

## Pemetaan Perubahan Penutup Lahan Di Sub-DAS Kreo Menggunakan Machine Learning Pada Google Earth Engine

### *Mapping Land Cover Changes in Kreo Sub-Watershed Using Machine Learning in Google Earth Engine*

Trida Ridho Fariz<sup>1\*</sup>, Fitri Daeni<sup>1</sup>, Habil Sultan<sup>1</sup>

<sup>1</sup>Ilmu Lingkungan, Universitas Negeri Semarang, Gunungpati, Kota Semarang 50229, Indonesia

\*Email korespondensi : [trida.ridho.fariz@mail.unnes.ac.id](mailto:trida.ridho.fariz@mail.unnes.ac.id)

#### ABSTRAK

Informasi penutup lahan merupakan data yang sangat penting dalam pengelolaan Daerah Aliran Sungai (DAS). Tantangan dalam penyediaan informasi penutup lahan di DAS Kreo adalah tutupan awan dan cangkupan areanya yang cukup luas. Hadirnya *platform* pengolahan data spasial berbasis *cloud* yaitu *Google Earth Engine* (GEE) bisa menjawab tantangan tersebut. Oleh karena itu penelitian ini bertujuan untuk memetakan penutup lahan di DAS Kreo menggunakan klasifikasi berbasis *machine learning* pada GEE. Proses pemetaan penutup lahan di DAS Kreo menggunakan citra satelit Landsat 8 dan DEM SRTM. *Input* data yang digunakan antara lain band 1 sampai 7 pada citra Landsat 8, transformasi NDVI dan NDBI serta nilai elevasi dari DEM SRTM. Adapun tahun yang dipilih adalah tahun 2015 dan 2020 dengan *machine learning* yang diujikan meliputi CART, *Random forest* dan *Voting SVM*. Hasil penelitian ini menunjukkan bahwa *machine learning* yang terbaik dalam memetakan penutup lahan di DAS Kreo adalah *Random forest*. Penelitian ini masih terdapat banyak keterbatasan terutama kelas penutup lahan yang dipetakan.

Kata kunci: *Google Earth Engine*, klasifikasi multispektral, *machine learning*, penutup lahan

#### ABSTRACT

*Land cover information is very important data in watershed management. The challenge in providing land cover information in the Kreo watershed is cloud cover and its wide area coverage. The presence of a cloud-based spatial data processing platform, namely Google Earth Engine (GEE) can answer these challenges. Therefore, this study aims to map land cover in the Kreo watershed using machine learning based classification on GEE. The land cover mapping process in the Kreo watershed uses Landsat 8 satellite imagery and DEM SRTM. The input data used include bands 1 to 7 on Landsat 8 imagery, NDVI and NDBI transformations as well as elevation values from DEM SRTM. The selected years are 2015 and 2020 with machine learning being tested including CART, Random forest and SVM Voting. The results of this study indicate that the best machine learning in mapping land cover in the Kreo watershed is Random forest. There are still many limitations in this research, especially the land cover class being mapped.*

*Keywords:* *Google Earth Engine*, multispectral classification, *machine learning*, land cover

#### PENDAHULUAN

Daerah Aliran Sungai yang disingkat menjadi DAS adalah wilayah yang dibatasi oleh titik ketinggian seperti punggung

gunung yang mengalirkan dan tempat berkumpulnya air hujan. Ekosistem DAS terbagi menjadi 3 bagian yang saling berkaitan yaitu hulu, tengah dan hilir. Kondisi penutup lahan di DAS bagian hulu

akan memberikan dampak ekologi kepada bagian hilir, sehingga pengelolaan DAS merupakan hal yang penting dan bersifat multidimensi (Effendi, 2008). Dalam pengelolaan DAS, aspek utama yang perlu dikendalikan adalah kondisi penutup lahan, tanah, air dan manusia (Setyowati dkk, 2012). Hal ini membuat informasi tutupan lahan memegang peranan penting dalam pengelolaan DAS, karena bermanfaat dalam kajian hidrologis seperti perhitungan debit puncak dan koefesien *run-off* (Saraswati dkk, 2017; Poongothai *et al.*, 2014).

