

Identificação de Bancos de Areia Situados na Região da Baía do Guajará Mediante Redes Neurais Convolucionais Profundas e Imagens de Radar de Abertura Sintética (SAR)

José A. S. Sá¹, Fábio F. Gama², Gilberto R. Queiroz²,
Lúbia Vinhas², Brígida R. P. Rocha³

¹Departamento de Ciências Sociais Aplicadas – Universidade do Estado do Pará (UEPA)
Tv. Doutor Enéas Pinheiro, 2626 – 66095-015 – Belém – PA – Brasil

²Instituto Nacional de Pesquisas Espaciais (INPE)
Av. dos Astronautas, 1758 – 12227-010 – São José dos Campos – SP – Brasil

³Centro Gestor e Operacional do Sistema de Proteção da Amazônia (CENSIPAM)
Av. Júlio César, 7060 – 66617-420 – Belém – PA – Brasil

josealbertosa@uepa.br,
{fabio.furlan,gilberto.queiroz,lubia.vinhas}@inpe.br,
rocha.brigida@sipam.gov.br

Abstract. Sandbanks represent a danger to river and sea navigation due to the significant damage they can cause to ships, crews and passengers. This work aimed to develop a methodology for the automatic identification of sandbanks located in an Amazonian estuarine region (Baía do Guajará) using synthetic aperture radar (SAR) image and deep convolutional neural networks (Deep Learning) in order to assist the obstacles monitoring in the local navigation. The results demonstrated significant differences in the use of the SAR polarization for the monitoring of the sandbanks, as well as elevated accuracy (99,6%) for automatic identification through the convolutional neural network.

Resumo. Bancos de areia representam um perigo à navegação fluvial e marítima devido aos danos significativos que podem gerar para as embarcações, tripulações e passageiros. Este trabalho buscou desenvolver uma metodologia para a identificação automática de bancos de areia situados em uma região estuarina Amazônica (Baía do Guajará) mediante imagem de radar de abertura sintética (SAR) e redes neurais convolucionais profundas (Deep Learning) no intuito de auxiliar o monitoramento da evolução destes obstáculos à navegação local. Os resultados demonstraram diferenças relevantes no uso das polarizações SAR para o monitoramento de bancos de areia, além de acurácia igual a 99,6% para a identificação automática.

1. Introdução

Um banco de areia consiste no acúmulo de sedimentos (areia e cascalho) depositados no leito de um rio ou ao longo da costa marítima, constituindo-se em um obstáculo ao escoamento e à navegação. Nos rios, os bancos são formados pelos depósitos de aluvião e nas praias eles podem se formados pelo fluxo e refluxo do mar ou pela ação das ondas. Os bancos de areia constituem-se em um perigo à navegação (fluvial e marítima), podendo gerar danos e naufrágios as embarcações.

Na região amazônica, a malha fluvial constitui-se em um dos principais meios de acesso aos municípios e comunidades, sendo os bancos de areia um problema significativo para quem trafega nos rios da Amazônia. No intuito de auxiliar a gestão da qualidade da navegação desta região este trabalho teve por objetivo desenvolver uma metodologia para auxiliar a identificação da formação de bancos de areia e as alterações das delimitações das linhas de costa, no intuito de colaborar com a atualização de cartas náuticas que possuem um importante papel para a navegação fluvial e marítima.

O levantamento *in loco* das áreas que possuem bancos de areia é geralmente difícil (risco às embarcações) e dispendioso (custos logísticos associados à realização das batimetrias), resultando em uma quantidade limitada de dados que pode ser obtida pelas técnicas tradicionais. Alternativamente, as técnicas de sensoriamento remoto fornecem ferramentas eficazes e seguras para a realização de inferências e indicações auxiliares aos processos de medição de grandes dimensões espaciais. O radar de abertura sintética (*Synthetic Aperture Radar* - SAR), em particular, é um meio promissor para o monitoramento da evolução temporal de bancos de areia, principalmente devido às suas vantagens na capacidade operacional, de gerar produtos significativos independentemente de tempo e clima, além de permitir a vigilância para uma ampla área [Cheng et al. 2013], [Yang et al. 2008].

