

Rotulagem Massiva de Imagens por Ciência Cidadã para Detecção de Desmatamento

Hugo Resende¹, Álvaro L. Fazenda¹, Fabio A. Faria^{1,2}

¹Instituto de Ciência e Tecnologia – Universidade Federal de São Paulo (UNIFESP)
Avenida Cesare Mansueto Giulio Lattes, 1201,
Eugenio de Mello, 12247-014, São José dos Campos – SP – Brasil

²Instituto Superior Técnico – Universidade de Lisboa – Portugal

{hresende, alvaro.fazenda}@unifesp.br, fabio.faria@tecnico.ulisboa.pt

Abstract. *Citizen science is an essential tool for democratizing knowledge, as it allows anyone to assist in large-scale data analysis. In the environmental context, this approach is essential for monitoring threats such as tropical forest deforestation. In this regard, this study demonstrates how massive volunteer participation can generate reliable labels through the wisdom of crowds. In the ForestEyes project, 1,800 remote sensing images were collaboratively classified and labeled (with an average of 875 classifications per day), achieving 88.78% accuracy compared to reference data, highlighting the potential of citizen science as a support tool for deforestation detection.*

Resumo. *A ciência cidadã é uma ferramenta essencial para democratizar o conhecimento, pois por meio dela, qualquer pessoa pode auxiliar na análise de dados em larga escala. No contexto ambiental, essa abordagem é essencial para monitorar ameaças como o desmatamento de florestas tropicais. Nesse sentido, este trabalho demonstra como a participação massiva de voluntários pode gerar rótulos confiáveis pela sabedoria das multidões. No projeto ForestEyes, foram classificadas e rotuladas, colaborativamente, 1800 imagens de sensoriamento remoto (com uma média de 875 classificações diárias), para as quais obteve-se 88,78% de acurácia em relação aos dados de referência, evidenciando o potencial da ciência cidadã como apoio na detecção de desmatamento.*

1. Introdução

As florestas tropicais são um tipo de bioma que desempenham um papel fundamental para a manutenção da vida no planeta, principalmente, na regulação climática, na preservação da biodiversidade e na manutenção dos ciclos hidrológicos. No entanto, essas áreas vêm sofrendo com o avanço contínuo do desmatamento, impulsionado por atividades como a expansão agropecuária, exploração madeireira e ocupação irregular do solo. Diante dessa ameaça latente, torna-se essencial o desenvolvimento e aprimoramento de estratégias eficazes para monitorar e mitigar o desmatamento [Brown and Pearce 2023, Artaxo, Paulo et al. 2022].

No Brasil, a Amazônia Legal representa a maior extensão contínua de floresta tropical do planeta, sendo, atualmente, um dos biomas mais afetados pelo desmatamento.

Apenas em 2023, mais de 2 milhões de quilômetros quadrados foram degradados, evidenciando a urgência de medidas que garantam um acompanhamento detalhado e ações de controle efetivas [Lapola, David et al. 2023, Reis and Guzman 2023].

Atualmente, o monitoramento do desmatamento conta com programas oficiais, como o Programa de Monitoramento da Floresta Amazônica Brasileira por Satélite (PRODES) e o Sistema de Detecção de Desmatamento em Tempo Real (DETER) [Pro et al. 2023, Diniz, Cesar G. et al. 2015]. O PRODES visa mapear e quantificar anualmente as áreas desmatadas, fornecendo estatísticas detalhadas sobre a perda florestal. Por outro lado, o DETER atua como um sistema de alerta em tempo quase real, ao identificar alterações na cobertura florestal para ações rápidas de fiscalização. Além desses programas, abordagens inovadoras têm sido desenvolvidas para complementar os sistemas oficiais, como é o caso do projeto ForestEyes, o qual alia ciência cidadã e aprendizado de máquina para aprimorar a detecção de desmatamento [Fazenda and Faria 2024].

No âmbito do ForestEyes, as campanhas de ciência cidadã são projetadas, criadas e hospedadas na plataforma conhecida como Zooniverse [Simpson, Robert et al. 2014]. Nessas campanhas, voluntários analisam segmentos de imagens (microrregiões) de sensoriamento remoto, classificando-as como floresta ou desmatamento recente [Fazenda and Faria 2024]. Esse processo gera rótulos que, posteriormente, são utilizados no treinamento de modelos de aprendizado de máquina para a detecção automatizada do desmatamento. Além da geração de amostras rotuladas, as campanhas promovem engajamento social, fortalecem a ciência voltada para causas ambientais e proporcionam capacitação e conscientização dos participantes.

