



## Klasifikasi Digital Tutupan Lahan Berbasis Objek menggunakan Integrasi Data Lidar dan Citra Satelit di Kawasan Tamalanrea Indah, Kota Makassar

*(Object-Based Digital Land Cover Classification Using Integration of Airborne Lidar Data and Satellite Image at Tamalanrea Indah, Makassar City)*

Bagus Wijanarko<sup>1</sup>, Djurdjani<sup>2</sup>

<sup>1</sup>Alumni Departemen Teknik Geodesi FT-UGM, Indonesia

<sup>2</sup> Staf Pengajar Departemen Teknik Geodesi FT-UGM, Indonesia

Penulis Korespondensi: Djurdjani | Email: [djurdjani@ugm.ac.id](mailto:djurdjani@ugm.ac.id)

Diterima (Received): 7/Sep/2021 Direvisi (Revised): 24/Dec/2021 Diterima untuk Publikasi (Accepted): 4/4/2022

### ABSTRAK

Kebutuhan pemerintah daerah akan informasi geospasial menjadi semakin penting saat RTH semakin sulit ditemui di kawasan urban. Informasi tersebut adalah peta tutupan lahan, yang dapat diperoleh dari proses klasifikasi citra satelit resolusi tinggi, tetapi masih memiliki keterbatasan informasi spektral dimana klasifikasi objek juga melibatkan karakteristik spasial hingga tekstur untuk mendapatkan nilai akurasi yang tinggi (Kushardono, 2017). Karakteristik tersebut sangat minimal pada data sensor pasif, tetapi banyak ditemukan pada data sensor aktif (radar/LiDAR). Dengan diketahuinya potensi kedua sensor (citra satelit dan LiDAR), beberapa peneliti telah melakukan penelitian serupa, di antaranya Awrangjeb dkk., (2013), Uzar dan Yastikli (2013), dan Gilani dkk., (2015). Pada penelitian ini, terdapat 3 data utama yaitu citra Pleiades, nDSM, dan citra intensitas. nDSM merupakan data turunan dari nilai elevasi LiDAR, sementara citra intensitas dibentuk dari nilai pantulan objek pada panjang gelombang NIR, yang masing-masing telah terkoreksi kemudian diinterpolasi menjadi data raster dan diklasifikasi. Proses klasifikasi dilakukan menggunakan metode OBIA dengan algoritma Assign Class melalui proses segmentasi. Skema klasifikasi yang dihasilkan menghasilkan sebanyak 12 subkelas (dalam 4 kelas utama) dari masing-masing hasil klasifikasi data sensor membentuk dataset komposisi. Proses integrasi ini menghasilkan sebanyak 3 dataset komposisi, yaitu dataset A (citra Pleiades), dataset B (Pleiades-intensitas) dan dataset C (Pleiades-nDSM). Dengan analisis SIG dilakukan uji akurasi dan didapat nilai akurasi dataset A sebesar 44,44% dan dataset B dan C keduanya menghasilkan nilai akurasi sebesar 63,89%. Nilai akurasi tersebut sangat rendah jika mengacu pada SNI LU/LC, dikarenakan jumlah 36 titik sampel tidak proporsional (< 20%) terhadap total jumlah objek yang mencapai ribuan.

**Kata Kunci:** OBIA, penutup lahan, Pleiades, LiDAR, nDSM, intensitas, integrasi

### ABSTRACT

The local government's need for geospatial information becomes important when green open space is difficult to find in urban areas. The information is a land cover map, which can be obtained from the classification process of high-resolution satellite images, but it still has limited spectral information where object classification also involves spatial characteristics and textures to get high accuracy value (Kushardono, 2017). These characteristics are minimal in passive sensor data but are mostly found in active sensor data (radar/LiDAR). By knowing the potential of the two sensors (satellite imagery and LiDAR), several researchers have conducted similar studies, including Awrangjeb et al., (2013), Uzar and Yastikli (2013), and Gilani et al., (2015). In this study, there are 3 main data, namely Pleiades images, nDSM, and intensity images. nDSM is derived data from the LiDAR elevation value, while the intensity image is formed from the object's reflection value at the NIR wavelength, each of which has been corrected and then interpolated into raster data and classified. The classification process is carried out using the OBIA method with the Assign Class algorithm through a segmentation process. The resulting classification scheme produces 12 subclasses (in 4 main classes) from each sensor data classification to form a composition dataset. This integration process produces 3 compositional datasets, namely dataset A (Pleiades image), dataset B (Pleiades-intensity) and dataset C (Pleiades-nDSM). With GIS analysis, an accuracy test was carried out and the accuracy value of dataset A was 44.44% and dataset B and C both produced an accuracy value of 63.89%. The accuracy value is very low when referring to SNI LU/LC, because the number of 36 sample points is disproportionate (<20%) to the total number of objects that reach thousands

**Keywords:** OBIA, land cover, Pleiades, LiDAR, nDSM, intensity, integration

## 1. Pendahuluan

Untuk memenuhi standar lingkungan hidup yang baik dalam sebuah kota, seperti yang tercantum dalam Undang-Undang Nomor 26 Tahun 2007 tentang Penataan Ruang Terbuka Hijau, diperlukan proporsi minimal RTH sebesar 30 persen dari keseluruhan lahan kota. Namun pada kenyataannya, menurut data yang dimiliki oleh Kementerian Pekerjaan Umum dan Perumahan Rakyat, sampai tahun 2019 baru tercatat sebanyak 13 dari 174 kota di Indonesia yang mampu memenuhi syarat sebagai kota yang memiliki luas RTH yang proporsional (Wahdaniyat, 2019). Menurut ahli arsitektur dan perkotaan dari Institut Teknologi Sepuluh November (ITS) Professor Johan Silas, minimnya proporsi RTH di kota-kota besar salah satunya dikarenakan penataan ruang yang berantakan. Untuk mengatasi kendala tersebut, diperlukan suatu perencanaan kota yang berkelanjutan dengan memanfaatkan informasi geospasial berupa peta tutupan lahan (Achsani, 2017).

Suatu peta tutupan lahan dapat diperoleh dari hasil klasifikasi lahan dengan berbagai macam metode, salah satunya yaitu dengan teknik penginderaan jauh atau inderaja (Sampurno dan Thoriq, 2016; Aristalindra dkk, 2020; Prayogo & Basith, 2020). Metode inderaja dipilih dalam pembuatan peta tutupan lahan karena memiliki beberapa kelebihan, yaitu mampu mencakup kawasan yang luas, memiliki resolusi yang cukup tinggi (foto udara), dapat dianalisis secara cepat dan dinamis serta dapat meminimalisir biaya survei (Kushardono, 2017).

