

IDENTIFIKASI AREA PERTAMBANGAN MENGGUNAKAN CITRA SATELIT LANDSAT DENGAN *MACHINE LEARNING* PADA *GOOGLE EARTH ENGINE* DI KECAMATAN CIPATAT, KABUPATEN BANDUNG BARAT

Denny Lumban Raja

Program Studi Teknologi Geologi, Politeknik Energi dan Pertambangan, Bandung

Email Penulis: denny.lumbanraja@esdm.go.id

Naskah Diterima: September 2023/Revisi: November 2023 /Disetujui: Desember 2023

ABSTRAK

Kegiatan pertambangan dan industri pertambangan kapur menimbulkan dampak positif dan negatif bagi masyarakat di Kecamatan Cipatat, Kabupaten Bandung Barat. Kemajuan teknologi dalam analisis citra satelit semakin mengarah pada pemanfaatan *cloud computing* dan *big data* seperti dalam implementasi *Google Earth Engine* (GEE) dalam klasifikasi lahan. Pengambilan keputusan yang cepat perlu didukung oleh penyajian data yang cepat dan akurat pula. Melalui teknologi *machine learning* maka permasalahan tersebut menjadi salah satu solusi yang tepat. Tujuan dari penelitian ini adalah untuk mengidentifikasi lahan pertambangan menggunakan *machine learning* di Kecamatan Cipatat, Kabupaten Bandung Barat. Metode yang digunakan adalah analisis klasifikasi terbimbing dengan algoritma *Classification and Regression Trees* (CART) dan *Random forest* menggunakan GEE. Hasil penelitian menunjukkan luas area dari masing-masing algoritma yaitu sebesar 8.178 Km² atau 6,8% dan 20.959 Km² atau 17,62%. Nilai *overall accuracy* dengan algoritma *random forest* lebih baik yaitu sebesar 93.2% dibandingkan dengan algoritma CART yaitu sebesar 91.5 %. Hasil penelitian ini dapat digunakan dalam pemantauan perkembangan area pertambangan dan sebagai salah satu pertimbangan dalam pengambilan kebijakan pada kegiatan pertambangan oleh pemerintah Kabupaten Bandung Barat, Jawa Barat.

Kata kunci: area pertambangan, Google Earth Engine, Random Forest, Classification and Regression Trees (CART)

ABSTRACT

The mining activities and limestone mining industry have both positive and negative impacts on the community in the Cipatat District, West Bandung Regency. The advancement of technology in satellite image analysis is increasingly leading to the utilization of cloud computing and big data, as seen in the implementation of Google Earth Engine (GEE) in land classification. Fast decision-making requires the support of rapid and precise data presentation. Through machine learning technology, this problem becomes one of the appropriate solutions. The objective of this research is to identify mining areas using machine learning in the Cipatat District, West Bandung Regency. The method used involves supervised classification analysis with the Classification and Regression Trees (CART) algorithm and Random Forest using GEE. The research results indicate that the area coverage of each algorithm is 8.178 km² or 6.8% and 20.959 km² or 17.62%, respectively. The overall accuracy value result with the Random Forest algorithm is better with an accuracy rate of 93.2% compared to the CART algorithm, which is 91.5%. The results of this study can be applied for monitoring the development of mining areas and serve as one of the considerations in policy-making related to mining activities by the West Bandung Regency government in West Java.

Keywords: mining area, Google Earth Engine, Random Forest, Classification and Regression Trees (CART)

PENDAHULUAN

Potensi sumber daya alam di Kabupaten Bandung Barat sangat besar dan dapat dikembangkan serta dimanfaatkan untuk kesejahteraan masyarakat di sekitarnya, khususnya pertambangan bahan galian C. Terdapat beberapa jenis bahan galian yang terdapat di Kecamatan Cipatat, Kabupaten Bandung Barat diantaranya yaitu andesit, kuarsa, marmer, dan kapur. Kecamatan Cipatat memiliki bentang alam Karst atau morfologi karst yang berada pada batu gamping formasi Rajamandala.

Kegiatan pertambangan di daerah penelitian selain dapat memberikan dampak positif bagi masyarakat seperti salah satu mata pencaharian masyarakat tetapi dapat juga memberikan dampak lain yang merugikan, utamanya wilayah tanah bekas galian bahan tambang yang sudah tidak aktif dan dibiarkan terlantar (Faikar & Chamid, 2020). Hal tersebut dapat mengakibatkan bencana longsor, penurunan kualitas air, pencemaran udara, dan kualitas lahan.

