

# Perbandingan Metode Klasifikasi Pemetaan Tutupan Lahan Menggunakan Algoritma *Machine Learning* Pada Citra Satelit Dengan *Google Earth Engine*

## *Mapping Land Cover Classification Using Machine Learning Comparison of Satellite Images with Google Earth Engine*

1<sup>st</sup> Asri Rahmi Putri  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia  
asrirp@students.telkomuniversity.  
ac.id

2<sup>nd</sup> Rita Purnamasari  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia  
ritapurnamasari@telkomiversity.a  
c.id

3<sup>rd</sup> Edwar  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia  
edwarm@telkomuniversity.ac.id

**Abstrak** - Perencanaan dan pembangunan sebuah lahan masih menjadi salah satu perhatian di beberapa negara berkembang seperti Indonesia. Cara untuk mengetahui perkembangan suatu tempat adalah dengan melihat informasi peta penggunaan lahannya. Dengan peta tutupan lahan maka dapat diketahui informasi jenis tutupan lahan, luas setiap tutupan lahan dan penggunaan lahan pada kawasan tersebut yang berguna bagi pemerintah setempat maupun para peneliti. Metode dalam Tugas Akhir dalam membuat klasifikasi tutupan lahan (land cover) pada citra satelit ini adalah dengan menggunakan klasifikasi terbimbing (*supervised classification*), diantaranya yaitu *Naïve Bayes*, *Random Forest* dan *Support Vector Machine (SVM)* dengan menggunakan *Google Earth Engine*. Pada Tugas Akhir ini, titik training yang digunakan sebanyak 27 dan 15 titik validasi yang digunakan. Kelas klasifikasi dibuat sebanyak 4 kelas: badan air, lahan terbangun, lahan terbuka dan vegetasi. Dan citra yang digunakan adalah citra dari satelit Sentinel-2 dan Landsat-8. Data dari hasil pengujian yang telah dilakukan dengan menggunakan aplikasi *Google Earth Engine* menunjukkan bahwa classifier *Support Vector Machine (SVM)* dengan citra Sentinel-2 memberikan keseluruhan akurasi (*Overall Accuracy*) tertinggi dengan nilai 97,22% dan nilai Kappa sebesar 96,29%. Sedangkan dengan menggunakan citra Landsat-8 mendapatkan nilai keseluruhan akurasi (*Overall Accuracy*) 74,07% dan nilai kappa sebesar 65,43%..

**Kata Kunci**- *Land Cover*, *Naïve Bayes*, *SVM*, *Random Forest*, *Sentinel-2*, *Landsat-8*.

**Abstrac** – *Planning and development of a land is still one of the concerns in several developing countries such as Indonesia. The way to know the development of*

*a place is to look at the map information of its land use. With a land cover map, information on the type of land cover, the area of each land cover and land use in the area can be known which is useful for local governments and researchers. The method in this final project in making land cover classification in this satellite image is to use a guided classification, including Naïve Bayes, Random Forest and Support Vector Machine (SVM) using Google Earth Engine. In this final project, 27 training points were used and 15 validation points were used. Classification is made of 4 classes: water bodies, built up land, open land and vegetation. And the images used are images from the Sentinel-2 and Landsat-8 satellites. Data from the results of tests that have been carried out using the Google Earth Engine application show that the Support Vector Machine (SVM) classifier with Sentinel-2 imagery provides the highest overall accuracy with a value of 97.22% and a Kappa value of 96.29%. Meanwhile, using Landsat-8 imagery, the overall accuracy value (Overall Accuracy) is 74.07% and the kappa value is 65.43%.*

**Keywords**- *Land Cover*, *Naïve Bayes*, *SVM*, *Random Forest*, *Sentinel-2*, *Landsat-8*.

### I. PENDAHULUAN

#### A. Latar Belakang

Aktivitas alam dapat menyebabkan perubahan permukaan tanah seperti gempa, longsor, banjir dan bencana alam lainnya. Sedangkan aktivitas manusia yang dapat mempengaruhi yaitu populasi manusia yang tiap tahun makin bertambah dan pembangunan fasilitas umum, pembangunan

permukiman, pembangunan pusat bisnis maupun aktivitas lainnya. Aktivitas alam ataupun manusia mengakibatkan tekanan yang besar bagi alam dan dari aktivitas-aktivitas tersebut akan mengakibatkan berkurangnya lahan hijau akibat dari aktivitas tersebut, penggunaan lahan pun menjadi tidak terkontrol.

Keuntungan menggunakan *deep learning* dengan data satelit sebagai masukkannya adalah dapat mengakuisisi data yang lebih cepat dan cakupan datanya yang lebih luas dibandingkan dengan teknologi konvensional atau observasi lapangan[1]. Penginderaan jauh dengan menggunakan citra satelit Sentinel-2 dapat dimanfaatkan untuk mengklasifikasikan jenis penggunaan lahan di area yang cukup luas dengan resolusi sedang dan cukup untuk sebuah *open data*.

