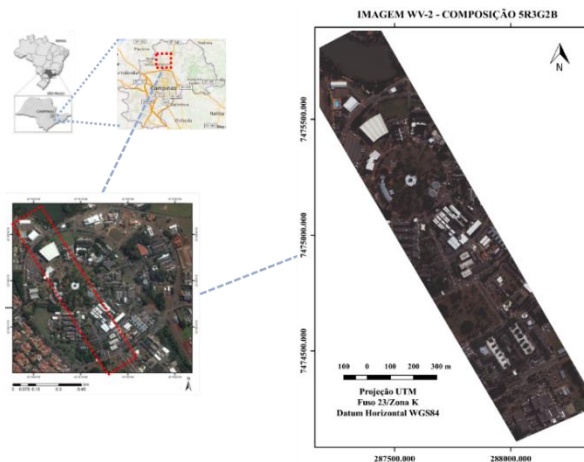


Figura 1. Área de estudo.

A metodologia começa com o pré-processamento das imagens, consistindo na correção atmosférica por meio do algoritmo FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*) implementado no ENVI 5.1. A seguir, foi realizada a ortorretificação valendo-se da ferramenta “Dispositivo de Ortoretificação” (*OrthoEngine*) do PCI Geomatics. Para que as duas imagens sejam perfeitamente coincidentes no seu posicionamento, foi realizado o registro de imagens, consistindo na realização de um ajuste do sistema de coordenadas de uma imagem (pixels/linhas) ao sistema equivalente da outra imagem [4].

Os atributos extraídos das imagens para realizar a classificação, foram: Análise por Componentes Principais (*Principal Component Analysis* - PCA); Fração de Ruído Mínima (*Minimum Noise Fraction* - MNF); Brilho (*Brightness*); Modelo Digital de Altura (MDA); quatro Índices de Vegetação por Diferença Normalizada (NDVI), alternando-se as bandas do vermelho e vermelho limítrofe, bem como as bandas do infravermelho próximo 1 e 2; Índice de Vegetação Ajustado ao Solo (SAVI); além de 19 atributos customizados (ACs), obtidos por meio de aritmética de bandas [5].

A segmentação das imagens foi realizada no *software* eCognition, por meio do algoritmo multirresolução. Após a segmentação, foi utilizado o algoritmo de ajuste por diferença espectral (*Spectral Difference*), para refinar os resultados da segmentação através da similaridade espectral entre os segmentos vizinhos [4].

As classes de cobertura do solo urbano foram definidas a partir dos trabalhos de Anjos [5] para os dados WV-2 e Ruiz

[4] para os dados WV-3. Devido à diferença temporal de cinco anos, o número de classes é diferente para cada imagem, sendo adotadas 38 classes para os dados WV-2 e 42 classes para os dados WV-3. A descrição das classes está presente na legenda dos mapas das Figuras 2 e 3. A sigla CRFS, que significa Cimento Reforçado com Fios Sintéticos, corresponde a um tipo de telha de fibrocimento visivelmente semelhante às telhas de fibrocimento com amianto, sem possuí-lo em sua composição. Os diferentes tipos de galvalume representam coberturas metálicas compostas ou recobertas por camadas de alumínio, zinco e silício. Nos dados WV-2, foram divididos em três tipos: A – ondulado com pintura eletrostática branca, B – trapezoidal sem pintura, C – ondulado sem pintura [5]. Por sua vez, no caso dos dados WV-3, foram divididos em dois tipos: A – com pintura eletrostática branca, B – sem pintura [4].

O processo de mineração de dados foi realizado por meio do *software* WEKA (*Waikato Environment for Knowledge Analysis*), 3.7.12. A rede neural utilizada neste trabalho foi a *Perceptron* multicamadas. As redes neurais artificiais (RNAs) são compostas por unidades de processamento (neurônios) que permitem armazenar o conhecimento e o tornar disponível para o uso. Os neurônios artificiais constituem uma estrutura lógica matemática altamente complexa por buscar simular a forma, comportamento e funções do neurônio biológico. Estas redes possuem múltiplas camadas de processamento. O aumento das camadas neurais favorece a capacidade de processamento não linear e a generalização da rede neural. O algoritmo *backpropagation* é utilizado para a realização do treinamento supervisionado, em que é utilizado um conjunto de treinamento com pares de entrada e saída conhecidos. Até a saída, o vetor de entrada é propagado camada a camada para ser comparado ao vetor de saída conhecido e, assim, é possível calcular o erro de saída, subtraindo-se a saída calculada da desejada (conhecida) [6].

