

ANALISIS KETELITIAN KLASIFIKASI PENUTUPAN LAHAN MENGGUNAKAN METODE *DIGITIZE ON SCREEN* DAN *DEEP LEARNING SERIES CONVOLUTIONAL NEURAL NETWORK (CNN)* BERDASARKAN CITRA LANDSAT-8 OLI (STUDI KASUS: PROVINSI KALIMANTAN TIMUR)

Bangun Muljo Sukojo^{a,*}, Niken Ramadaningtyas^a

^a Departemen Teknik Geomatika, FTSPK-ITS, Kampus ITS Sukolilo, Surabaya, 60111, Indonesia

*Korespondensi Penulis, E-mail: bangunms@gmail.com



Dikirim: 22 April 2024;

Diterima: 19 Maret 2025;

Diterbitkan: 25 Maret 2025.

Abstrak. Penutupan lahan bersifat dinamis dikarenakan kebutuhan manusia atau kejadian alam yang dapat terjadi secara terencana maupun tidak terencana. Dit. IPSDH-KLHK menggunakan data citra satelit penginderaan jauh untuk menghasilkan data penutupan lahan dengan metode interpretasi visual (penafsiran manual). Identifikasi objek dilakukan dengan cara *digitize on screen*. Seiring berkembangnya zaman dan teknologi saat ini telah muncul beberapa penelitian mengenai klasifikasi penutupan lahan dan uji akurasi nya menggunakan teknologi terbaru, salah satunya menggunakan *deep learning*. Dalam penelitian ini dilakukan uji akurasi hasil klasifikasi *digitize on screen* dan klasifikasi penutupan lahan dengan *deep learning* beserta uji akurasinya. Uji akurasi klasifikasi penutupan lahan hasil *digitize on screen* dilakukan dengan metode *centroid*. Validasi dilakukan dengan menggunakan

citra satelit resolusi tinggi yaitu *google earth pro* sesuai temporal akuisisi citra Landsat 8 yang digunakan, yaitu Juli 2019-Juni 2020 dengan menyebar 360 sampel secara acak. Hasil menunjukan Provinsi Kalimantan Timur memiliki 21 kelas penutupan lahan dengan nilai *overall accuracy* 87,22% kategori sangat baik dan masuk toleransi. Klasifikasi penutupan lahan menggunakan *deep learning* dilakukan dengan menggunakan citra Landsat-8 OLI yang telah dilakukan segmentasi. Pengambilan sampel dilakukan dengan *segment picker* untuk 20 kelas penutupan lahan tanpa kelas Pertanian Lahan Kering Campur. Hasil klasifikasi menunjukan saling tumpang tindih karena suatu kelas penutupan lahan juga terklasifikasi menjadi kelas lainnya serta tidak semua area citra terklasifikasi. Uji akurasi dilakukan dengan lokasi penyebaran titik sampel yang sama dengan sampel uji metode *digitize on screen*. Nilai akurasi metode *deep learning* menggunakan sampel pada area terklasifikasi sebanyak 188 sampel menghasilkan akurasi 70,21% untuk 21 kelas penutupan lahan. Hal ini disebabkan banyak nya kelas penutupan lahan dengan kunci interpretasi yang hampir mirip. Kunci interpretasi 21 kelas penutupan lahan lebih cocok digunakan untuk metode *digitize on screen*.

Kata kunci: CNN; *Deep Learning*; *Digitize on Screen*; Penutupan Lahan; Uji Akurasi.

Accuracy Analysis Of Land Cover Classification Using Digitize On Screen and Deep Learning Series Convolutional Neural Network (CNN) Methods Based on Landsat-8 OLI Images (Case Study: East Kalimantan Province)

Abstract. Land cover is dynamic due to human needs or natural events that can occur in a planned or unplanned manner. Dit. IPSDH-KLHK uses remote sensing satellite imagery data to generate land cover data using a visual interpretation method (manual interpretation). Object identification is done by digitizing on screen. Along with the development of the times and current technology, several studies have emerged regarding the classification of land cover and its accuracy test using the latest technology, one of which uses deep learning. In this study, the accuracy of the digitize on screen classification results and land cover classification using deep learning was carried out along with the accuracy test. The test for the accuracy of land cover classification as a result of digitizing on screen was carried out using the centroid method. Validation was carried out using high resolution satellite imagery, namely google earth pro according to the temporal acquisition of Landsat 8 imagery used, namely July 2019-June 2020 by spreading 360 samples randomly. The results show that East Kalimantan Province has 21 land cover classes with an overall accuracy value of 87.22% in the very good category and in the tolerance category. Land cover classification using deep learning is carried out using segmented Landsat-8 OLI images. Sampling was carried out with a segment picker for 20 land cover classes without the Mixed Dry Land Agriculture class. The classification results show overlapping because one land cover class is also classified into other classes and not all image areas are classified. The accuracy test was carried out with the same location of the sample point as the test sample for the digitize on screen method. The accuracy value of the deep learning method using 188 samples in classified areas resulted in an accuracy of 70.21% for 21 land cover classes. This is due to the many land cover classes with almost similar interpretation keys. The interpretation key of 21 land cover classes is more suitable for the digitize on screen method.

Keywords: CNN; Deep Learning; Digitize on Screen; Land Cover; Test Accuracy

I. PENDAHULUAN

Penutupan lahan adalah penutupan biofisik pada permukaan bumi yang dapat diamati dan merupakan hasil interpretasi dari citra penginderaan jauh. Beberapa objek pada data penutupan lahan berubah cepat, sehingga pemantauan perubahan data penutupan lahan yang cepat dan akurat menjadi hal yang sangat penting[3]. Penutupan lahan bersifat dinamis dikarenakan kebutuhan manusia atau kejadian alam yang dapat terjadi secara terencana maupun tidak terencana. Saat ini Provinsi Kalimantan Timur, lebih tepatnya Sebagian wilayah Kabupaten Penajam Paser Utara dan Kutai Kartanegara, dicanangkan menjadi ibukota baru Negara Indonesia[21]. Angka Deforestasi Bruto Kalimantan Timur Tahun 2018-2019 sebesar 54,8 ribu ha (11,8%) merupakan deforestasi terluas ketiga di periode ini[17]. Pada 2019-2020 nilai deforestasi Kalimantan Timur turun menjadi 6,17 ribu ha dan menempati urutan ke 10 deforestasi terluas[18]. Tentu hal ini akan berdampak pada dinamika penutupan lahan di Provinsi Kalimantan Timur.

