

COMPARAÇÃO DE ALGORITIMOS: SOFTWARE COMERCIAL X GOOGLE EARTH ENGINE

Marcos Reis Rosa¹, Bruna Botti Cruz², Cláudia Aparecida Soares Machado³, Alexandre da Costa Pinto³, André Leite Rodrigues³, Doris Jimena Roncancio Benitez⁴, Ismar Andrade², Juliana Marin Pedro⁵, Natalia Gallo Albuquerque³, Thatiany Karlovic de Abreu³, Tito Lopes⁴, José Alberto Quintanilha^{2,3}

¹Programa de Pós-Graduação em Geografia Física – Faculdade de Filosofia, Letras e Ciências Humanas da Universidade de São Paulo – Brasil

²Programa de Pós-Graduação em Ciências Ambientais – Universidade de São Paulo - Brasil

³Programa de Pós-Graduação em Engenharia de Transporte – Escola Politécnica da Universidade de São Paulo – Brasil

⁴Programa de Pós-Graduação em Saúde Pública – Escola de Saúde Pública da Universidade de São Paulo – Brasil

⁵Programa de Pós-Graduação em Ciências Ambientais – Universidade Federal do ABC – São Paulo - Brasil

RESUMO

O objetivo é comparar e analisar as classificações supervisionadas obtidas por meio dos algoritmos de classificação supervisionada Mínima Distância (MD) e Support Vector Machine (SVM) implementados na plataforma *online* do Google Earth Engine (GEE) e no software comercial ENVI[®] em dois tipos de ambientes: paisagem natural, utilizando imagens LANDSAT brutas e pré-processadas e área urbana, utilizando imagens SENTINEL 2A. Os resultados das classificações foram comparados utilizando a matriz de confusão de classes. Na paisagem natural o resultado mostrou que a classificação processada no GEE produziu um mapeamento de uso do solo mais preciso. Adicionalmente, o resultado mostrou que, nesse caso, a imagem pré-processada melhorou o resultado e o algoritmo SVM é mais robusto que o classificador MD. Na área urbana, aplicados em duas áreas, os resultados SVM foram significativamente superiores aos do MD muito similares via as plataformas, o que significa que o GEE é uma ótima opção sem custo para classificação de imagens de satélite.

Palavra-Chave —performance de algoritmos, mínima distância, SVM, uso do solo urbano, paisagem natural

ABSTRACT

The aims are compare and analyze the classifications obtained through the supervised Minimum Distance (MD) and Support Vector Machine (SVM) algorithms of the online platform Google Earth Engine (GEE) and of the conventional software ENVI[®] in two types of areas: landscape region, using raw and pre-processed LANDSAT images, and another urban one, using the SENTINEL images. Classifications were compared using the confusion matrix. In the landscape case, results showed that the GEE platform produced accurate land cover map. In addition, the results indicate that, in this case, image

preprocessing improves classification results and SVM is a more robust classifier than MD. In the urban case, for two different areas, there was a significant difference between the MD classifications produced. The results produced by the SVM were similar, which shows that GEE is a great free option for the classification of satellite images, when using the SVM.

Index Terms— algorithm performance, minimum distance, support vector machine, urban land use, landscape

1. INTRODUÇÃO

A informação da cobertura do solo corresponde a um dos dados espaciais essenciais para muitas aplicações ambientais e urbanas. Essas informações dependem cada vez mais da tecnologia de sensores remotos devido à sua capacidade de medir a superfície terrestre em escalas temporais e espaciais pertinentes [1] e [2]. Uma das principais estratégias para obter informações de cobertura terrestre é a classificação por sensoriamento remoto [3]. Numerosos algoritmos de classificação e ambientes de processamento foram desenvolvidos desde que a primeira imagem LANDSAT foi adquirida no início da década de 1970 [4]. No entanto, cada uma exibe diferentes limitações que devem ser consideradas.

O crescimento urbano desordenado afeta negativamente a qualidade de vida dos moradores urbanos, especialmente no uso do espaço público [5]. Consequentemente, no planejamento do crescimento urbano, o mapeamento da cobertura do solo se torna constante para a atualização da base de dados espacial. Na literatura, os trabalhos visam a assistência à pesquisa em desenvolvimento sustentável e planejamento urbano, elaborando mapas temáticos de cobertura terrestre e uso do solo, como em [6], por exemplo.

Recentemente, as plataformas de computação em nuvem, como o Google Earth Engine (GEE), representam uma nova tendência para a classificação da cobertura do solo. O GEE fornece acesso a cobertura mundial dos satélites MODIS, LANDSAT e outras imagens de outros satélites, o que inclui quase 40 anos de séries históricas LANDSAT [7]. Também disponibiliza um conjunto de "testes confiáveis" para processar o catálogo de imagens e detectar mudanças e tendências para mapear e quantificar as mudanças ocorridas na superfície da Terra [8]. A interface da API GEE (API - Application Program Interface) permite aos usuários acessar, desenvolver e aplicar algoritmos ao conjunto de dados de imagens do Earth Engine inteiro, através da plataforma de computação em nuvem do Google [9], [10] e [11].

