

USO DE PROCESSAMENTO EM NUVEM PARA A DETECÇÃO DE ÁREAS EDIFICADAS EM IMAGENS DE SENSORIAMENTO REMOTO

V. V. Mesquita¹, L. L. Parente², L. G. Ferreira³

^{1,2,3}Universidade Federal de Goiás - UFG, Brasil
Laboratório de Processamento de Imagens e Geoprocessamento
{¹vieiramesquita, ²leal.parente, ³lapig.ufg }@gmail.com

CT04 - SENSORIAMENTO REMOTO, FOTOGRAMETRIA E INTERPRETAÇÃO DE IMAGENS

RESUMO

O planejamento e monitoramento referente às dinâmicas de ocupação do espaço se fazem cada dia mais necessários, haja vista o intenso crescimento demográfico ocasionado pelos avanços nas áreas de produção de alimentos, medicina e engenharia pós-revolução industrial, os quais possibilitaram a expansão das aglomerações humanas em diversas regiões do planeta, colocando em risco a existência de vários ecossistemas. Com a popularização das plataformas de processamento de dados geográficos em nuvem, como por exemplo o Google Earth Engine (GEE), tornou-se muito mais simples analisar grandes extensões territoriais, pois a grande gama de dados disponíveis e o alto desempenho de processamento permitem executar diversas análises com velocidades superiores aos métodos tradicionais de processamento *in loco*. Especificamente, este trabalho utilizou a plataforma Google Earth Engine com o objetivo de se mapear as áreas edificadas ao redor do planeta utilizando índices como NDVI (*Normalized Difference Vegetation Index*), NDWI (*Normalized Difference Water Index inversed*), NDBI (*Normalized Difference Built-up Index inversed*) e dados de temperatura de brilho, corpos hídricos, fontes de luz estáveis e precipitação média anual, adquiridos por meio de dados Landsat 8 – OLI/TIRS, DMSP – OLS, TRMM 3B43 v7, GPM IMERG v4 e *Global Forest Change* (GFC). A identificação de áreas edificadas na superfície foi realizada a partir do fatiamento dos valores máximos de NDVI, NDWI e NDBI, de março de 2013 a dezembro de 2016, gerados através de diferenças normalizadas entre as bandas do verde, vermelho, infravermelho próximo e infravermelho de ondas curtas do satélite Landsat 8. Para assegurar a fidelidade do dado em detectar estruturas urbanas, foi utilizado como recorte espacial o fatiamento da temperatura de brilho gerada com a banda termal do Landsat 8, valores definidos de luminosidade característicos de zonas urbanizadas obtidos pelo DMSP e uma máscara de corpos hídricos disponibilizada pelo GFC. Visando otimizar os valores de NDVI para áreas áridas e semiáridas, com taxa de precipitação anual inferior à 750 milímetros, a média anual de precipitação (2000 a 2016, missões TRMM e GPM) foi utilizada como fator de ganho para os dados de NDVI. O resultado final possui algumas falhas como a dificuldade de mapear setores bastante arborizados e aglomerados urbanos e dificuldade de detecção em locais extremamente áridos, porém se mostra bastante consistente em todo o território brasileiro quando comparado com a Área Edificada do Brasil em 2015 (conforme da Base Cartográfica Contínua do Instituto Brasileiro de Geografia e Estatística) (e.g. Região metropolitana do Rio de Janeiro 1464 km²/IBGE – 1167 km²/GEE; Região metropolitana de Goiânia 646 km²/IBGE – 441 km²/GEE), bem como quando sobreposta com imagens de alta resolução, à exemplo daquelas disponibilizadas pelo Google Maps. Este método de mapeamento é bastante simples, rápido e de fácil alteração de parâmetros, sendo capaz de mapear com bastante precisão quando aplicado à regiões específicas.

