

Klasifikasi Tutupan Lahan Menggunakan Convolutional Neural Network pada Citra Satelit Sentinel-2

Eka Miranda*, Mediana Aryuni

Information Systems Department, School of Information Systems, Bina Nusantara University
Jl. KH. Syahdan No.9, RT.6/RW.12, Palmerah, Kec. Palmerah, Jakarta Barat 11480 Indonesia

*e-mail: ekamiranda@binus.ac.id

(received: 10 Januari 2021, revised: 12 April 2021, accepted: 20 April 2021)

Abstrak

Perencanaan dan pemantauan penggunaan lahan masih menjadi masalah di banyak negara berkembang seperti Indonesia. Teknologi konvensional dan observasi lapangan yang digunakan saat ini memiliki kendala terkait dengan wilayah Indonesia yang luas. *Deep learning* dan citra satelit dapat digunakan untuk mendukung otomatisasi pemantauan dan klasifikasi tutupan lahan. Tujuan penelitian ini adalah mengembangkan metode klasifikasi berdasarkan *Convolutional Neural Network* (CNN) dan citra satelit *Sentinel-2*. Penelitian ini menggunakan: fitur spektral, indeks spektral, fitur spasial sebagai *input* dan definisi kelas tutupan lahan dari dokumen RSNI-1 Badan Standar Nasional Indonesia untuk Klasifikasi Kelas Penutupan Lahan dalam Penafsiran Citra Optis Resolusi Sedang sebagai dasar untuk ekstraksi fitur. Area citra penelitian terletak di daerah Semarang. Alur penelitian meliputi: Mendefinisikan kelas hutan berdasarkan dokumen RSNI-1, Mengekstraksi fitur optik citra berdasarkan definisi kelas tutupan lahan, Mengekstraksi fitur citra dari citra satelit *Sentinel-2*, dan Mengklasifikasikan fitur objek citra menggunakan pengklasifikasi CNN. Segmentasi citra menghasilkan 2072 objek dengan menggunakan *eCognition*. Label kelas data pengujian ditentukan menggunakan pelatihan semi terawasi. Klasifikasi tutupan lahan dilakukan menggunakan *Convolutional Neural Network* untuk mengklasifikasikan objek ke kelas tutupan lahan hutan kering primer, hutan kering sekunder, hutan tanaman, padang rumput, pemukiman, badan air atau tanah terbuka. Metode CNN yang digunakan mampu mengklasifikasi dengan baik yaitu *overall accuracy* 98.4% untuk data pelatihan dan data pengujian, serta rata-rata nilai akurasi *user's accuracy* dan *producer's accuracy* lebih besar dari 95% untuk tiap kelas tutupan lahan.

Kata kunci: *Convolutional Neural Network* (CNN), klasifikasi tutupan lahan, *Sentinel-2*,

Abstract

Land cover planning and monitoring are problems in many developing countries and Indonesia. Conventional technology and field observations have constraint related to the wide coverage area in Indonesia. Deep learning and satellite imagery can be used to support automation of monitoring and land cover classification and planning. The research aimed to study a classification method based on Convolutional Neural Network (CNN) and Sentinel-2 satellite imagery. Spectral indices and spatial features were used as an input whereas the RSNI-1 document Indonesian National Standards Agency for Land cover classification in Medium Resolution Optical Images Interpretation as a basis for feature extraction. The study area covered land cover in Semarang area. The research flow consists of Defining forest classes based on the RSNI-1 document, Extracting optical features of imagery from the definition of land cover class, Extracting image features from Sentinel-2 satellite imagery, and Classifying the image object feature using the CNN. Image segmentation produced 2072 objects using eCognition software. Training data label for each class determined using a semi-supervised training approach. The land cover classification performed using the Convolutional Neural Network to classify the object into land cover class namely primary dry forest, secondary dry forest, plantation forest, grassland, settlement, waterbody or bare land. This research showed the CNN method performs high accuracy value result: overall accuracy of 98.4% for both training data and testing data. Average accuracy value for User's accuracy and producer's accuracy are more than 95% for each land cover classes.

Keywords: *Convolutional Neural Network* (CNN), land cover classification, *Sentinel-2*

1 Pendahuluan

Perencanaan dan pemantauan penggunaan lahan masih menjadi masalah di banyak negara berkembang seperti Indonesia. Teknologi konvensional dan observasi lapangan yang digunakan saat ini memiliki kendala terkait dengan wilayah Indonesia yang luas. Otomatisasi pemantauan dan klasifikasi tutupan lahan diperlukan untuk membantu pemantauan penggunaan lahan. Teknologi yang lebih lanjut diperlukan untuk dapat menganalisis tutupan lahan bumi secara otomatis dan mencakup area yang luas [1].

Deep learning dan citra satelit dapat digunakan untuk mendukung otomatisasi pemantauan dan klasifikasi tutupan lahan. Keuntungan penggunaan *deep learning* dengan data satelit sebagai *input* adalah dapat memfasilitasi akuisisi data yang lebih cepat dan cakupan data yang lebih luas dibandingkan dengan teknologi konvensional atau observasi lapangan [2]. Munculnya metode *deep learning* dalam dekade terakhir telah sangat berperan untuk mengembangkan metode yang handal untuk klasifikasi tutupan lahan menggunakan citra satelit sebagai *input*. Algoritma *Deep Learning* (DL) makin populer digunakan untuk analisis citra satelit (penginderaan jauh) beberapa tahun terakhir. DL telah diterapkan untuk analisis citra satelit termasuk klasifikasi citra, deteksi objek, klasifikasi penggunaan lahan dan tutupan lahan, segmentasi, dan analisis citra. Jaringan saraf sebagai dasar dari algoritma *deep learning* telah digunakan pada penginderaan jauh [3].

Algoritma *deep learning* terus berkembang. Salah satu algoritma DL yang berkembang pesat adalah *Convolutional Neural Networks* (CNNs). Studi terbaru menunjukkan bahwa representasi fitur yang dipelajari oleh CNN sangat efektif dalam pengenalan citra skala deteksi objek, dan segmentasi semantik [4][5][6][7].

