

KLASIFIKASI PENUTUPAN/PENGGUNAAN LAHAN DARI CITRA LANDSAT 8 DENGAN PENDEKATAN RANDOM FOREST DAN SUPPORT VECTOR MACHINE DI KABUPATEN SUMEDANG, JAWA BARAT

Land Cover/Use Classification at Landsat 8 with Random Forest and Support Vector Machine Algorithm in Sumedang Regency, West Java

Joycelyn Harmoko^{1)*}, Khursatul Munibah²⁾, dan Muhammad Ardiansyah³⁾

¹⁾ Program Studi Ilmu Perencanaan Wilayah, Sekolah Pascasarjana, IPB University, Jl. Meranti Kampus IPB Dramaga, Bogor 16680

^{2) 3)} Departemen Ilmu Tanah dan Sumberdaya Lahan, Fakultas Pertanian, IPB University, Jl. Meranti Kampus IPB Darmaga Bogor 16680

ABSTRACT

Sumedang Regency is one of the selected regions in the National Strategic Project (Proyek Strategis Nasional/PSN), involving the development of the Jatigede Dam and the Cisumdawu Toll Road. These infrastructure developments have led to the conversion of agricultural land, thus necessitating measurable monitoring of land cover/land use to understand land change dynamics, evaluate their impact on food security and the environment, and serve as a foundation for spatial planning and sustainable policy-making. This study aims to identify the reflectance patterns of each land cover/land use type and compare the classification results of 2023 land cover/land use in Sumedang Regency using the Random Forest (RF) and Support Vector Machines (SVM) approaches. Random Forest (RF) is a classification approach based on ensemble learning by constructing multiple decision trees, while Support Vector Machines (SVM) is a classification method that seeks the optimal hyperplane to separate data from different classes as distinctly as possible. The results show that land cover/land use reflectance patterns are distinctive; however, similarities in reflectance patterns were found between paddy fields and dry fields (*ladang/tegalan*), leading to a high risk of misclassification. Both RF and SVM approaches produced high classification accuracy, namely 93.6% and 98%, respectively. The difference in classified land area between RF and SVM reached 34.64%, due to differences in classification mechanisms. The largest difference in classified area occurred in paddy land, with 11,136 hectares and 31,445 hectares for RF and SVM, respectively. Thus, the SVM approach is considered more effective in producing accurate land cover/land use classification in Sumedang Regency.

Keywords : machine learning, reflectance pattern, national strategic project

ABSTRAK

Kabupaten Sumedang merupakan salah satu kabupaten terpilih dalam Proyek Strategis Nasional (PSN), berupa pembangunan Waduk Jatigede dan Jalan Tol Cisumdawu. Pembangunan tersebut menyebabkan alih fungsi lahan pertanian, sehingga dibutuhkan pemantauan penutupan/penggunaan lahan secara terukur untuk mengetahui dinamika perubahan lahan, mengevaluasi dampaknya terhadap ketahanan pangan dan lingkungan, serta menjadi dasar dalam perencanaan tata ruang dan pengambilan kebijakan yang berkelanjutan. Penelitian ini bertujuan mengidentifikasi pola reflektansi setiap jenis penutupan/penggunaan lahan dan membandingkan hasil klasifikasi penutupan/penggunaan lahan tahun 2023 di Kabupaten Sumedang dengan pendekatan *Random Forest* (RF) dan *Support Vector Machines* (SVM). *Random Forest* (RF) merupakan pendekatan klasifikasi berbasis *ensemble learning* dengan membangun banyak pohon keputusan, sedangkan *Support Vector Machines* (SVM) merupakan pendekatan klasifikasi dengan mencari *hyperplane* optimal untuk memisahkan data dari kelas yang berbeda secara maksimal. Hasil penelitian menunjukkan bahwa pola reflektansi penutupan/penggunaan lahan bersifat khas, tetapi kemiripan pola reflektansi dapat dijumpai pada penggunaan lahan sawah dan ladang/tegalan. Kemiripan pola reflektansi tersebut menyebabkan tingginya kerentanan misklasifikasi pada penutupan/penggunaan lahan. Pendekatan RF dan SVM menghasilkan akurasi klasifikasi yang tinggi, yaitu berturut-turut sebesar 93,6% dan 98% untuk RF dan SVM. Perbedaan luasan hasil klasifikasi RF dan SVM terjadi sebesar 34,64% karena adanya perbedaan cara kerja klasifikasi. Perbedaan luasan klasifikasi RF dan SVM terbesar terdapat pada penggunaan lahan sawah, yaitu berturut-turut sebesar 11.136 hektar dan 31.445 hektar untuk RF dan SVM. Dengan demikian, pendekatan SVM dinilai lebih unggul dalam menghasilkan klasifikasi penutupan/penggunaan lahan yang akurat di Kabupaten Sumedang.

