



Klasifikasi Citra *Sentinel* melalui *Google Earth Engine* dengan menggunakan algoritma *Machine Learning XGBoost*

Gregorius Anung Hanindito¹, Adi Wibowo², Budi Warsito³

¹. Sekolah Pascasarjana, Universitas Diponegoro, Universitas Antakusuma

²Departemen Informatika, Fakultas Sains dan Matematika, Universitas Diponegoro

³Departemen Statistika, Fakultas Sains dan Matematika, Universitas Diponegoro

Email : gregoriusanung@students.undip.ac.id, adiwibowo@lecturer.undip.ac.id,
budiwarsitoundip@gmail.com

Abstrak

Remote sensing technology and Geographic Information Systems (GIS) have rapidly evolved to provide extensive data and information on land cover. This study aims to monitor land cover in Tanjung Keluang Nature Tourism Park (TWA) and its surroundings using Sentinel satellite imagery on the Google Earth Engine (GEE) platform, employing the XGBoost machine learning algorithm. The methods involved acquiring Sentinel satellite imagery, pre-processing for geometric correction, developing training and testing datasets, as well as performing classification and accuracy evaluation. The results indicate that the XGBoost algorithm can classify land cover into several categories with an accuracy of up to 98%. The classified land cover includes water bodies (23,346 Ha), open land (9,680.54 Ha), sand mining areas (931.15 Ha), and vegetation (16,596.84 Ha). This study contributes positively to the management of conservation areas, particularly in supporting decision-making for TWA Tanjung Keluang in the future.

This is an open access article under the [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) license



Kata Kunci: *Remote sensing; machine learning; XGBoost*

Riwayat Artikel:

Diserahkan 15 Desember 2024

Direvisi 13 Nopember 2025

Diterima 27 Maret 2026

DOI:

10.22441/incomtech.v16i1.31354

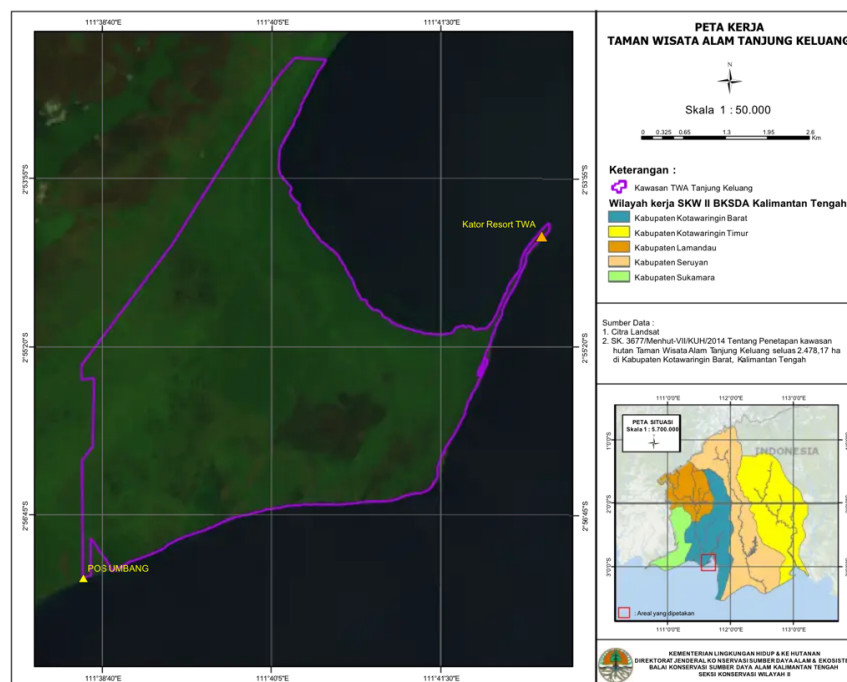
1. PENDAHULUAN

Teknologi penginderaan jauh dan sistem informasi geografis secara bersama-sama telah berkembang dan secara mudah menyediakan data dan informasi tutupan lahan dalam setiap kurun waktu tertentu. Salah satunya adalah citra satelit Landsat yang merupakan program pengamatan bumi yang telah berjalan kurang lebih 5 (lima) dekade [1]. Selain itu data hasil penginderaan jauh dapat memberikan data dalam resolusi yang tinggi pada kurun waktu tertentu serta dengan biaya yang relatif terjangkau [2]. Data hasil pengindraan jauh yang telah tersedia dapat diproses

