

Optimalisasi ANN-MLP dengan *GridSearch-CV* untuk Klasifikasi Tutupan Lahan Perkotaan Menggunakan Sentinel-2

Mayhendra Daud Sihaloho*, dan Arie Yulfa

Departemen Geografi, Fakultas Ilmu Sosial, Universitas Negeri Padang, Indonesia

*mayhendradsihaloho@gmail.com

ARTICLE INFO

Article History:

Received: 28/06/2025

Revision: 11/09/2025

Accepted: 11/11/2025

KETENTUAN SITASI

Sihaloho, M. D., Yulfa, A., (2025). *Optimalisasi ANN-MLP dengan GridSearch-CV untuk Klasifikasi Tutupan Lahan Perkotaan Menggunakan Sentinel-2.* Geadidaktika. Vol. 5 No. 2.

Copyright © 2024
Geadidaktika (E-ISSN
2774-339X)

<https://dx.doi.org/10.20961/gea.v5i2.105095>

ABSTRAK

Klasifikasi tutupan lahan yang akurat menjadi dasar penting bagi perencanaan dan pengelolaan wilayah perkotaan yang berkelanjutan. Penelitian ini mengoptimalkan model Artificial Neural Network Multi-Layer Perceptron (ANN-MLP) dengan *GridSearchCV* menggunakan citra Sentinel-2 untuk mengklasifikasi tutupan lahan di Kota Padang. Dengan 500 sampel dari lima kelas tutupan lahan dan validasi berbasis citra resolusi tinggi, model yang dioptimasi mencapai akurasi 97% dan nilai Kappa 96,25%. Hasil ini menunjukkan efektivitas optimasi hyperparameter dalam meningkatkan kinerja klasifikasi sekaligus memberikan kontribusi praktis bagi pemerintah daerah, seperti memetakan perkembangan kota, mengidentifikasi alih fungsi lahan, mengarahkan pembangunan sesuai daya dukung lingkungan, dan memperkuat kebijakan tata ruang berbasis data. Pendekatan ini juga dapat direplikasi di daerah lain dengan karakteristik serupa. Kata Kunci: ANN-MLP; hyperparameter; *gridsearchcv*; klasifikasi tutupan lahan; sentinel-2

ABSTRACT

Accurate land cover classification is essential for sustainable urban planning and management. This study optimizes the Artificial Neural Network Multi-Layer Perceptron (ANN-MLP) model using *GridSearchCV* and Sentinel-2 imagery to classify urban land cover in Padang City. Based on 500 samples across five land cover classes and validated with high-resolution imagery, the optimized model achieved 97% accuracy and a Kappa value of 96.25%. These results highlight the effectiveness of hyperparameter optimization in improving classification performance while offering practical contributions for local governments, including mapping urban growth, identifying land-use changes, guiding development according to environmental capacity, and strengthening data-driven spatial planning policies. The proposed approach can also be replicated in other regions with similar characteristics.

Keywords: ANN-MLP; hyperparameter; *gridsearchcv*; urban land classification; sentinel-2

A. PENDAHULUAN

Perkembangan teknologi penginderaan jauh dan komputasi modern telah banyak mengubah cara analisis tutupan lahan, terutama dalam bidang geografi dan perencanaan wilayah. Data spasial kini menjadi dasar penting dalam pengambilan keputusan terkait dinamika penggunaan lahan dan kondisi lingkungan (Yulfa et al., 2022). Perubahan tutupan lahan di kawasan perkotaan akibat urbanisasi yang cepat berdampak pada kualitas lingkungan dan keberlanjutan ekosistem (Lillesand et al., 2015). Dalam konteks ini, citra satelit Sentinel-2 dengan resolusi menengah dan cakupan multispektral yang luas menjadi salah satu sumber data utama yang potensial untuk pemetaan lahan perkotaan (Drusch et al., 2012). Pentingnya data yang akurat juga tercermin dalam kebijakan nasional, misalnya Peraturan Presiden No. 108 Tahun 2021 tentang perencanaan tata ruang serta pemantauan rutin KLHK (2020), yang menekankan kebutuhan metode klasifikasi yang presisi dan efisien.