De posse desses elementos motivadores, este trabalho tem como objetivo demonstrar a viabilidade de geração de uma base de dados robusta e confiável, com amostras rotuladas por meio de uma grande campanha de ciência cidadã no âmbito do ForestEyes. É importante ressaltar que, em campanhas anteriores, foram utilizadas 180 tarefas (segmentos), mas, devido ao engajamento observado nessas campanhas e à necessidade de treinar modelos mais robustos, como os baseados em aprendizado profundo (*deep learning*), foi projetada e conduzida uma campanha 10 vezes maior, totalizando 1800 tarefas. A comparação das classificações realizadas pelos voluntários com a “verdade” PRODES revelou uma taxa de acerto próxima de 90%, evidenciando a qualidade e a relevância da contribuição voluntária para a detecção de desmatamento.

2. Fundamentação Teórica

Nesta seção, serão apresentados os principais conceitos relacionados às tecnologias, técnicas e métricas relacionadas com esta pesquisa.

2.1. Satélite Sentinel-2

Atualmente, há diversos programas que disponibilizam dados de sensoriamento de forma gratuita, entre eles, as missões dos satélites Landsat-8, operada pela NASA e pelo Serviço Geológico dos Estados Unidos (USGS), e Sentinel-2, mantida pela Agência Espacial Europeia (ESA) no âmbito do programa Copernicus [Roy, David P. et al. 2014, Drusch, M. et al. 2012]. O Sentinel-2 é uma tecnologia mantida pela Agência Espacial Europeia (ESA), composto por dois satélites, denominados Sentinel-2A e Sentinel-2B, que operam em órbitas heliosíncronas. Esses satélites são equipados com o sensor óptico

conhecido como *MultiSpectral Instrument* (MSI), o qual é projetado para capturar imagens da superfície terrestre em 13 bandas espectrais distribuídas ao longo do espectro visível, do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR). Essa diversidade espectral permite a extração de informações valiosas para diferentes aplicações, desde a análise da saúde da vegetação até a identificação de corpos d'água e solos expostos [Drusch, M. et al. 2012, Main-Knorn, M. et al. 2017]. Por fim, é importante destacar que as bandas espectrais do Sentinel-2 possuem diferentes resoluções espaciais, as quais variam entre 10, 20 e 60 metros, o que permite obter uma boa riqueza de detalhes quando se utiliza dessas bandas de melhor resolução.

2.2. PRODES

O PRODES é o principal programa oficial brasileiro para o monitoramento do desmatamento na região da Amazônia Legal. Tal programa foi desenvolvido e é mantido pelo Instituto Nacional de Pesquisas Espaciais (INPE) [INPE 2024]. Entre as suas principais atividades, o PRODES realiza, desde 1988, a estimativa anual das taxas de desmatamento na região, principalmente por fornecer gratuitamente dados fundamentais para a formulação de políticas públicas ambientais e ações de fiscalização. As análises das regiões potencialmente desmatadas são baseadas em imagens de satélite da série Landsat (ou sensores equivalentes, como CBERS e Sentinel-2), permitindo a detecção de áreas com tamanho superior a 6,25 hectares [Pro et al. 2023]. Dentre as suas principais características, é importante destacar o seu período de operação, o qual consiste em um ciclo anual de monitoramento; particularmente, a sua cobertura é referente ao período de agosto do ano anterior a julho do ano corrente. Os dados gerados são públicos e amplamente utilizados por pesquisadores, organizações ambientais e órgãos governamentais, tornando-se uma referência essencial no combate ao desmatamento.

Um exemplo de dado do PRODES (após algumas etapas de processamento) pode ser visualizado por meio da Figura 1(b). Nessa imagem, denominada neste trabalho como verdade PRODES, os pixels verdes são regiões de floresta, os pixels vermelhos se referem à regiões com desmatamento recente (detectados no último ano do PRODES) e as regiões em preto dizem respeito a locais que não são de interesse no projeto ForestEyes, por exemplo, desmatamento antigo, estradas, hidrografia, entre outras. Para fins de comparação, por meio da Figura 1(a) é apresentada a mesma região Figura 1, em uma composição de falsa-cor referente às bandas 4, 11 e 12, do Sentinel-2.

