

Evaluasi Algoritma Machine Learning untuk Klasifikasi dan Prediksi Penggunaan Lahan

Fajar Nugraha^{1*}, Dwi Putro Tejo Baskoro¹, Suria Darma Tarigan¹

¹ Departemen Ilmu Tanah dan Sumberdaya Lahan, Fakultas Pertanian, Institut Pertanian Bogor, Indonesia

* Email koresponden: 23fnugraha@apps.ipb.ac.id

Submitted: 2024-08-14 Revisions: 2024-11-13 Accepted: 2025-02-17 Published: 2025-02-17

©2025 Fakultas Geografi UGM dan Ikatan Geograf Indonesia (IGI)

©2025 by the authors. Majalah Geografi Indonesia.

This article is an open access article distributed under the terms and conditions of the Creative Commons

Attribution (CC BY SA) <https://creativecommons.org/licenses/by-sa/4.0/>

Abstrak. Pemantauan, perencanaan, dan pengelolaan sumberdaya lahan membutuhkan data penggunaan lahan yang akurat. Banyak penelitian telah dilakukan mengenai klasifikasi dan prediksi penggunaan lahan. Namun, penelitian terkait penentuan metode klasifikasi dan prediksi yang akurat masih sangat penting. Penelitian ini bertujuan untuk mengevaluasi algoritma machine learning dalam klasifikasi dan prediksi penggunaan lahan serta menganalisis perubahan penggunaan lahan tahun 2002-2032. Area studi penelitian ini yaitu Sub DAS Tanralili, klasifikasi menggunakan Dzetsaka dengan algoritma seperti kNN, GMM, RF, dan SVM, dan prediksi menggunakan MOLUSCE dengan model CA yang dikombinasi dengan ANN, LR, WoE, dan MCE. Model dievaluasi menggunakan *overall accuracy* dan kappa, akurasi tertinggi pada tahun 2002, 2012, dan 2022 masing-masing adalah kNN (kappa 0,92), SVM (kappa 0,86), dan GMM (kappa 0,74). Algoritma SVM memiliki kappa rata-rata tertinggi untuk klasifikasi sebesar 0,83, sedangkan model CA-ANN menunjukkan nilai kappa tertinggi untuk prediksi sebesar 0,65. Pada periode 2002-2022, terjadi penurunan hutan sekunder (4.184,0 ha), pertanian lahan kering (1.259,3 ha), dan badan air (328,0 ha), sedangkan peningkatan pada semak belukar (5.303,3 ha), sawah (367,0 ha), padang rumput (64,5 ha), dan permukiman (36,5 ha). Pada periode 2022-2032 menunjukkan penurunan hutan sekunder (554,2 ha), sawah (332,6 ha), padang rumput (192,8 ha), dan badan air (33,4 ha), sedangkan peningkatan pada semak belukar (700,9 ha), pertanian lahan kering (401,1 ha), dan permukiman (1,1 ha).

Kata kunci: Dzetsaka; Kappa, Molusce; Perencanaan; Sub DAS Tanralili

Abstract. Monitoring, planning, and managing land resources require accurate land use data. Many studies have been conducted on land use classification and prediction. However, research related to determining accurate classification and prediction methods is still very important. This study aimed to evaluate machine learning algorithms in land use classification and prediction and analyzed land use change from 2002 to 2032. The study area of this research was the Tanralili Sub Watershed, with classification using Dzetsaka and algorithms such as kNN, GMM, RF, and SVM, and prediction using MOLUSCE with the CA model combined with ANN, LR, WoE, and MCE. The models were evaluated using *overall accuracy* and kappa; the highest accuracy in 2002, 2012, and 2022 were kNN (kappa 0.92), SVM (kappa 0.86), and GMM (kappa 0.74), respectively. The SVM algorithm had the highest average kappa for classification at 0.83, while the CA-ANN model showed the highest kappa value for prediction at 0.65. In the period 2002-2022, there was a decrease in secondary forests (4,184.0 ha), dry land agriculture (1,259.3 ha), and water bodies (328.0 ha), while an increase in shrubs (5,303.3 ha), rice fields (367.0 ha), grasslands (64.5 ha), and settlements (36.5 ha). The 2022-2032 period predicted a decrease in secondary forests (554.2 ha), rice fields (332.6 ha), grasslands (192.8 ha), and water bodies (33.4 ha), while an increase in shrubs (700.9 ha), dry land farming (401.1 ha), and settlements (1.1 ha).

Keywords: Dzetsaka; Kappa; Molusce; Plannin; Tanralili Sub-Watershed

PENDAHULUAN

Data penggunaan lahan yang akurat memainkan peranan penting dalam pemantauan (Widayani et al., 2023), perencanaan dan pengelolaan sumber daya lahan (Danoedoro et al., 2024; Putri et al., 2024). Perubahan penggunaan lahan merupakan proses dinamis (Widayani et al., 2023), yang telah menjadi bagian dari kebijakan-kebijakan pemerintah (Pande et al., 2024; Sparey et al., 2024). Proses ini dipengaruhi oleh pertumbuhan penduduk dan aktivitas ekonomi (Mao et al., 2024). Pertumbuhan penduduk yang tinggi menimbulkan kekhawatiran terhadap ketersediaan sumber daya lahan, untuk kegiatan pertanian dan permukiman (Pande et al., 2024).

Informasi penggunaan lahan dapat diperoleh melalui pengamatan langsung (*earth observation*) (Zhao et al., 2024)

dan memanfaatkan teknologi sistem informasi geografis (SIG) serta penginderaan jauh (Putri et al., 2024; Widayani et al., 2023). Teknologi penginderaan jauh telah dimanfaatkan untuk klasifikasi penggunaan lahan sejak setengah abad yang lalu (Danoedoro et al., 2024) dan terus mengalami perkembangan. Saat ini, klasifikasi penggunaan lahan sering menggunakan metode klasifikasi terbimbing (*supervised classification*) dan klasifikasi tidak terbimbing (*unsupervised classification*) dengan memanfaatkan algoritma *machine learning* (ML) yang memiliki proses lebih cepat dan akurat dibandingkan metode konvensional seperti (*maximum likelihood classification* dan *minimum distance*) (Chowdhury, 2024; Ghayour et al., 2021).

Beberapa algoritma ML yang seperti *random forest* (RF), *support vector machine* (SVM) (Chowdhury, 2024; Iqbal et al.,

2023), *gaussian mixture model* (GMM) (Iqbal et al., 2023), dan *k-nearest neighbor* (kNN) (Iqbal et al., 2023) sering digunakan dalam klasifikasi penggunaan lahan. Selain itu, algoritma ML juga dapat digunakan untuk memprediksi penggunaan lahan di masa depan (Hariyanto et al., 2024; Yue et al., 2024), yang sangat penting untuk perencanaan dan pengelolaan sumber daya lahan. Algoritma ML dapat melakukan pelatihan non-parametrik, sehingga dapat mempelajari pola-pola perubahan penggunaan lahan yang terjadi sebelumnya (Baig et al., 2022; Lukas et al., 2023) dan faktor yang mempengaruhi terjadinya perubahan tersebut (Yue et al., 2024). Algoritma ML yang umum digunakan untuk memprediksi penggunaan lahan seperti *artificial neural network* (ANN), dan *logistic regression* (LR) (Hariyanto et al., 2024).

Penelitian mengenai klasifikasi dan prediksi penggunaan lahan menggunakan algoritma ML saat ini telah banyak dilakukan (Hariyanto et al., 2024; Iqbal et al., 2023). Namun, penelitian terkait pemilihan jenis algoritma yang akurat untuk klasifikasi (Aryal et al., 2023) dan prediksi (Sparey et al., 2024) masih menjadi topik penting. Hal tersebut berguna untuk menghasilkan data penggunaan lahan yang akurat dan menjadi database bagi pemangku kepentingan (Pande et al., 2024; Sparey et al., 2024), yang dapat digunakan dalam menentukan suatu kebijakan.