Berbagai penelitian sebelumnya telah menggunakan metode pembelajaran mesin untuk klasifikasi tutupan lahan. Artificial Neural Network (ANN), khususnya Multi-Layer Perceptron (MLP), banyak digunakan karena mampu menangani data non-linear dan menghasilkan akurasi yang baik (Lee et al., 2020). Meski demikian, performa MLP sangat dipengaruhi oleh konfigurasi hyperparameter, sehingga diperlukan optimasi yang tepat. Salah satu metode yang banyak dipakai adalah GridSearchCV, yang terbukti mampu meningkatkan kinerja model klasifikasi (Ippolito, 2022; bi et al., 2025). Namun, sebagian besar penelitian masih berfokus pada skala global atau regional dengan algoritma seperti Random Forest (Zhang et al., 2021), sedangkan penerapan optimasi ANN-MLP berbasis GridSearchCV pada konteks urban tropis di Indonesia, khususnya Kota Padang, belum banyak dilakukan.

Kebaruan penelitian ini terletak pada penerapan ANN-MLP yang dioptimasi dengan GridSearchCV untuk klasifikasi tutupan lahan perkotaan menggunakan data Sentinel-2. Pendekatan ini mengisi celah dari penelitian sebelumnya yang cenderung hanya menggunakan algoritma klasik atau ANN tanpa optimasi sistematis. Selain itu, hasil penelitian ini diharapkan memberi manfaat praktis berupa peta tutupan lahan yang lebih akurat dan dapat dipakai pemerintah daerah untuk mendukung perencanaan tata ruang, pengendalian alih fungsi lahan, mitigasi bencana, serta pengelolaan lingkungan perkotaan secara berkelanjutan.

Dengan demikian, tujuan penelitian ini adalah menilai sejauh mana integrasi ANN-MLP dan GridSearchCV dapat meningkatkan akurasi klasifikasi tutupan lahan di Kota


Data utama berupa citra Sentinel-2 (periode Juli 2024–Maret 2025) dengan resolusi 10 m. Analisis memanfaatkan enam band spektral (B2, B3, B4, B8, B11, B12) dan lima indeks spektral (NDVI, NDBI, NDWI, NDMI, CMRI) untuk memperkuat diskriminasi antar kelas tutupan lahan. Berikut merupakan formula dari tiap indeks spektral di tampilkan pada Tabel 1.

Tabel 1. Indeks spektral beserta formulanya

Indeks Spektral	Formula Sentinel-2	Keterangan
NDVI (<i>Normalized Difference vegetation index</i>)	$NDVI = \frac{NIR - Red}{NIR + Red}$	Nilai NDVI berkisar antara -1 hingga 1, dengan nilai tinggi (>0,6) menunjukkan vegetasi yang sehat dan padat, sedangkan nilai rendah (<0,1) menunjukkan area non-vegetasi seperti air atau lahan terbangun (Rouse et al., 1974).
NDBI (<i>Normalized Difference Built-up</i>)	$NDBI = \frac{SWIR1 - NIR}{SWIR1 + NIR}$	NDBI digunakan untuk mengidentifikasi daerah terbangun. Nilai positif (>0) menunjukkan daerah terbangun, sedangkan nilai negatif menunjukkan area non-terbangun seperti vegetasi atau air (Zha et al., 2003).
NDWI (<i>Normalized Difference Water index</i>)	$NDWI = \frac{Green - NIR}{Green + NIR}$	NDWI digunakan untuk mendeteksi keberadaan air. Nilai tinggi (>0,2) menunjukkan badan air atau kelembaban tanah, sedangkan nilai rendah (<0) menunjukkan vegetasi atau lahan kering (McFeeters, 1996).
NDMI (<i>Normalized Different Moisture Index</i>)	$NDMI = \frac{NIR - SWIR1}{NIR + SWIR1}$	NDMI mengukur kadar air dalam vegetasi. Nilai tinggi (>0,4) menunjukkan vegetasi dengan kelembaban tinggi, sedangkan nilai rendah (<0,1) menunjukkan stres air atau lahan kering (Wilson & Sader, 2002).
CMRI (<i>Combined Mangrove Recognition Index</i>)	$CMRI = NDVI - NDWI$	CMRI dikhususkan untuk identifikasi mangrove. Nilai positif (>0,3) menunjukkan keberadaan mangrove (Son et al., 2017).

