

## Comparação entre classificações de imagem RapidEye para o cálculo CN de bacia hidrográfica urbana: estudo de caso do Arroio Pepino (Pelotas/RS)

Gustavo Willy Nagel<sup>1</sup>  
Fabrício da Silva Terra<sup>1</sup>  
Jade Silva de Oliveira<sup>1</sup>  
Márcio Pagano Aragona<sup>1</sup>

<sup>1</sup>Universidade Federal de Pelotas - UFPel/CDTec/Engenharia Hídrica  
Caixa Postal 354 - 96010-000 - Pelotas - RS, Brasil  
{gustavoonagel, marcio.aragona}@gmail.com  
jade\_s\_oliver@hotmail.com  
fabricio.terra@ufpel.edu.br

**Abstract.** The runoff curve-number (CN) is an empirical parameter used for predicting direct runoff from rainfall excess, and it depends on land use and cover changes. High spatial resolution images have been important to identify these changes. This research aimed to compare effects of different land use and cover maps produced from K-means, MaxVer, and SAM classifications of high spatial resolution orbital image on calculation of CN value in the urban watershed of Arroio Pepino (Pelotas/RS). Our hypothesis was that different classification algorithms have produced divergent maps that in turn have affect the CN value of an urban watershed. A RapidEye image was classified in order to map the surface, and the following 10 classes were identified: water, asphalt, dirt road, vegetation (three types), roofs (three types), and building shade. The CN value of each class was obtained by comparing to corresponding tabulated values, and the total CN value was calculated taking into account the proportional area of each class. The MaxVer was the best-performed classifier (global accuracy: 64.89 % and kappa index: 0.59). The three CN values based on the distinct maps had different intensities where values calculated from K-means (CN<sub>total</sub>: 88.91 %) and SAM (CN<sub>total</sub>: 88.88 %) classifications were similar to each other and different of the value from MaxVer (90.71 %). Differences on proportions of land use and cover classes obtained from different classifiers affect the CN value of this urban watershed where its quality is highly dependent on accuracy of the classified image.

**Palavras-chave:** maximum gaussian likelihood, spectral angle mapper, k-means, urban hidrology, runoff, flood, máxima verossimilhança gaussiana, mapeador de ângulo espectral, k-médias, hidrologia urbana, escoamento, alagamento/inundação.

### 1. Introdução

A urbanização traz consigo mudanças significativas nas propriedades físicas da superfície territorial, principalmente no que se refere à redução da relação infiltração/deflúvio da água, onde resultados obtidos a partir de estudos hidrológicos urbanos baseados em coleta de dados a campo e modelagens matemáticas tem se constituído como uma necessidade fundamental para o manejo significativa da água quanto à ocorrência de alagamentos, inundações, abastecimento de reservatórios, qualidade da água, etc. (Fletcher et al., 2013). Na hidrologia urbana torna-se importante a aplicação de imagens orbitais de alta resolução espacial para que seja possível identificar, classificar e mapear com qualidade e acurácia os diferentes usos e ocupações da superfície (Myeong et al., 2001). Inclusive, é possível o emprego destas imagens no cálculo do método curva-número (CN) em bacias hidrográficas urbanas (BHU), uma vez que diferentes coberturas tornam a superfície mais ou menos impermeável. O método curva-número (Método CN) visa o cálculo do deflúvio total gerado em uma bacia hidrográfica a partir da chuva efetiva (USDA, 1986). Este método é útil para o dimensionamento de terraços de infiltração e bacias de contenção, assim como para estimativas de vazão de projeto com base na Hidrógrafa Sintética Triangular (HUT). Os valores de CN correspondem à porcentagem (de 1 % a 100 %) de água escoada (deflúvio) e estão associados ao uso e cobertura da bacia e, também, são dependentes da classe de solo subjacente (Mello e Silva, 2013).