O Programa *Copernicus* da ESA (*European Space Agency*) pretende produzir, a longo prazo, dados SAR através das Missões Sentinel para subsidiar diferentes aplicações baseadas em séries temporais [EUROPEAN SPACE AGENCY 2018a 2018b 2018c]. O acesso aberto aos dados da Missão Sentinel-1, formada por dois satélites de órbita polar, que geram imagens SAR na banda C, configura-se, atualmente, em uma significativa fonte de dados para o monitoramento de bancos de areia na região Amazônica. A Missão Sentinel-1 foi projetada para fornecer alta resolução espaço-temporal para os serviços operacionais e aplicativos que exigem longas séries de tempo de dados terrestres, com estimativa que cada satélite da constelação Sentinel-1 transmita dados de observação da Terra por pelo menos 7 anos (com recursos de energia para 12 anos), sendo que para a região Amazônica o tempo de revisita é de 12 dias.

Aliado ao sensoriamento remoto, o monitoramento em tela também pode usufruir dos benefícios das técnicas de inteligência computacional para o reconhecimento automático de padrões evolutivos dos bancos de areia. Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNN) podem ser utilizadas para a identificação de mudanças em imagens orbitais (alterações nas áreas monitoradas). As CNN ou *ConvNets* são aplicadas no processamento e análise de imagens digitais. Em sua Modalidade Profunda caracterizam-se pela utilização de várias camadas (*Deep Learning*). Esta Aprendizagem Profunda é parte integrante dos métodos de Aprendizado de Máquina (*Machine Learning*). Uma das promessas da aprendizagem profunda é a substituição da obtenção de características feitas de forma manual por algoritmos eficientes capazes de extrair características de forma autômata [Zhu et al. 2017].

Assim, diante o exposto, este trabalho de nível exploratório-descritivo teve por objetivo propor uma metodologia de identificação automática de bancos de areia situados em uma baía Amazônica mediante a classificação de imagens de radar de abertura sintética (SAR) usando uma rede neural convolucional profunda (*Deep Learning*) denominada VGG-19, para extração de características das imagens SAR, e a Árvore de Decisão (*Decision Tree*) para determinação da base de regras de classificação.

2. Materiais e Métodos

2.1. Área de estudo: Baía do Guajará

A área de estudo escolhida foi a Baía do Guajará. Ela é formada pelo encontro da foz dos rios Guamá e Acará, que banha os municípios paraenses de Barcarena e Belém, capital do estado do Pará.

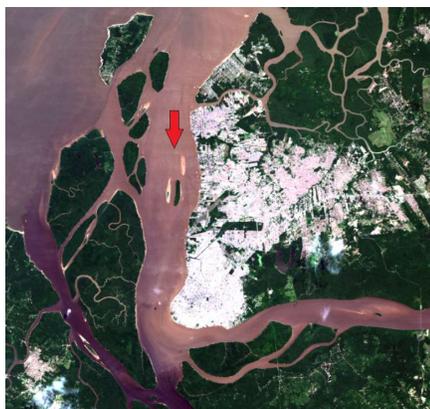


Figura 1. Área de Estudo: Baía do Guajará

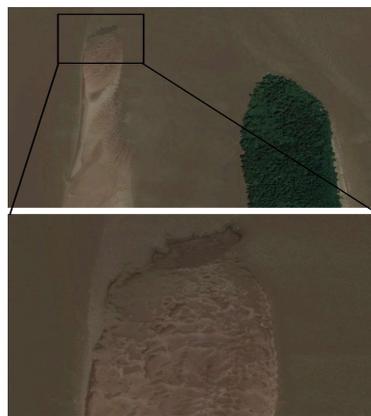


Figura 2. Detalhe de Banco de Areia

A Figura 1 mostra um recorte da cena do Satélite Landsat 8, Órbita/Ponto: 223/061, Sensor OLI, Composição RGB (Cor Natural), com data de aquisição em 07/06/2018, no momento em que a altura de maré era de 1,3 m acima do nível de redução (Porto de Belém). Para esta altura de maré já é possível a identificação de bancos de areia próximos a cidade de Belém (seta vermelha). A Figura 2 mostra detalhes de um banco de areia, na área de estudo, contíguo ao arquipélago denominado “Ilha da Barra”, ambos as proximidades do Aeroporto Internacional de Belém.