Pemetaan penutup lahan dapat dilakukan dengan interpretasi citra baik secara manual maupun otomatis. Salah satu tantangan dari pemetaan penutup lahan dalam lingkup area DAS di Indonesia adalah cangkupan wilayahnya yang besar serta tutupan awan yang menutupi kenampakan tutupan lahan (Fariz & Nurhidayati, 2020). Hadirnya *platform* bernama *Google Earth Engine* (GEE) bisa menjadi solusi dalam menjawab tantangan pemetaan penutup lahan untuk wilayah yang luas. Ketika dibandingkan dengan *platform* pengolahan data spasial yang lain, GEE mempunyai kelebihan seperti akses data yang sangat besar dan pengolahan data berbasis *cloud*, sehingga proses analisis *geo-big* data dapat dilakukan tanpa menggunakan super komputer (Tamiminia *et al.*, 2020). Pemrosesan data di GEE juga sangat praktis sehingga kita dengan mudah mendapatkan data citra yang bebas awan (Mateo-Garcia, 2018), apalagi GEE juga memiliki beberapa metode *machine learning* untuk analisis citra seperti *Random forest*, *CART* dan sebagainya.

Pemetaan penutup lahan menggunakan *machine learning* sudah sering dilakukan, tetapi pemilihan model dan langkah kerjanya yang sering terabaikan (Shih *et al.*, 2019). Sehingga kajian yang membandingkan kemampuan *machine learning* dalam pemetaan penutup lahan itu penting karena setiap *machine learning* memiliki pendekatan yang berbeda yang

berimbang pada perbedaan tingkat akurasi pemetaan (Talukdar *et al.*, 2020). Oleh karena itu, tujuan dari penelitian ini adalah untuk memetakan penutup lahan di DAS Kreo menggunakan *machine learning* yang tersedia di GEE untuk mengetahui *machine learning* yang terbaik dalam memetakan penutup lahan di DAS Kreo. Adapun Sub-DAS Kreo sendiri merupakan bagian dari DAS Garang yang merupakan DAS kritis di Provinsi Jawa Tengah (Perdana, 2018).

## BAHAN DAN METODE

### Lokasi dan data penelitian

Lokasi penelitian adalah Sub-DAS Kreo yang secara administratif berada di Kota Semarang, Kabupaten Semarang dan Kabupaten Kendal, Provinsi Jawa Tengah (Gambar 1). Sub DAS Krea memiliki luas area 6619.55 Ha, dengan daerah hilir merupakan wilayah perkotaan. Berbeda dengan daerah hilir, hulu DAS Kreo berada di Gunung Ungaran sehingga kenampakan tertutup awan.

Pengumpulan dan analisis data dilakukan menggunakan *platform* GEE melalui laman [code.earthengine.google.com](https://code.earthengine.google.com) dengan menggunakan script yang disusun oleh Farda (2020). Data citra satelit Landsat 8 yang digunakan dalam penelitian ini adalah perekaman tahun 2015 dan 2020 pada tanggal 1 Maret sampai 31 Oktober dari USGS *Landsat 8 Surface Reflectance Tier 1*. Pemilihan waktu perekaman citra berdasarkan rentang dikarenakan GEE menyediakan algoritma *cloud removal* dan *median*, sehingga citra satelit yang digunakan akan bebas awan dan mewakili kondisi suatu periode waktu (Fariz dan Nurhidayati, 2020). Citra *Landsat 8 USGS Surface Reflectance Tier 1* ini bersifat siap pakai karena sudah diproses ortorektifikasi dan kalibrasi reflektan. Selain citra satelit Landsat 8, penelitian ini juga menggunakan data DEM SRTM. Citra satelit Landsat 8 dan DEM SRTM digunakan sebagai input untuk pemetaan penutup lahan di Sub-DAS Kreo.



Gambar 1. Lokasi penelitian  
(Sumber: Hasil penelitian, 2021)