Kata Kunci : machine learning, pola reflektansi, proyek strategis nasional

PENDAHULUAN

Perubahan penutupan/penggunaan lahan telah terjadi di Kabupaten Sumedang sebagai akibat dari proyek strategis nasional yang berupa Jalan Tol Cisumdawu dan Waduk Jatigede. Proyek pembangunan Jalan Tol

Cisumdawu telah direncanakan sejak tahun 2005 dan baru terlaksana pada tahun 2012, sedangkan pembangunan Waduk Jatigede telah direncanakan sejak tahun 1988, tetapi proses pembangunan baru terlaksana kembali pada tahun 2007 – 2015. Kedua pembangunan tersebut selesai pada tahun 2023 dan mengakibatkan penurunan luas panen

^{*)} Penulis Korespondensi: Telp. +6287805991888; Email. joycelyn.harmoko@apps.ipb.ac.id DOI: <http://dx.doi.org/10.29244/jitl.27.1.24-31>

terutama untuk komoditas padi, yaitu dari seluas 84.020 hektar pada tahun 2015 menjadi 53.486 hektar pada tahun 2023. Selain itu, penurunan produksi pertanian juga terjadi pada komoditas padi (dari sebesar 443.340 ton pada tahun 2015 menjadi 298.163 ton pada tahun 2023), cabai besar (dari sebesar 48.317 kwintal pada tahun 2015 menjadi 17.919 kwintal pada tahun 2023), ketimun (dari sebesar 41.251 kwintal pada tahun 2015 menjadi 19.942 kwintal pada tahun 2023), dan lain sebagainya (BPS 2023). Oleh karena itu, dibutuhkan pemantauan penutupan/penggunaan lahan setelah pembangunan proyek strategis nasional tersebut agar perencanaan pertanian berkelanjutan dapat disusun dengan tepat di Kabupaten Sumedang.

Pemantauan penutupan/penggunaan lahan dapat dilakukan dengan teknologi penginderaan jauh karena data satelit tertentu memiliki resolusi temporal yang tinggi, resolusi spasial, dan resolusi spektral yang lebih luas (Attri *et al.*, 2015). Citra Landsat 8 memiliki resolusi spasial sebesar 15 meter untuk saluran pankromatik, 30 meter untuk saluran multispektral, dan 100 meter untuk saluran termal. Selain itu, citra ini memiliki resolusi temporal 16 hari dan resolusi spektral sebesar 12-bit (USGS, 2013). Deteksi penutupan/penggunaan lahan dapat dilakukan dengan klasifikasi penutupan/penggunaan lahan berbasis piksel ataupun objek. Cara kerja dari klasifikasi tersebut adalah dengan mengumpulkan informasi piksel/objek dan mengolahnya berdasarkan aturan statistik dengan asumsi bahwa data yang digunakan merupakan data parametrik dan beresolusi tinggi. Meskipun demikian, asumsi tersebut seringkali menghasilkan klasifikasi yang kurang tepat untuk data nonparametrik, seperti data penutupan/penggunaan lahan, karena data memiliki varians yang berbeda pada setiap kelas penutupan/penggunaan lahan dan tidak selalu berdistribusi normal (Macarringue *et al.*, 2022). Untuk itu, pendekatan *machine learning* dikembangkan untuk klasifikasi penutupan/penggunaan lahan karena pendekatan ini mampu (1) mengenali pola pada data nonparametrik seperti nilai reflektan, (2) melakukan prediksi penutupan/penggunaan lahan, (3) melakukan operasi informasi geospasial dengan cepat, (4) menangani data dan variabel dalam jumlah besar, serta (5) memodelkan hubungan dan interaksi model nonlinier yang kompleks antar nilai reflektan pada penutupan/penggunaan lahan (Chaturvedi dan Vries, 2021).

Pendekatan nonparametrik untuk klasifikasi penutupan/penggunaan lahan yang dikembangkan adalah pendekatan *Random Forest* (RF) dan *Support Vector Machine* (SVM) (Ma *et al.*, 2019). Kedua pendekatan tersebut terbukti memiliki hasil akurasi klasifikasi yang tinggi atau di atas 80% (Talukdar *et al.*, 2020). Kinerja yang baik tersebut dipengaruhi oleh nilai reflektan dari setiap penutupan/penggunaan lahan yang khas, sehingga menghasilkan klasifikasi yang lebih akurat daripada penutupan/penggunaan lahan tanpa pola tertentu. Oleh

karena itu, perbandingan kedua pendekatan dalam klasifikasi penutupan/penggunaan lahan di Kabupaten Sumedang pada tahun 2023 dan analisis pola reflektan setiap penutupan/penggunaan lahan diperlukan agar dapat menghasilkan hasil klasifikasi yang sesuai dengan kondisi sebenarnya. Oleh karena itu, penelitian ini bertujuan mengidentifikasi pola reflektan setiap jenis penutupan/penggunaan lahan di Kabupaten Sumedang dan membandingkan hasil klasifikasi penutupan/penggunaan lahan tahun 2023 dengan pendekatan RF serta SVM. Hasil perbandingan kedua pendekatan tersebut dapat digunakan untuk mengevaluasi pendekatan klasifikasi yang paling sesuai dalam pemantauan penggunaan lahan pasca pembangunan PSN serta menjadi dasar rekomendasi untuk perencanaan berkelanjutan di masa mendatang.