Dalam penelitian yang dilakukan oleh Alonso dan Malpica (2010), dilakukan kajian dari penggabungan sensor secara sinergis antara LiDAR dan citra multispektral dalam memetakan persebaran objek berupa bangunan. Dari penelitian yang telah dilakukan, diperoleh hasil yaitu *Overall Accuracy* klasifikasi menggunakan data citra satelit dan LiDAR sebesar 97,12% sedangkan *Overall Accuracy* klasifikasi menggunakan data citra satelit tanpa data LiDAR sebesar 80,34%. Selain itu, pada penelitian yang dilakukan oleh Awrangjeb dkk., (2013) dilakukan klasifikasi multisensor data LiDAR dengan citra multispektral untuk ekstraksi atap bangunan, dimana diperoleh akurasi deteksi dengan klasifikasi berbasis objek mencapai 94,1% dan akurasi deteksi dengan klasifikasi berbasis piksel mencapai 82,9 %. Penelitian serupa juga dilakukan oleh Uzar dan Yastikli (2013) dimana klasifikasi multisensor yang dilakukan untuk mendeteksi bangunan menghasilkan akurasi sebesar 96,73% untuk kelengkapan dan 95,02% untuk kebenaran objeknya.

LiDAR (*Light Detection And Ranging*) merupakan teknologi penginderaan jauh dengan sensor aktif berupa laser yang diintegrasikan dengan wahana terbang berupa pesawat atau wahana terbang nirawak/*Unmanned Aerial Vehicle* (UAV) yang mampu melakukan pemindaian (*scanning*) pada area yang cukup luas (Istarno, 2016). Dalam hal akuisisi data, LiDAR akan menghasilkan data ukuran berupa kumpulan titik-titik hasil pemindaian/*scanning* yang disebut *point cloud*, yang masing-masing memiliki koordinat tergeoreferensi sehingga elevasinya terhadap permukaan tanah dapat diketahui, serta karakteristik objek yang dipantulkan

dalam suatu nilai intensitas. Data *point cloud* tersebut jika diinterpolasi dengan metode tertentu berdasarkan nilai elevasinya dapat menghasilkan data turunan berbasis raster membentuk suatu citra dari wilayah yang dipetakan yang disebut *Digital Terrain Model* (DTM) dan *Digital Surface Model* (DSM). Sementara itu, jika data diinterpolasi berdasarkan nilai intensitas terhadap objek di permukaan tanah dapat dihasilkan data turunan berupa citra intensitas.

Selain menggunakan LiDAR, wahana yang lebih umum dimanfaatkan dalam klasifikasi tutupan lahan yaitu wahana satelit optis. Teknologi satelit optis memanfaatkan pencitraan menggunakan sensor pasif, yang memanfaatkan pantulan sinar matahari dari permukaan bumi ke sensor optik satelit sehingga memiliki kapabilitas yang berbeda dengan LiDAR. Jika wahana sensor aktif (radar/LiDAR) memiliki keunggulan dalam segi spasial (ketelitian geometris lebih tinggi tanpa adanya pergeseran relief), satelit memiliki keunggulan dalam segi spektral (rentang kanal spectral/band lebih luas dalam mengidentifikasi karakteristik pada objek) (Kushardono, 1997; Santosa, 2016; Aristalindra dkk, 2020).

Selain itu, menurut Kushardono (2017), umumnya hasil klasifikasi penutup lahan dengan citra satelit memberikan akurasi yang relatif lebih rendah dari metode lain disebabkan oleh kurangnya informasi untuk membedakan objek yang sangat heterogen terutama pada citra satelit resolusi tinggi. Pada citra satelit resolusi tinggi untuk mendapatkan nilai akurasi yang tinggi objek tidak hanya diklasifikasi berdasarkan karakteristik spektral tetapi juga melibatkan karakteristik spasial hingga tekstur. Karakteristik spasial dan tekstur tersebut tidak dimiliki oleh satelit dengan sensor pasif/optik, tetapi data tersebut dapat diperoleh dari satelit/instrumen yang bekerja dengan sensor aktif seperti halnya radar, *Synthetic Aperture Radar* (SAR) dan LiDAR. Secara teori, perbedaan kedua jenis sensor antara sensor pasif dengan sensor aktif memberikan data yang berbeda tetapi dapat memberikan interpretasi yang sama pada objek tertentu berdasarkan suatu acuan atau kaidah. Tentunya hal tersebut dapat memperkaya informasi atau karakteristik pada suatu objek sehingga diasumsikan dapat meningkatkan akurasi dari hasil klasifikasi.

Penelitian ini bertujuan untuk mengeksplorasi potensi dari citra satelit yang diintegrasikan dengan data LiDAR dalam mengklasifikasikan objek penutup lahan pada kawasan perkotaan Makassar yang memiliki objek penutup lahan yang bersifat heterogen. Hasil penelitian diharapkan dapat memberikan jawaban dari hipotesis yang telah dibuat dan memiliki kehandalan yang dapat diukur melalui uji akurasi.

## 2. Data dan Metodologi

### 2.1 Data dan Lokasi

Kegiatan penelitian ini mengambil lokasi di Kota Makassar pada tahun 2013, tepatnya di Kelurahan

Tamalanrea Indah. Lokasi ini dipilih berdasarkan pertimbangan peneliti akan ketersediaan data dari dua instansi penyedia data (PT. Asi Pudjiastuti Geosurvey dan Pustekdata LAPAN) pada lokasi dan waktu yang berdekatan (lihat pada Gambar 1).

Beberapa data yang digunakan pada penelitian ini sebagai berikut:

1. Data *point cloud* LiDAR
  - Lokasi : Kota Makassar
  - Waktu akuisisi : 1 – 22 Juni 2012
  - Average point spacing*: 0,47 meter
  - Format data : \*.las
  - Sumber data : PT. Asi Pudjiastuti Geosurvey
2. *Trajectory* wahana udara perekaman LiDAR
  - Lokasi : Kota Makassar
  - Waktu akuisisi : 1 – 22 Juni 2012
  - Tinggi terbang : 776 – 1038 meter dpl
  - Format data : \*.trj
  - Sumber data : PT. Asi Pudjiastuti Geosurvey
3. Data citra satelit Pleiades
  - Lokasi : Kota Makassar
  - Waktu akuisisi : 18 Agustus 2013
  - Resolusi spasial : 0,5 meter
  - Format data : \*.TIFF
  - Sumber data : Pustekdata LAPAN




Gambar 1 Lokasi penelitian

## 2.2 Metodologi

### 2.2.1. Penyaringan dan koreksi data *point cloud*

*Point cloud* dibagi ke dalam blok-blok persegi berukuran 1008,0349 x 1008,0349 m<sup>2</sup> menjadi sejumlah dua belas blok menggunakan *tools* Terrascan. Selanjutnya, dilakukan proses penyaringan kembali *point cloud* dari kelas *default* untuk mendapatkan kelas vegetasi menggunakan *tools* macro. Didapatkan sebanyak delapan kelas *point cloud*, yaitu kelas *default*, *ground*, *low vegetation*, *medium vegetation*, *high vegetation*, *building*, *low point* dan *model keypoints* sebagaimana ditunjukkan di Gambar 2.