Dalam rangka mengatasi dinamika penutupan lahan, Kementerian Lingkungan Hidup dan Kehutanan (KLHK) secara konsisten melakukan pemantauan penutupan lahan. Dit. IPSDH menggunakan data citra satelit penginderaan jauh yaitu Landsat-8 OLI yang disiapkan oleh LAPAN untuk menghasilkan data penutupan lahan dengan metode interpretasi visual (penafsiran manual). Proses penafsiran citra satelit penginderaan jauh ini memerlukan sumber


daya manusia yang andal, peralatan yang memadai, dan metode yang standar untuk menghasilkan data yang konsisten dan akurat[20].

Seiring perkembangan zaman dan teknologi saat ini telah muncul beberapa penelitian mengenai klasifikasi penutupan lahan dan uji akurasi nya menggunakan teknologi terbaru. *Deep learning* telah menjadi salah satu topik dalam dunia *machine learning* karena kapabilitasnya yang signifikan dalam memodelkan berbagai data kompleks seperti citra dan suara[28]. Pada tahun 2012, sebuah CNN dapat melakukan pengenalan citra dengan akurasi yang menyaingi manusia pada dataset tertentu[1].

Inti dari penelitian ini adalah melakukan klasifikasi dan uji akurasi penutupan lahan menggunakan data yang sama dengan metode yang berbeda. Diharapkan dari penelitian ini dapat menjadi referensi untuk kegiatan klasifikasi penutupan lahan yang efektif dan dapat teruji akurasi nya. Dengan begitu data tetap bisa dimanfaatkan oleh pihak-pihak yang berkepentingan.

II. METODOLOGI

Lokasi Penelitian terletak di Provinsi Kalimantan Timur dengan koordinat geografis 113°44' BT dan 119°00' BT serta di antara 2°33' LU dan 2°25' LS.




Gambar 1. Lokasi Penelitian

Data yang digunakan dalam penelitian ini adalah Data raster berupa mosaik citra Landsat-8 Level 1 *tile based* (*minim cloud cover*) ukuran 1 degree x 1 degree periode Juli 2018 - Juni 2019 (untuk penutupan lahan tahun 2019) dan Juli 2019 – Juni 2020 (untuk penutupan lahan tahun 2020) wilayah Provinsi Kalimantan Timur yang bersumber dari Direktorat IPSDH-KLHK. Data vektor penutupan lahan tahun 2019 dan 2020 wilayah Provinsi Kalimantan Timur skala nasional 1:250.000. Data vektor batas administrasi Provinsi Kalimantan Timur pada Oktober 2020 skala 1:100.000. Ketiga data tersebut bersumber dari Direktorat IPSDH-KLHK. Batas administrasi provinsi seluruh Indonesia skala nasional 1:250.000.


Piranti keras yang digunakan pada penelitian ini adalah laptop dan komputer. Piranti lunak yang digunakan pada penelitian ini adalah ArcGIS Desktop 10.3 untuk pengolahan data vektor titik uji akurasi klasifikasi penutupan lahan hasil dari metode *digitize on screen* serta digunakan untuk peyajian data berupa peta, ArcGIS Pro 2.7 untuk pengolahan data raster menggunakan metode *Deep Learning (CNN)*, *Google Earth Pro* untuk validasi jenis penutupan lahan, dan *Microsoft Office 365* untuk pengolahan data tabular, pembuatan laporan, serta penyajian laporan.

Pengolahan data dilaksanakan dalam dua tahap. Tahap pertama dilakukan uji akurasi penutupan lahan hasil *digitize on screen*. Tahap kedua dilakukan klasifikasi penutupan lahan dengan metode *deep learning* serta uji akurasi. Pada **Gambar 2** dilakukan uji akurasi hasil klasifikasi penutupan lahan dari metode *digitize on screen*. Uji akurasi dilakukan untuk data vektor berupa SHP penutupan lahan Provinsi Kalimantan Timur tahun 2020 hasil *digitize on screen*. Penyebaran sampel uji akurasi dilakukan dengan metode *sampling random point* pada *software* ArcGIS dengan tools “*Create Random Points*” pada *ArcToolbox*. Jumlah sampel uji akurasi penutupan

lahan Kalimantan Timur tahun 2020 adalah 360 sampel untuk 21 kelas penutupan lahan. Validasi data penutupan lahan menggunakan metode *centroid* dimana menggunakan titik pusat (*centroid*) sebagai titik sampel dengan *buffer* lingkaran seluas 6,25 ha (jari-jari ± 141 m), yang merupakan luas unit pemetaan terkecil (MMU) dalam pembuatan data penutupan lahan KLHK (**Gambar 3**).



Gambar 2. Diagram Alir Klasifikasi dan Uji Akurasi Metode *Digitize on Screen*



Gambar 3. Unit titik sampel data referensi (Direktorat IPSDH-KLHK, 2020)

Validasi data penutupan lahan hasil *digitize on screen* dilakukan dengan meletakkan sampel pada citra satelit resolusi tinggi yaitu *google earth pro* untuk mengidentifikasi lokasi sampel pada objek penutupan lahan. Digunakan pula citra satelit Landsat 8 OLI periode


satu tahun sebelumnya untuk mengetahui riwayat perubahan penutupan lahan pada titik sampel tersebut (**Gambar 4**)

No Sampel	Kode PL 2020 / Hasil Validasi	Citra Landsat 2019 / Tanggal Citra Google Earth	Citra Landsat 2020 / Citra Google Earth
1.	50011 (B) Rawa		
	50011	Tanggal Citra Google Earth: 11 September 2019	

Gambar 4. Monogram Validasi Penutupan Lahan

Akurasi adalah ukuran/tingkat kebenaran data/peta hasil klasifikasi terhadap data referensi[16]. Metode yang umum digunakan untuk menghitung akurasi klasifikasi penutupan lahan dari data penginderaan jauh adalah matriks error (*error matrix*) dan nilai kappa. Matriks error pada penelitian ini terdapat nilai *omission error*, *comission error*, *user accuracy*, *producer accuracy*, dan *overall accuracy*. Nilai akurasi dilihat dari nilai *overall accuracy* yang dihasilkan.