3. Diagram Alir Penelitian

Diagram alir penelitian berfungsi sebagai representasi visual yang menggambarkan tahapan, alur kerja, dan logika dalam penelitian. Penelitian ini dianalisis melalui serangkaian tahapan, mulai dari akuisisi data hingga visualisasi hasil. Proses tersebut dapat dilihat pada Gambar 2.



Gambar 2. Diagram Alir Penelitian

4. Tahap Pengerjaan


4.1 Persiapan Data

Tahap awal dalam pengolahan data melibatkan persiapan lingkungan komputasi dan akses ke sumber data yang diperlukan. Ini mencakup tiga langkah utama yakni, koneksi *Google Drive* ke *Google Colab* untuk memungkinkan akses dan pengelolaan data seperti file SHP, menggunakan fungsi *from Google.Colab import Drive* dan *Drive.mount('/content/Drive')* lalu melakukan *Import library Python* yang relevan untuk analisis data spasial dan *machine learning*, seperti *Geopandas* (*import Geopandas as gpd*) dan yang terakhir Integrasi *Google Colab* dengan *Google Earth Engine* (GEE) untuk mengakses dan memperoleh data citra satelit Sentinel-2, yang diawali dengan autentikasi (*ee.Authenticate()*) dan inisialisasi GEE (*ee.Initialize(project='ee-nama_project_di_GEE')*). Untuk memperoleh data primer berupa *shapefile Area of Interest*, dilakukan proses pembuatan *shapefile* baru menggunakan perangkat lunak Sistem Informasi Geografis (SIG). Proses ini bertujuan untuk mendefinisikan batas wilayah kajian

secara sistematis dan sesuai dengan standar pemetaan yang berlaku. Hasil akhir dari pembuatan shapefile wilayah kajian tersebut dapat diidentifikasi dan dianalisis sebagaimana ditampilkan pada Gambar 1.

4.2 Preprocessing Data


Tahapan preprocessing meliputi koreksi awan, komposit median, normalisasi, serta pemotongan citra sesuai AOI. Band dan indeks kemudian digabungkan sehingga menghasilkan 11 fitur input untuk setiap piksel, di mana hasilnya dapat dilihat pada Gambar 3.



Gambar 3. Visualisasi komposit RGB dan Semu

Tahap berikutnya dalam proses analisis citra mencakup sub-tahap *Feature Extraction*, yang bertujuan untuk menghasilkan informasi tambahan melalui pembentukan indeks spektral. Indeks spektral yang digunakan dalam analisis ini meliputi Normalized Difference Vegetation Index (NDVI), *Normalized Difference Built-up Index* (NDBI), *Normalized Difference Water Index* (NDWI), *Normalized Difference Moisture Index* (NDMI), serta *Combined Morphological Responsive Index* (CMRI). Visualisasi dari indeks-indeks tersebut dapat dilihat pada Gambar 4.

Selanjutnya, dilakukan proses pelabelan (*labeling*) pada band asli (*original band*) dengan indeks spektral yang telah dihasilkan, sehingga total data input yang digunakan dalam analisis mencapai 11 *input layer*. Setelah proses ini selesai, citra Sentinel-2 yang telah diperkaya dengan indeks spektral diekspor ke *Google Drive*. Langkah ini memungkinkan data untuk diunduh dan diproses lebih lanjut guna keperluan analisis serta pengolahan data sampel.



Gambar 4. Visualisasi indeks spektral NDVI, NDBI, NDWI, NDMI dan CMRI

4.3 Sampling Data

Sebanyak 500 titik sampel diambil dengan teknik random sampling, masing-masing 100 titik untuk lima kelas: badan air, vegetasi non-mangrove, mangrove, lahan terbangun, dan lahan terbuka. Random sampling dipilih untuk mengurangi bias peneliti dalam pemilihan sampel serta memberikan peluang yang sama bagi setiap piksel dalam AOI. Distribusi spasial sampel diperiksa secara visual agar representatif terhadap variasi kondisi lahan di seluruh wilayah. Rasio minimal 100 sampel per kelas dipertahankan, sesuai dengan rekomendasi literatur yang menyarankan jumlah seimbang untuk supervised classification (Foody, 2002; Maxwell et al., 2018). Dataset kemudian dibagi menjadi 80% data latih dan 20% data uji. Jumlah sampel tutupan lahan ditunjukkan pada Tabel 2.