dan didokumentasikan agar mendapatkan hasil analisis yang sesuai dengan apa yang diharapkan [3]. Data penginderaan jauh tersebut dapat dimanfaatkan bagi berbagai macam kebutuhan yang meliputi: pertanian, pemetaan penggunaan lahan, pariwisata, pemantauan lingkungan, bahkan hingga merambah ke dunia militer [4]. Dengan menggunakan data-data yang tersedia, teknologi penginderaan jauh dan sistem informasi geografis dengan baik dapat melakukan proses analisis dan pemantauan penggunaan dan tutupan lahan (*land use-land cover*) [5]. Data yang umum digunakan dalam teknologi penginderaan jauh dan sistem informasi geografis berasal dari platform *Google Earth Engine* (GEE). Platform ini merupakan sebuah layanan penyedia kumpulan data geospasial *multi-petabyte* yang menyediakan dataset citra satelit (Landsat, Sentinel 1 dan 2) [6]. *Google Earth Engine* lebih sering digunakan dalam proses klasifikasi tutupan lahan dengan menggunakan algoritma *machine learning* hal ini dikarenakan *Google Earth Engine* dapat mengevaluasi citra satelit multisumber serta memiliki kinerja yang baik [7]. Penggunaan data penginderaan jauh dan sistem informasi geografis dapat dilakukan melalui pengolahan citra yang dapat dilakukan dengan metode klasifikasi [4]. Dalam proses klasifikasi, metode *machine learning* sudah sangat lazim digunakan, model yang dihasilkan melalui metode *machine learning* ini sudah sangat teruji dalam melakukan kinerja khususnya dalam proses klasifikasi gambar, sehingga beberapa peneliti telah menggunakan metode *machine learning* ini untuk melakukan proses analisis tutupan lahan [8]. Selain itu kualitas peta tutupan lahan (*land cover*) hasil penginderaan jauh dapat dikarakterisasikan menggunakan fitur spectral, statistic dan berbasis index. Fitur tersebut selanjutnya dapat dinilai dan diproses melalui algoritma machine learning (Aryal et al., 2023). Beberapa algoritma *machine learning* memiliki kemampuan yang cukup baik dalam melakukan analisis dataset geospasial dalam pemantauan tutupan lahan (*land cover*), beberapa algoritma yang dapat digunakan antara lain: *decision trees*, *random forests*, *support vector machines*, atau *neural networks* [10]. Dalam proses klasifikasi data spasial, algoritma *random forest* pada *machine learning* terbukti sangat baik dan akurat untuk mengidentifikasi tutupan lahan berupa area pertanian, hutan, dan area perkotaan [11]. Selain beberapa hal tersebut, penerapan kombinasi antara *Google Earth Engine* dengan beberapa algoritma machine learning yang meliputi CART, *Support Vector Machine* (SVM) dan *Random Forest* dapat menghasilkan peta klasifikasi tutupan lahan yang sangat baik dan cukup diandalkan (Zhao et al., 2024). Tingkat akurasi perubahan tutupan lahan bergantung pada akurasi proses klasifikasi yang dilakukan [13]. *Random forest* dan SVM dapat secara spesifik melakukan analisis terhadap perubahan tutupan hutan, hal ini disebabkan algoritma tersebut memiliki nilai yang tinggi untuk koefisien Kappa, sensitifitas dan akurasi [14]. Selain *Random forest* dan SVM, algoritma lain juga dapat digunakan dalam pengklasifikasian citra satelit bahkan memiliki performa yang lebih unggul dibandingkan algoritma tersebut. Dalam sebuah penelitian disebutkan bahwa algoritma XGBoost memiliki performa yang mengungguli *Random Forest* dalam pengklasifikasian citra tutupan lahan [15]. Dalam penelitian lain disebutkan bahwa XGBoost memiliki performa yang luar biasa dalam monitoring penyakit pada tanaman kentang (*Potato late blight*) dengan menggunakan citra Sentinel dan UAV [16].

