

ANALISIS PERBANDINGAN PARAMETER SEGMENTASI DALAM KLASIFIKASI BERBASIS OBJEK UNTUK PENUTUPAN/PENGUNAAN LAHAN DI KABUPATEN SUMEDANG

Comparative Analysis of Segmentation Parameters in Object-Based Image Classification for Land Cover/Land Use in Sumedang Regency

Muhammad Ardiansyah^{1,2)*}, Boedi Thahjono¹⁾, Niken Dwia Oktaviani³⁾

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

ABSTRACT

Information on land cover and land use plays an important role in biophysical regional analysis, spatial planning, resource management, and the formulation of sustainable development policies. To support these needs, accurate remote sensing image classification is crucial. The Object-Based Image Analysis (OBIA) approach is considered superior to pixel-based classification, as it provides higher accuracy and minimizes the salt-and-pepper effect. The success of object-based classification is influenced by the segmentation method employed. In this study, two segmentation approaches, namely Original Multiresolution Segmentation (OMN) and Region Grow on Object (RGO), were examined based on combinations of segmentation parameters and evaluated for accuracy using the Random Forest (RF) classification algorithm. The segmentation results indicate that the OMN approach produces smaller and more detailed objects, though they tend to be fragmented, whereas the RGO approach generates larger and more generalized objects with greater spatial stability. Based on object-based classification using RGO segmentation with a scale parameter of 0.5, seven land cover and land use classes were identified, with three dominant categories: plantations (50,393 ha), bare land (29,658 ha), and rice fields (27,092 ha). The classification accuracy of RGO was consistently higher than OMN across all parameter configurations, with the rice field class showing close alignment with official BPS data from 2024, which recorded an area of 30,038 ha. These findings demonstrate that the RGO approach is more effective in producing representative segmentation and classification for land use mapping.

Keywords: compactness, OBIA, scale, shape

ABSTRAK

Informasi mengenai penutupan/penggunaan lahan memiliki peran penting dalam analisis biofisik wilayah, perencanaan tata ruang, pengelolaan sumber daya, dan perumusan kebijakan pembangunan berkelanjutan. Untuk mendukung kebutuhan tersebut, klasifikasi citra penginderaan jauh yang akurat menjadi krusial. Pendekatan *Object-Based Image Analysis* (OBIA) dinilai lebih unggul dibandingkan klasifikasi berbasis piksel karena mampu menghasilkan akurasi yang lebih tinggi serta meminimalkan efek *salt and pepper*. Keberhasilan klasifikasi berbasis objek dipengaruhi oleh metode segmentasi yang digunakan. Dalam penelitian ini, dua pendekatan segmentasi, yaitu *Original Multiresolution Segmentation* (OMN) dan *Region Grow on Object* (RGO), dikaji berdasarkan kombinasi parameter segmentasi dan dievaluasi akurasi melalui algoritma klasifikasi *Random Forest* (RF). Hasil segmentasi menunjukkan bahwa pendekatan OMN menghasilkan objek yang lebih kecil dan detail, namun cenderung terfragmentasi, sedangkan pendekatan RGO menghasilkan objek yang lebih besar dan tergeneralisasi dengan kestabilan spasial yang lebih tinggi. Berdasarkan klasifikasi berbasis objek menggunakan segmentasi RGO pada parameter *scale* 0.5, diperoleh tujuh kelas penutupan/penggunaan lahan, dengan tiga kategori dominan yaitu perkebunan (50,393 ha), tanah terbuka (29,658 ha), dan sawah (27,092 ha). Akurasi klasifikasi RGO tercatat lebih tinggi dibandingkan OMN pada seluruh konfigurasi parameter, dengan nilai kedekatan terhadap data BPS tahun 2024 khususnya pada kelas sawah yang tercatat sebesar 30,038 ha. Temuan ini menunjukkan bahwa pendekatan RGO lebih efektif dalam menghasilkan segmentasi dan klasifikasi yang representatif untuk pemetaan penggunaan lahan.

Kata kunci: compactness, OBIA, scale, shape

PENDAHULUAN

Pemantauan penutupan/penggunaan lahan merupakan aspek fundamental dalam pengelolaan sumber daya alam, perencanaan wilayah, dan pengawasan perubahan lingkungan. Teknologi penginderaan jauh telah

menjadi instrumen utama dalam menyediakan data spasial dan temporal yang luas, akurat serta berkesinambungan untuk mendukung analisis tersebut (Attri *et al.*, 2015). Dalam klasifikasi citra penginderaan jauh, pendekatan berbasis piksel dengan algoritma *Maximum Likelihood* dan *Random Forest* banyak diterapkan dalam berbagai studi

^{*)} Penulis Korespondensi: Telp. +62811112973; Email: ardysaja@gmail.com

DOI: <http://dx.doi.org/10.29244/jitl.27.2.131-139>

(Marlina, 2022; Purboyo *et al.*, 2024; Sampurno dan Thoriq, 2016) karena keunggulannya dalam pengolahan data spektral yang cepat dan menghasilkan klasifikasi dengan tingkat akurasi yang tinggi. Namun, pendekatan ini cenderung mengabaikan informasi spasial seperti bentuk, tekstur, dan hubungan antar-piksel, sehingga rentan menghasilkan fenomena *salt and pepper* yang menurunkan akurasi klasifikasi, terutama pada wilayah dengan heterogenitas tinggi (Marwati *et al.*, 2018; Wang *et al.*, 2022; Weih dan Riggan, 2009).