Dikutip dari Disperkim.jabarprov.go.id, gubernur Jawa Barat Ridwan Kamil mengatakan bahwa Waduk Sudah bersih sekali dan nyaman, Tinggal difasilitasi keinginan para wisatawan, sehingga Jawa Barat bisa menaikkan potensi wisata berlipat-lipat. Waduk Jatiluhur merupakan salah satu tempat wisata yang potensial di Jawa Barat. Kajian ini bertujuan memetakan potensi tutupan lahan disekitar waduk Jatiluhur guna mendukung tersajinya data spasial untuk penentuan lahan secara optimal.

Penggunaan citra satelit Sentinel-2 yang diluncurkan pada tahun 2017 masih belum banyak dilakukan, sehingga menjadi peluang untuk mengetahui kemampuannya dalam mengklasifikasi tutupan lahan yang diimplementasikan dengan algoritma *Naïve Bayes*, *Random Forest* dan *Support Vector Machine* (SVM).

## B. Tujuan dan Manfaat

Adapun tujuan dan manfaat yang dibahas pada Tugas akhir ini sebagai berikut:

1. Merancang dan mengimplementasikan suatu sistem untuk mengklasifikasi tutupan lahan menggunakan algoritma *Naïve Bayes*, *Random Forest* dan *Support Vector Machine* (SVM)
2. Mengetahui dan menganalisis seberapa besar akurasi sistem klasifikasi tutupan lahan berdasarkan klasifikasi terbimbing yang menggunakan citra satelit Sentinel-2 dan Landsat 8.
3. Menganalisis parameter yang mempengaruhi performansi sistem dalam mengklasifikasi tutupan lahan menggunakan metode klasifikasi terbimbing

## C. Rumusan Masalah

Berdasarkan latar belakang pada Tugas Akhir ini, berikut merupakan beberapa permasalahan yang dapat dirumuskan:

1. Bagaimana cara mendeteksi jenis tutupan dan membuat klasifikasi lahan melalui citra satelit berbasis *Google Earth Engine* dengan klasifikasi terbimbing?
2. Bagaimana hasil uji klasifikasi tutupan lahan berdasarkan klasifikasi terbimbing dengan menggunakan citra Sentinel-2 dan Landsat-8?
3. Bagaimana cara menganalisis performansi sistem melalui keseluruhan akurasi (*overall accuracy*), koefisien kappa, akurasi pembuat (*producer accuracy*) dan akurasi pengguna (*user accuracy*)?

## D. Batasan Masalah

Permasalahan yang telah dipaparkan dalam Tugas Akhir ini dibatasi oleh beberapa hal, yaitu:

1. Metode yang digunakan adalah klasifikasi terbimbing: *Naïve Bayes*, *Random Forest* dan *Support Vector Machine* (SVM)
2. Kawasan yang dijadikan objek identifikasi adalah daerah waduk Jatiluhur, Jawa Barat
3. Klasifikasi tutupan lahan yang menjadi objek penelitian adalah badan air, lahan terbuka, lahan terbangun dan vegetasi
4. Format citra yang digunakan adalah citra warna natural RGB (band 4-3-2) Sentinel-2 dan Landsat-8.
5. Program perangkat lunak yang digunakan adalah *Google Earth Engine*

## II. KAJIAN TEORI

### A. Tutupan Lahan

Tutupan lahan atau yang disebut *land cover* memiliki beberapa pengertian oleh para ahli, berikut definisi tentang tutupan lahan antara lain:

1. Penutupan lahan berkaitan dengan jenis kenampakan yang ada dipermukaan bumi [2]
2. Tutupan lahan adalah perwujudan secara fisik (visual) dari vegetasi, benda alam, dan unsur budaya yang ada dipermukaan bumi tanpa memperhatikan kegiatan manusia terhadap obyek tersebut [3]

3. Permukaan bumi sebagian terdiri dari kenampakan alamiah (penutupan lahan) contohnya antara lain; vegetasi, salju [4]

Tutupan lahan berfungsi menyediakan informasi penting untuk keperluan pemodelan serta untuk memahami bagaimana fenomena alam terjadi dipermukaan bumi [5]. Selain itu tutupan lahan juga berfungsi untuk mempelajari bagaimana iklim berubah dan memahami hubungan antara aktivitas manusia dan global warming. Tutupan lahan dapat dideteksi dengan menggunakan penginderaan jauh. Setiap tipe tutupan lahan memiliki atribut spasial yang spesifik, seperti misalnya variasi vegetasi, cadangan karbon dan kandungan hara. Tipe- tipe tutupan lahan akan membentuk konfigurasi habitat bagi tumbuhan dan hewan [6].