Pada **Gambar 5** dilakukan klasifikasi penutupan lahan menggunakan metode *deep learning* menggunakan data raster berupa Citra Landsat 8 OLI Provinsi Kalimantan Timur periode Juli 2019 – Juni 2020. *Deep learning* adalah metode pembelajaran yang dilakukan oleh mesin dengan cara meniru bagaimana sistem dasar otak manusia bekerja. Sistem dasar otak manusia bekerja ini disebut *neural networks*. Maka dari itu *deep learning* disebut menggunakan *artificial neural networks* dengan kata lain menggunakan *neural networks* buatan[29]. Metode *Deep Learning* yang saat ini memiliki hasil paling signifikan dalam pengenalan citra adalah *Convolutional Neural Network* (CNN) [24]. *Convolutional Neural Network* (CNN) merupakan salah satu metode *deep learning* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra[30]. CNN bisa digunakan untuk mendeteksi dan mengenali objek pada sebuah image[30]. *Training sampel* atau sampel pelatihan digunakan untuk melatih model *deep learning* menggunakan alat geoproses. File pendefinisian model yang dihasilkan atau *deep learning model package* (.dlpk) digunakan untuk menjalankan alat geoproses inferensi untuk mengekstrak lokasi objek tertentu, mengklasifikasikan, memberi label objek, atau mengklasifikasikan pixel dalam citra[9].




Gambar 5. Diagram Alir Klasifikasi Metode *Deep Learning*

III. HASIL DAN PEMBAHASAN

A. Penutupan Lahan Hasil *Digitize on Screen*

Klasifikasi metode *digitize on screen* menghasilkan 21 kelas penutupan lahan yang terdiri dari 7 kelas hutan dan 14 kelas non-hutan, diantaranya adalah Hutan Lahan Kering Primer (2001), Hutan Lahan Kering Sekunder (2002), Hutan Mangrove Primer (2004), Hutan Mangrove Sekunder (20041), Hutan Rawa Primer (2005), Hutan Rawa Sekunder (20051), Hutan Tanaman (2006), Perkebunan (2010), Semak Belukar (2007), Semak Belukar Rawa (20071), Pertanian Lahan Kering (20091), Pertanian Lahan Kering Campur (20092), Sawah (20093), Tambak (20094), Permukiman (2012), Permukiman Transmigrasi (20122), Lahan Terbuka (2014), Pertambangan (20141), Tubuh Air (5001), Rawa (50011), Bandara / Pelabuhan (20121). Luas kelas hutan adalah 7.553.710,06 ha dan kelas non-hutan adalah 5.308.779,29 ha.



Gambar 6. Peta Penutupan Lahan Kalimantan Timur Periode Juli 2019-Juni 2020 Hasil Digitize on Screen

B. Sampel Uji Akurasi Penutupan Lahan Hasil Digitize on Screen

Tahap pembuatan sampel menghasilkan total 360 sampel uji untuk 21 kelas penutupan lahan Kalimantan Timur tahun 2020. Jumlah sampel per penutupan lahan disajikan pada tabel berikut.

Tabel 1. Jumlah Sampel Per Kelas Penutupan Lahan

Kode Penutupan Lahan Tahun 2020	Luas (Ha)	Luas (Km ²)	Jumlah Sampel
2001	2.270.777,63	22.707,78	63
2002	4.381.855,78	43.818,56	108
2004	33.190,81	331,91	1
2005	22.447,22	224,47	2
2006	574.308,92	5.743,09	14
2007	1.962.048,78	19.620,49	53
2010	1.373.238,40	13.732,38	47
2012	88.935,77	889,36	3
2014	146.489,70	1.464,90	2
5001	187.420,25	1.874,20	3
20041	153.341,11	1.533,41	4
20051	103.624,27	1.036,24	2
20071	507.671,49	5.076,71	10
20091	86.775,16	867,75	7
20092	544.499,02	5.444,99	17
20093	32.091,74	320,92	5
20094	118.695,51	1.186,96	2
20121	1.159,40	11,59	5
20122	16.181,25	161,81	3
20141	167.505,43	1.675,05	1
50011	90.231,70	902,32	8
Total	12.862.489,35	128.624,89	360

C. Matriks Error Penutupan Lahan Kalimantan Timur Juli 2019-Juni 2020

Nilai akurasi disajikan dalam bentuk *matrix error* pada tabel berikut.

Tabel 2. Matriks Error Penutupan Lahan Kalimantan Timur Juli 2019-Juni 2020

KELAS PL	DATA REFERENSI																				Error of Commission	User Accuracy		
	H1	H2	H3	H4	H5	H6	H7	H8	H9	H10	H11	H12	H13	H14	H15	H16	H17	H18	H19	H20				
P L A T I F O R M	H1	100																			100			
	H2		100																		100			
	H3			100																	100			
	H4				100																100			
	H5					100															100			
H A T I L A H	H6						100														100			
	H7							100													100			
	H8								100												100			
	H9									100											100			
	H10										100										100			
N E T W O R K	H11											100									100			
	H12												100								100			
	H13													100							100			
	H14														100						100			
	H15															100					100			
H A N D B O O K	H16																100				100			
	H17																	100			100			
	H18																		100		100			
	H19																			100	100			
	H20																				100			
T O T A L	TOTAL	88	104	2	4	2	5	18	46	40	3	2	2	9	5	2	23	5	2	4	2	1	6	380
	Error of Omission	38.2	8.7	58.0	58.0	58.0	28.3	5.2	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	38.7
	Producer Accuracy	88.7	91.3	50.0	50.0	50.0	20.0	73.7	98.1	93.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0	83.3	
	Overall Accuracy	87.22222222																						

Overall Accuracy adalah nilai yang memberikan informasi proporsi area dalam peta referensi yang diklasifikasikan dengan benar. Nilai dengan akurasi 100% artinya semua areal dalam peta perubahan penutupan lahan telah diklasifikasikan dengan benar tanpa kesalahan. Dari 360 sampel yang disebar secara acak untuk 21 kelas penutupan lahan Provinsi Kalimantan Timur tahun 2020 didapatkan overall accuracy sebesar 87,22%. Nilai ini dapat dikatakan masuk untuk standar toleransi ketelitian unsur peta rupa bumi dari Perka BIG No 15 tahun 2014 berupa penutupan lahan yang mana standar nya adalah 85%. Menurut Koefisien Cohen, overall accuracy 87,2% atau 0,872 tergolong pada akurasi sangat baik. Adapun untuk overall accuracy penutupan lahan yang diklasifikasikan sebagai hutan dan non-hutan tertera pada tabel 3 berikut.