2.2. Coleta de dados SAR

A imagem SAR foi obtida gratuitamente no “Copernicus Open Access Hub” da ESA, um produto da Missão Sentinel-1; Plataforma Orbital: S1A; Banda: C; Tipo: *Ground Range Detected* (GRD); Polarizações: VV e VH; Modo Sensor: *Interferometric Wide Swath Mode* (IW), sendo este considerado o modo principal de aquisição de dados terrestres devido atender a maior parte dos serviços demandados.

2.3. Altura de maré

Optou-se por escolher uma imagem SAR sincronizada com uma pequena altura de maré, para maior exposição dos bancos de areia (porções emersas). Utilizou-se as “Tábuas de Marés” (publicadas pela Diretoria de Hidrografia e Navegação - MB) que informam, diariamente, os horários das Preamares (PM) e Baixa-mares (BM). Entretanto, não é comum o horário da visita do Satélite Sentinel-1 coincidir com o horário das Baixa-mares (BM) na região em estudo, sendo então necessária a utilização das “Tabelas de Correção” para se determinar a altura da maré no momento das visitas do satélite. Após a análise de 56 produtos SAR disponíveis na base de dados da ESA, optou-se pela imagem SAR, com data de aquisição em 30/03/2018, no momento em que a altura de maré era de 0,2 m acima do nível de redução (Porto de Belém).

2.4. Pré-processamento das imagens SAR

Utilizou-se o Software “*Sentinel Application Platform*”, mais conhecido como SNAP para realizar o pré-processamento da imagem SAR. Inicialmente, para a cena escolhida, conforme a etapa descrita no item 2.3, foi realizado um pré-processamento baseado em [Foumelis 2018], composto da seguinte sequência: (a) “*Apply Orbit File*”; (b) “*Calibrate*”; (c) “*Speckle Filtering*”; (d) “*Geocoding*”; e (e) “*Subset*”. A Figura 3 expõe a visualização de parte da área de estudo para Sigma Zero nas polarizações VH e VV, sendo possível perceber uma diferença significativa de brilho para os bancos de areia (setas vermelhas).