BAHAN DAN METODE

Bahan

Penelitian ini dilaksanakan pada September 2023 sampai dengan Mei 2024. Penelitian ini dilaksanakan di Kabupaten Sumedang dengan letak geografis antara 6°35' LS – 7°02' LS dan 107°44' BT – 108°13' BT. Peta lokasi penelitian dapat dilihat pada Gambar 1. Alat yang digunakan dalam penelitian adalah gawai yang terinstal aplikasi GPS, *Avenza Map*, dan *timestamp camera*, alat tulis, serta laptop yang telah terinstal aplikasi QGIS versi 3.22.3, *Microsoft Office*, dan *Google Earth Pro*. Bahan yang digunakan dalam penelitian ini adalah peta batas administrasi Kabupaten Sumedang pada skala 1 : 25.000 yang bersumber dari *website* Ina-Geoportal dan citra Landsat 8 OLI/TIRS *Collection 1 path 121 row 65* dengan tanggal akuisisi 14 Agustus 2023 yang bersumber dari *website* USGS.

Metode

Penelitian ini menggunakan data primer (sampel penutupan/penggunaan lahan) dan data sekunder (citra Landsat 8 Kabupaten Sumedang dan peta administrasi daerah Kabupaten Sumedang). Jenis penutupan/penggunaan lahan yang diobservasi di lapangan sebagai sampel penutupan/penggunaan lahan ditandai di *Avenza Map*, didigitasi pada citra Landsat 8 melalui aplikasi QGIS, dan dibandingkan kenampakan nyatanya pada tahun 2023 di *Google Earth Pro*. Sampel tersebut terdiri dari kelas badan air, hutan, lahan terbangun, perkebunan, ladang/tegalan, sawah fase generatif, sawah fase vegetatif, sawah fase bera basah, tanah terbuka, awan, dan bayangan. Citra Landsat 8 OLI/TIRS pada tahun 2023 dikoreksi secara radiometrik dengan *plugin* SCP agar nilai piksel sesuai dengan nilai piksel yang seharusnya tanpa gangguan atmosfer (Lukiawan, 2019).



Gambar 1. Peta lokasi penelitian

Analisis Pola Nilai Reflektan

Data setiap sampel setiap penutupan/penggunaan lahan diidentifikasi nilai pikselnya pada *band* biru, hijau, merah, inframerah dekat, SWIR 1, dan SWIR 2 dengan fitur *sample raster values*. Nilai piksel tersebut diubah ke dalam nilai reflektan dan divisualisasikan dengan aplikasi *Microsoft Excel*. Dengan demikian, pola reflektan setiap jenis penutupan/penggunaan lahan dapat diidentifikasi.

Klasifikasi Penutupan/Penggunaan Lahan dengan Machine Learning

Sampel penutupan/penggunaan lahan dipisahkan dengan rasio 75% untuk data *training* dan 25% untuk data validasi. Kemudian, citra Landsat 8 pada tahun 2023 dan data *training* diklasifikasi dengan *plugin Dzetsaka* pada aplikasi QGIS, sehingga didapatkan model dan hasil klasifikasi. Pendekatan RF bekerja dengan membangun banyak pohon keputusan dan menggabungkan hasil prediksi setiap pohon untuk menghasilkan prediksi akhir penutupan/penggunaan lahan. Parameter yang digunakan pada klasifikasi RF adalah *n-estimators*, *max features*, *min samples split*, *min samples leaf*, *max depth*, *criterion*, *bootstrap*, *oob score*, dan *random state* yang dapat dilihat pada Tabel 1.

Sementara itu, pendekatan klasifikasi SVM bekerja dengan mencari *hyperplane* yang dapat memisahkan nilai reflektan penutupan/penggunaan lahan dengan margin maksimum. Parameter yang digunakan dalam klasifikasi SVM adalah tipe Kernel, nilai C, gamma, jumlah iterasi, toleransi konvergen, dan *cache size* yang dapat dilihat pada Tabel 2.