Penelitian yang dilakukan oleh [8] menjelaskan model CNN dirancang sebagai hierarki *convolutional* dan lapisan *pooling*. Struktur hierarki CNN ini memungkinkan untuk mempelajari fitur dari data *input* secara hirarki. Penelitian ini berhasil melakukan pengenalan objek visual dan navigasi pengelihatian pada robot seluler *off-road*. Beragam data yang ada di dalam citra satelit seperti data multispektral belum dieksplorasi di penelitian ini. Penelitian lain yang dilakukan oleh [9] telah berhasil menggunakan informasi pada pita spektral citra satelit, yaitu bentuk dan warna untuk mengklasifikasikan tutupan lahan tetapi penelitian ini belum mengeksplorasi informasi indeks spektral pada citra satelit, sedangkan nilai indeks spektral ini berguna untuk mendeteksi suatu objek. Studi yang dilakukan oleh [10] menghasilkan penjelasan metode yang memanfaatkan keunggulan kerangka CNN yaitu: ekstraksi fitur citra secara otomatis untuk mengklasifikasi objek perkotaan yang kompleks (seperti atap bangunan dan mobil). Namun, penelitian ini belum mengekstraksi informasi yang ada pada definisi suatu kelas tutupan lahan. Penelitian yang dilakukan oleh [11] menjelaskan keuntungan penggunaan CNN dan memperoleh hasil akurasi yang tinggi 85% untuk klasifikasi tanaman (gandum, jagung, bunga matahari, kedelai, dan bit gula). Studi ini menjadi dasar untuk penggunaan lebih lanjut data citra satelit *Sentinel-1A* di Ukraina. Eksplorasi penggunaan CNN dan data citra *Sentinel* dapat juga dilakukan untuk wilayah Indonesia. Penelitian yang dilakukan oleh [12] menunjukkan keunggulan CNN untuk ekstraksi fitur dan klasifikasi tutupan lahan dari citra satelit. Penelitian ini menghasilkan akurasi sebesar 76%. Eksplorasi teknik ekstraksi dan seleksi fitur dapat digunakan untuk meningkatkan akurasi.

Berdasar hasil yang diperoleh dari penelitian sebelumnya, maka penelitian ini bertujuan mengembangkan metode klasifikasi tutupan lahan menggunakan CNN pada citra satelit *Sentinel-2* Kelas tutupan lahan yang dianalisa terdiri atas tujuh kelas yaitu hutan kering primer, hutan kering sekunder, hutan tanaman, padang rumput, pemukiman, badan air, dan lahan terbuka dengan area penelitian area Semarang, Jawa Tengah. Penelitian ini menggunakan fitur spektral, indeks spektral dan fitur spasial bersama sebagai fitur *input*. Penelitian ini juga menggunakan definisi kelas tutupan lahan dari dokumen RSNI-1 Badan Standar Nasional Indonesia untuk Klasifikasi Kelas Penutupan Lahan dalam Penafsiran Citra Optis Resolusi Sedang [13] sebagai dasar pada ekstraksi fitur untuk mendapatkan fitur pengklasifikasi yang tepat.

Tujuan penelitian ini yaitu melakukan klasifikasi tutupan lahan menggunakan *Convolutional Neural Network* pada citra satelit *Sentinel-2*. Tujuan ini dirumuskan berdasarkan potensi pengembangan penelitian sebelumnya. Kontribusi penelitian ini adalah menghasilkan metode

klasifikasi tutupan lahan sebagai alternatif cara untuk mengatasi masalah perencanaan dan pemantauan penggunaan lahan di Indonesia yang memiliki wilayah yang luas.

2 Tinjauan Literatur

2.1 Tutupan Lahan (Land Cover)

Tutupan lahan adalah tutupan fisik yang diamati di permukaan bumi. Penutup lahan meliputi kumpulan vegetasi, tanah terbuka, batu, atau air yang menempati permukaan tanah [13]. Penutup lahan dapat pula berarti penutup biofisik pada permukaan bumi yang dapat diamati [13]. Dipandang dari teknologi penginderaan jauh (inderaja), penutup lahan merupakan gambaran objek (penampakan biofisik) di permukaan bumi yang diperoleh dari sumber data terpilih (umumnya data penginderaan jauh) dan dikelompokkan ke dalam kelas-kelas penutup yang sesuai dengan kebutuhannya [13]. Klasifikasi Penutup Lahan Badan Standarisasi Nasional Indonesia SNI 7645:1:2014 disusun berdasarkan sistem klasifikasi penutup lahan UNFAO (*Food and Agriculture Organization of the United Nations*) dan ISO 19144-1 - *Geographic Information - Classification Systems - Part 1: Classification System Structure* ISO 19144-1. Definisi kelas tutupan lahan yang digunakan pada penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Definisi Kelas Tutupan Lahan [13]


Kelas tutupan lahan	Definisi kelas tutupan lahan	Kelas tutupan lahan
Hutan kering primer	Penampakan hutan primer ditandai dengan adanya objek yang berwarna hijau tua (pada pita 8, 4, 3) cenderung gelap dan bertekstur kasar dengan tajuk-tajuk pohon yang kelihatan bergerombol. Tidak terdapat bekas tebingan. Pada citra, warna yang cenderung gelap karena posisi objek yang berada pada tebing pegunungan tinggi sehingga cahaya matahari kurang.	<ol style="list-style-type: none"> 1. Hijau tua (warna) 2. Cenderung gelap (rona) 3. Bertekstur kasar (tekstur) 4. Tajuk pohon bergerombol (bentuk)
Hutan kering sekunder	Penampakan hutan sekunder ditandai dengan adanya objek yang berwarna hijau tua (pada pita 8, 4, 3) cenderung gelap dan bertekstur kasar dengan tajuk-tajuk pohon yang kelihatan bergerombol. Terdapat bekas tebingan. Pada citra, warna yang cenderung gelap karena posisi objek yang berada pada tebing pegunungan tinggi sehingga cahaya matahari kurang.	<ol style="list-style-type: none"> 1. Hijau tua (warna) 2. Cenderung gelap (rona) 3. Bertekstur kasar (tekstur) 4. Tajuk pohon bergerombol (bentuk)
Hutan tanam	Berwarna hijau (pada pita 8, 4, 3) Mempunyai umur seragam, tertata rapi dan mempunyai pola tertentu yang menunjukkan adanya manajemen dalam penanaman maupun pengelolaannya.	<ol style="list-style-type: none"> 1. Hijau (warna) 2. Cenderung agak gelap (rona) 3. Bertekstur kasar (tekstur) 4. Memiliki bentuk tertentu (bentuk)
Padang rumput	Penampakan objek ditandai dengan barisan tipis vegetasi yang bertekstur sangat halus berwarna hijau lumut (pada pita 8, 4, 3).	<ol style="list-style-type: none"> 1. Hijau (warna) 2. Cenderung agak gelap sampai agak terang (rona) 3. Bertekstur halus (tekstur)