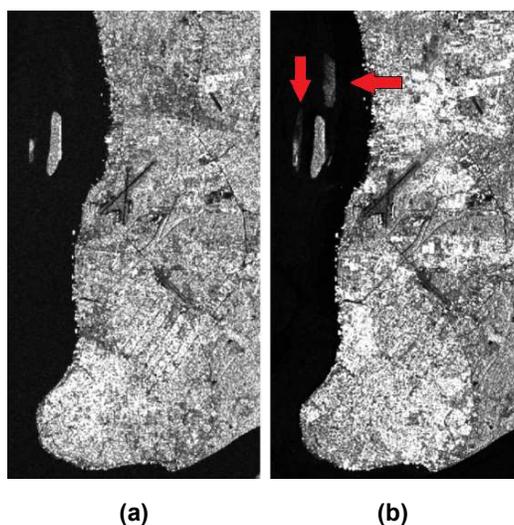


Figura 3. Visualização para: (a) Sigma Zero VH e (b) Sigma Zero VV

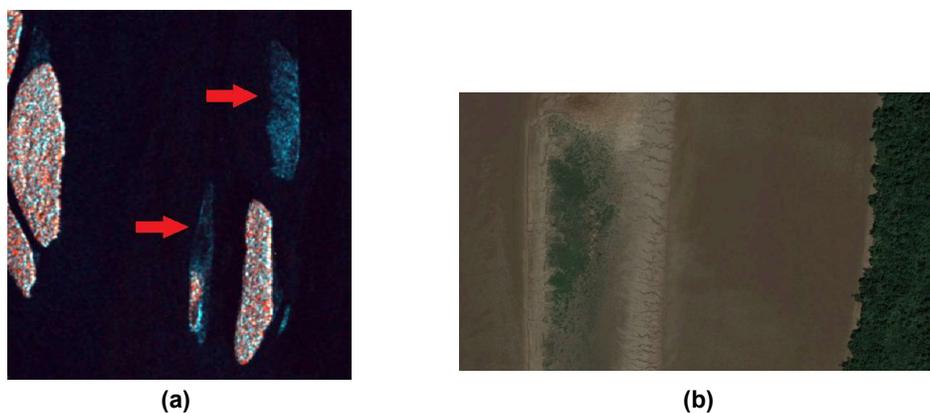


Figura 4. (a) Destaque dos Bancos de Areia e (b) Detalhes de Vegetação

2.5. Efeito *Bragg* e imagem RGB

O imageamento SAR diferencial, observado neste estudo, decorre do chamado Efeito *Bragg* (Ressonância *Bragg*) que representa uma maior intensidade da energia retroespalhada pelas “Ondas de *Bragg*” para o imageamento SAR na polarização VV e uma menor intensidade da energia retroespalhada para o imageamento SAR na

polarização VH [Violante-Carvalho 2010]. Considerando esta diferença de brilho observada, buscou-se criar uma máscara polarimétrica (destaque) para facilitar a identificação de bancos de areia. Utilizou-se uma composição colorida RGB: Red: Sigma Zero VH; Green: Sigma Zero VV; Blue: Sigma Zero VV - Sigma Zero VH. A Figura 4(a), mostra o resultado da composição RGB, onde são destacados os Bancos de Areia (setas vermelhas). Ainda na Figura 4(a), percebe-se que parte de um banco de areia apresenta semelhança da composição colorida das ilhas contíguas. A Figura 4(b) expõe detalhes de uma vegetação sobre a porção em questão, o que explica o retrospalhamento e conseqüentemente o produto de composição semelhante.

2.6. Classificação de bancos de areia utilizando Rede Neural Convolutacional

Após a aplicação da máscara polarimétrica (composição RGB), realizou-se amostragem aleatória de 600 recortes para banco de areia (BA), com dimensões constantes e iguais a 15x15 pixels e 600 recortes para não-banco de areia (NBA) (ilhas fluviais situadas na Baía do Guajará), também com dimensões constantes e iguais a 15x15 pixels, o que resultou em 1200 recortes. Deste total foram selecionados, aleatoriamente, 960 recortes para compor um conjunto de dados de treinamento (80% do total dos dados), sendo 480 recortes de BA e 480 recortes de NBA. Os dados remanescentes, portanto 240 recortes, foram utilizados para a composição do conjunto de dados de teste (20% do total dos dados), sendo 120 recortes de BA e 120 recortes de NBA. Desta forma, utilizou-se massas de dados balanceadas. A Figura 5(a) expõe exemplos de recortes BA e a Figura 5(b) exemplos de recortes NBA. Os recortes foram obtidos dentro de um retângulo envolvente com: Limite de Latitude Norte: 01° 19' 36" S; Limite de Longitude Oeste: 48° 31' 18" O; Limite de Latitude Sul: 01° 22' 38" S; e Limite de Longitude Leste: 48° 29' 16" O. O próximo passo da pesquisa foi desenvolver uma metodologia para a identificação automática dos bancos de areia. Inicialmente, utilizou-se uma arquitetura convolutacional denominada VGG-19 (19 camadas ocultas), vencedora do Prêmio “ImageNet Large Scale Visual Recognition Challenge 2014 (ILSVRC2014)” [VISUAL GEOMETRY GROUP 2018], que encontra-se disponível no Software Livre (*Free Software License*) denominado “Orange Data Mining” [ORANGE VISUAL PROGRAMMING 2018] para extrair características (*features*) dos recortes (4096 *features* por imagem). Posteriormente, foi utilizado o algoritmo denominado Árvore de Decisão (*Decision Tree*) com os parâmetros *default* do Orange - Versão 3.15, para a determinação da base de regras de classificação.

