

VIABILIDADE DA PLATAFORMA GOOGLE EARTH ENGINE EM PESQUISAS CAFEIIRAS NO SUL DE MINAS GERAIS

Daniel Altino Parede¹, Vanessa C. O. Souza², Margarete M. L. Volpato³ and Helena M. R. Alves⁴

¹ Univesidade Federal de Itajubá, Av. BPS, 1303, Bairro Pinheirinho, Itajubá – MG, danielaltino19@gmail.com, ² Univesidade Federal de Itajubá, Av. BPS, 1303, Bairro Pinheirinho, Itajubá – MG, vanessasouza@unifei.edu.br; ³ Empresa de Pesquisa Agropecuária de Minas Gerais, Universidade Federal de Lavras, Lavras - MG, margarete@epamig.br ⁴ Empresa Brasileira de Pesquisa Agropecuária, Universidade Federal de Lavras, Lavras - MG, helena@epamig.br

ABSTRACT

The use of cloud platform to geospatial data processing has been seen as a workaround to increase processing capacity in geospatial projects. In this work, Google Earth Engine (GEE) was used for the automated mapping of land use with coffee in the southern region of Minas Gerais. The classifiers random forest, cart, perceptron and minimum distance with Euclidean and Mahalanobis distances were used to classify images from Sentinel-2 and Landsat-8 satellites. In addition to the individual classifications, an ensemble of classifiers was applied, generating a new classified map. The results showed that GEE is an alternative to traditional land use projects with coffee since the accuracy of classifiers to coffee class were above the majority of those present in the literature.

Key words – Google Eart Engine, coffee, land cover classification, ensemble of classifiers.

1. INTRODUÇÃO

Devido à extrema importância econômica e financeira da cafeicultura no Brasil e, especialmente no Estado de Minas Gerais, o mapeamento das lavouras cafeeiras por meio de geotecnologias tem sido objeto de estudo há vários anos, por diferentes grupos de pesquisadores. O valor cultural, social e econômica da cafeicultura para Minas Gerais é tal que o governo do Estado recentemente investiu em um mapeamento de todo seu parque cafeeiro [1].

O uso de geotecnologias e classificações automáticas no mapeamento de áreas cafeeiras em Minas Gerais é comumente utilizado. Porém, apresenta ainda desafios científicos, uma vez que características como a alta variabilidade de padrões espectrais da cultura e características do plantio e do relevo (especialmente em Minas Gerais), dificultam o acerto dos classificadores, proporcionam baixa exatidão de mapeamento, tornando indispensável a conferência em campo dos mapas gerados [2–4]. Além disso, os algoritmos de classificação utilizados nas pesquisas citadas são aqueles disponíveis em Sistemas de Informações Geográficas (SIGs), cuja customização se dá apenas pelos parâmetros de configuração disponíveis nas interfaces. Dessa forma, a adaptação e a combinação de algoritmos apresentam alto nível de complexidade.

Por outro lado, atualmente há um vasto acervo de produtos de sensoriamento remoto e de algoritmos e metodologias para processá-los, disponíveis gratuitamente em plataformas em nuvem de processamento de dados geoespaciais, que podem

ajudar a melhorar e intensificar o mapeamento automatizado de áreas cafeeiras. O *Google Earth Engine* (GEE)¹ é uma plataforma de computação em nuvem para análise científica e visualização de conjuntos de dados geoespaciais [5]. Além de uma extensa série temporal de imagens de diferentes sensores, o GEE disponibiliza um conjunto atual de classificadores pixel-a-pixel² que podem ser utilizados para mapeamento de uso da terra. Exemplos de aplicações desse tipo podem ser encontradas em [6–8]. No Brasil, alguns estudos também estão seguindo nessa direção [9–11]. Apesar da popularização da plataforma, no contexto de mapeamento de áreas cafeeiras, a pesquisa realizada para este trabalho identificou apenas o artigo [12], cujo foco de estudo foi o mapeamento de cafés sombreados na Nicarágua. Sendo assim, o objetivo desse trabalho foi explorar a plataforma GEE na classificação de imagens de sensoriamento remoto para gerar mapas de uso da terra com café no Sul de Minas Gerais, testando essa metodologia no município mineiro de Três Pontas, importante produtor de café.

