

KLASIFIKASI PENUTUP LAHAN MENGGUNAKAN DATA LIDAR DENGAN PENDEKATAN *MACHINE LEARNING*

(*LAND COVER CLASSIFICATION USING LIDAR DATA WITH MACHINE LEARNING APPROACH*)

Mochamad Irwan Hariyono^{1,2,a}, Ratna Sari Dewi^{2,a}, Rokhmatullah^{1,a}, Mangapul P Tambunan^{1,a}

¹Magister Ilmu Geografi, Fakultas Matematika dan IPA, Universitas Indonesia

²Badan Informasi Geospasial (BIG)

^aKontributor Utama

e-mail: moch.irwan@ui.ac.id

Diterima : 19 Oktober 2021; Direvisi :8 Januari 2022; Disetujui : 10 Januari 2022

ABSTRACT

Lidar is a remote sensing technology. Lidar data is widely used and has been developed for mapping, detailed spatial planning, and natural disaster analysis. In its development for Lidar data management, software applications are widely used as well as by using built algorithms such as machine learning. The research aims to utilize Lidar data for land cover classification using machine learning, namely Support Vector Machine (SVM). The research location is Tanjung Karang village, Mataram City, Lombok. The classification applied is a supervised classification in which the training data is needed to perform the classification. The predicted land cover class in this study is limited to buildings, vegetation, roads, open land. The data used for classification is derived from Lidar, namely DTM, DSM, nDSM, and Intensity. The classification scheme used is one data input and a combination of data. The reference data used is a topographic map (Topographic map of Indonesia). The results showed that the classification with a data combination scheme had a better accuracy value than the one data classification scheme, which increased accuracy by about 15-20%. This shows that there are complementary factors between the data to be able to identify objects in the classification process.

Keywords: *Lidar, remote sensing, classification, machine learning*

ABSTRAK

Lidar merupakan salah satu teknologi penginderaan jauh. Data Lidar banyak digunakan dan telah dikembangkan untuk kebutuhan pemetaan, perencanaan detail tata ruang, serta analisa bencana alam. Dalam perkembangannya untuk pengelolaan data Lidar banyak digunakan aplikasi perangkat lunak maupun dengan menggunakan algoritma yang dibangun seperti *machine learning*. Tujuan dari penelitian ini adalah memanfaatkan data Lidar untuk klasifikasi penutup lahan dengan menggunakan *machine learning*, yaitu *Support Vecktor Machine* (SVM). Lokasi penelitian adalah desa Tanjung Karang, Kota Mataram, Lombok. Klasifikasi yang diterapkan adalah *supervised classification* dimana dibutuhkan data *training* untuk melakukan klasifikasi. Kelas penutup lahan yang diprediksi pada penelitian ini terbatas pada objek bangunan, vegetasi, jalan, lahan terbuka. Data yang digunakan untuk klasifikasi adalah data turunan dari Lidar yaitu DTM, DSM, nDSM dan Intensity. Skema klasifikasi yang digunakan adalah dengan data input satu data dan kombinasi data. Data referensi yang digunakan adalah peta topografi (Peta Rupabumi Indonesia). Hasil penelitian menunjukkan bahwa klasifikasi dengan skema kombinasi data memiliki nilai akurasi yang lebih baik dibandingkan dengan skema klasifikasi satu data, yaitu mengalami peningkatan akurasi sekitar 15-20%. Hal ini menunjukkan bahwa ada faktor saling melengkapi antar data untuk dapat mengidentifikasi objek dalam proses klasifikasi.