Pengambilan keputusan terhadap suatu masalah memerlukan data yang disajikan secara cepat, akurat, dan mudah. Hal tersebut hanya dapat dilakukan dengan bantuan teknologi salah satunya melalui *machine learning*. Beberapa penulis telah memanfaatkan teknologi tersebut salah satunya untuk mengidentifikasi perubahan wilayah bekas tambang di suatu daerah ((Catur et al., 2015; Nugroho et al., 2019)).

Pada era Industri 4.0 yang sedang berlangsung, kebutuhan untuk mengolah data citra dalam jumlah besar guna mendapatkan informasi secara cepat telah mendorong perkembangan teknologi penginderaan jauh ke arah pengolahan data berbasis internet atau *cloud computing*. Salah satu teknologi penginderaan jauh baru dalam pemanfaatan *big data* berbasis *cloud computing* untuk menyediakan data dan fasilitas pengolahan spasial dari citra satelit yaitu *Google earth engine* (GEE). GEE yang baru diluncurkan pada tanggal 2 Desember 2010 oleh Perusahaan Google merupakan platform analisis geospasial yang telah banyak digunakan didalam bermacam penelitian seperti analisis tata guna lahan (Fu & Zhang, 2022; Julianto et al., 2020; Novianti, 2021; Rizaldi et al., 2022; Zurqani et al., 2018), kebencanaan seperti gerakan tanah (Ilmy et al., 2021; Wu et al., 2022).

Melalui GEE, pengguna tidak perlu melakukan pengunduhan data citra yang besar sehingga dapat mengefisienkan waktu dan kapasitas penyimpanan. Kemampuannya dalam pengolahan data yang dikerjakan oleh server GEE membuat para pengguna tidak membutuhkan spesifikasi komputer yang tinggi dan aplikasi pengolah data pendinderaan jauh. Para pengguna cukup mengaksesnya melalui browser dan koneksi internet yang stabil. GEE menyediakan data citra mentah dengan historikal yang lengkap sesuai yang dibutuhkan pengguna dan disediakan fasilitas pengunduhan data raster maupun vektor.

Landsat-8 merupakan evolusi dari program Landsat 7, terlihat dari karakteristiknya, termasuk resolusi spasial, temporal, spektral, metode koreksi, ketinggian penerbangan, dan jenis sensor yang digunakan. Satelit Landsat dilengkapi dengan dua jenis sensor, yaitu *Operational Land Imager* (OLI) dan *Thermal Infrared Sensor* (TIRS), yang memiliki berbagai resolusi spasial, mulai dari 30 meter untuk berbagai panjang gelombang seperti visible, NIR, SWIR, hingga 100 meter untuk panjang gelombang termal, serta 15 meter untuk fitur tertentu.

Teknologi penginderaan jauh sudah banyak digunakan dalam mengklasifikasikan suatu lahan di permukaan bumi dengan cepat, tepat, dan mudah. Algoritma yang digunakan dalam melakukan klasifikasi juga terus berkembang seperti SVM (Support Vector Machine), *Classification and Regression Trees* (CART), *Random forest* (RF) dan metode klasifikasi lainnya. Selain untuk mengklasifikasikan tata guna lahan, *Classification and Regression Trees* (CART) telah digunakan di bidang kesehatan yaitu melakukan klasifikasi rekurensi Pasien Kanker Serviks (Sumartini, 2015). Beberapa peneliti telah memanfaatkan algoritma CART dan mampu mengklasifikasikan dengan tingkat akurasi yang sangat baik (Feizizadeh et al., 2023; Komariah et al., n.d.; Purnamawati et al., 2022). Tujuan utama CART menurut Breiman (dalam (Sumartini, 2015)) adalah untuk mencapai hasil klasifikasi yang tepat, diperlukan kelompok data yang akurat sebagai representasinya.

Pada tahun 2001, Breiman (Breiman, 2001) memperkenalkan *Random forest* (RF) dalam teknik bagging. Menurutny, *random forest* merupakan sebuah algoritma yang mampu mengatasi *missing data*, mampu memberikan hasil klasifikasi dengan tingkat kesalahan yang lebih rendah, dan mampu mengatasi volume data yang besar (Breiman, 2001). Beberapa penelitian menunjukkan *random forest* memiliki nilai akurasi yang tinggi (Fu & Zhang, 2022; Junus et al., 2023; Teluguntla et al., 2018; Vergni & Todisco, 2023).