O uso do GEE flexibiliza tanto a criação, quanto a utilização de algoritmos de classificação de imagens. Nesse trabalho foram utilizados tanto algoritmos de classificação ainda não utilizados para o mapeamento do café no Sul de Minas, como o *Random Forest*, *Perceptron* e *CART*, quanto algoritmos já utilizados anteriormente para esse fim, como o *Mínima Distância* com as medidas Euclidiana e Mahalanobis. Além de averiguar a classificação com cada um desses algoritmos, neste trabalho explorou-se ainda a combinação deles, gerando uma classificação final por combinação de classificadores utilizando um sistema de voto por maioria [13].

Neste contexto, contribuição deste trabalho está em: a) Avaliar o uso do GEE como uma alternativa de infraestrutura para projetos geoespaciais de mapeamento do uso da terra com café; b) Avaliar os classificadores clássicos já disponíveis no GEE que, apesar de serem bem definidos na literatura, ainda não foram testados para o mapeamento de áreas cafeeiras em Minas Gerais e, c) Avaliar a eficácia do mapeamento diante da combinação desses classificadores.

2. MATERIAL E MÉTODOS

A área de estudo compreende o município de Três Pontas (21°17'10,07" S a 21°27'57,41" S de latitude e 45°30'4,69" O a 45°45'3,33" O de longitude), numa área de aproximadamente 690 km na região Sul do Estado de

¹ <https://earthengine.google.com/>

² Utilizam apenas a informação espectral, isoladamente, de cada pixel para encontrar regiões homogêneas

Minas Gerais. Na região prevalece relevo predominantemente ondulado (60% da área do município) com algumas regiões montanhosas (20% da área do município). Graças a suas condições climáticas e geográficas, Três Pontas apresenta condições privilegiadas para cultura do café [14].

Todo processamento foi realizado *online* no ambiente de desenvolvimento disponibilizado pelo GEE (*GEE Code Editor*), utilizando a linguagem JavaScript (JS). O mapa de uso da terra de Três Pontas utilizado como referência (mapa verdade) foi concedido pela Empresa de Pesquisa Agropecuária de Minas Gerais (EPAMIG). O mapa foi gerado a partir de imagem do satélite Sentinel 2-A, sensor MSI (Multi Spectral Instrument), obtida em 26 de Julho de 2016 (T23KMS). As classes consideradas no mapeamento de cobertura da terra foram: corpos d'água, área urbana, café, outros usos (solo exposto, pastagens, outras cultivares agrícolas) e vegetação natural.

Nas atividades de pré-processamento, foram escolhidas as imagens dos sensores Sentinel-2³ e Landsat 8⁴. A imagem Sentinel foi a mesma utilizada para a geração do mapa de referência, também nas bandas 2, 3, 4 e 8, com 10m de resolução espacial. No caso do satélite Landsat 8, a melhor a imagem do catálogo era de 08 de Agosto de 2016 (LC08-219075). Foram utilizadas as bandas 2, 3, 4 e 5, com 30 metros de resolução espacial. As imagens foram recortadas utilizando a delimitação municipal de Três Pontas.

A próxima etapa foi classificá-las considerando as mesmas classes do mapa de referência. Foram selecionados alguns algoritmos pixel-a-pixel supervisionados disponíveis no GEE, sendo dois baseados em árvore de decisão (*Random Forest* e *CART*), um de rede neural (*Perceptron Multiclass*) e o distância mínima com as medidas Euclidiana e Mahalanobis. As referências de implementação são disponibilizadas pelo GEE.

Para o treinamento dos classificadores, foram coletados cinco mil pontos aleatórios sobre o mapa verdade. Todos os classificadores foram treinados com o mesmo conjunto de amostras. Os classificadores foram aplicados com os parâmetros *default*. A única exceção foi o *Random Forest* que teve os seguintes parâmetros alterados: *numberOfTrees: 100; variablesPerSplit: 50; minLeafPopulation: 10*. Para a etapa de testes, outros cinco mil pontos aleatórios foram obtidos. A mesma amostra de teste foi utilizada para todos os classificadores.

Após obter os mapas classificados, eles foram submetidos ao processo de combinação (*ensemble of classifiers*). Essa abordagem objetiva melhorar a performance da classificação combinando decisões individuais de cada classificador. Neste trabalho, a combinação realizada é do tipo *Combining Label Outputs*, onde cada classificador tem sua própria entrada e saída independentes. Posteriormente, um método de combinação das saídas é utilizado. O popular método de decisão pela maioria simples foi escolhido neste trabalho [13].