Kata kunci: Lidar, penginderaan jauh, klasifikasi, *machine learning*

1 PENDAHULUAN

Penutup lahan merupakan salah satu tema yang diinformasikan pada suatu peta. Penutup lahan adalah objek fisik yang menutup permukaan tanah yang meliputi vegetasi (alami maupun buatan), bangunan, tubuh air, es, batuan

dan permukaan pasir atau padang pasir (Berrios, 2004), dan bisa berupa objek yang dibangun oleh manusia ataupun objek yang muncul secara alami di permukaan bumi (Hariyono, 2018). Informasi penutup lahan penting untuk disampaikan, hal ini bisa digunakan

untuk berbagai analisa seperti perubahan penutup lahan dari waktu ke waktu, rencana tata guna lahan, perencanaan tata kota maupun analisa yang lain. Berbagai metode dilakukan untuk menghasilkan peta atau informasi penutup lahan, salah satunya adalah dengan melakukan digitasi *on screen* terhadap data yang tersedia. Data yang digunakan pada proses digitasi *on screen* sebagian besar adalah data penginderaan jauh, seperti citra satelit dan foto udara. Data-data penginderaan jauh selain dalam format raster, terdapat juga data lain yang bisa digunakan untuk analisa penutup lahan yaitu data Lidar (*Light Detection and Ranging*).

Digitasi *on screen* membutuhkan waktu dan biaya yang tidak sedikit, selain itu perlu didukung sumber daya manusia yang cukup berpengalaman. Dengan kondisi tersebut, untuk kebutuhan percepatan pemetaan maka perlu adanya solusi dalam mengatasinya. Berbagai metode dilakukan untuk mendukung percepatan pemetaan, salah satunya adalah otomatisasi dengan menggunakan pengembangan algoritma yaitu *machine learning*.

Tujuan dari penelitian ini adalah melakukan klasifikasi penutup lahan menggunakan data penginderaan jauh yaitu Lidar dengan algoritma *machine learning*. Metode *machine learning* yang dipakai adalah *Support Vector Machine* (SVM), metode ini dipilih karena sedang berkembang untuk klasifikasi multi kelas. Dalam komunitas *machine learning*, SVM merupakan salah satu pengklasifikasi yang paling umum digunakan untuk mengkategorikan data menggunakan *hyperplane* pemisah yang optimal (Cortes & Vapnik, 1995). Salah satu keuntungan utama dari penggunaan SVM untuk aplikasi data penginderaan jauh adalah kemampuannya untuk menangani data berdimensi tinggi menggunakan sampel pelatihan yang relatif sedikit (Melgani & Bruzzone, 2004).

Beberapa penelitian telah dilakukan untuk klasifikasi penutup lahan dengan menggunakan data Lidar, antara lain: penggunaan data Lidar *full-waveform* untuk klasifikasi wilayah kota (Mallet *et al.*, 2011); klasifikasi penutup lahan dengan metode *object based* dengan menggunakan data Lidar *first return* dan

last return (Chen & Gao, 2014); melakukan perbandingan hasil klasifikasi penutup lahan dengan metode *deep learning* dan *machine learning* (Panet *et al.*, 2019); klasifikasi penutup lahan dengan menggunakan sumber data Lidar kombinasi tinggi dan intensitas (Zhou, 2013); klasifikasi penutup lahan dengan menggunakan data Lidar *single-return* (Ekhtari *et al.*, 2018), selain itu dilakukan penelitian lain untuk klasifikasi dengan berdasarkan tanda spektral dari data penginderaan jauh (Yan *et al.*, 2015).

2 METODOLOGI

2.1 Lokasi dan Data

Data yang digunakan dalam penelitian ini adalah Lidar wilayah Desa Tanjung Karang, Kota Mataram, Lombok. Akuisisi data Lidar dilakukan oleh Badan Informasi Geospasial (BIG) tahun 2016. Data Lidar yang digunakan memiliki kerapatan 8 ppm (*points per square meter*), dimana per meter persegi terdapat atau tersebar 8 titik laser Lidar (*point cloud*). Data tersebut memiliki akurasi vertikal kurang dari 20 cm, dan akurasi horizontal 30-50 cm. Lokasi tersebut dipilih dengan pertimbangan objek-objek penutup lahan di wilayah tersebut yang variatif. Sehingga hasil klasifikasi dengan pendekatan *machine learning* tersebut diharapkan bisa cukup mewakili wilayah lain dengan kondisi penutup lahan yang hampir sama. Data Lidar yang digunakan bisa dilihat pada Gambar 2-1.



