

FUSÃO DE DADOS: NOVA TENDÊNCIA EM PROCESSAMENTO DIGITAL DE IMAGENS

Camila Souza dos Anjos¹, Marielcio Gonçalves Lacerda², Leidiane do Livramento Andrade², Roberto Neves Salles², Claudia Maria de Almeida³

¹Instituto Federal de Educação Ciência e Tecnologia do Sul de Minas Gerais - Campus Inconfidentes
Praça Tiradentes, 416 – 37576-000 – Inconfidentes - MG, Brasil
camila.lacerda@ifsuldeminas.edu.br

²Instituto de Estudos Avançados - Força Aérea Brasileira
Caixa Postal 6044 – 12.231-970 – São José dos Campos - SP, Brasil
{leidiane.andrade; marielcio; salles}@ieav.cta.br

³Instituto Nacional de Pesquisas Espaciais,
Av. dos Astronautas, 1758, 12227-010 São José dos Campos - SP, Brasil
almeida@dsr.inpe.br

RESUMO

O termo Fusão de Dados (*Data Fusion*) tem obtido cada vez mais destaque na literatura internacional de sensoriamento remoto. Entretanto, no Brasil o conceito é raramente empregado e quando utilizado é confundido com a chamada fusão de resoluções espaciais tratada na literatura internacional como *Resolution Merge* ou *Pan-sharpening*. O presente artigo visa impulsionar o uso do termo Fusão de Dados no Brasil e traz como estudo de caso uma pesquisa realizada pelo Instituto de Estudos Avançados da Força Aérea Brasileira. Tal estudo foi premiado no maior concurso internacional de sensoriamento remoto, o *Data Fusion Contest* no ano de 2017. O concurso é realizado anualmente pela IEEE Geoscience Remote Sensing Society (GRSS) e em 2017 contou com a participação de pesquisadores de cinquenta países.

Palavras-chave — Fusão de Dados, Concurso Internacional de Fusão de Dados, Sociedade de Geociências e Sensoriamento Remoto.

ABSTRACT

The term Data Fusion is widely used in the international literature of remote sensing. However, in Brazil the concept is rarely employed and when used it is confused with the fusion of spatial resolutions called in the international literature as Resolution Merge or Pan-sharpening. This paper aims to boost the use of the term Data Fusion in Brazil and brings as a case study a research conducted by Institute of Advanced Studies of the Brazilian Air Force that was awarded in the international competition, the Data Fusion Contest in the year of 2017. The competition is performed annually by the IEEE Geoscience Remote Sensing Society (GRSS) and in 2017 was attended by researchers from fifty countries.

Key words — *Data Fusion, Data Fusion Contest, Geoscience Remote Sensing Society.*

1. INTRODUÇÃO

A grande disponibilidade de dados atual tem motivado o uso conjunto de múltiplas fontes de dados para a análise de uma área específica. A utilização de dados provenientes de diferentes fontes integrados em uma mesma abordagem investigativa é chamada de Fusão de Dados (*Data Fusion*) e tem sido utilizada em diferentes aplicações. Entretanto, o conceito é raramente empregado no Brasil e quando utilizado é confundido com a chamada fusão de resoluções espaciais tratada na literatura internacional como *Resolution Merge* ou *Pan-sharpening*.

De acordo com [1], as observações derivadas de diferentes fontes de aquisição podem ser acopladas e analisadas conjuntamente para se obter uma descrição mais rica da cena, ou seja, uma caracterização detalhada e precisa dos alvos.

A possibilidade de combinar dados multiespectrais, hiperespectrais, LIDAR e/ou SAR com diferentes resoluções espaciais, fornece uma oportunidade única para caracterizar em profundidade os mais diversos materiais presentes na superfície da Terra.

Os avanços contínuos dos sensores remotos estimulam os pesquisadores a desenvolver novos métodos de processamento de imagens cada vez mais robustos e capazes de lidar com quantidades volumosas de dados de entrada. Os métodos de classificação de imagens tem evoluído continuamente, assim como os sistemas sensores. Para tal finalidade, [2] propõe o uso de técnicas de aprendizagem de máquina, como árvores de decisão e redes neurais, aprendizado profundo (*Deep Learning*) e máquinas de vetores de suporte (*Support Vector Machine - SVM*).

