

KLASIFIKASI TUTUPAN LAHAN TAHUN 2021 DENGAN METODE RANDOM FOREST (RF) DAN SUPPORT VECTOR MACHINE (SVM) (STUDI KASUS: KOTA MATARAM)

Muhammad Anis Raihan^a, Husnul Hidayat^a, Hedi Hapsari Handayani^{a,*}

^a Departemen Teknik Geomatika, FTSPK-ITS, Kampus ITS Sukolilo, Surabaya, 60111, Indonesia

*Korespondensi Penulis, E-mail: hh.handayani@its.ac.id



Dikirim: 22 April 2024;

Diterima: 25 Maret 2025;

Diterbitkan: 25 Maret 2025.

Abstrak. Tutupan lahan adalah segala jenis kenampakan yang ada di permukaan bumi pada lahan tertentu baik buatan ataupun alami. Informasi terkait dengan pemantauan dan pengolahan data citra satelit untuk mendapatkan klasifikasi tutupan lahan dapat dilakukan dengan berbagai cara, salah satu dengan metode machine learning. Penelitian ini bertujuan untuk menerapkan metode machine learning dalam pemantauan tutupan lahan menggunakan citra Landsat-8, sehingga didapatkan metode yang memiliki akurasi tinggi dan cocok untuk pemantauan tutupan lahan. Pada penelitian ini menggunakan metode machine learning yaitu Support Vector Machine (SVM) dan Random Forest (RF). Klasifikasi tutupan lahan pada penelitian ini terdiri dari lima kelas yaitu, area terbangun, badan air, lahan kosong, pertanian, dan vegetasi, dimana penentuan kelas tutupan lahan ini berdasarkan jenis tutupan lahan yang ada pada Peta RTRW Kota Mataram Tahun 2011-2031, namun dilakukan penyesuaian dengan citra yang digunakan. Penelitian ini menunjukkan bahwa metode dengan akurasi terbaik adalah metode Support Vector Machine (SVM) dengan nilai overall accuracy dan kappa accuracy sebesar 0,9101 dan 0,8748. Namun terdapat kesalahan klasifikasi yang disebabkan oleh beberapa faktor seperti nilai reflectance tiap piksel yang hampir sama, periode tanam, dan faktor lainnya. Faktor-faktor tersebut perlu diperhatikan karena mempengaruhi hasil klasifikasi tutupan lahan yang diperoleh.

Kata kunci: Tutupan Lahan, Random Forest, Support Vector Machine.

Land Cover Classification in 2021 Using Random Forest (RF) and Support Vector Machine (SVM) Methods (Case Study: Mataram City)

Abstract. Land cover is all types of features that exist on the earth's surface on certain land, either artificial or natural. Information related to monitoring and processing satellite image data to obtain land cover classification can be done in various ways, one of which is machine learning methods. This study aims to apply machine learning methods in monitoring land cover using Landsat-8 imagery, to obtain a technique that has high accuracy and is suitable for monitoring land cover. This study uses machine learning methods, namely Support Vector Machine (SVM) and Random Forest (RF). The classification of land cover in this study consists of five classes, namely, built-up areas, water bodies, vacant land, agriculture, and vegetation, where the determination of this land cover class is based on the type of land cover that exists on the RTRW Map of Mataram City in 2011-2031. match the image used. This study shows that the method with the best accuracy is the Support Vector Machine (SVM) method with overall accuracy and kappa accuracy values of 0.9101 and 0.8748. However, there is a misclassification caused by several factors such as the reflectance value of each pixel which is almost the same, the cropping period, and other factors. These factors need to be considered because they affect the land cover classification results.

Keywords: Land Cover; Random Forest; Support Vector Machine.