Secara eksplisit input dalam penelitian ini antara lain: band 1, band 2, band 3, band 4, band 5, band 6, band 7, NDVI, NDBI dan elevasi. Penggunaan band 1 sampai 7 dikarenakan kombinasi *band* tersebut memiliki akurasi tertinggi dibandingkan kombinasi semua band (tanpa pankromatik dan cirrus) pada citra Landsat 8 (Yu *et al.*, 2019; Fariz & Nurhidayati, 2020). Penggunaan transformasi citra NDVI dikarenakan menunjukkan intensitas pada obyek vegetasi, sedangkan transformasi citra NDBI menunjukkan intensitas pada obyek lahan terbangun. Untuk elevasi didapat dari DEM SRTM yang berguna untuk meningkatkan akurasi hasil pemetaan penutup lahan (Hidayati, 2013). DEM SRTM sejatinya adalah DSM (*Digital Surface Model*) yang merepresentasikan ketinggian tutupan lahan, sedangkan DEM yang representasikan ketinggian tanah yang sebenarnya adalah DTM (*Digital Terrain Model*) (Fariz, 2019). Penggunaan DEM SRTM pada penelitian ini diasumsikan bukan masalah mengingat skala pemetaan yang dipilih adalah 1:125.000.

### **Algoritma machine learning**

*Machine learning* adalah salah satu penerapan dari *artificial intelligence*. Kemampuan utama dari *machine learning* adalah menangani data berdimensi tinggi seperti data penginderaan jauh dan memetakannya menjadi beberapa kelas dengan karakteristik yang kompleks (Maxwell *et al.*, 2018).

GEE menyediakan banyak *machine learning* yaitu Fast Naïve Bayes, CART (*Classification and Regression Tree*), Random forests, GMO Max Entropy, Perceptron (*Multi Class Perceptron*), Winnow, IKPamir (*Intersection Kernel Passive Aggressive Method for Information Retrieval*, SVM), Pegasos (*Primal Estimated sub-Gradient Solver for SVM*), Voting SVM dan Margin SVM (Farda, 2017; Shelestov *et al.*, 2017). Semua *machine learning* yang tersedia tidak kami gunakan, hal ini mengingat bahwa *machine learning* dari GEE yang tersedia sekarang adalah CART, Random forest, Naïve Bayes dan SVM (Gorelick, 2021). Oleh karena itu kami menggunakan *machine learning* CART, Random forest dan SVM (Voting), hal ini juga merujuk pada Farda (2017) bahwa ketiga *machine learning* ini memiliki diatas 80% secara konsisten dalam pemetaan multi-waktu. Pendekatan klasifikasi yang gunakan adalah *pixel based* atau klasifikasi multispektral.

### **Sampel penelitian**

Penutup lahan yang dipetakan dalam penelitian ini hanya terdiri dari 6 kelas yaitu tubuh air, hutan dan kebun campur, lahan pertanian, lahan terbuka, permukiman dan industri seperti pada Tabel 1. Untuk mendukung proses klasifikasi menggunakan *machine learning* dibutuhkan beberapa sampel klasifikasi (*training sample*). Sampel yang digunakan adalah sebanyak 300 titik sampel. Selain sampel klasifikasi, diambil juga sampel penguji yang digunakan untuk menguji akurasi hasil klasifikasi. Jumlah titik sampel penguji dalam penelitian ini adalah sebanyak 170 titik. Pada penelitian ini, citra yang digunakan sebagai rujukan atau referensi penguji adalah citra satelit resolusi tinggi yang menjadi *basemap* di muka GEE. Jika terdapat perbedaan kenampakan akibat perbedaan waktu perekaman, maka referensi yang digunakan adalah citra Landsat 8.

Tabel 1. Kelas Penutup Lahan Yang Digunakan

Kelas penutup lahan	Batasan operasional
Tubuh air	Tutupan lahan berupa perairan seperti sungai dan waduk
Hutan dan kebun campur	Tutupan lahan vegetasi berkayu seperti hutan lahan kering, hutan rakyat dan kebun campur
Lahan pertanian	Tutupan lahan vegetasi tidak berkayu seperti tegalan, sawah
Lahan terbuka	Tutupan lahan berupa tanah terbuka seperti timbunan
Permukiman	Tutupan lahan berupa bangunan beratap tanah liat, bisa permukiman kota maupun permukiman desa
Industri	Tutupan lahan berupa bangunan beratap metal, bisa berupa gedung dan bangunan industri

## HASIL DAN PEMBAHASAN

### Pemetaan penutup lahan menggunakan machine learning GEE

Tahapan pemetaan penutup lahan dengan GEE dimulai dengan memanggil citra satelit Landsat 8 dari koleksi USGS Landsat 8 Surface Reflectance Tier 1. Tahapan selanjutnya adalah melakukan *reducer* citra menggunakan median untuk mengurangi koleksi gambar dengan menghitung nilai tengah dari semua nilai piksel citra pada rentang waktu tertentu. Fungsi ini berguna untuk mendapatkan citra pada tahun 2020 dan 2015 yang bebas awan, nilai pantulan tinggi dan bayangan awan. Kemudian dilanjutkan dengan pengambilan sampel klasifikasi setiap kelas penutup lahan, lalu dilakukan pemilihan *machine learning*. Konfigurasi pada setiap *machine learning* yang digunakan dalam penelitian ini tersaji di Tabel 2.