2.3. Algoritmos SLIC e MaskSLIC

A segmentação das imagens é uma etapa fundamental no projeto ForestEyes, pois é por meio dela que as regiões para análise dos voluntários são definidas. Entre as diversas abordagens existentes, os algoritmos baseados na construção de superpixels são amplamente utilizados devido à sua capacidade de agrupar pixels semelhantes, preservando fronteiras e reduzindo a complexidade da imagem. Nesse contexto, o algoritmo conhecido como *Simple Linear Iterative Clustering* (SLIC) se destaca na literatura computacional como uma técnica eficiente para a geração de superpixels [Achanta, Radhakrishna et al. 2012].

Originalmente, o SLIC é um método baseado no algoritmo de agrupamento *k-means*, que opera no espaço de cores CIELAB e incorpora uma métrica de distância que combina similaridade espectral e proximidade espacial. Seu funcionamento se baseia na inicialização de centróides distribuídos uniformemente sobre a imagem, os quais são

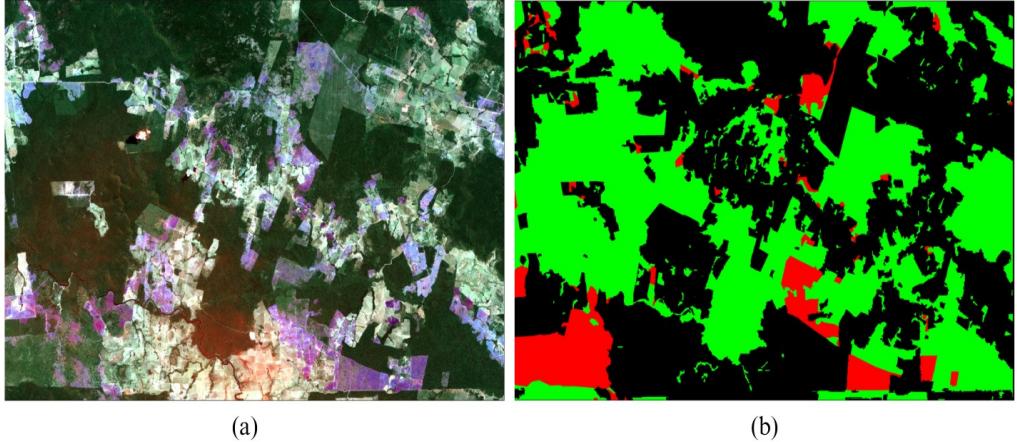


Figura 1. Exemplo de uma região de interesse, projetada em uma composição de falsa-cor com as bandas 4, 11 e 12 e a sua respectiva verdade PRODES.

refinados iterativamente até que a convergência seja alcançada. A distância utilizada pelo SLIC pode ser definida por meio da Equação 1.

$$D = \sqrt{d_c^2 + \left(\frac{d_s}{S}\right)^2} \quad (1)$$

Na Equação 1, d_c é a distância de cor no espaço CIELAB, d_s a distância espacial entre pixels e S o tamanho do superpixel. O algoritmo também inclui um parâmetro de compactação, o que permite um controle sobre a regularidade dos segmentos.

Apesar da eficiência do SLIC, a sua aplicação em imagens com máscaras ou regiões de interesse específicas pode ser um fator limitante. Para lidar com essa obstaculização, foi desenvolvido o MaskSLIC, uma variação do algoritmo original, porém ele incorpora restrições baseadas em máscaras binárias. O MaskSLIC ajusta a distribuição dos centróides e as atualizações de rótulos para garantir que os superpixels respeitem as fronteiras impostas pela máscara. Tal característica o torna uma abordagem mais adequada para imagens segmentadas de forma seletiva. No projeto ForestEyes isso é essencial, pois regiões com desmatamento antigo devem ser ignoradas.

2.4. Métricas de Avaliação

Atualmente, no projeto ForestEyes são utilizadas algumas métricas de avaliação, as quais podem ser aplicadas tanto na análise da qualidade dos segmentos, quanto na identificação da variabilidade das respostas dos voluntários em uma campanha de ciência cidadã. Nesse sentido, de modo a avaliar a qualidade do segmento a ser utilizado em uma campanha, faz-se o uso, no âmbito desse projeto, de uma medida conhecida como Taxa de Homogeneidade (HoR), a qual pode ser visualizada por meio da Equação 2.

$$HoR = \frac{\max(NFP, NNP)}{NP} \quad (2)$$

Na Equação 2, NFP e NNP dizem respeito, respectivamente, à quantidade de

pixels das classes “floresta” e “desmatamento”. Por outro lado, NP é a quantidade total de pixels do segmento.