Tabel 2. Sampel tutupan lahan

Kode Kelas	Nama Kelas	Jumlah Sampel
0	Badan Air	100
1	Vegetasi Non-Mangrove	100
2	Mangrove	100
3	Lahan Terbangun	100
4	Lahan Terbuka	100

Distribusi spasial dari seriap titik-titik sampel yang sebelumnya sudah diperoleh melalui teknik random sampling yang berjumlah 500 titik tersebut dapat dilihat pada Gambar 5.



Gambar 5. Sebaran sampel data

Lalu data dibagi menjadi dua subset, 80% untuk *training* dan 20% untuk *test* seperti yang disajikan pada Tabel 3.

Tabel 3. Pembagian dataset (*Split data*)

Variabel	Jumlah Sampel	Jumlah Fitur	Keterangan
Total Data	500	11	Dataset awal (<i>Features</i> dan labels).
X_{train}	400	11	Data fitur untuk <i>Training</i> (80%).
X_{Test}	100	11	Data fitur untuk <i>Testing</i> (20%).
y_{train}	400	-	Label untuk <i>Training</i> .
y_{Test}	100	-	Label untuk <i>Testing</i> .

Parameter dalam MLP pengaturan atau konfigurasi yang digunakan untuk mengontrol bagaimana model MLP bekerja, mulai dari struktur jaringan, proses *training*, hingga optimisasi. Dalam beberapa eksperimen, penulis menggunakan 80% data untuk training dan 20% untuk testing sebagai praktik karena penggunaan split ini sudah umum digunakan serta menghindari terjadinya *overfitting*. (Sharma et al., 2020)

Model MLP awal menggunakan konfigurasi *default* (1 hidden layer, 100 neuron, ReLU activation, optimizer Adam, max_iter=200). Untuk meningkatkan performa, dilakukan optimasi hyperparameter dengan GridSearchCV. Ruang pencarian hyperparameter meliputi variasi jumlah hidden layer, fungsi aktivasi, solver, learning rate, max iter dan learning rate init dapat dilihat pada Tabel 4.

Tabel 4. Ruang Pencarian Hyperparameter MLP dengan GridSearchCV

Parameter	Nilai yang bisa dicoba
<i>hidden_layer_sizes</i>	50, 100, 150, 200, 250
<i>activation</i>	tanh, relu, logistic
<i>solver</i>	adam, sgd
<i>learning_rate</i>	constant, adaptive
<i>max_iter</i>	300, 500, 700
<i>learning_rate_init</i>	0.0001, 0.001, 0.01

Penentuan nilai *hidden layer*, *max iter*, dan *learning rate init* dapat dikustomisasi, tetapi konfigurasi yang tidak tepat, khususnya pada jumlah unit hidden layer dan learning rate, dapat memicu masalah seperti underfitting atau kegagalan konvergensi. Sebaliknya, pemilihan hyperparameter yang optimal dapat mempercepat proses pelatihan dan meningkatkan performa model. Oleh karena itu, GridSearchCV diterapkan untuk menguji seluruh kombinasi hyperparameter melalui validasi silang (*5-fold cross-validation*) guna memperoleh konfigurasi paling efektif. (Goodfellow et al., 2016).


C. HASIL DAN PEMBAHASAN

1. Hasil uji Parameter Default

Hasil parameter *default* diperoleh melalui pengujian menggunakan data uji. Parameter ini bersifat *fixed* (tidak dapat dimodifikasi) karena menjadi acuan dasar dalam pemodelan, dapat dianalisis melalui representasi dalam bentuk tabel dan matriks konfusi (*Confusion Matrix*). Evaluasi ini bertujuan untuk memahami tingkat akurasi serta distribusi klasifikasi yang dihasilkan oleh model. Informasi mengenai hasil uji parameter *default* tersebut disajikan secara sistematis dalam Tabel 5 dan Gambar 6.