Através do sensoriamento remoto orbital é possível obter imagens periódicas para monitoramento de alvos naturais (renováveis ou não) ou urbanos, além de auxiliar no mapeamento de uso e cobertura da superfície, uma vez que o comportamento espectral dos objetos é diferente devido à intensidade de energia refletida e às feições de absorção de cada um destes (Jensen, 2009). Para otimizar o mapeamento do uso e ocupação da superfície é indispensável a classificação, supervisionada ou não, baseada na energia refletida dos alvos que compõem as imagens orbitais a serem utilizadas, mesmo para as de alta resolução espacial para alvos urbanos, pois possibilita assim a identificação e agrupamento de objetos comuns presentes dentro do perímetro urbano. Segundo Meneses e Almeida (2012) a classificação de imagens multiespectrais é o processo de associar pixels de uma imagem em um número adequado de classes que representem alvos do mundo real. Dentre os diversos algoritmos de classificação baseados no reconhecimento de padrões espectrais de imagens, destacam-se: o Mapeador de Ângulo Espectral (*Spectral Angle Mapper* - SAM) (Kruse et al., 1993), o Método de Máxima Verossimilhança Gaussiana (MaxVer) e o Método K-médias (Richards e Jia, 2006).

A BHU do Arroio Pepino, localizada no município de Pelotas/RS, vem sofrendo intenso processo de urbanização ocasionando maior escoamento superficial em períodos chuvosos e, conseqüentemente, inundações na respectiva região (Cardoso, 2012). Baseado na hipótese de que diferentes algoritmos de classificação de imagens produzem mapas temáticos de uso e cobertura da superfície divergentes que, por sua vez, afetam o valor CN desta BHU, o objetivo deste trabalho foi comparar o efeito dos diferentes mapas produzidos através de classificações não-supervisionada (K-médias) e supervisionadas (SAM e MaxVer) em imagem orbital de alta resolução espacial no cálculo da curva-número da BHU do Arroio Pepino.

## 2. Metodologia de Trabalho

A área de estudo correspondeu à BHU do Arroio Pepino que possui uma área de 19,89 Km<sup>2</sup> e está situada no perímetro urbano da cidade de Pelotas (RS) (Figura 1). As classes de solo predominantes na região são: Planossolos e Gleissolos (Streck et al., 2008). Estas classes são características de áreas de várzea e com pouca diferença de cota topográfica. A delimitação da bacia foi obtida através da digitalização, georreferenciamento e vetorização do mapa disponível em Cardoso (2012). Como informação orbital, utilizou-se uma imagem RapidEye adquirida em 09/11/2014, ortoretificada com resolução espacial de 5m, resolução radiométrica de 12 bits e resolução espectral como segue: banda 1 (azul: 440-510 nm), banda 2 (verde: 520-590 nm), banda 3 (vermelho: 630-685 nm), banda 4 (vermelho limítrofe: 690-730 nm) e banda 5 (infravermelho próximo: 760-850 nm). Esta imagem foi adquirida junto ao Geo Catálogo do Ministério do Meio Ambiente (MMA) através do Programa de Regularização Ambiental (instituído pelo Decreto Presidencial 7.830).

Para as classificações supervisionadas e não-supervisionada foi utilizado o software ENVI 4.5. Na classificação não-supervisionada, onde não há conhecimentos prévios sobre as classes existentes na imagem, foi utilizado o algoritmo K-médias tem por objetivo diminuir a variabilidade interna das classes geradas a partir da soma da distância ao quadrado (erros) entre cada pixel e o centro da classe ao qual foi alocado (Richards e Jia, 2006). Para o funcionamento do algoritmo, que tem a premissa da mínima interferência, apenas informa-se a quantidade de classes que se deseja criar, a quantidade de interações e o limiar da classificação, ou seja, a porcentagem máxima de pixels que não mudarão entre interações (Meneses e Almeida, 2012). Neste trabalho, foram geradas 10 classes, a partir de 10 interações, com um limiar de 5%.