Tabel 1. Pengaturan *default* parameter pendekatan RF pada *plugin Dzetsaka*

No	Parameter	Pengaturan
1	<i>n_estimators</i>	100
2	<i>Max_features</i>	Auto
3	<i>Min_samples_split</i>	2
4	<i>Min_samples_leaf</i>	1
5	<i>Max_depth</i>	None
6	<i>Criterion</i>	Gini
7	<i>Bootstrap</i>	TRUE
8	<i>Oob_score</i>	FALSE
9	<i>Random_state</i>	500

Tabel 2. Pengaturan *default* parameter pendekatan SVM pada *plugin Dzetsaka*

No	Parameter	Pengaturan
1	<i>Kernel type</i>	Radial Basis Function
2	<i>C</i>	100
3	<i>Gamma</i>	Auto
4	<i>Number of iterations</i>	1000
5	<i>Convergence tolerance</i>	0,001
6	<i>Cache size</i>	100

Perbandingan Klasifikasi RF dan SVM

Perbandingan antara hasil klasifikasi RF dan SVM dilakukan dengan cara *overlay* antara hasil klasifikasi RF dan SVM untuk tahun 2023 dan membandingkan juga akurasi klasifikasi penutupan/penggunaan lahan. *Overlay* antara klasifikasi RF dan SVM bertujuan mengidentifikasi persamaan dan perbedaan hasil klasifikasi RF dan SVM. *Overlay* tersebut dilakukan dengan fitur *cross classification* pada *plugin SCP*. Akurasi klasifikasi penutupan/penggunaan lahan diukur berdasarkan 25% data

validasi. Kemudian, *confusion matrix* dibuat dan diidentifikasi antara nilai *Overall Accuracy* (OA) dan nilai Kappa. Perhitungan nilai OA dan Kappa dapat dilihat pada rumus sebagai berikut (Verma *et al.* 2020).

$$\text{Overall Accuracy (OA)} = \frac{\sum_{i=1}^n X_{ii}}{N}$$

$$\text{Kappa Accuracy (KA)} = \frac{\frac{\sum_{i=1}^n X_{ii}}{N} - \sum_{i=1}^n \left(\frac{\sum_{j=1}^n X_{ij}}{N} \times \frac{\sum_{j=1}^n X_{ji}}{N} \right)}{1 - \sum_{i=1}^n \left(\frac{\sum_{j=1}^n X_{ij}}{N} \times \frac{\sum_{j=1}^n X_{ji}}{N} \right)}$$

Keterangan :

- n : Jumlah kelas
- i : kelas yang sebenarnya
- j : kelas yang diprediksi
- N : Total observasi
- X_{ij} : Observasi yang sebenarnya berada di kelas i tetapi diprediksi sebagai j
- X_{ji} : Observasi yang sebenarnya berada di kelas j tetapi diprediksi sebagai i
- X_{ii} : Observasi yang sebenarnya dan diprediksi sebagai kelas i

HASIL DAN PEMBAHASAN

Pola Reflektan Penutupan/Penggunaan Lahan

Nilai reflektan lahan terbangun dan tanah terbuka memiliki nilai yang tinggi di setiap *band*, yaitu pada rentang 0,30 – 0,90. Hal ini menunjukkan bahwa lahan terbangun dan tanah terbuka cenderung memantulkan energi matahari yang diterima sensor. Keduanya memiliki nilai reflektan yang tinggi daripada penutupan/penggunaan lahan lain pada *band* tampak dan *band* SWIR serta nilai yang rendah pada *band* inframerah dekat (NIR). Hal ini disebabkan oleh sifat lahan terbangun dan tanah terbuka yang tidak memiliki kandungan air, sehingga sebagian besar energi pada panjang gelombang tampak dan SWIR dipantulkan kembali ke sensor. Selain itu, kedua jenis penutupan lahan ini memiliki vegetasi yang sangat minim atau bahkan tidak ada, sehingga pantulan energi pada panjang gelombang inframerah dekat (NIR) yang umumnya berasal dari aktivitas klorofil menjadi sangat rendah (Roy *et al.*, 2014). Namun, lahan terbangun memiliki nilai reflektan pada *band* tampak dan SWIR 2 yang lebih rendah daripada tanah terbuka. Nilai reflektan badan air memiliki nilai terendah daripada penutupan/penggunaan lahan lain pada setiap *band* karena cenderung menyerap energi matahari yang diterimanya. Ciri khas dari pola reflektan badan air adalah memiliki nilai reflektan pada *band* biru yang rendah, *band* hijau yang sama dengan *band* merah, nilai tertinggi pada *band* inframerah dekat, dan pola menurun pada *band* SWIR.


Pola reflektan setiap jenis penutupan/penggunaan lahan dapat dilihat pada Gambar 2.