Perubahan lahan pertambangan yang begitu masif di Kabupaten Bandung Barat, memaksa pemerintah daerah harus secara cepat dalam pengambilan kebijakan sesuai dengan dampak positif dan negatifnya. Teknologi *machine learning* dengan memanfaatkan *platform* GEE dalam menganalisis perubahan lahan pertambangan di Kabupaten Bandung belum pernah dilakukan peneliti lain sebelumnya.

Telah banyak yang memanfaatkan platform *Google earth engine* (GEE) dalam melakukan klasifikasi penggunaan lahan dengan memanfaatkan algoritma *machine learning* seperti *Random forest* (RF) dan *Classification and Regression Trees* (CART). Kedua algoritma tersebut digunakan untuk melakukan perbandingan yang komprehensif terhadap kemampuan masing-masing algoritma dengan menggunakan kelas tutupan, citra satelit, dan sampel pelatihan yang identik (Putri et al., 2022; Rizaldi et al., 2022).


Pada penelitian sebelumnya menggunakan citra satelit Landsat – 8 dengan cara membuat komposit band 753 untuk mengidentifikasi kawasan pertambangan Timah dengan menggunakan algoritma supervised maximum likelihood. Metode tersebut digunakan untuk mengklasifikasikan tambang timah dan bukan tambang timah dengan nilai total akurasi sebesar 85% (Nugroho et al., 2019).

Melalui perkembangan teknologi khususnya penginderaan jauh dan memanfaatkan *machine learning* maka kegiatan evaluasi terhadap perubahan lahan pertambangan dapat dilakukan secara cepat dan akurat.

Adapun tujuan dari penelitian ini adalah mengidentifikasi perubahan lahan pertambangan menggunakan *machine learning* di Kecamatan Cipatat, Kabupaten Bandung Barat. Diharapkan melalui penelitian ini dapat menjadi salah satu alternatif teknologi dalam pengambilan keputusan dalam perubahan lahan pertambangan oleh pemerintah daerah Kabupaten Bandung Barat.


METODOLOGI

Lokasi penelitian adalah area pertambangan di Kecamatan Cipatat, Kabupaten Bandung Barat, Propinsi Jawa Barat. Secara geografis berada pada batas koordinat $107^{\circ}18'57.9528''$ BT - $107^{\circ}27'14.6916''$ BT dan $-6^{\circ}46'3.1512''$ LS - $-6^{\circ}53'27.1032''$ LS (Gambar 1).



Gambar 1 Daerah Penelitian Kecamatan Cipatat (Sumber: Citra *Landsat* 2017)

Alur penelitian ini seperti digambarkan pada gambar 2 dibawah ini. Studi literatur dilakukan pada awal kegiatan penelitian untuk mengetahui perkembangan terakhir mengenai topik penelitian yang dilakukan.



Gambar 2 Alur penelitian

Data citra satelit Landsat tahun 2017 didapat dari *google earth engine* dan sebagai bahan ground check dari model klasifikasi yang telah dibuat maka dilakukan observasi lapangan berupa foto dokumentasi.

Data citra satelit Landsat dilakukan seleksi berdasarkan citra satelit yang bebas dari tutupan awan dengan menggunakan cloud masking berdasarkan filter tanggal 1 Januari – 31 Desember 2017. Selanjutnya melakukan pemotongan dari citra Landsat tersebut sesuai dengan daerah penelitian/area of interest (AOI)). Training sampel dilakukan pada lokasi lahan pertambangan, pemukiman dan vegetasi di daerah penelitian. Hasil training sample tersebut kemudian digunakan 70% untuk sample training dan 30% untuk data validation.

Klasifikasi dilakukan dengan menggunakan citra satelit Landsat melalui kombinasi band yaitu band 7,5,3. Sedangkan untuk klasifikasi lahan pertambangan menggunakan algoritma *Random forest* (RF) dan *Classification and Regression Trees* (CART) berdasarkan data training sample yang telah diambil. Setelah dilakukan klasifikasi kemudian dihitung luas area yang dihasilkan dari kedua algoritma tersebut.

Classification and Regression Trees (CART) merupakan suatu algoritma yang sama dari suatu banyak pohon keputusan (decision tree). CART dikenal juga sebagai algoritma statistik nonparametrik yang dapat digambarkan sebagai variable respon dengan melibatkan satu atau bisa lebih variable predictor atau variable independent. CART adalah suatu teknik yang dirancang untuk menghasilkan representasi keputusan dalam bentuk pohon biner dengan memisahkan data pada sampel pembelajaran berdasarkan satu variabel tunggal (Komariah et al., n.d.).

