## **REVISTA DO DEPARTAMENTO DE GEOGRAFIA**

Universidade de São Paulo

www.revistas.usp.br/rdg - ISSN 2236-2878 Volume Especial do II Workshop do Programa de Pós-Graduação em Geografia Física (2018) DOI: 10.11606/rdg.v0ispe.145784

# Classificação do Padrão de Ocupação Urbana de São Paulo Utilizando Aprendizagem de Máquina e Sentinel 2

Urban land use classification of São Paulo using Machine Learning and Sentinel 2

### Marcos Reis Rosa<sup>1</sup>

<sup>1</sup> Universidade de São Paulo, marcosrosa@usp.br

**Resumo**: Mapear o padrão de ocupação urbana e intra-urbana é essencial para planejamento das grandes cidades. O Google Earth Engine, classificação com aprendizagem de máquina e imagens do Sentinel 2 permitem uma classificação detalhada das áreas urbanas que pode ser aprimorada pelo conjunto de bandas utilizadas, algoritmo e balanceamento das amostras. Foram produzidas classificações do município de São Paulo/SP para o ano de 2017 com o melhor resultado produzido pelo Random Forest com 87,2% de exatidão global quando utiliza as bandas de reflectância, índices espectrais, temporal e de textura. O resultado demonstra a capacidade de utilizar a plataforma e imagens livres com algoritmos de aprendizagem de máquina para classificar padrão de ocupação urbana e intra-urbana.

**Palavras-Chave**: GEE; Classificador por Aprendizagem de Máquina; Índice Temporal; Índice de Textura.

Recebido (*Received*): 30/04/2018 Aceito (*Accepted*): 26/08/2018

Abstract: Map Urban and intra-urban is essential for large city planning. Google Earth Engine, machine learning and Sentinel 2 images allow a detailed classification of urban areas that can be improved by the set of bands used, algorithm, and sample balancing. Classifications were produced for municipality of São Paulo in 2017 with the best result produced by Random Forest, with 87.2% global accuracy when using reflectance, spectral, temporal and texture bands. The result demonstrates the great capacity to use free platform and images with machine learning to classify urban and intra-urban areas.

*Keywords*: *GEE*; *Machine Learning Classifier*; *Temporal Index*; *Texture Index* 

#### 1.Introdução

Várias organizações internacionais, incluindo a International Geosphere-Biosphere Programme (IGPB) e a Food and Agriculture Organization of the United Nations (FAO) estão particularmente interessadas em metodologias para automatizar a classificação do uso da terra e estimar a mudança de uso baseada em dados de sensoriamento remoto. (COLDITZ *et al.*, 2011)

A urbanização é um fenômeno global e o crescimento contínuo de áreas construídas tem um impacto direto no uso e cobertura do solo nas paisagens urbanas (FAN *et al.*, 2017). O entendimento dos padrões de ocupação urbana e intra-urbana são críticos para um grande número de questões, incluindo habitação e desenvolvimento urbano, redução da pobreza, desenvolvimento sustentável, mudança climática, conservação da biodiversidade, provisão de serviços ecossistêmicos e gestão de desastres (PESARESI *et al.*, 2015). Com a melhora nas estimativas e o mapeamento de padrões do uso urbano aliados à melhora da resolução espacial de modelos climáticos será possível explicitar a contribuição urbana para a termodinâmica da atmosfera e balanço energético (SETO e SHEPHERD 2009).

A maior disponibilidade de imagens de alta resolução nos anos recentes, juntamente com avanços nos recursos computacionais e algoritmos de processamento de imagens tem promovido a geração de bases de dados de ocupações urbanas (ROY *et al.*, 2018). Dados de observação da Terra livres e abertos (por exemplo, Landsat e Sentinel) oferecem um grande potencial para o mapeamento de grandes áreas de assentamentos humanos (PESARESI *et al.*, 2016).