Para a implementação da combinação de classificadores no GEE, após a geração do mapa por cada classificador

³Coleção Sentinel-2 MSI: MultiSpectral Instrument, Level-1C

⁴Coleção Landsat 8 Collection 1 Tier 2 calibrated top-of-atmosphere (TOA)

Algoritmos	Acurácia Treinamento	Exatidão Global	Kappa	Acurácia Café
Sentinel-2				
RF	74.75	66.87	0.51	66.50
Cart	76.71	62.57	0.45	62.00
Perceptron	65.97	65.57	0.48	62.46
MD Eucl.	53.60	53.33	0.36	59.35
MD Mah.	43.57	42.15	0.26	53.47
Combinação 1	-	66.00	0.50	64.71
Combinação 2	-	66.89	0.51	66.89
Landsat 8				
RF	76.34	67.37	0.52	65.83
Cart	77.62	63.81	0.47	66.89
Perceptron	67.43	66.11	0.49	61.93
MD Eucl.	57.61	56.13	0.39	59.55
MD Mah.	53.79	51.60	0.35	52.35
Combinação 1	-	66.47	0.51	64.11
Combinação 2	-	67.59	0.52	68.54

Table 1: Resultados obtidos com a classificação.

individual, os mesmos foram reunidos em uma coleção (*imageCollection*) e um filtro de Moda foi aplicado. O filtro de Moda retorna, para cada pixel, o valor mais encontrado na coleção [15]. Duas combinações foram testadas: uma com todos os classificadores (combinação 1) e outra apenas com os classificadores que obtiveram melhores resultados (RF, CART e perceptron), nomeada aqui combinação 2. O mesmo procedimento de teste aplicado às classificações individuais foi utilizado nos mapas resultantes das combinações.

Para a etapa de validação, o GEE retorna os parâmetros necessários, ou seja, a acurácia de treinamento; índice Kappa; exatidão global e a matriz de erro da qual foi extraída a acurácia da cada classe temática Café.

3. RESULTADOS

A tabela 1 apresenta os resultados obtidos com o satélite Sentinel-2 e com o satélite Landsat 8. Os valores de acurácia estão em porcentagem.

A acurácia de treinamento é apresentada apenas para fins de comparação com a exatidão global obtida pela classificação. Verifica-se que em ambos os satélites, apesar do algoritmo CART ter obtido melhor acurácia de treinamento, o mesmo não apresentou a mesma eficiência no teste. Os algoritmos de mínima distância apresentaram resultados ruins tanto no treinamento quanto nos testes, tendo o Mahalanobis resultados piores que a distância Euclidiana. Esse resultado para os algoritmos de MD corroboram os encontrados por [2]. Os melhores resultados foram encontrados com o RF e o Perceptron.

Em relação à combinação dos classificadores, o melhor resultado foi obtido com a Combinação 2, onde a votação foi realizada entre os algoritmos RF, CART e Perceptron. Esse resultado se repetiu para os dois sensores avaliados, tanto para exatidão global, quanto para a acurácia da classe temática Café. No entanto é notável que a melhora obtida com a combinação de classificadores foi mínima quando comparada aos resultados do RF.

O valor do índice Kappa, em ambos os satélites e, tanto

para o RF, quanto para a combinação 2, ficou próximo de 0,5, classificado como bom. A acurácia da classe temática café teve resultados semelhantes para os dois sensores avaliados. O melhor resultado foi obtido com o Landsat 8, na combinação 2.

As figuras 1 e 2 apresentam os mapas dos resultados obtidos com a classificação simples RF, CART, Perceptron e Combinação 2 para o satélite Sentinel-2 e Landsat-8, respectivamente. Os classificadores RF e CART apresentam resultados mais segmentado. O Perceptron tende a gerar regiões mais homogêneas. A melhor resolução espacial do Sentinel-2 favorece a captação de detalhes mais precisos, como as ruas dos talhões e a presença de pequenos corpos d'água na região. Por outro lado, conforme visto na tabela 1, o acerto da classe café é maior com o Landsat e o motivo pode ser o mapa de referência, gerado por regiões e não pixel-a-pixel.