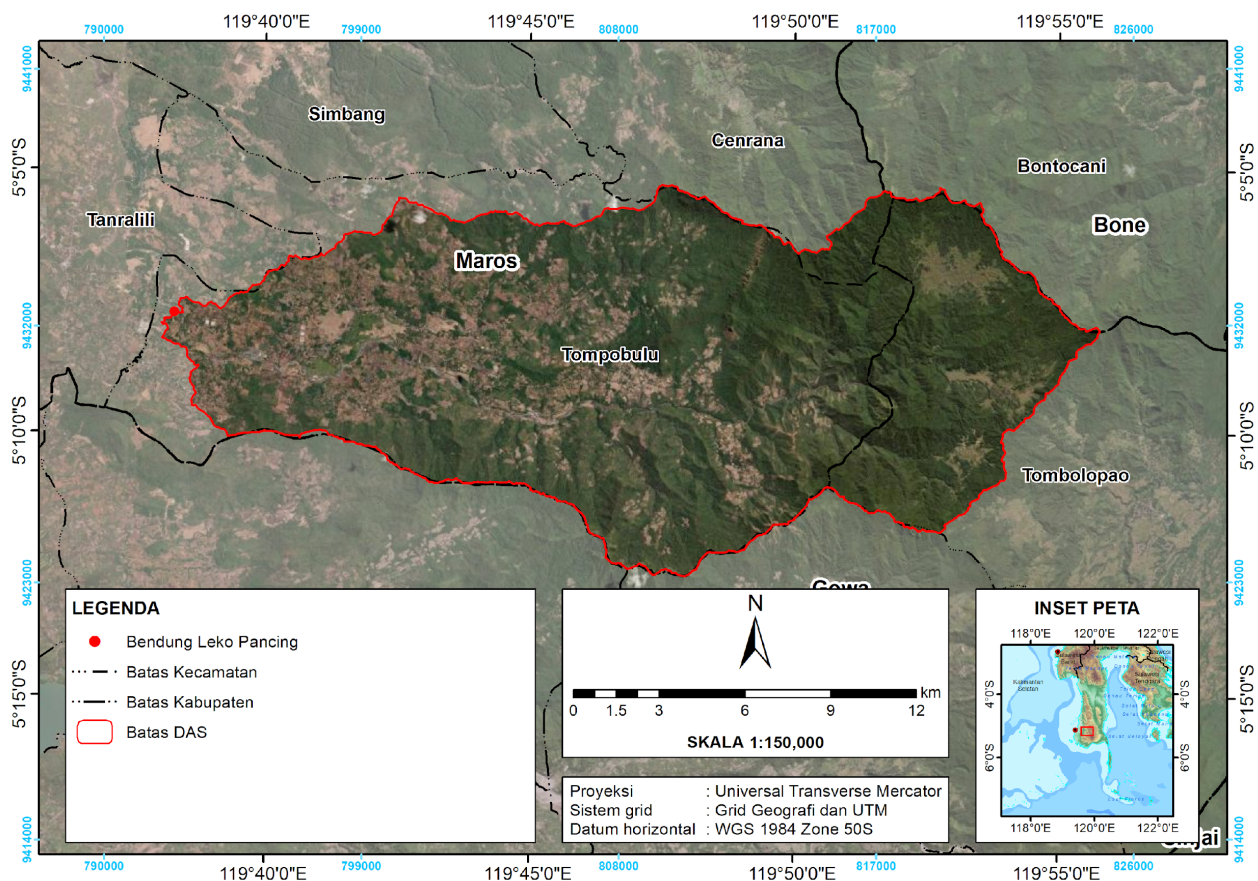
Penelitian ini juga menggunakan data penginderaan jauh yang mudah diakses dan bebas biaya (*opensource*), seperti citra Landsat. Citra ini dipilih karena memiliki arsip data yang panjang (Wulder et al., 2019) dan resolusi spasial yang dapat ditingkatkan hingga 15 meter menggunakan saluran (*band*) *panchromatic* (Ouchra et al., 2024; Wulder et al., 2019). Penggunaan citra tersebut cukup penting, agar memudahkan semua pihak atau peneliti yang tertarik dengan isu perubahan

penggunaan lahan untuk melakukan studi yang serupa (Iqbal et al., 2023). Area studi penelitian adalah Sub DAS Tanralili merupakan Sub dari DAS Maros yang berperan sebagai sumber air bersih bagi wilayah PDAM Kota Makassar dan PDAM Kabupaten Maros (Imran & Djafar, 2020; Surahman, 2017; Syafri et al., 2020), serta digunakan untuk berbagai keperluan seperti pertanian, perikanan (Imran & Djafar, 2020; Surahman, 2017), transportasi dan wisata (Imran & Djafar, 2020). Namun, Sub DAS Tanralili menghadapi berbagai masalah, seperti kekeringan, erosi (Imran & Djafar, 2020; Surahman, 2017), banjir (Surahman, 2017), dan longsor (Hasnawir et al., 2017), yang disebabkan oleh perubahan penggunaan lahan akibat pertumbuhan penduduk di Kabupaten Maros (Ekasari et al., 2021; Imran & Djafar, 2020; Syafri et al., 2020). Penelitian ini bertujuan untuk membandingkan dan mengevaluasi algoritma ML dalam klasifikasi dan prediksi penggunaan lahan, menganalisis perubahan penggunaan lahan periode 2002-2032.

METODE PENELITIAN

Area studi

Area studi yang menjadi lokasi penelitian yaitu Sub Daerah Aliran Sungai (DAS) Tanralili yang merupakan Sub dari DAS Maros, Provinsi Sulawesi Selatan. Secara geografis Sub DAS Tanralili berada pada koordinat $5^{\circ} 5' - 5^{\circ} 12'$ lintang selatan dan $119^{\circ} 38' - 119^{\circ} 55'$ bujur timur. Secara administratif terletak di Kecamatan Tompobulu Kabupaten Maros dan Kecamatan Tombolopao Kabupaten Gowa. Sub DAS Tanralili dengan hilir yang berada di Bendungan Leko Pancing memiliki luas wilayah sekitar 27.973 ha, dengan keadaan topografi yang didominasi dengan pegunungan di bagian timur dan dataran rendah di bagian barat.



Gambar 1. Peta lokasi penelitian

Dataset Penelitian

Dataset yang digunakan dalam penelitian ini yaitu Citra Landsat 7 ETM+ tahun 2002, dan 2012, serta 8 OLI tahun 2022 pada *path* 114 dan *row* 64, yang diunduh melalui situs United States Geological Survey (USGS) (<https://earthexplorer.usgs.gov/>). Faktor pendorong yang digunakan untuk prediksi penggunaan lahan, meliputi elevasi dan lereng yang diperoleh dari data *digital elevation model* (DEM) Alos Palsar yang diunduh melalui situs Alaska Satellite Facility (ASF) (<https://search.asf.alaska.edu/#/>); jarak dari jalan, sungai dan permukiman yang diperoleh dari rupa bumi Indonesia (RBI) digital yang diunduh melalui situs Tanah Air Indonesia (<https://tanahair.indonesia.go.id/>); dan jenis tanah yang diperoleh dari Balai Besar Sumber Daya Lahan Pertanian (BBSDLP).

Preprocessing data

Preprocessing data citra satelit meliputi koreksi geometrik yang bertujuan untuk mengurangi kesalahan geometri pada citra satelit (Priyanto et al., 2021). Menggabungkan *band* (saluran) pada citra Landsat yang digunakan, *band* (saluran) yang digunakan diantaranya *blue, green, red, near infrared* (NIR), *short wavelength infrared 1* (SWIR 1) dan *short wavelength infrared 2* (SWIR 2). Penajaman citra dilakukan dengan menggunakan *band* (saluran) *panchromatic* untuk meningkatkan resolusi spasial citra satelit menjadi 15 m (Ouchra et al., 2024). Komposit citra dilakukan dengan mengatur komposisi pewarnaan pada citra dengan mengatur *band* (saluran) yang digunakan. Pengambilan data latih dan validasi yang digunakan dalam membangun model klasifikasi menggunakan algoritma ML yang *dicrosscheck* menggunakan hasil pengecekan lapangan dan menggunakan citra google earth yang memiliki resolusi spasial yang tinggi, dengan perbandingan data latih dan validasi sebesar 70:30.