Palavras chave: processamento em nuvem, área edificada, mapeamento urbano, Earth Engine

ABSTRACT

The planning and monitoring of the dynamics of occupation of space is becoming more and more necessary, given the intense population growth caused by the advances in the areas of food production, medicine and engineering post-industrial revolution, which allowed the expansion of human agglomerations in several regions of the planet, putting at risk the existence of several ecosystems. With the popularization of the cloud geographic data processing platforms, such as Google Earth Engine (GEE), it has become much simpler to analyze large territorial extensions, because the wide range of data available and the high performance of processing allow to execute analyzes at speeds higher than traditional on-site processing methods. Specifically, this work used the Google Earth Engine platform to map the built up areas around the planet using indexes such as NDVI (*Normalized Difference Vegetation Index*), NDWI (*Normalized Difference Water Index inversed*), NDBI (*Normalized Difference Built-up Index inversed*) and

brightness temperature data, water bodies, stable light sources and annual average rainfall, acquired through Landsat 8 - OLI / TIRS, DMSP - OLS, TRMM 3B43 v7, IMERG v4 GPM and Global Forest Change (GFC). The identification of built areas in the surface was performed from the slicing of the maximum values of NDVI, NDWI and NDBI, from March 2013 to December 2016, generated through normalized differences between the green, red, near infrared and infrared short waves from Landsat 8 satellite. In order to ensure the fidelity of the data in detecting urban structures, was used like a spatial cut-off the brightness temperature generated with the Landsat 8 thermal band, defined values of luminosity characteristic of urban zones obtained by the DMSP and a mask of water bodies provided by the GFC. Aiming to optimize the NDVI values for arid and semiarid areas, with annual precipitation rate lower than 750 millimeters, the annual average precipitation (2000 to 2016, TRMM and GPM missions) was used as a gain factor for NDVI data. The final result has some flaws such as the difficulty of mapping fairly wooded areas of urban agglomerates and difficult to detect in extremely arid locations, but it is very consistent throughout the Brazilian territory when compared to the Brazilian Built Area in 2015 (according to the *Base Cartográfica Contínua do Instituto Brasileiro de Geografia e Estatística*) (e.g. Metropolitan Region of Rio de Janeiro 1464 km² / IBGE - 1167 km² / GEE; Metropolitan Region of Goiânia 646 km² / IBGE - 441 km² / GEE), as well as when superimposed with high resolution images, like those available by Google Maps. This method of mapping is quite simple, fast and easy to change parameters, being able to map very accurately when applied to specific regions.

Keywords: cloud processing, built area, urban mapping, Earth Engine

1 - INTRODUÇÃO

Os processos de urbanização e expansão dos centros urbanos ocorreram de forma distinta em diversas partes do planeta. Nos países desenvolvidos foi desencadeado pela intensa industrialização ocorrida durante os séculos XVIII e XIX, que possibilitou uma baixa nas taxas de mortalidade e uma leve queda de fertilidade, seguindo um ritmo controlado de crescimento. Ao fim da Segunda Grande Guerra, com a popularização dos medicamentos e a maior ocorrência de movimentos de migração rural-urbano, as nações conhecidas como “*países em desenvolvimento*” enfrentaram um processo intenso de crescimento populacional não planejado que à várias décadas vem tentando ser freado pelas mesmas. Quando não planejado, os processos de urbanização e expansão urbana põem em sérios riscos os recursos naturais (Bekele, 2005; Bongaarts, 2009).

O uso de dados de sensoriamento remoto e técnicas de geoprocessamento está a cada dia mais presente no monitoramento, planejamento e previsão de possíveis mudanças nas dinâmicas de uso e ocupação da superfície terrestre, sobretudo as que podem causar impactos ao meio ambiente como a expansão e aglomeração urbana (Jat, Garg & Khare, 2008).

O “boom” da computação em nuvem no início da segunda década do século XXI permitiu o nascimento de diversas plataformas de processamento em nuvem, entre elas a *Amazon Web Services* (AWS) (Amazon, 2017), *Microsoft Azure* (Microsoft, 2017), *Nebula Cloud Computing Platform* (NCCP) (NASA, 2017). Não menos importante que as plataformas citadas, o Google Earth Engine vem se destacando no que diz respeito a computação em nuvem aberta voltada para o processamento de dados satelitários e espaciais, pois o mesmo possui um catálogo com *petabytes* de dados orbitais e uma capacidade de processar e visualizar informações extremamente

superior aos métodos convencionais em *desktop GIS* (*Geographic Information System*) (Gorelick et al., 2017; Google, 2017b).