Berdasarkan latar belakang tersebut, maka penelitian ini berfokus pada analisis tutupan lahan melalui citra satelit Sentinel di studi area Taman Wisata Alam (TWA)

Tanjung Keluang dan sekitarnya dengan menggunakan metode *machine learning*. Taman Wisata Alam (TWA) Tanjung Keluang merupakan wilayah konservasi yang terletak di Kecamatan Kumai, kabupaten Kotawaringin Barat [17]. Hal tersebut berdasarkan SK Menteri Kehutanan Nomor: 046/Kpts-II/1984 tanggal 12 Maret 1984 dengan luas wilayah mencapai 2.000 Ha [18]. TWA Tanjung Keluang ini memiliki berbagai macam potensi pariwisata yang meliputi: keanekaragaman flora dan fauna, dan wisata pantai [19]. Selain hal tersebut, TWA Tanjung Keluang juga dijadikan sebagai lokasi penangkaran dan peneluran Penyu Sisik (*Eretmochelys imbricata*) yang menjadi salah satu daya tarik wisata konservasi. Penyu sisik juga merupakan salah satu hewan yang dilindungi berdasarkan Surat Keputusan Menteri Kehutanan No. 882/Kpts-II/1992 dan Peraturan Menteri Lingkungan Hidup Dan Kehutanan No P. 92 Tahun 2019 Tentang Jenis Tumbuhan Dan Satwa Dilindungi [20]. Berikut merupakan peta lokasi wilayah Taman Wisata Alam Tanjung Keluang. TWA Tanjung Keluang ini memiliki karakteristik berupa hamparan pasir putih, dengan tumbuhan khas seperti bakau, padada, nipah, pandan laut, cemara laut, kelapa dll [18].



Gambar 1. Peta Taman Wisata Alam Tanjung Keluang

Gambar 1 tersebut merupakan peta lokasi wilayah TWA Tanjung Keluang melalui citra satelit Landsat. Berdasarkan gambar tersebut, luas wilayah TWA Tanjung Keluang adalah sebesar 2.478,17 Ha. Meskipun Tanjung Keluang merupakan wilayah konservasi yang menyimpan berbagai macam potensi, sayangnya di beberapa wilayah sekitar TWA Tanjung Keluang terjadi kerusakan ekosistem akibat aktifitas manusia berupa perkebunan, pertambangan serta pembangunan. Berdasarkan latar belakang tersebut di atas, melalui penelitian ini akan dilakukan analisis pemantauan terhadap lahan di sekitar TWA Tanjung Keluang. Pemantauan ini dilakukan dengan menggunakan citra satelit Sentinel

melalui *Google Earth Engine (GEE)* dan selanjutnya dianalisis dengan menggunakan metode *machine learning* dengan algoritma *XGBoost*. Metode ini digunakan sebab dalam penelitian sebelumnya telah dijelaskan bahwa *XGBoost* memiliki keunggulan dalam melakukan klasifikasi citra penginderaan jarak jauh, sehingga diharapkan hasil klasifikasi citra memiliki tingkat akurasi yang baik. Selanjutnya hasil penelitian ini dapat dimanfaatkan bagi para aparat terkait dalam pengambilan kebijakan di masa yang akan datang terkait dengan pemanfaatan wilayah konservasi khususnya di TWA Tanjung Keluang.

2. METODE

Klasifikasi citra satelit mencakup evaluasi citra dengan penerapan aturan statistik dalam menentukan identitas tutupan lahan setiap piksel dalam suatu citra [21]. Dalam penelitian ini algoritma yang digunakan dalam proses klasifikasi citra satelit adalah algoritma *XGBoost* dengan tahapan sebagai berikut.



