

# Projeto ForestEyes: Uma proposta para aliar Ciência Cidadã e Aprendizado de Máquina para monitoramento de desmatamento

Fernanda B. J. R. Dallaqua<sup>1</sup>, Álvaro L. Fazenda<sup>1</sup>, Fabio A. Faria<sup>1</sup>

<sup>1</sup>Instituto de Ciência e Tecnologia – Universidade Federal de São Paulo (UNIFESP)  
Avenida Cesare Mansueto Giulio Lattes, nº 1201 – Eugênio de Mello – SP – Brazil

{fernanda.dallaqua, alvaro.fazenda, ffaria}@unifesp.br

**Abstract.** *This paper presents the ForestEyes project methodology, a Citizen Science project in which volunteers analyze and classify segments of remote sensing images. These classifications are used as training set of classifiers, which will then label new remote sensing images to monitor deforestation. The goal is that, with improvement, the project will be able to generate reliable data, being used in areas where there is a deficit of monitoring programs.*

**Resumo.** *Este artigo apresenta a metodologia do projeto ForestEyes, um projeto de Ciência Cidadã em que voluntários analisam e classificam segmentos de imagens de sensoriamento remoto. Essas classificações são utilizadas no treinamento de algoritmos classificadores, que depois classificarão novas imagens de sensoriamento remoto, a fim de monitorar desmatamento. A ambição é que, com aprimoramento, o projeto consiga gerar dados confiáveis e que possa ser utilizado em áreas onde haja deficit de programas de monitoramento.*

## 1. Introdução

As florestas tropicais desempenham um importante papel no ecossistema global, uma vez que abrigam mais da metade das espécies do planeta, retêm bilhões de toneladas de carbono, promovem a formação de nuvens e chuvas, e são o lar de inúmeros povos indígenas [Martin 2015].

Infelizmente, milhões de hectares de florestas tropicais são perdidos todo ano, seja por desmatamento ou degradação, fazendo-se necessários programas de monitoramento e detecção de desmatamento, além de políticas públicas para a prevenção e punição. Esses programas, que podem ser governamentais ou de institutos sem fins lucrativos, utilizam de imagens de sensoriamento remoto, processamento de imagens, técnicas de Aprendizado de Máquina e fotointerpretação de especialistas para analisar, identificar e quantificar mudanças na cobertura florestal [Luz et al. 2014].

Um grande desafio para as tecnologias da informação e comunicação (TIC) é a escassez de mão-de-obra especializada e/ou a grande quantidade de dados a serem analisados, tornando o processo custoso [Soares et al. 2010]. Uma possível solução é utilizar voluntários não especializados na coleta, análise e classificação de dados para resolverem problemas técnicos e científicos, o que é conhecido como Ciência Cidadã. É uma área que têm atraído bastante atenção devido a grande quantidade de dados que são gerados, que tendem a ser de boa qualidade e são obtidos a baixo custo [Grey 2009].

A Ciência Cidadã pode ser uma valiosa fonte de dados para a área de Observação da Terra, o que inclui o monitoramento do desmatamento [Fritz et al. 2017]. Para os projetos de Ciência Cidadã *ForestWatchers* [Luz et al. 2014], *EarthWatchers* [Schepaschenko et al. 2019] e *Geo-Wiki* [Fritz et al. 2012], voluntários analisam e classificam imagens de sensoriamento remoto. Essas classificações são utilizadas para a geração de mapas ou alertas de desmatamento. Já o projeto *Forest Watcher* utiliza a coleta de dados de voluntários *in situ* para confirmar alertas de desmatamento emitidos pelo *Global Forest Watch* [Petersen et al. 2017].

As classificações vindas dos voluntários também poderiam ser utilizadas como conjuntos de treinamento de técnicas de Aprendizado de Máquina. Nesse contexto, em abril/2019 foi lançado o projeto *ForestEyes* [Dallaqua et al. 2019], hospedado na conhecida plataforma de Ciência Cidadã, *Zooniverse* [Smith et al. 2013]. Os voluntários classificam segmentos de imagens de sensoriamento remoto e essas contribuições são utilizadas para criar conjuntos de treinamento de algoritmos classificadores, que serão utilizados para monitorar desmatamento em novas imagens de sensoriamento remoto.

