

KLASIFIKASI TUTUPAN LAHAN UAV MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK FEATURE MAP DENGAN KOMBINASI MACHINE LEARNING

Erika Maulidiya¹, Chastine Faticah², Nanik Suciati³ dan Fajar Baskoro⁴

^{1,2,3,4} Departemen Teknik Informatika, Institut Teknologi Sepuluh Nopember, Indonesia

Jl. Teknik Kimia, Keputih, Kec. Sukolilo, Surabaya, Jawa Timur 60111

e-mail: erikamaulidiya18@gmail.com¹, chastine@if.its.ac.id², nanik@if.its.ac.id³, fajar@if.its.ac.id⁴

ABSTRAK

Dalam analisis geografis, tutupan lahan memainkan peran penting dalam segala hal mulai dari analisis lingkungan hingga metode perencanaan berkelanjutan dan studi geografi fisik. Standar Nasional Indonesia (SNI 7645:2014) mengklasifikasikan analisis vegetasi berdasarkan kerapatan. Ada empat kategori indeks kerapatan vegetasi: non-vegetasi, gundul, sedang, dan tinggi. Secara teknis, data vegetasi dapat diperoleh melalui penginderaan jauh. Data satelit dan UAV adalah dua jenis data yang digunakan dalam penginderaan jauh untuk mengumpulkan informasi kerapatan vegetasi. Penelitian ini akan menganalisis tutupan lahan didasarkan pada informasi kerapatan vegetasi menggunakan data UAV. Berdasarkan informasi kerapatan vegetasi dari penginderaan jauh yang informasinya dapat membantu dalam pengolahan lahan, maka dilakukan Klasifikasi Tutupan Lahan berdasarkan kerapatan vegetasi. Convolutional Neural Network (CNN) telah dilatih secara ekstensif untuk menerapkan propertinya pada klasifikasi tutupan lahan. Penelitian ini akan mengevaluasi fitur-fitur yang diekstrak dari CNN (ResNet-50, Inception-V3, DenseNet-121) yang sebelumnya telah dilatih dan dilanjutkan dengan algoritma pohon keputusan, Random Forest, Support Vector Machine dan eXtreme Gradient Boosting sebagai metode klasifikasi. Dari hasil perbandingan pengujian klasifikasi antar metode machine learning, Support Vector Machine lebih unggul dibandingkan metode machine learning lainnya. Hal ini dibuktikan dengan hasil akurasi yang diperoleh sebesar 85% dengan ekstraksi fitur menggunakan ResNet-50 yang mana lama waktu proses adalah 8 menit. Disusul model terbaik kedua yaitu ResNet-50 dengan XGBoost yang memperoleh hasil akurasi yang sebesar 82% dengan lama waktu proses adalah 55 menit. Sedangkan penggunaan ekstraksi fitur dengan metode DenseNet-121, didapatkan dengan kombinasi metode Support Vector Machine dan Metode XGBoost dengan hasil akurasi yang diperoleh adalah 81%.

Kata Kunci: Arsitektur CNN, Ekstraksi Fitur, Klasifikasi, Kerapatan Vegetasi, Tutupan Lahan,

UAV LAND COVER CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK FEATURE MAP WITH A COMBINATION OF MACHINE LEARNING

Erika Maulidiya¹, Chastine Faticah², Nanik Suciati³ and Fajar Baskoro⁴

^{1,2,3,4} Department of Informatics, Institut Teknologi Sepuluh Nopember, Indonesia

Teknik Kimia, Keputih, Kec. Sukolilo, Surabaya, Jawa Timur 60111

e-mail: erikamaulidiya18@gmail.com¹, chastine@if.its.ac.id², nanik@if.its.ac.id³, fajar@if.its.ac.id⁴