Para cada tarefa (na plataforma Zooniverse, pode-se entender como um mesmo segmento representado de várias formas), ao se construir a campanha, deve-se definir a quantidade de classificações esperadas dos voluntários. Com base nessa informação, é possível definir a classificação majoritária e, consequentemente, o rótulo, para cada uma delas. Dessa forma, para cada tarefa é possível determinar o seu nível de dificuldade, por meio de uma análise da variabilidade das classificações. Objetivando, então, avaliar essa variabilidade, pode-se utilizar a Entropia de Shannon, a qual tem a sua formulação representada por meio da Equação 3

$$H(X) = - \sum_{i=1}^n p(x_i) \cdot \log_2(p(x_i)) \quad (3)$$

Na Equação 3, $p(x_i)$ diz respeito à probabilidade de ocorrência do x_i -ésimo evento. Por outro lado, n representa a quantidade de classes possíveis, as quais, neste trabalho, são “floresta” ou “desmatamento”. Dessa forma, a entropia é computada por meio da razão entre a quantidade de classificações (respostas) associadas à i -ésima classe e a quantidade de classificações da tarefa.

3. O Projeto ForestEyes

O projeto ForestEyes foi criado em 2019 com objetivo de combinar ciência cidadã e técnicas de processamento de imagens e aprendizagem de máquina para detecção de desmatamento em florestas tropicais [Fazenda and Faria 2024, Dallaqua et al. 2021]. Na Figura 2 é possível visualizar a estrutura do projeto ForestEyes.,

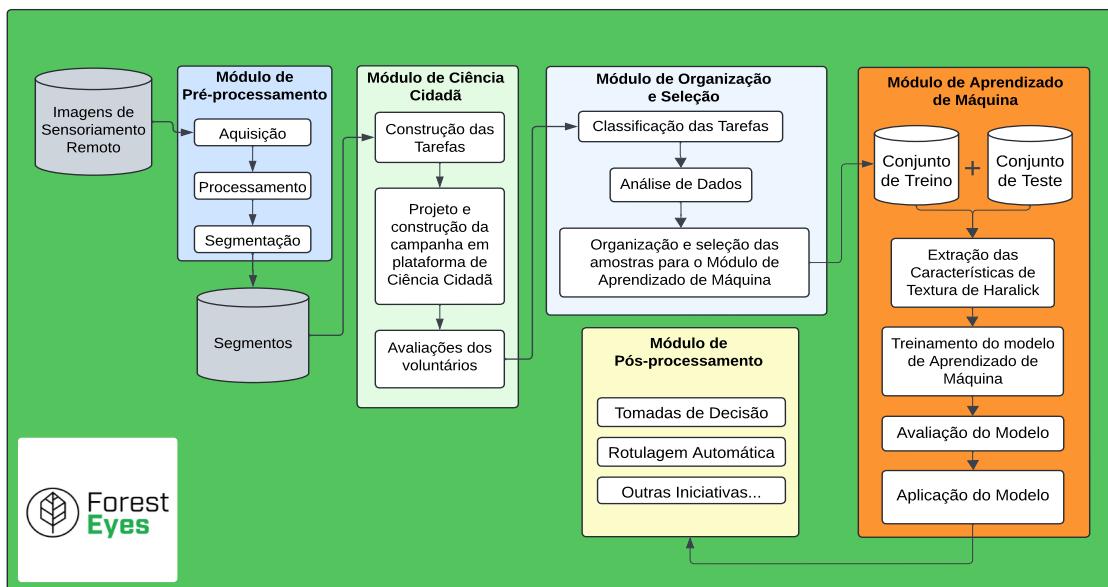


Figura 2. Diagrama Esquemático do Projeto ForestEyes.

