



## Ekstraksi Permukiman dari Kombinasi Citra Sentinel-2 dan Sentinel-1 dengan Pendekatan *Object-Based Image Analysis*

(*Settlement Extraction from Combination of Sentinel-2 and Sentinel-1 Images with Object-Based Image Analysis Approach*)

Dias Eramudadi<sup>1</sup>, Catur Aries Rokhmana<sup>2</sup>

<sup>1</sup> Magister Teknik Geomatika, Departemen Teknik Geodesi, Fakultas Teknik, Universitas Gadjah Mada, Yogyakarta, Indonesia

<sup>2</sup> Departemen Teknik Geodesi, Fakultas Teknik, Universitas Gadjah Mada, Yogyakarta, Indonesia

**Penulis Korespondensi:** Dias Eramudadi | **Email:** diaseramudadi@gmail.com

Diterima (*Received*): 04/12/2023 Direvisi (*Revised*): 22/07/2024 Diterima untuk Publikasi (*Accepted*): 01/08/2024

### ABSTRAK

Informasi yang akurat dan termutakhir mengenai data spasial permukiman skala menengah dibutuhkan berbagai bidang seperti agenda pembangunan berkelanjutan, perubahan iklim dan pengurangan risiko bencana. Namun, ekstraksi informasi spasial untuk permukiman selalu menjadi tantangan karena heterogenitas spasial permukiman yang kompleks. Penelitian ini bertujuan mengekstraksi permukiman dari kombinasi citra Sentinel-2 dan Sentinel-1 menggunakan metode *Object-Based Image Analysis* (OBIA) dengan platform *Google Earth Engine* (GEE). Dataset ekstraksi permukiman dibentuk dari 33 fitur kombinasi saluran spektral, indeks spektral dan tekstur. Sementara itu, dataset segmentasi terdiri dari kombinasi indeks spektral UI-NDVI-MNDWI hasil perhitungan *Optimum Index Factor* (OIF). Segmentasi diproses menggunakan *Simple Non-Iterative Clustering* (SNIC) dan diklasifikasi dengan algoritma *Random Forest* (RF). Secara visual, hasil ekstraksi permukiman menunjukkan pola distribusi yang konsisten dengan permukiman peta Rupabumi Indonesia (RBI) skala 1:25000, tetapi memiliki karakter geometri yang berbeda. Oleh karena itu, hasil ekstraksi permukiman belum dapat digunakan secara langsung sebagai data masukan pembuatan peta RBI skala menengah, tetapi dapat dimanfaatkan sebagai panduan digitasi dan mendukung kontrol kualitas. Selain itu, nilai penting fitur dalam klasifikasi RF juga dianalisis dengan hasil fitur polarisasi VV memiliki kontribusi paling tinggi. Uji akurasi menghasilkan nilai *overall accuracy* dan *F-score* sebesar 92%. Hasil ini menunjukkan bahwa model klasifikasi dan metode OBIA di GEE mampu menghasilkan data ekstraksi permukiman dengan akurasi yang tinggi di wilayah dengan landskap yang beragam.

**Kata Kunci:** Ekstraksi Permukiman, OBIA, Sentinel-2, Sentinel-1, GEE

### ABSTRACT

*Accurate and up-to-date information on the spatial data of medium-scale settlements is needed in various sectors, such as sustainable development agendas, climate change, and disaster risk reduction. However, the extraction of spatial information for settlements has always been a challenge due to the complex spatial heterogeneity of settlements. This research aims to extract settlements from a combination of Sentinel-2 and Sentinel-1 images using the Object-Based Image Analysis (OBIA) method with the Google Earth Engine (GEE) platform. The settlement extraction dataset is formed from 33 features combining spectral bands, spectral indices, and textures. Meanwhile, the segmentation dataset consists of a combination of UI-NDVI-MNDWI spectral indices resulting from the Optimum Index Factor (OIF) calculation. Segmentation was processed using Simple Non-Iterative Clustering (SNIC) and classified with the Random Forest (RF) algorithm. Visually, the settlement extraction results show a distribution pattern that is consistent with the settlements on the 1:25000 scale Indonesian Rupabumi (RBI) map but has different geometric characteristics. Therefore, the results of settlement extraction cannot be used directly as input data for producing medium-scale RBI maps but can be utilized as a guide for digitizing and supporting quality control. In addition, the importance of features in RF classification is also analyzed, with the result that the VV polarization feature has the highest contribution. The accuracy test resulted in an overall accuracy and F-score value of 92%. These results show that the classification model and OBIA method in GEE can produce settlement extraction data with high accuracy in areas with diverse landscapes.*

**Keywords:** Settlement Extraction, OBIA, Sentinel-2, Sentinel-1, GEE

## 1. Pendahuluan

Studi penggunaan lahan dan perubahan penggunaan lahan membutuhkan pemahaman tentang ukuran, distribusi, dan perubahan wilayah permukiman (Wang dkk., 2010). Merujuk dokumen indikator *Sustainable Development Goals (SDGs)* Indonesia, sebagian pengukuran untuk mencapai tujuan pilar ekonomi dan lingkungan yang telah ditetapkan, membutuhkan data spasial yang terkait dengan lahan terbangun dan permukiman (Rudiastuti dkk., 2021). Bidang lain seperti perencanaan pembangunan, perubahan iklim dan pengurangan risiko bencana juga memerlukan data spasial permukiman yang termutakhir, konsisten dan akurat untuk melaksanakan kebijakan, pemantauan, dan evaluasi (Corbane dkk., 2018).

Permukiman merupakan jenis penggunaan lahan yang memiliki karakteristik unik, kompleks, dan perkembangannya sangat dinamis. Tidak hanya mencakup rumah saja, permukiman umumnya juga bercampur dengan objek ruang terbuka, badan air, dan vegetasi diantara rumah (Rudiastuti dkk., 2021). Kondisi ini menjadi tantangan untuk mengelompokkan multiobjek tersebut menjadi satu kelas permukiman. Teknologi penginderaan jauh memiliki potensi mengatasi tantangan tersebut.

Penggunaan teknologi citra satelit penginderaan jauh resolusi menengah seperti citra Sentinel sudah banyak digunakan untuk klasifikasi penutup lahan/ penggunaan lahan seperti permukiman. Resolusi spasial yang tinggi 10m, akses publik dan non berbayar serta kemampuan multisensor menjadi keunggulan citra Sentinel. Permukiman dapat diekstraksi hanya dengan menggunakan citra optis multispektral Sentinel-2 seperti penelitian Matarira dkk. (2022). Namun demikian, kombinasi dengan citra *Synthetic Aperture Radar (SAR)* Sentinel-1 dengan mengeksplorasi saluran spektral, indeks spektral dan fitur tekstur dari kedua jenis citra mampu menghasilkan akurasi yang tinggi mencapai lebih dari 90% (Ji dkk., 2020; Matarira dkk., 2023; Rudiastuti dkk., 2022)

Metode interpretasi visual (manual) dapat memberikan hasil terbaik ketika kenampakan batas objek di citra terlihat jelas dan tegas sehingga mudah dideliniasi (Juniati, 2018; Santosa, 2016). Namun, metode ini memiliki keterbatasan karena sangat dipengaruhi keterampilan, pengetahuan, dan pengalaman interpreter dalam mengenali objek citra, serta membutuhkan banyak operator dan waktu pengerjaan yang lama. Selain secara visual, metode ekstraksi citra juga dapat dilakukan secara digital (otomatis) menggunakan *Machine Learning (ML)*, yang umumnya dibedakan menjadi dua yaitu berbasis piksel (*pixel-based*) dan berbasis objek (*object-based*).