A fim de pôr em teste o poder de processamento do GEE, o objetivo principal deste trabalho foi o de mapear as áreas edificadas de centros urbanos, em função do sinal peculiar que as mesmas possuem em imagens de satélite, um fator facilitador na interpretação de resultados.

2 - MATERIAIS E MÉTODOS

Para a realização deste estudo foram utilizados os dados satelitários USGS Landsat 8 TOA Reflectance ortorretificados (Google, 2017e), DMSP-OLS Nighttime Lights Time Series Version 4 (Google, 2017a), Hansen Global Forest Change v1.3 (Google, 2017d), ambos disponíveis no banco de dados do GEE, e também fez-se o uso de dados TRMM 3B43 v7 (GES DISC, 2017b) e GPM IMERG *Monthly* (GES DISC, 2017a) disponibilizados pelo *Goddard Earth Sciences Data and Information Services Center* (GES DISC).

Através do *Code Editor* (Google, 2017c), uma plataforma de programação e processamento em nuvem do GEE baseada na linguagem *Javascript*, foi possível o carregamento de toda a série temporal Landsat 8 disponível para o planeta entre os anos 2013 a 2016, dos dados DMSP *stable lights*, do dado GFC *datamask* e do dado TRMM/GPM da precipitação média anual de 2000 a 2016 (Este último foi inserido como *asset* na plataforma - via *upload*).

A partir da série de dados Landsat 8, foram realizados os cálculo dos valores máximos (MVC – *Maximum Composite Value*) de NDVI (*Normalized Difference Vegetation Index* - Rouse et al., 1973) visando separar a vegetação da análise, de NDBI (*Normalized Difference Built-up Index* - Zha, Gao & Ni, 2003) invertido com objetivo de realçar estruturas urbanas e de NDWI (*Normalized Difference Water Index* - McFeeters, 2013) invertido pensando na

remoção de corpos hídricos e atenuação da vegetação. Os dados de luminosidade *stable lights* com valores acima de 15 representam bem os os focos luminosos emitidos pelas cidades e junto aos pixels de superfície do dado *datamask* foram utilizados como máscaras objetivando a otimização do processamento dos dados, remoção de ruídos de corpos hídricos e dar maior enfoque as regiões urbanizadas. Também foi usado como máscara os valores máximos de temperatura de brilho acima de 15°C fornecidos pela banda 10 da série de dados Landsat 8, com o objetivo de minimizar a entrada de ruídos causados por nuvens e/ou neve.

Na tentativa de minimizar os efeitos da sazonalidade da vegetação nos dados de NDVI em regiões de climas semiáridos e áridos, foi gerado uma média anual de precipitação entre os anos de 2000 e 2016 com dados TRMM (01/2000 a 03/2014) e GPM (04/2014 a 12/2016) que posteriormente foi utilizada como fator de ganho para os valores de NDVI em regiões com média anual de precipitação abaixo dos 750mm, sendo eles: adicional de 25% para valores entre 750 e 400mm, adicional de 50% para valores entre 400 e 200mm e adicional de 100% para valores abaixo de 200mm. Caso não fosse aplicado esse ganho, seria possível observar em algumas regiões semiáridas – como as encontradas no nordeste brasileiro – uma saturação na identificação de áreas edificadas, ocasionando a adição de áreas de vegetação com baixos valores de NDVI.

Após todas estas etapas de processamento (Fig. 1) é feito o fatiamento dos valores máximos, sendo eles: valores de NDVI menores que 0.55, valores de NDBIi menores que 0.35 e valores de NDWIi menores que 0.6. Somando os resultados e removendo os valores abaixo de 0 – possíveis ruídos – obtem-se um mapa de área edificada em escala global como uma resolução espacial de 30 metros. Para efeito de avaliação dos dados, foi feita a seleção de algumas regiões representativas: região Metropolitana do Rio de Janeiro (RMRJ), região Metropolitana de São Paulo (RMSP), região Metropolitana de Goiânia (RMG) e Distrito Federal (DF).