#### B. Satelit *Sentinel-2*

Satelit *Sentinel-2* adalah satelit yang terdiri dari dua satelit konstelasi yaitu *Sentinel-2A* dan *Sentinel-2B* yang mengorbit kutub pada orbit sun-synchronous pada ketinggian 786 km. *Sentinel-2* merupakan citra satelit dengan resolusi spasial sedang dengan swath yang lebar, revisit di lokasi yang sama setiap 5 hari untuk dua satelit dan 10 hari untuk 1 satelit. Satelit ini dapat digunakan untuk pengamatan operasional seperti peta tutupan lahan, peta deteksi perubahan lahan dan variabel geofisika [7]. Citra yang dihasilkan oleh satelit *Sentinel-2* memiliki resolusi spasial sebesar 10 meter untuk 4 band, 20 meter untuk 6 band, dan 3 band sisanya memiliki resolusi spasial sebesar 60 meter. Citra satelit *Sentinel-2* juga memiliki 13 band multispektral, yang dibagi atas spektrum visible (coastal aerosol, merah, hijau) *near infrared*, dan *shortwave infrared*.

#### C. Satelit *Landsat-8*

*Landsat-8* merupakan kelanjutan dari misi *Landsat 7*. Ini terlihat dari karakteristiknya yang mirip dengan *landsat 7*, baik resolusinya (spasial, temporal, spektral), metode koreksi, ketinggian terbang maupun karakteristik sensor yang dibawa. Hanya saja ada beberapa tambahan yang menjadi titik penyempurnaan dari *landsat 7* seperti jumlah band, rentang spektrum gelombang elektromagnetik terendah yang dapat ditangkap sensor serta nilai bit (rentang nilai Digital Number) dari tiap piksel citra. Satelit pemantauan bumi ini memiliki dua sensor yaitu sensor Operational Land Imager (OLI) dan Thermal Infrared Sensor (TIRS). Kedua sensor ini menyediakan resolusi spasial 30 meter (visible, NIR, SWIR), 100 meter (thermal), dan 15 meter

(pankromatik). *Landsat 8* memiliki orbit Sun-Synchronous orbit pada ketinggian 705 km. *Landsat-8* memiliki resolusi temporal selama 16 hari [8].

#### D. Citra warna RGB

Citra warna RGB (Red, Green, Blue) adalah model warna yang digunakan sebagai acuan pokok, karena warna lain dapat dihasilkan dari kombinasi ketiga komponen (red, green, blue) tersebut. Setiap komponen warna RGB menggunakan 8 bit (dengan nilai berkisar antara 0 sampai dengan 255). Sehingga kemungkinan warna yang dihasilkan dari ketiga kombinasi warna tersebut adalah  $256 \times 256 \times 256$  atau sekitar 16.777.216 warna.

#### E. *Google Earth Engine*

*Google Earth Engine* merupakan sebuah platform cloud yang menawarkan analisis data lingkungan berskala dunia yang menyediakan data citra satelit, data cuaca, geografis, serta fitur seperti Normalized Difference Vegetation Index (NDVI)[9]. *Google Earth Engine* menggunakan pemrograman javascript API untuk menjalankan programnya.

#### F. *Naïve Bayes*

*Naïve Bayes* merupakan salah satu algoritma klasifikasi terbimbing yang diselesaikan dengan cara probabilitas dan statistik yang ditemukan oleh ilmuwan Inggris, Thomas Bayes. Algoritma ini dapat memprediksi probabilitas keanggotaan suatu kelas pada suatu objek dengan ciri-ciri yang termasuk dalam kelompok atau kelas didasarkan pada teorema probabilitas Bayes [10]. Tiga jenis model *Naïve Bayes* yang sering digunakan yaitu Gaussian *Naïve Bayes*, Multinomial *Naïve Bayes* dan Bernoulli *Naïve Bayes*. Teori *Naïve Bayes* ini memprediksi probabilitas dimasa depan dengan berdasar atas pengalaman masa sebelumnya.

#### G. *Random Forest*

Pada tahun 1995, Tin Kam Ho dari Bell Labs pertama kali memperkenalkan random forest. Menurutnya, random forest adalah algoritma pembelajaran ensemble untuk tahapan data mining dengan tugas klasifikasi dan regresi [11]. Random forest merupakan metode bagging yaitu metode yang membangkitkan sejumlah tree dari data sample dimana pembuatan satu tree pada saat training tidak bergantung pada tree sebelumnya, tetapi bisa digunakan lagi untuk training tree yang lain

sehingga keputusan diambil berdasarkan voting terbanyak [11].

#### H. Support Vector Machine

Support Vector Machine (SVM) merupakan suatu teknik untuk melakukan prediksi, baik dalam kasus klasifikasi maupun regresi. Bisa disebut ide dasar SVM adalah memaksimalkan batas hyperplane (maximal margin hyperplane). Hyperplane (batas keputusan) pemisah terbaik antara kedua class adalah hypereplane yang terletak ditengah dua set objek [12]. Dapat dicari dengan mengukur margin dari hyperplane dan mencari titik maksimalnya. Margin adalah jarak antara hyperplane tersebut dengan pattern terdekat dari masing-masing class.

#### I. Parameter Pengujian Performansi

##### 1. Confusion Matrix

Confusion matrix adalah suatu metode yang digunakan untuk mengukur performansi metode klasifikasi, berisi informasi yang membandingkan hasil klasifikasi oleh sistem dengan yang seharusnya. Sistem klasifikasi terbagi menjadi empat jenis berdasarkan jumlah output kelasnya, yaitu klasifikasi binary, multi-class, multi-label dan hierarchical.

