

PERBANDINGAN PARAMETER OMN DAN RGO DALAM SEGMENTASI OBIA UNTUK KLASIFIKASI PENUTUPAN/PENGGUNAAN LAHAN MENGGUNAKAN K-NEAREST NEIGHBOR DI KABUPATEN SUMEDANG

Comparison of OMN and RGO Parameters in OBIA Segmentation for Land Use and Land Cover Classification Using K-Nearest Neighbor in Sumedang Regency

Muhammad Ardiansyah^{1,2)*}, Boedi Tjahjono¹⁾, Niken Dwia Oktaviani³⁾

¹⁾ Departemen Ilmu Tanah dan Sumberdaya Lahan, Fakultas Pertanian, IPB University, Jl. Meranti – Kampus IPB Dramaga, Bogor, West Java 16680

²⁾ Center for Climate Risk and Opportunity Management in Southeast Asia and Pacific, IPB University, Jl. Pajajaran – Kampus IPB Baranangsiang, Bogor, West Java 16143

³⁾ Departemen Ilmu Tanah dan Sumberdaya Lahan, Fakultas Pertanian, IPB University, Jl. Meranti – Kampus IPB Dramaga, Bogor, West Java 16680

ABSTRACT

Land use/land cover (LULC) information is essential for environmental analysis, yet its accuracy depends on segmentation or classification methods. This study aims to analyze differences in segmentation results and classification accuracy using Original Multiresolution (OMN) and Region Grow on Object (RGO) integrated with the K-Nearest Neighbor (K-NN) method in Sumedang Regency. An Object-Based Image Analysis (OBIA) approach was applied with variations in scale, shape, and compactness, and accuracy was assessed using Overall Accuracy (OA), User's Accuracy (UA), and Producer's Accuracy (PA). The results show that OMN is sensitive to the scale parameter and tends to produce over-segmentation, while RGO generates larger, more homogeneous, and more stable objects. RGO-based classification achieved more consistent performance with slightly higher than OA, particularly for homogeneous classes such as forest and water bodies. In contrast, OMN captures finer spatial details but is prone to fragmentation. Therefore, RGO with moderate parameters (scale 0.5; shape 0.1 and compactness 0.4) is considered the optimal configuration. However, uncertainties remain in spectrally similar classes, suggesting the need for more adaptive classification methods or higher-resolution data in future studies.

Keywords: object based classification, scale, shape, compactness parameters

ABSTRAK

Informasi penutupan/penggunaan lahan sangat penting untuk analisis lingkungan, namun akurasi bergantung pada metode segmentasi atau klasifikasi. Penelitian ini bertujuan untuk menganalisis perbedaan hasil segmentasi dan akurasi klasifikasi dengan menggunakan *Original Multiresolution (OMN)* dan *Region Grow on Object (RGO)* yang diintegrasikan dengan metode *K-Nearest Neighbor (K-NN)* di Kabupaten Sumedang. Pendekatan *Object-Based Image Analysis (OBIA)* diterapkan dengan variasi parameter skala, bentuk, dan kekompakan, serta akurasi dinilai menggunakan *Overall Accuracy (OA)*, *User's Accuracy (UA)*, dan *Producer's Accuracy (PA)*. Hasil penelitian menunjukkan bahwa OMN sensitif terhadap parameter skala dan cenderung menghasilkan *over-segmentation*, sedangkan RGO menghasilkan objek yang lebih besar, homogen, dan stabil. Klasifikasi berbasis RGO menunjukkan kinerja yang lebih konsisten dengan OA sedikit lebih tinggi, khususnya pada kelas homogen seperti hutan dan badan air. Sebaliknya, OMN mampu menangkap detail spasial yang lebih halus namun rentan terhadap fragmentasi. Oleh karena itu, RGO dengan parameter moderat (skala 0,5; bentuk 0,1; dan kekompakan 0,4) dianggap sebagai konfigurasi optimal. Namun, ketidakpastian masih terjadi pada kelas dengan kemiripan spektral tinggi, sehingga diperlukan metode klasifikasi yang lebih adaptif atau data resolusi lebih tinggi pada penelitian selanjutnya.

Kata kunci: klasifikasi berbasis objek, parameter skala, bentuk, kekompakan

PENDAHULUAN

Informasi penutupan/penggunaan lahan merupakan variabel penting dalam analisis biofisik permukaan bumi karena mencerminkan respons spektral objek terhadap interaksi proses alami dan aktivitas manusia (Anderson *et al.*, 1976; Foody, 2002; Duveiller *et al.*, 2020). Informasi ini memiliki peran strategis dalam berbagai aplikasi spasial, antara lain pemodelan lingkungan, perencanaan tata ruang, pengelolaan kehutanan, serta penilaian keberlanjutan pemanfaatan lahan (FAO, 2017; IPCC, 2019; Potapov *et al.*, 2022). Akurasi dan keterkinian data penutupan/penggunaan lahan sangat menentukan

kualitas analisis spasial, khususnya dalam klasifikasi citra satelit dan pemodelan perubahan penggunaan lahan (Foody, 2002). Oleh karena itu, pemantauan penutupan/penggunaan lahan secara berkala berbasis data multi-temporal menjadi penting untuk mengidentifikasi pola dan dinamika perubahan lahan dari waktu ke waktu (Kabeja *et al.*, 2022; He *et al.*, 2024). Penelitian terbaru juga menegaskan bahwa integrasi data multi-temporal dan multi-sensor mampu meningkatkan akurasi pemetaan serta deteksi perubahan lahan secara signifikan (Ajibola dan Cabral, 2024; He *et al.*, 2024).

Klasifikasi berbasis piksel telah lama menjadi pendekatan utama dalam pemetaan penutupan/penggunaan

* Penulis Korespondensi: Telp. +62811112973; Email: ardyasaja@gmail.com

DOI: <http://dx.doi.org/10.29244/jitl.28.1.1-11>

lahan menggunakan data penginderaan jauh dengan berbagai resolusi spasial. Meskipun metode ini efektif dalam mengekstraksi informasi spektral, pendekatan berbasis piksel memiliki keterbatasan mendasar dalam merepresentasikan kompleksitas spasial, seperti bentuk, tekstur, dan hubungan kontekstual antar piksel. Hasil klasifikasi juga sering menunjukkan fenomena *salt-and-pepper*, yaitu fragmentasi spasial yang tinggi sehingga menurunkan konsistensi dan akurasi peta, terutama pada lanskap heterogen. Keterbatasan ini semakin nyata pada data resolusi tinggi karena meningkatnya variabilitas intrakelas (Ma *et al.*, 2019). Untuk mengatasi hal tersebut, pendekatan *Object-Based Image Analysis* (OBIA) dikembangkan dengan mengelompokkan piksel menjadi objek homogen berdasarkan karakteristik spektral dan spasial, sehingga lebih representatif terhadap kondisi di lapangan dan mampu meningkatkan kemampuan diskriminasi kelas (Blaschke, 2010; Hay dan Castilla, 2008). Studi lain juga menunjukkan bahwa OBIA tetap relevan dan kompetitif, bahkan ketika dikombinasikan dengan pendekatan pembelajaran mendalam (*deep learning*) dalam analisis citra penginderaan jauh (Lv *et al.*, 2023; Osco *et al.*, 2023).