Nilai reflektan penutupan/penggunaan lahan bervegetasi secara keseluruhan berada pada rentang 0,23 – 0,95 dengan pola khas, yaitu nilai reflektan yang rendah pada *band* biru dan merah, nilai reflektan *band* hijau yang sedikit lebih tinggi dari *band* biru dan merah, dan nilai tertinggi pada *band* inframerah dekat. Ciri khas dari pola reflektan hutan adalah memiliki nilai reflektan pada *band* inframerah dekat yang tertinggi dan nilai reflektan terendah pada *band* tampak daripada lahan bervegetasi lainnya. Pola tersebut disebabkan oleh tingginya keragaman dan kepadatan vegetasi pada hutan. Ciri khas dari pola reflektan perkebunan adalah memiliki nilai reflektan *band* inframerah dekat yang lebih rendah dan nilai *band* tampak yang lebih tinggi daripada hutan. Hal ini disebabkan oleh tanaman perkebunan yang memiliki kepadatan daun lebih rendah, tersusun seragam, dan struktur tajuk yang lebih terbuka sedangkan hutan umumnya memiliki tajuk pohon yang lebih rapat, tinggi, dan kanopi bertingkat. Karakteristik tersebut menyebabkan reflektansi NIR pada hutan lebih tinggi daripada perkebunan. Selain itu, tingkat kelembaban pada hutan lebih tinggi daripada perkebunan, sehingga kandungan air akan lebih banyak dan nilai reflektan *band* tampak pada hutan lebih rendah (Hu *et al.*, 2022).

Sawah memiliki pola reflektan yang khas pada setiap fasenya. Secara keseluruhan, nilai reflektan sawah berada pada rentang 0,23 – 0,81. Nilai reflektan pada sawah fase bera basah cenderung lebih rendah daripada fase generatif dan vegetatif karena dominan objek yang terdeteksi berupa air. Nilai reflektan sawah fase generatif akan lebih tinggi pada *band* inframerah dekat dan lebih rendah pada *band* biru, merah, dan SWIR 1 daripada sawah fase vegetatif. Nilai reflektan ladang/tegalan mirip dengan sawah fase generatif, tetapi dapat dibedakan karena ladang/tegalan memiliki nilai yang lebih rendah pada *band* SWIR dan lebih tinggi pada *band* biru, merah, dan inframerah dekat daripada sawah fase generatif.

Klasifikasi Penutupan/Penggunaan Lahan di Kabupaten Sumedang pada Tahun 2023

Jenis penutupan/penggunaan lahan sawah fase generatif dan ladang/tegalan merupakan kelas yang paling sering mengalami misklasifikasi pada pendekatan RF, sedangkan kelas ladang/tegalan merupakan kelas yang paling sering mengalami misklasifikasi pada pendekatan SVM. Sementara itu, piksel misklasifikasi sawah fase generatif umumnya diklasifikasikan menjadi perkebunan dan tanah terbuka pada pendekatan RF. Piksel misklasifikasi ladang/tegalan pada pendekatan RF umumnya diklasifikasikan menjadi tanah terbuka, sawah fase vegetatif, dan lahan terbangun.



Gambar 2. Pola reflektan setiap jenis penutupan/penggunaan lahan

Klasifikasi penutupan/penggunaan lahan dengan pendekatan RF dan SVM pada tahun 2023 dapat dilihat pada Gambar 3.

Luas penutupan/penggunaan lahan pada tahun 2023 pada kedua pendekatan dapat dilihat pada Gambar 4. Luas penutupan/penggunaan lahan pada pendekatan SVM yang lebih besar daripada pendekatan RF adalah badan air dan sawah secara umum, sedangkan yang lebih kecil adalah hutan, lahan terbangun, perkebunan, ladang/tegalan, serta tanah terbuka. Pola ini menunjukkan bahwa pendekatan RF cenderung lebih inklusif dalam mengklasifikasi area dengan variasi spektral yang tinggi, sehingga menghasilkan luasan yang lebih besar pada sebagian besar kelas penutupan/penggunaan lahan, kecuali badan air dan sawah secara umum (Belgiu dan Dragut, 2016). Sebaliknya, pendekatan SVM bekerja dengan margin klasifikasi yang lebih ketat dalam menyaring piksel berdasarkan karakteristik spektralnya, sehingga hanya kelas dengan ciri khas spektral yang kuat seperti badan air dan sawah yang diklasifikasikan lebih luas oleh SVM (Mountrakis *et al.*, 2011). Perbedaan ini menunjukkan bahwa pemilihan pendekatan klasifikasi memengaruhi hasil estimasi spasial, khususnya pada kelas yang memiliki pola spektral yang mirip (Rodriguez *et al.*, 2012).