A classificação de imagens por sensoriamento remoto explorando múltiplos sensores é um problema muito desafiador pois engloba conjuntos de dados afetados por diferentes distorções espectrais, não são co-registrados e são adquiridos sob diferentes condições atmosféricas e de iluminação [3]. Entretanto, inúmeros casos de sucesso no uso de Fusão de Dados são encontrados na literatura [4], [5] e [6].

2. O CONCURSO DATA FUSION CONTEST

O concurso *Data Fusion Contest* (DFC) ocorre anualmente desde 2006. Ele é promovido pela IEEE *Geoscience and Remote Sensing Society*. A cada ano um novo conjunto de dados provenientes de diversos sensores é disponibilizado aos participantes e um problema é apresentado com um tempo médio de 3 semanas para ser solucionado. Os quatro primeiros colocados no concurso são convidados a participarem do IGARSS (IEEE *International Geoscience and Remote Sensing Symposium*) onde apresentam, em uma sessão especial do evento, a metodologia estabelecida.

No ano de 2017 o tema do concurso foi “*Open Data for Global Multimodal Land Use Classification*” [7]. Foram disponibilizados dados multiespectrais Landsat-8 (30m) e Sentinel-2 (100m) para a classificação de Zonas Climáticas Locais (LCZ) [8] em quatro cidades ao redor do mundo: Amsterdam/Holanda, Chicago/Estados Unidos da América, Madrid/Espanha e Xi’An/China.

De acordo com [9] para este mesmo ano foram realizadas 856 submissões provenientes de grupos de pesquisa de 50 países. A distribuição percentual das equipes entre os países é apresentada na Figura 1. Destaca-se que apenas 3% das submissões foram realizadas por equipes do Brasil.




Figura 1. Distribuição percentual dos países participantes do DFC. Fonte: [9].

Os algoritmos mais utilizados pelos participantes foram: *Deep Learning*; *Extreme Gradient Boosting*; Fusão de múltiplos classificadores e *Random Forest* [9].

O grupo vencedor foi formado por pesquisadores da Universidade de Tokyo e Centro Aeroespacial Alemão (DLR) obtendo uma acurácia global de 74.9% [10]. A segunda colocação foi obtida por pesquisadores da AGT International (Suiça), com acurácia global de 72.6% [11]. A terceira colocação foi obtida pelo grupo de pesquisadores da Força Aérea Brasileira com acurácia global de 72.4% [12]. E a quarta colocação foi obtida por pesquisadores das

Universidades de Hong Kong and Xi’an com acurácia global de 69.9% [13].

3. ESTUDO DE CASO

3.1. Materiais e Métodos

Cidades podem ser descritas com base em Zonas Climáticas Locais (LCZ’s) [8], que representam uma descrição genérica das paisagens naturais e urbanas em categorias baseadas em propriedades de superfície relevantes para o clima.

Utilizando um conjunto de dados Landsat-8 e Sentinel-2 para cada uma das áreas de estudo foram rotuladas 10 LCZ’s urbanas e 7 LCZ’s rurais, resultando em 17 classes (Figura 2).

Zonas Climáticas Locais Urbanas	LCZ	Exemplo	Zonas Climáticas Locais Rurais	LCZ	Exemplo
	1	Prédios Altos Compactos		11 A	Árvores Densas
	2	Prédios Médios Compactos		12 B	Árvores Esparsas
	3	Prédios Baixos Compactos		13 C	Arbustos
	4	Prédios Altos Abertos		14 D	Vegetação Rasteira
	5	Prédios Médios Abertos		15 E	Rocha e Pavimentação
	6	Prédios Médios Abertos		16 F	Solo Exposto
	7	Favela		17 G	Água
	8	Prédios Baixos e Largos			
	9	Construções Esparsas			
	10	Indústria			

Figura 2. Zonas de Clima Local e Legenda de Classes.

A metodologia utilizada para a classificação das cenas é apresentada na Figura 3.

Todas as imagens foram reamostradas para 100m de resolução espacial e para cada conjunto individual de dados foram gerados atributos baseados em transformações espectrais e razões de bandas.