Gambar 2 *Point cloud* berdasarkan 12 blok area kerja

Kemudian, proses selanjutnya adalah mencari ketidakcocokan dalam data hasil pengukuran LiDAR dan menentukan nilai koreksinya dengan *tools find match*. Data *trajectory* dibutuhkan karena menyimpan data orientasi wahana terbang (*pitch*, *roll*, *heading*) serta *mirror scale* untuk selanjutnya menentukan besar koreksi orientasi, elevasi maupun fluktuasi wahana terbang. *Point cloud* yang telah terkoreksi selanjutnya diekspor sesuai dengan jalur terbang masing-masing. Hal ini dikarenakan dalam satu blok area kerja, *point cloud* terbagi ke dalam beberapa jalur terbang yang berbeda, yang selanjutnya mempengaruhi nilai intensitas.

### 2.2.2. *Normalized Digital Surface Model* (nDSM)

Dalam menghasilkan nDSM, *point cloud* yang diimpor disaring berdasarkan ketinggian relatifnya terhadap permukaan tanah (*point cloud* yang relatif lebih rendah dari permukaan tanah tidak digunakan) dan hanya menggunakan dua *return*, yaitu *first return* dan *last return* secara terpisah. Hal ini karena *first return* merupakan *point cloud* yang benar-benar meliputi semua objek yang berada di atas permukaan tanah sebagai hasil dari pantulan pertama, sementara *last return* merupakan *point cloud* yang mampu dipantulkan oleh objek yang paling dekat dengan permukaan tanah sebagai pantulan terakhir.


Selanjutnya, menentukan metode *gridding* serta memasukkan nilai *point spacing* dalam perangkat lunak Global Mapper. Metode *gridding* yang dipilih yaitu dengan *binning average values*, karena dinilai paling ideal untuk menghasilkan model permukaan yang lebih halus dibanding metode TIN, serta terhindar dari *noise* (Mills, 2020). Sementara itu, nilai *point spacing* didapat dari tahapan pengamatan karakteristik *point cloud* yang memberikan nilai rerata sebesar 0,471651 meter dan berguna untuk menentukan ukuran piksel dari raster yang dihasilkan. Dengan konfigurasi tersebut, dapat dihasilkan nDSM secara otomatis untuk kemudian diekspor dalam format raster (lihat Gambar 3).



Gambar 3 Hasil pembuatan nDSM *first return* (atas) dan *last return* (bawah)


### 2.2.3. Citra intensitas

Citra intensitas dibuat menggunakan perangkat lunak ENVI. Perangkat lunak ini dipilih karena mampu menghasilkan keluaran citra intensitas dengan kualitas radiometrik yang terjaga dan dapat dilakukan *image enhancement* yaitu *contrast stretching*. Citra intensitas yang telah diperbaiki kualitas radiometriknya dengan *contrast stretching*, selanjutnya dapat diproses lebih lanjut untuk diklasifikasi. Akan tetapi, citra-citra tersebut dalam proses pembuatannya menggunakan ENVI ternyata tidak mampu mempertahankan kualitas geometrik dari data *point cloud*, sehingga diperlukan pendefinisian ulang sistem koordinat dan *georeferencing* menggunakan citra yang telah memiliki sistem koordinat. Metode yang digunakan yaitu dengan rektifikasi atau *image to image* pada ArcGIS desktop dengan citra acuan yaitu citra Pleiades (lihat Gambar 4)



Gambar 4 Citra intensitas terkoreksi radiometrik dan geometric

### 2.2.4. Citra Pleiades



Gambar 5 Citra Pleiades berdasarkan 12 blok area kerja

Citra mosaik Pleiades (Gambar 5) dipotong menggunakan tools raster clip dalam dua tahap, yang pertama yaitu memotong citra mosaik sesuai dengan *extent boundary* poligon studi kasus, lalu yang kedua memotong citra yang telah sesuai *boundary* dengan grid blok area dari Terrasolid seperti halnya pada data nDSM.

### 2.2.5. Klasifikasi *Object-Based Image Analysis* (OBIA)

Pada proses segmentasi, nilai parameter masukan (*scale*, *shape*, dan *compactness*) ditentukan dengan cara *trial and error*, yaitu nilai dimasukan secara berulang-ulang sampai mendapatkan bentuk segmen yang proporsional secara visual. Nilai masukan juga memperhatikan kenampakan segmen/objek dalam citra. Selanjutnya, penyusunan skema klasifikasi untuk masing-masing data sensor didasarkan pada interpretasi visual yang mengacu pada skema klasifikasi SNI Penutup Lahan (2010) serta skema klasifikasi multiguna dimensi spasial tingkat IV milik Danoedoro (2006).

Masing-masing data sensor yang telah disegmentasi selanjutnya dilakukan klasifikasi satu per satu. Proses klasifikasi yang digunakan yaitu dengan menggunakan algoritma *Assign Class* pada perangkat lunak *eCognition*, yaitu algoritma klasifikasi sederhana yang mana setiap objek dikelaskan berdasarkan nilai kriteria dengan *threshold condition* ke dalam kelas tertentu. Algoritma *Assign Class* bersifat tidak terbimbing (*unsupervised*), dimana klasifikasi objek tidak menggunakan *training area* untuk acuan klasifikasi. Objek yang berupa segmen-segmen akan dikelaskan jika nilai kriteria pada objek tersebut memenuhi ambang batas yang diberikan. Kriteria-kriteria tersebut berupa kriteria spektral (*layer value*), kriteria

spasial (*shape and area*) dan kriteria tekstur. Penjelasan lebih detail terkait fitur yang digunakan dalam masing-masing data sensor dijelaskan sebagai berikut.

**(a) Citra Pleiades.** Dalam proses klasifikasi citra Pleiades, digunakan fitur-fitur yang memuat kriteria spektral, spasial hingga tekstur. Pada kriteria spektral, selain menggunakan fitur *band* yang sudah ada pada citra, juga menggunakan fitur tambahan berupa *band ratio*, diantaranya yaitu RVI, NDVI dan NDWI. *Band ratio* sangat berguna dalam identifikasi objek pada kelas utama, yang dapat membedakan objek vegetasi, tubuh air, lahan terbuka dan lahan terbangun. Selanjutnya untuk kriteria spasial dan tekstur seperti fitur *shape*, *area* dan *texture after Harralick* digunakan sebagai kriteria penunjang dalam klasifikasi subkelas yang lebih detail. Fitur-fitur yang ditampilkan pada objek bergantung pada skema klasifikasi yang diberikan, dimana pada citra Pleiades skema hasil klasifikasi terdiri dari empat kelas utama dan dua belas subkelas, yaitu Vegetasi (pekarangan, semak, ladang dan pepohonan), Tubuh air (kolam, rawa, danau dan sungai), Lahan terbuka (tanah kosong) dan Lahan terbangun (jalan, bangunan dan permukaan diperkeras lain).