Dalam pendekatan OBIA, proses segmentasi menjadi tahap krusial karena menentukan pembentukan unit objek yang akan diklasifikasikan. Kualitas segmentasi sangat dipengaruhi oleh parameter seperti *scale*, *shape*, dan *compactness*, yang mengontrol homogenitas dan bentuk objek. Metode segmentasi seperti *Original Multiresolution* (OMN) dan *Region Grow on Object* (RGO) memiliki karakteristik berbeda dalam menangkap variasi spasial dan spektral objek (Drăguț *et al.*, 2014). OMN bekerja melalui penggabungan objek secara iteratif berdasarkan homogenitas, sedangkan RGO mengembangkan wilayah berdasarkan kesamaan nilai piksel dan kedekatan spasial. Perbedaan ini berpotensi menghasilkan kualitas segmentasi yang berbeda dan berdampak langsung pada akurasi klasifikasi. Penelitian terkini menunjukkan bahwa optimasi parameter segmentasi merupakan faktor kunci dalam meningkatkan kinerja OBIA dan mengurangi kesalahan klasifikasi (Hossain dan Chen, 2019; Badia *et al.*, 2023; He *et al.*, 2024).

Selain segmentasi, pemilihan metode klasifikasi juga berperan penting dalam menentukan tingkat akurasi pemetaan berbasis OBIA. Pendekatan klasik seperti *minimum distance to mean* (MDM) atau *maximum likelihood classification* (MLC) cenderung kurang mampu menangani kompleksitas lanskap yang heterogen. Sebaliknya, pendekatan berbasis pembelajaran mesin seperti *K-Nearest Neighbor* (K-NN), *Random Forest* (RF), dan *Support Vector Machine* (SVM) terbukti mampu meningkatkan kinerja klasifikasi melalui pemanfaatan fitur spektral, tekstural, dan temporal (Belgiu dan Drăguț, 2016; Maxwell *et al.*, 2018). Studi lain juga menunjukkan bahwa pendekatan berbasis pembelajaran mesin dan hibrid, yaitu kombinasi beberapa metode atau integrasi OBIA dengan model pembelajaran mesin, memberikan performa yang lebih baik dibanding metode konvensional dalam klasifikasi

penutupan/penggunaan lahan (Ajibola dan Cabral, 2024; He *et al.*, 2024).

Metode K-NN memiliki keunggulan berupa kesederhanaan pendekatan, stabilitas hasil meski dengan data latih terbatas, serta sensitivitas terhadap pola lokal, jika dibandingkan dengan RF dan SVM. Sejumlah penelitian menunjukkan bahwa K-NN memberikan performa kompetitif, terutama bila dipadukan dengan kerangka OBIA yang telah mengoptimalkan representasi objek melalui segmentasi (Foody dan Mathur, 2004; Duro *et al.*, 2012). Integrasi K-NN dengan OBIA karenanya menjadi pendekatan potensial untuk meningkatkan akurasi klasifikasi pada lanskap heterogen. Meskipun demikian, sebagian besar penelitian masih berfokus pada perbandingan metode klasifikasi, sementara kajian mengenai pengaruh parameter segmentasi terhadap akurasi klasifikasi dalam kerangka OBIA yang terintegrasi masih terbatas. Oleh karena itu, penelitian ini bertujuan untuk menganalisis perbedaan hasil segmentasi dan akurasi klasifikasi penutupan/penggunaan lahan menggunakan metode OMN dan RGO yang diintegrasikan dengan K-NN. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan strategi klasifikasi citra penginderaan jauh yang lebih akurat dan aplikatif, khususnya untuk wilayah dengan karakteristik penutupan/penggunaan lahan yang kompleks.

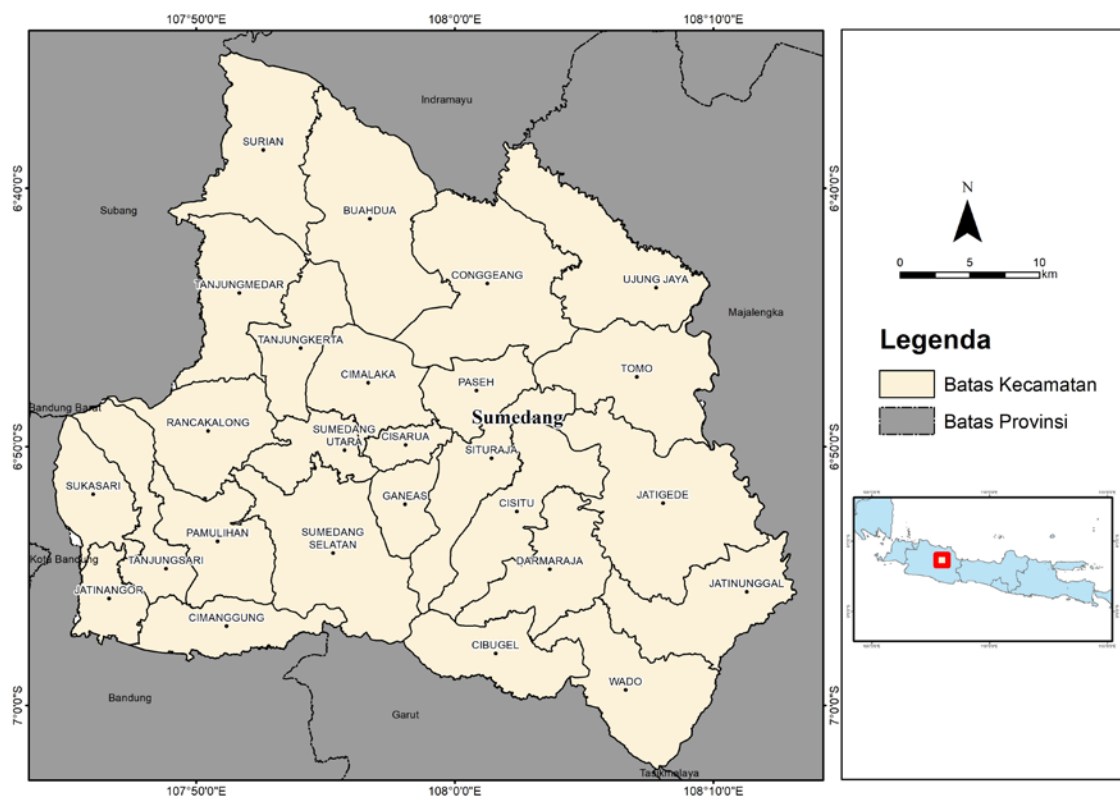
BAHAN DAN METODE

Lokasi Penelitian

Penelitian ini dilaksanakan pada periode Desember 2024 hingga Mei 2025 di Kabupaten Sumedang, Provinsi Jawa Barat, yang secara geografis terletak pada koordinat 6°44'–7°83' LS dan 107°21'–108°21' BT (Gambar 1). Kabupaten Sumedang berada pada koridor strategis Bandung–Cirebon dan memiliki karakteristik penutupan/penggunaan lahan yang heterogen, sehingga sesuai sebagai wilayah studi untuk analisis klasifikasi penutupan/penggunaan lahan.

Alat dan Bahan

Penelitian ini menggunakan perangkat komputer yang dilengkapi dengan perangkat lunak QGIS versi 3.28.3, eCognition Essentials 1.2, dan Google Earth Pro, serta perangkat *smartphone* yang dilengkapi aplikasi *Avenza Maps* versi 3.5 dan *Timestamp Camera* versi 1.234 untuk mendukung kegiatan pengamatan lapangan. Data utama yang digunakan berupa citra Landsat 8 OLI/TIRS Collection 2 Level-1 hasil akuisisi tanggal 17 September 2024 (Path 121; Row 065) yang mencakup wilayah Kabupaten Sumedang, diperoleh melalui portal *United States Geological Survey* (USGS) *EarthExplorer* (<https://earthexplorer.usgs.gov/>). Data pendukung berupa *shapefile* batas administrasi Kabupaten Sumedang diperoleh dari portal Tanah Air Indonesia (<https://tanahair.indonesia.go.id/portal-web/>).