Sebagai solusi atas keterbatasan tersebut, pendekatan *Object-Based Image Analysis* (OBIA) menawarkan klasifikasi yang lebih kontekstual dan representatif terhadap entitas geografis dengan mengelompokkan piksel serupa menjadi objek yang memuat informasi spektral, spasial, dan geometris secara komprehensif (Blaschke *et al.*, 2014; Engrila *et al.*, 2022). OBIA telah menunjukkan efektivitasnya dalam berbagai aplikasi, seperti klasifikasi fase tumbuh padi (Ardiansyah *et al.*, 2023), pemetaan vegetasi mangrove (Timisela *et al.*, 2020), dan identifikasi habitat bentik (Candra *et al.*, 2017). Studi komparatif menunjukkan bahwa OBIA mampu meningkatkan akurasi klasifikasi secara signifikan dibandingkan pendekatan berbasis piksel, serta mengurangi efek *salt and pepper* yang umum terjadi pada citra resolusi tinggi.

Dalam implementasinya, OBIA terdiri dari dua komponen utama, yaitu segmentasi dan klasifikasi, yang sangat menentukan kualitas hasil akhir. Segmentasi yang optimal memerlukan penyesuaian parameter dan pendekatan yang tepat agar objek yang terbentuk dapat merepresentasikan fitur geografis secara akurat (Drăguț dan Eisank, 2012). Selain parameter *scale*, faktor seperti *shape* dan *compactness* juga berperan penting dalam menentukan kualitas segmentasi. Studi oleh Akcay *et al.* (2018) menunjukkan bahwa kombinasi parameter segmentasi yang moderat, misalnya nilai *shape* dan *compactness* yang seimbang dapat menghasilkan segmentasi yang lebih konsisten dan meningkatkan akurasi klasifikasi secara signifikan. Penelitian lain oleh Koman *et al.* (2022) juga mengungkapkan bahwa pemilihan parameter segmentasi yang disesuaikan dengan karakteristik tutupan lahan, seperti dominasi vegetasi atau perairan, berdampak langsung terhadap akurasi keseluruhan klasifikasi OBIA.

Beberapa pendekatan segmentasi yang umum digunakan dalam OBIA antara lain adalah *Original Multiresolution Segmentation* (OMN), yang dikembangkan dalam perangkat lunak *eCognition* dan mampu menghasilkan objek dengan fleksibilitas tinggi berdasarkan parameter *scale*, *shape*, dan *compactness*. OMN sangat efektif dalam menangkap variasi spasial dan spektral pada citra resolusi tinggi. Proses OMN dilakukan secara *bottom-up* dengan membangun objek dari piksel, kemudian menggabungkan objek-objek secara iteratif berdasarkan kriteria homogenitas. Selain itu, pendekatan *Region Grow on Object* (RGO) juga mulai banyak digunakan, terutama dalam konteks citra yang memiliki struktur tekstur kompleks. RGO bekerja dengan memperluas wilayah berdasarkan kesamaan nilai piksel dan kedekatan spasial, sehingga cocok untuk klasifikasi tutupan lahan yang memiliki batasan alami seperti sungai, vegetasi, atau area terbangun. Studi oleh Hossain dan Chen (2019) menyoroti bahwa pemilihan algoritma segmentasi yang sesuai sangat

menentukan keberhasilan ekstraksi fitur dalam OBIA, dan bahwa pendekatan seperti OMN dan RGO memiliki keunggulan masing-masing tergantung pada konteks spasial dan spektral citra.


Klasifikasi berbasis objek memerlukan algoritma yang mampu mengenali pola secara efektif. Dua algoritma yang umum digunakan dalam klasifikasi OBIA adalah *K-Nearest Neighbor* (K-NN) dan *Random Forest* (RF), yang masing-masing memiliki keunggulan dalam hal interpretabilitas, efisiensi komputasi, dan kemampuan generalisasi (Belgiu dan Drăguț, 2016). Namun, hasil studi menunjukkan adanya variasi performa antara kedua metode tersebut. Fajarendra *et al.* (2024) melaporkan akurasi RF sebesar 81% dan K-NN sebesar 66%, sedangkan Zhang *et al.* (2023) menunjukkan bahwa K-NN lebih unggul dengan akurasi 87.5% dibandingkan RF sebesar 85.3%. Secara umum, RF lebih banyak digunakan dalam praktik OBIA karena kemampuannya menangani data berdimensi tinggi, mengatasi overfitting, dan memberikan estimasi akurasi yang stabil. Studi oleh Li *et al.* (2015) menunjukkan bahwa kombinasi OBIA dan RF menghasilkan akurasi klasifikasi hingga 90.87% dalam pemetaan tanaman pertanian menggunakan citra multisumber.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk melakukan klasifikasi penutupan/penggunaan lahan berbasis OBIA di Kabupaten Sumedang menggunakan citra Landsat 8. Pemilihan Kabupaten Sumedang sebagai lokasi studi didasarkan pada keragaman karakteristik penutupan/penggunaan lahannya serta dinamika pembangunan yang tinggi, sehingga wilayah ini dinilai representatif untuk kajian klasifikasi. Secara khusus, penelitian ini menganalisis perbedaan hasil segmentasi berdasarkan kombinasi parameter serta mengevaluasi akurasi klasifikasi dari dua pendekatan segmentasi, yaitu OMN dan RGO yang masing-masing dikombinasikan dengan metode klasifikasi RF. Hasil penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan strategi klasifikasi citra penginderaan jauh yang lebih akurat dan kontekstual, khususnya pada wilayah dengan kompleksitas tutupan lahan yang tinggi.