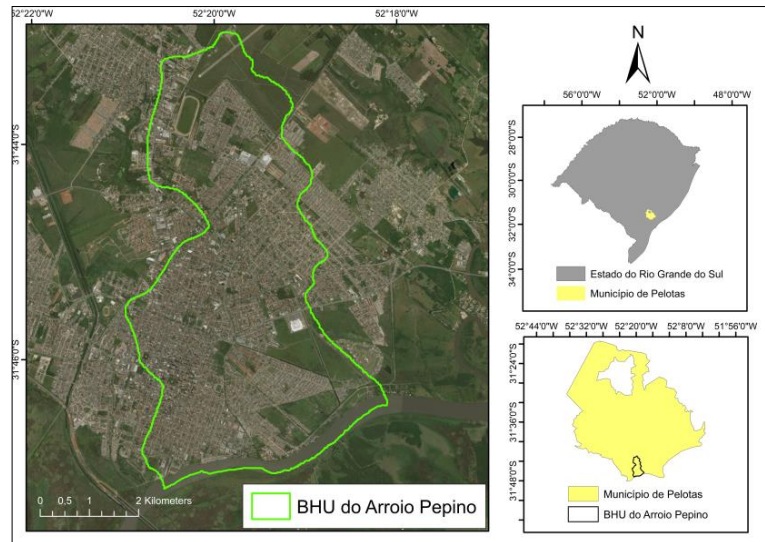


Figura 1. Localização da BHU do Arroio Pepino.

Para a classificação supervisionada, cujo objetivo é classificar pixels de identidade desconhecida a partir de pixels amostrais de identidade conhecida e cujo algoritmo precisa ser previamente treinado pelo analista utilizando pixels amostrais representativos das classes que se deseja criar, os métodos MaxVer e SAM foram utilizados. Através da interpretação visual da imagem, foram estabelecidas 10 classes: água, asfalto, estrada de terra, vegetações (arbustiva, baixa e moderada), coberturas (telhado de barro, de zinco e de alta reflectância) e sombra predial. Os pixels amostrais (*region of interest* –ROI's) foram os mesmos para os dois algoritmos utilizados, a fim de possibilitar a comparação dos resultados.

O algoritmo MaxVer avalia a variância e covariância das categorias dos padrões de resposta espectral para a classificação de pixels desconhecidos, onde assume-se que a distribuição dos pixels nas classes é gaussiana (distribuição normal) e, a partir dessa suposição, calcula-se a probabilidade de um dado pixel pertencer a uma classe específica (Richads e Jia, 2006). O pixel será classificado de acordo com a classe que apresentar maior probabilidade. O limiar (*threshold*) nesse algoritmo é a mínima probabilidade aceitável para que o pixel seja classificado em uma determinada classe (Meneses e Almeida, 2012). Neste trabalho, foi utilizado um limiar de 0% para que todos os pixels fossem classificados.

O algoritmo SAM determina a similaridade entre o espectro dos pixels da imagem com os pixels amostrados de referência a partir do cálculo do ângulo formado entre os espectros (Kruse et al., 1993). Isso é possível, pois o algoritmo trata os espectros como se fossem vetores em um ambiente onde o número de dimensões é o mesmo do número de bandas da imagem e pequenos ângulos formados significam grande correlação entre os pixels, enquanto grandes ângulos significam pouca correlação. O limiar (*threshold*) nesse algoritmo é o máximo ângulo permitido, o que significa que pixels que tiverem um ângulo maior do que o limiar não serão classificados. Neste trabalho, foi utilizado um limiar de 1 radiano para que todos os pixels fossem classificados.

Para avaliar o desempenho dos classificadores, utilizaram-se a Exatidão Global (EG) (Equação 1) e o Índice Kappa (K) (Equação 2) calculados a partir da matriz confusão. Uma vez que a imagem RapidEye utilizada datava de 2014, para geração da matriz, as verdades terrestres foram obtidas através da interpretação visual da imagem do *Google Earth (Digital Globe Quickbird)*, da mesma época (08/11/2014), e da delimitação manual (adição de polígonos) destas áreas. Os polígonos correspondentes a estas verdades terrestres (diferentes áreas das 10 classes definidas) foram então exportados individualmente no formato *Keyhole Markup Language* - Kml (\*.kml) para que posteriormente fossem convertidos para o formato

vetorial *Shapefile* - Shp (\*.shp) e agrupados conforme as classes as quais pertenciam. Por fim, o arquivo Shp foi sobreposto à imagem RapidEye no software ENVI 4.5 para que os pixels correspondentes às classes pudessem ser identificados como as verdades terrestres (ROI's).