Confusion Matrix		Prediksi					
		Kelas A	Kelas B	Kelas C	...	Kelas Q	$\Sigma$
Aktual	Kelas A	$x_{AA}$	$x_{AB}$	$x_{AC}$	...	$x_{AQ}$	$x_{A+}$
	Kelas B	$x_{BA}$	$x_{BB}$	$x_{BC}$	...	$x_{BQ}$	$x_{B+}$
	Kelas C	$x_{CA}$	$x_{CB}$	$x_{CC}$	...	$x_{CQ}$	$x_{C+}$
	.	.	.	.	.	.	.
	.	.	.	.	.	.	.
	Kelas Q	$x_{QA}$	$x_{QB}$	$x_{QC}$	...	$x_{QQ}$	$x_{Q+}$
$\Sigma$		$x_{+A}$	$x_{+B}$	$x_{+C}$	...	$x_{+Q}$	$\Sigma_{total}$

GAMBAR 2.2

CONFUSION MATRIX MULTICLASS

##### 2. Kappa Coefficient

Nilai indeks Kappa digunakan untuk mengetahui konsistensi nilai akurasi peta hasil pemetaan. Semakin besar nilai indeks kappa maka derajat kepercayaan terhadap nilai uji akurasi yang ditunjukkan akan lebih tinggi. Indeks kappa cenderung lebih komprehensif dalam menyatakan validitas klasifikasi. Nilai Kappa digunakan untuk menguji akurasi hasil klasifikasi tutupan lahan yang diperoleh dengan data ground truth. Akurasi yang digunakan dalam penelitian ini adalah nilai Kappa Coefficient dan Overall Accuracy dengan bantuan matriks kesalahan (confusion matrix).

$$\text{Kappa Coefficient} = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (G_i C_i)}{N^2 - \sum_{i=1}^r (G_i C_i)} \times 100\% \quad (2.1)$$

##### 3. Overall Accuracy

Akurasi keseluruhan (Overall Accuracy) mempresentasikan seberapa akurat sistem dapat mengklasifikasikan data secara benar. Nilai akurasi

adalah perbandingan antara data yang terklasifikasi benar dengan jumlah keseluruhan data. Nilai akurasi keseluruhan dapat diperoleh dengan persamaan (2.2) berikut

$$\text{Overall accuracy} = \frac{TTP_{all} + TTN_{all}}{\Sigma_{total}} \quad (2.2)$$

##### 4. Producer Accuracy

Producer accuracy memperlihatkan seberapa besar kemungkinan lahan di lapangan terklasifikasi secara tepat di dalam citra. Producer Accuracy atau Commision Error mewakili fraksi

nilai yang dimiliki oleh suatu kelas tetapi diprediksi berada di kelas yang berbeda. Producer accuracy dan user accuracy dapat ditentukan menggunakan rumus (2.3) dan (2.4) dibawah.

$$\text{producer accuracy} = \frac{x_{NN}}{\Sigma_{x+N}} \times 100\% \quad (2.3)$$

##### 5. User Accuracy

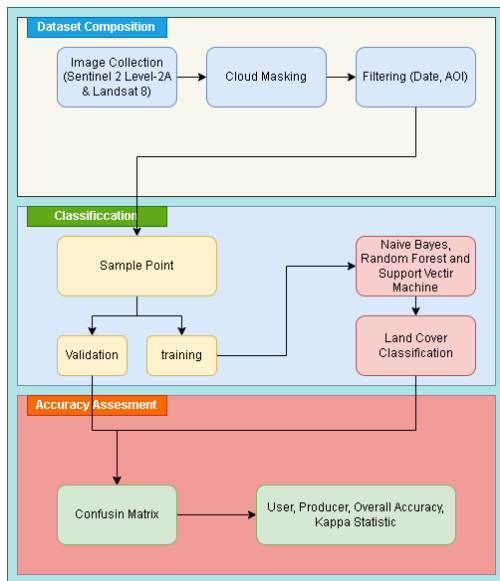
user accuracy memperlihatkan seberapa besar kemungkinan klasifikasi dalam citra terklasifikasi secara tepat di lapangan. (2.4)

$$\text{user accuracy} = \frac{x_{NN}}{\Sigma_{xN+}} \times 100\%$$

### III. METODE

#### A. Diagram Alur Sistem

Berikut merupakan perancangan sistem klasifikasi tutupan lahan seperti pada gambar 3.1.