No **Módulo de Pré-processamento** são realizadas as etapas de aquisição, processamento dos dados e segmentação. Na aquisição, obtém-se os dados de sensoriamento

remotos brutos, oriundos de satélites como o Landsat-8 e Sentinel-2 e do PRODES. Esses dados são de regiões bastante afetadas pelo desmatamento, conforme os dados do PRODES. No processamento, são realizados recortes das imagens e alinhamentos dos pixels entre elas e a verdade do PRODES. Por fim, na segmentação, é aplicado algum algoritmo segmentador, baseado na estratégia de construção de superpixels (por exemplo, o MaskSLIC), ignorando as regiões que não devem ser analisadas.

O **Módulo de Ciência Cidadã** engloba etapas relacionadas à elaboração da campanha. Na construção das tarefas, são realizadas atividades inerentes à definição das composições de falsa-cor que serão exibidas na campanha e nas quais os segmentos serão demarcados, entre outras. No projeto e construção da campanha em plataforma de ciência cidadã, são realizadas atividades, por exemplo, relacionadas ao upload de todo o material (imagens e metadados) para a plataforma em questão (Zooniverse), a definição de layouts, formas de exibição das tarefas e quantidade de respostas (classificações) esperadas para cada uma delas para o encerramento da campanha. A avaliação dos voluntários consiste em um período no qual a campanha fica vigente, ou seja, disponibilizada para participação. Nesse período, é fornecido todo o suporte necessário, via plataforma Zooniverse, para que os usuários possam tirar suas dúvidas relacionadas às análises.

No **Módulo de Organização e Seleção**, são realizadas atividades inerentes à análise dos voluntários na campanha. Particularmente, são calculadas as respostas majoritárias para cada tarefa, tempos de resposta para cada uma delas e entropia observada, por exemplo. Com base nesses dados, são estruturados conjuntos de treino e teste, devidamente rotulados para o próximo módulo.

O **Módulo de Aprendizado de Máquina** é constituído por etapas que variam desde a extração das características de textura de Haralick dos segmentos rotulados à aplicação do modelo (ou, em alguns casos, de vários modelos). Nesse módulo, em particular, dados os conjuntos de treino e teste obtidos no módulo anterior, inicialmente, são extraídas as características e, na sequência, o modelo utilizado no ForestEyes (geralmente, o *Support Vector Machine (SVM)*) é treinado com base nessas características. Em seguida, o modelo é avaliado e aplicado.

Por fim, no **Módulo de Pós-processamento** são realizadas atividades inerentes à tomadas de decisão, embasadas na detecção de desmatamento do módulo anterior. Além disso, espera-se que no futuro existam mecanismos para propiciar uma rotulagem automática das amostras que seja confiável, entre outras iniciativas.

4. Projeto e Construção da Campanha

A campanha objeto de estudo deste trabalho, denominada *Big Campaign*, seguiu o mesmo protocolo experimental do trabalho [Resende, Hugo et al. 2024], o qual faz uso de 9 diferentes áreas de estudo, totalizando 8.514 hectares, localizadas próximas a uma região com frequentes focos de desmatamento, conhecida como Bacia Hidrográfica do Rio Xingu, no estado do Pará. Uma das áreas de estudo utilizada neste trabalho pode ser observado na Figura 1(a), na Seção 2.

Para cada uma das nove áreas de estudo foi gerada uma imagem na composição das bandas 4, 3 e 2 (RGB), de modo que fosse possível gerar uma boa segmentação pelo algoritmo MaskSLIC. Essa composição foi definida em experimentos preliminares

que indicaram essa melhor combinação de bandas em detrimento de outras inúmeras combinações experimentadas. Uma vez segmentadas as imagens, foram selecionados, para cada área de estudo, 200 segmentos, dentre os quais 100 eram da classe “floresta” e 100 da classe “desmatamento”. Para cada um desses conjuntos de segmentos por classe, 50 tinham $HoR = 1,0$ e 50 com $0,7 \leq HoR \leq 0,9$. Além disso, de modo a evitar segmentos muito pequenos, cada um deles tinha tamanho mínimo de 630 pixels.