BAHAN DAN METODE

Lokasi Penelitian

Penelitian ini dilaksanakan pada Desember 2024 hingga Mei 2025 di Kabupaten Sumedang, Jawa Barat, yang terletak antara 6°44'–7°83' LS dan 107°21'–108°21' BT, serta berbatasan dengan Indramayu, Subang, Garut, Bandung, dan Majalengka (Gambar 1). Sebagai wilayah strategis yang berada di antara Kota Bandung dan Cirebon, Sumedang menjadi lokasi proyek strategis nasional, termasuk pembangunan Waduk Jatigede dan Jalan Tol Cisumdawu. Waduk Jatigede berfungsi untuk pengendalian banjir, irigasi, penyediaan air bersih, pengendalian erosi, dan pembangkit listrik (Sugiarti, 2017), sedangkan Tol Cisumdawu dirancang untuk mengintegrasikan jalur transportasi regional menuju Rancakalong, Bandung–Cirebon, Ujung Jaya, dan Cimalaka (Oka dan Pradono, 2011). Ibukota kabupaten berada di Kecamatan Sumedang Utara.



Gambar 1. Peta lokasi penelitian

Alat dan Bahan

Penelitian ini menggunakan komputer dengan perangkat lunak QGIS versi 3.28.3, eCognition Essentials 1.2, dan Google Earth Pro serta *smartphone* yang dilengkapi aplikasi Avenza Map versi 3.5 dan Timestamp Camera versi 1.234. Data utama 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, diunduh dari situs EarthExplorer (<https://earthexplorer.usgs.gov/>). Data pendukung berupa *shapefile* batas administrasi yang diunduh dari portal Tanahair Indonesia (<https://tanahair.indonesia.go.id/portal-web/>).

Pengolahan Citra

Citra Landsat 8 OLI/TIRS Collection 2 Level-1 tersedia dalam format *Digital Number* (DN) dengan rentang 0–65,535 (14 bit). Untuk meningkatkan akurasi radiometrik, dilakukan koreksi atmosferik menggunakan metode *Dark Object Subtraction*, yang mengasumsikan bahwa objek gelap memiliki reflektansi mendekati nol, sehingga nilai reflektan pada setiap kanal dapat dikurangi berdasarkan reflektansi minimum. Proses koreksi ini dilaksanakan menggunakan plugin *Semi-Automatic Classification Plugin* (SCP) pada perangkat lunak QGIS (Congedo, 2021). Tahap selanjutnya adalah pemotongan citra berdasarkan batas administrasi Kabupaten Sumedang menggunakan data *shapefile* lokasi penelitian.

Pengambilan Sampel Kelas Penutupan/penggunaan lahan

Pengambilan sampel kelas dilakukan secara purposif dengan mempertimbangkan representasi karakteristik penutupan/penggunaan lahan pada citra Landsat 8. Berdasarkan kombinasi kanal 5-4-2, sebanyak 10 kelas penutupan/penggunaan lahan dapat diinterpretasi, yaitu hutan, lahan terbangun, perkebunan, ladang/tegalan, tanah terbuka, sawah fase generatif, sawah fase vegetatif, sawah fase bera, sungai, dan waduk. Proses identifikasi kelas dibantu oleh data pengamatan lapangan yang ditandai melalui aplikasi Avenza Maps, citra resolusi tinggi dari Google Earth Pro, serta interpretasi visual terhadap kombinasi kanal warna Landsat 8 untuk meningkatkan akurasi klasifikasi. Sebanyak 735 poligon sampel diambil dari citra Landsat, dengan 44 titik diamati langsung di lapangan dan sisanya melalui Google Earth Pro. Luas rata-rata tiap sampel dihitung untuk masing-masing kelas penutupan dan penggunaan lahan, sebagaimana disajikan pada 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	Perkebunan	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 kelas penutupan/penggunaan lahan dipisah dengan rasio 70% sebagai data latih dan 30% sebagai data validasi dengan fitur *random selection* pada QGIS.