Tabel 5. Hasil *evaluation assessment* dengan parameter *default*

Kelas	Precision	Recall	F1-Score	Support
0	1.0000	0.9000	0.9474	20
1	1.0000	1.0000	1.0000	20
2	1.0000	1.0000	1.0000	20
3	1.0000	0.9000	0.9474	20
4	0.8333	1.0000	0.9091	20
<i>Accuracy</i>		0.9600		100
<i>Macro Avg</i>	0.9667	0.9600	0.9608	100
<i>Weighted Avg</i>	0.9667	0.9600	0.9608	100



Gambar 6. *Confusion Matrix parameter default*

Overall Accuracy sebesar 0.9600 atau 96% Untuk skor koefisien *Kappa* sebesar 0.95 atau 95% hal ini menunjukkan performa yang baik pada default parameter.

2. Optimalisasi menggunakan *hyperparameter*

Dalam upaya mengoptimalkan performa model ANN-MLP, dilakukan penyesuaian *hyperparameter* menggunakan metode *GridSearch-CV*. Modifikasi parameter yang diterapkan dalam *GridSearchCV* dirinci dalam Tabel 6, yang menyajikan variasi nilai *hyperparameter* yang diuji serta dampaknya terhadap kinerja model.

Tabel 6. *Hyperparameter* untuk *training* menggunakan *GridSearchCV*

Parameter	Nilai yang Dicoba
<i>hidden_Layer_sizes</i>	(150, 100), (200, 100), (250,100)
<i>activation</i>	tanh, relu
<i>Solver</i>	adam, sgd
<i>learning_rate</i>	constant, adaptive
<i>max_iter</i>	300, 500, 700
<i>learning_rate_init</i>	0.0001, 0.001, 0.01

Training memakan waktu 862.317 detik atau sekitar 14,4 menit dengan *fitting* 5 *folds* untuk 216 kandidat, menghasilkan 1080 *fit* (216 kandidat x 5 fold). Hasil dari *training* tersebut, di pilih *Best parameters* yang mana di dapati hasil *training* seperti yang ditampilkan pada Tabel 7.


Tabel 7. Hasil *training best hyperparameter GridSearchCV*

Parameter	Nilai
<i>random_state</i>	42
<i>hidden_layer_sizes</i>	(150, 100)
<i>activation</i>	'tanh'
<i>solver</i>	'adam'
<i>learning_rate</i>	'constant'
<i>learning_rate_init</i>	0.001
<i>max_iter</i>	300

Setelah proses *training* selesai, *best hyperparameter* yang diperoleh disajikan dalam Tabel 8, sementara hasil evaluasi model ditampilkan melalui matriks konfusi pada Gambar 7.

Tabel 8. Hasil *evaluation assessment best hyperparameter Tuning dengan GridSearchCV*


Kelas	Precision	Recall	F1-Score	Support
0	1.0000	1.0000	1.0000	20
1	0.9524	1.0000	0.9756	20
2	1.0000	0.9500	0.9744	20
3	1.0000	0.9500	0.9744	20
4	0.9091	1.0000	0.9524	20
<i>Accuracy</i>	0.9700			100
Macro Avg	0.9723	0.9700	0.9699	100
Weighted Avg	0.9723	0.9700	0.9699	100

Gambar 7. *Confusion Matrix* dengan *best hyperparameter Tuning GridSearchCV*

Hasil evaluasi meingkat menjadi 97% atau 0.97 dan untuk koefisien *Kappa* 0.9625 atau 96,25%. Hal ini membuktikan bahwa optimalisasi menggunakan *GridSearchCV* berhasil melakukan optimalisasi pada model tutupan lahan.

3. Visualisasi Hasil

Visualisasi hasil optimasi *hyperparameter* pada model MLP dilakukan menggunakan *library Matplotlib*, yang umum digunakan dalam evaluasi kinerja model *machine learning*. Representasi visual dari hasil pemodelan *best hyperparameter GridSearch-CV* disajikan pada Gambar 8.