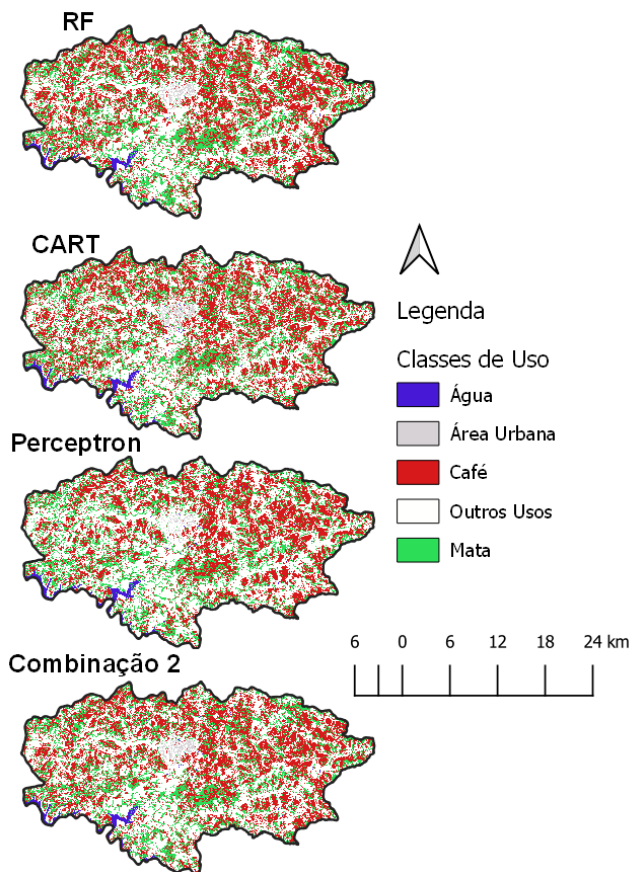


Figure 1: Mapas oriundos da classificação com o satélite Sentinel-2.

4. DISCUSSÃO

Comparando os resultados obtidos com aqueles presentes na literatura, avalia-se que a metodologia adotada apresentou boa performance ao apresentar acurácia da classe café de 66.89% e 68.54% respectivamente para os satélites Sentinel e Landsat. A exatidão da classe café obtida em [3] foi de cerca de 63%. Os resultados obtidos por [4] utilizando apenas atributos espectrais, como os utilizados nesse trabalho, obtiveram uma acurácia da classe café média de 56.8%, e

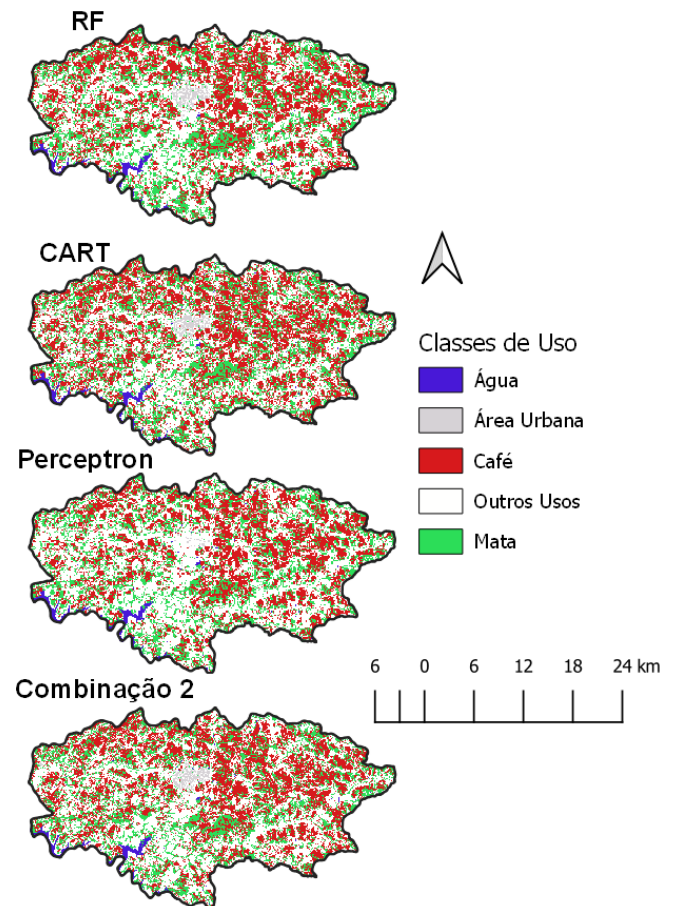


Figure 2: Mapas oriundos da classificação com o satélite Landsat 8.