Gambar 1. Peta lokasi penelitian

Pengolahan Awal Citra

Citra Landsat 8 OLI/TIRS *Collection 2 Level-1* digunakan sebagai data utama dalam penelitian ini. Data citra tersedia dalam format *Digital Number (DN)* dengan resolusi radiometrik 14-bit (rentang nilai 0–65.535). Untuk meningkatkan kualitas radiometrik serta meminimalkan pengaruh atmosfer, dilakukan koreksi atmosferik menggunakan metode *Dark Object Subtraction (DOS1)*, yang berasumsi bahwa objek paling gelap pada citra memiliki nilai reflektansi mendekati nol sehingga nilai minimum tiap kanal digunakan sebagai dasar koreksi.

Koreksi atmosferik dilakukan menggunakan QGIS melalui *Semi-Automatic Classification Plugin (SCP)* (Congedo, 2021). Tahapan koreksi atmosferik metode DOS1 pada SCP adalah sebagai berikut:

- Persiapan data, dengan mengimpor seluruh kanal citra Landsat 8 beserta file metadata (MTL.txt) ke dalam SCP melalui menu preprocessing > landsat.
- Aktivasi koreksi atmosferik DOS1, dengan memilih opsi atmospheric correction dan mengaktifkan metode DOS1.
- Konversi DN ke Top of Atmosphere (TOA), SCP secara otomatis mengonversi nilai DN menjadi reflektansi TOA dengan memanfaatkan parameter radiometrik pada file metadata.
- Penentuan nilai minimum (*dark object*), SCP secara otomatis mendeteksi nilai piksel terendah untuk setiap kanal sebagai representasi objek gelap (misalnya badan air atau bayangan).
- Perhitungan reflektansi permukaan, SCP mengurangi kontribusi atmosfer (*path radiance*) dari reflektansi TOA untuk menghasilkan reflektansi permukaan (*surface reflectance*).

Setelah proses koreksi atmosferik selesai, citra kemudian dipotong berdasarkan batas administrasi Kabupaten Sumedang menggunakan data *shapefile* wilayah penelitian untuk memperoleh area analisis yang lebih spesifik.

Pengambilan Sampel Kelas Penutupan/penggunaan Lahan

Pengambilan sampel kelas penutupan/penggunaan lahan dilakukan secara *stratified purposive* dengan mempertimbangkan keterwakilan karakteristik spektral masing-masing kelas pada citra Landsat 8 OLI/TIRS. Berdasarkan hasil interpretasi visual menggunakan komposit warna palsu dengan kombinasi kanal 5-4-2, diidentifikasi sepuluh kelas penutupan/penggunaan lahan, yaitu hutan, lahan terbangun, kebun campuran, ladang/tegalan, tanah terbuka, sawah fase generatif, sawah fase vegetatif, sawah fase bera, sungai, dan waduk.

Pengamatan lapangan dilakukan pada 44 titik yang tersebar pada berbagai kelas penutupan/penggunaan lahan, terdiri atas 6 titik hutan, 5 titik kebun campuran, 5 titik tanah terbuka, 11 titik lahan terbangun, 5 titik ladang/tegalan, 3 titik sungai, 3 titik waduk, serta masing-masing 2 titik untuk sawah fase generatif, vegetatif, dan bera. Identifikasi dan pengambilan sampel kelas penutupan/penggunaan untuk data latih dan validasi dilakukan secara terintegrasi dengan memanfaatkan beberapa sumber data pendukung, yaitu: (a) data pengamatan lapangan yang koordinatnya direkam menggunakan aplikasi Avenza Maps versi 3.5, (b) citra resolusi tinggi dari *Google Earth Pro*, serta (c) interpretasi visual citra Landsat 8 kombinasi kanal 5-4-2 untuk meningkatkan ketepatan dalam deliniasi dan pemilihan sampel. Secara keseluruhan, sebanyak 735 poligon sampel (Tabel 1).

Tabel 1. Sampel penutupan/penggunaan lahan

No.	Kelas	Jumlah poligon	Luas rata-rata poligon (ha)
1	Hutan	105	0,318
2	Lahan terbangun	105	0,309
3	Kebun campuran	105	0,306
4	Ladang/tegalan	105	0,329
5	Tanah terbuka	105	0,342
6	Sawah fase generatif	35	0,318
7	Sawah fase vegetatif	35	0,324
8	Sawah fase bera	35	0,319
9	Sungai	52	0,327
10	Waduk	53	0,342

Data sampel penutupan/penggunaan lahan dibagi menjadi dua subset, yaitu 70% (515 poligon) sebagai data latih (*training data*) dan 30% (220 poligon) sebagai data validasi (*validation data*). Pembagian sampel dilakukan secara acak menggunakan fungsi *random selection* pada menu *Preprocessing > Toolbox* di perangkat lunak QGIS.

Segmentasi Citra

Dua pendekatan segmentasi berbasis objek, yaitu OMN dan RGO, diterapkan pada penelitian ini. Parameter segmentasi yang digunakan meliputi *scale*, *shape*, dan *compactness*, yang diatur secara spesifik untuk masing-masing pendekatan (Tabel 2). Variasi parameter diterapkan untuk mengevaluasi pengaruhnya terhadap karakteristik objek hasil segmentasi, termasuk bentuk, ukuran, dan kejelasan batas objek. Nilai *scale* yang diuji, yaitu 0,1; 0,125; 0,5; dan 0,75, dipilih untuk merepresentasikan variasi tingkat segmentasi dari sangat halus hingga relatif kasar. Pemilihan rentang ini didasarkan pada pertimbangan bahwa parameter *scale* dalam segmentasi objek berperan langsung dalam mengontrol ukuran dan heterogenitas segmen yang dihasilkan. Nilai *scale* yang kecil (0,1 dan 0,125) digunakan untuk menangkap objek berukuran kecil dan detail spasial yang tinggi, seperti fitur sempit atau heterogen. Untuk nilai *scale* yang lebih besar (0,5 dan 0,75) digunakan untuk merepresentasikan objek yang lebih homogen dan luas, sehingga menghasilkan segmentasi yang lebih umum.

Tabel 2 Pengaturan segmentasi OBIA

OMN		RGO	
a.	<i>scale</i> : 0,1; 0,125; 0,5; 0,75 <i>shape</i> : default (0,1); <i>compactness</i> : default (0,4)	d.	<i>scale</i> : 0,1; 0,125; 0,5; 0,75 <i>shape</i> : default (0,1); <i>compactness</i> : default (0,4)
b.	<i>scale</i> : 0,1; 0,125; 0,5; 0,75 <i>shape</i> : 0,1; <i>compactness</i> : 0,5	e.	<i>scale</i> : 0,1; 0,125; 0,5; 0,75 <i>shape</i> : 0,1; <i>compactness</i> : 0,5
c.	<i>scale</i> : 0,1; 0,125; 0,5; 0,75 <i>shape</i> : 0,7; <i>compactness</i> : 0,2	f.	<i>scale</i> : 0,1; 0,125; 0,5; 0,75 <i>shape</i> : 0,7; <i>compactness</i> : 0,2

Penggunaan dua nilai *scale* yang berdekatan pada tingkat rendah (0,1 dan 0,125) bertujuan untuk menguji sensitivitas segmentasi pada skala halus, yang umumnya memiliki pengaruh signifikan terhadap akurasi klasifikasi berbasis objek. Secara keseluruhan, variasi nilai ini

memungkinkan evaluasi performa segmentasi pada berbagai tingkat detail, sehingga dapat ditentukan parameter yang paling optimal sesuai dengan karakteristik objek penutupan/penggunaan lahan yang dianalisis. Selanjutnya, kombinasi parameter *shape* dan *compactness* diuji dalam tiga konfigurasi, yaitu pengaturan default pada *eCognition* (*shape* 0,1; *compactness* 0,4), serta dua skenario modifikasi (*shape* 0,1; *compactness* 0,5 dan *shape* 0,7; *compactness* 0,2) untuk mengevaluasi pengaruh bentuk dan kekompakan objek terhadap hasil segmentasi.