Este artigo tem dois objetivos: - apresentar uma avaliação do desempenho da classificação da cobertura do solo da plataforma GEE e do software ENVI®, usando imagens Landsat brutas e pré-processadas e dois classificadores comumente usados; - comparar e analisar a classificação supervisionada realizada pela plataforma GEE e o software ENVI® em duas áreas urbanas diferentes da cidade de São Paulo, bem como a performance de dois algoritmos de classificação. Os algoritmos comparados, em ambos os casos, forma o de Mínima Distância (MD) e o Support Vector Machine (SVM).

2. METODOLOGIA

Para esses estudos, foram desenvolvidos dois experimentos: um em uma área de floresta e outro em duas áreas urbanas do município de São Paulo.

2.1. Região Florestal

A área de estudo está na costa do Brasil, na Mata Atlântica. Foi escolhida porque o uso da terra é bem conhecido, o que facilita coletar amostras de treinamento para a classificação e avaliar os pontos de controle usados para verificar a classificação. A área tem uma boa diversidade de paisagens e de cobertura da terra, contendo área urbana, agricultura, oceano e montanhas cobertas por florestas e rochas. Todas as classificações supervisionadas foram realizadas com base nas mesmas amostras coletadas. Foram delimitadas duas áreas com características semelhantes: uma onde foram coletadas amostras para classificação de toda região e outra onde foram coletados pontos de controle para validação da classificação, como mostrado na Figura 1.




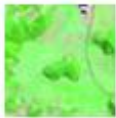

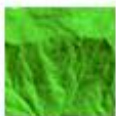




Figura 1. Área de estudo. Identificação de "Área de amostra" e "Área de controle" na imagem Landsat.

Foi utilizada a cena Landsat 8 (OLI), path 218, row 076, obtida em 31 de agosto de 2015, do repositório USGS (United States Geological Survey). As imagens bruta (isto é, C1, Nível 1) e processadas (ou seja, Surface Reflectance - Orthorectified and atmospheric corrected) foram utilizadas na classificação para comparação de desempenho entre a plataforma GEE e o software ENVI®, que exibe algoritmos de classificação supervisionados e não supervisionados implementados nativamente [12]. O GEE pode ser definido como uma plataforma interativa para a observação de superfície [13]. O processamento em tempo real é uma das principais características da plataforma, que também abrange os dados históricos da Landsat desde o seu lançamento. Além disso, o GEE também apresenta ferramentas avançadas para processamento de imagens de satélite [7].

Foram definidas sete classes de cobertura terrestre, de acordo com os dois primeiros níveis da tipologia CORINE [14].

Tabela 1. Classes utilizadas na classificação de acordo com os dois primeiros níveis da tipologia CORINE

Artificial areas		Open spaces with little or no vegetation	
Agricultural areas		Landslide scars	
Forests		Shadow	
Shrubs and/or herbaceous, vegetation associations			

Através da inspeção visual foram coletados 35 polígonos como amostras de treinamento de cada classe nas imagens Landsat. Esse mesmo conjunto de amostras foi utilizado em ambos os softwares de classificação, aplicados nas imagens brutas e pré-processadas. Support Vector Machine (SVM) e Mínima Distância Mahalanobis (MD) foram utilizados para classificação da cobertura do solo.

A precisão da classificação foi avaliada usando os mesmos pontos de controle produzidos utilizando imagens de alta resolução do Google Earth como amostras de verdade terrestre. Foi utilizada uma classificação supervisionada preliminar para distribuir aleatoriamente 100 pontos por classe na área de amostragem. As amostras de controle foram utilizadas para calcular as matrizes de confusão. Os erros gerais de precisão, comissão e omissão foram comparados para cada metodologia.

2.2. Áreas Urbanas

O estudo foi desenvolvido com dados do município de São Paulo, localizado a 23°32'5" de latitude Sul e 46°37'10" de longitude Oeste.

Foram escolhidas duas áreas com níveis de urbanização diferenciados, segundo apresentado na Figura 2. A Área UM (1), de alta densidade urbana, que pertence ao centro expandido da cidade de São Paulo, e a área dois (2) ao sul do município, área de fronteira de crescimento urbano onde ainda existem grandes áreas de conservação de mananciais.