Metode ML berbasis objek yang populer dengan nama *Object Based Image Analysis (OBIA)* mampu mengekstraksi objek dengan mempertimbangkan nilai spektral serta karakteristik spasial seperti bentuk dan tekstur (Blaschke dkk., 2014; Devi & Santosa, 2022). Metode OBIA dinilai memiliki ketelitian yang lebih baik dibanding metode ML berbasis piksel (Vizzari, 2022). Selain itu, ekstraksi citra

dengan pendekatan OBIA terbukti dapat mengurangi efek *salt and pepper* yang menjadi kekurangan metode ekstraksi citra berbasis piksel (Kete dkk., 2019).

Kualitas segmentasi sangat mempengaruhi akurasi hasil ekstraksi citra dengan OBIA. Segmentasi merupakan langkah membentuk objek atau membagi citra menjadi segmen-segmen dengan mengelompokkan piksel yang memiliki karakteristik spektral homogen (Blaschke dkk., 2014). *Simple Non-Iterative Clustering (SNIC)*, salah satu algoritma segmentasi superpiksel penyempurnaan *Simple Linear Iterative Clustering (SLIC)*, dianggap memiliki keunggulan dalam kecepatan dan penggunaan memori yang efisien dalam pemrosesan data (Achanta & Süsstrunk, 2017). Penelitian Csillik (2017) menyebutkan ekstraksi citra berbasis superpiksel memiliki kinerja serupa atau bahkan lebih baik daripada ekstraksi citra berbasis segmentasi multiresolusi.

Penggunaan platform *cloud computing* untuk pengolahan citra satelit dan data geospasial semakin berkembang. *Google Earth Engine (GEE)* adalah platform berbasis *cloud* yang memiliki kemampuan pemrosesan data geospasial secara paralel otomatis dan komputasi cepat untuk mengatasi tantangan *big data* (Amani dkk., 2020). GEE sudah banyak digunakan untuk aplikasi yang luas seperti klasifikasi penutup lahan/ penggunaan lahan, hidrologi, perencanaan perkotaan, bencana alam, analisis iklim dan pemrosesan citra digital lainnya. Berkaitan dengan ekstraksi citra, algoritma ML yang lebih banyak digunakan di GEE adalah *Random Forest (RF)* (Amani dkk., 2020). Algoritma RF dikenal bersifat non parametrik dan memiliki keunggulan dalam kemampuan mengelola data berdimensi tinggi dan *overfitting* serta berkinerja baik dibandingkan algoritma ML lainnya (Vizzari, 2022).

Penelitian ini bertujuan untuk mengekstraksi permukiman dari kombinasi citra Sentinel-2 dan Sentinel-1 dengan pendekatan OBIA. Fitur saluran spektral, indeks spektral dan tekstur dieksplorasi dari citra Sentinel-2 dan Sentinel-1. Citra disegmentasi menggunakan SNIC dan diklasifikasi dengan algoritma RF di GEE. Akurasi diukur dengan membandingkan hasil ekstraksi permukiman OBIA dengan interpretasi manual menggunakan *confusion matrix* (matrik konfusi). Selain itu, hasil ekstraksi permukiman OBIA juga dibandingkan secara visual dengan peta Rupabumi Indonesia (RBI) skala 1:25000 berdasarkan distribusi dan geometrinya. Hasil penelitian diharapkan dapat memberikan alternatif metode ekstraksi permukiman secara otomatis yang cepat, efisien dan akurat pada peta skala menengah.

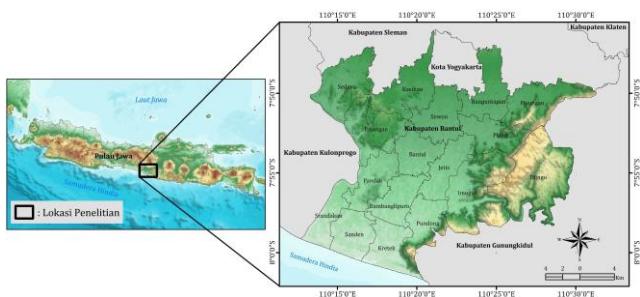
## 2. Data dan Metodologi

### 2.1. Data dan Lokasi

- Data yang digunakan dalam penelitian ini meliputi:
1. Citra Sentinel-2 *MultiSpectral Instrument (MSI)* level 2A perekaman 28 Mei 2022 wilayah Kabupaten Bantul, Provinsi Daerah Istimewa Yogyakarta (DIY), diperoleh secara *online* dari katalog data GEE

- Citra Sentinel-1 SAR dual polarisasi VV+VH level *Ground Range Detected* (GRD) perekaman 5 Mei 2022 (*ascending*) dan 1 Mei 2022 (*descending*) wilayah Kabupaten Bantul, DIY, diperoleh secara *online* dari katalog data GEE.
- Citra satelit resolusi tinggi *basemap* GEE tahun 2023.
- Peta RBI skala 1:25000 pemutakhiran tahun 2022 wilayah Kabupaten Bantul, DIY, diperoleh dari Badan Informasi Geospasial (BIG).

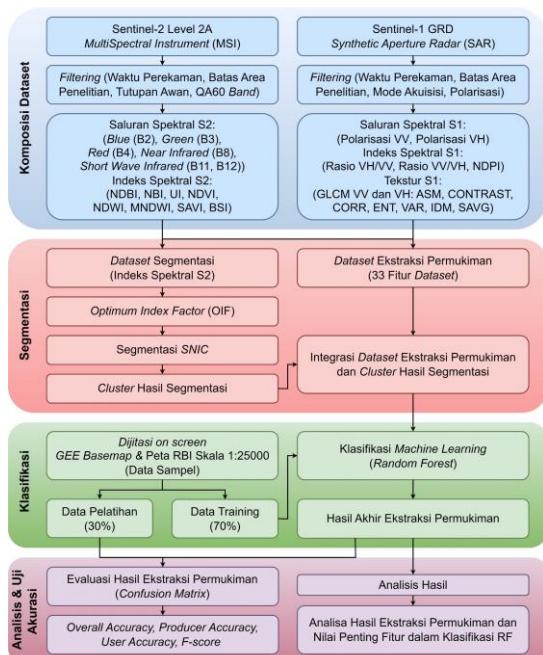
Penelitian ini dilakukan di Kabupaten Bantul, DIY (Gambar 1). Lokasi dipilih karena karakteristik fisik permukiman di wilayah ini cukup merepresentasikan keragaman permukiman di daerah perkotaan dan rural. Selain itu, lokasi penelitian memiliki landskap yang beragam yaitu dataran di bagian utara dan tengah, perbukitan di bagian timur dan barat serta wilayah pantai di bagian selatan.



Gambar 1 Lokasi penelitian

## 2.2. Metodologi

Diagram alir penelitian ini ditunjukkan Gambar 2:



Gambar 2 Diagram alir penelitian

### 2.2.1. Komposisi Dataset

Pembuatan komposisi *dataset* merupakan langkah penting dalam proses klasifikasi penutup lahan/ penggunaan lahan. Komposisi *dataset* penelitian ini dibentuk dari kombinasi saluran spektral, indeks spektral dan fitur tekstur citra Sentinel-2 dan Sentinel-1. Citra Sentinel-2 MSI level 2A diakses secara *online* dari katalog data GEE menggunakan fungsi *ee.ImageCollection* dengan koleksi *dataset COPERNICUS/S2\_SR\_HARMONIZED*. Citra ini sudah diortorektifikasi dan dikoreksi atmosfer sehingga sudah bernilai reflektan (ESA, 2015). Proses *filtering* citra Sentinel-2 meliputi waktu perekaman citra, batas area penelitian, serta persentase dan koreksi tutupan awan. Citra diseleksi dengan persentase tutupan awan kurang dari 10%. *Band QA60* yang memiliki informasi awan *opaque* dan *cirrus* digunakan untuk koreksi tutupan awan.