Segundo LU e WENG (2007), a pesquisa na classificação de imagens tem chamado a atenção da comunidade científica do sensoriamento remoto, no entanto, esse é um processo complexo que envolve muitos fatores, como escolha do método de classificação mais adequado, seleção de amostras de treinamento, pré-processamento de imagens, escolha de legenda adequada, pós-classificação e checagem de acuraria. Classificadores supervisionados não paramétricos baseados em aprendizagem de máquina tornaram-se cada vez mais populares para classificação de dados de sensoriamento remoto (BELGIU e DRĂGU 2016)

Esse artigo utiliza a plataforma de processamento em nuvem do Google Earth Engine (GEE) e imagens de alta resolução da Sentinel 2 para validar métodos de classificação supervisionada baseados em aprendizagem de máquina de padrões de ocupação urbana na cidade de São Paulo, variando as bandas de referência, o desenho amostral e o algoritmo de classificação.

O objetivo da pesquisa é analisar a capacidade dos algoritmos de aprendizagem de máquina para produzir, com base em imagens Sentinel 2 e índices de reflectância, temporais e de textura, classificações detalhadas sobre o padrão de ocupação urbana e intra-urbana.

#### 2. Materiais e métodos

#### 2.1. Plataforma de processamento e imagem

O trabalho foi desenvolvido na plataforma do Google Earth Engine que "consistem em um catálogo de vários peta bytes de dados prontos para análise acoplado à um serviço de computação intrinsecamente paralelo de alto desempenho"(GORELICK *et al.*, 2017)

Foram utilizadas imagens do sensor multiespectral do Sentinel 2, com nível 1c (melhor nível de correção produzido de forma sistemática que inclui: projeção em sistema cartográfico utilizando Modelo Digital de Terreno; valores de reflectância em Topo de Atmosfera (TOA); reamostragem em grid padrão de 10, 20 e 60m (GSD) e inclusão de máscara de nuvem) (ESA, 2015). Os satélites Sentinel-2A e 2B são satélites de imageamento multispectral que geram imagens em alta resolução (com bandas de 10m a 60m) e com alta capacidade de revisita (5 dias). (DRUSCH *et al.*, 2012)

Foi aplicado um filtro para remoção de pixels de nuvem nas imagens capturadas entre 01/07/2017 e 30/09/2017 e gerada uma imagem síntese do período utilizando o valor da mediana de cada pixel válido das bandas 'B2', 'B3', 'B4', 'B8', 'B11' (blue, green, red, NIR e SWIR 1, respectivamente). A utilização do valor da mediana é importante pois elimina pixels contaminados por ruídos causados por névoas, nuvem ou sombra de nuvem que não tenham sido removidos no filtro inicial.

Além das bandas originais foi gerado um segundo conjunto de bandas com o objetivo de avaliar a acurácia da classificação com a adição de índices de reflectância. Foi incluído o Índice de Vegetação da Diferença Normalizada (NDVI) (MALENOVSKÝ *et al.*, 2012), o Índice por Diferença Normalizada para Áreas Construídas (NDBI) (XU, 2008) e o Índice de vegetação melhorado (EVI2) (JIANG *et al.*, 2008).

Um terceiro conjunto de bandas foi gerado com a inclusão de outros dois índices com informações temporais e informações de contexto. Foram utilizados todas os pixels válidos das imagens do ano de 2017 para gerar a amplitude de variação do EVI2, calculado pela diferença entre o valor mínimo e máximo do EVI2. Outra banda adicionada armazena a estimativa de textura espacial, calculada pela função "entropy" do GEE utilizando um kernel de 5 pixels.

Durante a etapa da classificação é avaliado o ganho de acurácia obtido ao utilizar cada conjunto de bandas para determinar o impacto das informações sobre o algoritmo de aprendizagem de máquina.

#### 2.2. Definição das Classes e amostragem

Foi utilizada uma legenda capaz de testar a capacidade de diferenciar alvos urbanos nas imagens Sentinel com classificadores de aprendizagem de máquina. Foram utilizadas 10 classes (**Tabela 1**) que incluem formações naturais e padrões de ocupação urbana e intra-urbana.

A amostragem foi realizada através da delimitação de polígonos de treinamento sobre imagem Sentinel, validados sobre imagens de alta resolução disponibilizada no GEE. (Figura 1).