Segmentasi Citra

Penelitian ini menggunakan dua pendekatan segmentasi berbasis objek, yaitu OMN dan RGO, dengan pengaturan parameter *scale*, *shape*, dan *compactness* yang disesuaikan untuk masing-masing pendekatan (Tabel 2). Parameter *scale* mengatur ukuran objek hasil segmentasi dengan menetapkan ambang heterogenitas warna. Parameter *shape* mengendalikan keseimbangan antara homogenitas spektral dan bentuk geometris objek, dan *compactness* menentukan prioritas antara kekompakan bentuk dan *smoothness* batas objek selama proses segmentasi. Variasi parameter tersebut digunakan untuk mengevaluasi pengaruhnya terhadap bentuk, ukuran, dan ketajaman batas objek hasil segmentasi. Nilai *scale* yang diuji mencakup 0.1; 0.125; 0.5; dan 0.75, yang merepresentasikan tingkat segmentasi dari sangat halus hingga cukup besar. Sementara, kombinasi parameter *shape* dan *compactness* terdiri atas tiga konfigurasi, yaitu pengaturan default eCognition (*shape* 0.1; *compactness* 0.4), *shape* 0.1; *compactness* 0.5, serta *shape* 0.7; dan *compactness* 0.2.

Tabel 2 Pengaturan segmentasi OBIA

Original Multiresolution	Region Grow on Object
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

Klasifikasi Citra

Setelah proses segmentasi, dilakukan tahapan klasifikasi citra untuk mengidentifikasi kelas penutupan/penggunaan lahan. Metode klasifikasi yang digunakan adalah algoritma RF, yang telah terbukti efektif dalam pengolahan data spasial dan pengenalan pola. Proses pelatihan model RF menggunakan 70% dari total sampel data, yang mencakup 10 kelas penutupan/penggunaan lahan di wilayah Kabupaten Sumedang. Pemilihan parameter RF dilakukan secara otomatis berdasarkan konfigurasi default yang tersedia dalam perangkat lunak eCognition Essentials (Tabel 3), guna memastikan konsistensi dan efisiensi dalam proses klasifikasi.

Evaluasi Akurasi Klasifikasi

Evaluasi akurasi dilakukan untuk menilai kesesuaian hasil klasifikasi terhadap data referensi, dengan menggunakan 30% sampel sebagai data validasi. Parameter yang digunakan meliputi *User's Accuracy*, *Producer's Accuracy*, dan *Overall Accuracy*, *Producer's Accuracy* (PA), dan *Overall Accuracy* (OA), yang masing-masing

merepresentasikan akurasi tematik, akurasi referensi, dan akurasi total klasifikasi (Lillesand dan Kiefer, 2015). Ketiga besaran ini merupakan indikator standar dalam evaluasi kualitas klasifikasi citra penginderaan jauh dan telah digunakan secara luas dalam studi geospasial (Congalton dan Green, 2009; Foody, 2002).

Tabel 3 Parameter RF pada klasifikasi OBIA

Parameter	Nilai Default
<i>Depth</i>	0
<i>Min sample count</i>	0
<i>Use surrogates</i>	No
<i>Max categories</i>	16
<i>Active variables</i>	0
<i>Max tree number</i>	50
<i>Forest accuracy</i>	0,01
<i>Termination criteria</i>	Both

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

Karakteristik Segmentasi

Parameter segmentasi citra seperti *scale*, *shape*, dan *compactness* memiliki pengaruh signifikan terhadap jumlah dan luasan objek yang terbentuk dalam pendekatan segmentasi berbasis objek, baik pada metode OMN maupun RGO.

Segmentasi dengan Pendekatan OMN

Hasil segmentasi yang ditampilkan pada Tabel 4 menunjukkan bahwa parameter *scale* memiliki pengaruh paling dominan terhadap jumlah dan luas objek dalam pendekatan OMN. Pada nilai *scale* rendah (0.125), jumlah objek sangat tinggi, yaitu 1,731,784, dengan luas minimum, maksimum, dan rata-rata yang seragam sebesar 0,090 ha atau setara dengan satu piksel citra Landsat 8. Segmentasi pada tingkat ini menghasilkan objek yang tidak mempertimbangkan homogenitas spektral antar piksel, sehingga jika digunakan dalam klasifikasi, hasilnya akan menyerupai pendekatan klasifikasi berbasis piksel yang cenderung mengabaikan konteks spasial dan hubungan antar piksel (Blaschke *et al.*, 2005; Johnson *et al.*, 2015). Oleh karena itu, pemilihan parameter segmentasi yang tepat menjadi krusial dalam menghasilkan objek yang representatif dan mendukung akurasi klasifikasi berbasis objek.