ABSTRACT

In geographic analysis, land cover plays an important role in everything from environmental analysis to sustainable planning methods and physical geography studies. The Indonesian National Standard (SNI 7645:2014) classifies vegetation analysis based on density. There are four categories of vegetation density index: non-vegetation, bare, medium, and high. Technically, vegetation data can be obtained through remote sensing. Satellite and UAV data are two types of data used in remote sensing to collect information. This research will analyze land cover based on vegetation density information that can be collected through remote sensing. Based on vegetation density information from remote sensing, the information can help in land processing, Land Cover Classification is carried out based on vegetation density. Convolutional neural networks (CNN) have been trained extensively to apply their properties to land cover classification. This research will evaluate features extracted from Convolutional Neural Networks (ResNet 50, Inception-V3, DenseNet 121) which have previously been trained and continued with Decision Tree algorithms, Random Forest, Support Vector Machine and eXtreme Gradient Boosting to perform classification. From the comparison results of classification tests between machine learning methods, Support Vector Machine is superior to other machine learning methods. This is proven by the accuracy results obtained at 85% with feature extraction using ResNet-50 where the processing time is 8 minutes. Followed by the second-best model, namely ResNet-50 with XGBoost which obtained accuracy results of 82% with a processing time of 55 minutes. Meanwhile, the use of feature extraction using the DenseNet-121 method was obtained using a combination of the Support Vector Machine method and the XGBoost method with the accuracy obtained being 81%.

Keywords: CNN Architecture, Classification, Feature Extraction, Land Cover, Vegetation Density

I. PENDAHULUAN

Negara Indonesia memiliki lahan gambut seluas 149.056 km² yang terletak di tiga pulau yaitu di Kalimantan, Sumatra, dan Papua [1]. Lahan gambut di Indonesia merupakan lahan gambut terbanyak kedua di dunia [2]. Selain menjaga kualitas udara dan air serta mempertahankan populasi ikan, lahan gambut juga menawarkan banyak manfaat penting lainnya bagi kota-kota terdekat. Baik disengaja atau tidak, tindakan manusia merupakan penyebab utama kebakaran lahan gambut dan menyebabkan banyak operasi terganggu di Indonesia dan negara-negara sekitarnya [3], [4]. Untuk menganalisis lahan gambut diperlukan informasi tutupan lahan berdasarkan kerapatan vegetasi [5]. Keseluruhan tumbuhan yang menempati suatu area tertentu disebut vegetasi. Untuk mengetahui tingkat kekeringan pada suatu daerah atau lahan dapat ditentukan nilai indeks kekeringannya indeks yaitu dengan menggunakan metode Indeks Kekeringan Keetch-Byram (KBDI). Kerapatan tutupan vegetasi di lahan gambut berdasarkan KBDI terbagi menjadi tiga kategori: bare, sedang, tinggi [6]. Dalam aspek teknis untuk memperoleh informasi terkait vegetasi dapat dilakukan dengan menggunakan penginderaan jauh (*Remote sensing*).

Informasi mengenai penginderaan jauh dapat diperoleh dengan dua data yaitu data satelit dan data *Unmanned Aerial Vehicle* (UAV). Penginderaan jauh dengan data satelit dalam identifikasi dan klasifikasi pola tutupan lahan pada cakupan geografis yang luas telah banyak digunakan oleh penelitian sebelumnya, namun penggunaan data satelit yang memiliki ketinggian operasi yang tinggi dan mudah dipengaruhi oleh cuaca, awan dan faktor eksternal lainnya. Sehingga hal tersebut menjadi pertimbangan kembali dalam penggunaan data satelit. Dalam beberapa tahun terakhir, para peneliti secara bertahap mengeksplorasi perbandingan UAV dengan satelit, dimana tidak ada keraguan bahwa penginderaan jauh satelit telah terbukti menguntungkan dan berguna untuk aplikasi pertanian, namun penggunaannya memiliki keterbatasan [7]. Penginderaan jauh berdasarkan data citra UAV yang diperoleh dari menggunakan drone memberikan potensi mendapatkan hasil yang melakukan klasifikasi. UAV menghasilkan informasi spasial dan gambar beresolusi tinggi yang banyak digunakan dalam penelitian. Berdasarkan hal tersebut, citra udara menawarkan potensi besar untuk pengembangan teknologi penginderaan jauh seperti klasifikasi wilayah. Namun hasil optimal dapat dicapai dengan menggunakan UAV atau drone untuk melakukan klasifikasi berdasarkan objek dan metode pengolahan yang sesuai. Sehingga diperlukan metode yang lebih mendalam untuk klasifikasi [8].