A validação dos resultados das classificações dos dados foi realizada por meio de mapas de verdade de campo elaborados por Anjos [5], referente aos dados WV-2 e Ruiz [4], referente aos dados WV-3. Para realizar a validação estatística, foram gerados conjuntos de coordenadas aleatórias dentro dos limites da imagem para cada classificação utilizando-se o *software* Minitab 17. Cada conjunto de coordenadas foi importado para o *software* QGIS 2.14.2 para realizar o cruzamento espacial entre o mapa de verdade de campo e a classificação, a fim de associar cada ponto aleatório à classe de referência e àquela atribuída pela classificação. Assim, foi possível a geração das matrizes de confusão para o cálculo da exatidão global, índice Kappa, índice Kappa condicional, acurácias do produtor e usuário para cada classe [7].

### 3. RESULTADOS E DISCUSSÕES

O mapa da classificação final para os dados WV-2 é apresentado na Figura 2. Essa classificação apresentou índice Kappa de 0,7286 e exatidão global de 75,13%. Já a Figura 3

apresenta o mapa de classificação dos dados WV-3, juntamente com o mapa de verdade de campo. A classificação apresentou índice Kappa de 0,7577 e exatidão global de

77,91%. A Tabela 1 apresenta os valores do índice Kappa condicional por classe.

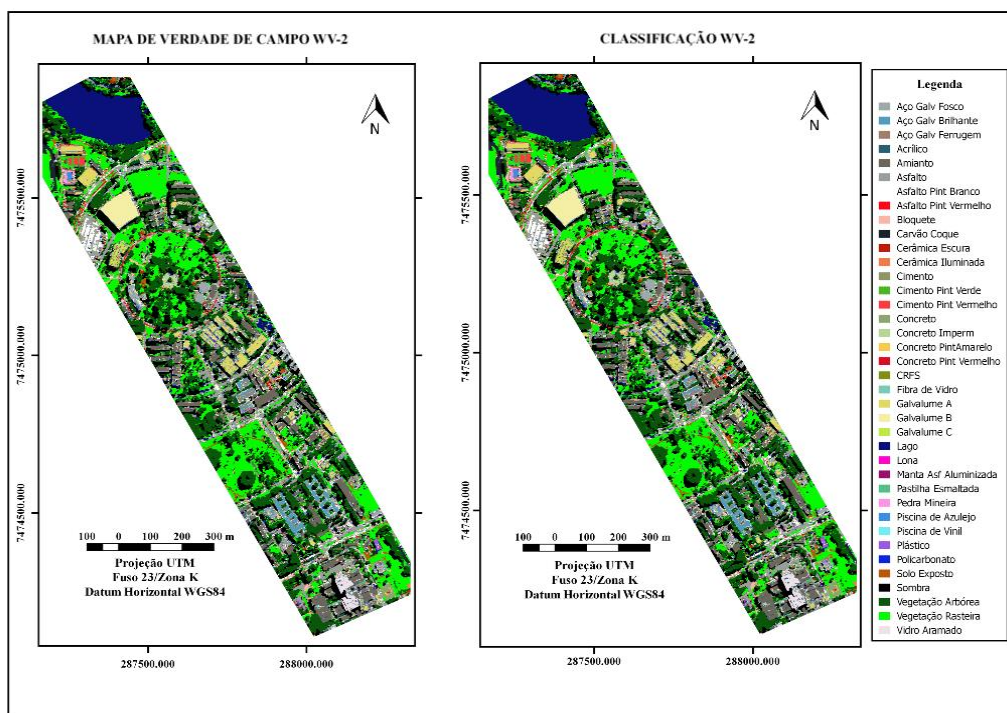


Figura 2. Mapa de verdade de campo e classificação dos dados WV-2.