<http://sistemasi.ftik.unisi.ac.id>

	Lapisan berwarna merah merupakan tanah terbuka. Penampakan rumput rawa sangat spesifik pada kondisi basah, namun pada kondisi kering cukup sulit dibedakan dengan tanah terbuka karena sama-sama berwarna merah (pada pita 8, 4, 3). Oleh karena itu diperlukan data pendukung seperti foto lapangan.	4. Tajuk rumput bergerombol (bentuk)
Badan air	Penampakan objek ditandai dengan adanya area berwarna biru muda, biru keputihan atau hitam (pada kombinasi pita 8, 4, 3) meliputi area cukup luas.	<ol style="list-style-type: none"> 1. Biru, biru muda, keputihan, hitam (warna) 2. Cenderung gelap sampai agak terang (rona) 3. Bertekstur halus (tekstur) 4. Bentuk danau, waduk, sungau dan laut tidak teratur (bentuk)
Permukiman	Dicirikan dengan sekumpulan pola bangunan yang rapat di permukiman kota, Jaringan jalan nampak padat. Permukiman di pedesaan lebih jarang dan terlihat adanya pola jalan penghubung antar kelompok permukiman.	<ol style="list-style-type: none"> 1. Warna 2. Terang (rona) 3. Bertekstur halus (tekstur) 4. Sekumpulan bangunan (bentuk)
Lahan terbuka	Penampakan objek (pada pita 8, 4, 3) ditandai dengan area berwarna merah muda hingga merah tua, kadang berwarna coklat, tergantung pada kandungan material tanahnya, dan berwarna putih apabila material tersusun dari kapur.	<ol style="list-style-type: none"> 1. Merah muda hingga tua, coklat, putih (warna) 2. Cenderung agak gelap sampai terang (rona) 3. Bertekstur kasar sampai halus (tekstur) 4. Bentuk lahan terbuka tidak teratur (bentuk)

2.2 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu jenis jaringan saraf yang biasa digunakan pada data citra. CNN bisa digunakan untuk mendeteksi dan mengenali objek pada sebuah citra [2]. Saat ini, banyak hasil yang mengesankan telah dicapai dalam domain penglihatan komputer dengan menggunakan metode *deep learning*. *Convolutional Neural Network* (CNN) adalah salah satu metode *deep learning*, yang memiliki sejumlah lapisan konvolusional dan penggabungan serta lapisan yang terhubung penuh (*Fully Connected Layer* (FCL)) sebagai penggolong [2]. CNN adalah salah satu model jaringan saraf untuk pembelajaran yang mendalam, yang dicirikan oleh tiga karakteristik spesifik, yaitu neuron yang terhubung secara lokal, *shared weight*, dan sub-sampel spasial atau temporal. Struktur penampang *input* pada CNN untuk matriks warna citra dapat dilihat pada Gambar 1 [2].



Gambar 1. Penampang Ukuran Input: 4 x 4 x 3 dengan 3 Channel Warna Matriks dari Citra Input


2.3 Sentinel-2

Satelit *Sentinel-2* adalah satelit pencitraan optik Eropa yang diluncurkan tanggal 23 Juni 2015, sebagai bagian dari program *Copernicus* Badan Antariksa Eropa [14]. Saat ini *Sentinel-2* merupakan salah satu satelit yang digunakan untuk menghasilkan citra satelit penutup lahan muka bumi (*land cover*). *Sentinel-2* dilengkapi dengan *instrument multispectral* dan memiliki 13 pita yang diperoleh dari instrumen MSI (*Multispectral Imager*). *Band* (pita) dalam citra satelit merupakan kumpulan panjang gelombang atau frekuensi bagi kanal atau saluran warna [15]. Pita-pita ini dikelompokkan ke daerah panjang gelombang berdasarkan asal cahaya [16]. *Sentinel-2* memiliki resolusi spasial 10 meter (untuk pita merah, biru, hijau dan *near-infrared*), 20 meter dan 60 meter (untuk pita *near-infrared* dan *short-infrared*). Resolusi temporal *Sentinel-2* adalah sepuluh hari yang dilakukan oleh satu satelit kemudian ditambah lima hari yang dilakukan dengan dua satelit yang akan membuat data observasi berjumlah banyak [17].

3 Metode Penelitian

3.1 Data dan Area Citra Penelitian

Tutupan lahan menggambarkan tutupan fisik yang diamati pada permukaan bumi. Citra pengamatan yang digunakan terletak di daerah Semarang, Jawa Tengah, Indonesia. Area ini dipilih karena alasan berikut: (1) Cakupan awan dari wilayah yang diamati (2) Karakteristik geografi dan topografi wilayah Semarang mewakili kelas tutupan lahan yang dianalisa dalam penelitian ini. Bagian kota Semarang yang dipilih untuk studi ini ditandai dengan kelas tutupan lahan utama yang terdiri atas hutan kering primer, hutan kering sekunder, hutan tanaman, padang rumput, pemukiman, badan air, lahan terbuka, (3) Semarang merupakan salah satu kota di Indonesia di mana Pertumbuhan penduduk dan perkembangan kota telah menyebabkan meningkatnya kebutuhan lahan. Alasan seperti itu membuat perencanaan dan pemantauan penggunaan lahan regional sangat penting. Citra satelit *Sentinel-2* area Semarang yang digunakan pada penelitian dapat dilihat pada Gambar 2.