Trabalhos preliminares [Dallaqua et al. 2019, Dallaqua et al. 2020] foram feitos para atestar a qualidade das contribuições dos voluntários e a viabilidade de utilizá-las como conjunto de treinamento em Aprendizado de Máquina. No entanto, ainda não existia uma formalização da metodologia do projeto. Este artigo apresenta essa metodologia, que pode ser dividida em 5 módulos.

A organização deste trabalho é a seguinte: a Seção 2 discorre sobre a metodologia do projeto *ForestEyes*; a Seção 3 apresenta um breve resumo dos resultados preliminares já publicados, atestando a viabilidade do projeto; e a Seção 4 conclui este artigo.

## 2. Metodologia do projeto ForestEyes

A metodologia do projeto *ForestEyes* pode ser dividida em cinco módulos principais: Módulo de Pré-processamento, Módulo de Ciência Cidadã, Módulo de Organização e Seleção, Módulo de Aprendizado de Máquina e Módulo de Pós-processamento. A Figura 1 apresenta o esquema simplificado dessa metodologia.

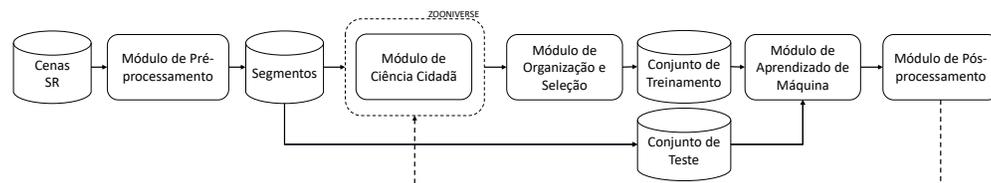
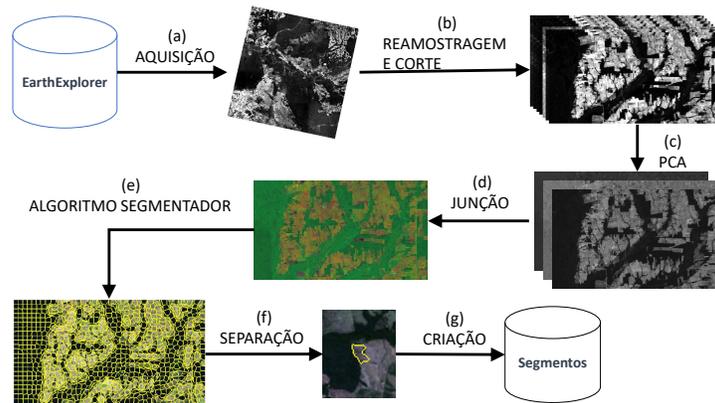


Figura 1. Esquema simplificado da metodologia do projeto *ForestEyes*.

No Módulo de Pré-processamento, exemplificado na Figura 2, as cenas de sensoriamento remoto são adquiridas, processadas e segmentadas. Atualmente, as cenas utilizadas são do satélite Landsat-8, em que 7 de suas 11 bandas são adquiridas na plataforma *EarthExplorer* do *United States Geological Survey* (USGS) (etapa (a)). Essas 7 bandas – costal, azul, verde, vermelho, infravermelho próximo, infravermelho médio I e infravermelho médio II – passam por reamostragem e corte da região de interesse (etapa (b)). Depois, a dimensionalidade é reduzida para 3 (etapa (c)), através de *Principal Component Analysis* (PCA) [Jolliffe 2011], gerando uma imagem (etapa (d)) que

é segmentada por um algoritmo de segmentação (etapa (e)), que pode ser *Simple Linear Iterative Clustering* (SLIC) [Achanta et al. 2012], *Image Foresting Transform-SLIC* (IFT-SLIC) [Alexandre et al. 2015], entre outros. Os segmentos (etapa (f)) são enviados a uma base de dados (etapa (g)).