Definidos os 1800 segmentos, cada um deles foi projetado em 3 composições de falsa-cor diferentes, juntamente com uma projeção em Índice de Vegetação por Diferença Normalizada (NDVI). Essas composições foram definidas pois, em testes preliminares, foram as que mais contrastaram as duas classes (“floresta” e “desmatamento”). Além disso, ao se gerar a marcação dos segmentos, prezou-se por definir as cores mais adequadas para cada falsa-cor, de modo a minimizar efeitos indesejados, como os Efeitos das Bandas de Mach [Mach 1865]. Na plataforma Zooniverse, algumas definições estratégicas também foram realizadas. Durante a exibição das composições, optou-se por exibir primeiramente aos voluntários, aquelas mais intuitivas. Além disso, foram elaborados tutoriais com exemplos de classificação e foi definida a quantidade de 15 respostas para a finalização de cada tarefa e posterior definição da resposta majoritária. Um exemplo de tarefa com as quatro composições pode ser visualizada por meio da Figura 3. Devido à difusão do projeto ForestEyes e da plataforma Zooniverse, não é necessário realizar algum tipo de divulgação da campanha, pois em tal plataforma existem milhares de voluntários que participam ativamente de campanhas em diversos projetos.

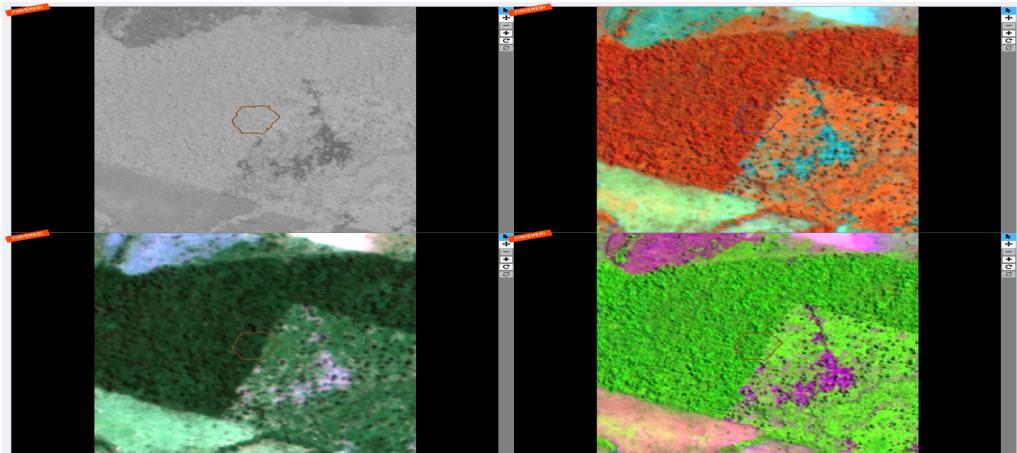


Figura 3. Exemplo de uma tarefa (segmento), com as três composições e o NDVI, disponível na plataforma Zooniverse para classificação.

5. Resultados e Discussão

Majoritariamente, as campanhas realizadas até então no projeto ForestEyes foram munidas de segmentos oriundos de imagens obtidas pelo satélite Landsat-8. A realização de uma campanha com dados do satélite Sentinel-2 foi inicialmente realizada e publicada no trabalho de [Resende, Hugo et al. 2024], no entanto, foram avaliadas apenas 180 tarefas, quantidade igual a adotada nas últimas campanhas do projeto ForestEyes. Devido ao grande engajamento observado nas campanhas já realizadas, as quais demandaram de 7 a 15 dias, aproximadamente, para a sua conclusão, foi então esperado um prazo

proporcional para essa nova campanha, com dez vezes mais tarefas ($10\times$). No entanto, observou-se um maior engajamento, com uma participação ainda mais massiva dos voluntários quando comparada às campanhas anteriores. Por meio da Tabela 1 é possível observar os principais resultados obtidos na campanha objeto de estudo deste artigo.

Tabela 1. Principais Resultados da Campanha.

Campanha	Período até a conclusão (em dias)	Voluntários Envolvidos	Segmentos rotulados	Acurácia da campanha	Tempo médio de resposta	Entropia média
<i>Campanha #1</i>	7	67	180	93,33% (Geral) 96,67% (Floresta) 90,00% (Desmatamento)	23,65s	0,55
<i>Big Campaign</i>	31	106	1800	88,78% (Geral) 99,33% (Floresta) 78,22% (Desmatamento)	32,95s	0,61

Como é possível observar na Tabela 1, no que diz respeito ao engajamento dos voluntários para classificar as tarefas, a *Big Campaign* superou a *Campanha #1*. Particularmente, na *Big Campaign* houve uma maior média de tarefas finalizadas (rotuladas) por dia, o que representa aproximadamente 870 classificações diárias, com 59 segmentos rotulados em média, diariamente. Por outro lado, a *Campanha #1* obteve uma média de 375 classificações diárias e 25 segmentos rotulados. Importante citar que para ambas as campanhas, cada tarefa, correspondente a um segmento de imagem, necessita de 15 classificações de voluntários para estar completa. Outro fato que também indica um maior engajamento na *Big Campaign* diz respeito à quantidade média de classificações por voluntários. Nessa campanha tem-se, em média, 255 segmentos classificados por voluntário, enquanto para a *Campanha #1* houve uma média de, aproximadamente, 41 classificações por voluntário.