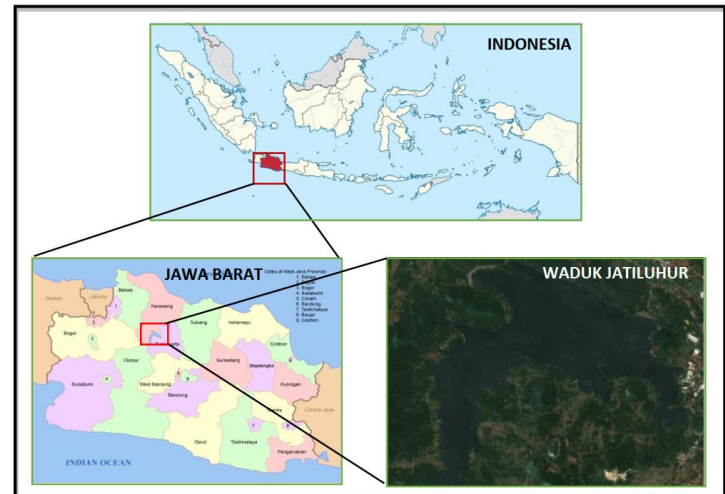


GAMBAR 3.1  
WORKFLOW PENELITIAN

Gambar (3.2) menjelaskan *workflow* pada pengerjaan Tugas Akhir ini, pada *dataset composition* atau dengan kata lain *input* citranya menggunakan citra Sentinel-2 Level-2A dan Landsat-8, lalu data di *cloud masking* agar citra terbebas dari awan dan di-*filter* dengan memasukkan fungsi *date* dan *AOI*. Setelah semua pengaturan tentang input, lalu masuk ke tahap klasifikasi dimana pada tahap ini terdapat pengambilan *sample point* untuk *training* dan *testing* dengan masing-masing titik berjumlah 27 dan 15. Setelah itu pada sisi *training* masuk ke *classifier* dan klasifikasi. Pada tahap akhir, validasi beserta hasil klasifikasi akan digabungkan menjadi *confusion matrix* yang menghasilkan nilai *Overall Accuracy*, *Kappa Coefficient*, *Producer Accuracy* (akurasi pembuat) dan *User's Accuracy* (akurasi pengguna).

#### B. Akuisisi Citra

Akuisisi citra merupakan proses awal yang dilakukan untuk mendapatkan citra digital sebagai alat data latih dan data uji. Citra yang digunakan adalah satelit Sentinel-2A, dengan daerah studi di Waduk Jatiluhur, Jawa Barat. Data satelit tersebut diperoleh dari <https://code.earthengine.google.com/>.



GAMBAR 3.2  
PETA KAWASAN WADUK JATILUHUR  
C. Pre-processing citra

Tahap *pre-processing* mengacu pada seperangkat Teknik yang bertujuan untuk memperbaiki kualitas citra *raw data*, sehingga mengoptimalkan akurasi sistem mengklasifikasi serta menghasilkan keluaran yang maksimal. Tahap *pre-processing* mencakup beberapa proses, diantaranya: koreksi atmosferik dan pemotongan citra.



GAMBAR 3.3  
DIAGRAM PRE-PROCESSING

Pemotongan citra merupakan pemotongan gambar citra guna untuk mendapatkan daerah penelitian dengan maksud membatasi daerah penelitian sehingga pengolahan data dapat lebih fokus terhadap objek yang diteliti dan lebih mudah

dianalisis oleh komputer. Untuk mendapatkan daerah yang kita inginkan kita dapat memotong (cropping) citra tersebut.



GAMBAR 3.4  
HASIL CROPPING CITRA

Gambar 3.4 diatas merupakan hasil pemotongan citra yang dilakukan dengan mengkombinasikan band 4, 3 dan 2 (*true color*). Citra komposit RGB *band* 4–3–2 menempatkan *band* 4 ( $0.636 - 0.636 \mu\text{m}$ ) pada *band* merah, *band* 3 ( $0.533 - 0.590 \mu\text{m}$ ) pada *band* hijau dan *band* 2 ( $0.452 - 0.512 \mu\text{m}$ ) pada *band* biru. Citra komposit ini menampilkan kondisi geologi dan geomorfologi secara regional dari daerah penelitian

#### IV. HASIL DAN PEMBAHASAN

##### A. Skenario Pengujian

Skenario pengujian dilakukan untuk mendapatkan parameter terbaik sehingga sistem

menghasilkan nilai akurasi tinggi. Dalam pengujian sistem dilakukan beberapa tahapan skenario pengujian, diantaranya:

##### 1. Tahap pertama

Tahap pertama yaitu melakukan cropping pada citra RGB 4-3-2 pada aplikasi *Google Earth Engine*. *Image* Sentinel-2 dikumpulkan dalam rentang yang dipilih dan di-*filter* untuk menghasilkan satu koleksi gambar yang bebas dari awan dan nilai pantulan tinggi.

##### 2. Tahap kedua

Untuk *image* yang sudah dipilih, selanjutnya memilih beberapa *sample* untuk mengekstrak piksel yang dijadikan data training oleh sebuah *classifier* yang disebut klasifikasi dasar.

##### 3. Tahap ketiga

Pada tahap ketiga, setelah dilakukan training, maka selanjutnya dilakukan pengklasifikasian terhadap data-data *sample* yang sudah dibuat sebelumnya. Setelah klasifikasi, untuk melihat seberapa akurat klasifikasi yang dilakukan dilakukan perhitungan melalui uji akurasi dengan parameter: keseluruhan akurasi (*overall accuracy*), akurasi pembuat (*producer accuracy*), akurasi pengguna (*user accuracy*) dan koefisien kappa (*kappa coefficient*).