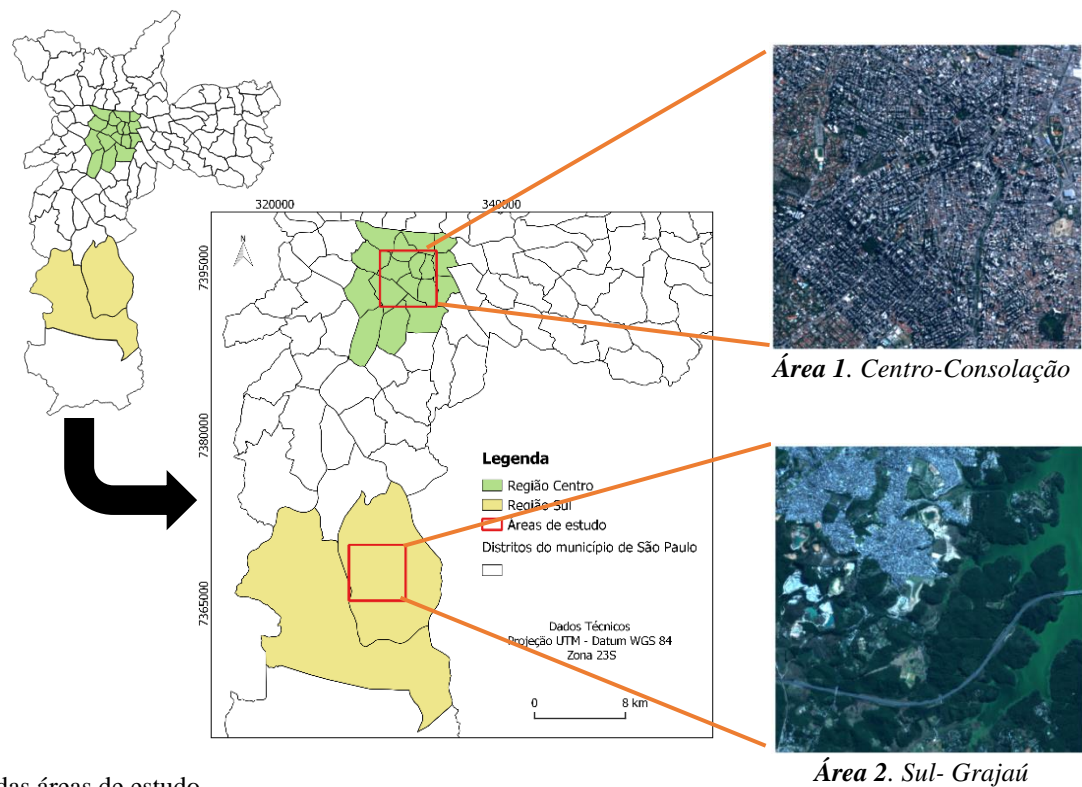


Figura 2. Definição das áreas de estudo.

Foram utilizadas imagens do satélite Sentinel-2, sobre o qual existem poucos estudos sobre o uso destas imagens para monitorar áreas urbanas[15]. A missão Sentinel-2 contém 13 bandas espectrais com uma resolução espacial de 10 m, o que oferece um grande potencial para o mapeamento em escala fina dos assentamentos humanos densos[16].

A imagem selecionada possui classificação 1C, na qual se inclui correções radiométricas e geométricas, incluindo orto-retificação e registro espacial. A data de toma da imagem escolhida foi 4 de julho de 2016 e a imagem foi descarregada do site pode ser encontrada tanto no site da Sentinel web browser no Amazon Web Services (<http://sentinel-pds.s3-website.eu-central-1.amazonaws.com/browser.html>), quanto na biblioteca de imagens Sentinel presente no Google Earth Engine. Apenas as bandas com resolução espectral de 10 metros foram utilizadas (azul, verde, vermelho e infravermelho próximo).

Com o objetivo de realizar a comparação dos resultados obtidos da classificação supervisionada das imagens de satélite da área urbana escolhida, foi planejado um experimento de comparação simples [17] no qual foram avaliados os efeitos de dois (2) fatores (algoritmo de classificação e nível de urbanização) para os dois softwares, sobre o mapa de classificação de áreas urbanas.

Foram utilizadas quatro (4) classes do sistema CORINE para gerar a classificação da imagem Sentinel escolhida. Foi preciso gerar uma classe adicional para identificar a sombra gerada pelas infraestruturas urbanas, origem de erros de classificação. Assim, as cinco (5) classe finais definidas foram 'Água', 'Solo Exposto', 'Sombra', 'Tecido urbano' e 'Vegetação'

No software ENVI foram realizadas duas classificações da imagem Sentinel 2 escolhida para cada área, utilizando dois algoritmos de classificação diferentes: SVM e Mínima Distância (MD). Na classificação

efetuada utilizando MD foi usada a opção Mahalanobis. Já na classificação do SVM o tipo de Kernel utilizado foi o Linear.

Por outro lado, no software GEE foi implementado um roteiro de processos utilizando a linguagem *Java Script*. A primeira instrução foi buscar na biblioteca do GEE a imagem Sentinel 2 previamente escolhida para cada área. Foi utilizada uma única cena sem mosaico e sem tratamento para realizar o processamento da imagem.

As amostras descritas no item a), foram convertidas ao formato Keyhole Markup Language (KML) e exportadas para um espaço na nuvem utilizando o *Google Fusion Table*. Esse processo serviu para conduzir a busca das amostras no GEE. Ainda utilizando o *Google Fusion Table*, foram inseridos os limites das áreas de classificação. Os resultados da classificação final foram exportados no formato Geotiff e armazenados no Google Drive.