Tabel 4 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; shape dan compactness default	1,731,784	0.090	0.090	0.090
Scale 0.5; shape dan compactness default	212,296	0.090	6.309	0.735
Scale 0.75; shape dan compactness default	106,788	0.090	11.626	1.462
Scale 0.125; shape 0.1; compactness 0.5	1,731,784	0.090	0.090	0.090
Scale 0.5; shape 0.1; compactness 0.5	288,793	0.090	4.236	0.540
Scale 0.75; shape 0.1; compactness 0.5	126,576	0.090	9.463	1.233
Scale 0.125; shape 0.7; compactness 0.2	1,731,784	0.090	0.090	0.090
Scale 0.5; shape 0.7; compactness 0.2	488,742	0.090	1.082	0.319
Scale 0.75; shape 0.7; compactness 0.2	295,914	0.090	4.326	0.527

Pada nilai *scale* yang meningkat dari 0.125 ke 0.5 atau ke 0.75 pada *shape* dan *compactness* yang sama, jumlah objek segmentasi menurun yang diikuti dengan meningkatnya luas maksimum dan rata-rata objek. Pada *scale* 0.5 dengan *shape* dan *compactness* default, jumlah objek menurun menjadi 212,296 dari 1,731,784 dan luas rata-rata objek meningkat menjadi 0.735 dari 0.090 ha pada *scale* 0.125. Jumlah objek makin turun pada *scale* yang lebih tinggi (0.75) dari 212,296 menjadi 106,788 yang diikuti dengan peningkatan luas rata-rata luas dari 0.735 menjadi 1.462 ha. Fenomena yang sama juga terjadi pada kombinasi *shape* dan *compactness* lainnya, bahwa peningkatan nilai parameter *scale* akan menurunkan jumlah objek dan meningkatkan luas objek. Ini menunjukkan bahwa peningkatan *scale* mendorong penggabungan piksel menjadi objek yang lebih besar dan lebih homogen.

Parameter *shape* dan *compactness* berperan penting dalam pembentukan objek segmentasi, terutama pada nilai *scale* menengah hingga tinggi. Kombinasi *shape* 0.7 dan *compactness* 0.2 menghasilkan objek yang lebih banyak namun berukuran kecil dan terfragmentasi, sedangkan konfigurasi *shape* 0.1 dan *compactness* 0.5 menghasilkan objek yang lebih sedikit dengan luas rata-rata lebih besar. Sebagai contoh, pada *scale* 0.75, konfigurasi *shape* 0.7 dan *compactness* 0.2 menghasilkan 295,914 objek (rata-rata 0.527 ha), sedangkan kombinasi *shape* 0.1 dan *compactness* 0.5 menghasilkan 126,576 objek (rata-rata 1.233 ha). Perbedaan ini menunjukkan bahwa peningkatan nilai *shape* dan penurunan *compactness* cenderung meningkatkan kompleksitas dan fragmentasi objek, sejalan dengan temuan Grybas *et al.* (2017) mengenai pengaruh parameter bentuk dan kekompakan terhadap keseragaman spasial hasil segmentasi.

Segmentasi dengan Pendekatan RGO

Pendekatan RGO, sebagaimana ditampilkan pada Tabel 5, menunjukkan kecenderungan menghasilkan jumlah objek yang lebih sedikit dibandingkan metode OMN, bahkan pada nilai *scale* yang rendah. Pada *scale* 0.125 dengan parameter *shape* dan *compactness* default, jumlah objek yang terbentuk tercatat sebanyak 115,616 dengan rata-rata luas sebesar 1.530 hektar. Pola ini mengindikasikan bahwa RGO mampu mengelompokkan piksel secara lebih menyeluruh, sehingga menghasilkan objek yang lebih besar dan homogen meskipun pada skala rendah. Seiring peningkatan nilai *scale*, jumlah objek terus menurun hingga mencapai 75,290 pada *scale* 0.75, sementara rata-rata luas objek meningkat menjadi 2.073 hektar. Pola ini menunjukkan bahwa RGO cenderung menghasilkan segmentasi yang stabil dan konsisten

terhadap perubahan *scale*, dengan karakteristik spasial objek yang lebih seragam.

Parameter *shape* dan *compactness* berpengaruh terhadap hasil segmentasi, meskipun tidak sekuat pengaruh metode OMN. Pada *scale* 0.75, kombinasi *shape* 0.1 dan *compactness* 0.5 menghasilkan 83,114 objek dengan rata-rata luas 1.878 hektar, sedangkan kombinasi *shape* 0.7 dan *compactness* 0.2 menghasilkan 102,002 objek dengan rata-rata luas 1.530 hektar. Konfigurasi pertama menghasilkan objek dengan ukuran yang lebih besar, sedangkan konfigurasi kedua menghasilkan objek yang lebih banyak dan lebih kecil. Perbedaan ini mengindikasikan bahwa pendekatan RGO mampu menghasilkan segmentasi yang lebih konsisten dalam hal ukuran dan bentuk objek, serta menunjukkan kestabilan yang lebih tinggi terhadap variasi parameter segmentasi.


Perbandingan OMN dan RGO

Perbandingan antara pendekatan OMN dan RGO menunjukkan perbedaan mendasar dalam sensitivitas terhadap parameter segmentasi. OMN cenderung sangat responsif terhadap perubahan nilai *scale*, di mana *scale* rendah menghasilkan segmentasi piksel tunggal (Gambar 2a) yang kurang optimal untuk klasifikasi berbasis objek karena tidak mempertimbangkan homogenitas spektral dan spasial. Sebaliknya, pada *scale* tinggi, OMN menghasilkan objek yang lebih besar dan homogen, namun jumlahnya jauh lebih sedikit. Sementara, RGO menunjukkan karakter segmentasi yang lebih stabil dan konservatif, dengan jumlah objek yang lebih sedikit dan ukuran yang lebih besar bahkan pada *scale* rendah, mencerminkan efektivitas pendekatan ini dalam mengelompokkan piksel berdasarkan kemiripan lokal.


