

Model Deteksi Tutupan Lahan di Kecamatan Gunungsitoli Menggunakan Algoritma Decision Tree Berbasis Machine Learning

*Land Cover Detection Model in Gunungsitoli District Using Decision Tree Algorithm
Based on Machine Learning*

Amati Eltriman Hulu*¹, Mizero Alexis²

^{1,2}Program Studi Pascasarjana Ilmu Pengelolaan Hutan, Departemen Manajemen Hutan,
Fakultas Kehutanan dan Lingkungan, IPB University, Dramaga, Bogor, 16880, Indonesia

²Department of Forestry and Nature Conservation, College of Agriculture, University of
Rwanda, P.O. Box 210 Musanze, Rwanda

E-mail : amatieltrimanhulu.com*¹, mizeroalexis2023@gmail.com²

*Corresponding author

Received 31 May 2025; Revised 9 June 2025; Accepted 19 June 2025

Abstrak – Perkembangan teknologi penginderaan jauh semakin berkembang, integrasi data penginderaan jauh dan *artificial intelligence-machine learning* menjadi pendekatan yang sangat efisien dalam mendeteksi tutupan lahan. Penelitian ini bertujuan untuk membangun model algoritma tutupan lahan menggunakan algoritma *decision tree*. Data yang digunakan yakni Citra PlanetScope NICFI Level 1 yang diturunkan menjadi beberapa indeks spektral yang terdiri atas *Normalized Difference Vegetation Index* (NDVI), *Visible Atmospherically Resistant Index* (VARI), *Soil Adjusted Vegetation Index* (SAVI), *Normalized Difference Water Index* (NDWI), dan *Green-Red Vegetation Index* (GRVI). Untuk mengukur setiap variabel digunakan Information Gain, Gini Index, dan Gain Ratio. Hasil penelitian menunjukkan bahwa SAVI dan NDVI merupakan variabel yang informatif dalam membangun model. Distribusi tutupan lahan di Kecamatan Gunungsitoli didominasi oleh tutupan hutan.

Kata Kunci – *Decision Tree, Machine Learning, Tutupan Lahan, Gunungsitoli*

Abstract - The development of remote sensing technology is increasingly developing, the integration of remote sensing data and artificial intelligence- machine learning be a very efficient approach in detecting land cover. This study aims to build a land cover algorithm model using the algorithm decision tree. The data used is PlanetScope NICFI Level 1 imagery which is broken down into several spectral indices consisting of *Normalized Difference Vegetation Index* (NDVI), *Visible Atmospherically Resistant Index* (VARI), *Soil Adjusted Vegetation Index* (SAVI), *Normalized Difference Water Index* (NDWI), and *Green-Red Vegetation Index* (GRVI). Information Gain, Gini Index, and Gain Ratio are used to measure each variable. The results of the study indicate that SAVI and NDVI are informative variables in building the model. The distribution of land cover in Gunungsitoli District is dominated by forest cover.

Keywords - *Decision Tree, Machine Learning, Land Cover, Gunungsitoli District*

1. PENDAHULUAN

Kompleksitas *landscape* Indonesia yang terdiri dari berbagai tipe tutupan lahan seperti hutan, area pertanian, kawasan terbangun, dan badan air memerlukan pendekatan yang sistematis dan *advanced* dalam proses deteksinya [1], [2]. Ketersediaan informasi tutupan lahan yang akurat menjadi sangat penting mengingat Indonesia memiliki wilayah yang luas dengan karakteristik geografis yang beragam [3]. Keakuratan dalam deteksi tutupan lahan memiliki implikasi

signifikan terhadap berbagai aspek pembangunan, termasuk perencanaan tata ruang, manajemen sumber daya alam, hingga implementasi kebijakan berbasis *spatial planning* [4].