Tabel 3. Matriks Error Kelas Penutupan Lahan Hutan dan Non-Hutan Kalimantan Timur Juli 2019 – Juni 2020

Kelas Tutupan Lahan	DATA REFERENSI						
	Hutan	Non Hutan	Total	Error of Commission Hutan	User Accuracy Hutan	Error of Commission Non Hutan	User Accuracy Non Hutan
Hutan	192	2	194	1,03	98,97		
Non Hutan	12	154	166			7,23	92,77
Total	204	156	360				
Error of Omission Hutan	5,88						
Producer Accuracy Hutan	94,12						
Error of Omission Non Hutan		1,28					
Producer Accuracy Non Hutan		98,72					
Overall Accuracy	96,11111111						

Total sampel untuk penutupan lahan hutan adalah sebanyak 194 sampel sedangkan penutupan lahan non-hutan adalah 166 sampel, sehingga total sampel keseluruhan adalah 360 sampel. Overall accuracy penutupan lahan yang diklasifikasikan dengan hutan dan non-hutan memiliki nilai 96,11% tergolong sangat baik dan masuk toleransi.

D. Segmentasi Citra

Citra yang digunakan dalam proses deep learning adalah citra Landsat-8 OLI hasil segmentasi. Segmentasi dapat mengelompokkan piksel-piksel tetangga atau yang bersebelahan yang memiliki warna sama dan memiliki karakteristik bentuk tertentu sehingga lebih memudahkan mesin


untuk mengklasifikasikan. Parameter segmentasi yang digunakan adalah *default system* dengan nilai sebagai berikut.

- a) *Spectral detail* : 15,50
- b) *Spatial detail* : 15
- c) *Minimum segment use in pixel*: 20

Nilai *spectral detail* dan *spatial detail* berkisar 1-20, semakin tinggi nilai nya maka semakin terlihat perbedaan piksel-piksel yang berdekatan



Gambar 7. Monogram Hasil Segmentasi Citra



Gambar 8. Peta Citra Landsat-8 Kalimantan Timur Hasil Segmentasi

Dari perbandingan citra sebelum dan sesudah segmentasi dapat diketahui bahwa struktur citra menjadi lebih halus karena piksel-piksel yang serupa menyatu. Untuk kelas penutupan lahan yang berbeda secara jelas dan lebih mudah diinterpretasi perbedaannya, seperti penampakan citra kelas hutan dan non-hutan dapat lebih mudah lagi dibedakan kenampakannya di hasil segmentasi. Namun, untuk kelas penutupan lahan yang hampir mirip kenampakannya, seperti kelas-kelas hutan, justru lebih sulit untuk diinterpretasi. Karena warna piksel dalam kelas hutan cenderung hijau saja sehingga saat dilakukan segmentasi piksel-piksel tersebut menyatu.

E. Sampel Label Objek *Deep Learning*

Pembuatan sampel label objek untuk kelas penutupan lahan Kalimantan Timur dilakukan menggunakan *tools segment picker*. Sampel label objek dibuat dengan memilih segmen dari lapisan tersegmentasi. Dari 21 kelas penutupan lahan Kalimantan Timur sesuai data Dit.IPSDH-KLHK, dalam pengambilan sampel penelitian ini dilakukan untuk 20 kelas tanpa kelas “Pertanian Lahan Kering Campur” dikarenakan secara definisi kelas ini merupakan “seluruh kenampakan yang merupakan campuran areal pertanian, perkebunan, semak dan belukar” namun kelas yang disebutkan dalam definisi tersebut sudah terpisah menjadi masing-masing kelas, sehingga untuk menghindari kebingungan pendefinisian oleh mesin kelas ini tidak diklasifikasikan. Dikarenakan proses klasifikasi dilakukan terpisah per kelas penutupan lahan, maka sampel label objek *deep learning* diexport dalam format SHP dan dipisahkan berdasarkan kelas-kelas penutupan lahan.

Tabel 4. Luas Sampel Klasifikasi *Deep Learning*

Kelas Penutupan Lahan	Luas Label (Ha)
Tambak	2.657,97
Hutan Lahan Kering Primer	335.154,19
Hutan Lahan Kering Sekunder	358.482,75
Hutan Mangrove Primer	5.088,53
Hutan Mangrove Sekunder	5.531,50
Hutan Rawa Primer	94.733,49
Hutan Rawa Sekunder	16.379,42
Hutan Tanaman	6.686,48
Perkebunan	22.377,10
Semak Belukar	41.361,87
Semak Belukar Rawa	3.724,54
Sawah	410,75
Permukiman	1.601,97
Lahan Terbuka	2.436,84
Pertambangan	8.866,61
Tubuh Air	41.288,94
Rawa	5.789,59
Bandara Pelabuhan	104,81
Pertanian Lahan Kering	8.805,11
Permukiman Transmigrasi	900,51
TOTAL	962.382,98

F. Export Training Data

Sampel label objek yang telah dibuat selanjutnya diproses menjadi *training data deep learning*. Metadata format yang digunakan adalah *classified tiles* dikarenakan *training sample data* yang digunakan adalah berupa kelas peta penutupan lahan. Salah satu hasil dari *training data* adalah folder *image* yang berisi *image chips* hasil pemrosesan

sampel. Pemrosesan *training data* dilakukan secara terpisah untuk masing-masing kelas penutupan lahan. Dari 20 kelas penutupan lahan menghasilkan total 3.319 *image chips*.