3. RESULTADOS

3.1. Região Florestal

Uma comparação simples, observável nas figuras 3 e 4, mostra que as classificações de cobertura do solo exibiram variação em termos do classificador, imagem e ambiente de processamento aplicados. A classificação de cobertura do solo mais precisa foi obtida usando o classificador SVM com imagens pré-processadas LANDSAT na plataforma GEE (90,9 de precisão geral e 0,89 índice kappa), como mostram os resultados exibidos nas tabelas 2 e 3.

A confusão observada entre arbustos e / ou associações herbáceas / vegetais, espaços abertos com pouca ou nenhuma vegetação, áreas agrícolas e classificação de corpos d'água podem estar associadas a semelhanças espectrais entre classes de cobertura de terra, juntamente com dificuldades de amostragem nas áreas de treinamento, desencadeadas pela interpretação visual .

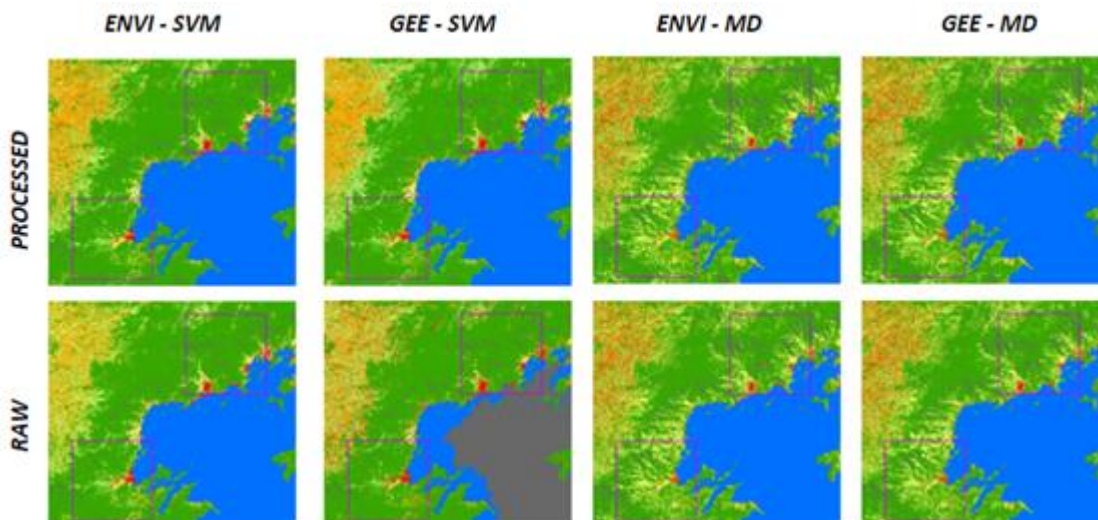


Figura 3. Resultados da classificação da cobertura terrestre para imagens Landsat brutas e pré-processadas da área de treinamento.

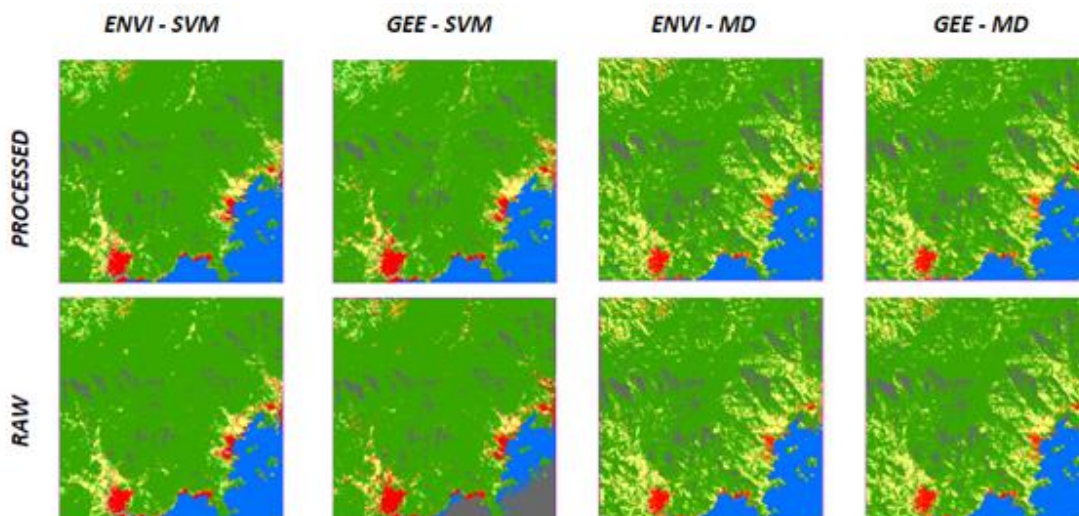


Figura 4. Resultados detalhados da classificação da cobertura do solo para imagens Landsat bruta e pré-processada da área de controle.