Kepulauan Nias merupakan sebuah gugusan kepulauan yang terletak di lepas pantai barat Provinsi Sumatera Utara, Indonesia, dengan Kota Gunungsitoli sebagai pusat pemerintahan dan kegiatan ekonomi utamanya. Keterisolasian geografis Kepulauan Nias sebagai entitas yang terpisah dari daratan utama Sumatera sering kali berdampak pada tingginya kerentanan terhadap perubahan lingkungan. Sebagai wilayah kepulauan terpencil, Nias sangat bergantung pada sumber daya alam lokal yang terbatas dan rentan terhadap bencana seperti longsor, banjir bandang, abrasi pantai, serta dampak perubahan iklim seperti kenaikan muka air laut dan cuaca ekstrem [5], [6]. Perubahan tutupan lahan seperti penggundulan hutan di lereng bukit, konversi hutan mangrove menjadi lahan pertanian, perluasan permukiman ke zona rawan, atau degradasi lahan dapat secara signifikan memperparah kerentanan ini. Oleh karena itu, deteksi tutupan lahan yang akurat, detail, dan berkelanjutan menjadi sangat penting [7].

Perkembangan teknologi penginderaan jauh telah mengalami perkembangan yang signifikan, dengan integrasi kecerdasan buatan (*artificial intelligence*) dan *machine learning* menjadi pendekatan baru dalam analisis data spasial [8], [9]. Teknologi penginderaan jauh, yang awalnya berfokus pada interpretasi visual dan klasifikasi manual, kini telah bertransformasi menjadi sistem yang lebih *sophisticated* dengan kemampuan pengolahan data yang lebih kompleks dan akurat [10]. Munculnya *machine learning* dalam ranah penginderaan jauh mampu melakukan pemrosesan data multispektral dan multitemporal secara lebih efisien [11], [12], dengan tingkat akurasi yang jauh lebih tinggi dibandingkan metode konvensional [13].

Salah satu algoritma *machine learning* yang sering digunakan dalam monitoring tutupan lahan yaitu algoritma *decision tree* (DT) [14], [15]. Dibandingkan dengan algoritma lainnya, algoritma DT mampu mengenali dengan jelas proses pengambilan keputusan dalam klasifikasi tutupan lahan dibandingkan dengan algoritma lainnya [16]. Algoritma ini bekerja dengan membentuk struktur pohon keputusan yang dapat mempartisi data multispektral ke dalam kelas-kelas tutupan lahan yang berbeda berdasarkan karakteristik spektralnya [17].

Pemanfaat *machine learning* dan citra satelit dalam mendeteksi tutupan lahan telah dilakukan, penelitian [18] menggunakan algoritma *Support Vector Machine* (SVM) dalam mengidentifikasi tutupan lahan, namun masih terbatas dalam menangkap seluruh informasi spektral dan menggunakan citra beresolusi sedang. Beberapa penelitian lainnya [19], [20] memanfaatkan citra resolusi sedang dan *Normalized Difference Vegetation Index* (NDVI) dengan algoritma *Maximum Likelihood Classification* (MLC). Namun, keterbatasannya terletak pada penggunaan citra beresolusi sedang dan hanya mengandalkan satu indeks spektral, yaitu NDVI, sehingga informasi yang dihasilkan belum sepenuhnya menggambarkan keragaman tutupan lahan secara akurat. Secara umum, penelitian-penelitian terdahulu rata-rata menggunakan citra beresolusi sedang, seperti Landsat dan Sentinel [21], resolusi spasial dari citra sangat mempengaruhi akurasi dalam mendeteksi tutupan lahan [22], [23], [24].


Berdasarkan keterbatasan tersebut, penelitian ini bertujuan untuk membangun algoritma klasifikasi tutupan lahan berbasis *machine learning* dengan pendekatan *Decision Tree* dan menggunakan data citra satelit beresolusi tinggi. Pendekatan ini diharapkan mampu meningkatkan akurasi klasifikasi melalui pemanfaatan detail spasial yang lebih tinggi serta memungkinkan integrasi berbagai parameter spektral. Hasil dari penelitian ini diharapkan dapat menjadi referensi dalam pengembangan algoritma klasifikasi tutupan lahan berbasis penginderaan jauh yang lebih efektif dan adaptif terhadap variasi karakteristik lahan.