Klasifikasi Citra

Klasifikasi citra berbasis objek dilakukan menggunakan metode K-NN pada perangkat lunak *eCognition Essentials* untuk mengidentifikasi kelas penutupan/penggunaan lahan. Proses klasifikasi dilatih menggunakan 70% dari total data sampel yang merepresentasikan 10 kelas penutupan/penggunaan lahan di wilayah penelitian. Klasifikasi K-NN dilakukan dengan cara menghitung jarak antara data uji dan seluruh data latih menggunakan jarak *Euclidean* (Cover dan Hart, 1967; Hastie *et al.*, 2009). Pada penelitian ini jumlah tetangga terdekat (K) ditetapkan 11, yang ditentukan dari jumlah kelas penutupan/penggunaan lahan (10 kelas) ditambah satu, untuk mengurangi potensi jumlah suara yang sama antar kelas dalam proses penentuan kelas berdasarkan mayoritas tetangga terdekat serta meningkatkan stabilitas hasil klasifikasi. Jarak *Euclidean* dihitung dengan persamaan di bawah ini:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

dimana:

$d(x,y)$ = jarak antara data uji (x) dan data latih (y)

x_i = data uji atribut ke- i

y_i = data latih atribut ke- i

n = jumlah atribut

Evaluasi Akurasi Klasifikasi

Evaluasi akurasi klasifikasi dilakukan menggunakan 30% data sampel sebagai data validasi untuk menilai kesesuaian hasil klasifikasi terhadap data referensi. Penilaian akurasi didasarkan pada matriks kesalahan (*confusion matrix*) dengan parameter *User's Accuracy* (UA), *Producer's Accuracy* (PA), dan *Overall Accuracy* (OA). UA menunjukkan tingkat ketepatan kelas pada peta hasil klasifikasi terhadap kondisi referensi, PA merepresentasikan tingkat keberhasilan data referensi terklasifikasi dengan benar, sedangkan OA menunjukkan proporsi keseluruhan data yang terklasifikasi secara tepat. Parameter-parameter tersebut merupakan indikator standar dalam evaluasi akurasi klasifikasi citra penginderaan jauh..

Persamaan akurasi dari UA, PA, dan OA secara berturut-turut adalah sebagai berikut.

$$User's Accuracy = \frac{x_{ii}}{x_{i+}} \times 100\%$$

$$Producer's Accuracy = \frac{x_{ii}}{x_{+i}} \times 100\%$$

$$Overall Accuracy = \frac{\sum_{i=1}^n x_{ii}}{N} \times 100\%$$

dimana:

N = jumlah total sampel yang digunakan

x_{ii} = jumlah sampel yang diklasifikasikan dengan benar untuk kelas i

x_{i+} = total jumlah sampel aktual dari kelas i

x_{+i} = total jumlah sampel yang diprediksi sebagai kelas i

HASIL DAN PEMBAHASAN

Segmentasi dengan Pendekatan OMN

Hasil segmentasi dengan pendekatan OMN (Tabel 3) menunjukkan bahwa parameter *scale* merupakan faktor paling menentukan terhadap jumlah dan ukuran objek hasil segmentasi. Pada nilai *scale* rendah (0,125), jumlah objek sangat tinggi (1.731.784 objek) dengan luas minimum, maksimum, dan rata-rata yang seragam sebesar 0,090 ha, setara dengan satu piksel citra Landsat 8, yang mengindikasikan bahwa segmentasi pada *scale* ini belum mampu menggabungkan piksel berdasarkan homogenitas spektral dan spasial. Kondisi tersebut menghasilkan objek yang menyerupai unit piksel individual dan cenderung mendekati pendekatan klasifikasi berbasis piksel (Blaschke *et al.*, 2008; Blaschke, 2010). Seiring peningkatan nilai *scale* menjadi 0,5 dan 0,75 pada kombinasi *shape* dan *compactness* yang sama, jumlah objek menurun secara signifikan, misalnya pada pengaturan default dari 1.731.784 menjadi 212.296 dan 106.788 objek, yang diikuti oleh peningkatan luas rata-rata objek dari 0,090 menjadi 0,735 dan 1,462 ha, mencerminkan penggabungan piksel menjadi objek yang lebih besar dan relatif homogen (Drăguț *et al.*, 2014). Secara umum, pendekatan OMN sangat sensitif terhadap variasi parameter *scale*, yang memengaruhi jumlah dan ukuran objek secara signifikan. Hal ini menghasilkan segmentasi yang lebih dinamis, tetapi

menuntut pemilihan parameter yang cermat agar objek tetap representatif.

Segmentasi dengan Pendekatan RGO

Hasil segmentasi menggunakan pendekatan RGO (Tabel 4) menunjukkan bahwa metode ini menghasilkan jumlah objek yang relatif lebih sedikit dan berukuran lebih besar dibandingkan pendekatan OMN, bahkan pada nilai *scale* rendah. Pada *scale* 0,125 dengan pengaturan *shape* dan *compactness default*, jumlah objek tercatat sebanyak 115.616 dengan luas rata-rata 1,350 ha, yang mengindikasikan bahwa RGO mampu mengelompokkan piksel secara lebih menyeluruh sehingga membentuk objek yang relatif homogen pada *scale* rendah. Seiring peningkatan nilai *scale* menjadi 0,5 dan 0,75, jumlah objek menurun secara bertahap hingga 75.290 objek, sementara luas rata-rata objek meningkat menjadi 2,073 ha, mencerminkan kecenderungan penggabungan objek yang konsisten seiring perubahan *scale*.

Variasi parameter *shape* dan *compactness* memengaruhi hasil segmentasi RGO, meskipun pengaruhnya relatif lebih moderat dibandingkan parameter *scale*. Pada *scale* 0,75, kombinasi *shape* 0,1 dan *compactness* 0,5 menghasilkan 83.114 objek dengan luas rata-rata 1,878 ha, sedangkan kombinasi *shape* 0,7 dan *compactness* 0,2 menghasilkan 102.002 objek dengan luas rata-rata 1,530 ha. Pola ini menunjukkan bahwa nilai *shape* yang lebih rendah dan *compactness* yang lebih tinggi cenderung membentuk objek yang lebih besar, sedangkan nilai *shape* yang lebih tinggi menghasilkan objek yang lebih terfragmentasi. Secara umum, hasil ini mengindikasikan bahwa pendekatan RGO menghasilkan segmentasi yang lebih stabil dan konsisten terhadap variasi parameter, dengan karakteristik spasial objek yang relatif seragam.