Acerca da acurácia dos voluntários nas campanhas, devido à resolução espacial do Sentinel-2, em ambas foram observados bons percentuais de acertos em relação à verdade do PRODES. Um percentual um pouco mais destoante foi observado na classe “desmatamento” na *Campanha #1*, porém, para a classe “floresta”, na *Big Campaign* os voluntários acertaram mais em suas classificações. Uma vez que a *Big Campaign* possui muito mais tarefas, essa diferença de acurácia computada para a classe “desmatamento” pode estar relacionada à existência de segmentos de imagem sem o devido contexto ou com regiões de pastagem e/ou rebrota de vegetação. Tanto pastagens como regiões de rebrota possuem aparências espectrais similares às regiões de floresta e, portanto, o contraste que evidencia e delimita duas regiões de classes diferentes pode não ser tão claro. Nesse caso em particular, os segmentos de imagens de regiões de desmatamento podem não fazer fronteira com uma área de floresta, e vice-versa. Fato esse que já se mostrou importante para garantir maior acurácia nas classificações, de acordo com campanhas prévias. Na Figura 4 é possível visualizar três segmentos classificados erroneamente pelos voluntários. Particularmente, na Figura 4(a) há um exemplo de pastagem sem um contexto de uma região florestal próxima ao segmento. Por outro lado, nas Figuras 4(b) e (c), embora exista o

contexto de regiões florestais próximas, os segmentos foram demarcados em regiões de rebrota, predominantemente na cor verde, o que pode ter induzido os voluntários ao erro.

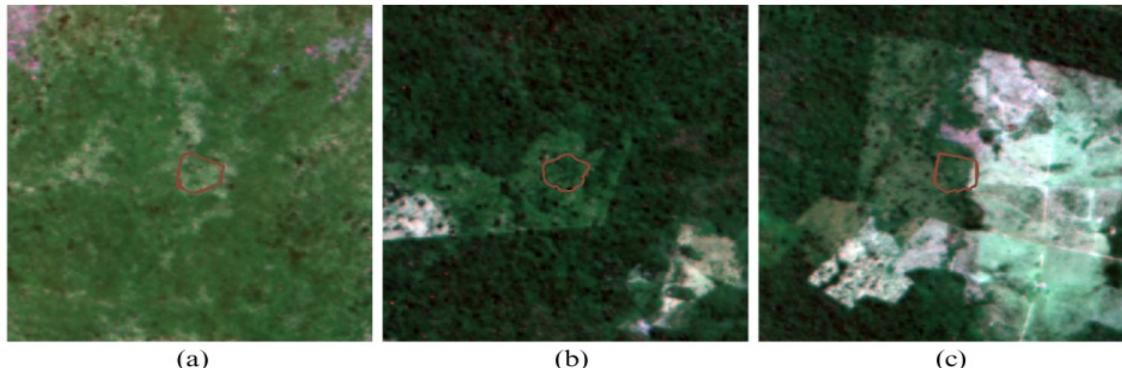


Figura 4. Exemplos de Segmentos Classificados Erroneamente.

Por fim, na *Big Campaign* foram obtidos tempo médio de resposta e entropia média mais altos, se comparado à *Campanha #1*. Sobre o tempo médio, tal ocorrência pode estar relacionada com a maior probabilidade de existência de *outliers* (tempos de resposta exorbitantes) dada a maior quantidade de tarefas. Por outro lado, a entropia média mais elevada, está provavelmente associada à inclusão de tarefas com maior complexidade de análise, dada a quantidade de tarefas da *Big Campaign*.