Para a verificação da precisão do dado gerado foi utilizado o dado de Área Edificada do Brasil de 2015 (IBGE, 2017) da Base Cartográfica Contínua do Brasil – 1:250000 disponibilizado pelo IBGE.

3 - RESULTADOS E DISCUSSÃO

Os resultados obtidos se mostram espacialmente consistentes quando sobrepostos com composições coloridas de bandas 5-6-4 de Landsat 8 (Fig. 2) e quando comparados a dados satelitários de alta resolução disponibilizados pela plataforma Google Maps, sobretudo para o Brasil; porém, é possível reparar problemas no dado final, como a ausência de algumas localidades nos dados DMSP, a adição de áreas de solo exposto e pastagens próximas às cidades, falha na inclusão de áreas edificadas em locais bastante áridos (Áreas próximas de desertos e/ou com

precipitação média muito baixa) e de estruturas localizadas em locais bastante arborizados (Fig. 3).

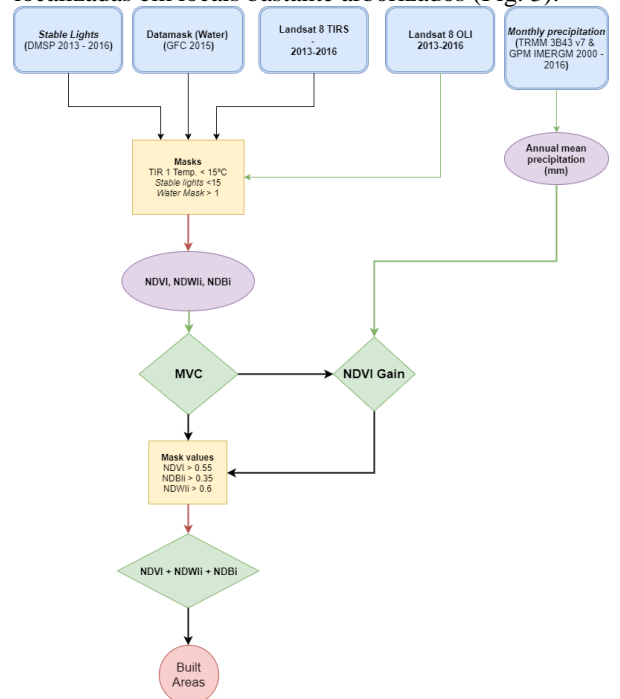


Fig. 1. Esquema representando as etapas de processamento dos dados.