RF adalah algoritma yang beroperasi dengan membuat sejumlah besar pohon keputusan dimana kelas sampel dan akan dilakukan *voting* untuk menentukan kelas dari semua dataset (Azhar & Pardede, 2021).

Langkah selanjutnya melakukan pengujian terhadap hasil klasifikasi dari penelitian ini dengan cara melakukan *confusion matrix*, *overall classification accuracy* dan *Kappa coefficient*. Akurasi klasifikasi dilakukan untuk mengetahui ketepatan klasifikasi secara keseluruhan. Semakin tinggi nilai akurasi klasifikasinya maka semakin optimal kinerja teknik klasifikasinya. Pengujian akurasi menggunakan metode *confusion matrix* yaitu untuk membandingkan hasil klasifikasi yang dihasilkan oleh sistem dengan hasil klasifikasi yang diharapkan. Nilai koefisien Kappa digunakan sebagai indikator tingkat konsistensi akurasi dalam hasil klasifikasi. Semakin tinggi nilai kappa, maka tingkat kepercayaan terhadap akurasi pengujian yang ditunjukkan juga semakin tinggi.

HASIL DAN PEMBAHASAN

a. Klasifikasi Area Pertambangan

Tingkat Akurasi dari klasifikasi lahan pertambangan training area dengan sample sebesar 70% dan validasi 30% menunjukkan bahwa *machine learning* dengan platform *Google earth engine* dapat mengklasifikasikan lokasi pertambangan dengan baik. Hal tersebut ditunjukkan dengan

IDENTIFIKASI AREA PERTAMBANGAN MENGGUNAKAN CITRA SATELIT LANDSAT DENGAN *MACHINE LEARNING* PADA *GOOGLE EARTH ENGINE* DI KECAMATAN CIPATAT, KABUPATEN BANDUNG BARAT

tingkat akurasi keseluruhan dari masing-masing algoritma yang digunakan yaitu CART sebesar 0.932% dan *Random forest* (RF) sebesar 0.915% dengan masing-masing nilai Kappa coefficient sebesar 0.826 dan 0.866 (Tabel 1). Untuk pembuktian dari model klasifikasi yang telah dibuat menggunakan kedua algoritma tersebut maka dilakukan pembuktian dilapangan. Gambar 3 berikut menunjukkan salah satu perusahaan pertambangan di Kecamatan Cipatat.



Gambar 3 Area Pertambangan di Kecamatan Cipatat


Berdasarkan klasifikasi lahan pertambangan, vegetasi, dan pemukiman dengan menggunakan algoritma CART dan RF dilakukan perhitungan luasan areanya pada tahun 2017 yang ditunjukkan pada tabel dibawah ini. Berdasarkan tabel tersebut diatas dapat dilihat perbedaan luasan setiap klasifikasi yang dihasilkan dari CART dan RF cukup signifikan. Luas area pertambangan dengan menggunakan CART sebesar 102.264 Km² atau 85.188% sedangkan menggunakan RF dihasilkan sebesar 83.705 Km² atau 70.35% (Gambar 4).

Tabel 1. Hasil klasifikasi menggunakan CART dan RF

Jenis Klasifikasi	CART		<i>Random forest</i>	
	Area (Km ²)	Area (%)	Area (Km ²)	Area (%)
Vegetasi	102.264	85,18	83.705	70,35
Pertambangan	8.178	6,81	20.959	17,62
Permukiman	9.603	8,01	14.316	12,03
<i>Overall accuracy</i>	0.915		0.932	
<i>Kappa Coefficient</i>	0.826		0.866	

b. Uji Tingkat Akurasi

Hasil tingkat akurasi dari klasifikasi terbimbing dengan algoritma *Random forest* dan CART menunjukkan perbedaan yang tidak terlalu signifikan. Algoritma CART menunjukkan tingkat akurasi yang lebih kecil dari pada *Random forest* yaitu 0.915 dan 0.932 dengan masing-masing nilai kappa adalah 0.826 dan 0.866. Menurut Firmansyah, jika dibandingkan dengan CART, RF memerlukan lebih sedikit sampel, sehingga RF memiliki kinerja pemrosesan keputusan yang lebih baik (Timur, 2019).