I. PENDAHULUAN


Tutupan lahan adalah segala yang meliputi jenis kenampakan yang ada di permukaan bumi pada lahan tertentu. Tutupan lahan merupakan istilah yang digunakan untuk menyebutkan suatu kenampakan lahan secara fisik, baik kenampakan alami maupun kenampakan buatan manusia misalnya sawah, hutan, pemukiman, perkebunan, badan air, dan lahan kosong [1]. Informasi terkait dengan penggunaan lahan di tiap tahunnya sangat dibutuhkan, dikarenakan dapat digunakan sebagai salah satu pertimbangan dalam membuat suatu program atau kebijakan pada suatu daerah salah satunya adalah Kota Mataram. Sebagai ibu kota provinsi Nusa Tenggara Barat, Pemerintah Kota Mataram akan selalu melakukan pembangunan pada setiap tahunnya untuk membuat Kota Mataram menjadi kota yang maju, religius dan berbudaya sesuai dengan motonya. Dari pembangunan tersebut membuat terjadinya perubahan lahan, sehingga diperlukan informasi terkait penggunaan lahan setiap tahunnya. Pengolahan data citra satelit untuk mendapatkan klasifikasi tutupan lahan dapat dilakukan dengan berbagai cara, salah satu dengan metode yang umum digunakan adalah metode digitize on screen, seperti pada penelitian yang dilakukan oleh Muhammad Rusdin Ranga Putra dan Iwan Rudiarto pada tahun 2018 tentang “Simulasi Perubahan Penggunaan Lahan Dengan Konsep *Celluler Automata* Di Kota Mataram”, didapatkan klasifikasi penggunaan lahan berupa Industri dan Pergudangan, Perdagangan dan Jasa, Transportasi, Permukiman, Pertanian, dan Taman Kota [2]. Namun, pada penelitian tersebut memiliki kekurangan, yaitu pada perhitungan uji akurasi karena dilakukan secara manual dan membutuhkan beberapa data penunjang untuk melakukan perhitungan tersebut. Hal ini berbanding terbalik dengan metode klasifikasi supervised untuk tutupan lahan. Klasifikasi supervised dapat dilakukan dengan algoritma machine learning. Machine learning memiliki kemampuan komputasi yang terus meningkat, dapat melakukan inferensi pada data yang besar (big data), serta dapat dilakukan secara otomatis [3]. memiliki kemampuan komputasi yang terus meningkat, dapat melakukan inferensi pada data yang besar (big data), serta dapat dilakukan secara otomatis [3]. Pemilihan metode yang digunakan didasarkan oleh penelitian yang dilakukan oleh Wening Aisyah Fauziana Koman [4].

Melalui penelitiannya didapatkan kesimpulan bahwa metode *Support Vector Machine* (SVM) memiliki akurasi yang lebih baik untuk melakukan klasifikasi tutupan lahan dibandingkan *Random Forest* (RF) dan *Gaussian Mixture Model* (GMM) dengan menggunakan citra Sentinel 2A – Level 2A. Sedangkan melalui penelitian yang dilakukan

oleh Wanliu Mao [5] terkait dengan perbandingan dari penggunaan *Machine Learning* yaitu antara *Artificial Neural Network* (ANN), *Support Vector Machines* (SVM) dan *Random Forest* (RF), dimana hasil yang didapat adalah metode RF memiliki akurasi yang lebih baik dibandingkan dengan metode SVM dan ANN dengan menggunakan landsat 5TM. Berdasarkan beberapa penelitian tersebut, kedua metode ini memiliki akurasi yang baik dalam melakukan klasifikasi tutupan lahan

II. METODOLOGI


Wilayah penelitian terdapat pada Kota Mataram, Provinsi Nusa Tenggara Barat. Secara geografis, Kota Mataram terletak antara 08°33'3" – 08°37'31" LS dan 116°04'15" – 116°10'15" BT. Secara administratif Kota Mataram memiliki luas 61,30 km², yang terbagi atas 6 kecamatan, yaitu Kecamatan Ampenan, Cakranegara, Mataram, Sandubaya, Selaparang, dan Sekarbela seperti yang ditunjukkan pada Gambar 1.