2. METODE PENELITIAN

1.1. Waktu dan Tempat

Penelitian ini dilaksanakan pada bulan Oktober 2024-Januari 2025 di Kecamatan Gunungsitoli, Kota Gunungsitoli, Provinsi Sumatra Utara. Pengolahan dan analisis data dilakukan

di Laboratorium Remote Sensing dan GIS, Departemen Manajemen Hutan, Fakultas Kehutanan dan Lingkungan, IPB University.



Gambar 1 Peta lokasi penelitian (a). Batas Administrasi Indonesia (b). Batas Adminstrasi Kepulauan Nias (c.) Batas Administrasi Kecamatan Gunungsitoli

1.2. Alat dan Data

Adapun alat yang digunakan dalam penelitian ini yakni *Global Positioning System* (GPS), ERDAS Imagine 2022, *Code Blocks* 20.03, ArcGIS Pro, Ai Studio 2024.1.0 dan *Microsoft Office*. Data terdiri dari dua jenis yakni data primer dan data sekunde. Data primer yaitu Citra PlanetScope NICFI Level 1 perekaman bulan Juni 2024 (Tabel 1). Data sekunder berupa peta administarsi kecamatan gunungsitoli dengan format shapefile.

Tabel 1 Karakteristik band Citra PlanetScope NICFI Level 1

Jenis Citra	Sensor Kanal	Resolusi Spasial
PlaneScope NICFI Level 1	Blue	4,77 Meter
	Green	
	Red	
	Near-Infrared	

1.3. Pengolahan dan Analisis Data

2.3.1. Pra Pengolahan Citra Satelit

Pengolahan data diawali dengan melakukan transformasi koordinat menjadi sistem transformasi geodetic *Universal Trasverse Mercator* (UTM) Zona 47 N. Citra PlanetScope terdiri dari banyak *scene* sehingga perlu dilakukan penggabungan 2 *scene* citra berdasarkan Lokasi penelitian. Untuk menghasilkan data tutupan lahan di Kecamatan Gunungsitoli dilakukan pemotongan citra di *Area of Interest* (AOI) yakni batas administrasi Kecamatan Gunungsitoli yang telah melalui proses topologi untuk menghindari *gap* atau duplikasi.

2.3.2. Training Area

Training area (TA) merupakan sampel area yang digunakan untuk klasifikasi tutupan lahan berdasarkan karakteristik spektral dan spasial wilayah kajian. Penentuan *TA* mengacu pada prinsip keterwakilan dan ketersebaran dengan mempertimbangkan proporsi distribusi tutupan lahan. Metode interpretasi visual dilakukan menggunakan kombinasi kanal RED-GREEN-BLUE pada citra PlanetScope NICFI Level 1 dengan memperhatikan kunci interpretasi meliputi bentuk, pola, warna, ukuran, lokasi, tekstur, dan asosiasi. Sebanyak 566 training area diseluruh tutupan

lahan dan tersebar di lokasi penelitian untuk menghasilkan parameter penciri kelas dalam proses klasifikasi tutupan lahan.

2.3.3. Indeks Spektral

Penelitian ini menggunakan beberapa citra sintetis/indeks spektral untuk memudahkan klasifikasi tutupan lahan. Indeks yang digunakan disajikan pada tabel 2.