Gambar 2-1. Data Lidar lokasi penelitian

2.2 Metode Penelitian

Penelitian ini menggunakan klasifikasi dengan pendekatan *Support Vector Machine* (SVM). SVM merupakan salah satu dari metode *machine learning*

yang sudah lama digunakan. Pada awalnya SVM digunakan untuk klasifikasi dua kelas penutup lahan, namun sekarang berkembang menjadi multi kelas. Algoritma SVM dibandingkan dengan metode klasifikasi lain seperti *Random Forest* (RF) dan *K-Nearest Neighbor* (kNN) memiliki keunggulan, yaitu hasil klasifikasi penutup lahan dengan bermacam data-set (*training sample size*) menunjukkan SVM memiliki *overall accuracy* yang lebih baik (Noi & Kappas, 2017). Penggunaan SVM dapat meminimalisir kesalahan klasifikasi dengan melakukan pemisahan *hyperplane* menggunakan label data (persamaan 2-1).

$$f(x) = [\omega \cdot \varphi(x) + b] \quad (2-1)$$

Penggunaan fungsi Kernel (persamaan 2) pada algoritma SVM untuk mengasumsikan pemisahan data non linier menjadi linier (Jamil & Bayram, 2018).

$$K(x, x') = \exp(-\lambda \|x - x'\|^2) \quad (2-2)$$

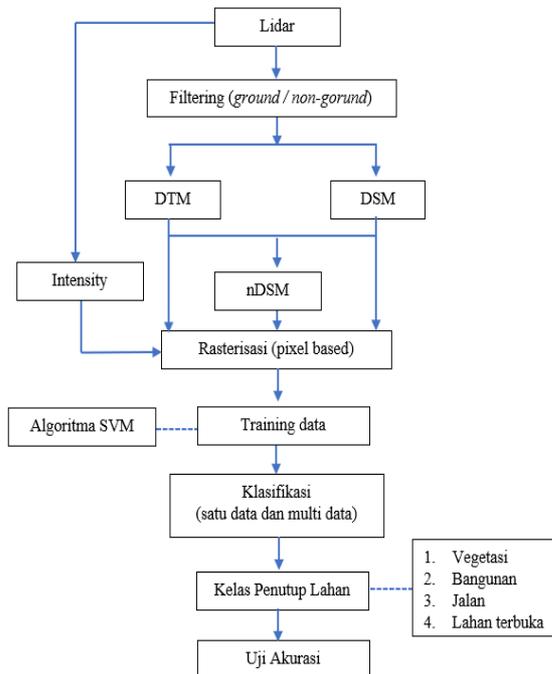
Pengolahan data yang dilakukan berbasis raster. Proses *filtering* pada data Lidar dibutuhkan untuk memisahkan data *ground* dan *non-ground*. Proses pemisahan tersebut dilakukan dengan menggunakan perangkat lunak *Global Mapper*. Pada tahap ini data Lidar *point cloud* dikelompokkan sesuai dengan nilai elevasinya. Data *ground point* didapatkan dari *point cloud* yang membentuk permukaan bumi tanpa objek di atasnya, sedangkan data *non-ground* didapatkan dari *point cloud* yang membentuk objek seperti vegetasi dan bangunan. Hasil dari *filtering* kemudian diproses untuk mendapatkan *Digital Terrain Model* (DTM) dan *Digital Surface Model* (DSM). DTM dibuat dari data *ground point*, sedangkan DSM dibuat dari *non-ground point*. Data DTM dan DSM digunakan untuk penghitungan nilai selisih elevasinya yaitu nilai *normalized DSM* (nDSM), selain itu digunakan data *intensity* yang merupakan nilai intensitas dari objek yang terekam pada Lidar tersebut. Proses pengolahan data Lidar bisa dilihat pada Gambar 2-2.