**(b) nDSM.** Jika dibandingkan dengan fitur-fitur yang ada pada citra Pleiades, fitur-fitur yang digunakan pada klasifikasi nDSM lebih sedikit, terutama pada fitur yang menentukan kriteria spektral yang memuat satu band saja (*elevation*) yaitu informasi nilai elevasi tiap objek (digolongkan sebagai kriteria spasial). Selain itu ditambahkan pula fitur lain yaitu nilai intensitas dan nilai *first pulse – last pulse* (Fp – Lp). Fitur Fp – Lp didapat dari selisih citra nDSM *first return* dengan citra nDSM *last return*. Fitur Fp – Lp selanjutnya akan sangat berguna dalam membedakan objek berupa bangunan dengan vegetasi (Jia, 2015). Sementara itu, skema hasil klasifikasi citra nDSM terdiri dari empat kelas utama dan dua belas subkelas yaitu Vegetasi (pekarangan, semak dan pepohonan), Tubuh air (kolam, rawa, danau dan sungai), Lahan terbuka (tanah kosong dan jalan) dan Lahan terbangun (bangunan pemukiman, bangunan infrastruktur dan permukaan diperkeras lain).

**(c) Citra intensitas.** Fitur-fitur yang digunakan sebagai kriteria penentu klasifikasi citra intensitas berjumlah cukup banyak, hampir sebanyak fitur yang digunakan pada klasifikasi citra Pleiades. Kriteria spektral yang digunakan yaitu bersumber dari citra intensitas yang menggunakan tiga *pulse* yang berbeda, yaitu citra intensitas *first return*, citra intensitas *last return*, dan citra intensitas *first of many returns* (FoM). Dari ketiga citra ini selanjutnya diperoleh fitur tambahan untuk klasifikasi objek yaitu fitur F – FoM (citra *first return* dikurangkan dengan citra *first of many returns*), fitur Fp – Lp (citra *first return* dikurangkan dengan citra *last return*) dan fitur intensitas rerata dari citra *first return* dengan *last return*. Fitur F – FoM berguna untuk identifikasi objek vegetasi seperti semak dan pepohonan,

dari objek lainnya. Sementara itu fitur Fp – Lp berguna sebagai fitur penunjang di samping fitur *texture after Harralick* untuk identifikasi objek berupa tubuh air. Fitur intensitas rerata berguna untuk memisahkan objek berupa lahan terbuka dengan lahan terbangun. Berdasarkan fitur-fitur tersebut diperoleh skema hasil klasifikasi yang terdiri dari empat kelas utama dan sebelas subkelas yaitu Vegetasi (semak dan pepohonan), Tubuh air (kolam, rawa, danau dan sungai), Lahan terbuka (pekarangan dan tanah kosong) dan Lahan terbangun (jalan, bangunan dan permukaan diperkeras lain).

Hasil klasifikasi yang telah diperoleh selanjutnya dapat diekspor dari perangkat lunak *eCognition*, dengan menyesuaikan tipe data berupa *shapefile* dalam format data vektor (.shp). Sebelumnya, fitur yang mendeskripsikan kelas objek dapat diekspor bersama dengan *shapefile* sebagai data atribut, dimana fitur yang digunakan adalah *Class-related features*, yaitu mencakup nama kelas dan nama subkelas dari setiap objek yang telah diklasifikasi. Selain itu, ekspor data juga dapat disesuaikan dengan kelas yang diinginkan, yang dalam penelitian ini mencakup semua kelas.

#### 2.2.6. Integrasi data

Setelah hasil klasifikasi ketiga data sensor terekspor, dapat dilakukan *overlay* dengan metode *identify* menggunakan ArcGIS desktop untuk dilakukan analisis kesesuaian kelas objek membentuk dataset komposisi. Analisis dilakukan dengan menghitung persentase jumlah objek yang memiliki kesesuaian kelas yang sama dari seluruh objek. Teknik yang dilakukan untuk menemukan entry objek yang memenuhi kondisi tersebut yaitu dengan membuat query SQL. Jumlah dari objek yang terseleksi dengan query selanjutnya dihitung berdasarkan jumlah total objek yang ter-*identify* untuk mendapatkan nilai persentase kesesuaian kelas objek, sementara dataset komposisi yang terbentuk dapat dimasukkan ke tahap uji akurasi. Hasil perhitungan yang telah didapatkan kemudian dapat dianalisis lebih lanjut.

#### 2.2.7. Uji akurasi

Proses uji akurasi dilakukan pada hasil klasifikasi dataset A (citra Pleiades), dataset B (citra Pleiades dengan citra intensitas) dan dataset C (citra Pleiades dengan nDSM). Uji akurasi diukur dari kecocokan kelas penutup lahan yang terklasifikasi dengan *ground truth* dari citra temporal *Google Earth* yang diinterpretasi secara visual. Digunakannya citra temporal *Google Earth* karena data acuan awal untuk proses uji akurasi semula akan menggunakan orthofoto kawasan studi kasus yang diakuisisi bersama dengan data LiDAR, namun data LiDAR dengan data citra satelit berselisih waktu sekitar empat belas bulan. Citra *Google Earth* yang digunakan memiliki waktu perekaman berdekatan dengan data citra satelit yaitu pada tanggal 19 Agustus 2013. Titik-titik koordinat *ground truth* yang dipilih ditampilkan dalam bentuk *ground check point*, dimana diambil secara acak dan merata di

seluruh tutupan lahan area studi kasus dengan jumlah sebanyak 36 titik sebagaimana ditunjukkan oleh Gambar 6. Uji akurasi dilakukan menggunakan perangkat lunak ArcGIS desktop untuk pengecekan hasil klasifikasi dan Google Earth untuk pengecekan *ground truth*.



Gambar 6 Sebaran *ground check points* untuk uji akurasi

### 3. Hasil dan Pembahasan

#### 3.1. Hasil segmentasi

##### 3.1.1. Citra Pleiades

Nilai parameter segmentasi masukan yaitu *shape* sebesar 0.8 dan *scale* sebesar 50 menunjukkan bahwa kenampakan objek pada citra Pleiades sangat heterogen secara spasial, sementara nilai parameter *compactness* sebesar 0.4 menunjukkan citra memiliki tekstur yang normal cenderung halus untuk bisa membedakan bentuk satu objek dengan objek lainnya. Hasil segmentasi ditunjukkan oleh Gambar 7.




Gambar 7 Hasil segmentasi citra Pleiades

##### 3.1.2. nDSM

Berdasarkan hasil segmentasi, dapat diketahui bahwa citra nDSM berbeda dengan citra Pleiades. Perbedaan paling mencolok yaitu nilai parameter *scale* sebesar 20,


yang berarti lebih kecil dari nilai pada citra Pleiades. Hal ini dapat disebabkan kenampakan objek dalam nDSM lebih sedikit dibanding kenampakan objek dalam citra Pleiades. Sementara itu, parameter *shape* bernilai minimum sebesar 0.1, yang berarti bahwa homogenitas piksel-piksel dalam nDSM jauh lebih mudah dibentuk menjadi segmen secara spektral daripada secara spasial. Nilai parameter *compactness* sebesar 0.6 menunjukkan bahwa tekstur pada nDSM cukup berpengaruh dalam membedakan bentuk satu objek dengan objek lainnya (lihat Gambar 8)



Gambar 8 Hasil segmentasi nDSM

##### 3.1.3. Citra intensitas

Berdasarkan nilai parameter masukan, citra intensitas memiliki kenampakan objek yang cenderung heterogen secara spektral karena parameter *shape* bernilai cukup kecil yaitu sebesar 0,3. Nilai parameter *scale* sebesar 80 dimaksudkan agar ukuran segmen proporsional terhadap cakupan citra yang sangat luas. Sementara itu, nilai parameter *compactness* sebesar 1,0 menunjukkan bahwa tingkat kekasaran citra intensitas sangat tinggi dalam membedakan objek satu dengan lainnya. (lihat Gambar 9)




Gambar 9 Hasil segmentasi citra intensitas


3.2. Hasil klasifikasi

3.2.1. Hasil ekspor klasifikasi


Hasil klasifikasi citra Pleiades, nDSM dan citra intensitas ditunjukkan oleh Gambar 10, Gambar 11 dan Gambar 12.