$$EG = (A/N) * 100 \quad (1)$$

$$K = [N * \sum_{i=1}^r X_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})] / [N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})] \quad (2)$$

Onde: “A” é o total de pixels classificados corretamente, “N” é o total de pixels correspondentes às verdades terrestres, “r” é o número de linhas da matriz, “ $x_{ii}$ ” é o número de pixels na linha “i” e coluna “i” e “ $x_{i+}$ ” e “ $x_{+i}$ ” são respectivamente os totais marginais da linha “i” e coluna “i”.

As imagens classificadas foram transportadas para o programa ArcGis 10.1 para que se pudesse realizar os demais processamentos. Através da ferramenta *extract by mask*, extraíram-se os pixels correspondentes à área delimitada da BHU, vetorizada previamente. Após, através ferramenta *raster to polygon*, os conjuntos de pixels pertencentes às mesmas classes e próximos entre si foram agrupados e transformados em polígonos. A partir da ferramenta *merge*, os polígonos pertencentes à mesma classe, porém separados espacialmente, foram fundidos. Ocorrências de nuvens foram, posteriormente, removidas a partir da ferramenta *erase*, pois o efeito de suas sombras causa confusão nas classificações. Realizadas estas etapas, calcularam-se as áreas referentes às classes e suas porcentagens em relação à área total da bacia.

O cálculo do método CN foi obtido de forma ponderada considerando as porcentagens de área de cada classe a fim de se obter um único valor representativo para toda a bacia, conforme a Equação 3. Segundo Sartori et al. (2005a, 2005b), pelo motivo da BHU estar, predominantemente, sobre solos pouquíssimo resistentes e tolerantes à erosão, rasos, com muito baixa taxa de infiltração e com razão textural muito variável (Planossolos e Gleissolos), a bacia enquadrou-se no grupo hidrológico D proposto pelo método da curva-número. Algumas adaptações e considerações foram feitas para associar as classes de uso e cobertura obtidas com as categorias tabeladas do valor CN (Mello e Silva, 2013).

$$CN_{total} = \sum_{i=1}^n (CN_i * A_i) / \sum_{i=1}^n (A_i) \quad (3)$$

Onde: “CN” é o valor curva-número, “A” é a área de cada classe (i) e “n” é o número total de classes.

### 3. Resultados e Discussão

O desempenho dos algoritmos de classificação supervisionados e não-supervisionados foi avaliado através da matriz confusão e pode ser observado na Tabela 1, a qual mostra a comparação entre a proporção de pixels classificados corretamente para a mesma classe, assim como a Exatidão Global e o Índice Kappa gerados a partir dos três algoritmos. O algoritmo K-médias não foi capaz de discriminar as classes específicas cobertura 1 (telhado de barro) e sombra predial, estando estas misturadas dentre as demais. No geral, o algoritmo MaxVer obteve a melhor performance de classificação com os maiores valores de EG (64,89 %) e K (0,59) e com proporções de acerto superiores em 50 % dos alvos e, em algumas situações, muito próximas às dos demais algoritmos, como nos seguintes alvos: asfalto, cobertura 3, vegetação arbustiva, vegetação baixa e água. O algoritmo SAM apresentou a segunda melhor performance de classificação. Os resultados encontrados corroboram com Cattani et al. (2013) e Simões et al. (2015) que obtiveram as maiores precisões em suas classificações pelo algoritmo MaxVer, seguido do SAM e K-médias. Considerando o índice



Kappa, os resultados foram moderados para os algoritmos MaxVer e SAM e razoável para o algoritmo K-médias. O baixo desempenho de todos os modelos testados pode ser justificado pela falta de resolução espectral da imagem utilizada, uma vez que os algoritmos em questão se baseiam na comparação entre pixels da energia refletida nas diferentes bandas espectrais e, portanto, quanto maior a resolução espectral da imagem, maiores serão as chances de se distinguirem os alvos.