Gambar 1 Lokasi Penelitian

Data yang dibutuhkan pada penelitian ini adalah citra Landsat 8 OLI C1 Level -1 (*Path/Row* : 166/066) dengan resolusi spasial 30 m dengan tanggal akuisisi 2 Juni 2021 yang didapatkan dari USGS (*EarthExplorer* (usgs.gov)). Citra yang digunakan dipilih sesuai dengan kriteria tutupan awan dibawah 10%, yaitu sebesar 2,37%. Untuk band yang digunakan dalam proses klasifikasi tutupan lahan adalah band 2, 3, 4, 5, 6 dan 7, hal ini dikarenakan, band 1 merupakan *coastal aerosol* dirancang untuk monitoring perairan pesisir dan *aerosol* erat kaitannya dengan band 2 yaitu *visible blue*, oleh karena itu band 1 tidak disertakan dalam proses klasifikasi. Kedua, Data digital *Training Point* dalam format *shapefile* (.shp) tutupan lahan wilayah Kota Mataram yang didapatkan dari hasil interpretasi manual. Selanjutnya, data Batas administrasi Kota Mataram sebagai batas lokasi penelitian

yang didapatkan dari Dinas Pekerjaan Umum Kota Mataram. Keempat, Peta RTRW Kota Mataram Tahun 2011 - 2031 skala 1:25000 yang digunakan sebagai validasi tutupan lahan yang didapat dari Dinas Pekerjaan Umum Kota Mataram. Terakhir, Data Citra Satelit Resolusi Tinggi (CSRT) Kota Mataram Tahun 2021 dari *Google Earth* digunakan untuk validasi. Sedangkan, peralatan yang digunakan untuk pengolahan data pada penelitian ini yaitu Laptop/PC, Perangkat lunak pengolahan data spasial antara lain *Envi*, *ArcMap*, *Google Earth*, dan *Rstudio*, serta Perangkat lunak pengolahan kata dan angka *Microsoft Office*.



Gambar 2 Alur Pengolahan Data

Tahap pengolahan data penelitian ini digambarkan dalam diagram alir Gambar 2. Langkah pertama yang dilakukan dalam penelitian ini adalah melakukan koreksi radiometrik untuk mendapatkan data *surface reflectance* untuk citra Satelit Landsat 8 OLI. Langkah selanjutnya, *training point* yang sudah dibuat merupakan titik yang terdiri dari *training* dan *testing* data tutupan lahan. Penempatan *training point* dilakukan sesuai dengan kelas klasifikasi yang telah ditentukan, dalam penelitian ini ada 5 kelas yaitu area terbuka, badan air, lahan kosong, pertanian, dan vegetasi. Lalu proses klasifikasi dengan *machine learning* dilakukan dengan menggunakan algoritma R, digunakan *R-package* untuk memproses data *training sample point* yang telah didesain sebelumnya dengan metode *Machine Learning* dengan algoritma *Support Vector Machine* (SVM) dan *Random Forest* (RF). *Machine learning* (ML) atau pembelajaran mesin merupakan pendekatan dalam *Artificial Intelligent* (AI) yang banyak digunakan untuk menggantikan atau menirukan perilaku manusia untuk menyelesaikan

masalah atau melakukan otomatisasi.. Ciri khas dari ML adalah adanya proses pelatihan, pembelajaran, atau training. Oleh karena itu, ML membutuhkan data untuk dipelajari yang disebut sebagai data training. Klasifikasi adalah metode dalam ML yang digunakan oleh mesin untuk memilah atau mengklasifikasikan obyek berdasarkan ciri tertentu sebagaimana manusia mencoba membedakan benda satu dengan yang lain [6]. *Support Vector Machine* (SVM) menggunakan sekumpulan fungsi matematika yang disebut dengan kernel sebagai data masukan. SVM bekerja dengan melakukan klasifikasi terhadap dua kelas atau lebih dengan mencari hyperlane terbaik yang memanfaatkan data pada titik pemisah (*super vector*) bahkan untuk jumlah sampel yang terbatas [7].