G. Train Model Deep Learning

Pembuatan *training model* juga dilakukan secara terpisah untuk masing-masing kelas penutupan lahan. Dalam proses *training model* digunakan beberapa parameter yang dilakukan berdasarkan *trial error* untuk *epoch* dan *batch*. Menurut *trial error* parameter yang cocok digunakan untuk *training model* adalah menggunakan *epoch* 20 dan *batch* 4. Apabila menggunakan nilai diatas itu, seperti dalam *trial error epoch* 50 dan *batch* 32, komputer berhenti bekerja. Apabila menggunakan nilai parameter dibawah itu, maka mesin gagal mengeksekusi. Dalam folder *ModelCharasteristics* terdapat kurva pembelajaran berupa grafik *loss* yang menunjukkan kinerja pembelajaran model selama pemrosesan. Grafik *loss* dapat menentukan kategori model.

H. Hasil Classify Pixel Using Deep Learning

Klasifikasi piksel *deep learning* dilakukan secara terpisah untuk masing-masing kelas penutupan lahan dengan menggunakan file pendefinisian model format *deep learning model package* (.dlpk) hasil dari proses *training model*. Parameter yang digunakan dalam klasifikasi piksel *deep learning* diantaranya adalah

- Input raster* : Citra Landsat-8 OLI segmentasi
- Model definition* : File *deep learning model package*
- Argument* : Default (*Padding* 64, *batch* 4, *predict background true*, *tile size* 256)
- Processing mode* : Default (*process as mosaicked image*)


Setelah semua kelas selesai tahap proses klasifikasi, dilakukan konversi format data dari raster ke polygon menggunakan *conversion tools – from raster to polygon*.

I. Hasil Klasifikasi


Hasil klasifikasi Citra Landsat-8 OLI Provinsi Kalimantan Timur periode tahun 2019-2020 untuk 20 kelas penutupan lahan menggunakan metode *deeplearning* dapat dikatakan belum berhasil

sempurna dikarenakan beberapa kondisi sebagai berikut.


- 1) Beberapa kelas saling tumpang tindih yang menunjukkan suatu kelas juga terklasifikasi menjadi kelas lain nya, misalnya pada kelas hutan yang mayoritas memiliki warna hijau. Kelas hutan berupa Hutan Lahan Kering Primer, Hutan Lahan Kering Sekunder, Hutan Rawa Primer, dan Semak Belukar mayoritas terklasifikasi lebih luas dan saling terklasifikasi kelas satu ke kelas lainnya.




Gambar 9. Peta Hasil Klasifikasi Penutupan Lahan Metode Deep Learning Hutan Lahan Kering Primer



Gambar 10. Peta Hasil Klasifikasi Penutupan Lahan Metode Deep Learning Hutan Lahan Kering Sekunder




Gambar 11. Peta Hasil Klasifikasi Penutupan Lahan Metode *Deep Learning* Hutan Rawa Primer



Gambar 12. Peta Hasil Klasifikasi Penutupan Lahan Metode *Deep Learning* Hutan

- 2) Beberapa kelas terlihat tidak terklasifikasi dengan baik sehingga menyebabkan timbulnya area kosong tidak terklasifikasi.



Gambar 13. Daerah Gambar Tidak Terklasifikasi

Dari gambar sebelah kiri hasil klasifikasi penutupan lahan menggunakan *deep learning* dibatasi dengan

garis merah. Dapat dilihat bahwa klasifikasi tidak menutup seluruh area. Kelas tubuh air berupa danau dan sungai nampak tidak terklasifikasi secara sempurna namun area terklasifikasi sudah benar. Kelas Hutan Rawa Primer dan Sekunder juga tidak terklasifikasi secara sempurna serta nampak terklasifikasi pula menjadi Hutan Lahan Kering Primer ditunjukkan pada polygon hijau sehingga hasil klasifikasi saling tumpang tindih. Dari gambar sebelah kanan terlihat kelas pertambangan, perkebunan, tambak, dan semak belukar. Kelas pertambangan dan perkebunan tidak terklasifikasi seluruhnya namun area klasifikasi sudah benar. Kelas semak belukar tidak terklasifikasi seluruhnya dan area klasifikasi salah karena terklasifikasi sebagai Hutan Lahan Kering Primer dan Sekunder yang ditampilkan dengan polygon hijau tua dan hijau muda.

Hasil klasifikasi masing-masing kelas penutupan lahan digabungkan menggunakan *tools merge* sehingga menghasilkan luas per kelas penutupan lahan sebagai berikut.

Tabel 5. Luas Penutupan Lahan Hasil Klasifikasi *Deep Learning*

No	Kode PL	Kelas Penutupan Lahan	Luas (Ha)
1	2001	Hutan Lahan Kering Primer	5.250.097,32
2	2002	Hutan Lahan Kering Sekunder	4.762.870,42
3	2004	Hutan Mangrove Primer	6.092,47
4	20041	Hutan Mangrove Sekunder	1.286,71
5	2005	Hutan Rawa Primer	6.183.434,01
6	20051	Hutan Rawa Sekunder	1.179.807,36
7	2006	Hutan Tanaman	35,29
8	2010	Perkebunan	54.794,67
9	2007	Semak Belukar	1.280.596,50
10	20071	Semak Belukar Rawa	1.502,34
11	20091	Pertanian Lahan Kering	277,94
12	20093	Sawah	16.449,21
13	20094	Tambak	49,43
14	2012	Permukiman	43,53
15	20122	Permukiman Transmigrasi	52,51
16	2014	Lahan Terbuka	2.352,65
17	5001	Tubuh Air	67.424,25
18	50011	Rawa	8,72
19	20121	Bandara Pelabuhan	0,05
20	20141	Pertambangan	9.331,15
Total			18.816.506,53

J. Uji Akurasi Kalsifikasi Penutupan Lahan *Deep Learning*

Uji akurasi hasil klasifikasi penutupan lahan metode *deep learning* dilakukan berdasarkan sampel pada area terklasifikasi saja dari lokasi penyebaran sampel *digitize on screen*. Dari 188 sampel pada area

terklasifikasi hasil *deep learning* didapatkan matriks konfusi sebagai berikut.