Tabel 2. Ekspresi Pada *Machine Learning* Yang Digunakan

Machine learning	Ekspektasi
CART	ee.Classifier.smileCart(6, 1)
Random forest	ee.Classifier.smileRandomForest(10, null, 1, 0.5, null, 0)
SVM	ee.Classifier.libsvm("Voting", "C_SVC", "LINEAR", true, null, null, null, null, null, null, null)

Peta penutup lahan yang dibangun menggunakan *machine learning* kemudian diuji akurasi dengan menggunakan 170 sampel penguji. Hasil uji akurasi menunjukkan bahwa peta penutup lahan yang memiliki akurasi terbaik didapat dari *machine learning Random forest*, baik untuk pemetaan di tahun 2015 dan 2020 yang terdapat pada Tabel 3. Peta penutup lahan dengan akurasi terendah didapat dari *machine learning SVM* dengan nilai *overall accuracy* dibawah 0.8.

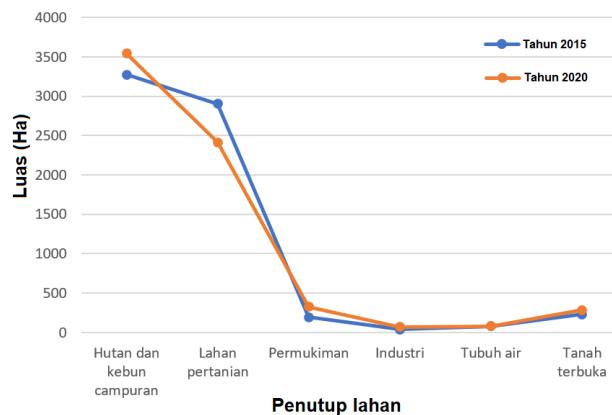
Tabel 3. Hasil Uji Akurasi Pemetaan Penutup Lahan Menggunakan *Machine Learning*

Machine learning	Overall accuracy	
	Tahun 2015	Tahun 2020
CART	0.85	0.86
Random forest	0.86	0.89
SVM	0.68	0.73

*Machine learning CART* secara umum juga memiliki akurasi diatas 0.8 baik untuk pemetaan di tahun 2015 dan 2020, namun nilai *overall accuracy* dirasa masih kurang baik dibandingkan *Random forest*. Peta penutup lahan dari *Random forest* dan *CART* memiliki akurasi tinggi dikarenakan *machine learning* ini berbasis *decision tree* yang terdapat proses pemilihan dalam penentuan kelas penutup lahan (Fariz dkk, 2021). Khusus untuk *Random Forest*, menjadi *machine learning* yang terbaik dalam penelitian ini mungkin dikarenakan sifatnya berbasis nonlinier dan hasil klasifikasinya bebas dari noise (Pelletier et al., 2016).

### Kondisi penutup lahan di DAS Kreo

Peta penutup lahan di DAS Kreo dalam penelitian ini menggunakan *machine learning Random forest*. Kelas penutup lahan dengan area terluas baik di tahun 2015 dan 2020 adalah hutan dan kebun campuran (Gambar 2). Pada rentang tahun 2015 ke tahun 2020, perubahan penutup lahan terluas di Sub-DAS Kreo adalah pada kelas penutup lahan pertanian dengan pengurangan luasan sekitar 489.23 Ha.