Random Forest merupakan sebuah metode klasifikasi yang mengandung beberapa pohon keputusan [8]. Dimana di setiap tree melakukan training terhadap sampel data. Penentuan kelas dilakukan berdasarkan jumlah vote dari setiap pohon [9]. Klasifikasi dengan suara terbanyak yang akan digunakan pada pohon tersebut. Evaluasi hasil klasifikasi dilakukan dengan kuantitatif dan kualitatif. Untuk evaluasi kuantitatif atau uji akurasi digunakan untuk melihat tingkat kesalahan yang terjadi pada klasifikasi yang dilakukan sehingga dapat ditentukan besarnya persentase ketelitian klasifikasi yang dihasilkan. Evaluasi ini menguji tingkat keakuratan secara visual dari klasifikasi terbimbing. Akurasi ketelitian pemetaan dilakukan dengan membuat matrik kesalahan (*confusion matrix*) seperti yang disajikan pada Tabel 2. Secara matematis akurasi (*overall accuracy*) diatas dapat dinyatakan sebagai berikut.

$$\text{Producer's accuracy} = \frac{X_{kk}}{x_{k+}} \times 100\% \quad (1)$$

$$\text{User's accuracy} = \frac{X_{kk}}{X_{+k}} \times 100\% \quad (2)$$

$$\text{Overall accuracy} = \frac{\sum X_{kk}}{N} \times 100\% \quad (3)$$

Overall accuracy adalah banyaknya jumlah piksel yang terklasifikasi secara benar pada tiap kelas dibanding jumlah sampel yang digunakan untuk uji akurasi pada semua kelas, sedangkan *producer's accuracy* adalah peluang rata-rata (%) suatu piksel yang menunjukkan sebaran dari masing-masing kelas yang telah diklasifikasi di lapangan dan *user's accuracy* adalah peluang rata-rata (%) suatu piksel secara aktual yang mewakili kelas-kelas tersebut. Namun, saat ini akurasi yang dianjurkan adalah akurasi kappa, karena *overall accuracy* secara umum masih *over estimate* [10]. Akurasi kappa ini dianjurkan karena dianggap ukuran paling relevan dengan mempertimbangkan segenap sel yang ada pada matriks kesalahan. Secara matematis akurasi kappa disajikan sebagai berikut.

$$Kappa\ accuracy = \frac{N \sum_k^r X_{kk} - \sum_k^r X_{k+} X_{+k}}{N^2 - \sum_k^r X_{k+} X_{+k}} \quad (4)$$

Tabel 1 Confusion Matrix

Klasifikasi	Refrensi				Jml Baris	User's Accuracy
	A	B	C	D		
A	X_{ii}				X_{+k}	X_{kk}/X_{+k}
B						
C						
D				X_{kk}		
Jml Kolom	X_{k+}				N	
Producer Accuracy	X_{kk}/X_k					

Untuk evaluasi kualitatif dilakukan dengan membandingkan hasil klasifikasi yang dilakukan dengan data yang berasal dari *Google Earth* pada tahun 2021. Terakhir melakukan analisa perbandingan terhadap akurasi hasil klasifikasi tutupan lahan terhadap 2 metode *Machine Learning* yang berbeda yaitu *Random Forest* dan *Support Vector Machine*.


III. HASIL DAN PEMBAHASAN

Klasifikasi tutupan terbagi menjadi lima kelas, yaitu area terbangun, badan air, lahan kosong, pertanian dan vegetasi. Penentuan kelas tutupan lahan ditentukan berdasarkan jenis tutupan lahan yang berada pada Peta RTRW Kota Mataram Tahun 2011-2031, namun dilakukan penyesuaian dengan citra yang digunakan yaitu citra landsat 8 dengan resolusi spasial sebesar 30 m.