Klasifikasi Penggunaan Lahan

Klasifikasi penggunaan lahan menggunakan plugin *dzetsaka* pada software QGIS yang mampu menjalankan beberapa algoritma *machine learning*, seperti *random forest* (RF), *support vector machine* (SVM), *gaussian mixture model* (GMM), dan *k-nearest neighbor* (KNN) (Iqbal et al., 2023). Seluruh algoritma tersebut diuji untuk menentukan algoritma yang terbaik dalam klasifikasi penggunaan lahan. Klasifikasi penggunaan lahan diawali dengan melakukan klasifikasi dengan input data citra Landsat dengan bantuan data latih. Hasil klasifikasi setiap algoritma diuji akurasi menggunakan

nilai *overall accuracy* dan kappa. Algoritma yang memiliki rata-rata akurasi tertinggi digunakan untuk memvisualisasikan penggunaan lahan tahun 2002, 2012, dan 2022.

Prediksi Penggunaan Lahan

Prediksi penggunaan lahan menggunakan plugin *Modules for Land-Use Change Simulation* (MOLUSCE) pada software QGIS yang dapat mensimulasikan perubahan penggunaan lahan menggunakan beberapa model, seperti *artificial neural network* (ANN), *logistic regression* (LR), *wight of evidence* (WoE), dan *multi criteria evaluation* (MCE) yang dikombinasikan dengan model matematis *cellular automata* (CA) (Muhammad et al., 2022). Seluruh model tersebut diuji untuk menentukan model terbaik untuk prediksi penggunaan lahan. *Driving factor* yang digunakan untuk prediksi penggunaan lahan, diantaranya elevasi, lereng, jarak dari jalan, sungai (Blissag et al., 2024), permukiman (Shafizadeh-Moghadam et al., 2017), dan jenis tanah (Yue et al., 2024).

Penggunaan lahan tahun 2002 digunakan sebagai data awal (*initial*), sedangkan penggunaan lahan tahun 2012 digunakan sebagai data akhir (*final*). Perubahan penggunaan lahan antara tahun 2002 dan 2012 dianalisis untuk dijadikan variabel dependen dalam prediksi penggunaan lahan. Selanjutnya, *driving factors* yang digunakan diuji korelasinya dengan *Pearson's correlation* untuk melihat hubungan antarvariabel. Pemodelan perubahan potensial dilakukan dengan menggunakan seluruh model yang tersedia dalam *plugin* MOLUSCE. Prediksi penggunaan lahan tahun 2022 dilakukan untuk memvalidasi model yang ada. Model dengan akurasi tertinggi dipilih untuk memprediksi penggunaan lahan pada tahun 2032.

Uji akurasi

Hasil klasifikasi dan prediksi penggunaan lahan dievaluasi menggunakan *overall accuracy* (persamaan 1), dan kappa (persamaan 4). Kappa bertujuan untuk mengevaluasi kesesuaian antara data sampel dan data klasifikasi atau prediksi. Uji akurasi klasifikasi penggunaan lahan membandingkan data latih dan data validasi dengan perbandingan 70:30, sedangkan uji akurasi prediksi penggunaan lahan membandingkan penggunaan lahan hasil klasifikasi tahun 2020 dan prediksi tahun 2020. Penggunaan lahan tahun 2002 dan 2012 didefinisikan sebagai t1 dan t2 yang digunakan untuk memprediksi penggunaan lahan tahun 2022 (t3). Persamaan untuk perhitungan *overall accuracy* dan kappa sebagai berikut (Blissag et al., 2024):

$$\text{Overall accuracy} = \frac{\text{Sum of correctly classified pixels}}{\text{Sum number of pixels (N)}} \times 100$$

$$\text{Overall accuracy} = \frac{\text{Sum of correctly classified pixels}}{\text{Sum number of pixels (N)}} \times 100 \quad \text{NDVI} = \frac{(\text{NIR} - \text{Red})}{(\text{NIR} + \text{Red})} \quad (1)$$

$$\text{Overall accuracy} = \frac{\text{Sum of correctly classified pixels}}{\text{Sum of pixels used for accuracy assessment (N)}} \quad (\text{Blissag et al., 2024})$$

$$P(A) = \sum_{i=1}^c P_{it} P_{tj} P(A) = \sum_{i=1}^c P_{it} P_{tj} \text{NDVI} = \frac{(\text{NIR} - \text{Red})}{(\text{NIR} + \text{Red})} P(E) = \sum_{i=1}^c P_{it} P_{tj} \quad (2)$$

(Blissag et al., 2024)

$$\text{NDVI} = \frac{(\text{NIR} - \text{Red})}{(\text{NIR} + \text{Red})} P(E) = \sum_{i=1}^c P_{it} P_{tj} P(E) = \sum_{i=1}^c P_{it} P_{tj} \quad (\text{Blissag et al., 2024}) \quad (3)$$

$$\text{NDVI} = \frac{(\text{NIR} - \text{Red})}{(\text{NIR} + \text{Red})} \text{Kappa} = \frac{P(A) - P(E)}{1 - P(E)} \text{Kappa} = \frac{P(A) - P(E)}{1 - P(E)} \quad (\text{Blissag et al., 2024}) \quad (4)$$

Dimana Pij adalah sel ke-i, ke-j dari *confusion matrix*, Pit adalah total semua sel dalam baris ke-i, Pjt adalah total semua sel dalam kolom ke-j, dan c adalah jumlah kategori raster. Berdasarkan (Eshetie et al., 2023), nilai kappa dibagi menjadi beberapa tingkatan, antara 0.8 dan 1.0 menunjukkan akurasi yang sangat tinggi, antara 0.6 dan 0.8 menunjukkan akurasi yang tinggi, antara 0.4 dan 0.6 menunjukkan akurasi sedang, 0.2 dan 0.4 menunjukkan akurasi yang rendah, dan antara 0 dan 0.2 menunjukkan akurasi yang sangat rendah.

HASIL DAN PEMBAHASAN

Klasifikasi penggunaan lahan

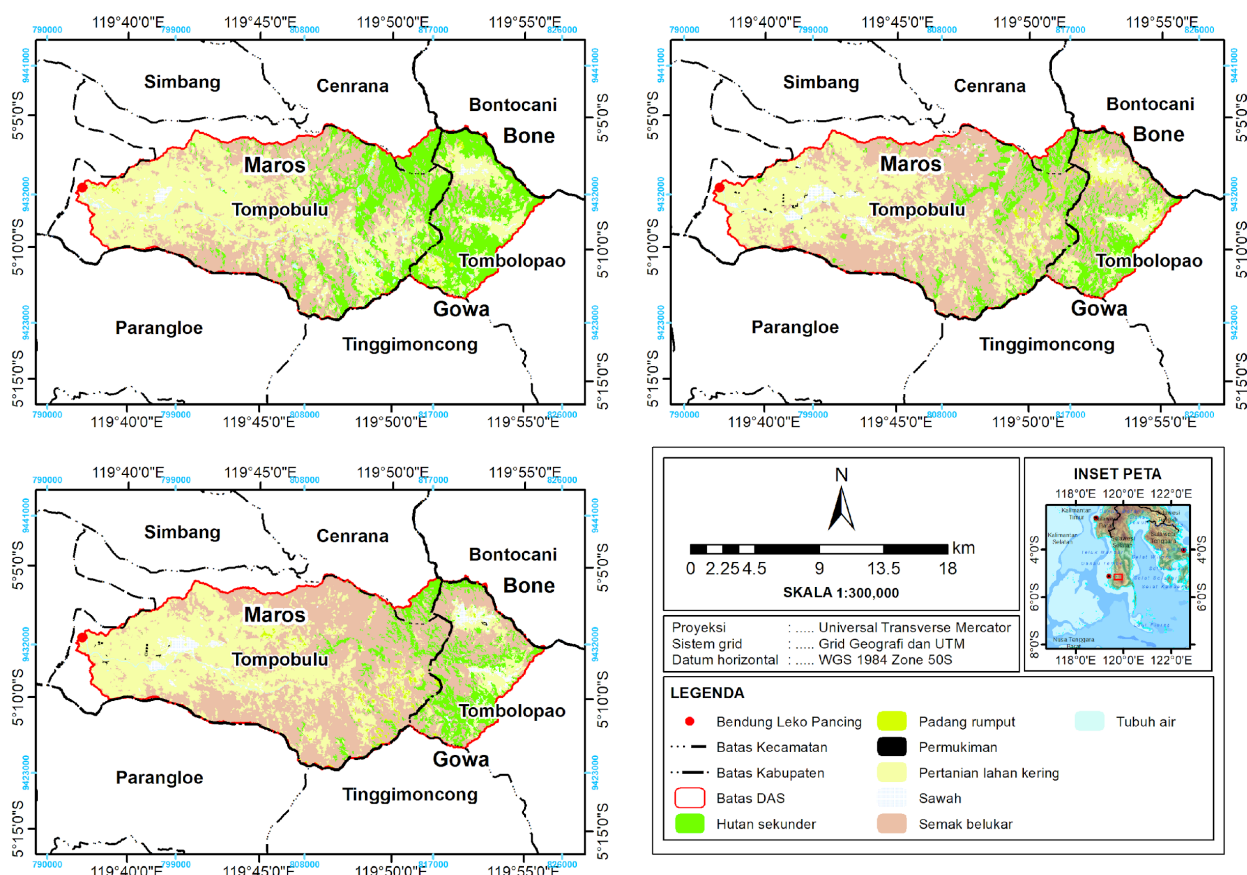
Penggunaan lahan di Sub DAS Tanralili terdiri dari hutan sekunder, semak belukar, sawah, pertanian lahan kering, padang rumput, tubuh air, dan permukiman. Akurasi algoritma ML dalam mengklasifikasi penggunaan lahan menunjukkan hasil yang bervariasi tiap tahunnya. Algoritma yang memiliki akurasi tertinggi pada tahun 2002, 2012 dan 2022 masing-masing adalah kNN (*overall accuracy* 93,23 dan kappa 0,92), SVM (*overall accuracy* 88,29 dan kappa 0,86), dan GMM (*overall accuracy* 78,88 dan kappa 0.74),