acurácia máxima de 65%. Especificamente para a região de Três Pontas, [14] obtiveram uma acurácia de 74.71% utilizando classificação orientada a objetos com atributos espectrais, texturais e de forma. Neste sentido a acurácia obtida nesse trabalho teve um resultado superior aos demais na literatura, sendo pior apenas do que a classificação que utiliza outros atributos, não apenas dados espectrais. Uma vantagem da metodologia apresentada neste trabalho é o tempo de processamento, de cerca de cerca de 8 minutos a uma conexão de 50/MBs.

A boa performance do *Random Forest* tem sido reportada em diferentes trabalhos científicos. Utilizando os algoritmos do GEE, os estudos [7, 8, 10, 12] obtiveram os melhores resultados utilizando o RF. Há uma boa discussão sobre o uso dos classificadores do GEE no mapeamento de uso da terra em [8].

Para o satélite Sentinel, o ganho com a combinação de classificadores foi mínima. Para o Landsat, houve um ganho maior, especialmente na acurácia da classe café, passando de 65.83% para 68.54%. Algumas alternativas podem ser utilizadas na tentativa de melhorar a performance da combinação. Uma delas é treinar os classificadores com diferentes conjuntos de amostras. Outra é utilizar o sistema de votação ponderado, considerando o acerto de cada classe temática para cada classificador combinado. Uma terceira alternativa é acrescentar classificadores que não utilizam apenas dados espectrais. O GEE apresenta ferramentas de

extração de textura. A literatura mostra que o uso de padrões texturais auxiliam o mapeamento do café, especialmente por diferenciar as plantações de café das vegetações nativas, uma vez que ambas classes temáticas apresentam resposta espectral muito parecidas.

Um aspecto relevante a ser discutido sobre os resultados aqui apresentados é a obtenção das amostras de treinamento. É sabido que a qualidade das amostras é importante nas abordagens de classificação supervisionada [12]. Ao optar por realizar essa coleta de forma automática e aleatória, não é possível garantir a qualidade. Ou seja, podem ter sido escolhidos pixels de fronteira que não são característicos da classe temática. Muito já se discutiu sobre a sensibilidade dos algoritmos em relação a amostra de treinamento, especialmente o *Random Forest* e o CART [7,8]. Além disso, por serem aleatórias, não há um equilíbrio na quantidade de amostras por classe. Elas são proporcionais à área ocupada por cada classe na região estudada. Esse aspecto também é discutido por [12]. No entanto, optou-se por essa metodologia para que o processo fosse completamente automatizado.

Outro ponto importante de ser citado é que o mapa de referência é um mapa que integra as classes de uso por regiões e não por pixel. Assim, talhões de café são completamente mapeados como café, desconsiderando as ruas dos talhões e possíveis árvores nativas plantadas no meio do cafezal, ou algum terreiro de secagem, por exemplo. Outro exemplo típico é a Área Urbana. No mapa de referência ela aparece como uma mancha, desconsiderando os diferentes alvos presentes em uma cidade. Na classificação pixel-a-pixel, tais detalhes presentes nas imagens são considerados e podem ser claramente detectados nos mapas classificados (figuras 1 e 2). A consequência é que pontos classificados corretamente podem ser erroneamente avaliados, quando comparados ao mapa de referência. Isto é, a classificação está correta, mas é considerada incorreta em relação à referência utilizada.

5. CONCLUSÕES

Este trabalho avaliou a viabilidade do uso da plataforma em nuvem da Google, GEE, na classificação automática do uso da terra com café no Sul de Minas Gerais. Guiando-se pelos resultados encontrados, conclui-se que a plataforma é conveniente para esse fim, possibilitando gerar mapas com acurácia satisfatória, sem a necessidade de nenhuma infraestrutura computacional local. Ou seja, todo processamento foi realizado *online*. O tempo ganho em obter os produtos de sensoriamento remoto já pré-processados deve ser considerado, especialmente em projetos maiores. Acreditamos que a metodologia apresentada neste trabalho pode ser ainda melhorada e aplicada a todo Estado de Minas Gerais. As amostras de treinamento e de testes podem ser obtidas a partir do mapeamento feito pela EMATER, cujos resultados são disponibilizados em um geoportal. Atualmente já se fala em Agricultura *Big Data* (AgBD) e, dada a importância da *commodity* café para o Brasil, torna-se importante alternativas de processamentos massivos de dados para gerar conhecimentos dessa cultura de forma mais ampla e ágil.