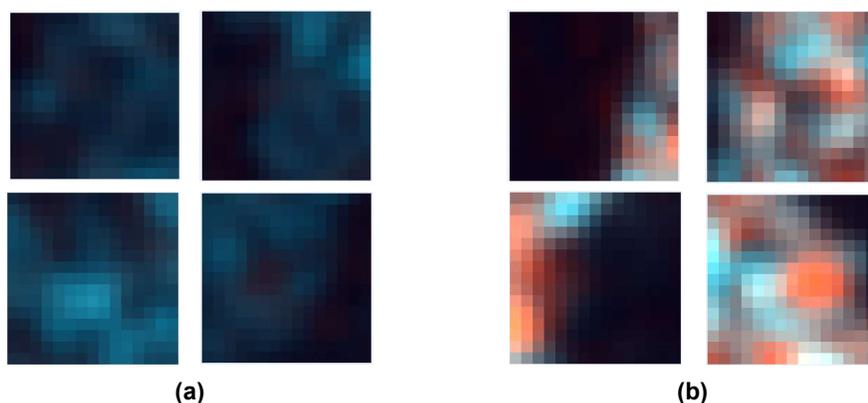


Figura 5. (a) Recortes BA e (b) Recortes NBA

3. Resultados da classificação

A Rede Neural Convolutiva VGG-19 realizou a extração de 4096 características para cada amostra do conjunto de dados de treinamento e teste, sendo obtida a partir desta massa de dados, com a Árvore de Decisão (*Decision Tree*), a base de regras para a classificação. A base de regras gerada proporcionou uma acurácia preditiva igual a 99,6% na identificação automática dos bancos de areia do conjunto de dados de teste.

4. Conclusões

O estudo permitiu obter as seguintes conclusões: (a) De forma individual, as imagens SAR da Missão Sentinel-1, para Sigma Zero na Polarização VV, apresentaram melhor detecção dos bancos de areia quando comparadas as imagens SAR, para Sigma Zero na Polarização VH (Efeito *Bragg*); (b) A forma combinada de polarizações, pela máscara polarimétrica (composição colorida RGB), utilizada neste trabalho, permitiu um destaque para os bancos de areia na área de estudo; (c) Com a aplicação da CNN VGG-19 foi possível extrair 4096 características de cada amostra da massa de treinamento e da massa de teste. Após o uso do algoritmo *Decision Tree*, obteve-se acurácia preditiva igual a 99,6% para a identificação de bancos de areia; e (d) A Rede Neural Convolutiva utilizada (VGG-19) demonstrou-se útil para a extração automática de características (*features*) e formação de massas de dados robustas para posterior classificação, entretanto, pelo fato do estudo ter se limitado a uma única baía Amazônica, novos estudos tornam-se necessários para a consolidação desta técnica autômata.

5. Referências

- Cheng, T. et al. (2013) “Sandbank and Oyster Farm Monitoring with Multi-Temporal Polarimetric SAR Data Using Four-Component Scattering Power Decomposition”, . IEICE TRANS. COMMUN. p. 2573-2579.
- EUROPEAN SPACE AGENCY (2018a) “Copernicus: Overview”, http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Overview3.
- EUROPEAN SPACE AGENCY (2018b) “Sentinel Missions”, <https://sentinel.esa.int/web/sentinel/missions>.
- EUROPEAN SPACE AGENCY (2018c) “Acquisition Modes”, <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-1-sar>.
- Foumelis, M. (2018) “Multi-temporal Analysis of Sentinel-1 SAR Backscattered Intensity”, French Geological Survey – BRGM.
- ORANGE VISUAL PROGRAMMING (2018) “Documentation - Release 3”, <https://orange.biolab.si/>.
- Violante-Carvalho, N. (2010) “Sobre os mecanismos de imageamento do radar de abertura sintética SAR para a estimação do espectro direcional de ondas geradas pelo vento”, Revista Brasileira de Geofísica. p. 593-607.
- VISUAL GEOMETRY GROUP (2018) Department of Engineering Science, University of Oxford. http://www.robots.ox.ac.uk/~vgg/research/very_deep/.
- Yang, J. et al. (2008) “Review of the study on the underwater topography detection with sar imagery in sino-european dragon cooperation programme”, ESA-SP Vol. 655, ISBN: 98-92-9221-219-3., p.10.
- Zhu, X. X. et al. (2017) “Deep Learning in Remote Sensing: A review”, IEEE GEOSCIENCE AND REMOTE SENSING MAGAZINE.