Tabel 2 Kelas Tutupan Lahan

Tutupan Lahan	Tutupan Lahan RTRW Kota Mataram 2011-2031
Area Terbangun	Permukiman, Industri, Pertahanan dan Keamanan, Pariwisata, Pelabuhan, Perdagangan dan Jasa, Perkantoran, Pelayanan Umum
Vegetasi	Pepohonan, Semak – semak, taman kota, Ruang Terbuka Hijau, dan Perkebunan
Lahan Kosong	Ruang Terbuka Non Hijau, Pasir Pantai
Pertanian	Sawah
Badan Air	Sungai dan Danau

Penempatan *training point* dilakukan dengan digitasi manual menggunakan prinsip interpretasi citra sesuai dengan kelas klasifikasi yang telah ditentukan. Berikut adalah desain penempatan *training point* pada citra yang digunakan seperti pada Gambar 3.




Gambar 3 Peta Desain Persebaran Titik Training

Jumlah *training point* masing- masing kelas terdiri dari minimal 50 titik, hal ini didasarkan oleh pernyataan Congalton dan Green [11] yang merekomendasikan jumlah titik sampel untuk setiap kategori penutup lahan atau penggunaan lahan adalah minimal 50 - 75 titik.


Tabel 3 Jumlah Training Point 2021

No	Tutupan Lahan	Jumlah Training Point 2021
1	Area Terbangun	95
2	Badan Air	57
3	Lahan Kosong	50
4	Pertanian	62
5	Vegetasi	68


Untuk mendapatkan akurasi yang ideal dari hasil klasifikasi tutupan lahan, maka peneliti melakukan perbandingan terhadap komposisi antara *training* data dan *testing* data. Hasil dengan akurasi terbaik yang diperoleh dari membandingkan beberapa komposisi *training point* tersebut, akan digunakan untuk kedua algoritma *machine learning* yaitu *support vector machine* dan *random forest*. Berikut adalah hasil perbandingan komposisi *training point* untuk tahun 2021 menggunakan 5 komposisi *splitting ratio* antara *training* dan *testing* yaitu 60:40, 70:30, 75:25, 80:20, dan 90:10.




60:40




70:30



75:25



80:20



90:10

Legenda

Area Terbangun Badan Air Lahan Kosong Pertanian Vegetasi


Gambar 4 Perbandingan Komposisi *Splitting Ratio Training Point*

Pada Gambar 4 yang menunjukkan perbandingan komposisi, kelima komposisi tersebut, dapat mengklasifikasikan lima tutupan lahan tersebut. Kemudian dilakukan perbandingan akurasi dari setiap komposisi *splitting ratio* sebagai berikut.


Tabel 4 Perbandingan Akurasi *Spliting Ratio Training Point*

No	Split Data		Overall Accuracy		Kappa	
	Training	Testing	SVM	RF	SVM	RF
1	60	40	0,8550	0,8550	0,8171	0,8168
2	70	30	0,8776	0,8673	0,8453	0,8319
3	75	25	0,9012	0,9012	0,8748	0,8743
4	80	20	0,8923	0,8769	0,8623	0,8436
5	90	10	0,8710	0,8710	0,8362	0,8360

Berdasarkan tabel diatas, kelima komposisi *training point* dengan dua metode menghasilkan *overall accuracy* diatas ketentuan yang USGS sebesar 0,85. Komposisi *training point* dengan akurasi yang terbaik adalah komposisi 75 % data *training* dan 25% data *testing*.



Gambar 5 Klasifikasi Metode Random Forest



Gambar 6 Klasifikasi Metode Support Vector Machine

Dari hasil klasifikasi tersebut, dilakukan uji akurasi kuantitatif dilakukan dengan metode statistika berupa *confusion matrix* yang menghasilkan nilai *overall*

accuracy, *user's accuracy*, *producer's accuracy* dan *kappa Accuracy*.