yang disajikan pada tabel 1. Algoritma SVM memiliki rata-rata *overall accuracy* dan kappa tertinggi sebesar 86,03 dan 0.83, dan termasuk kedalam kelas yang sangat baik dalam melakukan klasifikasi penggunaan lahan (Eshetie et al., 2023). Berdasarkan penelitian Noi & Kappas (2017) dan Wang & Zeng (2022), akurasi algoritma SVM lebih tinggi dibandingkan algoritma RF dan kNN dalam klasifikasi penggunaan lahan menggunakan citra satelit.

Algoritma SVM dapat melakukan klasifikasi sangat baik, karena algoritma tersebut dapat melakukan klasifikasi dengan akurasi yang tinggi meskipun dengan jumlah sampel yang kecil (Noi & Kappas, 2017; Santarsiero et al., 2022; Wang & Zeng, 2022). Jumlah sampel yang digunakan dalam pelatihan ini masih tergolong sedang jika mengacu pada penelitian Noi dan Kappas (2017). Selain itu, algoritma ini efektif dalam menangani data berdimensi tinggi dan *non-linear* seperti klasifikasi citra, dengan memanfaatkan fungsi kernel untuk memetakan data ke ruang fitur berdimensi lebih tinggi (Al-naeem et al., 2023). Kernel yang diimplementasikan dalam dzetsaka adalah *radial basis function* yang memberikan hasil yang sangat baik (Karasiak & Perbet, 2018). SVM juga dapat

Tabel 1. Validasi klasifikasi penggunaan lahan

Algoritma	2002		2012		2022		Rata-rata	
	Overall Accuracy	Kappa	Overall Accuracy	Kappa	Overall Accuracy	Kappa	Overall Accuracy	Kappa
K-NN	93,23	0,92	83,28	0,80	72,74	0,67	83,08	0,80
GMM	92,54	0,91	82,28	0,79	78,88	0,74	84,57	0,81
RF	92,82	0,91	85,29	0,82	75,03	0,69	84,38	0,81
SVM	92,13	0,91	88,29	0,86	77,72	0,72	86,03	0,83



Gambar 2. Penggunaan lahan menggunakan algoritma SVM: (a) 2002; (b) 2012; (c) 2022

Tabel 2. Luas penggunaan lahan menggunakan algoritma SVM

Penggunaan Lahan	2002		2012		2022	
	ha	%	ha	%	ha	%
Hutan sekunder	7.316,9	26,2	3.830,8	13,7	3.132,9	11,2
Semak belukar	7.710,5	27,6	12.140,7	43,4	13.013,8	46,5
Sawah	451,5	1,6	815,0	2,9	818,5	2,9
Pertanian lahan kering	11.762,4	42,1	10.716,8	38,3	10.503,1	37,6
Padang rumput	313,2	1,1	369,5	1,3	377,8	1,4
Tubuh air	419,2	1,5	62,3	0,2	91,1	0,3
Permukiman			38,6	0,2	36,5	0,1
Total	27.973,7	100	27.973,7	100	27.973,7	100

Tabel 3. Perubahan penggunaan lahan Sub DAS Tanralili

Penggunaan Lahan	2002-2012		2012-2022		2002-2022	
	ha	%	ha	%	ha	%
Hutan sekunder	-3.486,1	-47,6	-697,9	-18,2	-4.184,0	-57,2
Semak belukar	+4.430,2	+57,5	+873,1	+7,2	+5.303,3	+68,8
Sawah	+363,6	+80,5	+3,5	+0,4	+367,0	+81,3
Pertanian lahan kering	-1.045,6	-8,9	-213,7	-2,0	-1.259,3	-10,7
Padang rumput	+56,2	+17,9	+8,3	+2,3	+64,5	+20,6
Tubuh air	-356,9	-85,2	+28,9	+46,4	-328,0	-78,3
Permukiman	+38,6		-2,1	-5,5	+36,5	

mengatasi heterogenitas yang tinggi pada data citra (Jamsran et al., 2019; Santarsiero et al., 2022), sehingga dapat memberikan hasil yang optimal.

Klasifikasi penggunaan lahan tahun 2002, 2012 dan 2022 di Sub DAS Tanralili menggunakan algoritma SVM yang memiliki rata-rata akurasi tertinggi. Hasil klasifikasi dan luas penggunaan lahan disajikan pada gambar 2 dan tabel 2. Penggunaan lahan yang mengalami penurunan luas pada tahun 2002, 2012 dan 2022 diantaranya hutan sekunder masing-masing sebesar 7.316,9 ha (26,2%), 3.830,8 ha (13,7%), 3.132,9 ha (11,2%), pertanian lahan masing-masing sebesar 11.762,4 ha (42,1%), 10.716,8 ha (38,3%), 10.503,2 ha (37,6%) dan tubuh air masing-masing sebesar 419,2 ha (1,5%), 62,3 ha (0,2%), 91,1 ha (0,3%). Penggunaan lahan yang mengalami peningkatan luas pada tahun 2002, 2012 dan 2022 diantaranya semak belukar masing-masing sebesar 7.710,5 ha (27,6%), 12.140,7 ha (43,4%), 13.013,8 ha (46,5%), sawah masing-masing sebesar 451,5 ha (1,6%), 815,0 ha (2,9%), 818,5 ha (2,9%), padang rumput masing-masing sebesar 313,2 ha (1,1%), 369,5 ha (1,3%), 377,8 ha (1,3%), dan permukiman hanya terdapat pada tahun 2012 dan 2022 dengan luas masing-masing sebesar 38,6 ha (0,2%), 36,5 ha (0,1%).

Penggunaan lahan yang mengalami penurunan luas tertinggi selama periode 2002-2022 adalah hutan sekunder sebesar 4.184 ha (57,18%). Penggunaan lahan yang mengalami peningkatan luas tertinggi adalah semak belukar sebesar 5.303,3 ha (68,78%). Pada periode yang sama, lahan sawah dan permukiman juga mengalami peningkatan masing-masing sebesar 367,0 ha (81,29%) dan 36,5 ha. Perubahan penggunaan lahan Sub DAS Tanralili dapat dilihat pada tabel 3. Konversi hutan sekunder menjadi semak belukar, sawah dan permukiman dapat disebabkan oleh peningkatan jumlah penduduk di Kabupaten Maros sehingga permintaan terhadap lahan pertanian dan pemukiman meningkat. Hasil penelitian (Bounoua et al., 2023) menemukan adanya korelasi

yang kuat antara perluasan lahan pertanian dan kebutuhan dasar seperti pangan dan papan. Konversi lahan bertujuan untuk mengakomodasi penyediaan lahan untuk pertanian dan berbagai kepentingan lain seperti rumah, tempat ibadah dan lainnya. Namun perlu diperhatikan bahwa peningkatan area terbangun seperti permukiman dapat menyebabkan banjir. Hasil penelitian (Neves et al., 2023) menemukan bahwa kejadian banjir meningkat sebagai akibat dari konversi lahan dan pertumbuhan penduduk.