O algoritmo K-médias obteve as maiores proporções de pixels classificados corretamente para os alvos: asfalto e cobertura 3 (telhado de alta reflectância) (Tabela 1). A classe cobertura 1 não foi gerada, sendo introduzida dentro da classe estrada de terra. As principais confusões que ocorreram na classificação não-supervisionada K-médias envolveram as classes asfalto e estrada de terra; cobertura 2 e asfalto; e entre as vegetações arbustiva, moderada e baixa e estas com a água. A classe sombra predial não foi criada pelo algoritmo K-médias, sendo o comportamento espectral desta classe atribuído à água e à vegetação baixa de regiões úmidas, onde a absorção de energia incidente é bastante elevada nestes dois alvos.

O algoritmo SAM obteve as maiores proporções de pixels classificados corretamente para os alvos: vegetação arbustiva, vegetação baixa e água (Tabela 1). As maiores confusões foram entre as classes asfalto e coberturas 2 e 3; principalmente, entre cobertura 1 e estrada de terra e cobertura 2; entre vegetação arbustiva e sombra predial e vegetação baixa; e entre vegetações moderada e arbustiva.

O algoritmo MaxVer, apesar de ter tido os melhores resultados de classificação, também apresentou grandes confusões, principalmente com a classe asfalto. Esta classe confundiu-se com a cobertura 2. Demais confusões ocorreram entre cobertura 1 e estrada de terra, entre vegetação arbustiva e sombra predial e vegetação moderada, e entre vegetações moderada e baixa. As maiores proporções de pixels classificados corretamente foram para as classes cobertura 1, cobertura 2, estrada de terra, sombra predial e vegetação moderada (Tabela 1).

Todos os classificadores obtiveram bons resultados para as classes cobertura 3 e água (Tabela 1). No entanto, para as classes de vegetação, houve muita divergência dos resultados entre os algoritmos.

Tabela 1. Proporção dos pixels classificados corretamente para cada classe, exatidão global e índice Kappa dos diferentes classificadores.

Classes	K-médias	MaxVer (%)	SAM
Asfalto	80,91	72,02	80,26
Cobertura 1 (telhado de barro)	-	88,29	56,19
Cobertura 2 (telhado de zinco)	21,37	49,39	38,36
Cobertura 3 (telhado de alta reflectância)	100,00	99,82	99,08
Estrada de terra	34,75	94,92	78,81
Sombra predial	-	68,03	54,42
Vegetação arbustiva	20,30	36,50	44,71
Vegetação baixa (rala)	54,48	46,19	59,22
Vegetação moderada	4,37	73,62	4,45
Água	91,53	89,19	94,70
Exatidão Global (%)	47,25	64,89	54,46
Índice Kappa	0,37	0,59	0,48

A Figura 2 apresenta o resultado final das classificações onde se pode verificar uma discordância, entre algoritmos, nos mapas de uso e cobertura obtidos para a BHU do Arroio Pelotas no que diz respeito às classes predominantes na área de estudo. Conforme o resultado da classificação MaxVer, mais de 50 % da área corresponde às classes asfalto, cobertura 2 e vegetação baixa (total de 60,82 %) (Tabela 2). Segundo o produto da classificação K-médias, as classes asfalto e estrada de terra somam mais da metade da área (54,99 %), enquanto que para o classificador SAM a predominância ficou por conta das classes cobertura 2 e vegetação baixa (56,58 %) (Tabela 2). Visualmente, as maiores concordâncias entre mapas corresponderam às classificações SAM e K-médias (Figura 2).