Citra Sentinel-1 SAR level GRD diperoleh dari koleksi *dataset COPERNICUS/S1\_GRD* yang diakses secara *online* seperti citra Sentinel-2. Citra ini telah diproses dengan Sentinel-1 Toolbox berupa *thermal noise removal*, *radiometric calibration*, dan *terrain correction* (Ji dkk., 2020). Proses *filtering* citra Sentinel-1 menggunakan parameter waktu perekaman citra, batas area penelitian, mode akuisisi dan jenis polarisasi. Periode waktu perekaman citra Sentinel-1 dipilih berdekatan dengan Sentinel-2 untuk meminimalisir perbedaan tutupan lahan di kedua citra tersebut. Mode akuisisi *Interferometric Wide* (IW) dengan polarisasi ganda VV dan VH dipilih berdasarkan ketersediaan data wilayah Indonesia di GEE.

Memodifikasi penelitian Vizzari (2022), enam saluran spektral citra Sentinel-2 digunakan yaitu *blue* (B2), *green* (B3) dan *red* (B4) yang merupakan saluran tampak/ *visible*, B8 saluran inframerah dekat/ *near infrared* (NIR) serta B11 dan B12 saluran inframerah gelombang pendek/ *short wave infrared* (SWIR). Selain saluran spektral, delapan indeks spektral ditambahkan ke *dataset* dari perhitungan kombinasi saluran spektral citra Sentinel-2. Penambahan indeks spektral dapat memperkaya informasi spektral sehingga membantu meningkatkan hasil klasifikasi (Tassi dkk., 2021).

Indeks spektral Sentinel-2 terdiri dari kombinasi indeks lahan terbangun, indeks vegetasi, indeks air dan indeks tanah. Indeks lahan terbangun yang diterapkan meliputi *Normalized Difference Built-Up Index* (NDBI), *New Built-Up Index* (NBI), dan *Urban Index* (UI). NDBI dan UI efektif untuk pemetaan cepat lahan terbangun atau lahan kosong (Firozjaei dkk., 2019). Ji dkk. (2020) dalam penelitiannya menyatakan NDBI dan NDI efektif untuk pemetaan lahan terbangun. *Normalized Difference Vegetation Index* (NDVI) merupakan indeks vegetasi yang teruji banyak digunakan untuk pemetaan perubahan penutup lahan dan dapat secara signifikan meningkatkan akurasi ketika digunakan untuk klasifikasi penutup lahan/ penggunaan lahan (Vizzari, 2022). Penelitian Wang dkk. (2010) menyebutkan NDVI dapat meningkatkan kontras antara vegetasi dan lahan terbangun. *Normalized Difference Water Index* (NDWI) yang dipelopori Gao (1996) dan *Modified Normalized*

*Difference Water Index* (MNDWI) yang dikenalkan Xu (2006) merupakan indeks untuk mendeteksi badan air dan membedakan dengan lahan terbangun. *Soil-Adjusted Vegetation Index* (SAVI) yang dikembangkan Huete (1988) merupakan varian indeks vegetasi mampu mengurangi kesalahan dari variasi warna tanah sehingga dapat membedakan tanah dan vegetasi yang dinamis. *Bare Soil Index* (BSI) merupakan indeks kombinasi NDVI dan NDBI yang efektif membedakan lahan terbuka dengan tutupan lahan lainnya (Vizzari, 2022). Perhitungan indeks spektral di GEE memanfaatkan fungsi *normalized Difference* untuk perhitungan indeks yang sederhana dan *expression* ketika perhitungan indeksnya lebih kompleks. Persamaan indeks spektral pada citra Sentinel-2 dapat dilihat sebagai berikut:

$$\text{NDBI} = \frac{\text{B11} - \text{B8}}{\text{B11} + \text{B8}} \quad (1)$$

$$\text{NBI} = \frac{\text{B4} \times \text{B11}}{\text{B8}} \quad (2)$$

$$\text{UI} = \frac{\text{B12} - \text{B8}}{\text{B12} + \text{B8}} \quad (3)$$

$$\text{NDVI} = \frac{\text{B8} - \text{B4}}{\text{B8} + \text{B4}} \quad (4)$$

$$\text{NDWI} = \frac{\text{B3} - \text{B8}}{\text{B3} + \text{B8}} \quad (5)$$

$$\text{MNDWI} = \frac{\text{B3} - \text{B11}}{\text{B3} + \text{B11}} \quad (6)$$

$$\text{SAVI} = 1,5 \times \left[ \frac{(\text{B3} - \text{B11})}{(\text{B3} + \text{B11} + 0,5)} \right] \quad (7)$$

$$\text{BSI} = \frac{((\text{B11} + \text{B4}) - (\text{B8} + \text{B2}))}{((\text{B11} + \text{B4}) + (\text{B8} + \text{B2}))} \quad (8)$$

Kombinasi fitur dari citra Sentinel-1 menggunakan dua mode polarisasi VV dan VH *ascending* dan *descending*. Kombinasi *ascending* dan *descending* dapat mereduksi efek *layover*, *foreshortening* dan *shadow* sehingga dapat meningkatkan akurasi klasifikasi (Cheng dkk., 2021). Disamping itu, penggabungan informasi dari kedua orientasi tersebut dapat memberikan pandangan yang lebih komprehensif terutama di wilayah dengan topografi atau struktur yang kompleks. Memodifikasi penelitian Vizzari (2022), penggunaan rasio polarisasi ganda VH/VH dan VV/VH dapat mengkompensasi sebagian ketidakstabilan radiometrik sensor dan menunjukkan stabilitas yang tinggi daripada polarisasi tunggal (Vergni dkk., 2021). Selain rasio, indeks spektral *Normalized Difference Polarization Index* (NDPI) digunakan sebagai tambahan informasi karena dapat meningkatkan akurasi klasifikasi penutup lahan jika dibandingkan dengan menggunakan hanya data SAR polarisasi ganda (Kushardono, 2012). Perhitungan indeks spektral pada citra Sentinel-1 dapat dilihat pada persamaan berikut:

$$\text{Rasio VV/VH} = \frac{\text{VV}}{\text{VH}} \quad (9)$$

$$\text{Rasio VH/VV} = \frac{\text{VH}}{\text{VV}} \quad (10)$$

$$\text{NDPI} = \frac{\text{VH} - \text{VV}}{\text{VH} + \text{VV}} \quad (11)$$

Informasi tentang tekstur diperoleh melalui *Grey Level Co-occurrence Matrix* (GLCM) yang diusulkan Haralick dkk. (1973). GLCM menggambarkan distribusi nilai yang muncul bersama dari sebuah citra di area tertentu sehingga membantu dalam pemahaman pola dan karakteristik permukaan, termasuk identifikasi tekstur yang berbeda seperti halus, kasar, atau kompleks. Merujuk (Matarira dkk., 2022; Vizzari, 2022), 7 indikator GLCM yang digunakan yaitu *Angular Second Moment* (ASM), *Contrast* (CONTRAST), *Correlation* (CORR), *Entropy* (ENT), *Variance* (VAR), *Inverse Difference Moment* (IDM), *Sum Average* (SAVG). GLCM diterapkan dari fitur polarisasi VV dan VH. Pemrosesan GLCM di GEE dijalankan dengan fungsi *glcmTexture* menggunakan *windows size* 5x5.