Gambar 2. Grafik perubahan luasan penutup lahan di Sub-DAS Kreo (Sumber: Hasil penelitian, 2021)

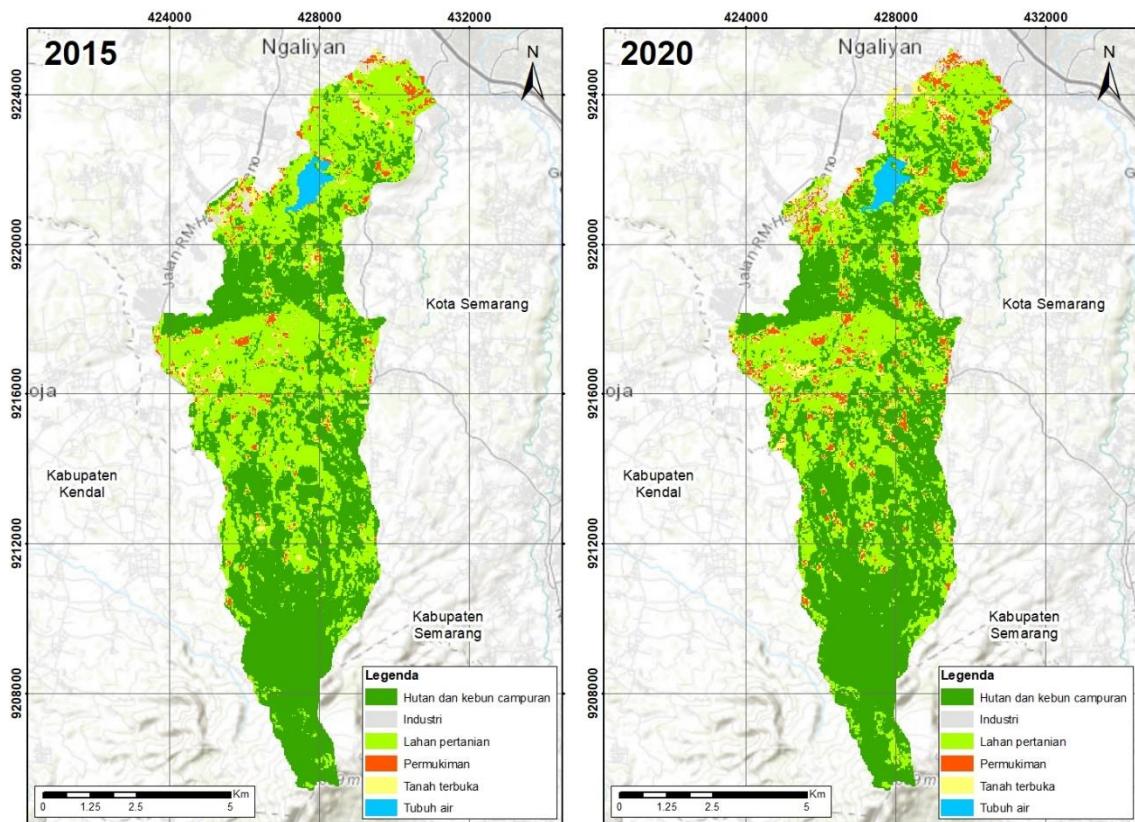
Jika dilihat pada Gambar 3, pada tahun 2020 banyak lahan pertanian yang berubah menjadi hutan dan kebun campuran serta permukiman. Perubahan lahan pertanian menjadi hutan dan kebun campuran tersebut dikarenakan faktor kelas penutup lahan yang ditentukan. *Training sample* untuk kelas penutup lahan pertanian dipenelitian ini adalah obyek yang memiliki warna hijau muda dan bertekstur halus, sedangkan *training sample* untuk hutan dan kebun campuran adalah obyek berwarna hijau tua dan bertekstur lebih kasar. Obyek seperti hutan rakyat yang berisi sengon (*Albizia chinensis*) pada saat baru tumbuh akan masuk kedalam klasifikasi lahan pertanian, tetapi jika sudah besar maka akan terklasifikasi dalam hutan dan kebun campuran. Hutan rakyat berupa sengon banyak ditemui di bagian tengah Sub-DAS Kreo atau disekitar Waduk Jatibarang.

Keberadaan hutan rakyat yang membuat hasil pemetaan perubahan penutup lahan di Sub-DAS Kreo menjadi kurang terlihat nyata. Untuk mensiasati hal tersebut, perlu dilakukan sentuhan manual melalui interpretasi visual untuk memisahkan obyek tersebut. Selain itu, perlu dicoba juga pendekatan lain seperti *object based* yang

mana memiliki akurasi yang lebih baik dibandingkan *pixel based* seperti yang kami gunakan dipenelitian ini (Tassi *et al.*, 2021).