Tabel 2 Indeks Spektral

No	Indek Spektral	Rumus	Sumber
1	<i>Normalized Difference Vegetation Index</i> (NDVI)	$\frac{NIR - RED}{NIR + RED}$	[25]
2	Visible Atmospherically Resistant Index (VARI)	$\frac{GREEN - RED}{GREEN + RED - BLUE}$	[26]
3	Soil Adjusted Vegetation Index (SAVI)	$\frac{NIR - RED}{NIR + RED + L} \times (1 + L)$	[27]
4	Normalized Difference Water Index (NDWI)	$\frac{GREEN - NIR}{GREEN + NIR}$	[28]
5	Green-Red Vegetation Index (GRVI)	$\frac{GREEN - RED}{GREEN + RED}$	[29]

2.3.4. Algoritma Decision Tree

Pohon keputusan (*decision tree*) merupakan salah satu metode klasifikasi dalam pembelajaran mesin yang menggunakan struktur pohon dengan *root node*, simpul cabang (*sub-tree*), dan *leaf node* (Gambar 2). Metode ini telah digunakan secara efektif untuk klasifikasi citra dalam penelitian penggunaan lahan dan tutupan lahan. Pembangunan pohon keputusan dilakukan dengan membagi data pelatihan dan data uji, di mana 60% data digunakan untuk pelatihan dan 40% untuk pengujian. Algoritma pohon keputusan mempelajari hubungan antara seluruh peubah yang digunakan dengan kelas tutupan lahan. Pembangunan pohon keputusan dilakukan menggunakan perangkat lunak Ai Studio 2024.1.0 dengan algoritma C4.5, di mana data dibagi menjadi beberapa kelompok kecil dengan nilai yang sama. Pembagian data pada pohon keputusan harus mempertimbangkan peubah yang paling prediktif dan dibuat berdasarkan kriteria dari peubah yang digunakan sebagai parameter.

Pengukuran algoritma pohon keputusan dimulai dengan menghitung nilai entropi, yang didefinisikan sebagai jumlah probabilitas setiap label dikalikan dengan log probabilitas dari label yang sama. Entropi digunakan untuk mengukur tingkat keacakan dalam suatu set data. Nilai split info juga dihitung untuk menyatakan entropi atau impurity dari suatu peubah. Information gain, yang merupakan perbedaan antara entropi kelas dan kondisional entropi, digunakan untuk mengukur perubahan entropi sebelum dan setelah pemisahan kelas. Peubah dengan information gain tertinggi dipilih sebagai peubah terbaik untuk dipisahkan. Gain ratio digunakan untuk mengevaluasi tingkat kepentingan dari semua peubah dan memberikan peringkatnya terhadap kelas. Gini index digunakan untuk menentukan kemurnian kelas tertentu setelah pemisahan kelas berdasarkan peubah tertentu, di mana pemisahan terbaik akan meningkatkan kemurnian set yang dihasilkan.

Gambar 2 Konsep algoritma *decision tree*

2.3.5. Uji Akurasi

Hasil *decision tree* di evaluasi/uji akurasi untuk menguji hasil segmentasi dalam mengelaskan objek. Uji akurasi digunakan adalah akurasi keseluruhan/*overall accuracy* (OA) dan akurasi kappa/*kappa accuracy* (KA). Uji OA dan KA menggunakan prinsip matrik konfusi sebagai pembandingan data referensi dan data segmentasi.

3. HASIL DAN PEMBAHASAN

1.4. Hasil

1.4.1. Model

Berdasarkan analisis variabel spektral yang dilakukan, beberapa indeks spektral menunjukkan tingkat relevansi yang berbeda-beda dalam membedakan objek dalam kelas tertentu (Tabel 3). Indeks spektral SAVI menunjukkan tingkat relevansi yang tinggi berdasarkan semua metode yang digunakan, yaitu Information Gain, Gini Index, Gain Ratio, dan Brute Force. Hal ini menunjukkan bahwa SAVI dapat memberikan informasi yang dibutuhkan untuk klasifikasi.

Indeks spektral NDVI juga menunjukkan relevansi yang relatif tinggi, meskipun terdapat sedikit variasi dalam hasil yang diperoleh dari berbagai metode. NDVI merupakan indeks yang efektif dalam mengidentifikasi vegetasi, sehingga nilai relevansinya yang tinggi dapat dikaitkan dengan kemampuannya untuk membedakan objek berdasarkan karakteristik vegetasi.