6. Conclusão

Nesta pesquisa, foi demonstrada a importância da ciência cidadã na rotulagem massiva de imagens por meio de voluntários não-especializados. A ciência cidadã democratiza o acesso das pessoas à ciência e, por meio do conceito da sabedoria das multidões, proporciona avaliações confiáveis. Assim, foi projetada e conduzida uma campanha no âmbito do projeto ForestEyes, na qual se utilizou segmentos de imagens de sensoriamento remoto, obtidas de regiões da floresta Amazônica com frequentes focos de desmatamento. Os resultados obtidos demonstraram um elevado engajamento dos voluntários, dentre os quais foram computadas quase 870 classificações diárias. Além disso, é importante destacar uma alta acurácia (próxima à 90%), se comparada à classificação feitas por especialistas em sensoriamento remoto de regiões florestais. Isso indica que a contribuição voluntária pode gerar dados valiosos e em larga escala, o que pode propiciar um treinamento adequado de modelos robustos de aprendizado profundo. Como trabalhos futuros, pretende-se utilizar desses dados rotulados para treinar os esses modelos profundo, substituindo os modelos de aprendizado tradicionais atualmente empregados no projeto ForestEyes (SVM e *Random Forest*), os quais recebem como entrada os vetores de características extraídos por descritores de imagens clássicos da literatura (*hand-crafted features*).

Agradecimentos

À UNIFESP e ao IFSULDEMINAS pelo suporte. Os autores deste trabalho agradecem às agências de fomento pelo suporte financeiro. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e com o apoio parcial de agências de fomento patrocinadoras do projeto Internet do futuro aplicada a cidades inteligentes, den-

tro do Programa Institutos Nacionais de Ciência e Tecnologia (INCT), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (processo 465446/2014-0), Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) (processos 2014/50937-1, 2015/24485-9, 2017/25908-6, 2018/23908-1, 2019/26702-8, 2023/00811-0, e 2023/00782-0, 2024/01115-0).

Referências

- Achanta, Radhakrishna et al. (2012). Slic superpixels compared to state-of-the-art superpixel methods. *IEEE TPAMI*, 34(11):2274–2282.
- Artaxo, Paulo et al. (2022). Tropical and boreal forest atmosphere interactions: A review. *Tellus. Series B: Chemical and Physical Meteorology*, 74:24–163.
- Brown, K. and Pearce, D. W. (2023). *The causes of tropical deforestation: the economic and statistical analysis of factors giving rise to the loss of the tropical forests*. Taylor & Francis.
- Dallaqua, F. B., Fazenda, Á. L., and Faria, F. A. (2021). Foresteyes project: Conception, enhancements, and challenges. *Elsevier FGCS*, 124:422–435.
- Diniz, Cesar G. et al. (2015). Deter-b: The new amazon near real-time deforestation detection system. *IEEE J-STARS*, 8(7):3619–3628.
- Drusch, M. et al. (2012). Sentinel-2: Esa’s optical high-resolution mission for gmes operational services. *Remote Sensing of Environment*, 120:25–36.
- Fazenda, A. L. and Faria, F. A. (2024). Foresteyes: Citizen scientists and machine learning-assisting rainforest conservation. *Communications of the ACM*, 67(8):95–96.
- INPE (2024). PRODES - Project for Monitoring Deforestation in the Legal Amazon by Satellite. <https://www.obt.inpe.br/prodes/index.php>. Acessado em setembro/2024.
- Lapola, David et al. (2023). The drivers and impacts of amazon forest degradation. *Science*, 379(6630):eabp8622.
- Mach, E. (1865). *Über die Wirkung der räumlichen Vertheilung des Lichtreizes auf die Netzhaut*. K. k. Hof-und Staatsdruckerei.
- Main-Knorn, M. et al. (2017). Sen2Cor for Sentinel-2. In *Image and Signal Processing for Remote Sensing*, volume 10427, page 1042704.
- Pro, G. F. W., Watcher, F., and Atlases, F. (2023). Global forest watch. *Update*.
- Reis, E. and Guzman, R. (2023). An econometric model of amazon deforestation. In *The causes of tropical deforestation*, pages 172–191. Routledge.
- Resende, Hugo et al. (2024). Sampling strategies based on wisdom of crowds for amazon deforestation detection. In *SIBGRAPI*, pages 1–6. IEEE.
- Roy, David P. et al. (2014). Landsat-8: Science and product vision for terrestrial global change research. *Remote sensing of Environment*, 145:154–172.
- Simpson, Robert et al. (2014). Zooniverse: observing the world’s largest citizen science platform. In *ACM WWW*, pages 1049–1054.