TABEL 4.1

JUMLAH TRAINING DAN VALIDASI POIN

NO	Kelas Penutup Lahan	Jumlah Training Poin	Jumlah Validasi Poin
1	Badan Air	27	15
2	Lahan Terbuka	27	15
3	Lahan Terbangun	27	15
4	Vegetasi	27	15

Untuk memastikan bahwa pengukuran hasil uji akurasi untuk semua klasifikasi berada dalam urutan yang sama, jumlah poin dan marker

untuk training & validasi didistribusikan secara merata antara semua kelas tutupan lahan.

##### B. Hasil Pengujian

##### 1. Hasil pengujian menggunakan Sentinel-2

Ketelitian dari confusion matrix dapat dihitung menggunakan Overall Accuracy (OA) dan Kappa Coefficient yang menunjukkan konfusi (kelalaian dan kesalahan *commission*, masing-masing akan dikuantifikasi oleh User Accuracy dan

Producer Accuracy). Uji hasil akurasi bertujuan untuk mengetahui tingkat ketelitian pemetaan pada saat melakukan klasifikasi. Klasifikasi citra dianggap benar jika hasil perhitungan confusion matrix  $\geq 80\%$ .

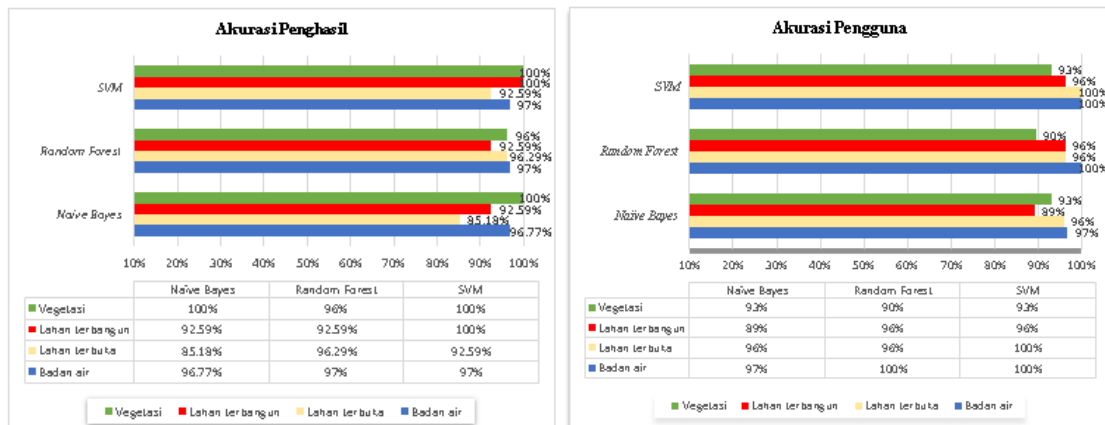
TABEL 4.2 HASIL KLASIFIKASI

NO	Classification	Overall Accuracy	Kappa Coeficient
1	Naïve Bayes	93,51 %	91,35%
2	Random Forest	95,37%	93,82%
3	Support Vector Machine (SVM) linear	97,22%	96,29%

Pada table diatas, dapat dilihat bahwa model terbaik didapatkan oleh *support vector machine* dengan akurasi paling tinggi. Nilai keseluruhan akurasi (*overall accuracy*) berjumlah 97,32% dan nilai kappa 96,42%. Dibawahnya terdapat *random forest* dengan nilai 95,53% untuk OA dan 94,04% untuk kappa. Dan akurasi paling rendah didapatkan oleh *naïve bayes* dengan nilai OA 93,75% dan kappanya berjumlah 91,65%. Dapat di analisis bahwa semakin kecil nilai *error rate* tingkat

akurasi semakin baik dan sebaliknya dengan kappa nilai yang tinggi akan memberikan akurasi yang lebih baik juga.

Akurasi penghasil merupakan akurasi yang dilihat dari sisi penghasil peta, sedangkan akurasi pengguna merupakan akurasi yang dilihat dari sisi pengguna petanya. Berikut merupakan hasil dari akurasi penghasil yang didapatkan dari klasifikasi, ditunjukkan pada gambar dibawah



GAMBAR 4.1

AKURASI PENGHASIL (*PRODUCER ACCURACY*) DAN AKURASI PENGGUNA (*USER ACCURACY*)