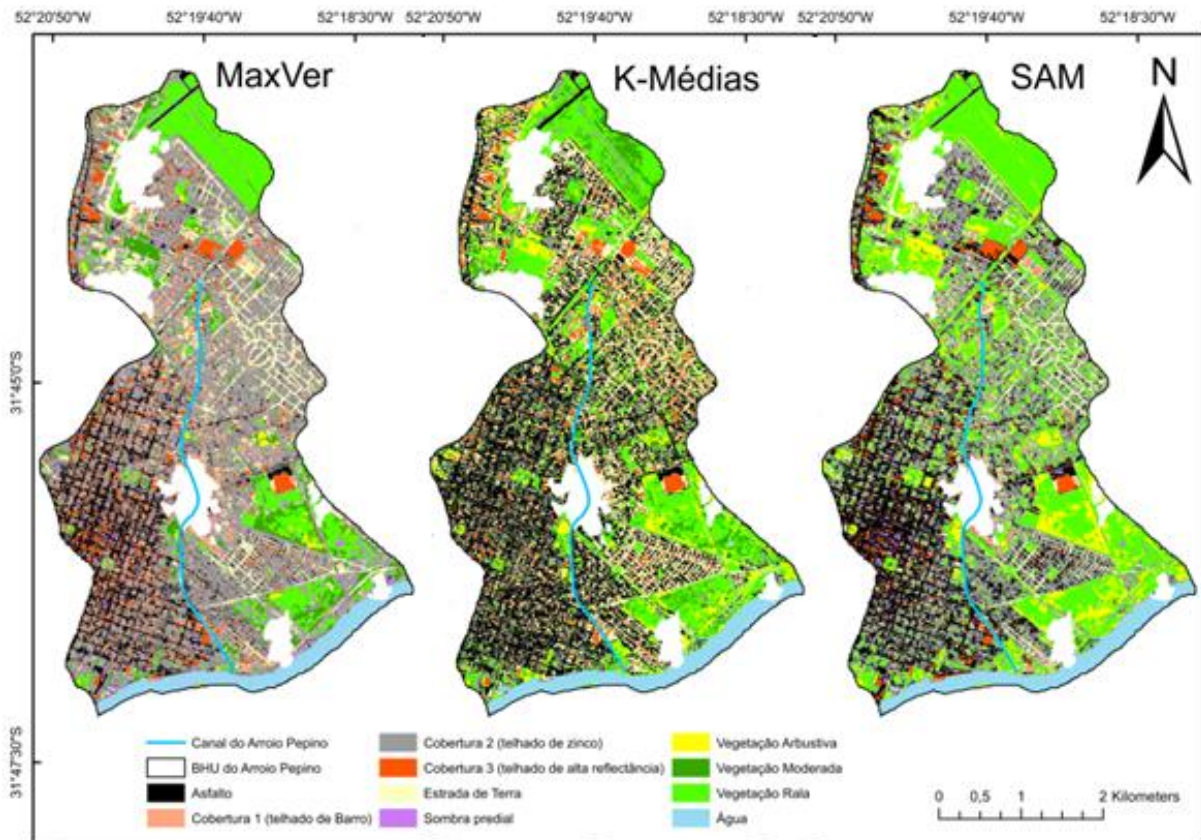


Figura 2: Mapas de uso e cobertura da superfície para a BHU do Arroio Pepino.

Os valores de  $CN_{total}$  para a BHU do Arroio Pelotas calculados a partir das informações extraídas dos mapas de uso e cobertura produzidos pelos algoritmos K-médias e SAM apresentaram-se bastante similares com 88,91 % e 88,88 %, respectivamente (Tabela 2). Apesar dos mapas correspondentes a estes algoritmos mostrarem alguma similaridade (Figura 2), ambos não classificaram igualmente os pixels, além de várias divergências espaciais entre classes, conforme já mencionado. O algoritmo K-médias, comparado ao SAM, obteve uma menor porcentagem de área para as classes de valor de CN mais alto (asfalto e coberturas). No entanto, o mesmo classificador também obteve uma menor porcentagem para as classes de vegetação, com os menores valores de CN devido ao alto potencial de infiltração, o que acabou por compensar e, conseqüentemente, igualar os valores de  $CN_{total}$  desses dois algoritmos.