Gambar 10 Hasil klasifikasi citra Pleiades



Gambar 11 Hasil klasifikasi nDSM



Gambar 12 Hasil klasifikasi citra intensitas

Dengan menggunakan simbol warna yang sama, dapat dilihat bahwa hasil klasifikasi dari tiga data sensor yang

berbeda juga memberikan hasil klasifikasi yang berbeda-beda. Pada hasil klasifikasi dari citra intensitas terlihat bahwa terdapat fitur yang menyerupai garis di bagian atas, garis tersebut merupakan bagian sambungan yang kurang sempurna dari citra intensitas yang berasal dari jalur terbang yang berbeda menggunakan *tools merge* dari *ArcToolbox*.

Selain tampilan secara visual, hasil klasifikasi juga memiliki data atribut yang ditampilkan dalam *attribute table* yang memuat informasi setiap objek yaitu berupa atribut KELAS dan SUBKELAS. Informasi ini selanjutnya dapat disertakan dalam analisis dengan *overlay* metode *identify* untuk dicocokkan dengan data atribut dari hasil klasifikasi data sensor lainnya.

3.2.2. Hasil *overlay* dan analisis *query*

Proses *overlay identify* berfokus pada penggabungan (*overlay*) data spasial (objek hasil klasifikasi) dari dua data sensor yang berbeda dengan tetap mempertahankan data atribut dari masing-masing data sensor. Hasil *overlay identify* mengakibatkan jumlah objek dari masing-masing dataset menjadi berlipat ganda yang jumlahnya sangat dipengaruhi oleh jumlah dan ukuran dari objek pada masing-masing data sensor saat proses segmentasi. Untuk dapat dilakukan analisis kesesuaian kelas objek, diperlukan informasi jumlah objek yang memenuhi kondisi dimana atribut KELAS\_1 sama dengan atribut KELAS\_2. Pencarian data berdasarkan kondisi tersebut dilakukan dengan menggunakan *query SQL*.

3.3. Skema klasifikasi

Skema klasifikasi ditunjukkan oleh Tabel 1 berikut.

Tabel 1 Skema klasifikasi tutupan lahan 3 data sensor

| Kelas           | Pleiades                  | nDSM                      | Intensitas                |
|-----------------|---------------------------|---------------------------|---------------------------|
| Tubuh air       | kolam                     | kolam                     | kolam                     |
|                 | sungai                    | sungai                    | sungai                    |
|                 | danau                     | danau                     | danau                     |
|                 | rawa                      | rawa                      | rawa                      |
|                 |                           |                           | pekarangan                |
| Lahan terbuka   | Tanah kosong              | Tanah kosong              | Tanah kosong              |
|                 |                           | jalan                     | jalan                     |
| Lahan terbangun | bangunan                  | Bangunan pemukiman        | bangunan                  |
|                 |                           | Bangunan infrastruktur    |                           |
|                 | Permukaan diperkeras lain | Permukaan diperkeras lain | Permukaan diperkeras lain |
|                 |                           |                           |                           |
| Jumlah subkelas | 12                        | 12                        | 11                        |

3.3.1. Citra Pleiades

Berdasarkan skema klasifikasi, citra Pleiades sangat

unggul dari segi spektral yang memiliki empat kanal *band* (*red, green, blue* dan NIR) serta *band ratio* (RVI, NDVI dan NDWI) dalam mengidentifikasi berbagai macam objek. Selain itu, terdapat juga subkelas ladang dari kelas Vegetasi yang tidak ditemukan pada subkelas dari data sensor lainnya, yang dalam identifikasinya menggunakan kriteria spasial dan kriteria tekstur untuk membedakan subkelas tersebut dengan subkelas lain dari kelas Vegetasi.

### 3.3.2. nDSM

Dari skema klasifikasi nDSM, terdapat perbedaan dengan skema klasifikasi pada citra Pleiades. Perbedaan ini sangat terlihat pada subkelas jalan yang termasuk dalam kelas Lahan terbuka sementara pada kelas Lahan terbangun subkelas bangunan terbagi menjadi subkelas bangunan pemukiman dan subkelas bangunan infrastruktur. Hal ini dikarenakan objek berupa jalan memiliki elevasi yang relatif sama dengan objek tanah kosong dibanding dengan objek lahan terbangun. Sementara itu, pembagian subkelas bangunan menjadi dua subkelas dapat dilakukan dengan mudah berdasarkan nilai elevasi relatif. Selain itu, perbedaan lainnya juga terdapat pada tidak adanya subkelas ladang, dikarenakan fitur-fitur identifikasi yang terbatas.

### 3.3.3. Citra intensitas

Dilakukan juga identifikasi perbedaan skema klasifikasi citra intensitas dengan skema klasifikasi pada citra Pleiades. Dapat dilihat bahwa skema klasifikasi pada citra intensitas memiliki susunan tersendiri seperti halnya pada skema klasifikasi data lainnya. Pada skema klasifikasi ini terlihat banyak kemiripan susunan kelas dengan skema klasifikasi yang digunakan pada citra Pleiades. Perbedaan paling mencolok yaitu pada subkelas pekarangan yang termasuk dalam kelas Lahan terbuka alih-alih kelas Vegetasi. Hal ini dikarenakan objek pekarangan memiliki karakteristik intensitas yang cenderung menyerupai tanah kosong dan tidak memberikan nilai yang signifikan pada citra *first of many return* seperti halnya subkelas vegetasi lainnya. Selain itu, perbedaan lainnya juga terdapat pada tidak adanya subkelas ladang, dikarenakan fitur-fitur identifikasi yang terbatas.

## 3.4. Hasil uji akurasi

Dari sebanyak 36 titik uji, pada dataset A atau Pleiades didapat jumlah objek yang sesuai dengan *ground truth* sebanyak 16 titik menghasilkan nilai *overall accuracy* sebesar 44,44%. Sementara itu, dengan integrasi dari data sensor LiDAR, pada dataset B (Pleiades ditambah citra intensitas) didapat sebanyak 23 titik uji yang akurat menghasilkan nilai *overall accuracy* sebesar 63,89% sementara pada dataset C (Pleiades ditambah nDSM) didapat pula sebanyak 23 titik uji yang akurat menghasilkan nilai *overall accuracy* sebesar 63,89%.