Gambar 2. Diagram alir Penelitian

Gambar 2 berikut merupakan diagram alir dalam penelitian yang meliputi sebagai berikut:

1. *Akuisisi Data*.
Dalam proses akuisisi data, dataset yang digunakan diperoleh melalui *Google Earth Engine* dan dengan menggunakan citra satelit Sentinel.
2. *Pra-processing*
Data *pra-prosesesing* dilakukan dengan menggunakan aplikasi *QGIS* yang dimaksudkan untuk melakukan koreksi geometrik, radiometrik, dan

atmosferik yakni dengan membersihkan data dari gangguan seperti distorsi geometrik, pengaruh atmosfer, dan kesalahan radiometrik.

3. Pembuatan Data untuk Pelatihan dan Pengujian

Selanjutnya, data dipecah menjadi dua kategori yang meliputi:

- Data untuk pelatihan model.
- Data untuk pengujian model.

4. Ekstraksi Fitur

Fitur diekstraksi dari data citra menggunakan raster library dalam hal ini menggunakan aplikasi *Google Collab*.

5. Klasifikasi dan Penilaian Akurasi

Proses klasifikasi dilakukan dengan menggunakan algoritma *Extreme Gradient Boosting (XGBoost)*. Selanjutnya hasil klasifikasi dievaluasi melalui *accuracy assessment* untuk mengukur kinerja model yang dibuat.

XGBoost merupakan algoritma yang menggunakan pendekatan melalui Teknik boosting, dengan menggabungkan pohon keputusan yang sederhana biasanya berupa model yang lemah menjadi model yang sangat kuat (strong learner) [22].

Pada metode ini diperlukan fungsi objektif yang berfungsi untuk menilai keakuratan model yang dibangun dengan menggunakan training data. Hal ini dapat diformulasikan sebagai berikut.

$$obj(\theta) = L(\theta) + \Omega(\theta)$$

L merupakan fungsi latih yang hilang sedangkan Ω merupakan fungsi regularisasi dan selanjutnya θ adalah parameter model terkait.

$$L(\theta) = \sum_{i=1}^n l(y_i - \hat{y}_i)$$

y_i adalah nilai data sebenarnya yang dianggap benar dan \hat{y}_i adalah hasil nilai prediksi dari model, sedangkan n adalah jumlah iterasi nilai dari model [23].

3. HASIL DAN PEMBAHASAN

a. Akuisisi Data

Seperti telah disampaikan sebelumnya bahwa penelitian ini menggunakan data citra Sentinel yang diakses melalui *Google Earth Engine*. Proses pengambilan data dilakukan dengan menggunakan aplikasi google collab dengan code sebagai berikut:

```
[ ] # additional library
!pip install pycrs

Requirement already satisfied: pycrs in /usr/local/lib/python3.10/dist-packages (1.0.2)

[ ] # Melakukan autentikasi dan mendefinisikan Google Cloud Project yang akan digunakan
ee.Authenticate()
ee.Initialize(project='ee-geosoftware-anung') #ganti dengan nama Google Cloud Project anda

# Menambahkan basemap
m = geemap.Map()
m
```

Gambar 3. Perintah dalam pembuatan project pada Google Earth Engine

Dalam Gambar 3 tersebut disebutkan bahwa dilakukan pembuatan project baru pada google earth engine dengan nama ee-geosoftware-anung, yang akan menampilkan citra yang selanjutnya akan dicrop sesuai dengan area of interest (AoI) yang dipilih. Gambar 4 berikut menunjukkan code untuk memanggil area of interest ke dalam GEE project.

```
[16] # Memasukkan shapefile AOI dan mengubahnya kedalam earth engine object
AOI_ee = geemap.shp_to_ee("/content/drive/MyDrive/PENGOLAHAN CITRA SATELIT Tj Puting/DATA/Geosoftware_Python_Raster/GOC1/Data/tanjung_keluang.shp")
AOI_ee = AOI_ee.geometry()

[17] AOI_ee
Polygon (5 vertices)

# Menambahkan AOI Kedalam Peta GEEMAP
m.addLayer(AOI_ee, {}, "AOI_geosoftware")
m.centerObject(AOI_ee, 9) #Set zoom in
m
```