Parameter *shape* dan *compactness* berfungsi sebagai pengatur bentuk dan kekompakan objek, di mana pada OMN perubahan nilai keduanya dapat memicu fragmentasi objek yang signifikan, terutama pada *scale* menengah (Gambar 3a dan Gambar 4a). Sebaliknya, pada RGO, pengaruh parameter tersebut bersifat lebih halus dan tidak menyebabkan fluktuasi ekstrem dalam jumlah maupun ukuran objek (Gambar 3b dan Gambar 4b). Berdasarkan karakteristik spasial yang dihasilkan, OMN cenderung menghasilkan segmen yang seragam dan geometris, sedangkan RGO menghasilkan segmen yang lebih adaptif terhadap kontur alami objek di permukaan lahan. Oleh karena itu, pendekatan RGO dapat dianggap sebagai alternatif yang lebih stabil dan representatif untuk segmentasi citra dalam konteks klasifikasi berbasis objek, terutama ketika konsistensi spasial dan efisiensi penggabungan piksel menjadi prioritas.

Tabel 5 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; shape dan compactness default	115,616	0.090	12.888	1.350
Scale 0.5; shape dan compactness default	99,096	0.090	14.961	1.575
Scale 0.75; shape dan compactness default	75,290	0.090	16.403	2.073
Scale 0.125; shape 0.1; compactness 0.5	115,099	0.090	12.888	1.356
Scale 0.5; shape 0.1; compactness 0.5	101,971	0.090	14.961	1.531
Scale 0.75; shape 0.1; compactness 0.5	83,114	0.090	16.403	1.878
Scale 0.125; shape 0.7; compactness 0.2	114,190	0.090	12.618	1.367
Scale 0.5; shape 0.7; compactness 0.2	109,510	0.090	12.798	1.425
Scale 0.75; shape 0.7; compactness 0.2	102,002	0.090	14.961	1.530



Gambar 2 Potongan citra segmentasi dengan shape dan compactness default: (a) OMN dan (b) RGO



Gambar 3 Potongan citra segmentasi dengan shape 0,1 dan compactness 0,5: (a) OMN dan (b) RGO

Gambar 4 Potongan citra segmentasi dengan *shape* 0,5 dan *compactness* 0,2: (a) OMN dan (b) RGO

Akurasi Klasifikasi

Klasifikasi dilakukan berdasarkan segmentasi citra menggunakan pendekatan OMN dan RGO. Parameter segmentasi yang digunakan meliputi nilai *scale* 0.5 dan 0.75 dengan *shape* dan *compactness default*, serta kombinasi *scale* 0.75; *shape* 0.1 dan *compactness* 0.5. Nilai *scale* 0.5 dan 0.75 dipilih karena menghasilkan segmentasi yang optimal dengan objek homogen, sedangkan kombinasi parameter *scale* 0.75; *shape* 0.1 dan *compactness* 0.5 digunakan untuk menganalisis dampak variasi bentuk dan kekompakan terhadap akurasi klasifikasi. Akurasi klasifikasi menggunakan citra segmentasi OMN dan RGO masing-masing disajikan pada Tabel 6.


Tabel 6. Akurasi keseluruhan klasifikasi Citra Segmentasi OMN dan RGO

Parameter Segmentasi	<i>Original Multiresolution</i>	<i>Region Grow on Object</i>
<i>scale</i> : 0.5 <i>shape</i> : <i>default</i> <i>compactness</i> : <i>default</i>	83.8	85.0
<i>scale</i> : 0.75 <i>shape</i> : <i>default</i> <i>compactness</i> : <i>default</i>	77.8	80.9
<i>scale</i> : 0.5 <i>shape</i> : 0.1 <i>compactness</i> : 0.5	81.6	80.6

Akurasi keseluruhan klasifikasi pada segmentasi OMN berada dalam rentang 77.8%–83.8%, sedangkan pada segmentasi RGO berkisar antara 80.6%–85.0% (Tabel 10). Akurasi tertinggi pada kedua pendekatan diperoleh dari citra hasil segmentasi dengan konfigurasi *scale* 0.5 serta *shape* dan *compactness default*. Tabel 6 menunjukkan bahwa

variasi akurasi OA dipengaruhi oleh parameter *scale*, serta *shape* dan *compactness* yang digunakan. Konfigurasi *scale* 0.5 dengan *shape* dan *compactness default* menghasilkan akurasi lebih tinggi dibandingkan konfigurasi lainnya, sehingga dapat dianggap sebagai parameter optimal dalam pembentukan objek homogen pada segmentasi OMN maupun RGO.