Convolutional Neural Network (CNN) dalam metode *deep learning* direvolusi dengan mempelajari bentuk dasarnya pada lapisan pertama dan lapisan yang lebih dalam kemudian diubah menjadi fitur gambar yang dipelajari, sehingga menghasilkan klasifikasi gambar yang lebih akurat [9]. Strategi pembelajaran mendalam CNN menghasilkan hasil yang paling mencolok dalam pengenalan gambar diantara prosedur pembelajaran mendalam yang masih berkembang [8]. CNN telah digunakan secara luas dalam meningkatkan bidang klasifikasi dan lainnya seperti deteksi objek, pengenalan objek dari rekaman video, pemeriksaan gambar deteksi jarak jauh, pembedaan objek dalam gambar, dan pengurutan inklusi tanah dan penggunaan lahan. CNN tidak hanya dapat mempelajari representasi fitur gambar secara otomatis, tetapi juga mengungguli banyak teknik ekstraksi fitur [10]. CNN mempelajari fitur gambar secara otomatis tanpa memerlukan ekstraksi fitur manual, yang merupakan perbedaan utama antara CNN dan teknik pembelajaran mesin lainnya [10]. Beberapa penelitian lain telah menerapkan metode CNN sebagai ekstraksi fitur dalam pengolahan data citra sebelum klasifikasi, namun penerapan arsitektur CNN dalam pengolahan data citra kerapatan vegetasi masih kurang karena identifikasi dan karakterisasi tumbuhan memerlukan ruang dan waktu [11].

Berdasarkan hal tersebut, penelitian ini mengusulkan klasifikasi tutupan lahan UAV menggunakan ekstraksi fitur dari arsitektur CNN yang dapat menganalisis data citra dengan lebih efisien, akurat dan fleksibel [11]. ResNet-50, Inception-V3 dan DenseNet-121 adalah arsitektur CNN yang digunakan dalam penelitian ini untuk ekstraksi fitur. Keunggulan ResNet-50 adalah memiliki strategi desain yang sederhana dan hanya memperkenalkan satu pintasan identitas. Sedangkan DenseNet-121 memiliki kapasitas lebih tinggi dengan menggabungkan fitur multi-layer dan memfasilitasi pelatihan pada jaringan dalam. Dan arsitektur Inception-V3 memiliki jaringan yang lebih dalam dibandingkan model Inception V1 dan V2, namun kecepatannya tidak terganggu. Penerapan algoritma pembelajaran mesin pada citra penginderaan jauh untuk klasifikasi tutupan lahan telah banyak digunakan pada penelitian sebelumnya [12]. Metode klasifikasi penggunaan lahan dan cakupan lahan telah menunjukkan kemajuan yang signifikan dalam beberapa tahun terakhir, seperti penerapan teknik klasifikasi menggunakan pembelajaran mesin [13], [14]. Model pembelajaran mesin memiliki teknik analisis terkemuka yang digunakan untuk memantau, memetakan, dan mengukur penggunaan lahan dan cakupan lahan beserta perubahannya seiring waktu. Berdasarkan studi literatur, metode yang banyak digunakan dalam penelitian ini untuk klasifikasi tutupan lahan berdasarkan kerapatan vegetasi antara lain *Decision Tree*, *Naïve Bayes*, *Random Forest*, *Support Vector Machine* dan *eXtreme Gradient Boosting* [12], [13]. Umumnya metode *machine learning* hanya digunakan pada data satelit dan belum diterapkan secara luas khususnya pada data UAV [15]. Sehingga penelitian ini akan melakukan pengklasifikasian tutupan lahan berdasarkan kerapatan vegetasi menggunakan metode *machine learning* dengan proses ekstraksi fitur