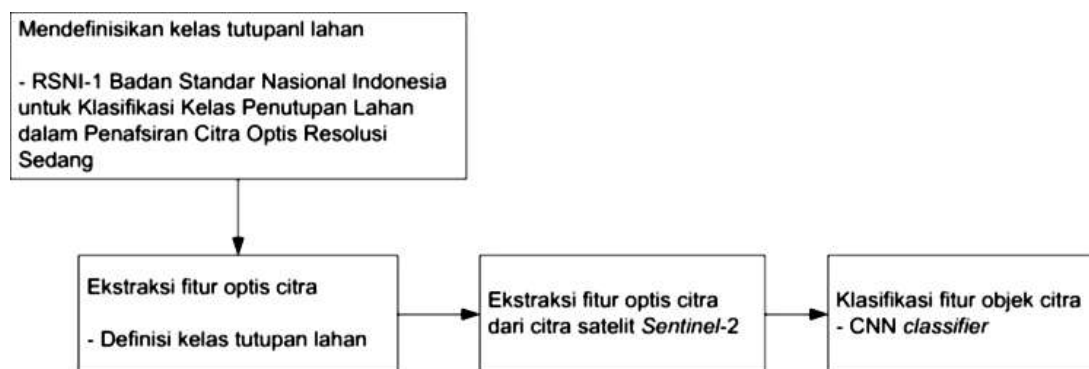
Gambar 2. False Color dari Pita 4, 3, 2, 8 Citra Satelit Sentinel-2 Area Semarang

Penelitian ini menggunakan data dari citra satelit *Sentinel-2* yang diakses melalui situs web dengan URL <https://earthexplorer.usgs.gov/>, yang diakuisisi pada 27 Agustus 2017, pukul 14:55:47 dengan tutupan awan di daerah yang diamati sebesar 8,49%. Citra diperoleh pada musim kemarau dengan paparan sinar matahari yang tinggi. Penelitian ini menggunakan citra satelit *Sentinel-2* karena alasan sebagai berikut [16]:

1. Cakupan citra satelit *Sentinel-2* mencakup seluruh dunia dalam resolusi 10-60 meter.
2. Citra satelit ini memiliki 13 pita spektrum pita. Pita yang digunakan pada penelitian ini terdiri atas: pita 4 (merah), pita 3 (hijau), pita 2 (biru), pita 8 (*Near-Infrared*) dan pita 11 (*SWIR, Short-Wave Infrared*). Pita 4 berguna untuk mengidentifikasi jenis-jenis vegetasi, tanah dan fitur perkotaan; pita 3 memberikan kontras yang sangat baik antara air jernih dan keruh (berlumpur); pita 2 berguna untuk identifikasi lahan dan vegetasi, pemetaan tipe hutan, dan untuk mengidentifikasi fitur buatan manusia; pita 8 baik untuk memetakan garis pantai dan kandungan biomasa, serta mendeteksi dan menganalisis vegetasi, juga digunakan untuk pengamatan status vegetasi, dan struktur kanopi; sementara pita 11 berguna untuk mengukur kelembaban tanah dan tumbuh-tumbuhan, dan pita ini memberikan kontras yang baik.
3. Memiliki resolusi temporal 10 hari dan 5 hari. Citra direkam setiap 10 hari dan 5 hari masing-masing menggunakan satu satelit dan dua satelit untuk menghasilkan data observasi dalam jumlah besar.

3.2 Alur Kerja Penelitian

Metode klasifikasi yang dikembangkan pada penelitian ini digambarkan pada alur penelitian sebagai berikut: (1) Mendefinisikan kelas hutan berdasarkan RSNI-1 Badan Standar Nasional Indonesia untuk Klasifikasi Kelas Penutupan Lahan dalam Penafsiran Citra Optis Resolusi Sedang, (2) Mengekstraksi fitur optik citra berdasarkan definisi kelas tutupan lahan, (3) Mengekstraksi fitur citra dari citra satelit *Sentinel-2*, dan (4) Mengklasifikasikan fitur objek citra menggunakan pengklasifikasi CNN. Alur kerja penelitian dapat dilihat pada Gambar 3.



Gambar 3. Alur Penelitian

3.3 Proses Klasifikasi Dengan CNN

Klasifikasi terawasi (*supervised*) digunakan pada penelitian ini. Klasifikasi secara *supervised* (terawasi) adalah proses klasifikasi piksel menggunakan sebuah model yang telah dilatih secara terawasi atau proses pelatihan menggunakan *dataset* yang sudah diberi label (kelas) kategori penutupan lahan sebagai input [18]. Kelebihan klasifikasi terawasi: (1) kontrol terhadap informasi karakteristik kelas berdasarkan area yang diamati, (2) adanya kontrol terhadap klasifikasi [18]. Proses klasifikasi tutupan lahan dengan CNN dapat dilihat pada Gambar 4.



Gambar 4. Tahapan Proses Klasifikasi dengan CNN


Proses ini terdiri atas: Menghasilkan data mentah hasil ekstraksi fitur citra, Menghasilkan data pelatihan, Melatih CNN dan Evaluasi. Lapisan utama arsitektur CNN yang digunakan dalam penelitian ini memiliki format sebagai berikut: Conv1D (filters _ 10, kernel_size _ 2, activation _ 'relu', input_shape _ (1, 4), padding _ 'same')

1. filters _ 10 dimensi *output* (jumlah filter *output* pada *convolutional*).
2. kernel_size _ 2 panjang jendela *convolutional*.
3. activation _ 'relu', fungsi aktivasi untuk *Rectified Linear Unit* (relu). ReLu tidak mengaktifkan *input* negatif.
4. input_shape _ (1, 4) bentuk vektor *input*.
5. padding _ 'same' menghasilkan *padding input*, agar *output* memiliki panjang yang sama dengan *input*.