Segmentasi RGO secara konsisten menghasilkan akurasi klasifikasi yang lebih tinggi, dengan rata-rata 82.17%, dibandingkan OMN, dengan rata-rata 81.07%, pada seluruh konfigurasi parameter. Hal ini menegaskan bahwa RGO memiliki kinerja yang lebih stabil. Visualisasi hasil klasifikasi (Gambar 5) memperlihatkan distribusi spasial penutupan/penggunaan lahan secara jelas. Secara visual, pendekatan segmentasi RGO menghasilkan objek klasifikasi yang lebih detail dan homogen, sedangkan OMN menghasilkan objek klasifikasi yang lebih besar dan tergeneralisasi untuk semua kelas. Berdasarkan klasifikasi berbasis objek dengan segmentasi RGO pada parameter *scale* 0.5, luas masing-masing kelas penutupan/penggunaan lahan tercatat sebagai berikut: hutan 16,600 ha, lahan terbangun 11,284 ha, perkebunan 50,393 ha, ladang/tegalan 14,269 ha, tanah terbuka 29,658 ha, sawah 27,092 ha, dan badan air 6,785 ha. Dari hasil tersebut, kategori perkebunan, tanah terbuka, dan sawah merupakan tiga kelas dominan di lokasi penelitian. Jika dibandingkan dengan data BPS tahun 2024, luas sawah menunjukkan kedekatan dengan luas sebesar 30,038 ha, sedangkan kategori lainnya cenderung memiliki luas yang lebih rendah. Perbedaan ini diperkirakan berasal dari perbedaan metodologi dalam proses pengumpulan dan interpretasi data antara pendekatan klasifikasi berbasis objek dan metode statistik.



Gambar 5 Hasil klasifikasi dengan parameter *scale* 0.5 serta parameter *shape* dan *compactness default*: OMN (kiri) dan RGO (kanan)

SIMPULAN

Parameter segmentasi seperti *scale*, *shape*, dan *compactness* memiliki pengaruh signifikan terhadap karakteristik spasial objek yang terbentuk. Pendekatan OMN menunjukkan sensitivitas tinggi terhadap perubahan parameter, menghasilkan objek yang lebih detail dan homogen namun cenderung terfragmentasi, terutama pada nilai *scale* rendah. Sebaliknya, RGO menghasilkan objek yang lebih besar dan tergeneralisasi, dengan kestabilan segmentasi yang lebih tinggi terhadap variasi parameter. Karakter ini berkontribusi pada akurasi klasifikasi yang lebih konsisten pada RGO dibandingkan OMN.

Hasil klasifikasi berbasis objek menunjukkan bahwa segmentasi RGO dengan parameter *scale* 0.5 mampu menghasilkan distribusi spasial penutupan/penggunaan lahan yang representatif, dengan tiga kelas dominan yaitu perkebunan, tanah terbuka, dan sawah. Luas sawah yang dihasilkan (27,092 ha) menunjukkan kedekatan dengan data BPS tahun 2024 (30,038 ha), sedangkan kelas lainnya cenderung memiliki nilai yang lebih rendah. Hal ini mengindikasikan bahwa segmentasi RGO tidak hanya stabil secara spasial, tetapi juga mampu mendekati estimasi statistik aktual, menjadikannya pendekatan yang lebih andal untuk klasifikasi berbasis objek dalam konteks pemetaan penggunaan lahan.

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

Akçay, O., E.O. Avsar, M. Inalpulat, L. Genc and A. Cam. 2018. Assessment of Segmentation Parameters for

Object-Based Land Cover Classification Using Color-Infrared Imagery. *ISPRS International Journal of Geo-Information*, 7(11): 424. <https://doi.org/10.3390/ijgi7110424>

Ardiansyah, M., K. Munibah dan S.N. Saniinah. 2023. Klasifikasi fase tumbuh padi dengan pendekatan berbasis objek menggunakan citra sentinel- 2. *J. Il. Tan. dan Ling.*, 25(2): 78 – 85. doi: <http://dx.doi.org/10.29244/jitl.25.2.78-85>

Attri, P., S. Chaudhry and S. Sharma. 2015. Remote sensing and GIS based approaches for LULC change detection – a review. *Int. J. Curr. Eng. and Tech.*, 5(5): 3126 – 3137.

Belgiu, M. and L. Drăguț. 2016. Random Forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*. 114: 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>

Blaschke, T., C. Burnett and A. Pekkarinen. 2005. Image Segmentation Methods for Object-based Analysis and Classification. In *Remote Sensing Image Analysis: Including the Spatial Domain*.

Blaschke, T., G.J. Hay, M. Kelly, S. Lang, P. Hofmann, E. Addink and D. Tiede. 2014. Geographic object-based image analysis – Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87: 180–191.