Secara keseluruhan, berbagai tingkat relevansi ini dapat dipengaruhi oleh karakteristik masing-masing indeks spektral dan kemampuannya untuk menangkap informasi spesifik yang terkait dengan objek yang dianalisis. Indeks yang lebih relevan cenderung lebih baik dalam membedakan objek berdasarkan atribut tertentu, seperti vegetasi atau kandungan air, sehingga berkontribusi secara signifikan terhadap proses klasifikasi.

Tabel 3 Bobot setiap peubah untuk kombinasi spektral

Variabel	Parameter				
	<i>Information gain</i>	<i>Gini index</i>	<i>Gain ratio</i>	<i>Rata-rata</i>	<i>Brute force</i>
SAVI	1	1	1	1	1
NDVI	1	0,830	1	0,94	1
GRVI	0,647	0,830	0,682	0,72	1
NDWI	0,540	0,020	0,418	0,33	1
VARI	0	0	0	0,00	1

1.4.2. Optimasi Parameter Model

Information Gain merupakan parameter terbaik dengan nilai akurasi keseluruhan tertinggi (Tabel 4). Parameter ini paling sering dipilih dalam sepuluh kombinasi teratas. Selain information gain, parameter lain yang dipilih untuk optimasi adalah gain ratio dan indeks Gini, yang juga memiliki akurasi keseluruhan yang tinggi.

Parameter Information Gain terbaik memerlukan proses pra-pemangkasan dengan nilai TRUE. Proses ini melibatkan jumlah simpul daun minimal 80, simpul variabel pembagi minimal 31, dan kedalaman pohon maksimal 20. Kedalaman pohon 20 menunjukkan panjang maksimum pohon keputusan dari simpul akar ke simpul daun. Misalkan jumlah sampel variabel melebihi 31. Dalam hal itu, pemisahan akan dilakukan untuk membagi jumlah variabel menjadi subset yang lebih kecil hingga mencapai simpul daun dengan sampel minimal 80.


Pre-pruning pada model optimal dilakukan untuk memangkas atau membuang cabang-cabang yang tidak diperlukan dan memiliki pengaruh yang lemah. *Pre-pruning* bertujuan untuk mengurangi kendala pada algoritma *Decision Tree*, meningkatkan keandalan, dan memperbaiki akurasi model. Hal ini terbukti dapat meningkatkan akurasi secara keseluruhan.

Tabel 4 Optimasi parameter model algoritma pohon keputusan terbaik

Kriteria	Pre-Pruning	Pruning	Minimal leaf size	Minimal size for split	Maximal depth	OA (%)
Information Gain	True	False	80	31	20	0.92
Gain Ratio	True	False	11	70	10	0.91
Information Gain	False	False	90	1	70	0.91
Gini Index	True	False	1	41	90	0.91
Information Gain	True	True	31	60	30	0.91
Information Gain	False	False	1	60	40	0.91
Information Gain	False	True	1	41	70	0.91
Gain Ratio	False	True	1	11	90	0.91
Gini Index	True	True	1	21	90	0.91
Information Gain	True	True	1	21	90	0.9


1.4.3. Uji Akurasi Model Klasifikasi

Berdasarkan hasil model klasifikasi yang telah dibangun dilakukannya uji akurasi untuk menilai seberapa tepat atau benar hasil yang diberikan oleh suatu model atau sistem terhadap data uji. Sebanyak 30% dari jumlah total *training area* digunakan untuk memvalidasi. Hasil uji akurasi menunjukan *overall accuracy* sebesar 92,86% dan *kappa accuracy* sebesar 89,69%.



Gambar 3 Confusion matrix hasil model decision tree

Model *decision tree* disajikan pada Gambar 4.