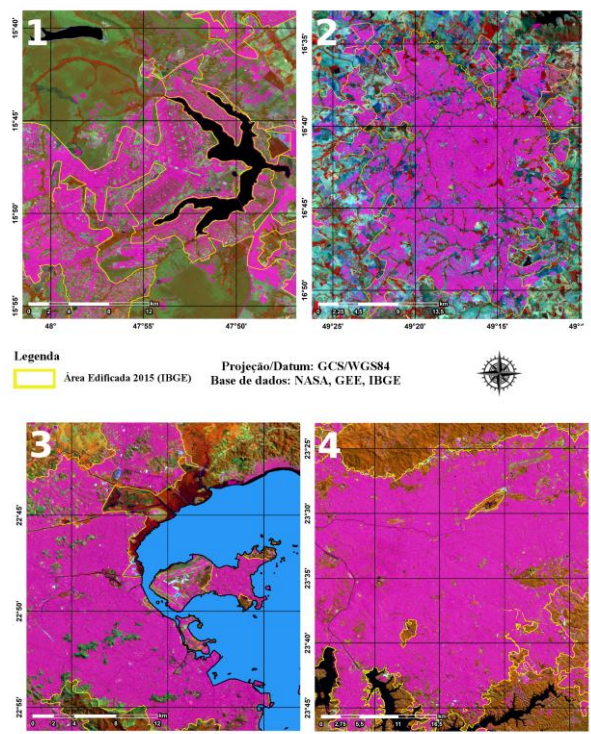


Fig. 2. Exemplo dos resultados de área edificada (em rosa) obtidos através do GEE comparados com a Área Edificada do Brasil 2015 do IBGE ambos sobrepostos a uma composição RGB 5-6-4 de imagens Landsat 8. Fig. 2.1. Distrito Federal; Fig. 2.2. RMG; Fig. 2.3. RMRJ; Fig. 2.4. RMSP.




Fig. 3. Estruturas urbanas mal classificadas devido a grande densidade de árvores por pixel - Tanguá/RJ.

Quando comparado aos dados de área edificada do IBGE, o trabalho em questão apresentou em área tamanhos inferiores ao dado de referência (Tabela 1), porém essa diferença pode ser facilmente explicada pelas generalizações que se encontram presentes no dado de referência, como, por exemplo, as várias zonas “verdes” de centros urbanos incluídas nos polígonos de área edificada (Fig. 4).

Tabela 1 – Comparação entre a área edificada estimada pelo GEE e a do IBGE

Região	Mapa produzido (km ²)	IBGE (km ²)	Diferença (%)
RMG	441,40	646,31	31,70%
RMRJ	1167,28	1463,70	20,25%
RMSP	1842,46	2234,37	17,54%
DF	625,76	641,02	2,38%




Fig. 4. Exemplo de alta inclusão de áreas vegetadas (coloração avermelhada) no interior dos polígonos de área edificada do IBGE (em amarelo) entre os municípios de São Gonçalo/RJ e Niterói/RJ.

4 - CONCLUSÃO

A grande velocidade de processamento, a capacidade de manejar uma enorme quantidade de dados em tempo real e a facilidade de modificação de parâmetros sugere que é possível identificar estruturas urbanas através de computação em nuvem com uma boa precisão, mesmo que existam problemas isolados. Leva-se em média oito minutos para se obter os resultados disponíveis para download e visualmente os dados levam poucos segundos para serem carregados,

possibilitando uma rápida tomada de decisão na escolha dos parâmetros que atendam ao usuário.

O surgimento de plataformas de processamento em nuvem dedicada ao uso e processamento de dados espaciais é uma tendência na área de GIS e talvez em um futuro próximo venha a substituir o uso de *softwares* GIS para *desktop*.

5 - RECOMENDAÇÕES E TRABALHOS FUTUROS

Pensando em dar continuidade a este trabalho e em tirar melhor proveito das ferramentas disponíveis no GEE, os dados utilizados neste trabalho serão inseridos em classificadores disponíveis na plataforma, como por exemplo o Random Forest, como foi utilizado no trabalho de Patel et al. (2014). Outra abordagem a ser testada será a utilização de novos parâmetros visando minimizar os erros apontados por este trabalho, como por exemplo o uso do *Enhanced Built-Up and Bareness Index* (EBBI) proposto por As-syakur et al. (2012) e de dados VIIRS, os quais apresentam resultados superiores aos dados DMSP (Elvidge et al., 2013).