Perbandingan Klasifikasi Penutupan/Penggunaan Lahan Pendekatan RF dan SVM

Perbandingan hasil klasifikasi penutupan/penggunaan lahan dilakukan dengan membandingkan nilai *User's Accuracy* (UA), *Producer's Accuracy* (PA), *Overall Accuracy* (OA), dan *Kappa Accuracy* (KA) dari pendekatan RF dan SVM, seperti terlihat pada Tabel 3. *User's Accuracy* (UA) digunakan untuk menilai seberapa baik model dalam mengenali kelas


yang benar, sedangkan *Producer's Accuracy* (PA) menilai seberapa baik model dalam menghasilkan prediksi yang benar secara keseluruhan (Sari *et al.*, 2021). Nilai *overall accuracy* menunjukkan gambaran umum kinerja model dalam memprediksi kelas penutupan/penggunaan lahan. Nilai Kappa digunakan untuk mencegah kesalahan penilaian *overall accuracy* pada kelas tutupan lahan yang tidak seimbang (Verma *et al.*, 2020).

Pendekatan RF dan SVM dalam klasifikasi penutupan/penggunaan lahan memiliki nilai UA, PA, dan rata-rata akurasi mayoritas di atas 80%. Hal ini menunjukkan bahwa model klasifikasi RF dan SVM mampu mengenali kelas dengan baik dan menghasilkan prediksi yang benar secara keseluruhan. Akurasi yang tinggi pada RF dan SVM disebabkan oleh cara kerja kedua pendekatan yang mampu mempelajari hubungan nonlinear pada pola reflektan dan adanya mekanisme tahan dari *noise* serta pencilaan. Selain itu, setiap penutupan/penggunaan lahan memiliki pola reflektan yang khas, sehingga pendekatan RF dan SVM dapat menentukan batasan kelas dengan jelas (Kamilaris dan Boldu, 2018).

Penutupan/penggunaan lahan berupa ladang/tegalan dan tanah terbuka memiliki akurasi rata-rata yang cukup baik (80% – 89%) pada pendekatan RF, yaitu sebesar 80,2% pada rata-rata akurasi ladang/tegalan serta 84,6% pada sawah fase bera basah. Namun, kedua jenis penutupan/penggunaan lahan tersebut dapat diklasifikasi dengan baik pada pendekatan SVM, yaitu sebesar 93,9% pada rata-rata akurasi ladang/tegalan dan 95,7% pada rata-rata akurasi sawah fase bera basah. Kesalahan klasifikasi pada sawah fase generatif dan ladang/tegalan disebabkan oleh adanya kemiripan pola spektral. Kemiripan pola spektral menyebabkan sulitnya penentuan batas nilai reflektan yang jelas antar kelas pada pendekatan RF dan SVM (Mohammadi dan Hezarkhani, 2019).



Gambar 3. Klasifikasi penutupan/penggunaan lahan dengan pendekatan RF dan SVM pada tahun 2023



Keterangan:

Ba : Badan Air

Ld : Ladang/Tegalan

Hn : Hutan

Sw : Sawah

Lt : Lahan Terbangun

Tn : Tanah Terbuka

Pk : Perkebunan

Gambar 4. Luas penutupan/penggunaan lahan pada pendekatan RF dan SVM

Perbandingan hasil klasifikasi pendekatan RF dan SVM dapat dilihat pada Gambar 5. Hasil klasifikasi RF dan SVM secara keseluruhan memiliki persamaan sebesar 65,4% dan perbedaan sebesar 34,6%. Perbedaan hasil klasifikasi RF dan SVM umumnya terjadi pada klasifikasi piksel menjadi hutan pada SVM tetapi menjadi perkebunan pada RF (5,45%), menjadi perkebunan pada SVM tetapi menjadi hutan pada RF (3,73%), dan menjadi perkebunan pada SVM tetapi menjadi ladang/tegalan pada RF (2,35%). Perbedaan ini disebabkan oleh cara kerja pendekatan RF dan SVM yang berbeda. Berdasarkan hasil observasi lapangan, area yang diklasifikasikan sebagai hutan oleh SVM namun sebagai perkebunan oleh RF merupakan

kawasan hutan sekunder dengan tutupan tajuk rapat yang cenderung menyerupai perkebunan dari segi nilai reflektan. Selain itu, area yang diklasifikasi sebagai perkebunan oleh SVM namun sebagai ladang/tegalan oleh RF merupakan perkebunan campuran dengan struktur vegetasi tidak seragam, sehingga cenderung menyerupai ladang/tegalan. Dengan demikian, pendekatan SVM lebih tepat dalam mengenali variasi pola reflektan pada penutupan/penggunaan lahan di lapangan.