Penelitian ini menunjukkan bahwa GEE memberikan kemudahan untuk penyediaan informasi perubahan penutup lahan di Sub-DAS Kreo. Proses pemetaan menjadi lebih cepat dikarenakan tidak perlu mengunduh citra satelit, melakukan pra-pengolahan citra dan menggunakan *super-computer*. Penelitian ini perlu dikembangkan dengan melakukan perbandingan antar *pixel based* dan *object based* serta kelas penutup lahan yang lebih banyak, selain itu perlu juga dilakukan pengujian hyperparameter antar *machine learning* seperti pada penelitian Shih *et al.* (2019).

Informasi penutup lahan sangat berguna dalam pengelolaan lingkungan di Sub-DAS Kreo. Selain berguna sebagai data kajian erosi dan konservasi lahan, informasi ini juga bisa digunakan sebagai indikasi tingkat kesuburan perairan Waduk Jatibarang (Fauzi & Maryono, 2016; Silitonga dkk, 2018). Dalam rangka menjaga kualitas perairan di Waduk Jatibarang, kajian perubahan penutup lahan perlu difokuskan pada wilayah hulu waduk seperti Kelurahan Jatirejo dan Kelurahan Jatibarang.



Gambar 3. Peta perubahan penutup lahan di Sub-DAS Kreo menggunakan *machine learning Random Forest* di GEE (Sumber: Hasil penelitian, 2021)

### UCAPAN TERIMA KASIH

Ucapan terima kasih ditujukan kepada Saryono S.Si yang telah membantu dalam penyediaan data pendukung sehingga penelitian ini dapat diselesaikan dengan baik.

### DAFTAR PUSTAKA

- Effendi, E. (2008). *Kajian model pengelolaan daerah aliran sungai (DAS) terpadu*. Direktorat Kehutanan dan Konservasi Sumberdaya Air, Badan Perencanaan Pembangunan Nasional. Jakarta.
- Farda, N. M. (2017). Multi-temporal land use mapping of coastal wetlands area using machine learning in Google earth engine. *IOP Conference Series: Earth and Environmental Science*, 98(1). Doi:[10.1088/1755-1315/98/1/012042](https://doi.org/10.1088/1755-1315/98/1/012042).
- Farda, N. M. (2020). *Image classification – Machine learning*. Diakses pada 9 Julo 2021, dari [code.earthengine.google.com/?accept\\_r=epo=users/farda/EE03](http://code.earthengine.google.com/?accept_r=epo=users/farda/EE03).
- Fariz, T. R. (2019). Penilaian kerentanan fisik rumah terhadap longsor berdasarkan interpretasi foto udara format kecil di Sub DAS Bompon, Kabupaten Magelang [tesis, Universitas Gadjah Mada]. Digital Library.
- Fariz, T. R., & Nurhidayati, E. (2020). Mapping land coverage in the Kapuas Watershed using machine learning in Google Earth Engine. *Journal of Applied Geospatial Information*, 4(2), 390-395. Doi:[10.30871/jagi.v4i2.2256](https://doi.org/10.30871/jagi.v4i2.2256).
- Fariz, T. R., Permana, P. I., Daeni, F., Putra, A. C. P. (2021). Pemetaan ekosistem mangrove di Kabupaten Kubu Raya menggunakan machine learning pada Google Earth Engine. *Jurnal Geografi: Media Informasi Pengembangan dan Profesi Kegeografian*, 18(2).
- Fauzi, R. M. Z., & Maryono, M. (2016). Kajian erosi dan hasil sedimen untuk konservasi lahan DAS Kreo Hulu. *Jurnal Pembangunan Wilayah dan Kota*, 12(4), 429-445. Doi:[doi.org/10.14710/pwk.v12i4.13508](https://doi.org/10.14710/pwk.v12i4.13508).