Tabel 3 Jumlah dan luas objek hasil segmentasi dengan pendekatan OMN

Parameter Segmentasi	Jumlah Objek	Luas Minimum Objek (ha)	Luas Maksimum Objek (ha)	Rataan Luas Objek (ha)
Scale 0,125; <i>shape</i> dan <i>compactness default</i>	1.731.784	0,090	0,090	0,090
Scale 0,5; <i>shape</i> dan <i>compactness default</i>	212.296	0,090	6,309	0,735
Scale 0,75; <i>shape</i> dan <i>compactness default</i>	106.788	0,090	11,626	1,462
Scale 0,125; <i>shape</i> 0,1; <i>compactness</i> 0,5	1.731.784	0,090	0,090	0,090
Scale 0,5; <i>shape</i> 0,1; <i>compactness</i> 0,5	288.793	0,090	4,236	0,540
Scale 0,75; <i>shape</i> 0,1; <i>compactness</i> 0,5	126.576	0,090	9,463	1,233
Scale 0,125; <i>shape</i> 0,7; <i>compactness</i> 0,2	1.731.784	0,090	0,090	0,090
Scale 0,5; <i>shape</i> 0,7; <i>compactness</i> 0,2	488.742	0,090	1,082	0,319
Scale 0,75; <i>shape</i> 0,7; <i>compactness</i> 0,2	295.914	0,090	4,326	0,527

Tabel 4 Jumlah dan luas objek hasil segmentasi dengan pendekatan RGO

Parameter Segmentasi	Jumlah Objek	Luas Minimum Objek (ha)	Luas Maksimum Objek (ha)	Rataan Luas Objek (ha)
Scale 0,125; <i>shape</i> dan <i>compactness default</i>	115.616	0,090	12,888	1,350
Scale 0,5; <i>shape</i> dan <i>compactness default</i>	99.096	0,090	14,961	1,575
Scale 0,75; <i>shape</i> dan <i>compactness default</i>	75.290	0,090	16,403	2,073
Scale 0,125; <i>shape</i> 0,1; <i>compactness</i> 0,5	115.099	0,090	12,888	1,356
Scale 0,5; <i>shape</i> 0,1; <i>compactness</i> 0,5	101.971	0,090	14,961	1,531
Scale 0,75; <i>shape</i> 0,1; <i>compactness</i> 0,5	83.114	0,090	16,403	1,878
Scale 0,125; <i>shape</i> 0,7; <i>compactness</i> 0,2	114.190	0,090	12,618	1,367
Scale 0,5; <i>shape</i> 0,7; <i>compactness</i> 0,2	109.510	0,090	12,798	1,425
Scale 0,75; <i>shape</i> 0,7; <i>compactness</i> 0,2	102.002	0,090	14,961	1,530

Perbandingan OMN dan RGO

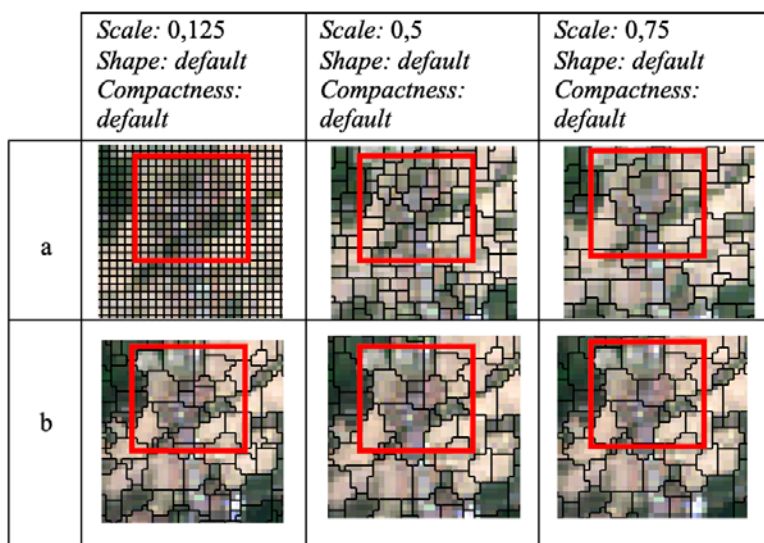
Hasil segmentasi menunjukkan bahwa pendekatan OMN dan RGO memiliki karakteristik yang berbeda secara signifikan. OMN sangat dipengaruhi oleh parameter *scale*, di mana nilai rendah menghasilkan jumlah objek yang sangat banyak dengan ukuran kecil (*over-segmentation*), sedangkan peningkatan *scale* menurunkan jumlah objek dan memperbesar ukuran objek melalui proses penggabungan piksel menjadi unit yang lebih homogen (Gambar 2a; Gambar 3a; Gambar 4a). Fenomena ini telah banyak dilaporkan dalam studi OBIA, bahwa parameter *scale* merupakan faktor utama yang mengontrol ukuran dan heterogenitas objek (Blaschke, 2010; Drăguț *et al.*, 2014). Variasi parameter *shape* dan *compactness* pada OMN terutama memengaruhi karakter geometris objek, khususnya pada *scale* menengah hingga tinggi, di mana bobot bentuk yang lebih besar cenderung menghasilkan objek yang lebih terfragmentasi (Baatz dan Schäpe, 2000; Hay dan Castilla, 2008).

Sebaliknya, RGO menghasilkan jumlah objek yang lebih sedikit dengan ukuran lebih besar dan relatif homogen, bahkan pada *scale* rendah, serta menunjukkan respons yang lebih stabil terhadap variasi parameter. Stabilitas ini berkaitan dengan mekanisme pertumbuhan wilayah (*region growing*) yang mengelompokkan piksel berdasarkan kesamaan spektral dan kedekatan spasial secara lebih menyeluruh (Hossain dan Chen, 2019; Badia *et al.*, 2023). Secara kuantitatif, perbedaannya cukup mencolok, di mana pada *scale* 0,125 jumlah objek OMN sekitar 15 kali lebih banyak dibandingkan RGO, dengan luas rata-ran yang jauh lebih kecil. Hal ini menunjukkan bahwa OMN cenderung menghasilkan segmentasi yang lebih rinci namun rentan terhadap fragmentasi, sedangkan RGO menghasilkan segmentasi yang lebih teragregasi dan konsisten. Perbedaan karakter ini sejalan dengan temuan penelitian lain yang menyatakan bahwa segmentasi yang

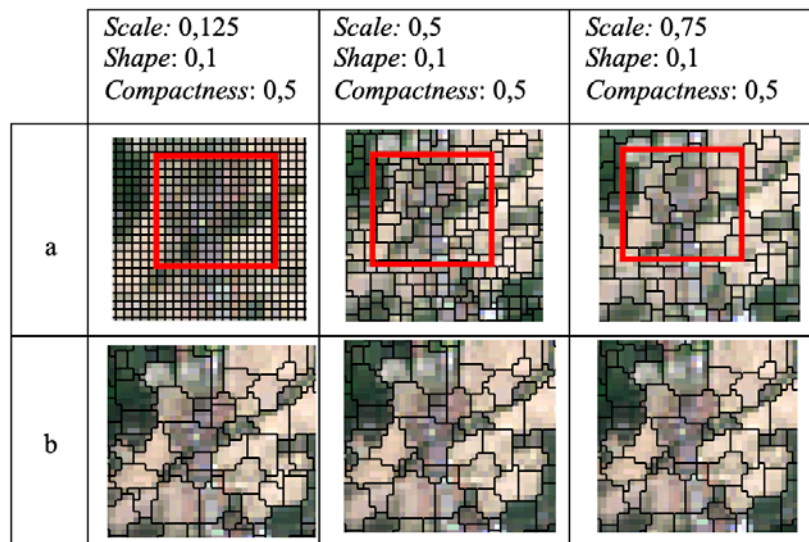
terlalu rinci maupun terlalu kasar dapat memengaruhi akurasi klasifikasi secara signifikan (Espíndola *et al.*, 2006; Badia *et al.*, 2023). Implikasinya, OMN berpotensi menangkap detail spasial yang lebih halus tetapi dapat meningkatkan kesalahan komisi, sementara RGO lebih representatif secara spasial meskipun berisiko melakukan generalisasi pada kelas yang heterogen (Blaschke, 2010; Foody, 2002).