4 Hasil dan Pembahasan

4.1 Ekstraksi Fitur

Ekstraksi fitur citra satelit diimplementasikan menggunakan perangkat lunak *eCognition* [19]. Segmentasi berbasis poligon digunakan untuk membagi citra menjadi sejumlah segmen/objek berdasarkan kesamaan piksel. Proses ini diimplementasikan dengan menggunakan logika *fuzzy* yang memungkinkan integrasi spektrum secara luas dari fitur objek yang berbeda, seperti nilai spektral, bentuk, dan tekstur [20]. Dalam penelitian ini, teknik segmentasi multi-resolusi diterapkan untuk menggabungkan piksel dengan nilai yang sama ke dalam satu objek. Segmentasi citra menghasilkan 2072 objek dengan menggunakan *eCognition* yang kemudian digunakan sebagai data training dan data testing.. Hasil segmentasi citra dapat dilihat pada Gambar 5.



Gambar 5. Segmentasi Citra Satelit Sentinel-2 Area Semarang

Selanjutnya, fitur citra diekstraksi berdasarkan definisi kelas tutupan lahan dari dokumen RSNI-1 Badan Standar Nasional Indonesia untuk Klasifikasi Kelas Penutupan Lahan dalam Penafsiran Citra Optis Resolusi Sedang untuk setiap segmen yang mewakili kelas tutupan lahan yang terkait. Fitur yang dihasilkan adalah: warna, rona, tekstur, dan bentuk, seperti yang ditunjukkan pada Tabel 2.

Karena ekstraksi fitur citra satelit diimplementasikan menggunakan perangkat lunak eCognition maka masing-masing fitur hasil ekstraksi (warna, rona, tekstur, dan bentuk) dipetakan ke dalam fitur-fitur citra yang ada di eCognition. Kemudian fitur-fitur ini yang digunakan sebagai fitur pengklasifikasi. Fitur-fitur tersebut yaitu: NDVI (*Normalized Difference Vegetation Index*), *Brightness*, GLCM (*the Gray-Level Co-occurrence Matrix*), dan *Rectangular fit*. Pemetaan atribut hasil ekstraksi fitur citra satelit *Sentinel-2* terhadap fitur citra *eCognition* dapat dilihat pada Tabel 2.

Tabel 2. Fitur Citra pada RSNI-1 dan Fitur eCognition

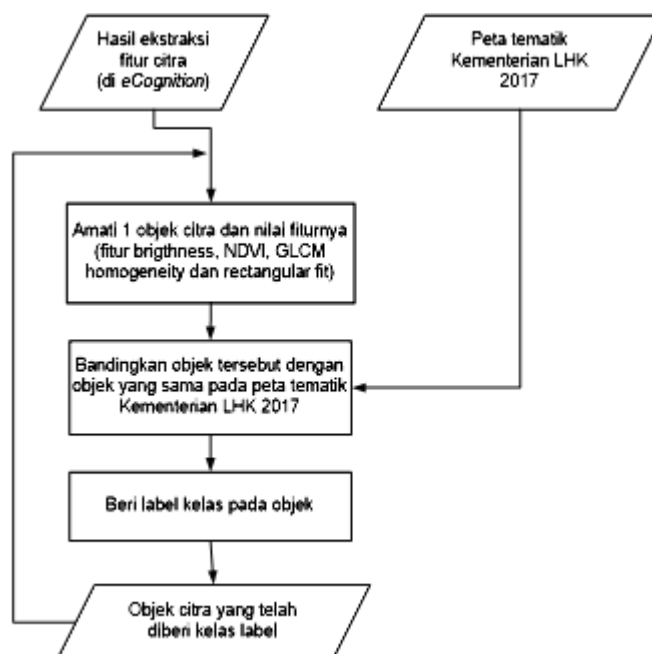
Fitur yang bersesuaian	
Fitur citra pada RSNI-1	Fitur pada eCognition
Warna	NDVI
Rona	<i>Brightness</i>
Tekstur	GLCM (<i>the Gray-Level Co-occurrence Matrix</i>) <i>homogeneity</i>
Bentuk	<i>Rectangular fit</i>

Di antara fitur yang diekstraksi, NDVI (*Normalized Difference Vegetation Index*) banyak digunakan sebagai indeks vegetasi karena kesederhanaannya tetapi efektif untuk mengukur vegetasi hijau. Nilai NDVI dihitung menggunakan persamaan (1) [19]:

$$NDVI = \frac{(Pita\ 8 - Pita\ 4)}{(Pita\ 8 + Pita\ 4)} \quad (1)$$

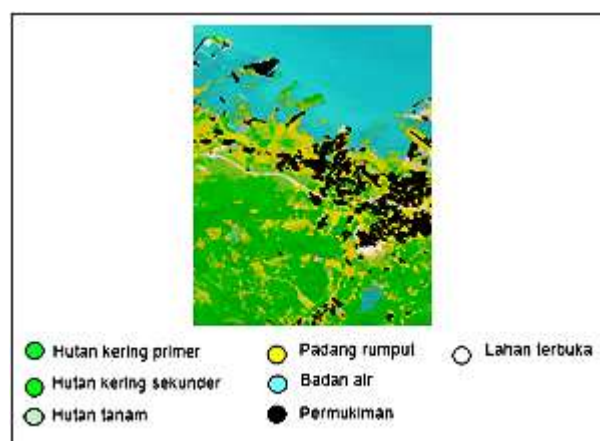
4.2 Klasifikasi Tutupan Lahan

Penelitian ini menggunakan teknik klasifikasi terawasi (*supervised*). Model pengklasifikasi pada klasifikasi terawasi dibentuk berdasarkan data yang sudah ada, data tersebut berupa sekumpulan data (*dataset*) yang telah diberi label kelas. Data umumnya dibagi menjadi data pelatihan dan data pengujian. Data pelatihan digunakan untuk menghasilkan model pengklasifikasi yang merupakan representasi pengetahuan. Sedangkan data pengujian digunakan untuk mengukur sejauh mana model pengklasifikasi berhasil melakukan klasifikasi dengan benar terhadap data baru yang belum pernah digunakan. *Dataset* yang digunakan pada penelitian ini merupakan objek-objek yang diperoleh dari hasil segmentasi dan ekstraksi fitur citra menggunakan *eCognition* area Semarang (terdapat 2072 objek citra). Tiap objek kemudian diberi label kelas menggunakan pendekatan pelatihan semi terawasi (*semi-supervised*) dengan proses sebagai berikut: (1) mengamati satu objek citra beserta nilai fiturnya (fitur *brighness*, NDVI, GLCM *homogeneity* dan *rectangular fit*), (2) membandingkan objek tersebut dengan objek yang sama pada peta tematik Kementerian LHK 2017, (3) memberi label kelas pada objek tersebut sesuai warna tema dan nama kelas yang ada pada tematik. Ulangi proses satu sampai tiga untuk semua objek citra. Alur proses memberi label kelas pada objek citra dapat dilihat pada Gambar 6.