Hasil dari proses rasterisasi didapatkan data raster dengan ukuran piksel 1 cm. Data raster tersebut digunakan untuk proses selanjutnya yaitu klasifikasi dengan menggunakan algoritma SVM pada Python, dimana perlu dibuat *training area* pada data karena menerapkan *supervised classification*. Peta Rupabumi Indonesia (RBI) skala 1:5000 tahun 2017 digunakan sebagai referensi. Kelebihan SVM salah satunya adalah bisa dilakukan dengan penggunaan data *training sample* yang terbatas (Mountrakis et al., 2011), serta bisa menghasilkan *output* yang baik untuk klasifikasi dengan menggunakan data spektral (Qin, 2015).

Proses training data pada penelitian ini dilakukan dengan cara mengambil sampel pada setiap kelas penutup lahan. Data sampel ini dijadikan sebagai acuan dalam mengklasifikasikan nilai pixel yang merepresentasikan kenampakan penutup lahan dari sumber data. Pengambilan data training dilakukan secara merata sebarannya terhadap setiap kelas penutup lahan, dengan kurang lebih 20 sampel untuk setiap kelasnya. Pada pengambilan sampel data didasarkan atas kemiripan (warna, rona, asosiasi, dan tekstur) untuk kelas atau objek yang sama. Untuk data training dan data uji akurasi pada penelitian ini dilakukan pada lokasi area yang sama.

Proses klasifikasi dilakukan dengan dua metode yaitu klasifikasi dengan menggunakan input satu data dan kombinasi data. Klasifikasi satu data dilakukan pada setiap data yaitu DTM, DSM, nDSM, dan *intensity*. Proses klasifikasi kombinasi data dilakukan dengan kombinasi input data seperti pada Tabel 2-1. Penutup lahan yang dipakai pada penelitian ini hanya dibatasi untuk kelas bangunan, vegetasi, jalan dan lahan terbuka. Kebaharuan dari penelitian ini adalah pemanfaatan kombinasi data untuk meningkatkan hasil akurasi dari proses klasifikasi penutup lahan.

Penilaian akurasi hasil klasifikasi digunakan penghitungan *Kappa Coefficient* dan *Overall Accuracy* dengan berdasarkan pada *Confusion Matrix* (Matriks Konfusi).



Gambar 2-2. Proses pengolahan Data

3 HASIL PEMBAHASAN

Visualisasi *image/raster* yang merupakan data turunan hasil pengolahan data Lidar dapat dilihat pada Gambar 3-1 dan 3-2. Data DSM berisi informasi nilai ketinggian permukaan objek (bangunan, vegetasi dan objek lain), data DTM menunjukkan informasi nilai ketinggian permukaan *terrain*. nDSM merupakan nilai ketinggian objek diatas *terrain* (Gambar 3-3) dan data intensity berisi informasi nilai intensitas objek pada saat akuisisi data Lidar (Gambar 3-4).

Dari data-data turunan tersebut dilakukan klasifikasi dengan skema input satu data dan kombinasi data pada proses klasifikasi. Setiap objek dilakukan data *training* dengan minimal 20 sampling. Hasil klasifikasi untuk skema *single* data dapat dilihat pada Gambar 3-5.