Akurasi dan Hasil Klasifikasi Penutupan/Penggunaan Lahan

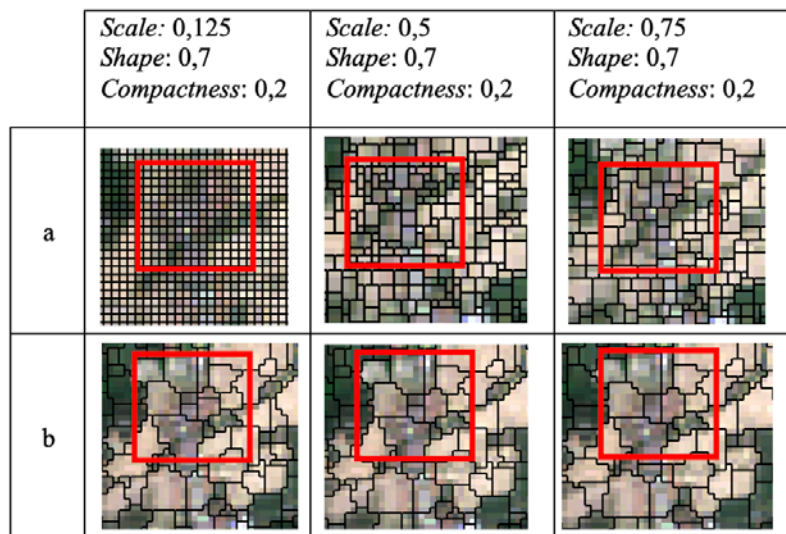
Hasil evaluasi akurasi klasifikasi berbasis objek dengan pendekatan OMN menunjukkan bahwa konfigurasi parameter segmentasi, khususnya nilai *scale*, berpengaruh signifikan terhadap kinerja klasifikasi K-NN (Tabel 5). Pada *scale* 0,5 dengan parameter *shape* dan *compactness* default, diperoleh kinerja klasifikasi yang paling seimbang antar kelas, ditunjukkan oleh nilai rata-ran akurasi menengah hingga tinggi, dengan kelas hutan mencapai akurasi tertinggi (>90%) serta kelas pertanian seperti sawah vegetatif, sawah bera, dan ladang menunjukkan akurasi yang relatif stabil (70–85%). Peningkatan *scale* menjadi 0,75 (parameter default) meningkatkan akurasi pada kelas yang homogen dan berukuran luas, terutama hutan, namun menurunkan akurasi pada kelas yang bersifat heterogen dan kompleks secara spasial, seperti lahan terbangun, tanah terbuka, dan sawah generatif, akibat terjadinya generalisasi objek. Pada konfigurasi *scale* 0,75 dengan *shape* 0,1 dan *compactness* 0,5, akurasi klasifikasi cenderung menurun secara keseluruhan, yang tercermin dari rendahnya nilai UA pada sebagian besar kelas dan mengindikasikan meningkatnya kesalahan komisi. Secara keseluruhan, nilai OA masing-masing sebesar 75,3%, 69,6%, dan 67,6% menunjukkan bahwa kombinasi parameter segmentasi yang moderat memberikan kinerja klasifikasi K-NN yang paling optimal pada pendekatan OMN.



Gambar 2. Potongan citra segmentasi pada *scale* 0,125 (kiri), 0,5 (tengah) dan 0,75 (kanan) dengan *shape* dan *compactness default*: (a) OMN dan (b) RGO



Gambar 3. Potongan citra segmentasi pada *scale* 0,125 (kiri), 0,5 (tengah) dan 0,75 (kanan) dengan *shape* 0,1 dan *compactness* 0,5: (a) OMN dan (b) RGO



Gambar 4. Potongan citra segmentasi pada *scale* 0,125 (kiri), 0,5 (tengah) dan 0,75 (kanan) dengan *shape* 0,5 dan *compactness* 0,2: (a) OMN dan (b) RGO

Tabel 5. Akurasi Klasifikasi Penutupan/penggunaan Lahan Menggunakan K-NN pada Citra Segmentasi OMN

	<i>Scale</i> 0,5; <i>Shape</i> dan <i>Compactness</i> Default			<i>Scale</i> 0,75; <i>Shape</i> dan <i>Compactness</i> default			<i>Scale</i> 0,75; <i>Shape</i> 0,1; <i>Compactness</i> 0,5		
	UA (%)	PA (%)	Mean (%)	UA (%)	PA (%)	Mean (%)	UA (%)	PA (%)	Mean (%)
Hutan	83,3	98,0	90,7	92,4	95,0	93,7	82,9	100	91,5
Lahan Terbangun	77,0	80,4	78,7	70,7	62,7	66,7	66,9	63,9	65,4
Kebun Campuran	81,5	59,9	70,7	69,5	60,5	65	74,3	57,1	65,7
Ladang	68,2	74,3	71,3	70,4	69,4	69,9	64,0	61,8	62,9
Tanah Terbuka	50,0	58,1	54,0	32,2	46,7	39,5	35,8	46,7	41,3
Sawah Generatif	65,8	49,0	57,4	54,2	51,0	52,6	53,5	45,0	49,3
Sawah Vegetatif	63,2	80,0	71,6	74,0	66,7	70,4	50,0	50,0	50,0
Sawah Bera	96,0	72,7	84,4	80,0	72,7	76,4	61,1	66,7	63,9
Waduk	100	100	100	100	100	100	100	100	100
Sungai	91,9	98,0	95,0	90,8	88,8	89,8	92,0	89,9	91,0
OA (%)		75,3			69,6			67,6	

Hasil evaluasi akurasi klasifikasi berbasis objek pada citra hasil segmentasi RGO menunjukkan kinerja yang relatif stabil terhadap variasi parameter segmentasi (Tabel 6). Pada konfigurasi *scale* 0,5 dengan *shape* dan *compactness default*, diperoleh nilai OA tertinggi sebesar 75,6%, dengan performa sangat baik pada kelas berukuran besar dan homogen seperti hutan (rata-rata akurasi 91,4%), sawah bera (92,4%), waduk (100%), dan sungai (84,9%). Peningkatan *scale* menjadi 0,75 (parameter default) menurunkan OA menjadi 71,8%, terutama akibat penurunan akurasi pada kelas yang memiliki heterogenitas spektral tinggi, seperti ladang dan kebun campuran, meskipun akurasi kelas sungai tetap meningkat. Pada konfigurasi *scale* 0,75 dengan *shape* 0,1 dan *compactness* 0,5, OA kembali meningkat menjadi 72,6%, dengan perbaikan pada kelas ladang dan lahan terbangun, namun masih menunjukkan keterbatasan pada kelas tanah terbuka dan sawah generatif. Secara keseluruhan, hasil ini menunjukkan bahwa segmentasi RGO menghasilkan objek yang lebih homogen dan stabil, sehingga mampu mendukung klasifikasi K-NN secara konsisten, terutama pada kelas dengan struktur spasial yang jelas.