Prediksi penggunaan lahan

Prediksi penggunaan lahan didasarkan pada *driving factors* yang mempengaruhi perubahan lahan seperti elevasi, lereng, jarak dari jalan, sungai, permukiman dan jenis tanah, yang dapat dilihat pada gambar 3. Elevasi dan lereng diperoleh dari data DEM alos palsar. Jarak dari jalan, sungai, permukiman yang diperoleh dari data rupa bumi Indonesia digital yang diolah menggunakan perangkat lunak QGIS. Jenis tanah disajikan dalam tingkatan sub ordo menurut Soil Survey Staff (2022) yang diperoleh dari BBSDLP.

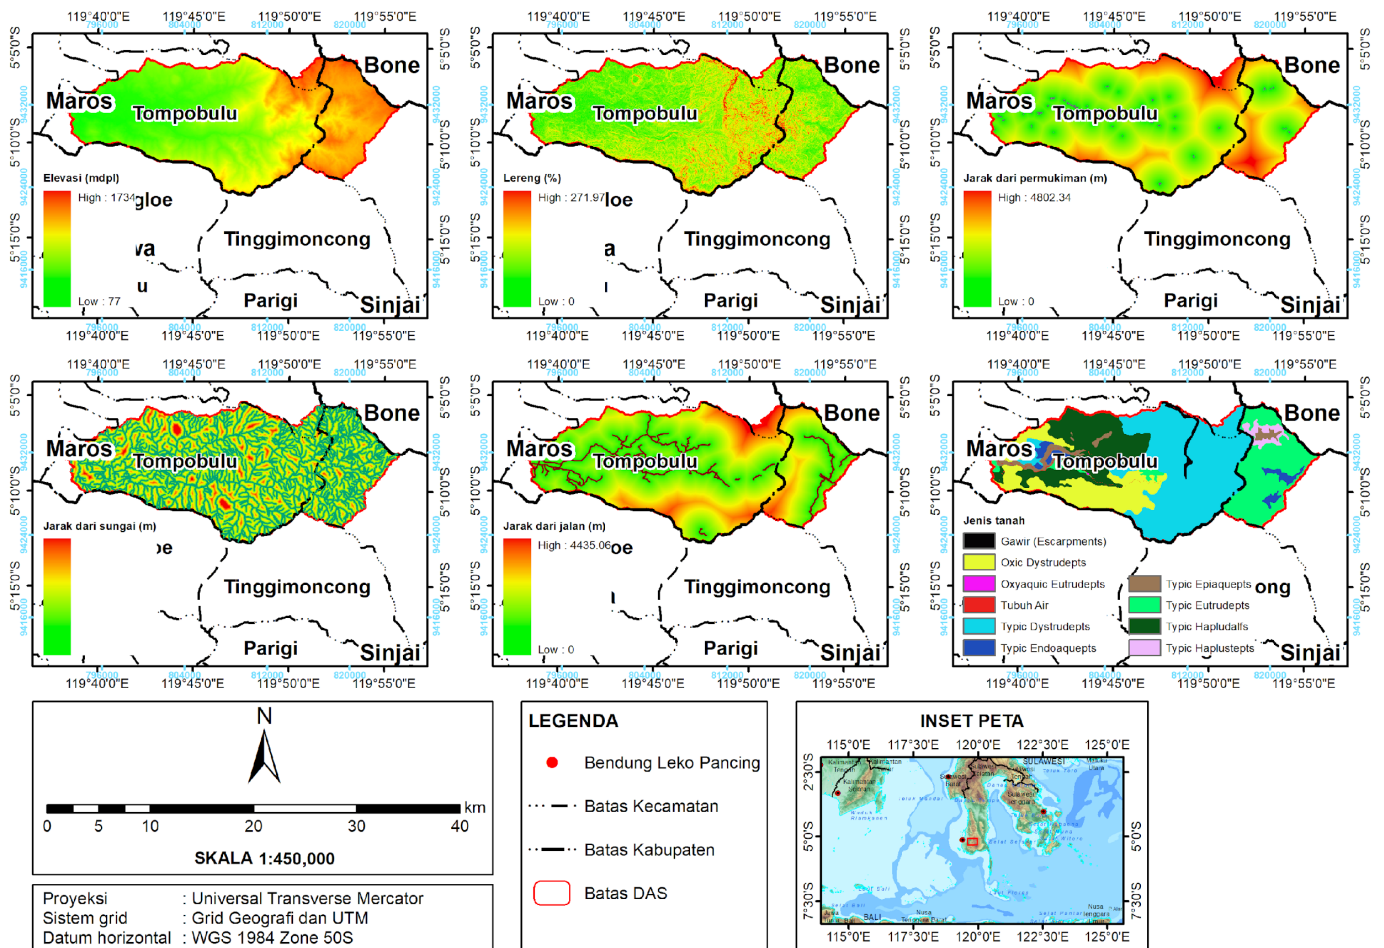
Seluruh model yang terdapat di *plugin* MOLUSCE, seperti ANN, WoE, LR, dan MCE yang dikombinasikan dengan *cellular automata* (CA) untuk memprediksi penggunaan lahan. Performa model diuji menggunakan *overall accuracy* dan kappa, dengan membandingkan penggunaan lahan aktual dan prediksi setiap model yang digunakan, hasil uji akurasi dapat dilihat pada tabel 4. Hasil uji akurasi menunjukkan bahwa algoritma ANN memiliki nilai *overall accuracy* dan kappa tertinggi, masing-masing sebesar 78.43 dan 0.65. Hasil penelitian Hariyanto et al. (2024) dan Shafizadeh-Moghadam et al. (2017) menunjukkan bahwa model ANN memiliki akurasi yang lebih tinggi dibandingkan model LR, MCE, dan WoE. Hal tersebut dikarenakan ANN memiliki kemampuan dalam mempelajari hubungan non-linear pada suatu data

yang memungkinkan fleksibilitas dalam menangani variabel heterogen dan dinamika data yang kompleks (Baig et al., 2022; Tayyebi & Pijanowski, 2014). Kombinasi model ANN dengan CA, ANN dapat mempelajari pola dari data historis dan menyempurnakan prediksi berbasis aturan CA, yang memberikan hasil yang lebih akurat dibandingkan model tradisional (Jayabaskaran & Das, 2023). Selain itu, CA-ANN mampu mensimulasikan perubahan spasial-temporal, menangkap interaksi lokal dan fenomena kompleks seperti pertumbuhan kota atau deforestasi (Din & Yamamoto, 2024).

Faktor yang mempengaruhi nilai akurasi yang diperoleh, salah satunya yaitu jenis citra. Penggunaan lahan aktual tahun 2022 dihasilkan dari klasifikasi menggunakan citra Landsat 8 OLI, sedangkan penggunaan lahan prediksi tahun 2022 dibangun dari hasil klasifikasi penggunaan lahan tahun 2002 dan 2012 yang menggunakan citra Landsat 7 ETM+. Namun model ANN dan MCE dapat diterima karena nilai kappa masih berada dalam rentang kelas baik (0.6-0.8) (Eshetie et al., 2023). Hasil penelitian (Ghayour et al., 2021) menunjukkan

bahwa jenis citra dan resolusi spasial berpengaruh terhadap nilai akurasi.