Gambar 8. Hasil pemetaan penutup lahan dengan best MLP model

4. Pembahasan

Peningkatan akurasi dari 96% menjadi 97% memang terlihat kecil jika hanya dilihat dari angka, namun dalam konteks spasial dampaknya sangat berarti. Pada area penelitian seluas 100.000 hektar, misalnya, tambahan 1% akurasi setara dengan sekitar 1.000 hektar lahan yang kini terklasifikasi dengan benar. Luas ini bisa mencakup kawasan pertanian, mangrove, atau permukiman yang sebelumnya keliru teridentifikasi, sehingga berpengaruh langsung terhadap ketepatan peta tematik yang digunakan untuk perencanaan. Meski begitu, analisis lebih lanjut menunjukkan masih ada kesalahan pada kelas tertentu, terutama lahan terbuka dan lahan terbangun. Keduanya memiliki ciri spektral yang mirip, sehingga sering tertukar, terutama di wilayah perkotaan yang kompleks dan heterogen. Kesalahan juga ditemukan di daerah pesisir, di mana vegetasi

darat dan mangrove saling tumpang tindih sehingga menimbulkan ambiguitas. Visualisasi spasial memperlihatkan bahwa pola distribusi tutupan lahan secara umum sesuai dengan kondisi nyata: air mengikuti alur sungai dan garis pantai, vegetasi mendominasi kawasan pedesaan, mangrove terkonsentrasi di pesisir, sementara lahan terbangun menyebar dari pusat kota hingga ke daerah pinggiran. Lahan terbuka sendiri lebih banyak muncul sebagai area transisi, seperti sawah yang tidak ditanami atau lahan reklamasi. Pola ini memperlihatkan bahwa kesalahan klasifikasi tidak acak, melainkan banyak terjadi di batas antar kelas dan kawasan dengan dinamika tinggi. Hasil ini memiliki implikasi langsung bagi pemerintah daerah, terutama dalam perencanaan tata ruang, pengendalian alih fungsi lahan, perlindungan ekosistem pesisir, hingga mitigasi bencana. Dengan peta yang lebih akurat, estimasi tutupan vegetasi untuk inventarisasi karbon maupun kebutuhan ruang perkotaan dapat dilakukan dengan lebih percaya diri. Peningkatan performa model ini dicapai melalui penerapan GridSearchCV yang menyeleksi kombinasi hyperparameter secara menyeluruh sehingga menghasilkan konfigurasi yang stabil. Dengan demikian, meskipun kenaikan akurasi hanya 1%, dampak spasial dan manfaat praktisnya jauh lebih besar untuk mendukung pengelolaan wilayah secara berkelanjutan.

D. KESIMPULAN

Penelitian ini membuktikan bahwa penerapan GridSearchCV pada model ANN-MLP mampu meningkatkan akurasi klasifikasi tutupan lahan perkotaan dari 96% menjadi 97% dengan nilai Kappa 96,25%. Hasil ini sejalan dengan studi Achmad et al. (2023), namun penelitian ini memiliki fokus berbeda karena menggunakan data Sentinel-2 pada kawasan urban tropis di Indonesia. Kebaruan penelitian terlihat dari kombinasi ANN-MLP dengan GridSearchCV, pemanfaatan data spektral dan indeks secara bersamaan, serta penerapan cloud computing yang membuat proses komputasi lebih efisien. Dibandingkan dengan pendekatan Zhang et al. (2021) yang menggunakan Random Forest, ANN-MLP lebih fleksibel dalam mengolah data yang kompleks dan non-linear.

Meski akurasinya tergolong tinggi, evaluasi spasial menunjukkan masih ada kelemahan terutama di batas antar kelas, yang dipengaruhi oleh keterbatasan resolusi Sentinel-2 jika dibandingkan dengan citra resolusi tinggi, seperti dijelaskan oleh Jensen (2015). Faktor lain seperti teknik sampling, kualitas data pelatihan, dan keragaman

tutupan lahan juga berpengaruh pada hasil klasifikasi. Hal ini menegaskan bahwa angka akurasi belum tentu mencerminkan ketepatan spasial, sebagaimana diingatkan oleh Foody & Arora (1997). Ke depan, penelitian ini dapat ditingkatkan dengan penggunaan data multitemporal, citra resolusi tinggi, dan metode deep learning yang lebih adaptif untuk mengurangi kesalahan pada area transisi serta memperkuat ketepatan hasil di lapangan.