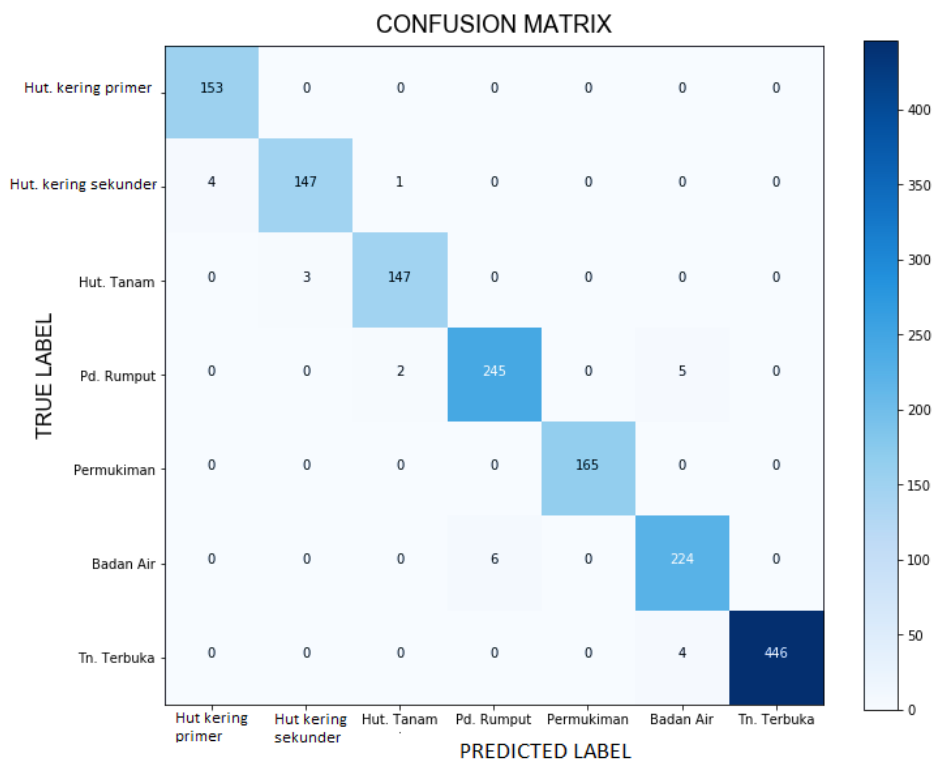


Gambar 6. Alur Proses Pelabelan Kelas pada Objek Citra

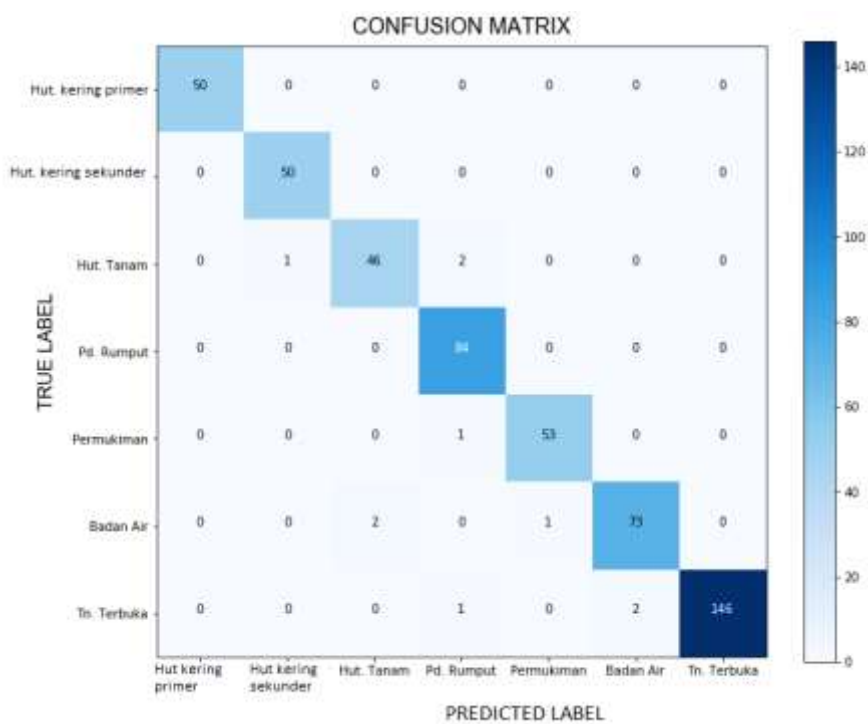
Dataset berlabel ini kemudian digunakan untuk melatih model pengklasifikasi pelatihan terawasi (*supervised*) menggunakan *Root Mean Square Error* (RMSE) sebagai fungsi objektif. *K-Fold cross-validation* digunakan untuk mengukur kinerja model klasifikasi CNN. Kinerja model diukur menggunakan *overall accuracy*, untuk data pelatihan, dan data pengujian, *producer's accuracy* dan *user's accuracy* untuk tiap kelas tutupan lahan. *K-Fold cross-validation* bekerja dengan membagi data ke wadah sebanyak K dan mengulangi (iterasi) eksperimen sebanyak K juga. Penelitian menggunakan $K = 4$, artinya data dilipat (dibagi) menjadi empat bagian kemudian iterasi eksperimen proses belajar model klasifikasi diulangi sebanyak empat kali. Nilai K ini dipilih dengan pertimbangan ukuran *dataset* yang tidak terlalu besar (2072 objek citra). Akurasi pelatihan dikalkulasi pada tiap iterasi. Penelitian ini menggunakan *epoch* 5000 untuk CNN dengan harapan makin lama siklus/waktu pelatihan/belajar dapat menghasilkan nilai akurasi yang tinggi. Satu *epoch* terdiri dari satu siklus pelatihan penuh pada data pelatihan. Setelah semua data pada data pelatihan diseksekusi, siklus pelatihan satu *epoch* dinyatakan selesai dan menandai awal dari siklus pelatihan *epoch* berikutnya. Hasil klasifikasi kelas tutupan lahan dan *confusion matrix* data pelatihan dan data pengujian dapat dilihat pada Gambar 7, 8 dan 9.