Tabel 6. *Matrix Error* Penutupan Lahan Kalimantan Timur Periode Juli 2019 – Juni 2020 Metode *Deep Learning*

Kode PL	Data Referensi																			Error of Commission	User Accuracy
	Ht	Hs	Hwp	Hnp	Ht	B	Pk	Pm	T	A	Br	Pt	Sw	Tm	Bkr	Tr	Tb	Rw	TOTAL		
Ht	45,00	15,00				2,00	4,00	3,00												78,00	24
Hs	1,00	14,00				2,00	5,00	2,00												78,00	15
Hwp			1,00																	1,00	0
Hnp				1,00																1,00	0
Ht	1,00	3,00				1,00	3,00	3,00												21,00	85
Hs																				1,00	0
Ht																				0,00	0
Hs																				0,00	0
Hwp																				0,00	0
Hnp																				0,00	0
B						1,00	4,00	2,00												0,00	0
Pk																				0,00	0
Pm																				0,00	0
T																				0,00	0
A																				0,00	0
Br																				0,00	0
Pt																				0,00	0
Sw																				0,00	0
Tm																				0,00	0
Bkr																				0,00	0
Tr																				0,00	0
Tb																				0,00	0
Rw																				0,00	0
TOTAL	45,00	75,00	1,00	1,00		7,00	20,00	15,00												188,00	
Error of Omission	3,3	14,7	-	100,0	-	100,0	80,0	86,7													
Producer Accuracy	96,7	85,3	100,0	-	100,0		20,0	13,3													
Overall Accuracy																				70,21	

Dari matrix konfusi dapat diketahui bahwa klasifikasi hasil *deep learning* 21 kelas memiliki nilai akurasi 70,21% dari hasil penyebaran sampel pada area terklasifikasi. Menurut koefisien Cohen *overall accuracy* 70,21% atau 0,7021 tergolong pada peluang akurasi baik.

Tabel 7. *Matrix Error* Kelas Penutupan Lahan Hutan dan Non-Hutan Kalimantan Timur Periode Juli 2019 – Juni 2020 Metode *Deep Learning*

Kelas Tutupan Lahan	DATA REFERENSI					
	Hutan	Non Hutan	Total	Error of Commission Hutan	User Accuracy Hutan	Error of Commission Non Hutan
Hutan	143,00	33,00	176,00	18,75	81,25	
Non Hutan	2,00	10,00	12,00			16,67
Total	145,00	43,00	188,00			83,33
Error of Omission Hutan	1,38					
Producer Accuracy Hutan	98,62					
Error of Omission Non Hutan		76,74				
Producer Accuracy Non Hutan		23,26				
Overall Accuracy			81,38			

Untuk kelas hutan dan non-hutan memiliki nilai akurasi 81,38% dari hasil penyebaran sampel pada area terklasifikasi. Menurut koefisien Cohen *overall accuracy* 81,38% atau 0,8138 tergolong pada peluang akurasi sangat baik.


K. Analisis Hasil Klasifikasi dan Ketelitian Penutupan Lahan Metode *Digitize on Screen* dan *Deep Learning*

Perbandingan luas hasil klasifikasi metode *digitize on screen* dan *deep learning* dapat dilihat pada tabel dan grafik berikut.

Tabel 8. Luas Hasil Klasifikasi Penutupan Lahan

Kode Penutupan Lahan Tahun 2020	Digitize on Screen (Km2)	Deep Learning (Km2)	Selisih
2001	22.707,78	52.500,97	29.793,20
2002	43.818,56	47.628,70	3.810,15
2004	331,91	60,92	270,98
20041	1.675,05	12,87	1.662,19

Kode Penutupan Lahan Tahun 2020	Digitize on Screen (Km2)	Deep Learning (Km2)	Selisih
2005	224,47	61.834,34	61.609,87
20051	1.036,24	11.798,07	10.761,83
2006	5.743,09	0,35	5.742,74
2010	13.732,38	547,95	13.184,44
2007	19.620,49	12.805,97	6.814,52
20071	5.076,71	15,02	5.061,69
20091	867,75	2,78	864,97
20092	5.444,99	0,00	5.444,99
20093	320,92	164,49	156,43
20094	1.186,96	0,49	1.186,46
2012	889,36	0,44	888,92
20122	161,81	0,53	161,29
2014	1.464,90	23,53	1.441,37
5001	1.874,20	674,24	1.199,96
50011	902,32	0,09	902,23
20121	11,59	0,00	11,59
20141	1.533,41	93,31	1.440,10
Total	128.624,89	188,165,07	152.409,91



Tabel 9. Diagram Luas Hasil Klasifikasi Penutupan Lahan

Hasil *digitize on screen* menunjukkan penutupan lahan paling luas adalah kelas Hutan Lahan Kering Sekunder dengan nilai 43.818,56 ha dan paling sedikit adalah kelas kelas Bandara/Pelabuhan dengan nilai 11,59 ha. Hasil *deep learning* menunjukkan penutupan lahan paling luas adalah kelas Hutan Rawa Primer dengan nilai 61.834,34 ha dan terdapat kelas yang tidak terklasifikasi dengan nilai 0 ha yaitu kelas Bandara/Pelabuhan.

Hasil klasifikasi kedua metode menghasilkan nilai akurasi yang berbeda jauh. Nilai akurasi hasil *digitize on screen* senilai 87,2% tergolong sangat baik sedangkan hasil *deep learning* 70,2%. Hal ini dapat disebabkan oleh beberapa hal diantaranya adalah sebagai berikut:

- Kunci interpretasi kelas penutupan lahan lebih cocok untuk kegiatan *digitize on screen* karena dapat menentukan kelas berdasarkan kelas tertentu di sekitarnya, misalkan kelas Hutan

Rawa berasosiasi dengan rawa, Hutan Mangrove biasanya terletak di daerah pantai atau sekitar sungai yang masih mengalami pasang surut, Hutan Tanaman dapat berasal dari Kegiatan reboisasi / reklamasi / penghijauan / industri perlu melihat kelas tersebut di tahun sebelumnya. *Deep Learning* melakukan klasifikasi berdasarkan sampel yang dibuat dalam kata lain berdasarkan apa yang diajarkan pada mesin, sehingga tidak dapat mengklasifikasikan kelas tertentu yang memiliki asosiasi dengan kelas lain nya.