## 2.2.2. Segmentasi Citra

Segmentasi citra merupakan tahapan penting dalam alur kerja OBIA. Tujuannya adalah mempartisi citra menjadi sekumpulan *region* yang berbeda menurut karakteristik tertentu seperti tekstur, warna, bentuk, ukuran dan tingkat keabuan (Hossain & Chen, 2019). Untuk mendapatkan hasil segmentasi yang optimal, diperlukan kombinasi fitur *dataset* yang dapat merepresentasikan dan membedakan kenampakan objek dengan jelas dan tegas. Analisa dengan metode *Optimum Index Factor* (OIF) diterapkan untuk memperoleh kombinasi tiga fitur yang paling optimal digunakan sebagai *dataset* segmentasi. Metode OIF dihitung dengan persamaan berikut ini:

$$\text{OIF} = \sum_{i=1}^3 \text{SD}_i / \sum_{j=1}^3 |\text{CC}_{ij}| \quad (12)$$

$\text{SD}_i$  adalah standar deviasi untuk fitur  $i$  dan  $|\text{CC}_{ij}|$  adalah nilai absolut koefisien korelasi. Semakin tinggi nilai OIF, maka informasi yang terkandung dalam citra tersebut akan semakin banyak dan semakin sedikit redundansinya.

Metode OIF dihitung dari indeks spektral citra Sentinel-2. Setiap indeks spektral umumnya digunakan untuk mengidentifikasi objek tertentu secara spesifik. Indeks spektral dikelompokkan menjadi tiga yaitu indeks lahan terbangun atau terbuka (NDBI, NBI, UI, BSI), indeks vegetasi (NDVI, SAVI), dan indeks air (NDWI, MNDWI). Selanjutnya, indeks spektral dieksplorasi menggunakan metode OIF dengan ketentuan tiga fitur yang dikombinasikan terdiri dari indeks lahan terbangun/terbuka, vegetasi dan air. Nilai standar deviasi masing-masing indeks spektral dihitung menggunakan fungsi *ee.Reducer.stdDev*, sedangkan korelasi antar indeks

spektral dihitung dengan fungsi *ee.Reducer.pearsonsCorrelation*. Berdasarkan perhitungan OIF (Persamaan 12), kombinasi indeks spektral UI-NDVI-MNDWI memperoleh nilai tertinggi dan digunakan sebagai *dataset segmentasi*.

Setelah kombinasi indeks spektral yang optimal diperoleh, segmentasi citra diproses dengan menggunakan algoritma *Simple Non-Iterative Clustering* (SNIC). SNIC mengkategorikan objek (*cluster*) atau mensegmentasi objek citra berdasarkan parameter yang ditetapkan. Di GEE, parameter masukan meliputi *size*, *compactness*, *connectivity*, *neighbourhood size* dan *seeds*. SNIC diproses menggunakan fungsi *ee.Algorithms.Image.Segmentation.SNIC*. Nilai parameter ditetapkan *compactness*: 1, *connectivity*: 8, *neighbourhoodSize*: 128, dan *seedGrid*: 15. Selain mengacu penelitian Matarira dkk. (2023), yang memiliki kemiripan karakteristik lanskap dengan wilayah penelitian ini, nilai parameter dipilih setelah uji coba berulang sekaligus analisis visual terhadap hasil SNIC.

### 2.2.3. Klasifikasi Random Forest

Ekstraksi permukiman menerapkan klasifikasi *supervised* dengan pendekatan OBIA menggunakan algoritma RF. Algoritma RF menggunakan *bootstrap aggregation (bagging)* untuk membangun beberapa pohon keputusan/ *decision trees* (DT) dan menggabungkan hasilnya menggunakan metode pemilihan terbanyak (*majority voting*) untuk membuat prediksi yang lebih akurat (Tassi dkk., 2021). Sejumlah aplikasi pemetaan yang menggunakan GEE menunjukkan keunggulan algoritma RF diterapkan untuk klasifikasi penutup lahan/ penggunaan lahan berbasis OBIA. Algoritma RF juga dapat mengukur kuantitatif dari kontribusi setiap fitur terhadap hasil klasifikasi, dimana itu berguna untuk mengevaluasi pentingnya setiap fitur (Teluguntla dkk., 2018).

Ada tiga kelas objek yang diklasifikasikan yaitu permukiman, non permukiman dan badan air. *Dataset* yang terdiri dari 33 fitur kombinasi citra Sentinel-2 dan Sentinel-1 disiapkan sebagai data masukan dalam model klasifikasi. Selanjutnya, fungsi *reduceConnectedComponents* dijalankan untuk menghitung nilai rata-rata dari semua fitur yang tersedia berdasarkan segmen/ *cluster* SNIC. Seluruh proses klasifikasi mulai dari perancangan dan pengaturan model klasifikasi menggunakan fungsi *ee.Classifier.smileRandomForest*. Model RF diproses dengan 200 pohon (*tree*) yang ditetapkan berdasarkan analisis *Out-Of-Bag* (OOB) *error* setelah percobaan berulang dengan jumlah *tree* yang berbeda-beda.

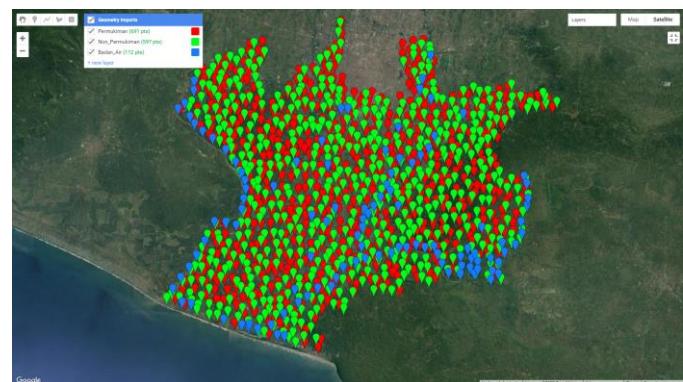
### 2.2.4. Analisis Hasil

Analisis hasil ekstraksi permukiman dilakukan dengan membandingkan secara visual dengan citra RGB *true color* dan peta RBI skala 1:25000 berdasarkan aspek distribusi dan geometri. Selain itu, dilakukan juga pengukuran kontribusi setiap variabel atau fitur *dataset* dari hasil ekstraksi permukiman. Analisis ini dapat menjelaskan tingkat pengaruh fitur atau nilai penting sebuah fitur dalam

proses klasifikasi menggunakan algoritma RF. Nilai penting atau kontribusi masing-masing fitur diperoleh dengan menggunakan fungsi *explain* yang informasinya tersimpan dalam fungsi *ee.Dictionary*. Grafik dibuat dengan fungsi *ui.Chart.feature.byProperty* untuk menggambarkan kontribusi masing-masing fitur terhadap hasil klasifikasi RF.

#### 2.2.4. Uji Akurasi

Ada 1400 titik sampel terdistribusi secara acak merata digunakan sebagai data pelatihan dan validasi seperti yang ditunjukkan Gambar 3. Titik sampel tersebut diidentifikasi secara manual menggunakan citra satelit resolusi tinggi *basemap* dari GEE dan disinkronkan dengan data permukiman dari unsur penutup lahan peta RBI skala 1:25000. Secara random di GEE, 70% titik sampel digunakan sebagai data pelatihan dan 30% sebagai data validasi. Rasio ini sudah umum dan banyak diimplementasikan pada aplikasi ekstraksi citra RF (Tassi dkk., 2021).