REFERÊNCIAS BIBLIOGRÁFICAS

- Amazon; 2017. Amazon Web Services. Disponível em: <https://aws.amazon.com/pt/what-is-cloud-computing/?nc2=h_l2_cc>. Acesso em: 7 de set. De 2017.
- As-syakur, A.R.; I.W.S. Adnyana, I.W. Arthana e I.W Nuarsa, 2012. Enhanced Built-Up and Bareness Index (EBBI) for Mapping Built-Up and Bare Land in an Urban Area. *Remote Sensing*. Vol 4, pp. 2957-2970.
- Bekele, H.; 2005. Urbanization and Urban Sprawl. (Master thesis) *Royal Institute of Technology*, Sweden.
- Bongaarts, John; 2009. Human Population Growth and the Demographic Transition. *Philosophical Transactions of the Royal Society B: Biological Sciences*, Vol. 364, pp. 2985–2990.
- Elvidge, C.; K. E Baugh, M. Zhizhin e F. Hsu, 2013. Why VIIRS data are superior to DMSP for mapping nighttime lights. *Proceedings of the Asia-Pacific Advanced Network*. Vol. 35. pp. 62-69.
- Gorelick, Noel; Matt Hancher, Mike Dixon, Simon Ilyushchenko, David Thau e Rebecca Moore, 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*. ISSN 0034-4257
- Google; 2017a. DMSP-OLS Nighttime Lights Time Series Version 4. Disponível em: <https://explorer.earthengine.google.com/#detail/NOAA%2FDMSP-OLS%2FNIGHTTIME_LIGHTS>. Acesso em: 20 de jun. de 2017.
- Google; 2017b. Earthengine. Disponível em: <<https://earthengine.google.com/>>. Acesso em: 7 de set. de 2017.

- Google; 2017c. Google Earth Engine – Code Editor. Disponível em: < <https://code.earthengine.google.com/> >. Acesso em: 20 de jun. de 2017.
- Google; 2017d. Hansen Global Forest Change v1.3 (2000-2015). Disponível em: < https://explorer.earthengine.google.com/#detail/UMD%2Fhansen%2Fglobal_forest_change_2015_v1_3 >. Acesso em: 20 de jun. de 2017.
- Google; 2017e. USGS Landsat 8 TOA Reflectance (Orthorectified). Disponível em: < https://explorer.earthengine.google.com/#detail/LANDSAT%2FLC8_L1T_TOA >. Acesso em: 20 de jun. De 2017.
- GES DISC; 2017a. GPM IMERG Final Precipitation L3 1 month 0.1 degree x 0.1 degree V04. Disponível em: < https://disc.gsfc.nasa.gov/datasets/GPM_3IMERGM_V04/summary?keywords=GPM_3IMERGM_004 >. Acesso em: 8 de set. de 2017
- GES DISC; 2017b. TRMM (TMPA/3B43) Rainfall Estimate L3 1 month 0.25 degree x 0.25 degree V7. Disponível em: < https://disc.gsfc.nasa.gov/datasets/TRMM_3B43_V7/summary?keywords=TRMM_3B43_007 >. Acesso em: 8 de set. de 2017
- Jat, M. K.; P. K. Garg e D. Khare; 2008. Monitoring and modelling of urban sprawl using remote sensing and GIS techniques. International Journal of Applied Earth Observation and Geoinformation, Vol.10, Issue 1, pp. 26-43.
- McFeeters, S.K.; 2013. Using the Normalized Difference Water Index (NDWI) within a Geographic Information System to Detect Swimming Pools for Mosquito Abatement: A Practical Approach. Remote Sensing, Vol. 5, pp. 3544-3561.
- Microsoft; 2017. Azure. Disponível em: < <https://azure.microsoft.com/pt-br/overview/what-is-azure/> >. Acesso em: 7 de set. De 2017.
- NASA; 2017. Nebula Cloud Computing Platform. Disponível em: < <https://www.nasa.gov/open/nebula.html> >. Acesso em: 7 de set. De 2017.
- Patel, Nirav N.; Emanuele Angiuli, Paolo Gamba, Andrea Gaughan, Gianni Lisini, Forrest R. Stevens, Andrew J. Tate e Giovanna Trianni, 2015. Multitemporal settlement and population mapping from Landsat using Google Earth Engin. International Journal of Applied Earth Observation and Geoinformation, Vol. 35, Part B, pp. 199-208.
- Rouse, J. W.; R. H. Haas, J. A. Schell, D. W. Deering, 1973. Monitoring vegetation systems in the great plains with ERTS. Earth Resources Technology Satellite - 1 Symposium, 1973. Vol.1, pp.309 – 317.
- Zha, Y.; J. Gao e S. Ni., 2003. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. International Journal of Remote Sensing. Vol 24, pp. 583–594.