Foram observadas diferenças entre as imagens utilizadas. Nas imagens pré-processadas os classificadores apresentaram melhor desempenho do que nas imagens brutos em todas as abordagens metodológicas. Esse padrão pode ser creditado ao fato de que as imagens brutas geralmente contêm um conjunto de degradações radiométricas devido ao ajuste da calibração do sensor, erros esporádicos de transmissão de dados, interferência atmosférica e distorções geométricas [18]. Essas imperfeições podem resultar em resultados inadequados e produtos derivados da imagem, se não forem resolvidos. Portanto, os resultados obtidos através de imagens pré-processadas, reforçam a importância do processamento geométrico de imagens de sensoriamento remoto para superar possíveis fontes de erros e melhorar a classificação da cobertura terrestre [1] 1, [18].

Os resultados mostram que as classificações geradas pelo aplicativo SVM apresentaram maior precisão do que o classificador de MD (Tabela 2 e 3).

Tabela 2. Resultados da Exatidão Global de acordo com o ambiente de processamento, classificador e imagem utilizados

Platform	GEE		ENVI	
Image	raw	preprocessed	raw	preprocessed
MD	64.9%	70.6%	62.4%	63.1%
SVM	69.9%	90.9%	72.1%	74.6%

Tabela 3. Resultados do índice Kappa de acordo com o ambiente de processamento, classificador e imagem utilizados

Platform	GEE		ENVI	
Image	raw	preprocessed	raw	preprocessed
MD	0.59	0.65	0.56	0.63
SVM	0.64	0.89	0.67	0.7

Finalmente, o ambiente de processamento também provocou variação nos resultados da classificação. As classificações derivadas de GEE exibiram valores de precisão global e índice de kappa superior aos daqueles realizados no software ENVI®. Isso pode ser um resultado da implementação do algoritmo classificador intrínseco a cada ambiente de processamento, por exemplo, a complexidade computacional empregada.

3.2. Áreas Urbanas

3.2.1 Classificação com Mínima Distância Mahalanobis

A Figura 5 mostra os mapas de classificação obtidos para o classificador Mínima Distância nos softwares ENVI e Google Earth Engine (GEE) na área 1 (Centro). Nas duas classificações realizadas as classes com maior presença são ‘Tecido Urbano’, ‘Vegetação’ e ‘Sombra’. No entanto, existe uma variação importante na proporção da cobertura apresentada. Esta variação é claramente refletida na concordância das classificações realizadas pelos softwares que é apenas de 36%. De tal modo, que com este valor é esperada uma diferença expressiva dos mapas exibidos na **figura 5**.

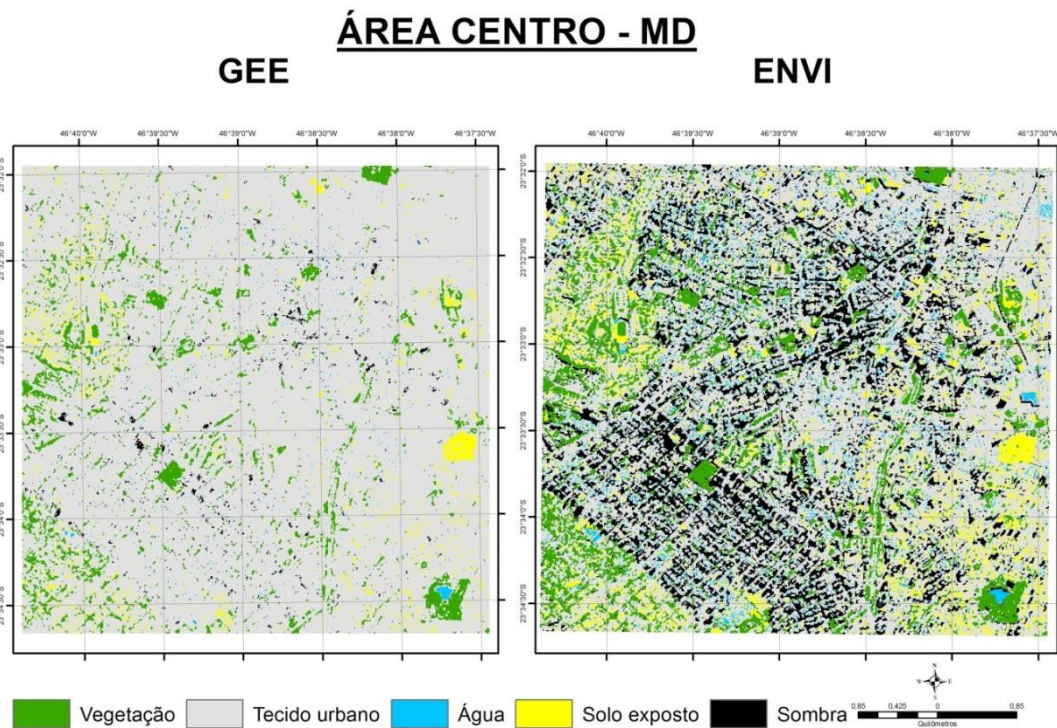


Figura 5. Mapas de classes gerados pelo classificador MD nos softwares ENVI e GEE para a área centro.

Esta diferença pode ser atribuída a alguma disparidade na implementação dos algoritmos de mínima distância mahalanobis entre os softwares utilizados ou à qualidade das amostras utilizadas, uma vez que a parametrização do algoritmo e as amostras utilizadas como referência foram iguais para os dois softwares.