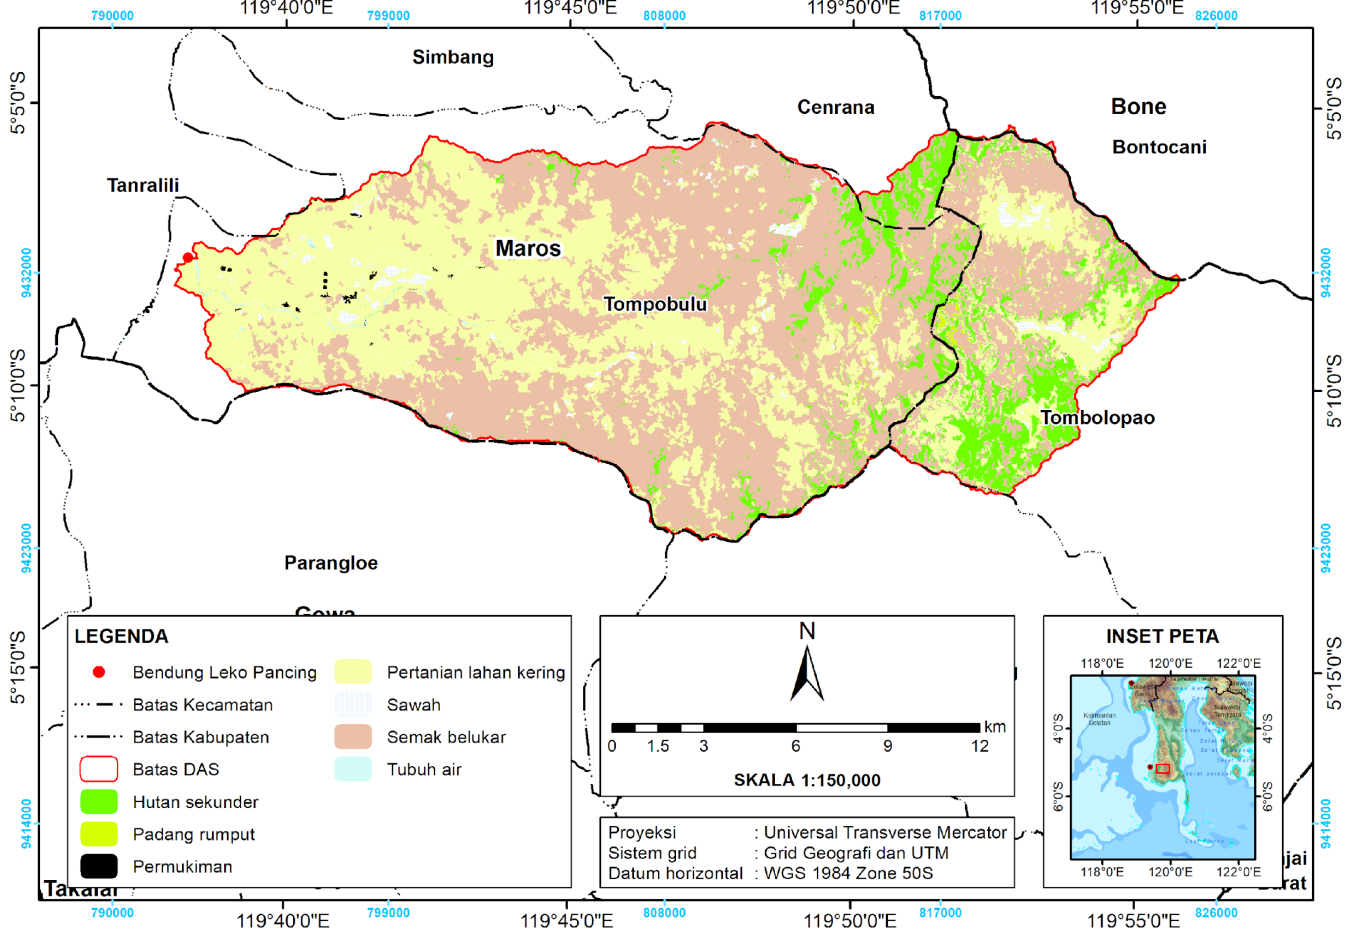
Algoritma ANN dipilih untuk memprediksi penggunaan lahan tahun 2032 karena memiliki akurasi tertinggi. ANN bekerja layaknya otak manusia yang menggunakan *neuron* (jaringan syaraf) dalam pelatihan model. *Hidden layer* dan *maximum iteration* merupakan parameter yang penting dalam algoritma ANN, jumlah yang digunakan masing-masing sebesar 500 dan 2000, yang merujuk pada penelitian (Nkolokosa et al., 2023). Pengoptimalan parameter tersebut dapat mengatasi kesulitan dalam pelatihan (Njock et al., 2021). Tidak ada ketentuan baku untuk penentuan jumlah *hidden layer* yang terbaik, namun jumlahnya perlu diperhatikan agar jaringan yang terbentuk tidak menjadi semakin rumit sehingga dapat menyebabkan *overfitting* (Zhang et al., 2018). Hasil penelitian (Ogunbo et al., 2020) menunjukkan bahwa performa ANN meningkat seiring dengan peningkatan jumlah *hidden layer*.



Gambar 3. *Driving factors* perubahan penggunaan lahan: (a) Elevasi; (b) Lereng; (c) Jarak dari jalan; (d) Jarak dari sungai; (e) Jarak dari permukiman; (f) Jenis tanah

Tabel 4. Uji akurasi prediksi penggunaan lahan

Model	Overall Accuracy	Kappa
ANN	78,4	0,65
WoE	68,4	0,51
LR	71,6	0,54
MCE	77,9	0,65



Gambar 4. Penggunaan lahan prediksi tahun 2032

Tabel 5. Luas penggunaan lahan prediksi tahun 2032

Penggunaan Lahan	2022		2032		2022-2032	
	ha	%	ha	%	ha	%
Hutan sekunder	3.132,9	11,20	2.578,7	9,22	-554,2	-17,69
Semak belukar	13.013,8	46,52	13.714,7	49,03	700,9	5,39
Sawah	818,5	2,93	495,9	1,77	-322,6	-39,41
Pertanian lahan kering	10.503,1	37,55	10.904,2	38,98	401,1	3,82
Padang rumput	377,8	1,35	185,0	0,66	-192,8	-51,04
Tubuh air	91,1	0,33	57,7	0,21	-33,4	-36,70
Permukiman	36,5	0,13	37,6	0,13	1,1	2,98
Total	27.973,7	100	27.973,7	100		

Hasil prediksi menunjukkan bahwa pada periode 2022-2032 penggunaan lahan yang mengalami penurunan luas tertinggi adalah hutan sekunder sebesar 554,2 ha (17,69%). Sawah, padang rumput dan tubuh air masing-masing mengalami penurunan sebesar 322,6 ha (39,41%), 192,8 ha (51,04%) dan 33,4 ha (36,7%). Penggunaan lahan yang mengalami peningkatan yang tertinggi adalah semak belukar sebesar 700,9 ha (5,39%). Pertanian lahan kering dan permukiman masing-masing mengalami peningkatan sebesar 401,1 ha (3,82%) dan 1,1 ha (2,98%), peta dan luas penggunaan lahan prediksi dapat dilihat pada gambar 4 dan tabel 5. Trisnaputra et al. (2023) menemukan bahwa suksesi alami dari pertanian pertanian lahan kering menyebabkan

perluasan area yang ditutupi oleh semak belukar. Peningkatan jumlah penduduk berkontribusi besar terhadap konversi hutan menjadi lahan pertanian, dan permukiman (Eshetie et al., 2023). Perubahan penggunaan lahan tidak hanya disebabkan oleh pertumbuhan populasi, namun juga ekonomi (Mao et al., 2024), topografi, dan iklim (Nkolokosa et al., 2023). Penelitian (Wolde et al., 2021) menunjukkan bahwa penurunan tutupan hutan dan perluasan lahan pertanian berdampak buruk terhadap aliran dasar, aliran lateral, perkolasi yang mengakibatkan kerentanan pangan. Deforestasi ini dapat diperburuk oleh perubahan iklim yang sedang terjadi, yang berpotensi meningkatkan kejadian banjir di masa depan (Ramadhan et al., 2023).

KESIMPULAN

Akurasi algoritma ML dalam mengklasifikasi penggunaan lahan bervariasi setiap tahunnya. Akurasi tertinggi pada tahun 2002, 2012, dan 2022 masing-masing adalah kNN, SVM, dan GMM. Secara keseluruhan, SVM memiliki akurasi rata-rata tertinggi. Model CA-ANN memiliki nilai akurasi tertinggi dalam memprediksi penggunaan lahan. Analisis perubahan penggunaan lahan periode 2002-2022 menunjukkan penurunan luas hutan sekunder, pertanian lahan kering, dan tubuh air. Pada saat yang sama, penggunaan lahan yang mengalami peningkatan luas adalah semak belukar, sawah, padang rumput, dan permukiman. Analisis korelasi *driving factors* prediksi penggunaan lahan menunjukkan adanya hubungan positif tertinggi antara jarak dari pemukiman dan jalan. Sebaliknya, terdapat hubungan negatif tertinggi antara jarak dari jalan dan jenis tanah. Prediksi penggunaan lahan tahun 2032 menunjukkan penurunan luas hutan sekunder, sawah, padang rumput, dan tubuh air, serta peningkatan luas semak belukar, pertanian lahan kering, dan permukiman. Penelitian ini kedepannya diharapkan dapat menggunakan jenis citra yang sama dengan resolusi spasial tinggi atau sangat tinggi untuk mengetahui efektivitas model apabila menggunakan citra resolusi tinggi atau sangat tinggi.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Program Studi Ilmu Tanah Fakultas Pertanian Institut Pertanian Bogor yang telah mendukung secara penuh dalam aspek akademik. Sekaligus penulis berterima kasih kepada USGS, ASF, BIG, dan BBSDLP yang masing-masing telah menyediakan data citra satelit Landsat, DEM Alos Palsar, RBI digital dan peta tanah sebagai data utama riset ini. Penelitian ini tidak didanai oleh sumber pendanaan eksternal.