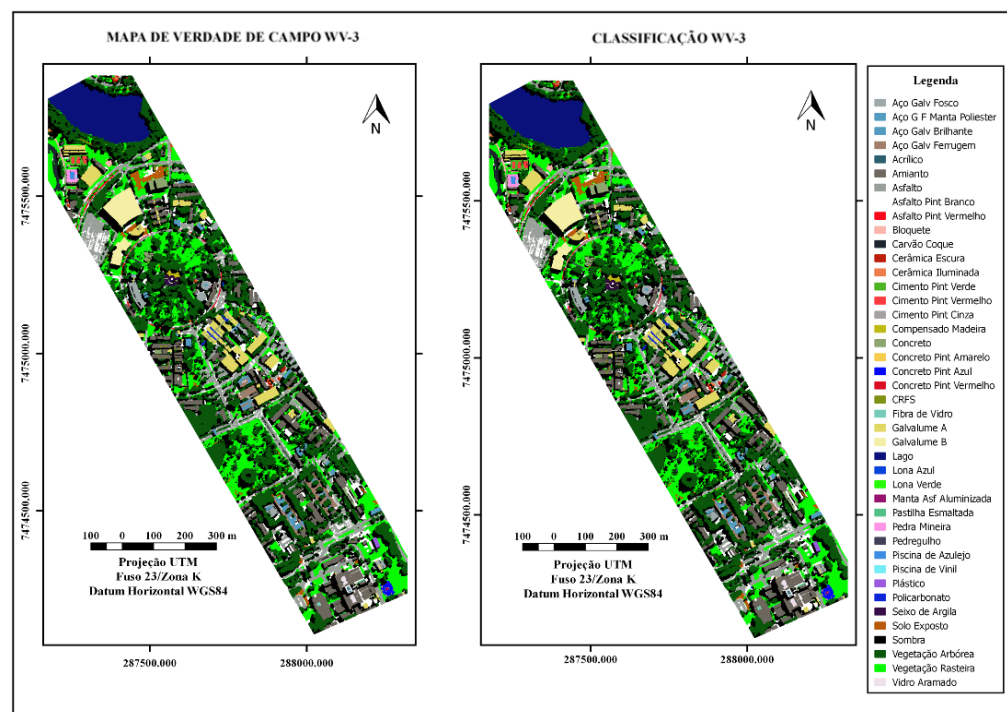


Figura 3. Mapa de verdade de campo e classificação dos dados WV-3.

Pelos resultados alcançados, observa-se que as classes que são constituídas por materiais visualmente semelhantes proporcionaram maiores confusões nas classificações. Isso é observado em ambas classificações, devido ao grande número de classes. Isso é o caso dos diferentes tipos de telhados de aço galvanizado, galvalume e amianto, bem no caso das confusões entre concreto e asfalto. Destacam-se também confusões entre classes espectralmente semelhantes, a exemplo das coberturas cerâmicas e solo exposto e entre policarbonato intemperizado e asfalto.

Classes	WV-2		WV-3	
	K <sub>u</sub>	K <sub>p</sub>	K <sub>u</sub>	K <sub>p</sub>
Aço Galvan. Brilhante	0,4954	0,6778	0,4951	0,5368
Aço Galvan. Ferrugem	0,4981	0,3317	0,5471	0,6850
Aço Galvan. Fosco	0,5963	0,5200	0,6997	0,7710
Aço Galv. Fosco Manta	--	--	0,7990	0,6138
Acrílico	0,6210	0,1973	1,0000	0,3328
Amianto	0,6620	0,7828	0,8325	0,8523
Asfalto	0,7920	0,6796	0,7556	0,7794
Asfalto Pint. Branco	0,6124	0,3298	0,5218	0,3890
Asfalto Pint. Vermelho	0,5571	0,9296	0,8448	0,5213
Bloquete	0,2597	0,2033	0,8079	0,8079
Carvão Coque	0,9281	0,8378	0,8642	0,9197
Cerâmica Escura	0,5956	0,3131	0,9318	0,7320
Cerâmica Iluminada	0,4135	0,3815	0,7770	0,7770
Arg. de Cimento	1,0000	0,1754	--	--
Arg. Cimento P. Cinza	--	--	0,7495	0,5994
Arg. Cimento Pint. Verde	0,8559	0,8559	0,8954	0,9625
Arg. Cimento P. Vermelho	1,0000	0,8789	1,0000	0,9252
Compensado Madeira	--	--	0,9540	0,7217
Concreto	0,7261	0,7052	0,6060	0,4115
Concreto Impermeabilizad	0,8339	0,9020	--	--
Concreto Pint. Azul	--	--	0,8999	0,9130
Concreto Pint. Amarelo	0,8444	0,4042	0,8169	0,4978
Concreto P. Vermelho	1,0000	0,4985	0,8329	0,8329
CRFS	0,4981	0,6650	0,6651	0,3317
Fibra de Vidro	0,5698	0,7896	1,0000	0,6678
Galvalume A	0,8542	0,8542	0,6743	0,9277
Galvalume B	0,9469	0,9469	0,9579	0,9579
Galvalume C	0,2494	1,0000	--	--
Lago	1,0000	0,8406	1,0000	0,8317
Lona	0,1987	0,4979	--	--
Lona Azul	--	--	1,0000	1,0000
Lona Verde	--	--	1,0000	0,4421
Manta Asfáltica Alum.	0,7261	0,7991	0,7129	0,8324
Pastilha Esmaltada	0,7980	0,1649	1,0000	0,0826
Pedra Mineira	0,6864	0,7955	0,9576	0,9313
Pedregulho	--	--	1,0000	0,0982
Piscina de Azulejo	0,9511	0,9358	1,0000	0,9622
Piscina de Vinil	0,7997	1,0000	1,0000	0,4996
Plástico	0,8483	0,6265	0,8323	0,9370
Policarbonato	-0,0076	-0,0101	0,7418	0,1096
Seixo de Argila	--	--	0,9718	0,9452
Solo Exposto	0,3532	0,3532	0,8109	0,6166
Sombra	0,6206	0,8445	0,5276	0,8227
Vegetação Arbórea	0,8276	0,7961	0,7847	0,7673
Vegetação Rasteira	0,6846	0,8508	0,6733	0,9092
Vidro Aramado	0,9741	0,5736	1,0000	0,8469