Gambar 4. Hasil klasifikasi area pertambangan dengan (a) Algoritma CART dan (b) *Random forest*

Menurut Altman (dalam (Nugroho et al., 2019)), nilai kappa yang diperoleh dari hasil klasifikasi berdasarkan pendekatan objek dengan menggunakan *machine learning* CART maupun RF memiliki tingkat kesamaan sangat kuat dengan rentang nilai 0.81 – 1.00.

Tabel 2. Keterangan kualitatif nilai kappa

Kappa	Keterangan Kesamaan
< 0.20	Rendah (<i>Poor</i>)
0.21 - 0.40	Lumayan (<i>Fair</i>)
0.41 - 0.60	Cukup (<i>Moderate</i>)
0.61 - 0.80	Kuat (<i>Good</i>)
0.81 – 1.00	Sangat Kuat (<i>Very Good</i>)

Sumber: Altman, 1991

Dari hasil penelitian ini, diharapkan dapat digunakan sebagai salah satu metode dalam pemantauan perkembangan area pertambangan dan juga menjadi salah satu pertimbangan yang relevan dalam pengambilan kebijakan pada kegiatan pertambangan oleh pemerintah Kabupaten Bandung Barat, Jawa Barat.

KESIMPULAN

Berdasarkan penelitian ini, pendekatan berbasis objek dengan menggunakan algoritma *machine learning* mampu mendeteksi lahan pertambangan secara cepat dan akurat. Klasifikasi menggunakan *Random forest* (RF) dapat mencapai akurasi yang lebih tinggi dibandingkan dengan *Classification and Regression Trees* (CART) karena dapat mengurangi kesalahan dalam menganalisis citra Landsat-8 dengan menghasilkan *overall accuracy* sebesar 93.2% dengan nilai Kappa sebesar 0.866. Luas area pertambangan yang diperoleh menggunakan

CART adalah sebesar 8.178 Km² atau 6,8% sedangkan menggunakan *Random forest* diperoleh area pertambangan lebih luas yaitu sebesar 20.959 Km² atau 17,62%.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Politeknik Energi dan Pertambangan Bandung dan seluruh pihak yang telah memberikan saran dan masukan selama berjalannya penelitian ini.

DAFTAR PUSTAKA

- Azhar, M., & Pardede, H. F. (2021). Klasifikasi Dialek Pengujar Bahasa Inggris Menggunakan Random Forest. *Jurnal Media Informatika Budidarma*, 5(2), 439. <https://doi.org/10.30865/mib.v5i2.2754>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Catur, U., Yudhatama, D., & Mukhoriyah. (2015). Identifikasi Lahan Tambang Timah Menggunakan Metode Klasifikasi Terbimbing Maximum Likelihood Pada Citra Landsat 8. *Majalah Ilmiah Globe Volume*, 17(1), 9–15. www.bdpjn-catalog.lapan.go.id
- Faikar, F. A., & Chamid, C. (2020). Kajian Dampak Kegiatan Industri Pertambangan Batu Gamping di Desa Citatah Kecamatan Cipatat Kabupaten Bandung Barat. *Prosiding Perencanaan Wilayah Dan Kota*, 6 No.1, 43–53.
- Feizizadeh, B., Omarzadeh, D., Kazemi Garajeh, M., Lakes, T., & Blaschke, T. (2023). Machine learning data-driven approaches for land use/cover mapping and trend analysis using Google Earth Engine. *Journal of Environmental Planning and Management*, 66(3), 665–697. <https://doi.org/10.1080/09640568.2021.2001317>
- Fu, Y., & Zhang, Y. (2022). Research on temporal and spatial evolution of land use and landscape pattern in Anshan City based on GEE. *Frontiers in Environmental Science*, 10(August), 1–17. <https://doi.org/10.3389/fenvs.2022.988346>
- Ilmy, H. F., Darminto, M. R., & Widodo, A. (2021). Application of Machine Learning on Google Earth Engine to Produce Landslide Susceptibility Mapping (Case Study: Pacitan). *IOP Conference Series: Earth and Environmental Science*, 731(1). <https://doi.org/10.1088/1755-1315/731/1/012028>
- Julianto, F. D., Putri, D. P. D., & Safi'i, H. H. (2020). Analisis Perubahan Vegetasi dengan Data Sentinel-2 Menggunakan Google Earth Engine. *Jurnal Penginderaan Jauh Indonesia*, 02(02), 13–18. <http://jurnal.mapin.or.id/index.php/jpji/article/view/29>
- Junus, C. Z. V., Tarno, T., & Kartikasari, P. (2023). Klasifikasi Menggunakan Metode Support Vector Machine Dan Random Forest Untuk Deteksi Awal Risiko Diabetes Melitus. *Jurnal Gaussian*, 11(3), 386–396. <https://doi.org/10.14710/j.gauss.11.3.386-396>
- Komariah, N., Nugroho, S., & Rizal, J. (n.d.). Classification and Regresssion Tree (CART) Analysis Pada Penderita Skizofrenia di RSJKO Soeprpto Daerah Bengkulu. *Universitas Bengkulu, Jurnal Statistik*, 1–15.
- Novianti, T. C. (2021). Klasifikasi Landsat 8 OLI Untuk Tutupan Lahan Di Kota Palembang Menggunakan Google Earth Engine. *Jurnal Swarnabhumi*, 6(1), 75–85. <http://code.earthengine.google.com/>
- Nugroho, U. C., Kushardono, D., & Dewi, E. K. (2019). Identifikasi Kawasan Pertambangan Timah Menggunakan Data Satelit Sentinel – 1 dengan Metode Object Based Image Analysis (OBIA). *Jurnal Ilmu Lingkungan*, 17(1), 140. <https://doi.org/10.14710/jil.17.1.140-148>
- Purnamawati, A., Winnarto, M. N., & Mailasari, M. (2022). Analisis Cart (Classification and Regression Trees) Untuk Prediksi Pengguna Sepeda Berdasarkan Cuaca. *Jurnal*