Na região sul existem disparidades grandes apenas na classes ‘Solo exposto’, onde a acurácia é maior na classificação obtida com o GEE. Quanto aos erros de comissão, eles são destacados na classe ‘Solo exposto’, ‘Sombra’ e ‘Vegetação’. Estas observações apontam ao grande problema que apresenta a identificação e classificação do solo exposto nas áreas avaliadas, que é perceptível nos mapas da figura 6. Contudo, a concordância dos resultados dos softwares alcançou o 69%.

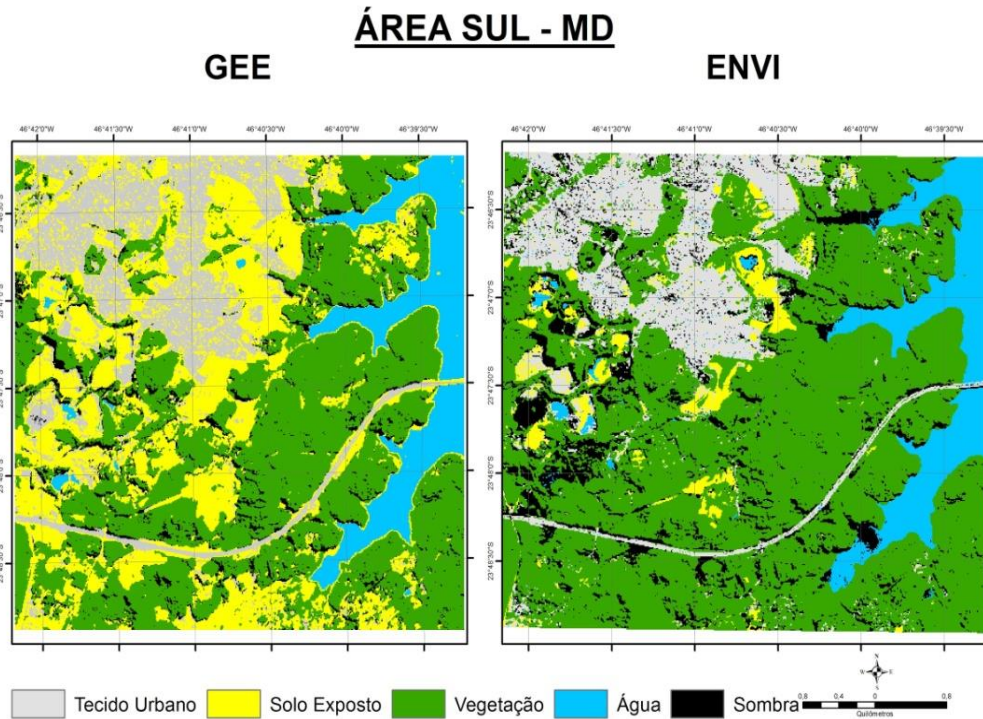


Figura 6. Mapas de classes gerados pelo classificador MD nos softwares ENVI e GEE na área sul.

3.2.2 Classificação realizada com Support Vector Machine (SVM)

A Figura 7 apresenta o resultado da classificação utilizando o SVM. Existe uma diferença pequena nas acurácias totais obtidas, sendo que a maior é a apresentada pelo ENVI (73,4%) com uma diferença de apenas 3,4% frente à obtida com o GEE (70%).

Os maiores erros de comissão são observados para a classe ‘Solo exposto’ tanto no ENVI (81%), quanto no GEE (82%). Os maiores erros de omissão se apresentaram na classe ‘Sombra’ com valores similares para o ENVI (86,5%) e o GEE (92%), a classe Vegetação (ENVI=55%, GEE=69%) e a classe ‘Solo exposto’ (ENVI=45,5%, GEE=36%). Para o software ENVI foi encontrado um erro de omissão significativo na classe ‘Água’ (50%).