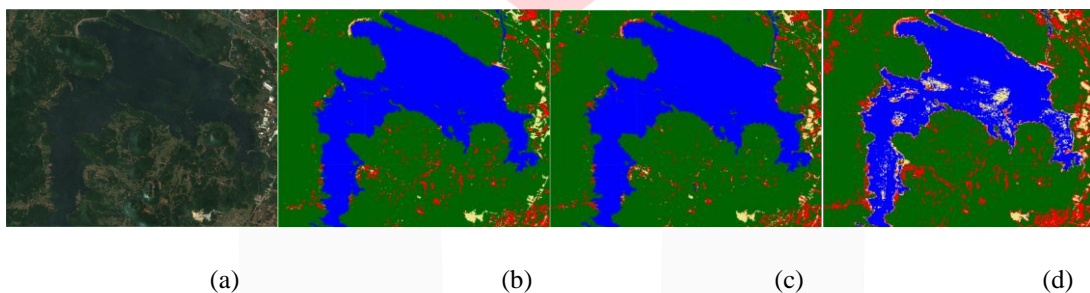
Pada sisi akurasi penghasil, kelas vegetasi mendapatkan nilai paling baik diantara ketiga *classifier* tersebut. Tetapi terdapat beberapa kesalahan klasifikasi, contohnya pada kelas vegetasi dengan klasifikasi *random forest*, terdapat 96% hasil yang dapat diklasifikasikan secara benar dan 4%

kesalahan berupa pengurangan (*ommission*) piksel yang masuk kedalam kelas tutupan lahan yang lain. Sedangkan nilai akurasi penghasil paling rendah didapatkan oleh lahan terbuka dengan *classifier* *Naïve Bayes* dengan tingkat akurasi 85,18%. Berdasarkan gambar akurasi pengguna diatas, pada

ketiga jenis *classifier* kelas badan air dengan *classifier* SVM, *random forest* ataupun *naïve bayes* mendapat akurasi yang paling baik diantara kelas tutupan lahan lainnya. Sebagai contoh: pada kelas badan air dengan *classifier* *Naïve Bayes* terdapat 97% akurasi yang diklasifikasikan secara benar, sedangkan 3% sisanya disebut dengan penambahan (Commission) jumlah piksel dalam suatu kelas yang diakibatkan masuknya piksel dari kelas tutupan lahan yang lain. Akurasi pengguna dan penghasil untuk kelas tertentu biasanya tidak sama. Pada contoh gambar diatas kelas vegetasi dengan *classifier* SVM mendapatkan akurasi penghasil 100% sedangkan akurasi penggunaanya adalah 93%. Ini berarti bahwa meskipun 100% dari vegetasi telah

diidentifikasi dengan benar sebagai “vegetasi”, hanya 93% dari daerah yang diidentifikasi sebagai “vegetasi” dalam klasifikasi yang benar-benar vegetasi.

Selanjutnya, hasil klasifikasi yang dilakukan terhadap tiga *classifier* yaitu *Support Vector Machine*, *Random Forest* dan *Naïve Bayes* dengan menggunakan citra satelit Sentinel-2 akuisisi menghasilkan klasifikasi yang tergolong sangat baik. Hal ini dapat dilihat dari nilai akurasi keseluruhan yang didapat diatas batas akurasi yaitu  $\geq 80\%$ . Hasil klasifikasi dapat dilihat pada gambar dibawah



GAMBAR 4.2. (A)

RAW DATA DAN HASIL KLASIFIKASI ANTARA KLASIFIKASI (B) SVM (C) RANDOM FOREST, DAN (D) NAÏVE BAYES

## 2. Uji akurasi menggunakan citra Landsat-8

Setelah didapatkan akurasi terbaik pada citra *Sentinel-2*, selanjutnya untuk mengetahui seberapa berpengaruh citra yang digunakan, dilakukan perbandingan dengan menggunakan citra *Landsat-8*. Perbandingan dilakukan dengan membandingkan hasil klasifikasi terbaik dari citra *Sentinel-2*, lalu dibandingkan dengan model yang sama oleh citra *Landsat-8*. Hasil yang ditunjukkan oleh citra *Landsat-8* ditunjukkan oleh table dibawah

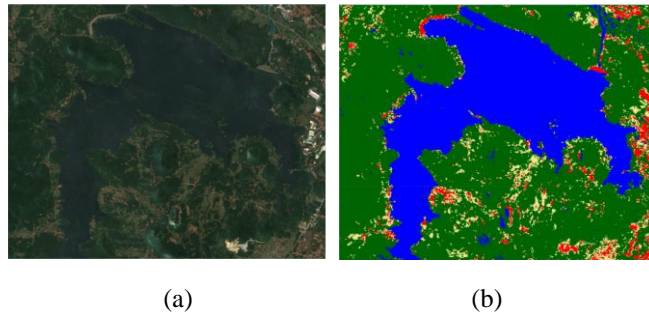
TABEL 4.3

HASIL KLASIFIKASI MENGGUNAKAN CITRA LANDSAT-8

Jenis <i>classifier</i>	Overall Accuracy	Kappa Coefficient
-------------------------	------------------	-------------------

Support Vector Machine (SVM)	74,07%	65,43%
------------------------------	--------	--------

Dapat dilihat pada table diatas, hasil akurasi keseluruhan pada citra *Landsat-8* adalah sebesar 74,07% sedangkan nilai koefisien kappanya sebesar 65,43%. Pada penelitian yang dilakukan oleh [34] mengungkapkan bahwa kinerja *Sentinel-2* lebih baik daripada data *Landsat-8* dikarenakan band Red-Edge 1 (Band 5) pada *sentinel* memiliki resolusi spasial yang lebih baik. Karena resolusi spasial *Sentinel-2* lebih baik, maka untuk pengidentifikasian obyek nilainya relatif lebih tinggi. Hasil klasifikasi dari citra *landsat* dapat dilihat pada gambar dibawah