### 3.4.1 Dataset A (Pleiades)

Hasil pengujian dataset A yaitu citra Pleiades ditunjukkan dalam Tabel 2. Dalam hal akurasi pembuat

peta (*producer accuracy*), terdapat empat subkelas yang diklasifikasi secara akurat yaitu semak, kolam, danau dan sungai, sementara untuk subkelas pekarangan, rawa, tanah kosong dan permukaan diperkeras lain memiliki akurasi yang paling rendah dimana tidak dikelaskan dengan benar (ditunjukkan dari nilai omisi). Subkelas yang bernilai 'NULL' menunjukkan bahwa tidak ada *ground check point* yang merepresentasikan subkelas tersebut. Sementara itu, dalam hal akurasi pengguna peta (*user accuracy*), ladang menjadi subkelas yang paling mudah untuk diidentifikasi, sementara kelas lainnya cenderung sulit untuk dibedakan satu sama lain (ditunjukkan dari nilai komisi). Subkelas yang bernilai 'NULL' menunjukkan bahwa tidak ada objek dari hasil klasifikasi pada 36 titik yang merepresentasikan subkelas tersebut. Dengan demikian, rendahnya akurasi keseluruhan dari hasil klasifikasi dataset A (Pleiades) dikarenakan banyak objek yang masih sulit dibedakan satu sama lain.

Tabel 2 Persentase akurasi subkelas objek terhadap *producer* dan *user accuracy* dataset A

|                           | Producer accuracy | Omisi | User accuracy | komisi |
|---------------------------|-------------------|-------|---------------|--------|
| Pekarangan                | 25%               | 75%   | 33%           | 67%    |
| Ladang                    | NULL              | NULL  | 100%          | 0%     |
| Semak                     | 75%               | 25%   | 0%            | 100%   |
| Pepohonan                 | 40%               | 60%   | 20%           | 80%    |
| Kolam                     | 100%              | 0%    | 0%            | 100%   |
| Rawa                      | 0%                | 100%  | 0%            | 100%   |
| danau                     | 100%              | 0%    | 0%            | 100%   |
| Sungai                    | 75%               | 25%   | 0%            | 100%   |
| Tanah kosong              | 0%                | 100%  | Null          | NULL   |
| jalan                     | Null              | NULL  | 0%            | 100%   |
| Bangunan                  | 44%               | 56%   | 0%            | 100%   |
| Permukaan diperkeras lain | 0%                | 100%  | 0%            | 100%   |

### 3.4.2 Dataset B

Hasil pengujian dataset B yaitu citra Pleiades+citra intensitas ditunjukkan dalam Tabel 3. Dalam hal akurasi pembuat peta, terdapat lima subkelas yang diklasifikasi secara akurat yaitu semak, kolam, danau, sungai dan bangunan, sementara untuk rawa, tanah kosong dan permukaan diperkeras lain menjadi subkelas yang paling tidak akurat (ditunjukkan dari nilai omisi yang besar). Subkelas ladang dan jalan bernilai 'NULL' menunjukkan bahwa tidak ada *ground check point* yang merepresentasikan subkelas tersebut. Selanjutnya, dalam hal akurasi pengguna peta, terdapat lima subkelas yang paling mudah untuk diidentifikasi yaitu semak, danau, sungai, tanah kosong dan bangunan, sementara terdapat empat subkelas yang masih sulit untuk diidentifikasi yaitu ladang, rawa, jalan dan permukaan diperkeras lain.



Tabel 3 Persentase akurasi subkelas objek terhadap *producer* dan *user accuracy* dataset B

|                           | Producer accuracy | Omisi | User accuracy | komisi |
|---------------------------|-------------------|-------|---------------|--------|
| Pekarangan                | 50%               | 50%   | 67%           | 33%    |
| Ladang                    | NULL              | NULL  | 0%            | 100%   |
| Semak                     | 75%               | 25%   | 100%          | 0%     |
| Pepohonan                 | 60%               | 40%   | 60%           | 40%    |
| Kolam                     | 100%              | 0%    | 67%           | 33%    |
| Rawa                      | 0%                | 100%  | 0%            | 100%   |
| danau                     | 100%              | 0%    | 100%          | 0%     |
| Sungai                    | 75%               | 25%   | 100%          | 0%     |
| Tanah kosong              | 25%               | 75%   | 100%          | 0%     |
| jalan                     | NULL              | NULL  | 0%            | 100%   |
| Bangunan                  | 89%               | 11%   | 80%           | 20%    |
| Permukaan diperkeras lain | 0%                | 100%  | 0%            | 100%   |

Tidak ada di antara subkelas yang bernilai 'NULL' menunjukkan bahwa semua objek dari hasil klasifikasi pada 36 titik telah merepresentasikan semua subkelas. Dengan demikian, akurasi hasil klasifikasi dataset B memiliki kualitas yang lebih baik dibanding dataset A yang hanya memanfaatkan citra Pleiades.

### 3.4.3 Dataset C

Hasil pengujian dataset C yaitu citra Pleiades+nDSM ditunjukkan dalam Tabel 4.

Tabel 4 Persentase akurasi subkelas objek terhadap *producer* dan *user accuracy* dataset C

|                           | Producer accuracy | Omisi | User accuracy | komisi |
|---------------------------|-------------------|-------|---------------|--------|
| Pekarangan                | 25%               | 75%   | 33%           | 67%    |
| Ladang                    | NULL              | NULL  | 0%            | 100%   |
| Semak                     | 75%               | 25%   | 100%          | 0%     |
| Pepohonan                 | 80%               | 20%   | 57%           | 43%    |
| Kolam                     | 100%              | 0%    | 67%           | 33%    |
| Rawa                      | 0%                | 100%  | 0%            | 100%   |
| danau                     | 100%              | 0%    | 100%          | 0%     |
| Sungai                    | 75%               | 25%   | 100%          | 0%     |
| Tanah kosong              | 75%               | 25%   | 100%          | 0%     |
| jalan                     | NULL              | NULL  | NULL          | NULL   |
| Bangunan                  | 67%               | 33%   | 75%           | 25%    |
| Permukaan diperkeras lain | 0%                | 100%  | 0%            | 100%   |

Jika dibandingkan dengan dataset B, persentase akurasi subkelas objek pada dataset C hampir sama, tetapi dengan distribusi yang berbeda. Dataset C memiliki akurasi pembuat peta yang baik pada enam subkelas yaitu semak, pepohonan, kolam, danau, sungai dan tanah kosong yang mampu diklasifikasikan secara akurat. Akan tetapi, untuk

pekarangan, rawa dan permukaan diperkeras lain masih menjadi subkelas yang paling tidak akurat (dintujukan dari nilai omisi). Subkelas ladang dan jalan bernilai 'NULL' menunjukkan bahwa tidak ada *ground check point* yang merepresentasikan kelas tersebut. Sementara itu, dari segi akurasi pengguna peta, dataset C memiliki akurasi yang hampir sama dengan dataset B, hanya saja dengan akurasi bangunan yang sedikit lebih rendah. Selain itu, subkelas jalan pada dataset ini bernilai 'NULL' karena tidak ada objek dari hasil klasifikasi pada 36 titik yang merepresentasikan subkelas tersebut. Dengan demikian, akurasi hasil klasifikasi dataset C juga masih lebih baik dibanding dengan dataset A dan setara dengan dataset B tetapi hanya berbeda pada distribusi subkelasnya.