Figura 3. Metodologia utilizada na pesquisa.

A segmentação das imagens e a coleta de amostras foi realizada no *software* eCognition 8.7. As classificações dos dados foram geradas no *software* Weka 3.7 por meio do classificador *Random Forest*. Os resultados finais foram visualizados no formato shapefile por meio do *software* QGIS 2.12.3.

A validação dos resultados foi realizada pela equipe avaliadora do DFC.

Informações detalhadas sobre a metodologia são encontradas em [12].

3.2. Resultados e Discussão

Os resultados visuais das quatro classificações obtidas pelo presente estudo são apresentados na Figura 4.




Figura 4. Resultado das classificações para Amsterdam (a), Chicago (b), Madrid (c) e Xi'an (d).

As classificações foram submetidas ao DFC e como resultado obteve-se uma acurácia global de 72,38% e índice Kappa de 0,68. Tais valores equivalem a valores médios para as quatro classificações. Uma única matriz de confusão foi disponibilizada pela organização do concurso, que também equivale a média ponderada por área para as quatro classificações.

Para facilitar a interpretação dos resultados e analisar quais classes obtiveram uma maior ou menor taxa de acerto foi criada uma nova matriz onde os percentuais de acerto ou

erro são representados por círculos proporcionais ao acerto para aqueles círculos que estão na diagonal principal, ou confusões, para os círculos que estão em outro lugar da matriz (Figura. 5). As cores utilizadas são as mesmas que representam as classes LCZs.

A classe C13C (Arbustos) foi 68,1% erroneamente classificada como C14D (Vegetação Rasteira); C3 (Prédios Baixos Compactos) foi 48% erroneamente classificada como C6 (Prédios Baixos Abertos); C15 (Rocha e Pavimentação) foi 44,7% erroneamente classificada como C8 (Prédios Baixos e Largos); e C5 (Prédios Médios Abertos) foi 42,8% erroneamente classificada como C6 (Prédios Baixos Abertos).

A confusão entre Arbustos e Vegetação Rasteira é compreensível, pois ambas as classes contêm solo e vegetação. As dificuldades remanescentes estavam na separação das classes urbanas, porque diferentes LCZs possuem os mesmos materiais, mas não na mesma altura, tendo assinaturas espectrais semelhantes, como o caso das classes Prédios Médios Abertos e Prédios Baixos Abertos.




Figura 5. Análise percentual da matriz de confusão.

4. CONCLUSÕES

Apesar do termo Fusão de Dados ser amplamente utilizado na literatura internacional, no Brasil ele ainda é uma novidade que está se tornando tendência haja vista que trabalhos que utilizam a prática tem alcançado percentuais superiores de acerto do que aqueles que utilizam dados provenientes de um único sensor.

Frequentemente acredita-se que um único sensor de altíssima resolução espacial ou hiperespectral é suficiente

para caracterizar os objetos de interesse. Entretanto inserir no processo de fusão de dados dados provenientes de sensores com características inferiores as do sensor principal pode melhorar o desempenho da análise. Isso pode ser explicado pelo fato de que os métodos de classificação atuais atuam como mineradores de dados e são capazes de lidar com massiva quantidade de dados de entrada, bem como com variáveis explanatórias fracas [14].

O concurso DFC disponibiliza os dados anualmente no mês de janeiro, sugere-se aos leitores que participem das próximas edições para fortalecer a qualificação do Brasil junto a comunidade acadêmica internacional de Sensoriamento Remoto.

5. AGRADECIMENTOS

Os autores gostariam de agradecer as iniciativas WUDAPT (<http://www.wudapt.org/>) e GeoWIKI (<http://geo-wiki.org/>) por fornecer os pacotes de dados usados neste estudo e o IEEE GRSS *Image Analysis and Data Fusion Technical Committee*. Dados Landsat 8 disponíveis em *U.S. Geological Survey* (<https://www.usgs.gov/>). Dados Copernicus Sentinel disponíveis em *European Space Agency* (<https://sentinel.esa.int>).