Gambar 4. Aturan *decision tree* dari sebagian algoritma

1.5. Klasifikasi Tutupan Lahan


Berdasarkan model *Decision tree* yang dibangun dari lima indeks spektral yaitu NDVI, VARI, SAVI, GRVI, dan NDWI dihasilkan tutupan lahan di Kecamatan Gunungsitoli (Gambar 5). Indeks spektral SAVI mempunyai kemampuan yang sangat baik dalam membedakan kelas tutupan lahan, terutama karena indeks ini telah disesuaikan dengan kondisi tanah, sehingga dapat mengurangi pengaruh latar belakang tanah terhadap citra satelit. Temuan ini sejalan dengan beberapa studi literatur yang telah dilakukan sebelumnya. Misalnya penelitian oleh [27]

menyatakan bahwa SAVI lebih unggul dalam kondisi tanah terbuka atau dengan tutupan vegetasi rendah, yang menjelaskan mengapa SAVI berkinerja terbaik dalam model ini. NDVI juga menunjukkan kinerja yang kuat dengan nilai rata-rata 0,94, yang menunjukkan bahwa indeks ini tetap menjadi salah satu alat yang paling dapat diandalkan dalam mengidentifikasi vegetasi, konsisten dengan temuan dalam sebuah studi oleh [29] yang menyatakan bahwa NDVI efektif dalam memantau kesehatan dan kerapatan vegetasi. NDWI, yang dirancang untuk mendeteksi kadar air, kurang efektif dalam membedakan kelas penutup lahan yang tidak berhubungan langsung dengan air. Sebuah studi oleh [30] menunjukkan bahwa NDWI efektif dalam mendeteksi badan air tetapi kurang efektif dalam membedakan kelas penutup lahan lainnya. Hal ini memperkuat temuan dalam hasil klasifikasi ini bahwa NDWI memiliki kontribusi yang terbatas. Sementara itu, VARI yang digunakan untuk mengidentifikasi vegetasi dalam berbagai kondisi atmosfer tidak memberikan kontribusi yang signifikan terhadap model ini, hal ini disebabkan oleh keterbatasan dalam membedakan kelas penutup lahan yang kompleks.



Gambar 5. Klasifikasi Tutupan Lahan

Berdasarkan data luas tutupan lahan, sebaran kelas tutupan lahan dapat dijelaskan dalam bentuk persentase. Hutan merupakan kelas tutupan lahan yang paling dominan dari total luas wilayah penelitian. Pertanian/Perkebunan menempati porsi yang cukup besar, yaitu sekitar 33,02%, hal ini menunjukkan bahwa kegiatan pertanian dan perkebunan juga cukup dominan di wilayah Kecamatan Gunungsitoli.



Gambar 6 Luas tutupan lahan di Kecamatan Gunungsitoli

4. KESIMPULAN

Integrasi data penginderaan jauh dan *artificial intelligence - machine learning* sangat efektif dalam mendeteksi tutupan lahan. Pemanfaatan karakteristik spektral dalam citra satelit memberikan informasi yang baik dalam membedakan tutupan kelas. Seleksi fitur ketat menggunakan tiga metrik berbeda (Information Gain, Gini Index, dan Gain Ratio) secara konsisten mengidentifikasi SAVI dan NDVI sebagai variabel paling informatif dan berpengaruh signifikan dalam membangun model. Temuan ini mengindikasikan bahwa karakteristik vegetasi (kondisi hijauan dan kesehatan tanaman) serta penyesuaian terhadap latar belakang tanah merupakan faktor kunci yang paling membedakan kelas-kelas tutupan lahan. Hasil klasifikasi akhir mengungkapkan pola tutupan lahan yang jelas, di mana tutupan hutan mendominasi secara signifikan lanskap Kecamatan Gunungsitoli. Hal ini tidak hanya memberikan gambaran spasial yang akurat tentang kondisi aktual wilayah tersebut, tetapi juga menyoroti pentingnya keberlanjutan pengelolaan ekosistem hutan yang menjadi penopang utama lingkungan di kawasan kepulauan yang secara geografis terisolasi dan rentan terhadap perubahan ini.