Classe	Descrição
Floresta	Formações vegetais de porte florestal. Não há separação entre áreas naturais, alteradas ou plantadas
Campo	Formações vegetais de porte arbustivo ou campestre. Não há separação entre áreas naturais ou antrópicas
Residencial arborizado	Áreas predominantemente residenciais com ruas ou terrenos arborizados
Residencial	Áreas de uso predominantemente residencial
Residencial adensado	Áreas de uso predominantemente residencial com ocupação desordenada e predomínio de autoconstrução, praticamente sem espaço entre as construções e sem arborização
Verticalizado	Áreas com predomínio de prédios, muito caracterizadas na imagem pela existência de suas sombras
Industrial	Grandes construções caracterizadas normalmente por teto de zinco com alta reflectância nas imagens
Vias Principais	Grandes vias e rodovias da capital
Solo Exposto	Áreas de solo exposto, normalmente por obras ou algum uso agrícola

т.і. і.	1.Т	<b>`</b> `.~	1	-1			1	~
i abela	1:1	Jescricao	das	classes	utilizadas	s na c	lassitica	icao
I to o the		> • 0 • 1 1 • a 0	cierb	•1400000	weiling weiter	, 1100 0	100011100	iya ci ci



Figura 1: Exemplo das amostras de treinamento da classe Residencial Adensado (polígonos vermelhos) sobre imagem Sentinel 2.

A partir dos polígonos de treinamento foi gerado um primeiro conjunto de pontos com sorteio aleatório estratificado simples com 500 amostras para cada classe. Um segundo conjunto de amostras foi gerado para analisar a acurácia quando é realizado um balanceando na quantidade de amostras sorteadas de acordo com a área de ocorrência de cada classe na área de estudo. Esse conjunto de amostras foi gerado pelo sorteio de 1.500 amostras para as classes de "Floresta" e "Residencial", 500 amostras para as classes "Residenciais adensadas", "Vias" e "Solo Exposto". As demais classes tiveram 1.000 amostras sorteadas.

Os polígonos de validação foram delimitados de forma independente e utilizados para o sorteio de um terceiro grupo composto 300 amostras aleatórias estratificadas por classe, utilizado para geração da matriz de confusão e cálculo da exatidão do mapeamento.

#### 2.3. Classificação

Foram realizadas diversas classificações da área de estudo variando as bandas fornecidas para treinamento e classificação, o algoritmo de classificação e a quantidade de amostras. Para comparação, foram utilizados os dois métodos de classificação por aprendizagem de máquina mais comuns. O Random Forest (RF), inicialmente descrito

em BREIMAN (2001) foi utilizado com 100 interações. O Support vector machine (SVM) (VAPNIK, 1995) foi utilizado com procedimento de decisão por votação e tipo do kernel "LINEAR".

#### 3. Resultados e Discussões

A primeira etapa de análise foi realizada com um número padrão de 500 amostras aleatórios para cada classe e incrementa o conjunto bandas fornecidas para treinamento e classificação do RF, adicionado às bandas originais do Sentinel 2 os índices espectrais e os índices temporais e de textura.

O resultado de acurácia (**Tabela 2**) demonstra que adicionar índices espectrais baseados em cálculos entre bandas (2ª classificação) contribui pouco para melhora da acurácia, isso porque o classificador possui novos nós para geração da árvore de classificação estatística, mas não existe nenhuma informação nova.

**Tabela 2**: Comparação da Exatidão Global e Kappa para 1<sup>a</sup> etapa de análise.

Classificação	Bandas utilizadas	Exatidão Global	Kappa
1ª classificação	Apenas bandas de reflectância	77.2%	0.7463
2ª classificação	Adição de NDVI e NDBI	79.8%	0.7759
3ª classificação	Adição de EVI2 (mediana e amplitude) e NDBI_entropy	87.2%	0.8578

A 3<sup>a</sup> classificação apresenta um aumento significativo da acurácia. Nesse caso, foram adicionadas novas informações que não existiam na imagem original. A amplitude de variação do EVI2 permite diferenciar melhor alvos que permanecem estáveis durante todo ano (construções, vias, áreas industriais, etc.) de alvos que variam durante o ano (sombras, vegetação, agricultura, água, etc.) A banda de textura permite uma diferenciação pelos pixels do entorno, adicionando uma informação de contexto. É importante notar como essa banda ajudou a classificar regiões mais homogêneas, refletindo uma boa generalização que se espera para classificações de áreas urbanas (**Figuras 2 e 3**).