Gambar 7. Hasil Klasifikasi Kelas Tutupan Lahan Citra Satelit Sentinel-2 Area Semarang



Gambar 8. Confusion Matrix Data Pelatihan



Gambar 9. Confusion Matrix Data Pengujian

Hasil klasifikasi yang ditunjukkan pada Gambar 9 menunjukkan *false value* yang tinggi dihasilkan dari perbandingan kelas hutan tanam terhadap padang rumput hal ini terjadi karena karakteristik dan nilai indeks vegetasi (NDVI) yang hampir mirip. Selain itu *false value* yang tinggi

<http://sistemasi.ftik.unisi.ac.id>

juga ditunjukkan pada perbandingan lahan terbuka terhadap badan air. Hal ini terjadi terutama pada lahan terbuka dengan rona gelap. Akurasi hasil klasifikasi dikalkulasi dengan basis *confusion matrix*. yaitu membandingkan nilai aktual dengan nilai prediksi pada data *training* dan data *testing*. Hasil dari penelitian ini yaitu CNN telah dapat mengklasifikasi tujuh kelas tutupan lahan yang diamati dengan nilai akurasi sebagai berikut:

- a. *Overall accuracy*, nilai akurasi ini memberitahu berapa proporsi dipetakan dengan benar dari semua data referensi. *Overall accuracy* diperoleh hasil 98.4% untuk data pelatihan dan 98.4% untuk data pengujian, hal ini menunjukkan bahwa model klasifikasi ini telah dengan akurat dan baik mengklasifikasi kelas penutup lahan dengan fitur citra yang diekstraksi dari citra satelit *Sentinel-2* dan definisi kelas tutupan lahan pada dokumen RSNI-1 Badan Standar Nasional Indonesia untuk Klasifikasi Kelas Penutupan Lahan dalam Penafsiran Citra Optis Resolusi Sedang (NDVI, *Brightness*, *GLCM homogeneity* and *Rectangular fit*).
- b. *User's accuracy*, nilai akurasi ini pada dasarnya untuk mengetahui seberapa sering kelas pada peta benar-benar akan hadir di lapangan (nilai akurasi ini disebut juga dengan kehandalan). Kehandalan 100% artinya model memiliki kehandalan yang tinggi [21]. Model klasifikasi pada penelitian ini memiliki kehandalan yang tinggi (rata-rata nilai akurasi lebih besar dari 95%) pada data pelatihan dan data pengujian untuk mengklasifikasi tiap kelas penutup lahan seperti yang ditunjukkan pada Tabel 3 dan 4.
- c. *Producer's accuracy*, nilai akurasi ini dapat diartikan bahwa seberapa sering fitur-fitur nyata di lapangan dengan benar ditampilkan pada peta hasil klasifikasi atau berapa kemungkinan bahwa penutup lahan dapat diklasifikasikan dengan benar. Nilai *producer's accuracy* 100% artinya model memiliki kemungkinan yang besar untuk mengklasifikasi dengan benar [21]. Model klasifikasi pada penelitian ini memiliki kemungkinan yang besar (rata-rata nilai akurasi lebih besar dari 95%) untuk data pelatihan dan data pengujian bahwa tiap penutup lahan dapat diklasifikasikan dengan benar seperti yang ditunjukkan pada Tabel 3 dan 4.

Tabel 3. *User's accuracy* dan *producer's accuracy* data pelatihan

	<i>User's accuracy</i>	<i>Producer's accuracy</i>
Hutan kering primer	0.975	1.000
Hutan kering sekunder	0.980	0.967
Hutan tanam	0.980	0.980
Padang rumput	0.976	0.972
Pemukiman	1.000	1.000
Badan air	0.961	0.974
Lahan terbuka	1.000	0.991
Rata-rata nilai akurasi	0.982	0.983

Tabel 4. *User's accuracy* dan *producer's accuracy* data pengujian

	<i>User's accuracy</i>	<i>Producer's accuracy</i>
Hutan kering primer	1.000	1.000
Hutan kering sekunder	0.980	1.000
Hutan tanam	1.000	0.939
Padang rumput	0.955	1.000
Pemukiman	0.981	0.981
Badan air	0.973	0.986
Lahan terbuka	1.000	0.980
Rata-rata nilai akurasi	0.984	0.984

Penelitian ini telah membuktikan penelitian sebelumnya [3] tentang potensi penggunaan salah satu metode *deep learning* yakni CNN pada analisis citra satelit untuk klasifikasi objek, deteksi objek dan klasifikasi tutupan lahan. Dibandingkan dengan penelitian sebelumnya [3], penelitian ini telah membuat perbaikan dengan menambahkan fitur spektral, indeks spektral dan fitur spasial sebagai fitur input dan menambahkan definisi kelas tutupan lahan dari dokumen RSNI-1 Badan Standar

Nasional Indonesia untuk Klasifikasi Kelas Penutupan Lahan dalam Penafsiran Citra Optis Resolusi Sedang sebagai dasar untuk fitur ekstraksi untuk mendapatkan fitur pengklasifikasi yang tepat.