E. DAFTAR PUSTAKA

- Achmad, R. R., & Haris, M. (2023). Hyperparameter Tuning Deep Learning for Imbalanced Data. *Tepian*, 4(2), 90-101.
- Bahrami, H., Chokmani, K., Homayouni, S., Adamchuk, V. I., Albasha, R., Saifuzzaman, M., & Leduc, M. (2025). Machine Learning-Based Alfalfa Height Estimation Using Sentinel-2 Multispectral Imagery. *Remote Sensing*, 17(10), 1759.
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Labertini, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., & Bargellini, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote sensing of Environment*, 120, 25-36.
- Foody, G. M., & Arora, M. K. (1997). An evaluation of some factors affecting the Accuracy of classification by an Artificial Neural Network. *International Journal of Remote Sensing*, 18(4), 799-810.
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1, No. 2). Cambridge: MIT press.
- Ippolito, P. P. (2022). Hyperparameter Tuning: the art of fine-Tuning Machine and deep Learning models to improve metric results. In *Applied data science in tourism: Interdisciplinary approaches, methodologies, and applications* (pp. 231-251). Cham: Springer International Publishing.
- Jensen, J.R. (2015). *Introductory Digital Image Processing: A Remote Sensing Perspective*. 4th Edition, Prentice Hall Press, Upper Saddle River.
- Kementerian Lingkungan Hidup dan Kehutanan (KLHK). (2020). *Laporan Pemantauan Tutupan Lahan untuk Mengatasi Deforestasi, Degradasi Lahan, dan Perubahan Iklim*. Jakarta: Kementerian Lingkungan Hidup dan Kehutanan.
- Lee, Y. S., Lee, S., & Jung, H. S. (2020). Mapping forest vertical structure in Gong-Ju, Korea using Sentinel-2 satellite images and artificial neural networks. *Applied Sciences*, 10(5), 1666.
- Lillesand, T., Kiefer, R. W., & Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.

- 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.
- McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International journal of remote sensing*, 17(7), 1425-1432.
- Pemerintah Indonesia. (2007). Undang-Undang Nomor 26 Tahun 2007 tentang Penataan Ruang. Lembaran Negara Republik Indonesia Tahun 2007 Nomor 68. Tambahan Lembaran Negara Republik Indonesia Nomor 4725. Jakarta: Pemerintah Pusat.
- Pemerintah Indonesia. (2021). Peraturan Presiden Nomor 108 Tahun 2021 tentang Rencana Tata Ruang Kawasan Strategis Nasional. Lembaran Negara Republik Indonesia Tahun 2021 Nomor 108. Jakarta: Pemerintah Pusat.
- Rouse Jr, J. W., Haas, R. H., Deering, D. W., Schell, J. A., & Harlan, J. C. (1974). Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation (No. E75-10354).
- Sharma, A., Jain, A., Gupta, P., & Chowdary, V. (2020). Machine learning applications for precision agriculture: A comprehensive review. *IEEe Access*, 9, 4843-4873.
- Son, N. T., Chen, C. F., Chang, N. B., Chen, C. R., Chang, L. Y., & Thanh, B. X. (2014). Mangrove mapping and change detection in Ca Mau Peninsula, Vietnam, using Landsat data and object-based image analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(2), 503-510.
- Wilson, E. H., & Sader, S. A. (2002). Detection of forest harvest type using multiple dates of Landsat TM imagery. *Remote Sensing of Environment*, 80(3), 385-396.
- Yulfa, A., Chandra, D., Ramadhan, R., & Andreas, A. (2022). Geovisualization for information extraction of shoreline changes in Padang city 2000–2020. *Geodesy and Cartography*, 48(2), 78-84.
- Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International journal of remote sensing*, 24(3), 583-594.
- Zhang, T., Su, J., Xu, Z., Luo, Y., & Li, J. (2021). Sentinel-2 satellite imagery for urban land cover classification by optimized random forest classifier. *Applied Sciences*, 11(2), 543.
- Zhang, Y., Liu, Y., & Wang, X. (2019). *Artificial Neural Networks and Their Applications. Computational Intelligence and Neuroscience*, 2019, 1-10.