**Figura 2:** Figura com a região Oeste/Sul apresentando A) mapa com nome dos bairros; B) Imagem Sentinel 2; C) 2<sup>a</sup> classificação; D) 3<sup>a</sup> classificação.



**Figura 3:** Figura com a região dos Jardins/Itaim/Ibirapuera apresentando A) mapa com nome dos bairros; B) Imagem Sentinel 2; C) 2ª classificação; D) 3ª classificação.

A segunda etapa de análise compara a classificação produzida pelo RF e SVM utilizando o mesmo conjunto de bandas e amostras de treinamento. A classificação produzida pelo RF se demostrou mais acurada (**Tabela 3**).

A terceira etapa de análise utilizou o conjunto completo de bandas, comparando a classificação realizada pelo RF ao utilizar um número igual de amostras aleatórias para todas as classes e ao utilizar a quantidade de amostras balanceadas pela área de ocorrência de cada classe. O balanceamento da quantidade de amostras em cada classe teve pouco efeito sobre a acurácia do mapeamento (**Tabela 4**). Pela análise visual do produto foi possível perceber a diminuição de algumas confusões entre as áreas residenciais, que possuem maior abrangência, e áreas residenciais de baixo padrão (**Figura 4**), gerando uma classificação mais homogênea.

Classificação	Alternativas	Exatidão Global	Kappa
RF	Mesmas bandas e amostras que a 3a classificação classificada pelo RF	87.2%	0.8578
SVM	Mesmas bandas e amostras que a 3a classificação utilizando SVM	84.3%	0.8256

**Tabela 3**: Comparação da Exatidão Global e Kappa para 2ª etapa de classificação.

Classificação	Alternativas	Exatidão Global	Kappa
Amostras iguais	RF com mesmas bandas que a 3a classificação e 500 amostras para cada classe	87.2%	0.8578
Amostras Balanceadas	RF com mesmas bandas que a 3a classificação, mas utilizando amostras balanceadas	87.1%	0.8567



**Figura 4:** Figura com a região Leste apresentando: A) mapa com nome dos bairros; B) Imagem Sentinel 2; C) 3<sup>a</sup> classificação; D) Classificação com amostras balanceadas.

#### 4. Conclusões

O trabalho demonstra a grande capacidade para diferenciação dos padrões de ocupação urbano e intra-urbano utilizando imagens Sentinel 2, com bandas de 10 e 20m de resolução. A utilização do Google Earth Engine (GEE) permite que as etapas de tratamento das imagens, a remoção de nuvens, criação do mosaico e criação de índices espectrais, temporais e de textura e classificação seja realizado com grande flexibilidade permitindo a realização dos experimentos com grande facilidade.

O método RF se demonstrou superior ao SVM, capaz de produzir classificações com maior acurácia. A capacidade computacional e o tempo de processamento eram uma barreira à utilizado desse método. Sua implementação no GEE e o processamento em nuvem permitem agora que uma área como a cidade de São Paulo possa ser processada com imagens de 10m de resolução em poucos minutos.

Em toda classificação supervisionada é essencial fornecer ao classificador a maior quantidade de informações sobre cada pixel para que seja possível realizar uma boa diferenciação estatística entre os alvos. A utilização de índices de forma complementar às bandas apresentou uma pequena melhora na exatidão da classificação. O resultado da classificação melhorou sensivelmente ao incluir uma banda com informação temporal e outra banda com informação de textura. Essas duas bandas possuem pouca correlação com as bandas originais e fornecem novas informações que podem ser utilizadas pelo classificador para entender o comportamento dos alvos e melhorar a classificação. A pesquisa revela a importância de utilizar a informações temporais e de contexto de forma complementar as informações de reflectância para aumento da acurácia da classificação.

O balanceamento da quantidade de classes teve pequena alteração na acurácia, mas a classe residencial (de maior ocorrência espacial na área mapeada) teve um aspecto visual mais consistente. Novos estudos devem qualificar melhor a importância do balanceamento utilizando outros modelos ou outras cidades brasileiras.

É importante que estudos futuros explorem a estabilidade da classificação em diferentes anos, para analisar a possibilidade de monitorar as alterações do padrão de ocupação urbana utilizando as imagens Sentinel 2, disponíveis desde 2015.