Tabel 5 Confusion matrix metode RF (N=73 pixel)

Prediction	Reference					F
	A	B	C	D	E	
Area Terbangun	23	0	1	1	0	23
Badan Air	0	11	1	0	0	11
Lahan Kosong	0	1	9	1	0	12
Pertanian	0	1	1	13	0	18
Vegetasi	0	1	0	0	17	17
Total	23	14	12	15	17	81

Dimana A = Area terbangun, B = Badan Air, C = Lahan Kosong, D = Pertanian, E = Vegetasi, F = Total

Tabel 6 Confusion matrix metode SVM (N=73 pixel)

Prediction	Reference					F
	A	B	C	D	E	
Area Terbangun	23	0	0	0	0	23
Badan Air	0	10	1	0	0	11
Lahan Kosong	0	0	10	1	1	12
Pertanian	0	3	1	14	0	18
Vegetasi	0	1	0	0	16	17
Total	23	14	12	15	17	81

Dimana A = Area terbangun, B = Badan Air, C = Lahan Kosong, D = Pertanian, E = Vegetasi, F = Total

Tabel 7 Nilai *User's Accuracy* dan *Producer's Accuracy*

Kelas	RF		SVM	
	User Accuracy (%)	Producer Accuracy (%)	User Accuracy (%)	Producer Accuracy (%)
A	92	100	100	100
B	91,67	78,57	90,91	71,43
C	81,82	75	83,33	83,33
D	86,67	86,67	77,78	93,33
E	94,44	100	94,12	94,12


Dimana A = Area terbangun, B = Badan Air, C = Lahan Kosong, D = Pertanian, E = Vegetasi.

Tabel 8 Perbandingan Nilai *Overall Accuracy* dan *Kappa Accuracy*

Overall Accuracy		Kappa Accuracy	
SVM	RF	SVM	RF
0,9012	0,9012	0,8748	0,8743

Berdasarkan Tabel 5 dan 6, data *testing* sebanyak 25% dari 23 titik area terbangun, 14 titik badan air, 12 titik lahan kosong, 15 titik pertanian, dan 17 titik vegetasi. Untuk metode RF dan SVM, dari total 81 titik *testing*, hanya 73 titik yang dianggap benar. *Producer's accuracy* didasarkan pada sudut pandang klasifikasi yang sudah dilakukan, sedangkan *user's accuracy* menunjukkan kenyataan di lapangan. *user's accuracy* yang lebih tinggi mencerminkan keakuratan klasifikasi yang dihasilkan. Berdasarkan Tabel 7, Untuk metode RF, nilai *user's accuracy* terendah terdapat pada tutupan lahan kosong sebesar 81,82%. Untuk *overall accuracy* dan *kappa accuracy* dengan nilai berturut turut 0,9101 dan 0,8743. Sedangkan, metode SVM memiliki nilai *user's accuracy* terendah terdapat pada tutupan lahan pertanian sebesar 77,78% dan lahan kosong sebesar 83,33% dengan *overall accuracy* dan *kappa accuracy* dengan nilai berturut turut 0,9101 dan 0,8748.

Pada data hasil klasifikasi tutupan lahan tahun 2021 untuk kedua metode terdapat tutupan lahan lahan kosong yang memiliki UA yang rendah (kurang dari 85%) dengan nilai 83,33% untuk metode SVM dan 81,82 % untuk metode RF.



Gambar 7 Perbandingan Kelas Area Terbangun Kedua Metode dengan CSRT

Berdasarkan pada Gambar 7, terlihat untuk tutupan lahan pada CSRT yang dominan area terbangun namun hasil klasifikasi tutupan lahan yang dihasilkan terdapat *pixel* kelas pertanian ataupun lahan kosong diantara lahan terbangun, hal ini merupakan salah satu faktor terdapat perubahan lahan yang signifikan, untuk metode RF terdapat kelas badan air pada daerah vegetasi.