O valor de  $CN_{total}$  calculado com as informações de superfície obtidas através do algoritmo MaxVer foi de 90,76 % devido, principalmente, às maiores proporções dos pixels classificados como cobertura, sobretudo a classe cobertura 2 (38,78 % da área total), e às menores áreas de vegetação (18,01 % da área total), o que resultou no valor mais alto entre os

classificadores testados (Tabela 2). Esta tendência pode ser visualizada na Figura 2, onde o mapa do algoritmo MaxVer apresenta a predominância de cores correspondentes às coberturas, em detrimento às vegetações. Os mapas dos algoritmos K-médias e SAM possuem coloração predominante verde e amarela, correspondentes às diferentes classes de vegetação.

A pequena diferença nos valores finais de  $CN_{total}$  (Tabela 2) pode ser atribuída à baixa variação dos valores de CN por categoria, uma vez que estes foram obtidos para ambientes classificados hidrologicamente no grupo D, ou seja, sobre regiões de solo de várzea com pouca infiltração, como é o caso da BHU do Arroio Pepino onde mesmo em áreas de vegetação o escoamento superficial é alto. No entanto, estas pequenas diferenças no valor de CN podem produzir alterações significativas na quantificação do volume de escoamento superficial em uma bacia urbana afetando sua hidrologia.

Tabela 2. Relação entre classes e categorias tabeladas, valores de CN por categoria, predominância em percentual de cada classe por algoritmo de classificação, e valor de CN total para a BHU do Arroio Pelotas por classificador.

Classes	Categorias Tabeladas	CN	K-médias (%)	MaxVer	SAM
Asfalto	Ruas e estradas <sup>1</sup>	93	31,83	10,98	18,52
Estrada de terra	Ruas e estradas <sup>2</sup>	89	23,16	9,87	7,59
Cobertura 1	Lotes urbanos	94	-	6,04	1,07
Cobertura 2	Lotes urbanos	94	8,09	38,78	29,20
Cobertura 3	Lotes urbanos	94	5,36	5,58	3,49
Vegetação arbustiva	Florestas normais	76	3,95	0,91	6,71
Vegetação baixa	Campos permanentes <sup>3</sup>	83	20,04	11,06	27,38
Vegetação moderada	Campos permanentes <sup>4</sup>	79	3,19	6,04	0,29
Sombra predial	-	-	-	6,82	1,53
Água	-	-	4,37	3,93	4,22
		$CN_{total}$	88,91	90,76	88,88

<sup>1</sup>Pavimentadas e coletores abertos; <sup>2</sup>Estradas de terra; <sup>3</sup>Esparsos de baixa transpiração; <sup>4</sup>Normais.

#### 4. Conclusão

A hipótese do trabalho foi comprovada. Com base nos resultados apresentados, diferenças nas proporções de classes de uso e cobertura da superfície, obtidas através dos mapas temáticos produzidos pelos algoritmos de classificação supervisionada e não-supervisionada (K-médias, MaxVer e SAM), afetam o cálculo da curva-número da BHU do Arroio Pepino. Sendo assim, a qualidade do valor de  $CN_{total}$  é altamente dependente da acurácia do produto final da classificação. Neste sentido, o algoritmo de classificação MaxVer foi considerado a melhor opção apesar do seu desempenho moderado na BHU em estudo, cujo resultado do valor de  $CN_{total}$  prediz que, aproximadamente, apenas 10% da água proveniente de uma chuva irá infiltrar. O que ajuda a explicar o grande índice de inundações e alagamentos que a região sofre em períodos chuvosos.

A imagem de satélite RapidEye, assim como outras imagens de alta resolução espacial, apresenta-se como uma ferramenta importante e necessária para o cálculo do valor CN em BHU, uma vez que as proporções correspondentes à cada classe podem ser melhor mensuradas e consideradas no cálculo total da bacia. No entanto, ressalta-se que a falta de resolução espectral deste sensor pode afetar o desempenho de classificadores que se baseiam no comportamento espectral dos alvos, assim como os testados, onde a utilização de

classificadores que avaliam a forma dos objetos pode ser a melhor opção. Estudos neste sentido serão realizados na sequência.