### 3.5. Hasil analisis kesesuaian kelas objek

Berdasarkan hasil yang diperoleh pada Tabel 5, dapat diketahui bahwa hasil analisis secara SIG menggunakan *tools identify* dan *query SQL* pada ketiga dataset komposisi memberikan persentase kesesuaian kelas objek yang berbeda-beda. Berdasarkan nilai rerata, dataset C memperoleh kesesuaian kelas objek paling tinggi yaitu sebesar 45,78% dibanding dataset B yang sebesar 36,61%, dimana nilai persentase rerata yang dihasilkan pada dataset C cukup signifikan jika dibandingkan dengan dataset B. Salah satu faktor yang menyebabkan hal tersebut yaitu karena dipengaruhi oleh jumlah subkelas dari tiap data yang menyusun komposisi. Pada dataset C, komposisi tersusun dari 12 subkelas citra Pleiades dan 12 subkelas citra nDSM, sementara pada dataset B dengan komposisi tersusun dari 11 subkelas citra intensitas dan 12 subkelas citra Pleiades. Hasil analisis kesesuaian objek antardata ditunjukkan dalam Tabel 5


Tabel 5 Persentase hasil analisis kesesuaian objek antardata

| Nomor blok    | Dataset B (Pleiades+Intensitas) | Dataset C (Pleiades+nDSM) |
|---------------|---------------------------------|---------------------------|
| 001           | 35,67%                          | 49,96%                    |
| 002           | 30,31%                          | 55,11%                    |
| 003           | 33,75%                          | 42,44%                    |
| 004           | 36,13%                          | 56,00%                    |
| 005           | 40,60%                          | 31,47%                    |
| 006           | 38,91%                          | 49,00%                    |
| 007           | 30,60%                          | 52,80%                    |
| 008           | 39,66%                          | 40,35%                    |
| 009           | 40,02%                          | 44,08%                    |
| 010           | 40,22%                          | 51,97%                    |
| 011           | 31,73%                          | 37,65%                    |
| 012           | 41,65%                          | 38,51%                    |
| <b>Rerata</b> | <b>36,61%</b>                   | <b>45,78%</b>             |
| <b>Min</b>    | <b>30,31%</b>                   | <b>31,47%</b>             |
| <b>max</b>    | <b>41,65%</b>                   | <b>56,00%</b>             |


#### 3.5.1 Dataset B

Berdasarkan analisis, terdapat 322 objek yang dikelaskan sebagai bangunan pada citra intensitas tetapi

dikelaskan sebagai pepohonan pada citra Pleiades. Ketidaksesuaian klasifikasi tersebut dikarenakan adanya *noise* yang belum dihilangkan dari citra intensitas sehingga menghasilkan efek *salt and pepper* pada hasil klasifikasi (Mills, 2020). Ketidak sesuaian klasifikasi akibat *noise*, efek bayangan dan perubahan tutupan lahan ditunjukkan dalam Gambar 13, Gambar 14 dan Gambar 15.



Gambar 13 Ketidaksesuaian klasifikasi akibat *noise*



Gambar 14 Ketidaksesuaian klasifikasi akibat efek bayangan

Terdapat pula 306 objek yang dikelaskan sebagai pepohonan dan 143 objek dikelaskan sebagai semak pada citra intensitas tetapi objek-objek tersebut dikelaskan sebagai bangunan pada citra Pleiades. Hal ini dapat disebabkan karena terdapat efek bayangan pada citra Pleiades yang tidak ditemukan pada citra intensitas.




Gambar 15 Ketidaksesuaian klasifikasi akibat perubahan tutupan lahan

Selanjutnya, terdapat 113 objek yang dikelaskan sebagai bangunan pada citra intensitas tetapi dikelaskan sebagai pekarangan pada citra Pleiades. Hal ini salah satunya dapat disebabkan karena sempat terjadinya perubahan tutupan lahan di selisih perbedaan waktu akuisisi kedua data.


### 3.5.2 Dataset C

Berdasarkan hasil analisis, sebagian besar objek yang tidak bersesuaian klasifikasinya pada citra nDSM dikelaskan sebagai tanah kosong, tetapi pada citra Pleiades, sebanyak 76 objek dikelaskan sebagai kolam, 52 objek dikelaskan sebagai sungai, 76 objek dikelaskan sebagai pekarangan dan 38 objek dikelaskan sebagai bangunan.



Gambar 16 Ketidaksesuaian klasifikasi akibat interaksi *pulse* LiDAR dengan permukaan air

Penyebab ketidaksesuaian hasil klasifikasi tersebut diduga pada saat *pulse* LiDAR mengenai objek yang berupa permukaan air, sebagian *pulse* berhasil dipantulkan karena terdapat objek di permukaan air tersebut (yang memberikan data elevasi) dan sebagian lainnya yang mengenai permukaan air langsung diserap (tidak memberikan data elevasi) (Suradji, 2020). Ketidak sesuaian klasifikasi akibat interaksi *pulse* LIDAR, perbedaan fitur spektral dan karakteristik segmen ditunjukkan dalam Gambar 16, Gambar 17 dan Gambar 18.




Gambar 17 Ketidaksesuaian klasifikasi akibat perbedaan fitur spektral dua sensor

Pada Gambar 18, terdapat objek yang dikelaskan sebagai pekarangan pada citra Pleiades tetapi dikelaskan sebagai tanah kosong pada citra nDSM. Objek tersebut dalam citra Pleiades kemungkinan adalah tumbuhan air yang mengapung, sebab mampu memberikan nilai RVI dan NDVI yang signifikan. Sementara itu, objek yang berupa pekarangan dan lahan kosong pada citra nDSM umumnya sangat sulit untuk dibedakan, terlebih bila ketinggian vegetasi sangat rendah (tidak lebih dari satu meter) dan tidak memberikan nilai yang signifikan pada citra  $F_p - L_p$  (*First return - Last return*) atau juga karena nilai intensitas yang terlalu rendah, dimana sangat riskan untuk dikelaskan ke dalam Lahan terbuka atau Lahan terbangun.

