



CLASSIFICAÇÃO DE IMAGENS DO SENSORIAMENTO REMOTO PARA FINS DE MAPEAMENTO DE SOLO

Leonardo Tullio¹, Weverton Carlos Ferreira Trindade²

RESUMO: O objetivo deste trabalho foi explorar as diversas ferramentas do *software* GIS Quantum GIS (QGIS 3.0.1), utilizando estas ferramentas para visualizar e manipular dados espaciais (vetores e rasters) e classificar imagens de satélites orbitais para fins de mapeamento de solo. Como resultado, foram gerados mapas da cidade de Ponta Grossa (Paraná) referentes ao Índice de Vegetação por Diferença Normalizada (NDVI) e à classificação da cobertura da terra utilizando o complemento *Semi-automatic Classification Plugin*. As ferramentas disponíveis no QGIS se mostraram eficazes na classificação e análise da vegetação e mapeamento do solo.

PALAVRAS-CHAVE: Classes; QGIS; Mapas.

INTRODUÇÃO

Uma das formas de identificar e classificar os pixels de uma imagem de satélite é através da classificação supervisionada, onde o usuário identifica alguns dos pixels pertencentes às classes desejadas (áreas de treino) e o software localiza todos os demais pixels pertencentes àquelas classes (GANAN et al., 2005). Uma das ferramentas disponíveis para este tipo de classificação é o *Semi-Automatic Classification Plugin* (SCP) (CONGEDO, 2018), um complemento para o software de uso livre QGIS.

O SCP tem sido amplamente utilizado nos mais diversos campos de estudo, como por exemplo análise de catástrofes ambientais (VIEIRA; TEODORO; GOMES, 2016) e impactos ecológicos (POTIĆ et al., 2017), efeitos da urbanização (DARMANTO; VARQUEZ; KANDA, 2017) e análise de áreas agrícolas (ESCOLÀ et al., 2017). O objetivo deste trabalho foi explorar as diversas ferramentas do *software* GIS Quantum GIS (QGIS 3.0.1), utilizando estas ferramentas para visualizar e manipular dados espaciais (vetores e rasters) e classificar imagens de satélites orbitais para fins de mapeamento do solo.

MATERIAL E MÉTODOS

Download e Pré-processamento das imagens

¹Doutorando, UFPR, Curitiba-PR. leonardo.tullio@outlook.com

²Mestrando, UEPG, Ponta Grossa-PR.

A classificação supervisionada e o cálculo do Índice de Vegetação por Diferença Normalizada (NDVI) foram realizados com base em imagens do Satélite Landsat 8 OLI, que conta com 12 bandas espectrais com resoluções de 15 metros (banda pancromática), 100 metros (bandas de infravermelho 1 e 2) e 30 metros (demais bandas).

O processamento, classificação e análise das imagens foram realizados no software QGIS 3.0.1, por meio do complemento *Semi-Automatic Classification Plugin (SCP)* 6.2.2.

No SCP, as imagens foram pré-processadas, onde foi realizada a conversão dos valores das bandas espectrais de *Digital Number (DN)* para *Top Of Atmosphere (TOA)* reflectance e a temperatura das bandas termais para graus Celsius. Como sugerido por Song et al. (2001), não foi realizada a correção atmosférica, já que o estudo não envolveu comparação de tempos ou lugares diferentes. Após o pré-processamento, as imagens foram cortadas utilizando um *shapefile* dos limites da cidade de Ponta Grossa.

Índice de Vegetação por Diferença Normalizada (NDVI)

Para cálculo do NDVI foram utilizadas as bandas vermelha (*Red*) e Infravermelha próxima (*NIR*). O cálculo foi feito utilizando a calculadora Raster, segundo a fórmula:

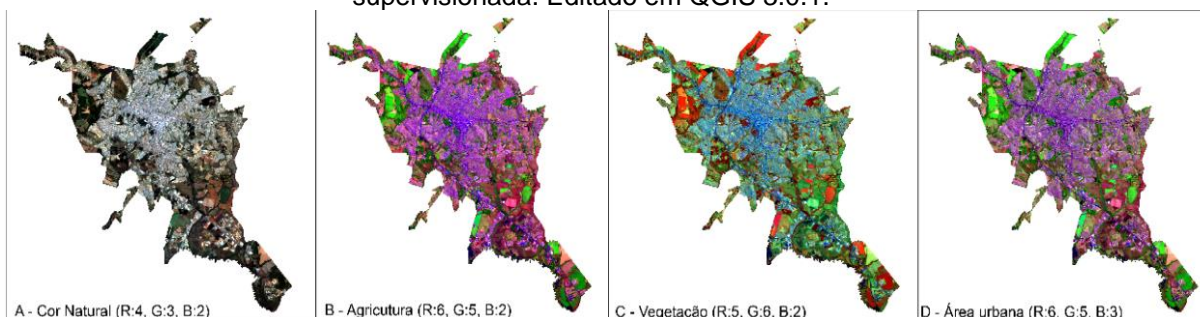
$$NDVI = \frac{NIR - Red}{NIR + Red}$$

Classificação Supervisionada

A metodologia de classificação foi feita seguindo o manual criado por Araújo (2015), usando as classes e cores RGB do II Nível de Classes de Cobertura e Uso do Solo do IBGE (IBGE, 2006).

Conforme sugerido por Butler (2013) e Peters (2015), além da combinação RGB 4-3-2 para cor natural, foram usadas as combinações 6-5-2 para diferenciação e classificação de áreas agrícolas; 6-5-4 e 5-6-2 para diferenciação e classificação de vegetações, principalmente para diferenciar florestas de campo; 5-6-4 para classificação de corpos d'água; e 6-5-3 para classificação da área urbana (Figura 1).

Figura 1. Diferentes composições de bandas utilizadas para coleta de amostras na classificação supervisionada. Editado em QGIS 3.0.1.





RESULTADOS E DISCUSSÃO

Classificação supervisionada

Utilizando as ferramentas de criação de ROI (*Region of interest*) por pontos e polígonos, foram coletados como amostra 1118 pixels de área urbanizada, 14817 pixels de lavoura, 3113 pixels de área florestal, 2027 pixels de área campestre e 308 pixels de corpos d'água continentais. A Figura 2 mostra as características espectrais (*signatures*) de cada tipo de amostra. A área urbanizada possuiu uma maior diversidade de valores espectrais, com média de desvio padrão de 0.037 para as 6 bandas, enquanto as amostras de corpos d'água apresentaram a menor diversidade, com média de desvio padrão de 0.012.

Figura 2. Plot das características (signatures) espectrais dos 5 tipos de amostras.

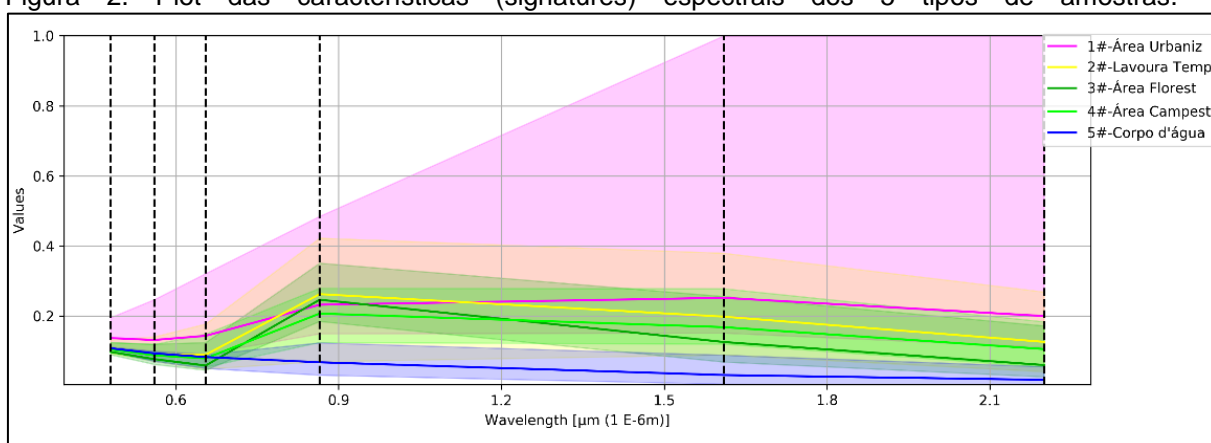
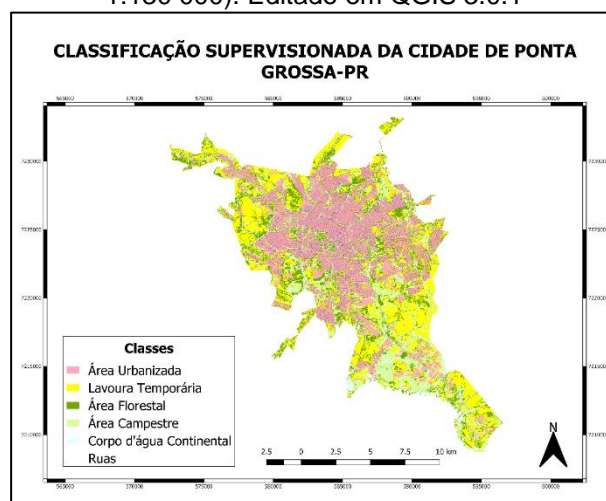