## REFERÊNCIAS

BELGIU, M.; DRĂGU, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.

BREIMAN, L. Random forests. Machine Learning, v. 45, n. 1, p. 5–32, 2001.

COLDITZ, R. R.; SCHMIDT, M.; CONRAD, C.; HANSEN, M. C.; DECH, S. Land cover classification with coarse spatial resolution data to derive continuous and discrete maps for complex regions. **Remote Sensing of Environment**, v. 115, n. 12, p. 3264–3275, 2011. Disponível em: <a href="http://dx.doi.org/10.1016/j.rse.2011.07.010">http://dx.doi.org/10.1016/j.rse.2011.07.010</a>>.

DRUSCH, M.; DEL BELLO, U.; CARLIER, S.; COLIN, O.; FERNANDEZ, V.; GASCON, F.; HOERSCH, B.; ISOLA, C.; LABERINTI, P.; MARTIMORT, P.; MEYGRET, A.; SPOTO, F.; SY, O.; MARCHESE, F.; BARGELLINI, P. Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. **Remote Sensing of Environment**, v. 120, p. 25–36, 2012.

ESA. **SENTINEL - 2 User Handbook**. 2015. Disponível em: <a href="https://sentinel.esa.int/documents/247904/685211/Sentinel-2\_User\_Handbook">https://sentinel.esa.int/documents/247904/685211/Sentinel-2\_User\_Handbook</a>.

FAN, C.; MYINT, S. W.; REY, S. J.; LI, W. Time series evaluation of landscape dynamics using annual Landsat imagery and spatial statistical modeling: Evidence from the Phoenix metropolitan region. **International Journal of Applied Earth Observation and Geoinformation**, v. 58, p. 12–25, 2017. Disponível em: <a href="http://linkinghub.elsevier.com/retrieve/pii/S0303243417300090">http://linkinghub.elsevier.com/retrieve/pii/S0303243417300090</a>>.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, n. 2016, 2017. Disponível em: <a href="http://linkinghub.elsevier.com/retrieve/pii/S0034425717302900">http://linkinghub.elsevier.com/retrieve/pii/S0034425717302900</a>>.

JIANG, Z.; HUETE, A. R.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833–3845, 2008.

LU, D.; WENG, Q. Review article A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, v. 28, n. 5, p. 823–870, 2007.

MALENOVSKÝ, Z.; ROTT, H.; CIHLAR, J.; SCHAEPMAN, M. E.; GARCÍA-SANTOS, G.; FERNANDES, R.; BERGER, M. Sentinels for science: Potential of Sentinel-1, -2, and -3 missions for scientific observations of ocean, cryosphere, and land. **Remote Sensing of Environment**, v. 120, p. 91–101, 2012.

PESARESI, M.; CORBANE, C.; JULEA, A.; FLORCZYK, A. J.; SYRRIS, V.; SOILLE, P. Assessment of the added-value of sentinel-2 for detecting built-up areas. **Remote Sensing**, v. 8, n. 4, 2016.

PESARESI, M.; EHRLICH, D.; FERRI, S.; FLORCZYK, A.; FREIRE, S.; HAAG, F.; HALKIA, M.; JULEA, A. M.; KEMPER, T.; SOILLE, P. Global human settlement analysis for disaster risk reduction. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives, v. 40, n. 7W3, p. 837–843, 2015.

ROY CHOWDHURY, P. K.; BHADURI, B. L.; MCKEE, J. J. Estimating urban areas: New insights from very high-resolution human settlement data. **Remote Sensing Applications: Society and Environment**, v. 10, n. October 2017, p. 93–103, 2018. Disponível em: <a href="https://doi.org/10.1016/j.rsase.2018.03.002">https://doi.org/10.1016/j.rsase.2018.03.002</a>>.

SETO, K. C.; SHEPHERD, J. M. Global urban land-use trends and climate impacts. Current Opinion in Environmental Sustainability, v. 1, n. 1, p. 89–95, 2009.

VAPNIK, V. The Nature of Statistical Learning Theory. New Yourk: Springer-Verlag, 1995.

XU, H. A new index for delineating built-up land features in satellite imagery. **International Journal of Remote Sensing**, v. 29, n. 14, p. 4269–4276, 2008.