DAFTAR PUSTAKA

- [1] R. Sharma *et al.*, "Modeling land use and land cover changes and their effects on biodiversity in Central Kalimantan, Indonesia," *Land (Basel)*, vol. 7, no. 2, 2018, doi: 10.3390/land7020057.
- [2] K. G. Austin, A. Schwantes, Y. Gu, and P. S. Kasibhatla, "What causes deforestation in Indonesia?," *Environmental Research Letters*, vol. 14, no. 2, 2019, doi: 10.1088/1748-9326/aaf6db.
- [3] A. Setiawan, "Keanekaragaman Hayati Indonesia: Masalah dan Upaya Konservasinya," *Indonesian Journal of Conservation*, vol. 11, no. 1, 2022.
- [4] A. E. Hulu *et al.*, "Spatial Analysis of Water Infiltration Potential in the Miu Watershed of Sigi Regency," *Advance Sustainable Science Engineering and Technology*, vol. 5, no. 2, p. 0230208, Jul. 2023, doi: 10.26877/asset.v5i2.16626.
- [5] S. Mendrofa, R. Kurnia, and N. T. M. Pratiwi, "Land Changes and Management Strategies of Mangrove in Sawo District, North Nias Regency, North Sumatera Province," *Jurnal*

- Ilmu dan Teknologi Kelautan Tropis*, vol. 9, no. 2, pp. 499–506, Jan. 2018, doi: 10.29244/jitkt.v9i2.19286.
- [6] J. Ilmiha, “Analisis Potensi Beberapa Sektor Ekonomi Kabupaten Nias Utara 2022,” *Jurnal Simki Economic*, vol. 6, no. 1, 2023, doi: 10.29407/jse.v6i1.170.
 - [7] Z. Gu and M. Zeng, “The Use of Artificial Intelligence and Satellite Remote Sensing in Land Cover Change Detection: Review and Perspectives,” 2024. doi: 10.3390/su16010274.
 - [8] A. E. Maxwell, T. A. Warner, and F. Fang, “Implementation of machine-learning classification in remote sensing: An applied review,” 2018. doi: 10.1080/01431161.2018.1433343.
 - [9] V. F. Rodriguez-Galiano, B. Ghimire, J. Rogan, M. Chica-Olmo, and J. P. Rigol-Sanchez, “An assessment of the effectiveness of a random forest classifier for land-cover classification,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 67, no. 1, 2012, doi: 10.1016/j.isprsjprs.2011.11.002.
 - [10] J. R. Otukei and T. Blaschke, “Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 12, no. SUPPL. 1, 2010, doi: 10.1016/j.jag.2009.11.002.
 - [11] R. Saini and S. Singh, “Land use land cover mapping and snow cover detection in Himalayan region using machine learning and multispectral Sentinel-2 satellite imagery,” *International Journal of Information Technology (Singapore)*, vol. 16, no. 2, 2024, doi: 10.1007/s41870-023-01673-1.
 - [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, 2024, doi: 10.1016/j.rama.2023.10.007.
 - [13] A. Kumar, R. D. Garg, P. Singh, A. Shankar, S. R. Nayak, and M. Diwakar, “Monitoring the Land Use, Land Cover Changes of Roorkee Region (Uttarakhand, India) Using Machine Learning Techniques,” *International Journal of Social Ecology and Sustainable Development*, vol. 14, no. 1, 2023, doi: 10.4018/IJSESD.316883.
 - [14] C. Huang, L. S. Davis, and J. R. G. Townshend, “An assessment of support vector machines for land cover classification,” *Int J Remote Sens*, vol. 23, no. 4, 2002, doi: 10.1080/01431160110040323.
 - [15] A. Schneider, “Monitoring land cover change in urban and peri-urban areas using dense time stacks of Landsat satellite data and a data mining approach,” *Remote Sens Environ*, vol. 124, 2012, doi: 10.1016/j.rse.2012.06.006.
 - [16] R. Tobar-Díaz, Y. Gao, J. F. Mas, and V. H. Cambrón-Sandoval, “Classification of land use and land cover through machine learning algorithms: a literature review,” *Revista de Teledeteccion*, vol. 2023, no. 62, 2023, doi: 10.4995/raet.2023.19014.
 - [17] L. Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone, *Classification and regression trees*. 2017. doi: 10.1201/9781315139470.
 - [18] A. A. Purboyo, A. Kurniawan, and L. Muta’ali, “Identifikasi Tutupan Lahan Menggunakan Support Vector Machine di Kawasan Perkotaan Cekungan Bandung,” *Jurnal Komtika (Komputasi dan Informatika)*, vol. 8, no. 1, pp. 54–64, May 2024, doi: 10.31603/komtika.v8i1.11140.
 - [19] N. C. I. Natun and S. Sumarlin, “Analisis Perbandingan Klasifikasi Supervised dan Unsupervised Citra Satelit Landsat untuk Pemetaan Penutupan Lahan di Kabupaten Kupang,” *Jurnal Manajemen Informatika Jayakarta*, vol. 5, no. 2, p. 142, Mar. 2025, doi: 10.52362/jmijayakarta.v5i2.1812.
 - [20] P. Aryastana, L. Dewi, L. Sinda, and I. K. Budha, “Pengelompokan Kelas Tutupan Lahan di Kabupaten Jembrana Berdasarkan Ekstraksi Citra Landsat 8,” *Jurnal Ilmiah MITSU (Media Informasi Teknik Sipil Universitas Wiraraja)*, vol. 12, no. 1, pp. 45–58, 2024.