- Gorelick, N. (2021). *Announcement: Old classifiers will stop working on March 1.* Diakses pada 2 Juli 2021, dari <http://goo.gle/deprecated-classifiers>.
- Hidayati, I. N. (2013). Pengaruh ketinggian dalam analisis kemasuk-akalan (plausibility function) untuk optimalisasi klasifikasi Penggunaan lahan. *Majalah Ilmiah Globe*, 15(1).
- Mateo-García, G., Gómez-Chova, L., Amorós-López, J., Muñoz-Marí, J., & Camps-Valls, G. (2018). Multitemporal cloud masking in the Google Earth Engine. *Remote Sensing*, 10(7), 1079. Doi:[doi.org/10.3390/rs10071079](https://doi.org/10.3390/rs10071079).
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817. Doi:[doi.org/10.1080/01431161.2018.1433343](https://doi.org/10.1080/01431161.2018.1433343).
- Pelletier, C., Valero, S., Inglada, J., Champion, N., & Dedieu, G. (2016). Assessing the robustness of Random forests to map land cover with high resolution satellite image time series over large areas. *Remote Sensing of Environment*, 187, 156-168.
- Perdana, A. P. (2018). *Tujuh DAS di Jawa Tengah kritis.* Diakses pada 2 Juli 2021, dari [kompas.id/baca/nusantara/2018/04/19/tujuh-das-di-jawa-tengah-kritis](https://kompas.id/baca/nusantara/2018/04/19/tujuh-das-di-jawa-tengah-kritis).
- Poongothai, S., Sridhar, N., & Shourie, R. A. (2014). Change detection of land use/land cover of a watershed using sremote sensing and GIS. *Inter. J. Engg. Adv. Tech*, 3(6), 226-230.
- Saraswati, G. F., Suprayogi, A., & Amarrohman, F. J. (2017). Analisis perubahan tutupan lahan Das Blorong terhadap peningkatan debit maksimum Sungai Blorong Kendal. *Jurnal Geodesi Undip*, 6(2), 90-98.
- Setyowati, D. L., Amin, M., Suharini, E., & Pigawati, B. (2012). Model agrokonservasi untuk perencanaan pengelolaan Das Garang Hulu. *TATALOKA*, 14(2), 131-141. Doi:[doi.org/10.14710/tataloka.14.2.131-141](https://doi.org/10.14710/tataloka.14.2.131-141).
- Shelestov, A., Lavreniuk, M., Kussul, N., Novikov, A., & Skakun, S. (2017). Exploring Google Earth Engine platform for big data processing: Classification of multi-temporal satellite imagery for crop mapping. *Frontiers in Earth Science*, 5, 17. Doi:[doi.org/10.3389/feart.2017.00017](https://doi.org/10.3389/feart.2017.00017).
- Shih, H. C., Stow, D. A., & Tsai, Y. H. (2019). Guidance on and comparison of machine learning classifiers for Landsat-based land cover and land use mapping. *International Journal of Remote Sensing*, 40(4), 1248-1274. Doi:[doi.org/10.1080/01431161.2018.1524179](https://doi.org/10.1080/01431161.2018.1524179).
- Silitonga, Y. T., Sulardiono, B., & Purnomo, P. W. (2018). Peranan tata guna lahan bagian hulu terhadap kesuburan perairan pada Waduk Jatibarang, Semarang. *Management of Aquatic Resources Journal (MAQUARES)*, 7(1), 39-48. Doi:[doi.org/10.14710/marj.v7i1.22523](https://doi.org/10.14710/marj.v7i1.22523).
- Talukdar, S., Singha, P., Mahato, S., Pal, S., Liou, Y. A., & Rahman, A. (2020). Land-use land-cover classification by Machine learning classifiers for satellite observations—A review. *Remote Sensing*, 12(7), 1135. Doi:[doi.org/10.3390/rs12071135](https://doi.org/10.3390/rs12071135).
- Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S., & Brisco, B. (2020). Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, 152-170. Doi:[10.1016/j.isprsjprs.2020.04.001](https://doi.org/10.1016/j.isprsjprs.2020.04.001).
- Tassi, A., Gigante, D., Modica, G., Di Martino, L., & Vizzari, M. (2021). Pixel vs. object-based Landsat 8 data classification in Google Earth Engine using Random forest: The case study of Maiella National Park. *Remote Sensing*, 13(12), 2299. Doi:[doi.org/10.3390/rs13122299](https://doi.org/10.3390/rs13122299).
- Yu, Z., Di, L., Yang, R., Tang, J., Lin, L., Zhang, C., Sun, Z. (2019). Selection of Landsat 8 OLI band combinations for land use and land cover classification in 2019 8th International Conference on Agro-Geoinformatics. *Agro-Geoinformatics*. 1-5. Doi:[10.1109/Agro-Geoinformatics.2019.8820595](https://doi.org/10.1109/Agro-Geoinformatics.2019.8820595).