### Agradecimentos

Ao Ministério do Meio Ambiente (MMA) pela imagem RapiEye disponibilizada e ao Programa de Educação Tutorial (PET) do curso de Engenharia Hídrica da UFPel.

### Referências

Cardoso, E.C.A. **Mapeamento das transformações socioambientais da Bacia Hidrográfica do Arroio Pepino, 1916 – 2011 / Pelotas (RS)**. 2012. 48 p. Dissertação (Mestrado em Geografia) – Universidade Federal do Rio Grande, Rio Grande. 2012.

Cattani, C.E.V.; Mercante, E.; Souza, C.H.W.; Wrublack, S. C. Desempenho de algoritmos de classificação supervisionada dos Satélites RapdEye. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. Artigos, p. 8005-8010. CD-ROM, On-line. ISBN 978-85-17-00066-9. Disponível em: < <http://www.dsr.inpe.br/biblioteca/>>. Acesso em: 04 nov. 2016.

Fletcher, T.D; Andrieu, H; Hamel, P. Understanding, management and modeling of urban hydrology and its consequences for receiving waters: A state of the art. **Advances in Water Resources**, v. 51, p. 261-279, 2013.

Jensen, J.R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2009. 604 p.

Kruse, F.A.; Lefkoff, A.B.; Bordman, J.W.; Heidebrecht, K.B.; Shapiro, A.T.; Barloon, P.J.; Goetz, A.F.H. The spectral image processing system (SIPS) - interactive visualization and analysis of image spectrometer data. **Remote Sensing of Environment**, v. 44, p. 145-163, 1993.

Mello, C.R.; Silva, A.M. **Hidrologia: Princípios e Aplicações em Sistemas Agrícolas**. Lavras: UFLA, 2013. 455 p.

Meneses, P.R; Almeida, T. **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: UnB, 2012. 266 p.

Myeong, S.; Nowak, D. J.; Hopkins, P. F.; Brock, R. H. Urban cover mapping using digital, high-spatial resolution aerial imagery. **Urban Ecosystems**, v. 5, p. 243-256, 2001

Sartori, A.; Lombardi Neto, F.; Genovez, A.M. Classificação hidrológica de solos brasileiros para a estimativa da chuva excedente com o método do serviço de conservação do solo dos Estados Unidos. Parte 1: Classificação. **Revista Brasileira de Recursos Hídricos**, v. 10, n. 4, p. 5-18, 2005a.

Sartori, A.; Genovez, A.M.; Lombardi Neto, F. Classificação hidrológica de solos brasileiros para a estimativa da chuva excedente com o método do serviço de conservação do solo dos Estados Unidos. Parte 2: Aplicação. **Revista Brasileira de Recursos Hídricos**, v. 10, n. 4, p. 19-29, 2005b.

Simões, I; Duft, D.G; Miranda, C.G; Souza, C.H.W; Sanches, G.M; Picoli, M.C.A. Avaliação do desempenho de classificadores em imagens de Veículo Aéreo Não **Anais...** São José dos Campos: INPE, 2013. Artigos, p. 0611-0618. CD-ROM, On-line. ISBN 978-85-17-00076-8. Disponível em: < <http://www.dsr.inpe.br/biblioteca/>>. Acesso em: 04 nov. 2016.

Strech, E.V.; Kampf, N.; Dalmolin, R.S.D.; Klant, E.; Nascimento, P.C.; Schneider, P.; Giasson, E.; Pinto, L.F.S. **Solos do Rio Grande do Sul**. Porto Alegre: Emater/RS-ASCAR, 2008. 222 p.

Richards, J. A.; Jia, X. **Remote sensing digital image analysis: an introduction**. New York: Springer Verlag, 2006. 494 p.

USDA - United States Department of Agriculture. **Urban Hydrology for Small Watersheds**. Washington: United States Department of Agriculture, 1986. 164 p. (USDA-210-VI-TR-55).