**Tabela 1. Índice Kappa condicional do usuário (K<sub>u</sub>) e produtor (K<sub>p</sub>) referente às classificações dos dados WV-2 e WV-3.**

Os resultados demonstraram que as classificações com os dados WV-3 alcançaram índices de exatidão global e Kappa maiores que aqueles obtidos com os dados WV-2. Esta constatação ganha respaldo pelo seu maior refinamento espacial, além do espectral. O ganho em resolução espacial permite distinguir alvos pequenos presentes na cena urbana. Por exemplo, aço galvanizado fosco recoberto com manta impermeabilizada, manta asfáltica aluminizada, diferentes cores de lonas, fibra de vidro e pastilha esmaltada. Já o

refinamento espectral permite a melhor separabilidade entre classes espectralmente semelhantes. Por exemplo, as coberturas cerâmicas e solo exposto apresentaram melhores índices Kappas condicionais na classificação dos dados WV-3. Este mesmo comportamento foi observado pela classe policarbonato.

#### 4. CONCLUSÕES

Neste trabalho, foram comparadas classificações da cobertura do solo urbano usando redes neurais artificiais em dados provenientes de dois sensores de alta resolução espacial. Para a cena WV-2, foram definidas 38 classes de cobertura do solo, enquanto para a cena WV-3 foram adotadas 42 classes. As classificações obtiveram índices de exatidão global acima de 75%. A classificação utilizando dados WV-3 obteve melhores do que a derivada do WV-2.

Este trabalho evidencia a necessidade de agregar altas resoluções espaciais e espectrais para a identificação das classes de cobertura do solo urbano em nível de legenda extremamente detalhado. Não obstante, adequados algoritmos de mineração de dados, caso das redes neurais artificiais, são essenciais para obter êxito na tarefa de classificar imagens provenientes de dados orbitais, sobretudo de áreas urbanas, por essas possuírem pequenos e diversos alvos a serem discriminados.

#### 5. REFERÊNCIAS

- [1] Jensen, J.R. *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. São José dos Campos: Parêntese, 2011. Tradução: José Carlos Neves Epiphânio (coordenador).
- [2] Chakraborty, D., Singh, S. and Dutta, D. Segmentation and classification of high spatial resolution images based on Hölder exponents and variance. *Geospatial Information Science*, 20:1, p. 39-45, 2017.
- [3] Witten, I.H. and Frank, E. *Data mining: Practical machine learning tools and techniques with JAVA implementations*. San Francisco: Morgan Kaufmann. 371p., 2000.
- [4] Ruiz, P.R.S. *Classificação da cobertura do solo urbano usando árvores de decisão a partir de cenas WorldView-2 e WorldView-3 para diferentes níveis de legenda*. São José dos Campos – SP. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais.
- [5] Anjos, C.S. *Classificação de áreas urbanas com imagens multiespectrais e hiperespectrais utilizando métodos não-paramétricos*. São José dos Campos - SP. Tese (Doutorado em Sensoriamento Remoto) - Instit. Nacional de Pesquisas Espaciais.
- [6] Haykin, S. *Redes Neurais: Princípios e Prática*. 2. ed. Porto Alegre: Bookman, 2001.
- [7] Congalton, R.G., Green, K. *Assessing the accuracy of remotely sensed data: principles and practices*. 2 ed. Boca Raton: CRC Press, 2009.