5 Kesimpulan

Hasil kajian penelitian ini menunjukkan bahwa metode klasifikasi tutupan lahan menggunakan *deep learning* yakni CNN pada citra satelit *Sentinel-2* memberikan hasil akurasi yang tinggi untuk mengklasifikasi tujuh kelas tutupan lahan (hutan kering primer, hutan kering sekunder, hutan tanaman, padang rumput, pemukiman, badan air, dan lahan terbuka), yaitu *overall accuracy* diperoleh hasil 98.4% untuk data pelatihan dan 98.4% untuk data pengujian serta rata-rata nilai akurasi lebih besar dari 95% pada *user's accuracy* dan *producer's accuracy* untuk data pelatihan dan pengujian. Namun metode ini masih menghasilkan *false value* yang tinggi dari perbandingan kelas hutan tanam terhadap padang rumput, hal ini terjadi karena karakteristik dan nilai indeks vegetasi (NDVI) yang hampir mirip. Selain itu *false value* yang tinggi juga ditunjukkan pada perbandingan lahan terbuka terhadap badan air. Hal ini terjadi terutama pada lahan terbuka dengan rona gelap. Tantangan masa depan penelitian ini termasuk penentuan wilayah yang diminati, keanekaragaman jenis tutupan lahan yang diamati (pada beberapa kelas tutupan lahan memiliki karakteristik yang hampir sama) dan penentuan algoritma klasifikasi. Secara teknis, metode dalam penelitian ini dapat diadaptasi untuk melatih model klasifikasi tutupan lahan di lokasi mana pun selama citra satelit *Sentinel-2* untuk lokasi yang diamati dan peta tematik serta dokumen klasifikasi kelas tutupan lahan yang diterbitkan oleh pemerintah daerah tersedia untuk menentukan kelas tutupan lahan.

Referensi

- [1] M. Kampffmeyer, A. Salberg, R. Jenssen, "Urban Land Cover Classification with Missing Data Using Deep Convolutional Neural Networks", in *IEEE International Geoscience and Remote Sensing Symposium*, 2017, pp. 5161-5164.
- [2] 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*, pp. 1-18. 2018.
- [3] L. Ma, X. Liu, Y. Zhang, G. Yin, B.A Johnson, "Deep Learning in Remote Sensing Applications: A Meta Analysis and Review" *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 152, pp. 166-177, 2019.
- [4] K. He, S. Zhang, S. Ren, J. Sun, "Deep Residual Learning for Image Recognition" in *IEEE International Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770-778.
- [5] K. Simonyan, A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition", in *IEEE International Conference on Learning Representation*, 2015, pp. 1-14.
- [6] R. Girshick, J. Donahue, T. Darrell, J. Malik, "Region-Based Convolutional Networks for Accurate Object Detection and Segmentation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, issue. 1, pp. 142-158, 2016.
- [7] J. Redmon, S. Divvala, R. Girshick, A. Farhadi, "You only look once: Unified, Realtime Object Detection" in *IEEE International Conference on Computer Vision and Pattern Recognition*, 2016, pp. 779-788.
- [8] Y. LeCun, K. Kavukcuoglu, C. Farabet, C. "Convolutional Networks and Applications in Vision", in *IEEE International Symposium on Circuits and Systems*, 2010, pp. 253-256.
- [9] K. Uddin, H. Gilani, M. Murthy, R. Kotru, F.M. Qamer, "Forest Condition Monitoring Using Very-Highresolution Satellite Imagery in A Remote Mountain Watershed in Nepal", *Mountain Research and Development*, vol. 35, issue. 3, pp. 264-278, 2015.
- [10] W. Zhao, S. Du, W.J. Emery, "Object-Based Convolutional Neural Network for High-Resolution Imagery Classification". *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, issue. 7, pp. 3386-3396, 2017.
- [11] N. Kussul, M. Lavreniuk, S. Skakun, A. Shelestov, "Deep Learning Classification of Land Cover and Crop Types using Remote Sensing Data" *IEEE Geoscience and Remote Sensing Letters*, vol. 14, issue. 5, pp. 778-782, 2017.

- [12] Y. Zhu, S. Newsam, "Land Use Classification Using Convolutional Neural Networks Applied to Ground-Level Images, in *the 23rd SIGSPATIAL International Conference on Advances in Geographic Information Systems*, 2015, pp. 1-4.
- [13] Badan Standardisasi Nasional, "RSNI-1 Standar Nasional Indonesia. Kelas Penutupan Lahan Dalam Penafsiran Citra Optis Resolusi Sedang", *Badan Standardisasi Nasional*, 2014. [Online] Available: http://appgis.menlhk.go.id/appgis/download.aspx?status=view&filename=RSNI_1b_KELAS%20PENUTUPAN%20LAHAN%20DALAM%20PENAFSIRAN%20CITRA%20OPTIS%20RESOLUSI%20SEDANG.pdf&fileFullName=E:%5Cwebgisapp%5CDownload%5CPeraturan%20Terkait%5CRSNI_1b_KELAS%20PENUTUPAN%20LAHAN%20DALAM%20PENAFSIRAN%20CITRA%20OPTIS%20RESOLUSI%20SEDANG.pdf
- [14] E. Mandanici, G. Bitelli, "Preliminary comparison of sentinel-2 and landsat 8 imagery for a combined use", *Remote Sensing* vol. 8, issue.12, pp. 1014, 2016.
- [15] A Canada Centre for Remote Sensing, *Fundamentals of Remote Sensing*, A Canada Centre for Remote Sensing, 2016.
- [16] Sentinel-2 EO. "Sentinel Hub Data", [Online]. Available: <https://www.sentinel-hub.com/explore/data/>.
- [17] H. Saadat, J. Adamowski, R. Bonnell, F. Sharifi, M. Namdar, S. Ale-Ebrahim,"Land use and land cover classification over a large area in Iran based on single date analysis of satellite imagery', *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 66, issue. 5, pp. 608–619, 2011.
- [18] GISGeography, "Supervised and Unsupervised Classification in Remote Sensing", *GISGeography*, 2018. [Online]. Available: <https://gisgeography.com/supervised-unsupervised-classification-arcgis/>
- [19] Trimble Geospatial, "eCognition Transform Data to Information". [Online]. Available: <https://geospatial.trimble.com/products-and-solutions/ecognition>.
- [20] Trimble Geospatial, Benefits of Object-based Feature Extraction. [Online]. Available: <https://geospatial.trimble.com/blog/benefits-object-based-feature-extraction>.
- [21] G.B. Scofield, E. Pantaleao, R.G. Negri, "A Comparison of Accuracy Measures for Remote Sensing Image Classification: Case Study in An Amazonian Region using Support Vector Machine", *International Journal of Image Processing*, vol. 9, issue. 1, pp. 11–21, 2015.