KONTRIBUSI PENULIS

Penulis Pertama mendisain metode penelitian, melakukan analisis data, dan membuat naskah publikasi; **Penulis Kedua** dan **Penulis Ketiga** yakni interpretasi hasil, mensupervisi dan review naskah publikasi.

DAFTAR PUSTAKA

Ambarwulan, W., Yulianto, F., Widiatmaka, W., Rahadiati, A., Tarigan, S. D., Firmansyah, I., & Hasibuan, M. A. S. (2023). Modelling land use/land cover projection using different scenarios in the Cisadane Watershed, Indonesia: Implication on deforestation and food security. *The Egyptian Journal of Remote Sensing and Space Sciences*, 26(2), 273-283. <https://doi.org/10.1016/j.ejrs.2023.04.002>

Aryal, J., Sitaula, C., & Frery, A. C. (2023). Land use and land cover (LULC) performance modeling using machine learning algorithms: a case study of the city of Melbourne, Australia. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-40564-0> PMID:37598272 PMCID:PMC10439905

Baig, M. F., Mustafa, M. R. U., Baig, I., Takaijudin, H. B., & Zeshan, M. T. (2022). Assessment of Land Use Land Cover Changes and Future Predictions Using CA-ANN Simulation for Selangor, Malaysia. *Water*, 14(3). <https://doi.org/10.3390/w14030402>

Blissag, B., Yebdri, D., & Kessar, C. (2024). Spatiotemporal change analysis of LULC using remote sensing and CA-ANN approach in the Hodna basin, NE of Algeria. *Physics and Chemistry of the Earth*, 133. <https://doi.org/10.1016/j.pce.2023.103535>

Bounoua, L., Bachir, N., Souidi, H., Bahi, H., Lagmiri, S., Khebiza, M. Y., Nigro, J., & Thome, K. (2023). Sustainable Development in Algeria's Urban Areas: Population Growth and Land

Consumption. *Urban Science*, 7(1). <https://doi.org/10.3390/urbansci7010029>

Chowdhury, M. S. (2024). Comparison of accuracy and reliability of random forest, support vector machine, artificial neural network and maximum likelihood method in land use / cover classification of urban setting. *Environmental Challenges*, 14. <https://doi.org/10.1016/j.envc.2023.100800>

Danoedoro, P., Widayani, P., Hidayati, I. N., Kartika, C. S. D., & Alfani, F. (2024). Incorporating landscape ecological approach in machine learning classification for agricultural land-use mapping based on a single date imagery. *Geocarto International*, 39(1), 1-20. <https://doi.org/10.1080/10106049.2024.2356844>

Din, S. U., & Yamamoto, K. (2024). Urban Spatial Dynamics and Geo-informatics Prediction of Karachi from 1990-2050 Using Remote Sensing and CA-ANN Simulation. *Earth Systems and Environment*, 8, 849-868. <https://doi.org/10.1007/s41748-024-00439-4>

Ekasari, C., Barkey, R., Chairil, A., Nursaputra, M., & Pahar, S. P. P. (2021). Socioeconomic characteristics of communities utilizing land in forest areas in the Maros Watershed. *IOP Conference Series: Earth and Environmental Science*, 886(1). <https://doi.org/10.1088/1755-1315/886/1/012028>

Eshetie, A. A., Wubneh, M. A., Kiflew, M. S., & Alemu, M. G. (2023). Application of artificial neural network (ANN) for investigation of the impact of past and future land use - land cover change on streamflow in the Upper Gilgel Abay watershed, Abay Basin. *Applied Water Science*, 13. <https://doi.org/10.1007/s13201-023-02003-3>

Ghayour, L., Neshat, A., Paryani, S., Shahabi, H., Shirzadi, A., Chen, W., Al-Ansari, N., Geertsema, M., Amiri, M. P., Gholamnia, M., Dou, J., & Ahmad, A. (2021). Performance evaluation of sentinel-2 and landsat 8 OLI data for land cover/use classification using a comparison between machine learning algorithms. *Remote Sensing*, 13(7). <https://doi.org/10.3390/rs13071349>

Hariyanto, A. D., Yudono, A., & Wicaksono, A. D. (2024). Comparison of Land Cover Change Prediction Models: A Case Study in Kedungkandang District, Malang City. *Journal of Geomatics and Planning*, 11(1), 85-98. <https://doi.org/10.14710/geoplanning.11.1.85-98>

Hasnawir, Kubota, T., Sanchez-Castillo, L., & Soma, A. S. (2017). The Influence of Land Use and Rainfall on Shallow Landslides in Tanralili Sub-watershed, Indonesia. *Journal of the Faculty of Agriculture, Kyushu University*, 62(1), 171-176. <https://doi.org/10.5109/1801778>

Imran, A. N., & Djafar, M. (2020). Pengaruh Pengetahuan Ekosistem, Pengetahuan Konservasi, dan Pengetahuan Pencemaran, terhadap Sikap Memelihara Lingkungan Masyarakat di Wilayah DAS Maros Bagian Hulu Kabupaten Maros. *Jurnal Eboni*, 2(1), 1-11. <https://ejournals.umma.ac.id/index.php/eboni/article/view/610/465>

Iqbal, I. M., Balzter, H., Firdaus-e-Bareen, & Shabbir, A. (2023). Mapping *Lantana camara* and *Leucaena leucocephala* in Protected Areas of Pakistan: A Geo-Spatial Approach. *Remote Sensing*, 15(4). <https://doi.org/10.3390/rs15041020>

Jamsran, B. E., Lin, C., Byambakhuu, I., Raash, J., & Akhmadi, K. (2019). Applying a support vector model to assess land cover changes in the Uvs Lake Basin ecoregion in Mongolia. *Information Processing in Agriculture*, 6(1), 158-169. <https://doi.org/10.1016/j.inpa.2018.07.007>

Jayabaskaran, M., & Das, B. (2023). Land Use Land Cover (LULC) Dynamics by CA-ANN and CA-Markov Model Approaches: A Case Study of Ranipet Town, India. *Nature Environment and Pollution Technology*, 22(3), 1251-1265. <https://doi.org/10.46488/NEPT.2023.v22i03.013>

Karasiak, N., & Perbet, P. (2018). Remote Sensing of Distinctive Vegetation in Guiana Amazonian Park. In N. Baghdadi, C. Mallet, & M. Zribi (Eds.), *QGIS and Applications in Agriculture*