Gambar 4. Perintah penginputan AoI dalam google earth engine

Dari penginputan tersebut, menghasilkan citra sentinel dengan area of interest seperti pada Gambar 5 berikut:



Gambar 5. Citra Satelit Sentinel sesuai dengan area of interest

- b. Pembuatan Training dan testing data
Pembuatan data training ini dilakukan pada aplikasi QGIS dengan menggunakan data raster citra *Sentinel* yang telah disesaukan dengan area

of interest. Pembuatan *data training* dan *data test* ini dilakukan dengan membuat *training site* berupa *dot/polygon* pada data raster area of interest. Setiap *dot/polygon* tersebut diklasifikasikan berdasarkan nilai piksel yang dimiliki oleh data *raster*. Dalam penelitian ini terdapat 4 (empat) buah kelas yang akan mewakili kenampakan citra pada area of interest TWA Tanjung Keluang. Masing masing citra akan diwakili setidaknya 110 buah *training site*, sehingga jumlah total *training site* yang terdapat pada citra *area of interest* TWA Tanjung Keluang adalah sebanyak 440 buah. Berikut merupakan Gambar pembuatan *training Site* pada citra raster *area of interest*.



Gambar 6. Pembuatan data training dan test pada QGIS

Selanjutnya data training dan data test dipisahkan dengan komposisi 80% digunakan sebagai data training dan 20% digunakan sebagai data test seperti terlihat pada perintah berikut:

```
from sklearn.model_selection import train_test_split
# Split data: 80% for training and 20% for testing
X_train, X_test, y_train, y_test = train_test_split(features, labels, test_size=0.2,
stratify=labels, random_state=42)
print(X_train.shape, X_test.shape, y_train.shape, y_test.shape)
```


Selanjutnya data traing dan data test disimpan untuk selanjutnya digunakan dalam proses klasifikasi citra.

```
# Menyimpan numpy X_train, X_test, y_train, and y_test kedalam folder data GOC2 untuk digunakan Minggu depan
```

```
np.save('/content/drive/MyDrive/PENGOLAHAN CITRA SATELIT Tj  
Puting/DATA/DATA TRAINING DAN TESTING/X_train.npy', X_train)  
np.save('/content/drive/MyDrive/PENGOLAHAN CITRA SATELIT Tj  
Puting/DATA/DATA TRAINING DAN TESTING/X_test.npy', X_test)  
np.save('/content/drive/MyDrive/PENGOLAHAN CITRA SATELIT Tj  
Puting/DATA/DATA TRAINING DAN TESTING/y_train.npy', y_train)  
np.save('/content/drive/MyDrive/PENGOLAHAN CITRA SATELIT Tj  
Puting/DATA/DATA TRAINING DAN TESTING/y_test.npy', y_test)
```