Perbedaan cara kerja di antara keduanya adalah sebagai berikut. Pendekatan RF bekerja dengan membangun banyak pohon keputusan dan menggabungkan prediksi dari setiap pohon untuk menghasilkan prediksi

akhir. Pembangunan pohon keputusan dimulai dari memilih subset acak dari data asal, kemudian dipisahkan berdasarkan kriteria tertentu hingga menghasilkan prediksi akhir. Kelas hasil klasifikasi merupakan label prediksi yang paling banyak muncul pada pohon-pohon keputusan dalam pendekatan RF (Avci *et al.*, 2023). Sementara itu, pendekatan SVM dilakukan dengan mencari *hyperplane* atau fungsi yang dapat memisahkan kelas dengan margin maksimum. Pencarian margin tersebut dilakukan dengan menentukan vektor pendukung melalui langkah optimasi *Lagrangian relaxation* (Anca *et al.*, 2021). Jika terdapat

penutupan/penggunaan lahan yang belum dapat dipisahkan, parameter nilai C (*cost parameter*) dapat diperbesar agar menghasilkan margin yang lebih kecil. Selain itu, parameter jenis Kernel juga digunakan karena mampu memetakan data ke ruang dimensi yang lebih tinggi dengan membentuk batas nonlinear selama fase optimalisasi. Filter Kernel yang digunakan dalam klasifikasi ini adalah RBF Gaussian karena merupakan kernel yang serbaguna dan dapat diterapkan tanpa adanya pengetahuan sebelumnya (Awad dan Khanna, 2015).

Tabel 3 Sebaran rata-rata nilai akurasi dengan pendekatan RF dan SVM

Kelas	RF 2023			SVM 2023		
	UA (%)	PA (%)	Mean (%)	UA (%)	PA (%)	Mean (%)
Ba	92,9	94,2	93,5	94,9	96,2	95,6
Hn	92,8	91,2	92,0	99,1	97,4	98,3
Lt	97,3	98,5	97,9	98,3	99,5	98,9
Pk	92,2	95,0	93,6	96,3	99,3	97,8
Ld	83,1	77,2	80,2	97,4	90,5	93,9
Tn	93,1	92,2	92,6	99,1	98,0	98,5
Sw.Gn	80,7	73,8	77,2	99,0	90,5	94,8
Sw.Vg	92,5	93,9	93,2	94,0	95,4	94,7
Sw.Bb	87,2	81,9	84,6	98,7	92,8	95,7
OA (%)		93,6			98,0	
KA (%)		91,8			97,4	

Keterangan:

Ba : Badan Air

Ld : Ladang/Tegalan

Hn : Hutan

Sw : Sawah

Lt : Lahan Terbangun

Tn : Tanah Terbuka


Pk : Perkebunan

Sw.Gn : Sawah Fase Generatif

Sw.Vg : Sawah Fase Vegetatif

Sw.Bb : Sawah Fase Bera Basah

Perbandingan Hasil Klasifikasi SVM dan RF 2023



Keterangan:

Ba : Badan Air

Ld : Ladang/Tegalan

Hn : Hutan

Sw : Sawah

Lt : Lahan Terbangun

Tn : Tanah Terbuka

Pk : Perkebunan

Gambar 5. Perbandingan klasifikasi SVM dan RF di Kabupaten Sumedang pada tahun 2023

SIMPULAN

Reflektansi lahan terbangun dan tanah terbuka secara umum memiliki nilai yang tinggi pada semua band karena cenderung memantulkan gelombang elektromagnetik. Sebaliknya, nilai reflektansi pada badan air cenderung rendah karena cenderung menyerap gelombang elektromagnetik. Reflektansi vegetasi memiliki nilai yang rendah pada band biru dan merah, sedikit lebih tinggi pada band hijau, dan sangat tinggi pada band inframerah dekat. Kemiripan pola pada ladang/tegalan dan sawah menyebabkan terjadinya salah klasifikasi. Klasifikasi

penutupan/penggunaan lahan di Kabupaten Sumedang untuk tahun 2023 secara keseluruhan menghasilkan akurasi yang tinggi, yaitu di atas 90% untuk RF dan di atas 95% untuk SVM. Perbedaan hasil klasifikasi RF dan SVM tahun 2023 adalah sebesar 36,53% dengan luas perbedaan terbesar pada penggunaan lahan sawah (11.136 hektar dan 31.445 hektar masing-masing pada RF serta SVM). Hal ini terjadi karena adanya perbedaan cara kerja klasifikasi pada kedua pendekatan. Pendekatan SVM menunjukkan akurasi yang lebih tinggi (di atas 95%) dibandingkan RF (di atas 90%) dan lebih efektif dalam mengidentifikasi kelas dengan ciri spektral yang lebih jelas, seperti sawah dan badan air.

Sebaliknya, RF lebih baik dalam menangani kelas dengan pola spektral yang tumpang tindih, seperti lahan terbangun dan ladang/tegalan. Oleh karena itu, pendekatan SVM lebih direkomendasikan untuk wilayah dengan kelas yang memiliki perbedaan spektral yang jelas, sementara pendekatan RF lebih sesuai untuk wilayah dengan kelas yang memiliki pola spektral yang lebih tumpang tindih.

UCAPAN TERIMA KASIH

Para penulis menyampaikan ucapan terima kasih kepada Divisi Penginderaan Jauh dan Informasi Spasial, Departemen Ilmu Tanah dan Sumber Daya Lahan, Fakultas Pertanian, Institut Pertanian Bogor yang telah memfasilitasi penelitian ini.