- and Forest (pp. 215-245). John Wiley & Sons, Inc. <https://doi.org/10.1002/9781119457107.ch7>
- Lukas, P., Melesse, A. M., & Kenea, T. T. (2023). Prediction of Future Land Use/Land Cover Changes Using a Coupled CA-ANN Model in the Upper Omo- Gibe River Basin, Ethiopia. *Remote Sensing*, 15(4). <https://doi.org/10.3390/rs15041148>
- Mao, Y., Fan, J., Zhou, D., He, Y., Yuan, M., & Zhang, H. (2024). Community-Scale Classification and Governance Policy Implications for Demographic, Economic, and Land-Use Linkages in Mega-Cities. *Land*, 13(4). <https://doi.org/10.3390/land13040441>
- Muhammad, R., Zhang, W., Abbas, Z., Guo, F., & Gwiazdzinski, L. (2022). Spatiotemporal Change Analysis and Prediction of Future Land Use and Land Cover Changes Using QGIS MOLUSCE Plugin and Remote Sensing Big Data: A Case Study of Linyi, China. *Land*, 11(3) <https://doi.org/10.3390/land11030419>
- Neves, J. L., Sellick, T. K., Hasan, A., & Pilesjö, P. (2023). Flood risk assessment under population growth and urban land use change in Matola, Mozambique. *African Geographical Review*, 42(5), 539-559. <https://doi.org/10.1080/19376812.2022.2076133>
- Njock, P. G. A., Shen, S.-L., Zhou, A., & Modoni, G. (2021). Artificial neural network optimized by differential evolution for predicting diameters of jet grouted columns. *Journal of Rock Mechanics and Geotechnical Engineering*, 13(6), 1500-1512. <https://doi.org/10.1016/j.jrmge.2021.05.009>
- Nkolokosa, C., Stothard, R., Jones, C. M., Stanton, M., Chirombo, J., & Tangena, J. A. (2023). Monitoring and simulating landscape changes: how do longterm changes in land use and longterm average climate affect regional biophysical conditions in southern Malawi? *Environmental Monitoring and Assessment*, 195(10), 1-16. <https://doi.org/10.1007/s10661-023-11783-9> PMID:37750982 PMCID:PMC10522741
- Noi, P. T., & Kappas, M. (2017). Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors*, 18(1). <https://doi.org/10.3390/s18010018> PMID:29271909 PMCID:PMC5796274
- Ogunbo, J. N., Alagbe, O. A., Oladapo, M. I., & Shin, C. (2020). N-hidden layer artificial neural network architecture computer code: geophysical application example. *Heliyon*, 6(6). <https://doi.org/10.1016/j.heliyon.2020.e04108> PMID:32566777 PMCID:PMC7298414
- Ouchra, H., Belangour, A., & Erraissi, A. (2024). Supervised Machine Learning Algorithms for Land Cover Classification in Casablanca, Morocco. *International Information and Engineering Technology Association*, 29(1), 377-387. <https://doi.org/10.18280/isi.290137>
- Pande, C. B., Diwate, P., Orimoloye, I. R., Sidek, L. M., Mishra, A. P., Moharir, K. N., Pal, S. C., Alshehri, F., & Tolche, A. D. (2024). Impact of land use/land cover changes on evapotranspiration and model accuracy using Google Earth engine and classification and regression tree modeling. *Geomatics, Natural Hazards and Risk*, 15(1). <https://doi.org/10.1080/19475705.2023.2290350>
- Priyanto, H., Mudjiono, & Yosomulyono, S. (2021). Koreksi Geometrik Pemetaan Tataguna Lahan di Sekitar Calon Tapak PLTN Kalimantan Barat. *Jurnal Pengembangan Energi Nuklir*, 23(1), 61-69. <https://doi.org/10.17146/jpen.2021.23.1.6306>
- Putri, E. A. W., Danoedoro, P., & Farda, M. N. (2024). Studi Komparasi Teknik Klasifikasi berbasis Objek terhadap Citra Resolusi Spasial Menengah dan Tinggi untuk Pemetaan Tutupan Lahan di Sebagian Kabupaten Kulonprogo. *Majalah Geografi Indonesia*, 38(1), 1-7. <https://doi.org/10.22146/mgi.81374>
- Ramadhan, C., Dina, R., & Nurjani, E. (2023). Spatial and temporal based deforestation proclivity analysis on flood events with applying watershed scale (case study: Lasolo watershed in Southeast Sulawesi, Central Sulawesi, and South Sulawesi, Indonesia). *International Journal of Disaster Risk Reduction*, 93. <https://doi.org/10.1016/j.ijdr.2023.103745>
- Santarsiero, V., Nolè, G., Lanorte, A., Tucci, B., Cillis, G., & Murgante, B. (2022). Remote Sensing and Spatial Analysis for Land-Take Assessment in Basilicata Region (Southern Italy). *Remote Sensing*, 14(7). <https://doi.org/10.3390/rs14071692>
- Shafizadeh-Moghadam, H., Tayyebi, A., & Helbich, M. (2017). Transition index maps for urban growth simulation: application of artificial neural networks, weight of evidence and fuzzy multi-criteria evaluation. *Environmental Monitoring and Assessment*, 189(6). <https://doi.org/10.1007/s10661-017-5986-3> PMID:28555438
- Soil Survey Staff. (2022). *Keys to Soil Taxonomy* (13th ed.). USDA Natural Resources Conservation Service.
- Sparey, M., Williamson, M. S., & Cox, P. M. (2024). Machine Learning for Global Bioclimatic Classification: Enhancing Land Cover Prediction through Random Forests. *Atmosphere*, 15(6). <https://doi.org/10.3390/atmos15060700>
- Surahman, S. (2017). Perubahan Penggunaan Lahan dan Dampaknya Terhadap Karakteristik Hidrologi Sub DAS Tanralili Provinsi Sulawesi Selatan Menggunakan Model Swat. *Jurnal Agrotan*, 3(2), 50-67. <https://ejournals.umma.ac.id/index.php/agrotan/article/view/24/22>
- Syafri, S., Surya, B., Ridwan, R., Bahri, S., Rasyidi, E. S., & Sudarman, S. (2020). Water Quality Pollution Control and Watershed Management Based on Community Participation in Maros City, South Sulawesi, Indonesia. *Sustainability*, 12(24). <https://doi.org/10.3390/su122410260>
- Tayyebi, A., & Pijanowski, B. C. (2014). Modeling multiple land use changes using ANN, CART and MARS: Comparing tradeoffs in goodness of fit and explanatory power of data mining tools. *International Journal of Applied Earth Observation and Geoinformation*, 28, 102-116. <https://doi.org/10.1016/j.jag.2013.11.008>
- Trisnaputra, A., Barus, B., & Trisasongko, B. H. (2023). Modeling land use/land cover change in Berau Pantai Forests, Berau Regency, East Kalimantan Province. *Journal of Natural Resources and Environmental Management*, 13(3), 386-397. <https://doi.org/10.29244/jpsl.13.3.386-397>
- Wang, Y., & Zeng, W. (2022). A Comparison of Three Different Group Intelligence Algorithms for Hyperspectral Imagery Classification. *Processes*, 10(9). <https://doi.org/10.3390/pr10091672>
- Widayani, P., Salsabila, H. N., & Andriantari, A. (2023). Dampak perubahan penutup lahan terhadap nilai jasa ekosistem di Kabupaten Sleman Daerah Istimewa Yogyakarta. *Majalah Geografi Indonesia*, 37(2), 104-113. <https://doi.org/10.22146/mgi.78192>
- Wolde, Z., Wei, W., Likessa, D., Omari, R., & Ketema, H. (2021). Understanding the Impact of Land Use and Land Cover Change on Water-Energy-Food Nexus in the Gidabo Watershed, East African Rift Valley. *Natural Resources Research*, 30(3), 2687-2702. <https://doi.org/10.1007/s11053-021-09819-3>
- Wulder, M. A., Loveland, T. R., Roy, D. P., Crawford, C. J., Masek, J. G., Woodcock, C. E., Allen, R. G., Anderson, M. C., Belward, A. S., Cohen, W. B., Dwyer, J., Erb, A., Gao, F., Griffiths, P., Helder, D., Hermosilla, T., Hipple, J. D., Hostert, P., Hughes, M. J., ... Zhu, Z. (2019). Current status of Landsat program, science, and applications. *Remote Sensing of Environment*, 225, 127-147. <https://doi.org/10.1016/j.rse.2019.02.015>

- Yue, W., Qin, C., Su, M., Teng, Y., & Xu, C. (2024). Simulation and prediction of land use change in Dongguan of China based on ANN cellular automata - Markov chain model. *Environmental and Sustainability Indicators*, 22. <https://doi.org/10.1016/j.indic.2024.100355>
- Zhang, Y., Chen, H., Yang, B., Fu, S., Yu, J., & Wang, Z. (2018). Prediction of phosphate concentrate grade based on artificial neural network modeling. *Results in Physics*, 11, 625-628. <https://doi.org/10.1016/j.rinp.2018.10.011>
- Zhao, Z., Islam, F., Waseem, L. A., Tariq, A., Nawaz, M., Islam, I. U., Bibi, T., Rehman, N. U., Ahmad, W., Aslam, R. W., Raza, D., & Hatamleh, W. A. (2024). Comparison of Three Machine Learning Algorithms Using Google Earth Engine for Land Use Land Cover Classification. *Rangeland Ecology & Management*, 92, 129-137. <https://doi.org/10.1016/j.rama.2023.10.007>