6. AGRADECIMENTOS

Os autores agradecem à Empresa de Pesquisa Agropecuária de Minas Gerais

disponibilizados, e ao Consórcio Pesquisa Café, FAPEMIG e CNPQ pelo apoio financeiro e concessão de bolsas.

7. REFERENCES

- [1] EMATER. *Geoportal do Café*. 2018. Available at: <<http://geoportaldocafe.emater.mg.gov.br/ferramenta>>.
- [2] BERNARDES, T.; ALVES, H. M. R.; VIEIRA, T. G. C. Classificação automática de imagens de satélites no mapeamento da região cafeeira de Patrocínio, MG. In: *Simpósio Pesqui. dos Cafés do Bras.* [S.l.: s.n.], 2007.
- [3] ANDRADE, L. N. d. . V. et al. Aplicação de redes neurais artificiais na classificação de áreas cafeeiras em Machado-MG. *Coffee Sci.*, v. 1, 2013.
- [4] MARUJO, R. d. F. B. et al. Mapeamento da cultura cafeeira por meio de classificação automática utilizando atributos espectrais, texturais e fator de iluminação. *Coffee Sci.*, v. 12, n. 2, p. 164–175, 2017.
- [5] GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sens. Environ.*, v. 202, p. 18–27, 2017.
- [6] AGUILAR, R.; ZURITA-MILLA, R. A Cloud-Based Multi-Temporal Ensemble Classifier to Map Smallholder Farming Systems. *Remote Sens.*, v. 10, n. 729, 2018.
- [7] SHELESTOV, A. et al. Exploring Google Earth Engine Platform for Big Data Processing : Classification of Multi-Temporal Satellite Imagery for Crop Mapping. *Front. Earth Sci.*, v. 5, n. February, p. 1–10, 2017.
- [8] TSAI, Y. H. et al. Mapping Vegetation and Land Use Types in Fanjingshan National Nature Reserve Using Google Earth Engine. *Remote Sens.*, v. 10, n. 927, 2018.
- [9] BOURSCHIEDT, V. Análise de tendência da temperatura de superfície a partir de imagens Landsat 5: contribuições da plataforma Google Earth Engine. In: *Simpósio Bras. Sensoriamento Remoto*. Santos/SP: INPE, 2017. p. 7401–7407. ISBN 9788517000881.
- [10] MEDEIRO, F. S. L.; LOBÃO, J. S. B.; VASCONCELOS, R. N. AVANÇOS NO PROCESSAMENTO DIGITAL DE IMAGENS: O GOOGLE EARTH ENGINE. In: *Simpósio Reg. Geoprocessamento e Sensoriamento Remoto*. Salvador/BA: [s.n.], 2017. p. 367–371.
- [11] NEVES, S. A. B. d. C.; SILVA, J. d. S. V. da; NEVES, S. M. A. d. S. Proposta de uso de computação em nuvem em aplicações de zoneamento. In: *Simpósio Geotecnologias do Pantanal*. [S.l.: s.n.], 2016. p. 133–140.
- [12] KELLEY, L. C.; PITCHER, L.; BACON, C. Using Google Earth Engine to Map Complex Shade-Grown Coffee Landscapes in Northern Nicaragua. *Remote Sens.*, v. 10, n. 952, 2018.
- [13] KUNCHEVA, L. I. *Combining pattern classifiers: methods and algorithms*. [S.l.]: John Wiley & Sons, 2004.
- [14] MARUJO, R. d. F. B. et al. Classificação orientada a objetos aplicada á cultivos cafeeiros em Três Pontas - MG. In: *Simpósio Bras. Sensoriamento Remoto*. Foz do Iguaçu/PR: INPE, 2013.
- [15] GOOGLE. *Google Earth Engine*. 2018. Available at: <<https://earthengine.google.com/>>.

%