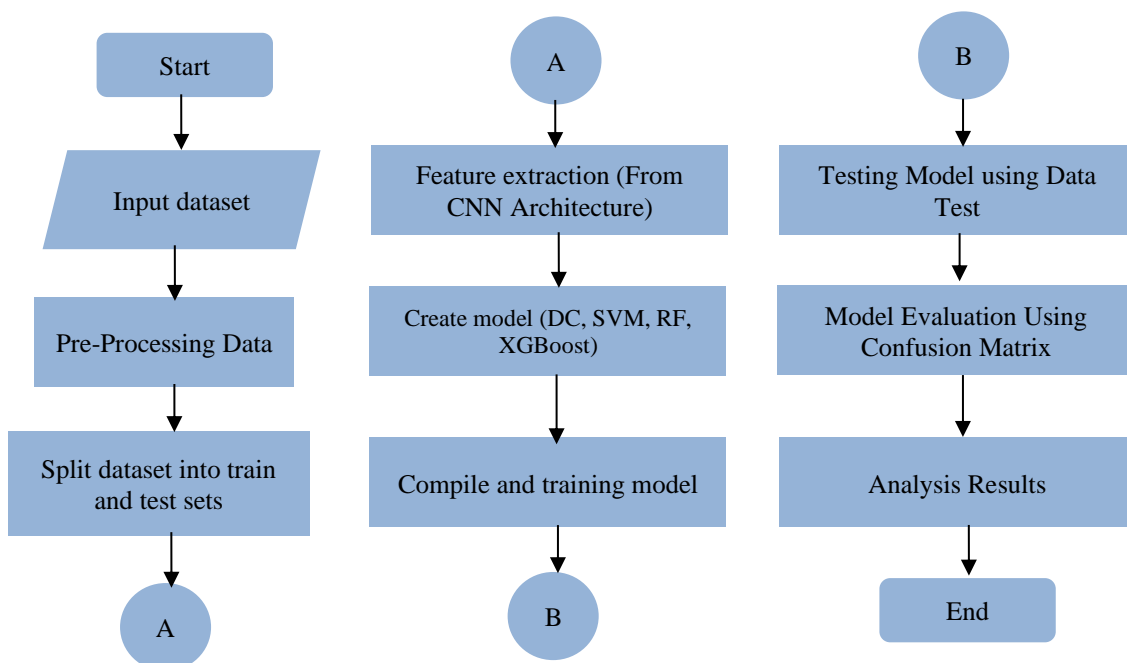
dari arsitektur CNN.

II. METODE


Alur dan metode yang digunakan dalam penelitian ini dijelaskan pada *flowchart* pada Gambar 1, yang masing-masing proses dijelaskan pada subbab di bawah ini.

A. Dataset

Dataset diperoleh dan diambil di lahan Blok 1 Hutan Lindung Liang Anggang Banjarbaru 1 menggunakan *DJI Mavic Pro Drone* pada tahun 2021. Beberapa bagian Hutan Lindung Liang Anggang tidak dapat difoto oleh drone karena letaknya yang mendekati dengan bandara Syamsudin Noor, yang mana memasuki zona terbang sehingga adanya batasan drone terbang untuk terbang di area penelitian. Hal tersebut membuat drone tidak dapat terbang lebih dari 60 meter. Sehingga drone hanya dapat menangkap gambar dengan ketinggian pengambilan drone 20 meter. Dataset yang diperoleh sebanyak 3000 data citra vegetasi dengan pembagian kelas klasifikasi pada penelitian ini dibagi menjadi 3 kelas yaitu bare, sedang dan tinggi. Setiap kelas dengan berisikan 1000 data citra. Pembagian kelas ini berdasarkan pada keadaan Hutan Lindung Liang Anggang yang mempunyai kelimpahan tumbuhan yang memenuhi persyaratan pengumpulan data mengenai karakteristik dan jenis kerapatan vegetasi klasifikasi tutupan lahan. Dataset dapat diakses melalui Mendeley di link ini: <https://data.mendeley.com/datasets/tb26zy2jst/1>. Letak hutan lindung Liang Anggang sebagai berikut, seperti digambarkan pada Gambar 2.




Gambar 1. Alur Penelitian



Gambar 2. Lokasi Pengambilan Data

B. Pengolahan Dataset

Tahapan ini dilakukan pemotongan citra (*cropping*) untuk memudahkan proses klasifikasi sehingga mengurangi penggunaan banyak ruang atau memori dan waktu selama proses klasifikasi. Ukuran gambar awal adalah 4000 x 3000 piksel, data gambar berasal dari drone memiliki resolusi gambar yang tinggi. Kemudian semua gambar diubah ukurannya menjadi 256 x 256 piksel untuk memfasilitasi pembelajaran. Pengolahan data sangat penting karena kumpulan data yang diperoleh digunakan untuk merancang distribusi data pelatihan dan pengujian pada tahap ini. [16], [17]. Dilanjutkan dengan pelabelan gambar, berikut hasil pelabelan gambar pada penelitian ini dapat dilihat pada Tabel 1.