Perbedaan hasil klasifikasi juga dapat disebabkan oleh perbedaan bentuk dan ukuran segmen. Pada Gambar 19 terlihat bahwa segmen yang dibentuk pada citra Pleiades lebih kompak dan detail daripada segmen pada citra nDSM yang lebih halus. Akan tetapi, menurut Guo dkk., (2007), bentuk segmen yang terlalu detail pada citra Pleiades dapat menghasilkan *over classification* dimana struktur objek menjadi terpecah-pecah dan dikelaskan ke kelas yang berbeda-beda. Sementara itu, bentuk segmen yang halus pada nDSM juga tidak memberikan hasil yang lebih baik dimana juga terjadi kesalahan klasifikasi yang

menyebabkan objek yang berupa tepi-tepi atap bangunan menjadi satu segmen dengan pepohonan di sekitarnya dan dikelaskan sebagai pepohonan.



Gambar 18 Ketidaksesuaian klasifikasi akibat perbedaan karakteristik segmen

#### 4. Kesimpulan

Berdasarkan hasil dan pembahasan penelitian yang didapatkan, diperoleh kesimpulan sebagai berikut:

1. Hasil klasifikasi citra Pleiades (dataset A) dengan metode OBIA pada area studi kasus secara keseluruhan menghasilkan akurasi yang cukup rendah yaitu sebesar 44,44%,
2. Hasil klasifikasi citra Pleiades yang telah ditambahkan data LiDAR (citra intensitas dan nDSM) dimana masing-masing membentuk dataset B dan dataset C, keduanya mampu meningkatkan akurasi hasil klasifikasi sebesar 19,45% atau hampir 20% dibanding dataset A yang hanya memanfaatkan sensor tunggal Pleiades,
3. Rendahnya nilai akurasi hasil klasifikasi pada penelitian ini jika mengacu pada SNI Penutup dan Penggunaan Lahan (minimal 70%) dapat disebabkan karena jumlah titik sampel yang sebanyak 36 buah, sangat jauh dari jumlah yang proporsional terhadap total jumlah objek terklasifikasi yang mencapai ribuan, yang seharusnya mencakup 20% dari total jumlah objek terklasifikasi untuk dapat memberikan hasil uji yang signifikan,
4. Dataset B dan dataset C masing-masing menghasilkan persentase kesesuaian kelas objek yang berbeda, dimana berdasarkan nilai terendah dan tertinggi pada dataset B menghasilkan kesesuaian objek dalam rentang 30% hingga 41%, dan pada dataset C menghasilkan kesesuaian objek dalam rentang 31% hingga 56% dimana kesesuaian kelas objek tidak berpengaruh pada peningkatan akurasi hasil klasifikasi terhadap *ground truth*.

#### 5. Pernyataan Konflik Kepentingan

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

## 6. Referensi

- Achsan, A. C. (2017). Pemanfaatan Citra Landsat untuk Klasifikasi Tutupan Lahan Lanskap Perkotaan Kota Palu. *E-Journal Arsitektur Lansekap*, 59.
- Alonso, M., & Malpica, J. (2010). *Satellite Imagery Classification with Lidar Data*. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science.
- Aristalindra, F., Santosa, P. B., Diyono & Subaryono. (2020). Evaluasi Pemanfaatan Citra Tegak Satelit Resolusi Tinggi untuk Percepatan Pembuatan Peta Blok Pajak Bumi dan Bangunan (PBB-P2) secara Partisipatif di Desa Triharjo, Kabupaten Bantul, DIY. *Journal of Geospatial Information Science and Engineering*, vol 3 no 1. <https://doi.org/10.22146/jgise.55788>
- Awrangjeb, M., Zhang, C., & Fraser, C. (2013). Automatic extraction of building roofs using LiDAR data and multispectral Imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 83, 1-18.
- Danoedoro, P. (2006). *Versatile Land-use Information for Local Planning in Indonesia*. Centre for Remote Sensing and Spatial Information Science (CRSSIS): School of Geography, Planning and Architecture. The University of Queensland.
- Gilani, S., Awrangjeb, M., & Lu, G. (2015). *Fusion of LiDAR data and multispectral imagery for effective building detection based on graph and connected component analysis*. The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 40, 65.
- Guo, Q. H., Kelly, M., Gong, P., & Liu, D. (2007). *An object-based classification approach in mapping tree mortality using high spatial resolution imagery*. GIScience dan Remote Sensing.
- Istarno. (2016). *Buku Ajar Penginderaan Jauh Sensor Aktif Airborne Laser Scanning/Lidar*. Yogyakarta: Departemen Teknik Geodesi UGM.
- Jia, Y. (2015). *Object-based land cover classification with orthophoto and lidar data*. Stockholm: School of Architecture and the Built Environment (KTH) Stockholm, Sweden.
- Kushardono, D. (1997). Model Klasifikasi Penutup Lahan Data Multisensor Radar-Optik. *Majalah LAPAN* no.83.
- Kushardono, D. (2017). *Klasifikasi Digital Penginderaan Jauh*. Bogor: Penerbit IPB Press.
- Mills, M. (2020, June 23). *Elevation Grid Creation in Global Mapper: Creating a DTM*. Retrieved from Insight from Blue Marble Geographics: <https://blog.bluemarblegeo.com/2020/06/23/elevation-grid-creation-in-global-mapper-creating-a-dtm/>
- Prayogo, L. M. & Basith, A. (2020). Uji Performa Citra Worldview 3 dan Sentinel 2A untuk Pemetaan Kedalaman Laut Dangkal (Studi Kasus di Kepulauan Karimunjawa, Jawa Tengah). *Journal of Geospatial Information Science and Engineering*, vol 3 no 2. <https://doi.org/10.22146/jgise.59572>
- Sampurno, R., & Thoriq, A. (2016). Klasifikasi Tutupan Lahan Menggunakan Citra Landsat 8 Operational Land Imager (OLI) di Kabupaten Sumedang. *Jurnal Teknotan* Vol.10.2.
- Santosa, P. B. (2016). Evaluation of satellite image correction methods caused by differential terrain illumination. *Forum Geografi*, vol 30 no 1. doi: [10.23917/forgeo.v30i1.1768](https://doi.org/10.23917/forgeo.v30i1.1768)
- SNI 7645. (2010). SNI 7645: 2010 tentang Klasifikasi Penutup Lahan. Badan Standardisasi Nasional.
- Suradji, A. (2020, May 18). Webinar PT Waindo Specterra. Retrieved from Teknologi GIS Enterprise, Dashboard Operation, CSRT, airborne LiDAR dan Aplikasi Pemanfaatannya di Bidang Pertambangan: <https://youtu.be/1e9LgCy1vqs>
- Uzar, M., & Yastikli, N. (2013). *Automatic building extraction using LiDAR and aerial photographs*. *Boletim de Ciências Geodésicas*, 153-171.
- Wahdaniyat, H. (2019, August 20). Ruang Terbuka Hijau yang Masih Terpinggirkan di Indonesia. Retrieved from Direktorat Jenderal Cipta Karya, Kementerian Pekerjaan Umum dan Perumahan Rakyat: [http://ciptakarya.pu.go.id/pbl/index.php/detail\\_berita/565/ruang-terbuka-hijau-yang-masih-terpinggirkan-di-indonesia](http://ciptakarya.pu.go.id/pbl/index.php/detail_berita/565/ruang-terbuka-hijau-yang-masih-terpinggirkan-di-indonesia)