Tabel 2-1. Kombinasi data pada klasifikasi penutup lahan

No.	Kombinasi Data		
1.	DSM	DTM	nDSM
2.	DSM	DTM	<i>Intensity</i>
3.	DSM	nDSM	<i>Intensity</i>
4.	DTM	nDSM	<i>Intensity</i>



Gambar 3-1. Data DSM (*Digital Surface Model*)



Gambar 3-2. Data DTM (*Digital Terrain Model*)



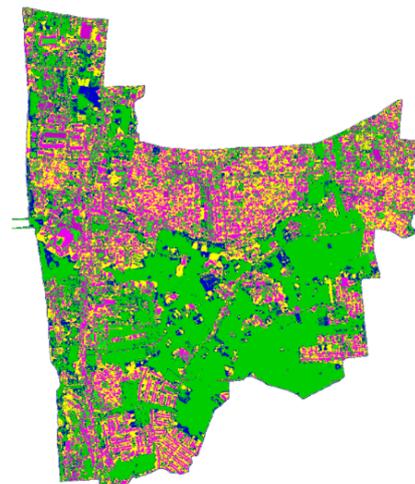
Gambar 3-3. Data nDSM (*normalized Digital Surface Model*)



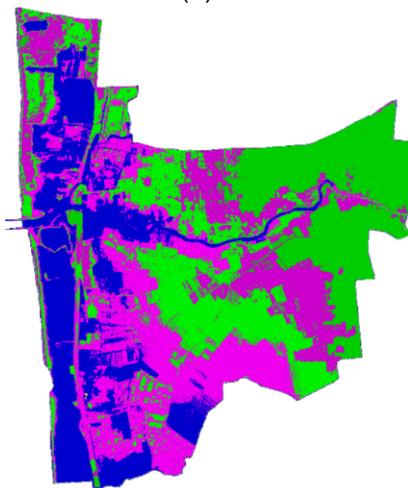
Gambar 3-4. Data *Intensity*



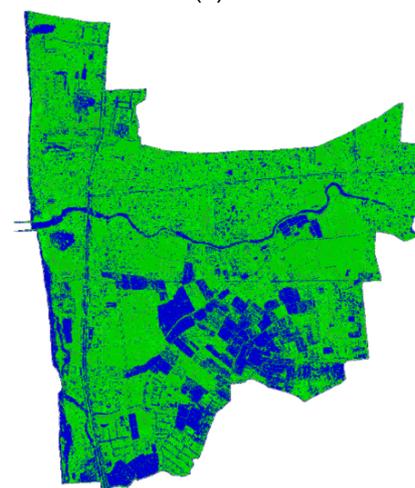
(a)



(c)



(b)



(d)

- Bangunan
- Vegetasi tinggi
- Vegetasi rendah
- Badan Jalan
- Lahan terbuka

Gambar 3-5. Hasil klasifikasi menggunakan data (a) DTM, (b) DSM, (c) nDSM, (d) *Intensity*

Hasil klasifikasi penutup lahan dengan satu data belum menunjukkan

hasil yang optimal, masih ada kelas penutup lahan yang belum

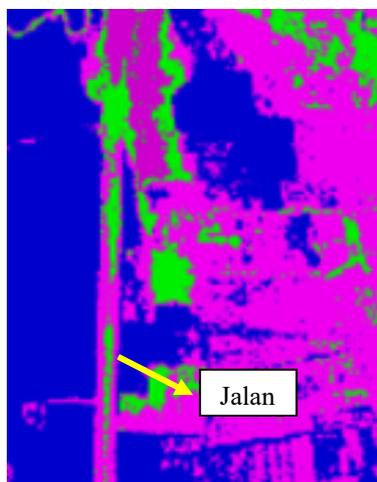
teridentifikasi, yaitu badan jalan. Kelas bangunan dan vegetasi sudah teridentifikasi namun masih ada yang belum sesuai dengan data referensi.

Hasil penghitungan *Overall Accuracy* dapat dilihat pada tabel 3-1, dari tabel tersebut dapat kita ketahui untuk nilai OA terendah adalah dari data intensity, sedangkan OA tertinggi dari data DSM.