- b. Metode *digitize on screen* tidak memungkinkan kelas satu terklasifikasi juga menjadi kelas lainnya karena pembuatan batas kelas penutupan lahan dilakukan secara manual dengan digitasi sehingga saat uji akurasi menggunakan data referensi titik sampel langsung dapat diketahui benar atau salahnya dan memiliki nilai 1 (satu) untuk setiap sampel. Sedangkan metode *deep learning* klasifikasi seluruhnya dilakukan oleh mesin sehingga memungkinkan timbul tumpang tindih hasil klasifikasi kelas penutupan lahan apabila memiliki ciri/*feature* yang mirip sehingga saat dilakukan uji akurasi dengan data referensi titik sampel nilai sampel perlu dibagi ke kolom benar dan salah. Hal ini memengaruhi nilai akhir dari akurasi.
- c. Hasil klasifikasi metode *deep learning* beberapa kelas penutupan lahan yang tidak terklasifikasi, pada *matrix error* digolongkan pada kolom "Tidak Terklasifikasi" yang menunjukkan sampel salah sehingga sangat mengurangi nilai akurasi.

IV. KESIMPULAN

Klasifikasi penutupan lahan menggunakan metode *digitize on screen* menghasilkan 21 kelas penutupan lahan dari 23 kelas selain awan dan savana yang mengacu pada SNI 8033-2014 dan Perdirjen No 1/2015. Sampel yang digunakan dalam uji akurasi untuk kedua metode sejumlah 360 sampel disebar secara acak dan telah mencakup seluruh kelas penutupan lahan. Nilai akurasi hasil klasifikasi penutupan lahan menggunakan metode *digitize on screen* adalah senilai 87,2% atau 0,872 untuk 21 kelas penutupan lahan dan senilai 96,1% atau 0,961

untuk kelas hutan dan non-hutan yang masuk toleransi menurut standar BIG pada Perka BIG No.15 tahun 2014 senilai 85% serta menunjukan kategori sangat baik. Citra yang digunakan dalam klasifikasi penutupan lahan Kalimantan Timur dari Citra Landsat-8 menggunakan metode *deep learning* adalah citra hasil segmentasi. Hasil klasifikasi menunjukan hasil yang kurang maksimal karena beberapa kelas mengalami kondisi bahwa satu kelas terklasifikasi juga menjadi kelas lainnya sehingga hasil saling tumpang tindih antara satu kelas dengan kelas lain nya. Kondisi lain juga menunjukan bahwa citra tidak berhasil diklasifikasi seluruh areanya sehingga menimbulkan area tidak terklasifikasi. Nilai akurasi klasifikasi penutupan lahan hasil *deep learning* dari 188 sampel pada area terklasifikasi untuk 21 kelas adalah senilai 70,21% atau 0,7021 yang menunjukan kategori baik sedangkan untuk kelas hutan dan non-hutan memiliki akurasi 81,38% atau 0,8138 yang tergolong sangat baik menurut koefisien Cohen. Kunci interpretasi 21 kelas penutupan lahan lebih cocok digunakan untuk metode *digitize on screen*.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Laboratorium Geospasial Departemen Teknik Geomatika ITS yang telah membantu dan memberikan fasilitas penunjang dalam pemrosesan data pada penelitian ini. Penulis juga menyampaikan terima kasih kepada Dit.IPSDH-KLHK yang telah membantu dalam penyediaan data penelitian.

DAFTAR PUSTAKA

- [1] A.Coates, H.Lee and A.Y. Ng, "An Analysis of Single-Layer Networks in Unsupervised Feature Learning" 2011.
- [2] A.Karpathy, "CS231n Convolutional Neural Network for Visual Recognition, "Stanford University, [Online].Available: <http://cs231m.github.io/>.
- [3] Belward, A. S., Estes, J. E., & Kilne, K. D. (1999). The IGBP-DIS global 1-km land-cover dataset DISCover: a project overview. Photogrammetric Engineering and Remote Sensing, 65, 1013-1020.
- [4] Badan Standarisasi Nasional. 2014. *Metode Penghitungan Perubahan Tutupan Hutan Berdasarkan Hasil Penafsiran Citra Penginderaan Jauh Optik secara Visual*. SNI 7645-2010. Badan Standarisasi Nasional: Jakarta.