- [21] Z. Ara, R. Jha, and A. R. Quaff, "Critical Appraisal of Satellite Data for Land Use/Land Cover Classification and Change Detection: A Review," 2023, pp. 113–130. doi: 10.1007/978-981-99-1901-7_11.
- [22] X. Liu *et al.*, "Large-Scale High-Resolution Coastal Mangrove Forests Mapping Across West Africa With Machine Learning Ensemble and Satellite Big Data," *Front Earth Sci (Lausanne)*, vol. 8, 2021, doi: 10.3389/feart.2020.560933.
- [23] T. Mollick, M. G. Azam, and S. Karim, "Geospatial-based machine learning techniques for land use and land cover mapping using a high-resolution unmanned aerial vehicle image," *Remote Sens Appl*, vol. 29, 2023, doi: 10.1016/j.rsase.2022.100859.
- [24] C. A. Ramezan, T. A. Warner, A. E. Maxwell, and B. S. Price, "Effects of training set size on supervised machine-learning land-cover classification of large-area high-resolution remotely sensed data," *Remote Sens (Basel)*, vol. 13, no. 3, 2021, doi: 10.3390/rs13030368.
- [25] J. W. Rouse, R. H. Haas, J. A. Schell, and D. W. Deering, "Monitoring vegetation systems in the Great Plains with ERTS. NASA special publication," *NASA special publication*, vol. 24, no. 1, 1974.
- [26] A. A. Gitelson, Y. J. Kaufman, R. Stark, and D. Rundquist, "Novel algorithms for remote estimation of vegetation fraction," *Remote Sens Environ*, vol. 80, no. 1, 2002, doi: 10.1016/S0034-4257(01)00289-9.
- [27] A. Huete, "A soil-adjusted vegetation index (SAVI). Remote Sensing of Environment," *Remote Sens Environ*, vol. 25, 1988.
- [28] S. K. McFeeters, "The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features," *Int J Remote Sens*, vol. 17, no. 7, 1996, doi: 10.1080/01431169608948714.
- [29] C. J. Tucker, "Red and photographic infrared linear combinations for monitoring vegetation," *Remote Sens Environ*, vol. 8, no. 2, 1979, doi: 10.1016/0034-4257(79)90013-0.
- [30] B. C. Gao, "NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space," *Remote Sens Environ*, vol. 58, no. 3, 1996, doi: 10.1016/S0034-4257(96)00067-3.