IV. KESIMPULAN

Berdasarkan penelitian yang sudah dilakukan dapat disimpulkan bahwa antara algoritma SVM memiliki akurasi yang lebih baik dibandingkan dengan RF dengan komposisi sebesar 25% data *training* dan 75% data *testing* dengan nilai dengan nilai *overall accuracy* dan *kappa accuracy* sebesar 0,9101 dan 0,8748. Namun terdapat kesalahan klasifikasi yang disebabkan oleh beberapa faktor seperti nilai reflectance tiap piksel yang hampir sama, periode tanam, dan faktor lainnya

UCAPAN TERIMAKASIH

Penulis mengucapkan terimakasih kepada seluruh pihak yang telah membantu dalam pelaksanaan penelitian ini terutama kepada instansi-instansi penyedia data yaitu Dinas PU Kota Mataram, Dinas PU Provinsi NTB, dan Badan Informasi Geospasial.

DAFTAR PUSTAKA

- [1] A. B. Suryo dan T. Hariyanto, "Studi Perubahan Tutupan Lahan Das Ciliwung Dengan Metode Klasifikasi Terbimbing Citra Landsat 7 Etm+ Multitemporal Tahun 2001 & 2008 (Studi Kasus : Bogor)," *Geoid*, vol. 9, no. 1, hlm. 1, 2013, doi: 10.12962/j24423998.v9i1.732.
- [2] M. R. R. Putra dan I. Rudiarto, "Simulasi Perubahan Penggunaan Lahan Dengan Konsep Celluler Automata Di Kota Mataram," *Jurnal Pengembangan Kota*, vol. 6, no. 2, hlm. 174, 2018, doi: 10.14710/jpk.6.2.174-185.
- [3] J. W. G. Putra, "Pengenalan konsep pembelajaran mesin dan deep learning," *Computational Linguistics and Natural Language Processing Laboratory*, vol. 4, no. August, hlm. 1–235, 2019.
- [4] W. A. F. Koman, A. Janur, F. N. I. D. Putri, dan G. Pratiwi, "Perbandingan Metode Otomatisasi Supervised Machine Learning terhadap Perubahan Tutupan Lahan," *FIT ISI 2020 "Smart Surveyors in the New Normal Era"*, vol. 1, hlm. 301–307, 2021.
- [5] W. D. L. L. H. X. L. W. Y. Mao, "Comparison of Machine-Learning Methods for Urban," 2020.
- [6] A. Ahmad, "Mengenal Artificial Intelligence, Machine Learning, & Deep Learning," *Jurnal Teknologi Indonesia*, vol. 1, no. June, hlm. 1–6, 2017.
- [7] G. Zhu dan D. G. Blumberg, "Classification using ASTER data and SVM algorithms: The case study of Beer Sheva, Israel," *Remote Sensing of Environment*, vol. 80, no. 2, hlm. 233–240, 2002, doi: 10.1016/S0034-4257(01)00305-4.
- [8] L. Breiman, "RANDOM FOREST," *International Journal of Advanced Computer Science and Applications*, vol. 7, no. 6, hlm. 1–33, 2016, doi: 10.14569/ijacsa.2016.070603.
- [9] K. A. Sambodo, M. I. Rahayu, N. Indriasari, dan M. Natsir, "Klasifikasi Hutan-Non Hutan Data Alos Palsar Menggunakan Metode Random Forest," *Prosiding Seminar Nasional Penginderaan Jauh 2014*, hlm. 120–127, 2014.
- [10] I. N. S. Jaya, *Analisis citra digital : perspektif penginderaan jauh untuk pengelolaan sumber daya alam*. PT Penerbit IPB Press, 2014.
- [11] K. Congalton, R.G., & Green, *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices, Second Edition (2nd ed.)*, 2nd ed. CRC Press, 2008. doi: 10.1201/9781420055139.