- [5] Badan Standarisasi Nasional. 2010. *Klasifikasi Penutup Lahan*. SNI 8033-2014. Badan Standarisasi Nasional: Jakarta.
- [6] Brownlee, Jason. 2019. *How to Use Learning Curves to Diagnose Machine Learning Model Performance*. <https://machinelearningmastery.com/learning-curves-for-diagnosing-machine-learning-model-performance/> diakses pada 30 November 2021
- [7] ESRI. 2021. *ArcGIS Desktop*. <https://esriindonesia.co.id/arcgis-desktop> diakses pada 30 Agustus 2021 Pukul 12:40 WIB
- [8] ESRI. 2021. <https://pro.arcgis.com/en/pro-app/latest/get-started/get-started.htm> diakses pada 30 Agustus 2021 Pukul 13:13 WIB
- [9] ESRI. *Deep Learning in ArcGIS Pro*. <https://pro.arcgis.com/en/pro-app/2.6/help/analysis/image-analyst/deep-learning-in-arcgis-pro.htm> diakses pada 30 November 2021.
- [10] ESRI. *Segmentation*. <https://pro.arcgis.com/en/pro-app/2.7/help/analysis/image-analyst/segmentation.htm> diakses pada 30 November 2021
- [11] ESRI Indonesia Education & Community. 2020. *Digitasi Objek Menggunakan Metode Deep Learning dengan Software ArcGIS Pro*. <https://www.youtube.com/watch?v=LCr0zHmUOuU> diakses pada 2 September 2021 Pukul 16:04 WIB
- [12] Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80, 185-201.
- [13] Florensia, Yesinta, dkk. 2019. *Klasifikasi Citra Hiperspektral Pada Kasus Tutupan Lahan Menggunakan Metode Convolutional Neural Network (CNN)*. Palembang: Universitas Sriwijaya
- [14] Fung, T., & LeDrew, E. (1988). The determination of optimal threshold levels for change detection using various accuracy indices. *Photogrammetric Engineering and Remote Sensing*, 54, 1449-1454.
- [15] Janssen, L. L. F., & van der Wel, F. J. M. (1994). Accuracy assessment of satellite derived land-cover data: a review. *Photogrammetric Engineering and Remote Sensing*, 60, 419-426.
- [16] Kementerian Lingkungan Hidup dan Kehutanan. 2020. *Akurasi Data Penutupan Lahan Nasional Tahun 1990-2016*. Direktorat Inventarisasi dan Pemantauan Sumber Daya Hutan. Direktorat Jenderal Planologi Kehutanan dan Tata Lingkungan. Kementerian Lingkungan Hidup dan Kehutanan. Jakarta.
- [17] Kementerian Lingkungan Hidup dan Kehutanan. 2020. *Deforestasi Indonesia Tahun 2018-2019*. Direktorat Inventarisasi dan Pemantauan
- [18] Sumber Daya Hutan. Direktorat Jenderal Planologi Kehutanan dan Tata Lingkungan. Kementerian Lingkungan Hidup dan Kehutanan. Jakarta.
- [19] Kementerian Lingkungan Hidup dan Kehutanan. 2021. *Deforestasi Indonesia Tahun 2019-2020*. Direktorat Inventarisasi dan Pemantauan Sumber Daya Hutan. Direktorat Jenderal Planologi Kehutanan dan Tata Lingkungan. Kementerian Lingkungan Hidup dan Kehutanan. Jakarta.
- [20] Kementerian Lingkungan Hidup dan Kehutanan. 2020. *Penutupan Lahan*. Direktorat Inventarisasi dan Pemantauan Sumber Daya Hutan. Direktorat Jenderal Planologi Kehutanan dan Tata Lingkungan. Kementerian Lingkungan Hidup dan Kehutanan. Jakarta.
- [21] Kementerian Lingkungan Hidup dan Kehutanan. 2020. *Petunjuk Teknis Penafsiran Citra Satelit Resolusi Sedang Untuk Update Data Penutupan Lahan Nasional*. Direktorat Inventarisasi dan Pemantauan Sumber Daya Hutan. Direktorat Jenderal Planologi Kehutanan dan Tata Lingkungan. Kementerian Lingkungan Hidup dan Kehutanan. Jakarta.
- [22] Kementerian Lingkungan Hidup dan Kehutanan. 2020. *Rekalkulasi Penutupan Lahan Indonesia Tahun 2019*. Direktorat Inventarisasi dan Pemantauan Sumber Daya Hutan. Direktorat Jenderal Planologi Kehutanan dan Tata Lingkungan. Kementerian Lingkungan Hidup dan Kehutanan. Jakarta.
- [23] Kominfo. 2019. *Ibukota Negara Pindah ke Wilayah Penajam Paser Utara dan Kutai Kartanegara*. <https://www.kominfo.go.id/content/detail/20899/ibu-kota-negara-pindah-ke-sebagian-penajam-paser-utara-dan-sebagian-kutai-kartanegara/0/berita> diakses pada 4 September 2021 pukul 18:05 WIB
- [24] K. Fukushima, "Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position," *Biological Cybernetics*, 1980.
- [25] Khichar, M. L., Ram Niwas, dan M. S. Grewal. 2015. *Remote Sensing, GIS, and Land Use Planning*. Department of Agricultural Meteorology CCS Haryana Agricultural University India.
- [26] Kushardono, Dony. 2016. *"Klasifikasi Penutup/Penggunaan Lahan dengan Data Satelit Penginderaan Jauh Hiperspektral (Hyperion) menggunakan Metode Neural Network Tiruan"*. Jakarta Timur: Pusat Pemanfaatan Penginderaan Jauh, LAPAN.
- [27] Kvålseth, T. O. (2015). Measurement of Interobserver Disagreement: Correction of Cohen's

- Kappa for Negative Values. *Journal of Probability and Statistics*, vol. 2015, Article ID 751803, 8 pages, 2015
- [28] Lillesand, Kiefer. 1979. *Penginderaan Jauh dan Interpretasi Citra*. Yogyakarta: Gadjah Mada University Press.
- [29] Miranda, Eka dan Aryuni, Mediana. 2021. *Klasifikasi Tutupan Lahan Menggunakan Convolutional Neural Network pada Citra Satelit Sentinel-2*. Jakarta: Binda Nusantara University.
- [30] Maulid, Reyvan. 2021. *Kenali Algoritma Deep Learning*. <https://dqqlab.id/yuk-pahami-jenis-jenis-algoritma-deep-learning> diakses pada 31 Agustus 2021 pukul 09:27 WIB
- [31] Sena, Samuel. 2017. *Pengenalan Deep Learning Part 7: Convolutional Neural Network (CNN)*. Diakses melalui <https://medium.com/@samuelsena/pengenalan-deep-learning-part-7-convolutional-neural-network-cnn-b003b477dc94>
- [32] Suartika IW, Wijaya AY, Soelaiman R. 2016. Klasifikasi citra menggunakan convolutional neural network (CNN) pada Caltech 101. *Jurnal Teknik ITS*. 5(1):2337-3539.
- [33] Sukojo, Bangun Muljo dan Anita, Novi. 2021. *Analisis Identifikasi Oil Pattern Menggunakan Metode Deep Learning Semantic dari Citra Satelit Pleiades 1B dengan Software ArcGIS Pro*. Surabaya: Departemen Teknik Geomatika, FTSPK, ITS
- [34] Sukojo, BanGun Muljo dan Izzaty. Atika. 2021. *Identifikasi Lahan Kritis Dengan Penerapan Deep Learning Menggunakan Data Sentinel 2a (Studi Kasus: Kabupaten Lahat*. Surabaya: Departemen Teknik Geomatika, FTSPK, ITS
- [35] Stanford University, "An Introduction to Convolutional Neural Network," Vision Imaging Science and Technology Lab, Stanford University, [Online]. Available: http://white.stanford.edu/teach/index.php/An_Introduction_to_Convolutional_Neural_Networks.
- [36] Tang, W., Hu, J., Zhang, H., Wu, P., & He, H. (2015). Kappa coefficient: a popular measure of rater agreement. *Shanghai Archives of Psychiatry*, 2015, vol. 27, No. 1.
- [37] Teknik Geomatika, ITS. 2013. *Aturan Penyusunan Tugas Akhir*. Surabaya: Departemen Teknik Geomatika, FTSPK, ITS
- [38] Tosiani, Anna, dkk. 2020. *Standar Operasional Prosedur (SOP): Perhitungan Akurasi dan Uncertainty Perubahan Penutupan Lahan*. Bogor: IPB Press, Bogor-Indonesia