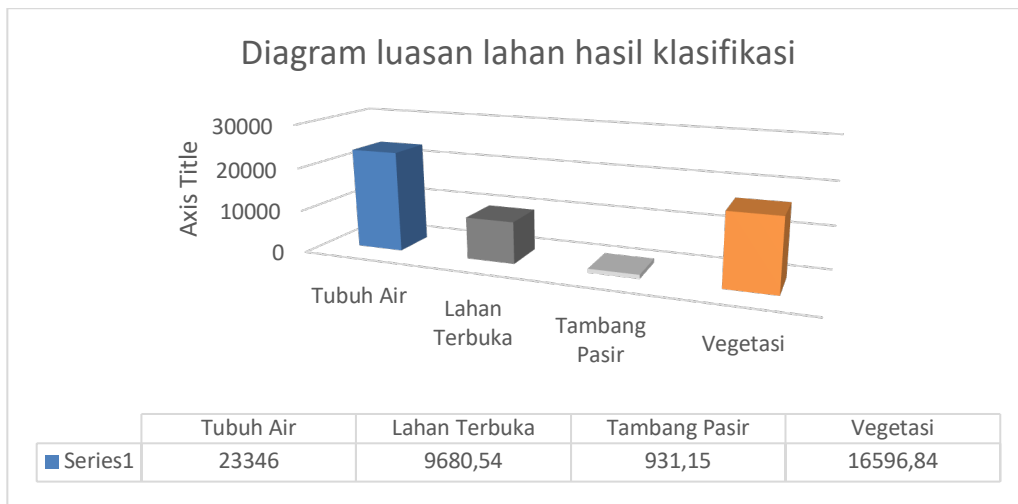
c. Hasil Klasifikasi

Selanjutnya citra diklasifikasikan dengan menggunakan algoritma XGBoost, dan dalam klasifikasi tersebut diperoleh kenampakan citra hasil klasifikasi sebagai berikut:



Gambar 7. Citra hasil klasifikasi

Berdasarkan hasil klasifikasi tersebut diperoleh data sebagai berikut:



Gambar 8. Diagram hasil klasifikasi citra

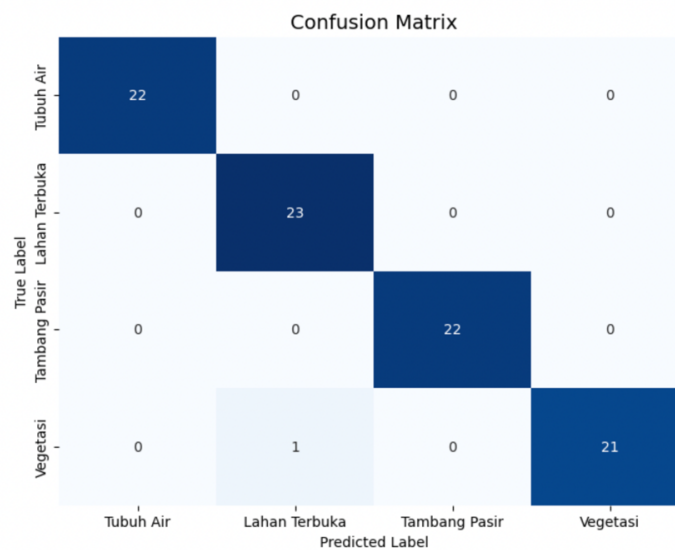
Berdasarkan klasifikasi citra yang dilakukan dengan menggunakan algoritma XGBoost diperoleh data sebagai berikut: Tubuh Air sebesar 23.346 Ha, Lahan Terbuka sebesar 9.680, 54 Ha, Tambang Pasir sebesar 931,15 Ha, dan Vegetasi sebesar 16.596,84 Ha.

d. Akurasi

Dari hasil klasifikasi yang dilakukan dengan menggunakan algoritma XGBoost, diperoleh tingkat akurasi sebesar 98% dengan keterangan sebagai berikut seperti pada Gambar 9.

Overall Accuracy: 0.9888

	precision	recall	f1-score	support
0.0	1.0000	1.0000	1.0000	22
1.0	0.9583	1.0000	0.9787	23
2.0	1.0000	1.0000	1.0000	22
3.0	1.0000	0.9545	0.9767	22
accuracy			0.9888	89
macro avg	0.9896	0.9886	0.9889	89
weighted avg	0.9892	0.9888	0.9888	89