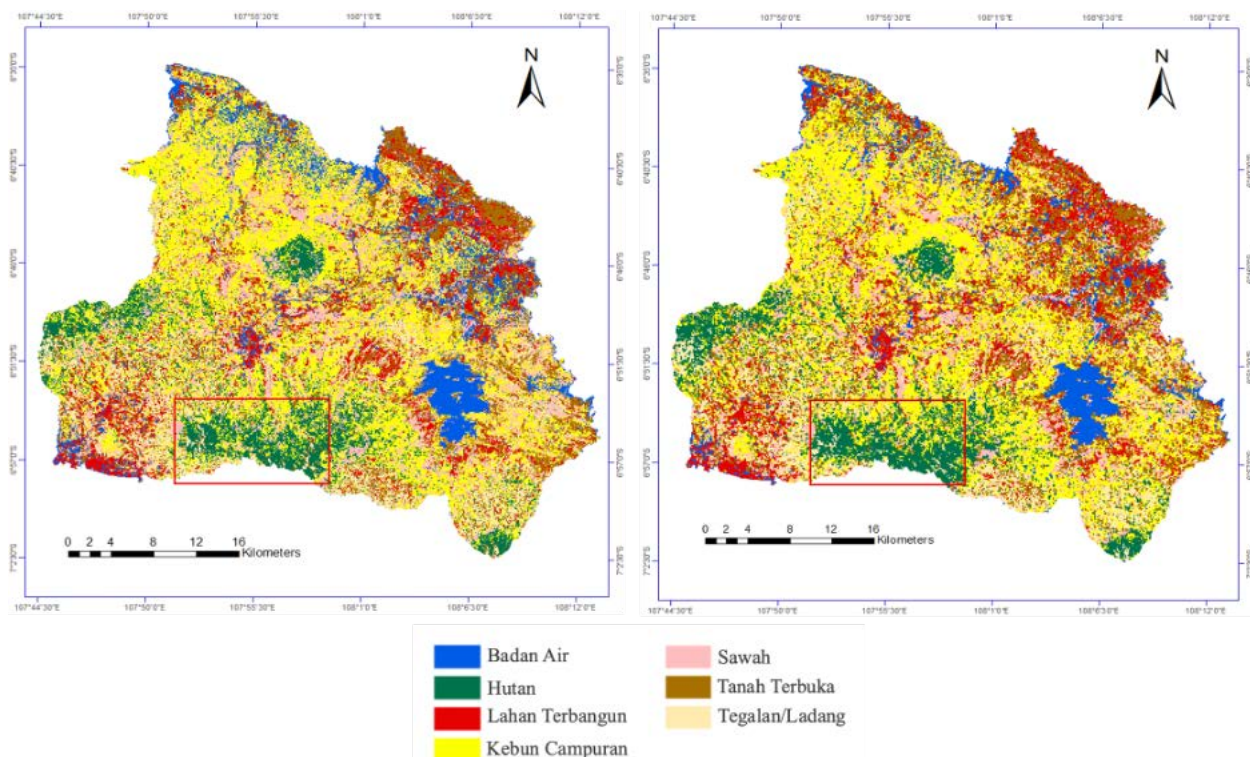
Perbandingan akurasi klasifikasi K-NN menunjukkan perbedaan kinerja yang jelas antara segmentasi OMN dan RGO. Secara umum, RGO menghasilkan nilai OA sedikit lebih tinggi dan lebih stabil dibandingkan OMN pada konfigurasi parameter yang setara, dengan OA maksimum mencapai 75,6% pada *scale* 0,5 (default), sedangkan OMN mencapai OA tertinggi sebesar 75,3% pada konfigurasi yang sama. Pada tingkat UA dan PA, RGO menunjukkan keunggulan yang lebih konsisten pada kelas dengan objek besar dan homogen, seperti hutan, sawah bera, waduk, dan sungai, yang ditunjukkan oleh nilai UA dan PA di atas 85–100%.

Sebaliknya, OMN menunjukkan sensitivitas yang lebih tinggi terhadap variasi parameter segmentasi, khususnya nilai *scale*, yang menyebabkan fluktuasi UA dan PA pada kelas yang heterogen dan berfragmentasi, seperti lahan terbangun, tanah terbuka, dan sawah generatif. Meskipun OMN mampu menangkap detail spasial yang lebih halus pada *scale* menengah, fragmentasi objek yang berlebihan pada *scale* tinggi cenderung meningkatkan kesalahan komisi dan menurunkan UA. Dengan demikian, hasil ini mengindikasikan bahwa segmentasi RGO lebih efektif dalam mendukung klasifikasi K-NN pada citra Landsat karena menghasilkan objek yang lebih representatif dan stabil secara spasial.

Visualisasi hasil klasifikasi dengan parameter *scale* 0.5 serta *shape* dan *compactness default* menunjukkan pendekatan segmentasi RGO menghasilkan objek klasifikasi yang lebih homogen dibandingkan dengan OMN. Gambar 5 menampilkan tujuh kelas penggunaan lahan, dengan sawah generatif, sawah vegetatif, dan sawah bera digabung sebagai kelas sawah; sedangkan waduk dan sungai digabung sebagai kelas badan air. Luasan hasil klasifikasi dengan segmentasi RGO adalah hutan 14.560 ha, lahan terbangun 16.298 ha, kebun campuran 50.494 ha, ladang/tegalan 16.355 ha, tanah terbuka 26.955 ha, sawah 21.097 ha, dan badan air 10.322 ha. Jika dibandingkan dengan Data Badan Pusat Statistik (BPS) terkait jenis penggunaan lahan tahun 2024 dan 2025 untuk Kabupaten Sumedang, terlihat perbedaan signifikan. Luas sawah hasil klasifikasi K-NN (21.097 ha) lebih kecil dibandingkan luas baku sawah BPS (31.164 ha), sementara luas hutan (14.560 ha) dan terutama kebun campuran (50.494 ha) hasil klasifikasi jauh lebih besar dibandingkan data BPS masing-masing sebesar 10.613 ha dan 5.180 ha.

Tabel 6. Akurasi Klasifikasi Penutupan/penggunaan Lahan Menggunakan K-NN pada Citra Segmentasi RGO

	<i>Scale</i> 0,5; <i>Shape</i> dan <i>Compactness Default</i>			<i>Scale</i> 0,75; <i>Shape</i> dan <i>Compactness default</i>			<i>Scale</i> 0,75; <i>Shape</i> 0,1; <i>Compactness</i> 0,5		
	UA (%)	PA (%)	Mean (%)	UA (%)	PA (%)	Mean (%)	UA (%)	PA (%)	Mean (%)
Hutan	86,7	96,0	91,4	90,0	89,2	89,6	86,1	91,2	88,7
Lahan Terbangun	79,9	72,8	76,4	76,2	69,0	72,6	77,7	72,8	75,3
Kebun Campuran	75,4	66,7	71,0	70,7	59,2	65,0	64,7	59,9	62,3
Ladang	80,1	84,0	82,0	63,8	78,5	71,2	69,9	85,4	77,7
Tanah Terbuka	43,8	54,3	49,0	37,5	45,7	41,6	42,7	41,9	42,3
Sawah Generatif	46,4	51,0	48,7	60,0	58,8	59,4	50,0	49,0	49,5
Sawah Vegetatif	84,6	73,3	79,1	73,3	73,3	73,3	73,3	73,3	73,3
Sawah Bera	100	84,8	92,4	100	84,8	92,4	100	84,8	92,4
Waduk	100	100	100	100	100	100	100	100	100
Sungai	88,9	80,9	84,9	94,9	84,3	89,6	90,0	80,9	85,5
OA (%)		75,6			71,8			72,6	



Gambar 5. Hasil klasifikasi K-NN dengan *scale*: 0,5 dan parameter *shape* dan *compactness default*: OMN (kiri) dan RGO (kanan)