Gambar 3 Sebaran sampel data pelatihan dan validasi

Kualitas ekstraksi permukiman diuji akurasinya dengan metode matrik konfusi, sebuah pendekatan yang berdasarkan perbandingan hasil klasifikasi dengan data *ground truth* (Congalton, 1991; Foody, 2002). Nilai akurasi yang diturunkan dari matrik konfusi berupa *Overall Accuracy* (OA) (Persamaan 13), *Producer Accuracy* (PA) (Persamaan 14), *User Accuracy* (UA) (Persamaan 15) dan *F-score* (Persamaan 16) sesuai dengan rumus sebagai berikut:

$$OA = \frac{\sum_{k=1}^q n_{kk}}{n} \times 100\% \quad (13)$$

$$PA = \frac{n_{kk}}{n_{+k}} \quad (14)$$

$$UA = \frac{n_{kk}}{n_{k+}} \quad (15)$$

$$F\text{-score} = 2 \times \frac{PA \times UA}{PA + UA} \quad (16)$$

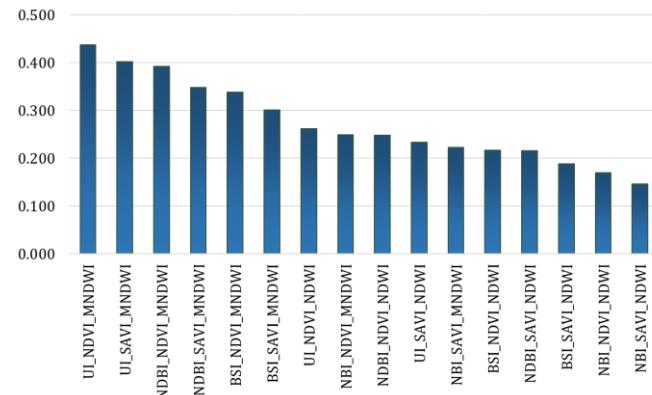
Berdasarkan persamaan diatas, q adalah jumlah total kolom di matrik konfusi atau jumlah total kelas,  $n_{kk}$  adalah jumlah klasifikasi yang benar dari sampel pada baris ke-k

dan kolom ke-k,  $n_{k+}$  dan  $n_{+k}$  adalah jumlah total sampel pada baris ke-k dan kolom ke-k, dan n adalah jumlah total sampel yang digunakan untuk verifikasi. *F-score* yang dihitung sebagai rata-rata harmonik PA dan UA menunjukkan seberapa efektif hasil klasifikasi (Matarira dkk., 2023; Zurqani dkk., 2019).

### 3. Hasil dan Pembahasan

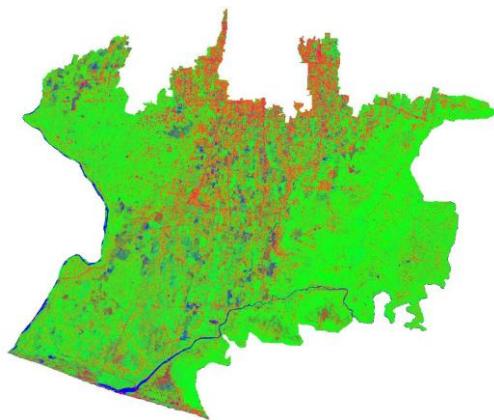
#### 3.1. Hasil Segmentasi SNIC

Ada 16 kombinasi fitur yang diperoleh dari perhitungan OIF seperti terlihat pada Gambar 4.



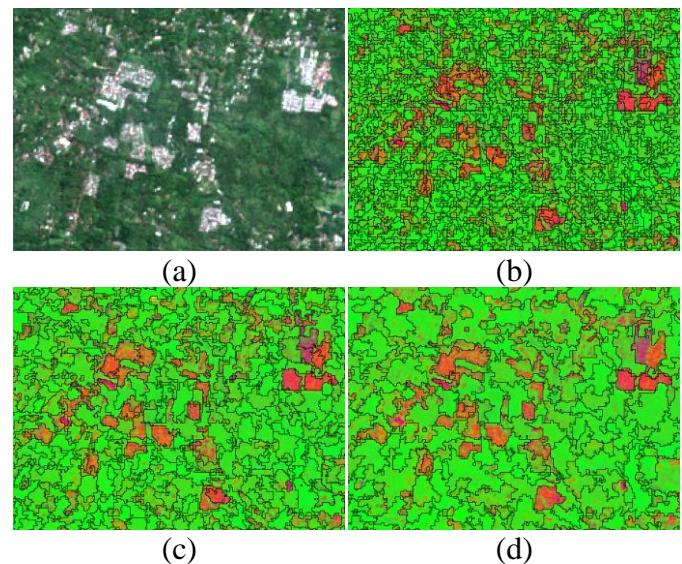
Gambar 4 Grafik OIF kombinasi fitur *dataset* segmentasi

Gambar 4 menunjukkan urutan kombinasi fitur dari perhitungan OIF indeks spektral dengan nilai yang tertinggi hingga yang terendah. Dapat dilihat, kombinasi fitur UI\_NDVI\_MNDWI memiliki nilai OIF tertinggi mencapai 0,438. Sebaliknya, kombinasi fitur NBL\_SAVI\_NDWI memiliki nilai OIF terendah yaitu 0,147. Nilai OIF yang tinggi menandakan jika informasi yang terdapat dalam citra lebih banyak dengan redundansi informasi yang minimal. Oleh karena itu, kombinasi fitur yang digunakan untuk proses segmentasi adalah UI\_NDVI\_MNDWI. Kenampakan kombinasi fitur UI\_NDVI\_MNDWI dalam format RGB *false color* dapat dilihat pada Gambar 5.



Gambar 5. Fitur UI\_NDVI\_MNDWI (RGB *false color*)

Hasil segmentasi menggunakan SNIC dipengaruhi nilai parameter *input*. Selain mempertimbangkan nilai parameter dari penelitian sebelumnya yang memiliki karakteristik lokasi sama, dilakukan percobaan untuk menerapkan ukuran atau *size seedGrid* yang berbeda untuk mendapatkan hasil segmentasi yang optimal. Hasil percobaan perbedaan penerapan ukuran *seedGrid* ditunjukkan Gambar 6.

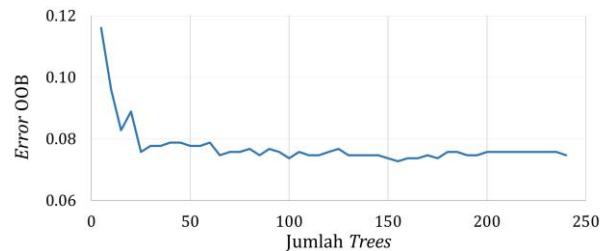


Gambar 6 Citra RGB *true color* (a) dan hasil segmentasi dengan ukuran *seedGrid* 5 (b), 10 (c), dan 15 (d)

Berdasarkan kenampakan Gambar 6, ukuran *seedGrid* yang optimal adalah 15. Objek permukiman terlihat dapat tersegmentasi dengan baik dibandingkan dengan penggunaan ukuran *seedGrid* 5 dan 10. Saat ukuran *seedGrid* diterapkan dengan ukuran 5 dan 10, objek disegmentasi terlalu detil sehingga terjadi *over segmentation*.