**Figura 2. Esquematisação do Módulo de Pré-processamento do projeto *Fores-tEyes*. Fonte: [Dallaqua 2020].**

No Módulo de Ciência Cidadã, alguns dos segmentos na base de dados são enviados à plataforma *Zooniverse*, sendo criado um *workflow*, onde é definido o tipo de tarefa que os voluntários terão que realizar, a interface gráfica, as respostas possíveis, além da definição de um tutorial e de textos de ajuda. Os voluntários são instruídos pelo tutorial a classificar um segmento em ‘floresta’ ou ‘não-floresta’ se 70% ou mais *pixels* do segmento pertencerem a uma dessas classes; senão, os voluntários devem assinalar ‘indefinido’. Atualmente é definido que cada tarefa deverá ser respondida por 15 voluntários distintos. Ao final, é feito o *download* das contribuições dos voluntários em um arquivo CSV.

No Módulo de Organização e Seleção, as contribuições dos voluntários passam por uma filtragem, eliminando contribuições redundantes – mesmo voluntário respondeu a mesma tarefa mais de uma vez – e respostas em excesso. Depois, a classe de cada tarefa é definida pelo voto majoritário das 15 respostas e são feitas análises como nível de dificuldade das tarefas [Arcanjo et al. 2016], convergência do consenso [Arcanjo et al. 2016], acurácia das classificações em relação à uma verdade, cálculo da pontuação dos voluntários [Arcanjo et al. 2016], entre outras. Para compor o conjunto de treinamento do próximo módulo são consideradas apenas as amostras que receberam classe ‘floresta’ ou ‘não-floresta’, sendo eliminadas as amostras de classe ‘indefinido’ e as em que ocorreu empate. Para o futuro também poderiam ser eliminadas amostras de maior dificuldade ou de acordo com alguma outra análise, por exemplo.

No Módulo de Aprendizado de Máquina, o conjunto de treinamento é o gerado pelo módulo anterior. Já o conjunto de teste é composto pelos segmentos que não foram enviados ao Módulo de Ciência Cidadã. Todos esses segmentos têm suas características extraídas por descritores de imagem. Depois, esses vetores de características são normalizados e então uma técnica de Aprendizado de Máquina é treinada e aplicada no conjunto de teste. Diferentes descritores de imagem e técnicas de Aprendizado de Máquina podem

ser testadas.

O Módulo de Pós-processamento é planejado para o futuro, onde as classificações realizadas pelo Módulo de Aprendizado de Máquina podem ser validadas por especialistas, gerando alertas de desmatamento às autoridades competentes, por exemplo. Além disso, segmentos interessantes, que trariam informação ao treinamento das técnicas de Aprendizado de Máquina, poderiam ser enviados ao Módulo de Ciência Cidadã.

### 3. Estudos preliminares

Para atestar a viabilidade do *ForestEyes* foi realizado um estudo de caso para uma pequena área de Rondônia, no ano de 2016, comparando com verdades baseadas no PRODES. O projeto PRODES estima a taxa anual de desmatamento na Amazônia Legal Brasileira. Especialistas fotointerpretam imagens de sensoriamento remoto, coletadas pelos satélites Landsat-8, Sentinel e CBERS-4 e os dados gerados são disponibilizados no portal Terra-Brasilis [Souza et al. 2019].

Como no ano de 2016 as imagens temáticas do PRODES possuíam resolução espacial de 60m, foi necessário reamostrar as 7 bandas do Landsat-8 de 30m para 60m. Depois, a dimensionalidade foi reduzida através da técnica PCA e a imagem resultante foi segmentada pelo algoritmo SLIC, gerando 1022 segmentos com tamanho médio de 174 *pixels*. Esses segmentos foram apresentados aos voluntários em composições de cor RGB e falsa-cor com as bandas infravermelho médio II, infravermelho próximo e verde do Landsat-8. Foram recebidas 19.807 contribuições, de 227 voluntários [Dallaqua et al. 2019].