Gambar 9 Tingkat akurasi algoritma XGBoost dalam klasifikasi citra

4. KESIMPULAN

Teknologi yang berkembang saat ini sangat mendukung hampir di seluruh bidang kegiatan manusia, tidak terkecuali pada bidang konservasi. Dalam bidang tersebut, ada beberapa teknologi yang dapat dimanfaatkan guna meningkatkan pelestarian lingkungan dan wilayah konservasi. Saat ini telah tersedia citra satelit yang dapat dimanfaatkan dalam pemantauan wilayah konservasi di seluruh permukaan bumi. Salah satu citra satelit yang dapat dimanfaatkan dalam aktifitas tersebut adalah Sentinel. Sebagaimana disebutkan sebelumnya, citra Satelit Sentinel dapat dimanfaatkan guna melakukan pemantauan *Land Use* dan *Land Cover* di permukaan bumi dalam kurun waktu tertentu. Selain itu, citra sentinel ini dapat dikombinasikan dengan metode *machine learning* untuk memperoleh klasifikasi tutupan lahan di suatu wilayah tertentu. Dalam penelitian ini, citra Sentinel yang diperoleh dari platform *google earth engine* diklasifikasikan dengan menggunakan metode *machine learning* XGBoost. Hasil dari proses tersebut, diperoleh sebuah model yang digunakan untuk mengklasifikasikan citra dengan hasil uji akurasi sebesar 98%. Berdasarkan hasil tersebut, dapat disimpulkan bahwa metode XGBoost merupakan algoritma yang cocok digunakan dalam pengklasifikasian citra satelit Sentinel.

Saran dari penelitian ini diharapkan ke depannya dilakukan penelitian serupa yang menitik beratkan pada prediksi tutupan lahan di sekitar wilayah TWA Tanjung Keluang dalam kurun waktu beberapa tahun ke depan.

REFERENSI

- [1] S. M. Yimer, A. Bouanani, N. Kumar, B. Tischbein, and C. Borgemeister, "Comparison of different machine-learning algorithms for land use land cover mapping in a heterogenous landscape over the Eastern Nile river basin, Ethiopia," *Advances in Space Research*, vol. 74, no. 5, pp. 2180–2199, Sep. 2024, doi: 10.1016/j.asr.2024.06.010.
- [2] Z. Gao, D. Guo, D. Ryu, and A. W. Western, "Training sample selection for robust multi-year within-season crop classification using machine learning," *Comput Electron Agric*, vol. 210, Jul. 2023, doi: 10.1016/j.compag.2023.107927.
- [3] K. Sharma and M. Sood, "Monitoring, classification and analysis of waste disposal sites using Machine Learning," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 1558–1567. doi: 10.1016/j.procs.2024.04.147.
- [4] S. Vidhya, M. Balaji, and V. Kamaraj, "Satellite Image Classification using CNN with Particle Swarm Optimization Classifier," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 979–987. doi: 10.1016/j.procs.2024.03.287.
- [5] F. A. Kondum, M. K. Rowshon, C. A. Luqman, C. M. Hasfalina, and M. D. Zakari, "Change analyses and prediction of land use and land cover changes in Bernam River Basin, Malaysia," *Remote Sens Appl*, vol. 36, Nov. 2024, doi: 10.1016/j.rsase.2024.101281.
- [6] P. Kulithalai Shiyam Sundar and P. C. Deka, "Spatio-temporal classification and prediction of land use and land cover change for the Vembanad Lake system, Kerala: a machine learning approach," Dec. 01, 2022, *Springer Science and Business Media Deutschland GmbH*. doi: 10.1007/s11356-021-17257-0.
- [7] W. Tesfaye, E. Elias, B. Warkineh, M. Tekalign, and G. Abebe, "Modeling of land use and land cover changes using google earth engine and machine learning approach: implications for landscape management," *Environmental Systems Research*, vol. 13, no. 1, Dec. 2024, doi: 10.1186/s40068-024-00366-3.
- [8] J. Kim *et al.*, "Application of the domain adaptation method using a phenological classification framework for the land-cover classification of North Korea," *Ecol Inform*, vol. 81, Jul. 2024, doi: 10.1016/j.ecoinf.2024.102576.