DAFTAR PUSTAKA

- Anca, D., M. Kluczek, B. Zagajewski, E. Raczko, M. Kycko, A.H. Al-Sulttani, A. Tarda, L. Pineda, and J. Corbera. 2021. Comparison of support vector machines and random forests for corine land cover mapping. *Remote Sens.*, 13(4): 1-36.
- Attri, P., S. Chaudhry, and S. Sharma. 2015. Remote sensing and GIS based approaches for LULC change detection – a review. *International Journal of Current Engineering and Technology*, 5(5): 3126-3137.
- Avci, C., M. Budak, N. Yagmur, and F.B. Balcik. 2023. Comparison between random forest and support vector machine algorithms for classification. *International Journal of Engineering and Geosciences*, 8(1): 1-10.
- Awad, M., and R. Khanna. 2015. *Efficient Learning Machines*. New York (US) : Apress.
- Belgiu, M., and L. Dragut. 2016. Random forest in remote sensing : A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114(1): 24-31.
- [BPS] Badan Pusat Statistik. 2023. Produksi Tanaman Sayuran Menurut Kecamatan dan Jenis Tanaman di Kabupaten Sumedang. [diakses 08/07/2024]. <https://sumedangkab.bps.go.id/>
- Chaturvedi, V., and W.T.D. Vries. 2021. Machine learning algorithms for urban land use planning: a review. *Urban Science*, 68(5): 1-16.
- Hu, Y., Z. Wang, Y. Zhang, and Y. Dian. 2022. Logging pattern detection by multispectral remote sensing imagery in North Subtropical Plantation Forests. *Remote Sens.*, 14(19): 1-15.
- Kamilaris, A., and F.X.P. Boldu. 2018. Deep learning in agriculture: a survey. *Computers and Electronics in Agriculture*, 147(1): 70-90.
- Lukiawan, R., E.H. Purwanto, dan M. Ayundyahrini. 2019. Standar koreksi geometrik citra satelit resolusi menengah dan manfaat bagi pengguna. *Jurnal Standardisasi*, 21(1): 45-54.
- Ma, L., Y. Liu, X. Zhang, Y. Ye, G. Yin, and B.A. Johnson. 2019. Deep learning in remote sensing applications : a meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152(1): 166-177.
- Macarrigue, L.S., E.L. Bolfe, and P.R.M. Pereira. 2022. Developments in land use and land cover classification techniques in remote sensing : a review. *Journal of Geographic Information System*, 14(1): 1-28.
- Mohammadi, N.M., and A. Hezarkhani. 2019. A comparative study of SVM and RF methods for classification of alteration zones using remotely sensed data. *Journal of Mining and Environment*, 11(1): 49-61.
- Mountrakis, G., J. Im, and C. Ogole. 2011. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3): 247-259.
- Rodriguez, V.F.G., B. Ghimire, J. Rogan, M.O. Chica, and J.P.S. Rigol. 2012. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67(1): 93-104.
- Roy, D.P., M.A. Wulder, T.R. Loveland, Woodcock C.E., R.G. Allen, M.C. Anderson, D. Helder, J.R. Irons, D.M. Johnson, R. Kennedy, T.A. Scambos, C.B. Schaaf, J.R. Schott, Y. Sheng, E.F. Vermote, A.S. Belward, R. Bindaschadler, W.B. Cohen, F. Gao, J.D. Hipple, P. Hostert, J. Huntington, C.O. Justice, A. Kilic, V. Kovalsky, Z.P. Lee, L. Lymburner, J.G. Masek, J. McCorkel, Y. Shuai, R. Trezza, J. Vogelmann, R.H. Wynne, and Z. Zhu. 2014. Landsat-8: science and product vision for terrestrial global change research. *Remote Sensing of Environment*. 145(4) : 154 – 172.
- Sari, I.L., C.J. Weston, G.J. Newnham, and L. Volkova. 2021. Assessing accuracy of land cover change maps derived from automated digital processing and visual interpretation in tropical forests in Indonesia. *Remote Sensing*, 13(8): 1-18.
- Talukdar, S., P. Singha, S. Mahato, Shahfahad, S. Pal, Y.A. Liou, and A. Rahman. 2020. Land-use land-cover classification by machine learning classifiers for satellite observations : a review. *Remote Sens.*, 12(7): 1-24.
- [USGS] United State Geological Survey. 2013. *Landsat 8*. [diakses 21/01/2025]. <https://usgs.gov/>
- Verma, P., A. Raghubanshi, P.K. Srivastava, and A.S. Raghubanshi. 2020. Appraisal of kappa-based metrics and disagreement indices of accuracy assessment for parametric and nonparametric techniques used in LULC classification and change detection. *Modeling Earth Systems and Environment*, 6(2020): 1045-1059.