Três conjuntos verdade baseados no PRODES foram criados: um baseado em *pixel* (GT-PRODES) e dois baseados em segmentos (GT-U e GT-M). Em GT-PRODES, o mosaico PRODES é binarizado, em que todas as classes diferentes de ‘floresta’ são agregadas como ‘não-floresta’. Já para GT-U e GT-M, classificam-se segmentos de acordo com a proporção de *pixels* ‘floresta’ e ‘não-floresta’ de GT-PRODES. Em GT-M, por exemplo, a classe que possui mais de 50% dos *pixels* será a classe do segmento. Para esses 3 conjuntos verdade foram obtidas acurácias acima de 84%, mostrando como voluntários conseguem criar dados de qualidade [Dallaqua et al. 2019].

Para um experimento de Aprendizado de Máquina, selecionou-se apenas as amostras que receberam classe ‘floresta’ ou ‘não-floresta’, gerando um conjunto de treinamento de 934 amostras, sendo metade de uma classe e metade da outra. Já para o conjunto de teste, adquiriu-se segmentos de outra área de Rondônia, no ano de 2016, que foram rotulados de acordo com a verdade GT-M [Dallaqua et al. 2020].

Para cada segmento, de cada conjunto, 13 descritores de textura de Haralick [Haralick et al. 1973] foram extraídos, gerando vetores de características. Como classificador foi utilizado *Support Vector Machine* (SVM) [Hearst et al. 1998] e realizou-se tanto aprendizado supervisionado quanto aprendizado ativo [Tuia et al. 2011], em que o conjunto de treinamento é iterativamente construído através de uma seleção das amostras que trarão melhor representatividade ao treino. A utilização de aprendizado ativo emulou a situação em que existe o ciclo entre os Módulos de Ciência Cidadã e Pós-processamento (linha pontilhada na Figura 1).

Os resultados mostraram que aprendizado ativo, com uma boa inicialização,

constrói um conjunto de treinamento que consegue resultados similares ao aprendizado supervisionado, porém, utilizando bem menos amostras [Dallaqua et al. 2020]. Assim, sua implementação no projeto *ForestEyes* conseguiria baratear ainda mais o processo, uma vez que apenas os segmentos importantes que seriam enviados aos voluntários.

#### 4. Conclusão

Este artigo apresentou a metodologia do projeto *ForestEyes*, que visa aliar Ciência Cidadã com Aprendizado de Máquina para o monitoramento de desmatamento. O projeto é composto de cinco módulos principais, de fácil adaptação, permitindo o teste de diferentes técnicas para processamento de imagens, Aprendizado de Máquina, entre outros.

A viabilidade do projeto foi atestada por estudos preliminares, que validaram os resultados com dados do projeto PRODES. Esses estudos mostraram que os voluntários conseguem boa acurácia na classificação dos segmentos e que essas classificações podem ser utilizadas como conjunto de treinamento de um SVM.

O projeto ainda precisa de aprimoramento, mas pode no futuro ser uma alternativa para áreas onde não existam programas de monitoramento oficiais, ou também ser utilizado como fonte complementar de dados. No entanto, a viabilidade deste projeto não significa que especialistas possam ser substituídos por voluntários, ainda mais para um escopo tão crítico e sensível quanto monitoramento de desmatamento, que exige dados bem acurados para a implementação de políticas públicas.

#### 5. Agradecimentos

Os autores gostariam de agradecer a agência fomentadora CAPES (Código de Financiamento 001), o USGS pelas imagens Landsat-8, o INPE pelos dados do PRODES, a plataforma *Zooniverse* por hospedar o projeto *ForestEyes*, e os voluntários que realizaram as tarefas. Esta pesquisa é parte do INCT da Internet do Futuro para Cidades Inteligentes, financiado por CNPq (proc. 465446/2014-0), CAPES (Código de Financiamento 001) e FAPESP (procs. 14/50937-1 e 15/24485-9).