Tabel 3-1. Nilai *Overall Accuracy*

No.	Data	Overall Accuracy
1.	DTM	55,22 %
2.	DSM	60,40%
3.	nDSM	51,81%
4.	Intensity	33,19%

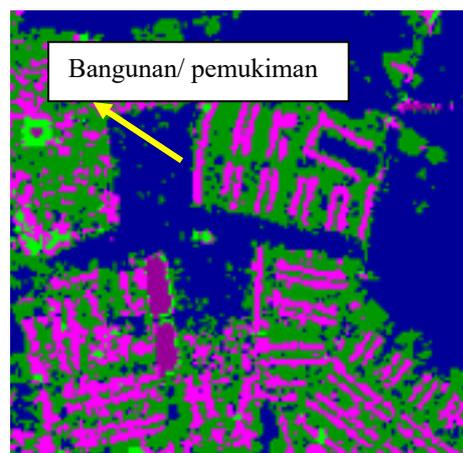
Gambar 3-5(a) yaitu hasil klasifikasi dengan data DTM dapat kita lihat sebaran objek yang terbentuk dari hasil klasifikasi sebagian besar adalah bangunan, vegetasi tinggi (pohon) dan vegetasi rendah (sawah, ladang, kebun). Klasifikasi tersebut belum menunjukkan hasil yang terlihat berupa objek badan jalan dan lahan terbuka. Lebih rinci untuk lokasi jalan yang belum tervisualisasi dari hasil klasifikasi bisa dilihat pada Gambar 3-6.



Gambar 3-6. Objek jalan belum terklasifikasi.

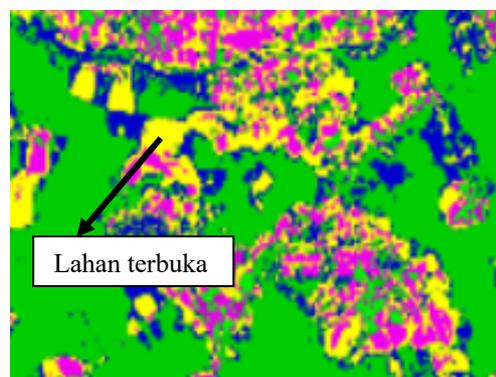
Gambar 3-5(b) hasil klasifikasi data DSM, objek penutup lahan yang terbentuk adalah bangunan, vegetasi tinggi dan vegetasi rendah. Hampir mirip dengan hasil klasifikasi DTM, namun ada perbedaan yang cukup baik yaitu mulai terbentuk dengan jelas adanya permukiman atau lokasi perumahan (Gambar 3-7). Hasil klasifikasi tersebut terjadi peningkatan akurasi sekitar 5%

jika dibandingkan dengan hasil klasifikasi DTM.



Gambar 3-7. Objek bangunan/ permukiman sudah terklasifikasi

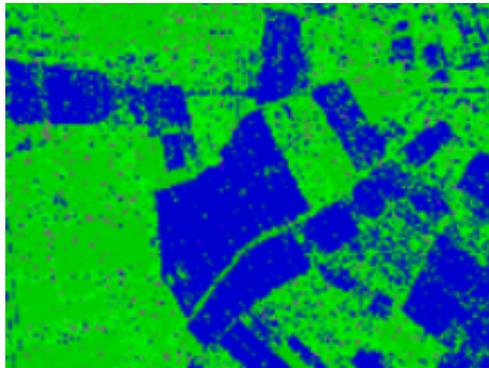
Gambar 3-5(c) hasil klasifikasi data nDSM, akurasi yang didapat adalah 51,81% dimana terdapat objek baru yang terbentuk dibanding dengan hasil klasifikasi dengan data sebelumnya, yaitu objek badan jalan dan lahan terbuka (Gambar 3-8). Objek lain yaitu vegetasi rendah belum nampak dengan baik, sebagian besar vegetasi rendah teridentifikasi sebagai vegetasi tinggi.