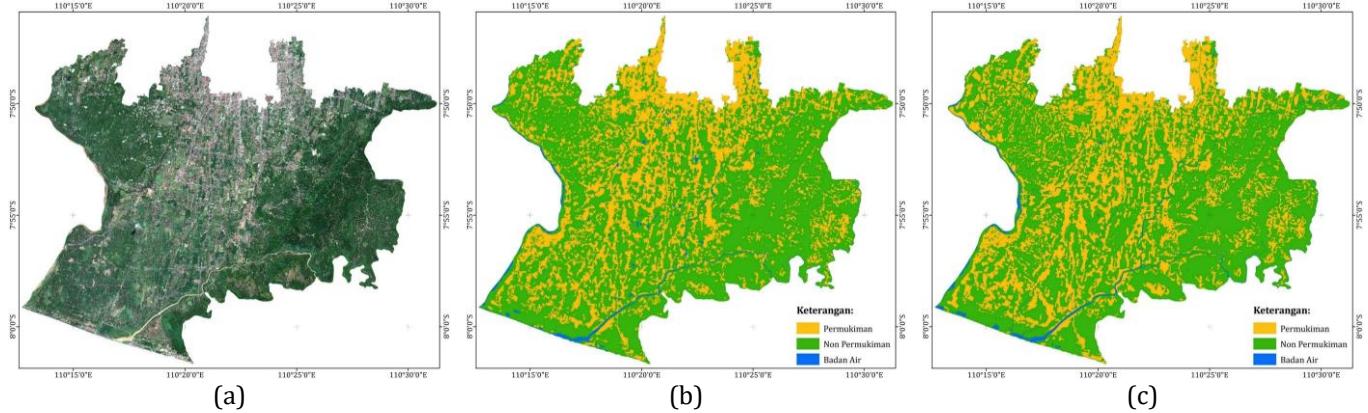
#### 3.2. Hasil Ekstraksi Permukiman

Ekstraksi permukiman diproses di GEE menggunakan algoritma RF. *Cluster* hasil segmentasi SNIC dan 33 fitur *dataset* kombinasi citra Sentinel-2 dan Sentinel-1 digunakan sebagai *input* model klasifikasi. Jumlah pohon (*tree*) optimal dianalisis menggunakan *Out-of-Bag* (OOB) *error*. Hasil percobaan OOB *error* dengan menggunakan jumlah *tree* 1-250 dapat dilihat pada Gambar 7.



Gambar 7 Analisis OOB *error*

Gambar 7 memperlihatkan nilai OOB *error* stabil setelah jumlah *tree* mencapai 200. Ambang batas ini dipilih sebagai kompromi optimal berkaitan dengan nilai akurasi hasil



Gambar 8 Citra RGB *true color* (a), hasil ekstraksi permukiman OBIA (b), permukiman peta RBI skala 1:25000 (c)

Gambar 8 menunjukkan pola distribusi permukiman hasil klasifikasi sinkron dengan kenampakan permukiman di citra RGB *true color* dan peta RBI skala 1:25000. Namun, jika dilihat dari aspek geometri atau bentuknya, permukiman hasil ekstraksi menggunakan RF memiliki karakteristik yang berbeda dengan geometri permukiman peta RBI (Gambar 9).



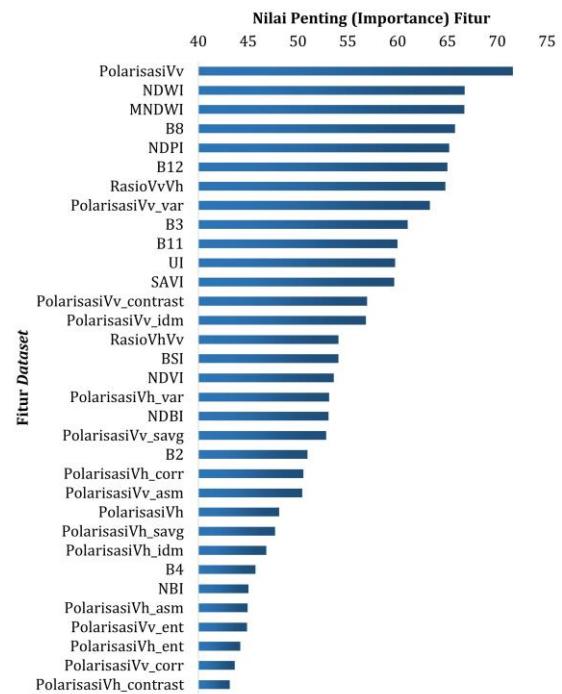
Gambar 9 Geometri permukiman ekstraksi *machine learning* RF (a) dan peta RBI (b)

Pembentukan permukiman dengan metode pendekatan OBIA menggunakan ML RF hanya berdasarkan informasi spektral dari piksel citra saja sedangkan permukiman di peta RBI sudah dipengaruhi aspek generalisasi. Oleh karena itu, hasil ekstraksi permukiman penelitian ini belum dapat secara langsung digunakan sebagai data masukan dalam produksi peta RBI skala menengah. Sejalan dengan hasil penelitian Widyaningrum dkk. (2021), hasil ekstraksi permukiman dengan metode OBIA dapat digunakan sebagai panduan digitasi (*guided digitization*) untuk mengekstraksi unsur permukiman peta RBI. Selain itu, hasil ekstraksi permukiman juga dapat mendukung proses kontrol kualitas data hasil produksi atau pemutakhiran peta RBI skala menengah.

klasifikasi dan biaya komputasi. Model RF dilatih menggunakan 990 sampel atau 70% dari total sampel.

### 3.3. Analisis Kontribusi Fitur Klasifikasi RF

Analisis kontribusi fitur dilakukan untuk mengevaluasi nilai penting fitur dalam klasifikasi menggunakan algoritma RF. Nilai setiap fitur *dataset* diubah menjadi angka acak, kemudian dampaknya terhadap akurasi model klasifikasi dihitung. Pengklasifikasi RF akan memberikan skor untuk setiap fitur *input* berdasarkan kontribusi atau seberapa pentingnya fitur tersebut dalam memprediksi nilai yang benar.



Gambar 10 Nilai penting fitur model klasifikasi RF

Gambar 10 menggambarkan nilai penting dari 33 fitur input dalam model klasifikasi RF untuk ekstraksi

permukiman. Semua fitur memberikan kontribusi nilai yang berbeda-beda terhadap hasil klasifikasi. Secara keseluruhan, polarisasi VV merupakan fitur yang memiliki nilai penting paling tinggi diantara fitur lainnya. Citra SAR dikenal memiliki kelebihan dapat memberikan informasi mengenai struktur dan sifat dielektrik dari material permukaan. Selain itu, efek *double bounce scattering* pada polarisasi VV cocok untuk digunakan mendeteksi objek yang memiliki struktur vertikal seperti bangunan yang ada di wilayah permukiman.

Berdasarkan pengelompokan jenis fitur yaitu saluran spektral, indeks spektral dan tekstur, dapat dilihat fitur nilainya dominan. NIR (B8) dan SWIR (B12) merupakan dua fitur dari kelompok saluran spektral citra Sentinel-2 dengan nilai tertinggi. NIR memberikan informasi spektral yang kuat untuk deteksi objek vegetasi, sedangkan SWIR berguna untuk mengidentifikasi lahan terbangun. NDWI dan MNDWI merupakan indeks spektral yang memiliki kontribusi kuat untuk mengidentifikasi objek badan air. Selain polarisasi VV, indeks spektral NDPI dan rasio VV/VH juga memiliki nilai penting yang tinggi dalam model klasifikasi RF. Terkait informasi tekstur, GLCM varian dari polarisasi VV menjadi fitur yang paling tinggi nilainya dibandingkan fitur tekstur lainnya. Hasil analisis nilai penting fitur dapat digunakan sebagai pertimbangan untuk menentukan fitur apa saja yang efektif dan efisien dalam pembentukan model klasifikasi.

#### 3.4. Uji Akurasi Hasil Klasifikasi

Uji akurasi dilakukan dengan membandingkan hasil ekstraksi permukiman dengan data validasi (*ground truth*) hasil digitasi *on screen* berdasarkan data citra satelit resolusi tinggi *basemap* GEE dan peta RBI skala 1:25000. Ada 410 sampel data validasi yang terdiri dari 206 sampel permukiman (P), 173 sampel non permukiman (NP) dan 31 sampel badan air (BA). Seluruh sampel data validasi tersebut tersebar secara acak dan merata mewakili seluruh landskap yang ada di lokasi penelitian.