#### Referências

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., and Süsstrunk, S. (2012). SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE transactions on pattern analysis and machine intelligence*, 34(11):2274–2282.
- Alexandre, E. B., Chowdhury, A. S., Falcao, A. X., and Miranda, P. A. V. (2015). IFT-SLIC: A general framework for superpixel generation based on simple linear iterative clustering and image foresting transform. In *2015 28th SIBGRAPI Conference on Graphics, Patterns and Images*, pages 337–344. IEEE.
- Arcanjo, J. S., Luz, E. F., Fazenda, A. L., and Ramos, F. M. (2016). Methods for Evaluating Volunteers' Contributions in a Deforestation Detection Citizen Science Project. *Future Gener. Comput. Syst.*, 56(C):550–557.
- Dallaqua, F., Fazenda, A., and Faria, F. (2019). ForestEyes Project: Can Citizen Scientists Help Rainforests? In *IEEE 15th International Conference on eScience*, pages 18–27. IEEE.

- Dallaqua, F., Fazenda, A., and Faria, F. (2020). Aprendizado Ativo com dados de Ciência Cidadã para o monitoramento de florestas tropicais. In *1ª Escola Regional de Aprendizado de Máquina e Inteligência Artificial de São Paulo (ERAMIA-SP 2020)*.
- Dallaqua, F. B. J. R. (2020). *Projeto ForestEyes - Ciência Cidadã e Aprendizado de Máquina na Detecção de Áreas Desmatadas em Florestas Tropicais*. PhD thesis, Universidade Federal de São Paulo. Instituto de Ciência e Tecnologia.
- Fritz, S. et al. (2012). Geo-Wiki: An online platform for improving global land cover. *Environmental Modelling & Software*, 31:110–123.
- Fritz, S., Fonte, C., and See, L. (2017). The role of citizen science in earth observation. *Remote Sensing*, 9(4).
- Grey, F. (2009). Viewpoint: The age of citizen cyberscience. *Cern Courier*, 29.
- Haralick, R. M., Shanmugam, K., and Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6):610–621.
- Hearst, M. A., Dumais, S. T., Osuna, E., Platt, J., and Scholkopf, B. (1998). Support vector machines. *IEEE Intelligent Systems and their applications*, 13(4):18–28.
- Jolliffe, I. (2011). *Principal component analysis*. Springer.
- Luz, E. F., Correa, F. R. S., González, D. L., Grey, F., and Ramos, F. M. (2014). The ForestWatchers: A Citizen Cyberscience Project for Deforestation Monitoring in the Tropics. *Human Computation*, 1:137–145.
- Martin, C. (2015). *On the Edge: The State and Fate of the World's Tropical Rainforests*. Greystone Books Ltd.
- Petersen, R., Pintea, L., and Bourgault, L. (2017). Forest Watcher Brings Data Straight to Environmental Defenders. <http://blog.globalforestwatch.org/people/forest-watcher-brings-data-straight-to-environmental-defenders/>. Accessed: 08-07-2020.
- Schepaschenko, D. et al. (2019). Recent advances in forest observation with visual interpretation of very high-resolution imagery. *Surveys in Geophysics*, 40(4):839–862.
- Smith, A. M., Lynn, S., and Lintott, C. J. (2013). An introduction to the zooniverse. In *First AAAI conference on human computation and crowdsourcing*.
- Soares, M. D., Santos, R., Vijaykumar, N., and Dutra, L. (2010). Citizen science-based labeling of imprecisely segmented images: Case study and preliminary results. In *Collaborative Systems-Simposio Brasileiro de Sistemas Colaborativos (SBSC), 2010 Brazilian Symposium of. IEEE*, pages 87 – 94.
- Souza, A. et al. (2019). Metodologia Utilizada nos Projetos PRODES e DETER. *São José dos Campos: INPE*.
- Tuia, D., Volpi, M., Copa, L., Kanevski, M., and Munoz-Mari, J. (2011). A survey of active learning algorithms for supervised remote sensing image classification. *IEEE Journal of Selected Topics in Signal Processing*, 5(3):606–617.