Gambar 3-8. Objek lahan terbuka sudah terklasifikasi

Gambar 3-5(d) hasil klasifikasi dari data intensity memiliki nilai akurasi paling rendah yaitu 33,19%, hasil klasifikasi hanya mengidentifikasi vegetasi tinggi dan vegetasi rendah seperti terlihat jelas pada Gambar 3-9. Perbedaan hasil klasifikasi dari data-data turunan Lidar tersebut bisa disebabkan oleh adanya informasi tinggi atau ketinggian yang terdapat pada masing-masing data sebelum proses rasterisasi dari sumber datanya (*Lidar point cloud*), yaitu ketinggian permukaan objek,

ketinggian *terrain*/ permukaan tanah, dan tinggi objek diatas permukaan tanah (nDSM). Informasi ketinggian tersebut berpengaruh terhadap kenampakan dari setiap objek penutup lahan yang diklasifikasikan.



Gambar 3-9. Hasil klasifikasi objek vegetasi tinggi dan vegetasi rendah

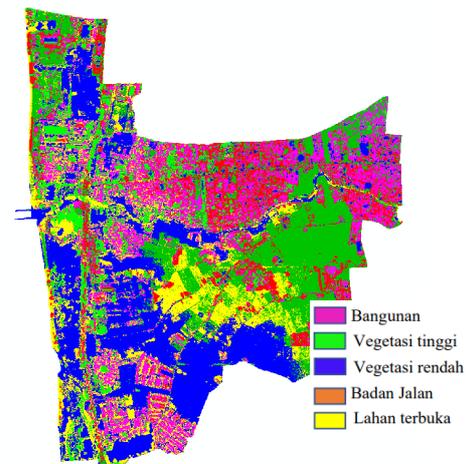
Skema klasifikasi yang kedua yaitu klasifikasi dengan kombinasi data. Skema ini bertujuan untuk mendapatkan hasil klasifikasi yang lebih optimal atau lebih akurat dari klasifikasi input satu data. Kombinasi datanya dapat dilihat pada Tabel 2-1, dari percobaan kombinasi data tersebut didapatkan nilai *Overall Accuracy* (OA) seperti pada Tabel 3-2. Nilai OA dengan skema kombinasi data memiliki hasil rata-rata diatas 75%, hal ini menunjukkan dengan pemanfaatan skema kombinasi dapat meningkatkan nilai akurasi 15-20% dari hasil klasifikasi satu data. Nilai OA terendah adalah dari kombinasi DSM, nDSM, intensity yaitu 79,27%, sedangkan nilai tertinggi didapatkan dari kombinasi DTM, nDSM, intensity sebesar 85,50 %. Hasil klasifikasi dengan kombinasi data didapatkan nilai akurasi dari masing-masing kombinasi dengan selisih yang tidak terlalu besar. Peningkatan nilai akurasi dari hasil kombinasi data dapat disebabkan oleh adanya kombinasi kenampakan objek yang berbeda-beda dari setiap data yang saling melengkapi, hal ini berpengaruh pada hasil *training data set* yang dilakukan pada proses *supervised classification*.

Visualisasi hasil klasifikasi penutup lahan dengan nilai akurasi tertinggi yaitu kombinasi DTM, nDSM, intensity dapat dilihat pada Gambar 3-10. Hasil klasifikasi tersebut menunjukkan objek-objek penutup lahan sudah terklasifikasi dengan baik, sudah terbentuk objek yang

dikelaskan yaitu bangunan, vegetasi tinggi, vegetasi rendah, badan jalan, lahan terbuka. Kelas bangunan, area permukiman atau perumahan sudah terbentuk dengan baik.

Tabel 3-2. Nilai *Overall Accuracy* klasifikasi kombinasi data.