- [9] J. Aryal, C. Sitaula, and A. C. Frery, "Land use and land cover (LULC) performance modeling using machine learning algorithms: a case study of the city of Melbourne, Australia," *Sci Rep*, vol. 13, no. 1, Dec. 2023, doi: 10.1038/s41598-023-40564-0.
- [10] T. Sivasubramaniyan and R. N. Rajaperumal, "Identifying land use land cover dynamics using machine learning method and GIS approach in Karaivetti, Tamil Nadu," *Journal of Autonomous Intelligence*, vol. 7, no. 3, 2024, doi: 10.32629/jai.v7i3.1333.
- [11] F. Alonso-Sarría, C. Valdivieso-Ros, and F. Gomariz-Castillo, "Analysis of the hyperparameter optimisation of four machine learning satellite imagery classification methods," *Comput Geosci*, vol. 28, no. 3, pp. 551–571, Jun. 2024, doi: 10.1007/s10596-024-10285-y.
- [12] Z. Zhao *et al.*, "Comparison of Three Machine Learning Algorithms Using Google Earth Engine for Land Use Land Cover Classification," *Rangel Ecol Manag*, vol. 92, pp. 129–137, Jan. 2024, doi: 10.1016/j.rama.2023.10.007.
- [13] H. He, J. Yan, D. Liang, Z. Sun, J. Li, and L. Wang, "Time-series land cover change detection using deep learning-based temporal semantic segmentation," *Remote Sens Environ*, vol. 305, May 2024, doi: 10.1016/j.rse.2024.114101.
- [14] M. Worachairungreung *et al.*, "Using a Logistic Regression Model to Examine the Variables Influencing Changes in Northern Thailand's Forest Cover and Comparing Machine Learning Algorithms," *Forests*, vol. 15, no. 6, Jun. 2024, doi: 10.3390/f15060981.
- [15] Z. Shao, M. N. Ahmad, and A. Javed, "Comparison of Random Forest and XGBoost Classifiers Using Integrated Optical and SAR Features for Mapping Urban Impervious Surface," *Remote Sens (Basel)*, vol. 16, no. 4, Feb. 2024, doi: 10.3390/rs16040665.
- [16] S. Chang *et al.*, "Development of a Multiscale XGBoost-Based Model for Enhanced Detection of Potato Late Blight Using Sentinel-2, UAV, and Ground Data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 62, 2024, doi: 10.1109/TGRS.2024.3466648.
- [17] Dinas Kelautan dan Perikanan Kalteng, "Rencana Pengelolaan dan Zonasi Kawasan Konservasi Perairan Daerah," 2020.
- [18] M. Nur Karim, S. Rifanjani, and S. Siahaan, "Karakteristik Habitat Tempat Bertelur Penyu Sisik (*Eretmochelys Imbricata*) Di Taman Wisata Alam Tanjung Keluang Kecamatan Kumai Kalimantan Tengah," 2019.
- [19] A. Musthofan, K. Nisa, D. Abdi, F. Program, and S. Kehutanan, "Penilaian Potensi Objek Wisata Taman Wisata Alam Tanjung Keluang Dan Pantai Kubu Di Kabupaten Kotawaringin Barat Kalimantan Tengah Potential Assessment of Tanjung Keluang Natural Tourism Park and Kubu Beach in Kotawaringin Barat Regency, Central Kalimantan," 2024.
- [20] I. P. Saputri, S. Parsudi, and E. Nurhadi, "Persepsi Dan Strategi Pengembangan Taman Wisata Alam Tanjung Keluang, Kecamatan Kumai, Kalimantan Tengah," in *Prosiding Seminar Nasional Program Doktor Agribisnis*, 2021, pp. 74–86.
- [21] S. Swetanisha, A. R. Panda, and D. K. Behera, "Land use/land cover classification using machine learning models," *International Journal of Electrical and Computer Engineering*, vol. 12, no. 2, pp. 2040–2046, Apr. 2022, doi: 10.11591/ijece.v12i2.pp2040-2046.
- [22] G. Martínez-Muñoz, C. Bentéjac, and A. Csörg, "O B Gonzalo Martínez-Muñoz, "A Comparative Analysis of XGBoost", doi: 10.48550/arXiv.1911.01914.
- [23] E. H. Yulianti, O. Soesanto, and Y. Sukmawaty, "Penerapan Metode Extreme Gradient Boosting (XGBOOST) pada Klasifikasi Nasabah Kartu Kredit," *JOMTA Journal of Mathematics: Theory and Applications*, vol. 4, no. 1, 2022.