Tabel 1 Matrik konfusi hasil ekstraksi permukiman

Kelas Objek	Data Referensi			Total	UA
	P	NP	BA		
Data Klasifikasi	P	187	19	0	91%
	NP	8	165	0	95%
	BA	3	2	26	84%
Total	198	186	26	410	
PA	94%	89%	100%		92%

Tabel 1 menunjukkan akurasi hasil ekstraksi permukiman yang diturunkan dari matrik konfusi. OA dari penelitian ini sebesar 92%, melebihi 85%, yang menurut Kpienbaareh dkk. (2021) merupakan ambang batas nilai OA untuk menilai hasil klasifikasi yang baik. Penilaian UA dan PA untuk setiap kelas objek juga memiliki skor di atas 85%, kecuali UA objek badan air yang hanya sebesar 84%.

Hasil ini menunjukkan bahwa pendekatan model klasifikasi yang digunakan secara umum mampu mengklasifikasikan setiap kelas objek dengan baik.

Secara rinci, nilai UA paling rendah adalah objek badan air. Hasil ini mengindikasikan ada ketidaksesuaian objek badan air dari hasil klasifikasi, namun kenyataan di data referensi merupakan objek permukiman atau non permukiman. Meskipun nilai UA badan air terendah, akan tetapi badan air memiliki nilai PA tertinggi mencapai 100%. Hal ini menggambarkan jika keseluruhan objek badan air dari data referensi terkласifikasi dengan benar.

Objek non permukiman memiliki nilai UA tertinggi dibandingkan kelas objek lainnya yaitu sebesar 95%. Masih ada kesalahan klasifikasi objek non permukiman yang seharusnya di data referensi adalah objek permukiman. Nilai PA objek non permukiman sebesar 89% menunjukkan jika masih terdapat objek non permukiman dari data referensi yang terkласifikasi sebagai objek permukiman dan badan air.

Permukiman menjadi objek yang memiliki nilai UA dan PA paling konsisten di atas 90%, lebih tepatnya 91% dan 94%. Meskipun masih ada ketidaksesuaian hasil klasifikasi, tetapi nilai akurasi tersebut sudah cukup menggambarkan jika permukiman terklasifikasi dengan akurat. Selain OA, UA dan PA, dilakukan juga evaluasi kualitas hasil ekstraksi permukiman menggunakan *F-score*.

Tabel 2 Perhitungan *F-score*

Kelas Objek	PA	UA	F-Score
Permukiman	94%	91%	93%
Non Permukiman	89%	95%	92%
Badan Air	100%	84%	91%
Rata-Rata	94%	90%	92%

Tabel 2 menunjukkan perhitungan nilai *F-score* dari hasil ekstraksi permukiman. Nilai *F-score* untuk masing-masing kelas objek berkisar 91-93%, dimana objek permukiman memiliki nilai *F-score* tertinggi yaitu 93%. Akurasi klasifikasi objek permukiman yang tinggi tersebut menunjukkan kemampuan metode OBIA di GEE dapat menghasilkan data ekstraksi permukiman dengan kualitas yang baik di wilayah dengan variasi landskap yang beragam. Di samping itu, nilai rata-rata *F-score* sebesar 92% memperlihatkan bahwa model memiliki kinerja yang baik dalam mengklasifikasikan objek secara keseluruhan.

#### 4. Kesimpulan

Berdasarkan hasil penelitian ini, dapat diperoleh kesimpulan bahwa penentuan komposisi fitur *dataset* memegang peranan penting dalam proses ekstraksi permukiman dan segmentasi. Komposisi *dataset* ekstraksi permukiman terdiri dari 33 fitur kombinasi saluran spektral, indeks spektral dan tekstur dari citra Sentinel-2 dan Sentinel-1. Sedangkan komposisi fitur *dataset* segmentasi terdiri dari kombinasi indeks spektral UI-NDVI-

MNDWI, yang merupakan kombinasi fitur optimal hasil perhitungan metode OIF.

Hasil ekstraksi permukiman dari kombinasi citra Sentinel-2 dan Sentinel-1 menggunakan pendekatan OBIA menghasilkan tiga kelas yaitu permukiman, non permukiman dan badan air. Pola distribusi permukiman yang diklasifikasi, secara visual konsisten dengan distribusi permukiman pada peta RBI skala 1:25000. Namun, dari segi geometri atau bentuknya, karakteristik permukiman hasil klasifikasi berbeda dengan permukiman peta RBI. Hasil ekstraksi permukiman dalam penelitian ini hanya dapat digunakan sebagai panduan digitasi dan mendukung kontrol kualitas dalam proses produksi atau pemutakhiran peta RBI skala menengah. Dari analisis kontribusi nilai penting fitur menggunakan algoritma RF, menunjukkan polarisasi VV memiliki kontribusi tertinggi, yang menandakan kemampuannya dalam memberikan informasi yang efektif tentang struktur dan sifat dielektrik permukaan khususnya objek permukiman.

Secara keseluruhan, hasil uji akurasi ekstraksi permukiman mencapai tingkat akurasi yang tinggi, dengan nilai OA dan *F-score* sebesar 92%. Tingkat akurasi tertinggi ada pada objek permukiman dengan nilai *F-score* 93%, sementara akurasi terendah pada objek badan air sebesar 91%. Hasil ini menunjukkan metode OBIA dan model klasifikasi RF di GEE memiliki kinerja yang baik dan mampu menghasilkan data ekstraksi permukiman dengan akurasi yang tinggi di wilayah dengan landskap yang beragam.

## 5. Pernyataan Konflik Kepentingan

Penulis menyatakan tidak ada konflik kepentingan dalam artikel ini (*The authors declare no competing interest*).

## 6. Referensi

- Achanta, R., & Süsstrunk, S. (2017). Superpixels and Polygons using Simple Non-Iterative Clustering. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-Janua(Ic)*, 4895–4904. <https://doi.org/10.1109/CVPR.2017.520>
- Amani, M., Ghorbanian, A., Ahmadi, S. A., Kakooei, M., Moghimi, A., Mirmazloumi, S. M., Moghaddam, S. H. A., Mahdavi, S., Ghahremanloo, M., Parsian, S., Wu, Q., & Brisco, B. (2020). Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 5326–5350. <https://doi.org/10.1109/JSTARS.2020.3021052>
- Blaschke, T., Hay, G. J., Kelly, M., Lang, S., Hofmann, P., Addink, E., Queiroz Feitosa, R., van der Meer, F., van der Werff, H., van Coillie, F., & Tiede, D. (2014). Geographic Object-Based Image Analysis - Towards A New Paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 180–191. <https://doi.org/10.1016/j.isprsjprs.2013.09.014>
- Cheng, J., Sun, G., Zhang, A., Fu, H., Jiao, Z., & Yao, Y. (2021). Synergetic Use of Descending and Ascending SAR With Optical Data for Impervious Surface Mapping. *International Geoscience and Remote Sensing Symposium (IGARSS), 2021-July*, 4272–4275. <https://doi.org/10.1109/IGARSS47720.2021.9553144>
- Congalton, R. G. (1991). A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sensing of Environment*, 37(1), 35–46. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B)
- Corbane, C., Lemoine, G., Pesaresi, M., Kemper, T., Syrris, V., & Ferri, S. (2018). Enhanced Automatic Detection of Human Settlements using Sentinel-1 Interferometric Coherence. *International Journal of Remote Sensing*, 39(3), 842–853. <https://doi.org/10.1080/01431161.2017.1392642>
- Csillik, O. (2017). Fast Segmentation and Classification of Very High Resolution Remote Sensing Data using SLIC Superpixels. *Remote Sensing*, 9(3). <https://doi.org/10.3390/rs9030243>
- Devi, N. S. & Santosa, P. B. (2022). Analisis Geospasial Perubahan Ruang Terbuka Hijau Wilayah Kota Purwokerto dari Tahun 2013 sampai 2020. *Journal of Geospatial Information Science and Engineering*, Vol. 5 No. 2 (2022). <https://doi.org/10.22146/jgise.74620>
- ESA. (2015). Sentinel-2 User Handbook. In *ESA Standard Document*.
- Firozjaei, M. K., Sedighi, A., Kiavarz, M., Qureshi, S., Haase, D., & Alavipanah, S. K. (2019). Automated Built-up Extraction Index: A New Technique for Mapping Surface Built-up Areas Using LANDSAT 8 OLI Imagery. *Remote Sensing*, 11(17). <https://doi.org/10.3390/rs11171966>
- Foody, G. M. (2002). Status of Land Cover Classification Accuracy Assessment. *Remote Sensing of Environment*, 80, 185–201. [https://doi.org/https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/https://doi.org/10.1016/S0034-4257(01)00295-4)
- Gao, B.-C. (1996). NDWI - A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water From Space. *Remote Sensing of Environment*, 58(3), 257–266. [https://doi.org/https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/https://doi.org/10.1016/S0034-4257(96)00067-3)
- Haralick, R. M., Dinstein, I., & Shanmugam, K. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics, SMC-3(6)*, 610–621. <https://doi.org/10.1109/TSMC.1973.4309314>
- Hossain, M. D., & Chen, D. (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(November 2018), 115–134. <https://doi.org/10.1016/j.isprsjprs.2019.02.009>