Blaschke, T. 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1): 2–16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>

[BPS]. 2024. Provinsi Jawa Barat dalam Angka 2024. Jawab Barat (ID): Badan Pusat Statistik

Candra, I.D., V.P. Siregar dan S.B. Agus. 2017. Pemetaan zona geomorfologi dan habitat bentik di Pulau Kotok

- Besar menggunakan klasifikasi berbasis objek. *J. Tekno. Perikan. dan Kelaut.*, 8(2): 209-219. doi:10.24319/jtpk.8.209-219.
- Congalton, R.G. and K. Green. 2009. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. 2nd ed. CRC Press.
- Congedo, L. 2021. *Semi-Automatic Classification Plugin Documentation Release 7.9.7.1*.
- Drăguț, L. and C. Eisank. 2012. Automated object-based classification of topography from SRTM data. *Geomorphology*, 141-142: 21-33.
- Engnila, H.M., S.K. Putri dan N. Arifian. 2022. Monitoring perubahan tutupan lahan dengan metode OBIA pada citra sentinel – 2A tahun 2017 – 2021 (studi kasus: Kecamatan Sungai Rumbai, Kabupaten Dharmasraya). *JAGAT*, 6(1): 264 – 270
- Fajarendra, Y.I., Y.R. Fauzan dan S. Uyun. 2024. Klasifikasi citra eurosat menggunakan algoritma k-nn, decision tree, dan random forest. *JATI*, 8(4): 7754 – 7761.
- Foody, G.M. 2002. Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1): 185-201.
- GIS Geography. 2023. Pixel-based vs object-based classification in remote sensing. Diakses dari: <https://gisgeography.com/pixel-vs-object-based-classification/>
- Grybas, H., L. Melendy and R.G. Congalton. 2017. A comparison of unsupervised segmentation parameter optimization approaches. *GIScience & Remote Sensing*, 54(4): 515-533.
- Hossain, M.D. and D. Chen. 2019. Segmentation for object-based image analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150: 115-134. <https://doi.org/10.1016/j.isprsjprs.2019.02.009>
- Johnson, B.A., M. Bragais, I. Endo and D.B. Macandog. 2015. Image Segmentation Parameter Optimization Considering Within- and Between-Segment Heterogeneity. *ISPRS Int. J. Geo-Inf.*, 4(4): 2292-2305
- Koman, W.A.F., A.S. Izza and D. Candraningtyas. 2022. Perbandingan Parameter Segmentasi OBIA dalam Klasifikasi Tutupan Lahan. *Jurnal Paradigma: Jurnal Multidisipliner Mahasiswa Pascasarjana Indonesia*, 3(2): 104-13
- Li, Q., C. Wang, B. Zhang and L. Lu. 2015. Object-based crop classification with Landsat-MODIS enhanced time-series data. *Remote Sens.*, 7(12): 16091 – 16107
- Lillesand, T.M. and R.W. Kiefer. 2015. *Remote Sensing and Image Interpretation*. 7th ed. Wiley.
- Marlina, D. 2022. Klasifikasi tutupan lahan pada citra Sentinel-2 Kabupaten Kuningan dengan NDVI dan algoritma random forest. *STRING*, 7(1): 41 - 49
- Marwati, A., Y. Prasetyo dan A. Suprayogi. 2018. Analisis perbandingan klasifikasi tutupan lahan kombinasi data point cloud lidar dan foto udara berbasis metode segmentasi dan supervised (studi kasus: Tanggamus Lampung). *J. Geod. Undip.*, 7(1): 36 – 45
- Oka, W.B. and Pradono. 2011. Risk threats in a creative funding scheme for infrastructure project in Indonesia : Cileunyi-Sumedang-Dawuan toll road project case. *Journal of Civil Engineering and Architecture*, 5(1) : 89 – 96.
- Purboyo, A.A., A. Kurniawan dan L. Muta'ali. 2024. Analisis spasial temporal perubahan tutupan lahan di Kawasan Perkotaan Cekungan Bandung berbasis Google Earth Engine. *J. Pendidik. Geogr. Undiksha.*, 12(2):251-260. doi: <https://doi.org/10.23887/jjpg.v12i02.75526>
- Sampurno, R.M. dan A. Thoriq. 2016. Klasifikasi tutupan lahan menggunakan citra landsat 8 Operational Land Imager (OLI) di Kabupaten Sumedang. *J. Teknotan.*, 10(2): 61 – 70. doi: <https://doi.org/10.24198/jt.vol10n2.9>
- Sugiarti, A.L. 2017. The relationship of the Jatigede Dam construction towards socio-economic conditions on farming community in the district of Jatigede-Sumedang. *International Research Journal of Education and Sciences*, 1(2) : 15 – 20.
- Timisela, W.A., G. Mardiatmoko dan G. Puturuhi. 2020. Analisis jenis mangrove menggunakan citra UAV dengan Klasifikasi OBIA. *J. Hutan-Hutan Kecil*, 4(2): 132-149.
- Wang, M., J. Wang, Y. Cui, J. Liu and L. Chen. 2022. Agricultural field boundary delineation with satellite image segmentation for high-resolution cropmapping: a case study of rice paddy. *Agronomy*, 12. doi: <https://doi.org/10.3390/agronomy12102342>
- Weih, R.C. and N.D. Riggan. 2009. A comparison of pixel-based and object-based classification methods for land cover mapping. *GIScience & Remote Sensing*, 46(4): 387-399.
- Zhang, C., Y. Liu and N. Tie. 2023. Forest land resource information acquisition with Sentinel-2 image utilizing support vector machine, k-nearest neighbor, random forest, decision trees and multi-layer perceptron. *Forests*, 14(2): 254. doi: <https://doi.org/10.3390/f14020254>