No.	Data			<i>Overall Accuracy</i> (OA)
1.	DSM	DTM	nDSM	81,70 %
2.	DSM	DTM	Intensity	85,18 %
3.	DSM	nDSM	Intensity	79,27 %
4.	DTM	nDSM	Intensity	85,50 %



Gambar 3-10. Hasil klasifikasi menggunakan kombinasi data (DTM, nDSM, intensity)

KESIMPULAN

Hasil klasifikasi penutup lahan dari data Lidar (DTM, DSM, nDSM, intensity) dengan metode *machine learning SVM*, menunjukkan bahwa dengan skema input satu data menghasilkan nilai akurasi yang belum optimal yaitu sekitar 60%, masih terdapat objek yang belum teridentifikasi. Klasifikasi dengan skema kombinasi data menghasilkan nilai akurasi yang lebih baik dibandingkan dengan skema satu data, yaitu mencapai peningkatan sekitar 15-20%. Kelas penutup lahan yang teridentifikasi yaitu bangunan, vegetasi, jalan, lahan terbuka. Kombinasi data dengan nilai *Overall Accuracy* tertinggi yaitu kombinasi DTM, nDSM, intensity dengan nilai sebesar 85,50%.

UCAPAN TERIMAKASIH

Terimakasih kepada para pembimbing atas arahan yang telah diberikan dan kepada Badan Informasi Geospasial (BIG) yang telah menyediakan/ memfasilitasi data pada penelitian ini.

DAFTAR RUJUKAN

- Berrios, P. H. (2004). *Spatial Analysis of The Differences Between Forest Land Use and Forest Cover Using GIS and RS. A case study in Telake Watershed, Pasir district, East Kalimantan*. The Netherlands: ITC.
- Chen, Z., & Gao, B. (2014). An Object-Based Method for Urban Land Cover Classification Using Airborne Lidar Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(10), 4243–4254. <https://doi.org/10.1109/JSTARS.2014.2332337>
- Cortes, C., & Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 20, 273–297.
- Ekhtari, N., Glennie, C., & Fernandez-Diaz, J. C. (2018). Classification of Airborne Multispectral Lidar Point Clouds for Land Cover Mapping. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(6), 2068–2078. <https://doi.org/10.1109/JSTARS.2018.2835483>
- Hariyono, M. I. (2018). Kajian Perubahan Penutup Lahan Peta Rupabumi pada Skala yang Berbeda. In *Seminar Nasional Geografi dan Pembangunan Berkelanjutan 2018* (pp. 292–300).
- Jamil, A., & Bayram, B. (2018). Tree Species Extraction and Land Use / Cover Classification From High-Resolution Digital Orthophoto Maps. *Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(1), 89–94. <https://doi.org/10.1109/JSTARS.2017.2756864>
- Mallet, C., Bretar, F., Roux, M., Soergel, U., & Heipke, C. (2011). Relevance assessment of full-waveform Lidar data for urban area classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66, S71–S84. <https://doi.org/10.1016/j.isprsjprs.2011.09.008>
- Melgani, F., & Bruzzone, L. (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8), 1778–1790. <https://doi.org/10.1109/TGRS.2004.831865>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247–259. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- Noi, P. T., & Kappas, M. (2017). Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors*, 18, 18–37. <https://doi.org/10.3390/s18010018>
- Pan, S., Guan, H., Yu, Y., Li, J., & Peng, D. (2019). A Comparative Land-Cover Classification Feature Study of Learning Algorithms : DBM , PCA ,and RF Using Multispectral Lidar Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(4), 1314–1326. <https://doi.org/10.1109/JSTARS.2019.2899033>
- Qin, R. (2015). A Mean Shift Vector-Based Shape Feature for Classification of High Spatial Resolution Remotely Sensed Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(5), 1974–1985.
- Yan, W. Y., Shaker, A., & El-ashmawy, N. (2015). Urban land cover classification using airborne Lidar data : A review. *Remote Sensing of Environment*, 158, 295–310. <https://doi.org/10.1016/j.rse.2014.11.001>
- Zhou, W. (2013). An Object-Based Approach for Urban Land Cover Classification Integrating Lidar Height and Intensity Data. *IEEE Geoscience and Remote Sensing Letters*, 10(4), 928–931. <https://doi.org/10.1109/LGRS.2013.2251453>