6. REFERÊNCIAS

- [1] Dalla Mura M.; Prasad, S.; Pacifici, F.; Gamba, P.; Chanussot, J.; Benediktsson, J. A. "Challenges and Opportunities of Multimodality and Data Fusion in Remote Sensing." *Proc. IEEE Geoscience and Remote Sensing Society*, vol. 103, no. 9, pp. 1585-1601, 2015.
- [2] Qiao, T.; Yang, Z.; Ren, J.; Yuen, P.; Zhao, H.; Sun, G.; Marshall, S.; Benediktsson, J. A. "Joint Bilateral Filtering and spectral similarity-based sparse representation: a generic framework for effective feature extraction and data classification in hyperspectral imaging". *Pattern Recognition*, 2017. DOI: 10.1016/j.patcog.2017.10.008.
- [3] Tuia, D.; Marcos, D.; Camps-Valls, G. "Multi-temporal and multi-source remote sensing image classification by nonlinear relative normalization", *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 120, pp. 1-12, 2016.
- [4] Ortiz, A.; Rosario, D.; Fuentes, O.; Blair, S. "Image-based 3D model and hyperspectral data fusion for improved scene understanding." *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Fort Worth, TX, pp. 4020-4023, 2017. DOI: 10.1109/IGARSS.2017.8127882.
- [5] Kussul, N.; Lavreniuk, M.; Skakun S.; Shelestov, A. "Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data," *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 5, pp. 778-782, 2017. DOI: 10.1109/LGRS.2017.2681128
- [6] Joshi, N.; Baumann, M.; Ehammer, A.; Fensholt, R.; Grogan, K.; Hostert, P.; Jepsen, M. R.; Kuemmerle, T.; Meyfroidt, P.; Mitchard, E.T.A.; Reiche, J.; Ryan, C. M. and Waske, B. "A Review of the Application of Optical and Radar Remote Sensing Data Fusion to Land Use Mapping and Monitoring", *Remote Sensing*, vol. 8, no. 1, 2016. DOI: 10.3390/rs8010070.
- [7] IEEE Geoscience Remote Sensing Society. "2017 IEEE GRSS Data Fusion Contest" <<http://www.grss-ieee.org/2017-ieee-grss-data-fusion-contest/>>
- [8] Stewart, I.D.; Oke, T.R. "Local climate zones for urban temperature studies", *Bulletin of the American Meteorological Society*, vol. 93, no. 12, pp.1879-1900, 2012.
- [9] Tuia, D.; Moser, G.; Le Saux, B.; Bechtel, B.; See, L. "2017 IEEE GRSS Data Fusion Contest: Open Data for Global Multimodal Land Use Classification". *IEEE Geoscience and Remote Sensing Magazine*. pp.110-114. December 2017. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8113125>>
- [10] Yokoya, N.; Ghamisi, P.; Xia, J. "Multimodal, multitemporal, and multisource global data fusion for local climate zones classification based on ensemble learning," In: *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Fort Worth, TX, pp. 1197-1200. 2017. DOI: 10.1109/IGARSS.2017.8127172. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8127172&isnumber=8126808>>.
- [11] Sukhanov, S.; Tankoyeu, I.; Louradour, J.; Heremans, R.; Trofimova, D.; Debes, C. "Multilevel ensembling for local climate zones classification" In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Fort Worth, TX, USA, pp. 1201-1204. 2017.
- [12] Anjos, C. S.; Lacerda, M. G.; Andrade, L. L.; Salles, R. N. "Classification of urban environments using feature extraction and random forest," In: *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Fort Worth, TX, pp. 1205-1208. 2017. DOI: 10.1109/IGARSS.2017.8127174. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8127174&isnumber=8126808>>.
- [13] Xu, Y.; Ma, F.; Meng, D.; Ren, C.; Leung, Y. "A co-training approach to the classification of local climate zones with multi-source data," *2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Fort Worth, TX, pp. 1209-1212. 2017. DOI: 10.1109/IGARSS.2017.8127175. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8127175&isnumber=8126808>>.
- [14] Walton, J. T. "Subpixel urban land cover estimation: comparing cubist, random forests, and support vector regression". *Photogrammetric Engineering and Remote Sensing*, vol. 74, no. 10, p. 1213-1222. 2008.