Perbedaan ini tidak hanya terkait nilai OA (75,6%), tetapi lebih dipengaruhi variasi UA dan PA yang mencerminkan kesalahan komisi dan omisi (Congalton, 1991; Foody, 2002). Pada kebun campuran, PA rendah (59,9%) menunjukkan kesalahan omisi, namun luas yang berlebihan menandakan dominasi kesalahan komisi, di mana kelas lain seperti ladang/tegalan dan sawah terklasifikasi sebagai kebun campuran. Sebaliknya, ladang/tegalan, tanah terbuka, dan sawah menunjukkan PA rendah sehingga sebagian area berpindah ke kelas lain. Kesamaan spektral antar vegetasi serta efek segmentasi (fragmentasi atau generalisasi) meningkatkan ketidakpastian pada lanskap heterogen (Drăguț *et al.*, 2014; Blaschke, 2010). Selain itu, keterbatasan K-NN dalam membedakan kelas dengan separabilitas spektral rendah dan variasi intra-kelas tinggi turut menambah kesalahan pada citra Landsat resolusi menengah (Hastie *et al.*, 2009). Temuan ini sejalan dengan penelitian OBIA lain yang menekankan kualitas segmentasi sebagai faktor utama akurasi klasifikasi (Badia *et al.*, 2023; He *et al.*, 2024), di mana segmentasi terlalu rinci atau terlalu umum dapat menurunkan representativitas objek dan meningkatkan kesalahan.

SIMPULAN

Perbedaan pendekatan segmentasi OMN dan RGO terbukti berpengaruh signifikan terhadap karakteristik objek dan kinerja klasifikasi penutupan/penggunaan lahan berbasis K-NN di Kabupaten Sumedang. Parameter *scale* menjadi faktor paling dominan, di mana OMN menunjukkan sensitivitas tinggi dengan kecenderungan *over-segmentation* pada *scale* rendah dan generalisasi pada *scale* tinggi. Sebaliknya, RGO menghasilkan segmentasi yang lebih stabil, dengan objek yang lebih besar dan homogen serta relatif konsisten terhadap variasi parameter.

Akurasi menunjukkan bahwa RGO memberikan kinerja klasifikasi sedikit lebih baik dan stabil dibandingkan OMN, terutama pada kelas yang homogen. Meskipun OMN mampu menangkap detail spasial lebih halus, pendekatan ini memerlukan pengaturan parameter yang lebih hati-hati. Secara keseluruhan, RGO dengan parameter moderat (*scale* 0,5; *shape* 0,1; dan *compactness* 0,4) direkomendasikan sebagai konfigurasi optimal, meskipun ketidakpastian klasifikasi masih terjadi pada kelas dengan kemiripan spektral tinggi akibat keterbatasan metode K-NN dan resolusi citra.

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

- Ajibola, S., and P. Cabral. 2024. A Systematic Literature Review and Bibliometric Analysis of Semantic Segmentation Models in Land Cover Mapping. *Remote Sensing*, 16(12): 2222.
- Anderson, J.R., E.E. Hardy, J.T. Roach, and R.E. Witmer. 1976. A land use and land cover classification system for use with remote sensor data. *US Geological Survey Professional Paper*, 964: 1–41.
- Baatz, M., and A. Schäpe. 2000. Multiresolution segmentation: An optimization approach for high quality multi-scale image segmentation. In: Strobl J, Blaschke T, Griesebner G (eds). *Angewandte Geographische Informationsverarbeitung XII*. Wichmann Verlag. 12–23.

- Badia, A., A.C. Teodoro, and O. El Kharki. 2023. Remote sensing imagery segmentation in object-based analysis: A review of methods and optimization. *Remote Sensing Applications: Society and Environment*, 32: 101031.
- Belgiu, M., and L. Drăgu. 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114: 24–31.
- Blaschke, T., S. Lang, and G.J. Hay. 2008. *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications*. Berlin: Springer.
- Blaschke, T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1): 2–16.
- Congalton, R.G. 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1): 35–46.
- Congedo, L. 2021. Semi-Automatic Classification Plugin Documentation Release 7.9.7.1.
- Cover, T.M., and P.E. Hart. 1967. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1): 21–27
- Drăguț, L., O. Csillik, C. Eisank, and D. Tiede. 2014. Automated parameterisation for multi-scale image segmentation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 88: 119–127.
- Duro, D.C., S.E. Franklin, and M.G. Dubé. 2012. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms. *Remote Sensing of Environment*, 118: 259–272
- Duveiller, G., J. Hooker, and A. Cescatti. 2020. Local biophysical effects of land use and land cover change: towards an assessment tool for policy makers. *Land Use Policy*, 91: 104382.
- Espíndola, G.M., G. Câmara, I.A. Reis, L.S. Bins, and A.M.V. Monteiro. 2006. Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation. *International Journal of Remote Sensing*, 27(14): 3035–3040.
- FAO. 2017. *Land use statistics and indicators*. Food and Agriculture Organization of the United Nations. Rome.
- Foody, G.M., and A. Mathur. 2004. Toward intelligent training of supervised image classifications: Directing training data acquisition for SVM classification. *Remote Sensing of Environment*, 93(1–2): 107–117.
- Foody, G.M. 2002. Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1): 185–201.
- Hastie, T., R. Tibshirani, and J. Friedman. 2009. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). New York: Springer.
- Hay, G.J., and G. Castilla. 2008. Geographic object-based image analysis (GEOBIA): A new name for a new discipline. In T. Blaschke, S. Lang, & G. J. Hay (Eds.), *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications* (pp. 75–89). Berlin: Springer.
- He, T., J. Chen, L. Kang, and Q. Zhu. 2024. Evaluation of Global-Scale and Local-Scale Optimized Segmentation Algorithms in GEOBIA with SAM on Land Use and Land Cover. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17: 6721–6738.
- Hossain, M.D., and D. Chen. 2019. Segmentation for object-based image analysis: A review. *Remote Sensing*, 11(7): 1–28
- IPCC. 2019. 2019 Refinement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories. Intergovernmental Panel on Climate Change.
- Kabeja, C., R. Li, D.E.R. Rwatangabo, and J. Duan. 2022. Monitoring Land Use/Cover Changes by Using Multi-Temporal Remote Sensing for Urban Hydrological Assessment: A Case Study in Beijing, China. *Remote Sensing*, 14(17): 4273
- Lv, J., Q. Shen, M. Lv, and Y. Wang. 2023. Deep learning-based semantic segmentation of remote sensing images: A review. *Frontiers in Ecology and Evolution*, 11: 1201125.
- Ma, L., Y. Liu, X. Zhang, Y. Ye, G. Yin, and B.A. Johnson. 2019. Deep learning in remote sensing applications: A meta-analysis. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152: 166–177.
- Maxwell, A.E., T.A. Warner, and F. Fang. 2018. Implementation of machine-learning classification in remote sensing. *Remote Sensing*, 10(9): 1–22.
- Oscro, L.P., Q. Wu, E.L. de Lemos, and W.N. Gonçalves. 2023. The Segment Anything Model for remote sensing applications. *arXiv*, 2306.16623: 1–15.
- Potapov, P., M.C. Hansen, A. Pickens, A. Hernandez-Serna, A. Tyukavina, S. Turubanova, V. Zalles, X. Li, A. Khan, F. Stolle, N. Harris, X.P. Song, A. Baggett, I. Kommareddy, and A. Kommareddy. 2022. The Global 2000–2020 Land Cover and Land Use Change Dataset Derived from the Landsat Archive: First Results. *Frontiers in Remote Sensing*, 3: 856903.
- Hastie, T., R. Tibshirani, and J. Friedman. 2009. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.