- Teknoinfo*, 16(1), 14. <https://doi.org/10.33365/jti.v16i1.1478>
- Putri, A. R., Purnamasari, R., & Edwar. (2022). *Perbandingan Metode Klasifikasi Pemetaan Tutupan Lahan Menggunakan Algoritma Machine Learning Pada Citra Satelit Dengan Google Earth Engine Mapping Land Cover Classification Using Machine Learning Comparison of Satellite Images with Google Earth Engine*. 8(6), 37–53.
- Rizaldi, A., Darmawan, A., Kaskoyo, H., & Setiawan, A. (2022). Pemanfaatan google earth engine untuk pemantauan lahan agroforestri dalam skema perhutanan sosial. *Majalah Geografi Indonesia*, 37(1), 12. <https://doi.org/10.22146/mgi.73923>
- Sumartini, S. H. (2015). Penggunaan Metode Classification and Regression Trees (CART) untuk Klasifikasi Rekurensi Pasien Kanker Serviks di RSUD Dr. Soetomo Surabaya. *Jurnal Sains Dan Seni ITS*, 4(2), 211–216.
- Teluguntla, P., Thenkabail, P., Oliphant, A., Xiong, J., Gumma, M. K., Congalton, R. G., Yadav, K., & Huete, A. (2018). A 30-m landsat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform. *ISPRS Journal of Photogrammetry and Remote Sensing*, 144(February), 325–340. <https://doi.org/10.1016/j.isprsjprs.2018.07.017>
- Timur, L. (2019). Perbandingan Klasifikasi SVM dan Decision Tree untuk Pemetaan Mangrove Berbasis Objek Menggunakan Citra Satelit Sentinel-2B di Gili Sulat, Lombok Timur. *Jurnal Pengelolaan Sumberdaya Alam Dan Lingkungan (Journal of Natural Resources and Environmental Management)*, 9(3), 746–757. <https://doi.org/10.29244/jpsl.9.3.746-757>
- Vergni, L., & Todisco, F. (2023). A Random Forest Machine Learning Approach for the Identification and Quantification of Erosive Events. *Water (Switzerland)*, 15(12). <https://doi.org/10.3390/w15122225>
- Wu, W., Zhang, Q., Singh, V. P., Wang, G., Zhao, J., Shen, Z., & Sun, S. (2022). A Data-Driven Model on Google Earth Engine for Landslide Susceptibility Assessment in the Hengduan Mountains, the Qinghai–Tibetan Plateau. *Remote Sensing*, 14(18). <https://doi.org/10.3390/rs14184662>
- Zurqani, H. A., Post, C. J., Mikhailova, E. A., Schlautman, M. A., & Sharp, J. L. (2018). Geospatial analysis of land use change in the Savannah River Basin using Google Earth Engine. *International Journal of Applied Earth Observation and Geoinformation*, 69(December 2017), 175–185. <https://doi.org/10.1016/j.jag.2017.12.006>