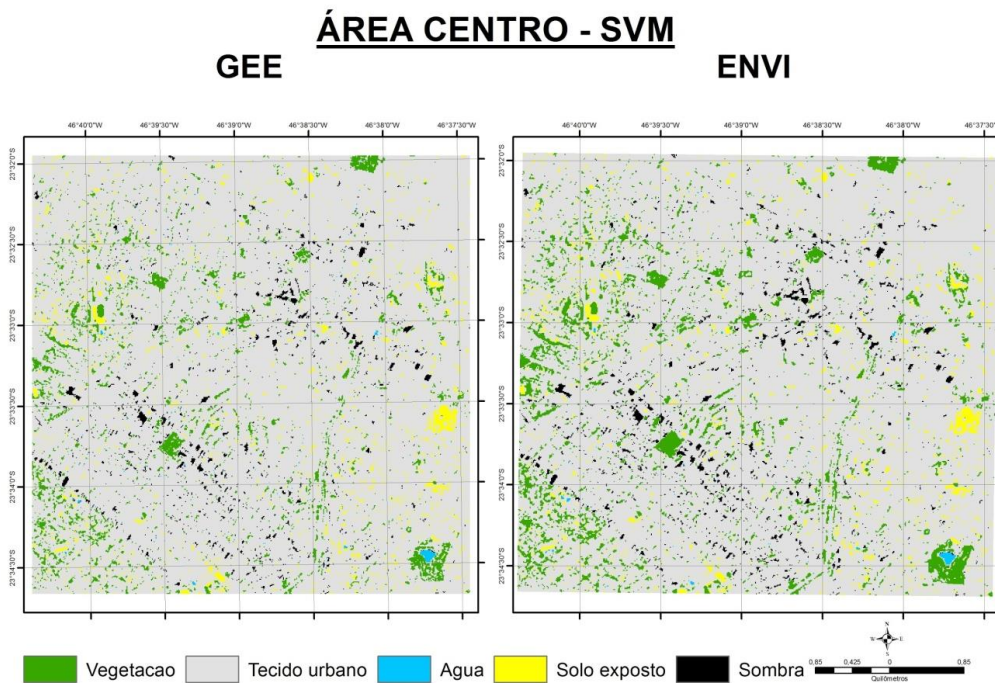


Figura 7. Mapas de classes gerados pelo classificador SVM nos softwares ENVI e GEE para a área centro.

De maneira similar, a concordância entre softwares obtida para as classificações realizadas na área sul utilizando o algoritmo de classificação SVM foi de 88%. Assim, os resultados obtidos da classificação realizada com os softwares avaliados, não apresentam resultados contrastantes nos mapas da **figura 8**.

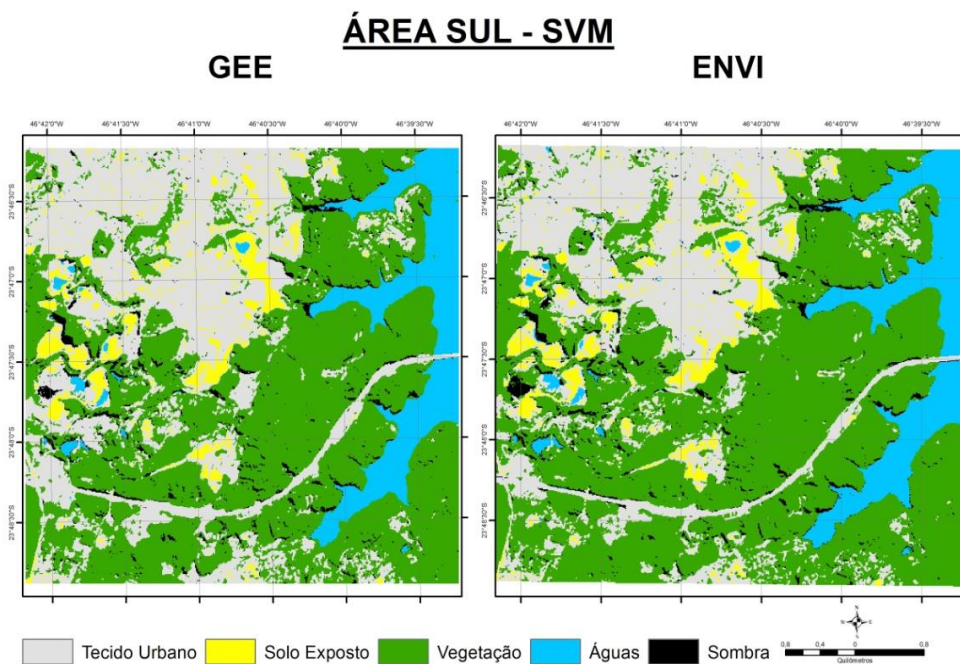


Figura 8. Mapas de classes gerados pelo classificador SVM nos softwares ENVI e GEE para a área sul.

4. CONCLUSÃO

Os resultados comprovaram o potencial substancial que o Google Earth Engine oferece na análise de dados de sensoriamento remoto, especialmente quando comparado ao software comercial utilizado, como o ENVI®, no contexto das imagens e outras condições de uso. O algoritmo de classificação implementado no GEE teve resultados iguais ou melhores e funciona em um software que é gratuito para uso e pesquisa e possui excelentes capacidades de processamento e acesso direto ao catálogo LANDSAT e SENTINEL.

Além disso, os resultados indicam que as imagens pré-processadas melhoram os resultados da classificação e o SVM é um classificador mais robusto, que o MD. O algoritmo de mínima distância não é um bom classificador para realizar mapeamento de paisagens altamente heterogêneas, como as áreas urbanas avaliadas. No entanto, dentro da comparação realizada, não se esperava encontrar valores de precisão total dramaticamente diferentes conforme apresentado nos resultados do teste, considerando que as amostras utilizadas eram as mesmas. Portanto, recomenda-se realizar outros testes que permitam avaliar se existe uma diferença entre os algoritmos utilizados pelos dois softwares / plataformas ou se as diferenças encontradas podem ser atribuídas à qualidade das amostras utilizadas e / ou a classificação utilizada parâmetros.