GAMBAR 4.3 (A)

RAW DATA DAN (B) HASIL KLASIFIKASI SVM DENGAN MENGGUNAKAN CITRA LANDSAT-8

## V. KESIMPULAN DAN SARAN

### A. Kesimpulan

Pada penelitian ini telah dirancang suatu sistem yang dapat mengklasifikasi kelas tutupan lahan dengan menggunakan aplikasi Google Earth Engine dan tiga classifier: Naïve Bayes, Random Forest dan Support Vector Machine (SVM). Dalam penelitian dilakukan beberapa skenario pengujian sistem dengan hasil dan analisis pengujian yang dapat disimpulkan sebagai berikut:

1. Hasil terbaik diperoleh dengan classifier SVM dengan overall accuracy 97,22% dan Kappa Coefficient 96,29% yang diperoleh dari data satelit Sentinel-2, dikatakan lebih bagus dari Landsat-8 dikarenakan Sentinel-2 mempunyai band yang resolusi temporal dan spektralnya jauh lebih bagus.
2. Hasil Overall accuracy menggunakan Landsat-8 yaitu 74.07% dan kappa coefficient sebesar 65.43%
3. Hasil producer accuracy tertinggi Sentinel-2 didapatkan oleh kelas vegetasi dengan jumlah 100% menggunakan naïve bayes dan support vector machine dan lahan terbangun sebesar 100% oleh support vector machine, sedangkan user accuracy tertinggi didapatkan oleh lahan terbuka sebesar 100% menggunakan support vector machine dan badan air sebesar 100% dengan classifier random forest dan support vector machine.
4. Hasil producer accuracy terendah Sentinel-2 didapatkan oleh kelas lahan terbuka dengan jumlah 85.18% menggunakan naïve bayes dan user accuracy terendah didapatkan oleh lahan terbuka sebesar 89% menggunakan naïve bayes

### B. Saran

Adapun saran untuk mengembangkan lebih lanjut dari penelitian ini, sebagai berikut:

1. Diharapkan pada penelitian selanjutnya dapat mengumpulkan variasi data yang lebih banyak dengan kualitas citra satelit yang lebih tinggi sehingga menghasilkan ciri yang lebih jelas sehingga memudahkan pada saat klasifikasi

2. Diharapkan dapat menambahkan kombinasi indeks spektral pada saat klasifikasi dan membandingkan kelas klasifikasi lain sehingga dapat dibandingkan metode mana yang lebih baik
3. Diharapkan dapat menambah kelas tutupan lahan yang lebih banyak sehingga didapatkan data yang lebih akurat

## REFERENSI

- [1] Q. Weng, Z. Mao, J. Lin, X. Liao. "Land-Use Scene Classification Based on A CNN Using A Constrained Extreme Learning Machine". International Journal of Remote Sensing, 2018, pp. 1-18.
- [2] Lillesand, T. M and Kiefer R.W. "Penginderaan Jauh dan Interpretasi Citra". Yogyakarta: Gadjah Mada University Press, 1990.
- [3] Townshend, J. and Justice, C. "Information Extraction from Remotely Sensed Data". A User View. Remote Sensing, 2, 313-329, 1981.
- [4] Barret, R. B dan L. F. Curtis. "Introduction to environmental remote sensing". Chapman and Hall. London. 352 h, 1982.
- [5] Liang, S. "Advances in Land Remote Sensing System, Modeling Inversion and Application". 2008, Springer, Dordrecht.
- [6] Mulyoutami E, Sakuntaladewi N, Agus F, van Noordwijk M. "Perubahan Pola Perladangan: Pergeseran persepsi mengenai para peladang di Indonesia". Bogor, Indonesia, 2010.
- [7] European Space Agency, E. S. A. (2015). "Sentinel-2 User Handbook". In Sentinel-2 User Handbook.
- [8] Ihlen, Vaughn. "Landsat 8 (L8) Data Users Handbook". U.S. Geological Survey, 2019.
- [9] Kumar, L. and Mutanga, O.\. "Google Earth Engine Applications since Inception Usage, Trends

and Potential". Remote Sensing, 10, 2018, Article No. 1509

[10] Widodo, Sri. Ekstraksi Fitur Citra Biomedik: Dilengkapi dengan Source Code Matlab. (n.d.). (n.p.): Penerbit Pustaka Rumah C1nta, 2021.

[11] Ho, T. "Random decision forests". In: Proceedings of the Third International Conference

on Document Analysis and Recognition, vol. 1, 1995, pp. 278–282. IEEE

[12] Wibowo, A. T., Saikhu, A., & Soelaiman, R. "Implementasi Algoritma Deteksi SPAM yang Tersisipi Informasi Citra dengan Metode SVM dan Random Forest", 2016, TUGAS AKHIR – KI141502.