Figura 3. Resultado final da classificação (Raster) (Projetado em SAD69/ UTM 22S com escala 1:130 000). Editado em QGIS 3.0.1



De acordo com os dados gerados pelo algoritmo GRASS "*r.report*", a área urbanizada cobre 68 km² da cidade, lavouras cobrem 61 km², áreas florestais 37 km², áreas

campestres 32 km² e corpos d'água 2 km². O mapa final, com os vetores de ruas e bacias hidrográficas incorporados, pode ser visualizado na Figura 3.

CONCLUSÃO

As ferramentas disponíveis no QGIS se mostraram eficazes na classificação e análise da vegetação e mapeamento do solo. Em relação a classificação supervisionada, o resultado se mostrou satisfatório, apesar do algoritmo classificar algumas áreas erroneamente, principalmente em relação a área urbana, que apresenta uma enorme diversidade de valores espectrais.

REFERÊNCIAS

- ARAÚJO, M. P. DE. **QGIS: Classificação Supervisionada de Imagens Orbitais com o Semi-Automatic Classification Plugin**. Disponível em: <<http://qgisbrasil.org/blog/2015/08/18/qgis-classificacao-supervisionada-de-imagens-orbitais-com-o-semi-automatic-classification-plugin/>>. Acesso em: 8 março. 2019.
- BUTLER, K. **Band Combinations for Landsat 8**. Disponível em: <<https://www.esri.com/arcgis-blog/products/product/imagery/band-combinations-for-landsat-8/>>. Acesso em: 8 março. 2019.
- CONGEDO, L. **Semi-Automatic Classification Plugin Documentation**. Disponível em: <<https://fromgistors.blogspot.com/p/user-manual.html?spref=scp>>. Acesso em: 10 março de 2019.
- DARMANTO, N. S.; VARQUEZ, A. C. G.; KANDA, M. Urban roughness parameters estimation from globally available datasets for mesoscale modeling in megacities. **Urban Climate**, v. 21, p. 243–261, set. 2017.
- ESCOLÀ, A. et al. Using Sentinel-2 images to implement Precision Agriculture techniques in large arable fields: First results of a case study. **Advances in Animal Biosciences**, v. 8, n. 02, p. 377–382, 1 jul. 2017.
- GANAN, J. R. et al. Mapeamento da cultura da soja com imagens Landsat 5/TM utilizando algoritmos de classificação supervisionada. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**, 2005.
- IBGE. **Manual Técnico de Uso da Terra**. 2. ed. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística, 2006.
- PETERS, J. **The Many Band Combinations of Landsat 8**. Disponível em: <<https://www.harrisgeospatial.com/Learn/Blogs/Blog-Details/TabId/2716/ArtMID/10198/ArticleID/15691/The-Many-Band-Combinations-of-Landsat-8.aspx>>. Acesso em: 8 abril. 2019.
- POTIĆ, I. M. et al. Remote sensing role in environmental stress analysis: East Serbia wildfires case study (2007–2017). **Journal of the Geographical Institute Jovan Cvijic**, v. 67, n. 3, p. 249–264, 2017.
- VIEIRA, D.; TEODORO, A.; GOMES, A. Analyzing land surface temperature variations during Fogo Island (Cape Verde) 2014-2015 eruption with Landsat 8 images. **Earth Resources and Environmental Remote Sensing/GIS Applications**, 2016.