Não foram encontradas diferenças significativas nos mapas obtidos com o classificador SVM nas ferramentas usadas. Assim, de acordo com os resultados obtidos, este algoritmo de classificação foi uma ferramenta eficiente para o mapeamento das áreas avaliadas. No entanto, é importante notar que houve problemas de identificação e classificação para classes Urbana e Solo. Deve-se ter em mente que a classificação de áreas com grandes heterogeneidades pode se beneficiar do uso de informações de contexto e outros produtos de sensoriamento remoto para obter mapas de classificação de qualidade superior.

O Google Earth Engine mostrou ser uma poderosa ferramenta de classificação, uma vez que os mapas resultantes alcançaram alta precisão qualidade comparável e / ou superior ao software ENVI®, que já é uma ferramenta reconhecida.

5. AGRADECIMENTOS

Os Autores agradecem o Programa de Pós Graduação em Engenharia de Transportes da Escola Politécnica da Universidade de São Paulo - Brasil para a oportunidade de pesquisa e para o Conselho Brasileiro de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio aos bolsistas.

6. REFERÊNCIAS BIBLIOGRÁFICAS

[1] Jensen, J. R., *Introductory digital image processing: a remote sensing perspective*. Univ. of South Carolina, Columbus. 1986

[2] Sellers, P. J., Meeson, B. W., Hall, F. G., Asrar, G., Murphy, R. E., Schiffer, R. A., Bretherton, F. P., “Remote sensing of the land surface for studies of global change: models—algorithms—experiments”. *Remote Sensing of Environment*, 51, 3–26, 1995.

[3] Huang, C., Davis, L.S., Townshend, J.R.G., “An assessment of support vector machines for land cover classification”. *International Journal of Remote Sensing*, 23(4), pp.725-749, 2002.

- [4] Hall, F. G., Townshend, J. R., Engman, E. T., “Status of remote sensing algorithms for estimation of land surface state parameters”. *Remote Sensing of Environment*, 51, 138–156, 1995.
- [5] Din, S. El, Shalaby, A., Farouh, H. E., Elariane, S. A. “Principles of urban quality of life for a neighborhood”. *HBRC Journal*, 9(1), 86–92. 2013.
- [6] Megahed, Y.; Cabral, P.; Silva, J.; Caetano, M. “Land cover mapping analysis and urban growth modelling using remote sensing techniques in greater Cairo region—Egypt”. *ISPRS Int. J. Geo-Inf.*, 4, 1750–1769, 2015.
- [7] Patel, N. N., Angiuli, E., Gamba, P., Gaughan, A., Lisini, G., Stevens, F. R., Trianni, G., “Multitemporal settlement and population mapping from Landsat using Google Earth Engine”. *International Journal of Applied Earth Observation and Geoinformation*, 35, 199-208, 2015.
- [8] GOOGLE EARTH ENGINE API. Guide. Available in:
<<https://developers.google.com/earth-engine/>>. Accessed: Oct. 27, 2016.
- [9] Erickson, T., “Multi-source geospatial data analysis with Google Earth Engine”. American Geophysical Union, *Proceedings*, Fall Meeting, 2014.
- [10] Hancher, M., “Planetary-scale geospatial data analysis techniques in Google's Earth Engine platform”. American Geophysical Union, *Proceedings*, Fall Meeting, 2013.
- [11] Hansen, M. C., Potapov, P. V., Moore, R., Hancher, M., Turubanova, S. A., Tyukavina, A., Kommareddy, A., Egorov, A., Chini, L., Justice, C.O., Townshend, J.R.G. “High-resolution global maps of 21st-century forest cover change”. *Science*, 342(6160), 850-853, 2013.
- [12] EXELIS *Visual Information Solutions*. ENVI v. 4.8. Boulder, Colorado, 2010.
- [13] Molthan, A.; Burks, J.; Bell, J., “Interactive Computing and Processing of NASA Land Surface Observations using Google Earth Engine”. *Slides* from 32nd Conference on Environmental Information on Processing Technologies (EIPT), New Orleans, LA. 2016.
- [14] Bossard, M.; Feranec, J.; Otahel, J. *CORINE, Land cover technical guide – Addendum 2000*. European Environment Agency, 2000.
- [15] Lefebvre, A.; Sannier, C.; Corpetti, T. “Monitoring Urban Areas with Sentinel-2A Data: Application to the Update of the Copernicus High Resolution Layer Imperviousness Degree”. *Remote Sensing*, [s.l.], v. 8, n. 7, p.606-627, 19 jul. 2016. MDPI AG. <http://dx.doi.org/10.3390/rs8070606>.
- [16] 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*, [s.l.], v. 8, n. 4, p. 299-317, 1 abr. 2016. MDPI AG. <http://dx.doi.org/10.3390/rs8040299>.

[17] Montgomery, D.C., *Design and Analysis of Experiments*, 4th ed., John Wiley and Sons, New York. 1997.

[18] Toutin, T., "Review article: Geometric processing of remote sensing images: models, algorithms and methods". *International Journal of Remote Sensing*, 25(10), pp.1893-1924, 2004.