- Huete, A. R. (1988). Comparative Studies on IFAT, ELISA & DAT for Serodiagnosis of Visceral Leishmaniasis in Bangladesh. *Remote Sensing of Environment*, 25(1), 295–309.  
[https://doi.org/https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/https://doi.org/10.1016/0034-4257(88)90106-X)
- Ji, H., Li, X., Wei, X., Liu, W., Zhang, L., & Wang, L. (2020). Mapping 10-m Resolution Rural Settlements using Multi-Source Remote Sensing Datasets with The Google Earth Engine Platform. *Remote Sensing*, 12(17), 1–23. <https://doi.org/10.3390/rs12172832>
- Juniati, E. (2018). *2D Semantic Labeling Penutup Lahan di Area Urban dengan Analisis Berbasis Objek Dari Foto Udara dan LiDAR*. Universitas Gadjah Mada.
- Kete, S. C. R., Suprihatin, Tarigan, S. D., & Effendi, H. (2019). Land Use Classification Based on Object and Pixel using Landsat 8 OLI in Kendari City, Southeast Sulawesi Province, Indonesia. *IOP Conference Series: Earth and Environmental Science*, 284(1). <https://doi.org/10.1088/1755-1315/284/1/012019>
- Kpienbaareh, D., Sun, X., Wang, J., Luginaah, I., Kerr, R. B., Lupafya, E., & Dakishoni, L. (2021). Crop Type and Land Cover Mapping in Northern Malawi Using The Inegration of Sentinel-1, Sentinel-2, and PlanetScope Satellite Data. *Remote Sensing*, 13(4), 1–21. <https://doi.org/10.3390/rs13040700>
- Kushardono, D. (2012). Klasifikasi Spasial Penutup Lahan Dengan Data Sar Dual- Polarisasi Menggunakan Normalized Difference Polarization Index Dan Fitur Keruangan Dari Matrik Kookurensi (Spatial Land Cover Classification Using Dual-Polarization Sar Data Based on Normalized Diff. *Jurnal Penginderaan Jauh*, 9(1), 12–24.
- Matarira, D., Mutanga, O., & Naidu, M. (2022). Google Earth Engine for Informal Settlement Mapping : A Random Forest Classification Using Spectral and Textural Information. *Remote Sensing*, 14(20). <https://doi.org/10.3390/rs14205130>
- Matarira, D., Mutanga, O., Naidu, M., & Vizzari, M. (2023). Object-Based Informal Settlement Mapping in Google Earth Engine Using the Integration of Sentinel-1, Sentinel-2, and PlanetScope Satellite Data. *Land*, 12, 1–17. <https://doi.org/https://doi.org/10.3390/land12010099>
- Rudiastuti, A. W., Farda, N. M., & Ramdani, D. (2021). Mapping Built-Up Land & Settlements : A Comparison of Machine Learning Algorithms. *Proceedings Volume 12082, Seventh Geoinformation Science Symposium 2021*. <https://doi.org/10.11117/12.2619493>
- Rudiastuti, A. W., Lumban-Gaoi, Y., Silalahi, F. E. S., Prihanto, Y., & Pranowo, W. S. (2022). Implementing Random Forest Algorithm in GEE: Separation and Transferability on Built-Up Area in Central Java, Indonesia. *International Journal of Informatics Visualization*, 6, 74–82. <https://doi.org/https://doi.org/10.30630/jov.6.1.873>
- Santosa, P. B. (2016). Evaluation of satellite image correction methods caused by differential terrain illumination. *Jurnal Forum Geografi*. Vol. 30, No. 1 (2016). <https://doi.org/10.23917/forgeo.v30i1.1768>
- Tassi, A., Gigante, D., Modica, G., & Martino, L. Di. (2021). Pixel- vs . Object-Based Landsat 8 Data Classification in Google Earth Engine Using Random Forest: The Case Study of Maiella National Park. *Remote Sensing*, 13. <https://doi.org/10.3390/rs13122299>
- Teluguntla, P., Thenkabail, P., Oliphant, A., Xiong, J., Gumma, M. K., Congalton, R. G., Yadav, K., & Huete, A. (2018). A 30-m Landsat-Derived Cropland Extent Product of Australia and China using Random Forest Machine Learning Algorithm on Google Earth Engine Cloud Computing Platform. *ISPRS Journal of Photogrammetry and Remote Sensing*, 144(February), 325–340. <https://doi.org/10.1016/j.isprsjprs.2018.07.017>
- Vergni, L., Vinci, A., Todisco, F., Santaga, F. S., & Vizzari, M. (2021). Comparing Sentinel-1, Sentinel-2, and Landsat-8 Data in the Early Recognition of Irrigated Areas in Central Italy. *Journal of Agricultural Engineering*, 52(4), 43–53. <https://doi.org/10.4081/JAE.2021.1265>
- Vizzari, M. (2022). PlanetScope, Sentinel-2, and Sentinel-1 Data Integration for Object-Based Land Cover Classification in Google Earth Engine. *Remote Sensing*, 14, 1–19. <https://doi.org/https://doi.org/10.3390/rs1411262>
- Wang, L., Gong, P., Ying, Q., Yang, Z., Cheng, X., & Ran, Q. (2010). Settlement Extraction in The North China Plain using Landsat and Beijing-1 Multispectral Data with An Improved Watershed Segmentation Algorithm. *International Journal of Remote Sensing*, 31(6), 1411–1426. <https://doi.org/10.1080/01431160903475332>
- Widyaningrum, E., Perdana, A. P., Andari, R., Mayasari, R., & Damayanti, A. P. (2021). Penggunaan Citra Satelit Sentinel-2 Dan Spot 6-7 Dengan Kompilasi Data Keruangan Untuk Pemutakhiran Peta Dasar. *Elipsoida*, 04(02), 100–108. <https://doi.org/https://doi.org/10.14710/elipsoida.2021.13874>
- Xu, H. (2006). Modification of Normalised Difference Water Index (NDWI) to Enhance Open Water Features in Remotely Sensed Imagery. *International Journal of Remote Sensing*, 27(14), 3025–3033. <https://doi.org/10.1080/01431160600589179>
- Zurqani, H. A., Post, C. J., Mikhailova, E. A., & Allen, J. S. (2019). Mapping Urbanization Trends in a Forested Landscape Using Google Earth Engine. *Remote Sensing in Earth Systems Sciences*, 2(4), 173–182. <https://doi.org/10.1007/s41976-019-00020-y>