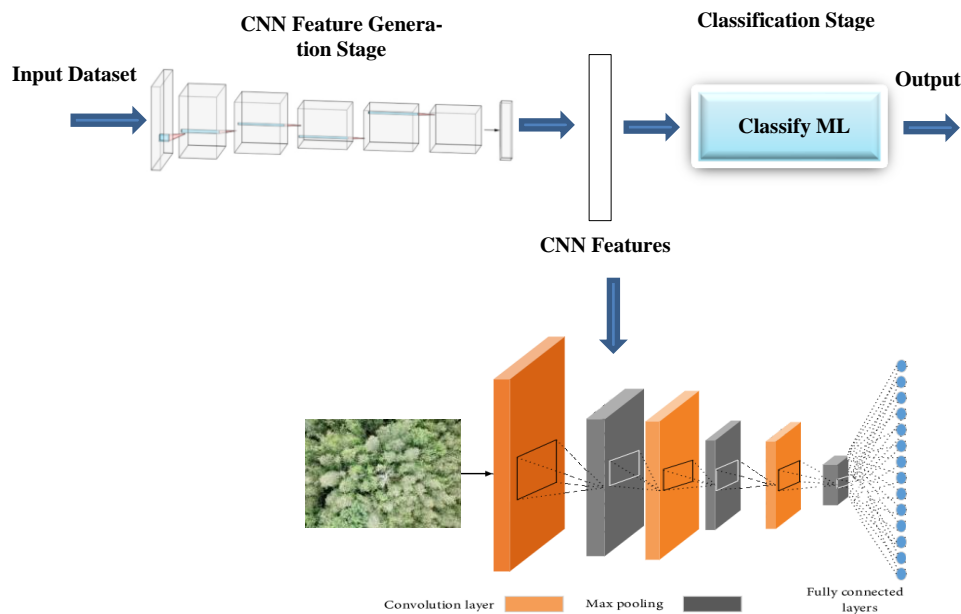


TABEL I
HASIL PELABELAN DATA

Gambar			Kelas
			Bare
			Sedang
			Tinggi

C. Ekstraksi Fitur

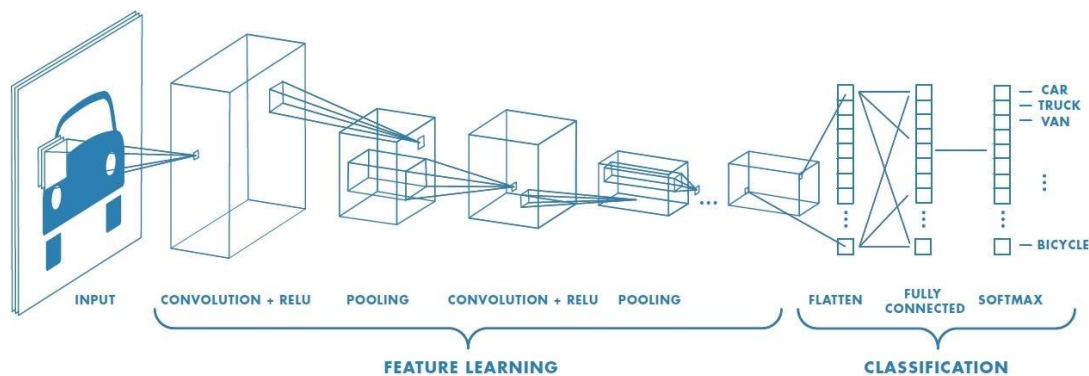
Tahap ekstraksi fitur penting sebelum melakukan proses klasifikasi karena dapat meningkatkan prediksi dan membuat kalibrasi dapat diandalkan dan memberikan interpretasi yang lebih mudah [18], [19]. Penelitian sebelumnya telah mengembangkan teknik ekstraksi fitur dengan studi kasus yang berbeda. Namun hingga saat ini, tidak ada ekstraktor fitur yang sempurna. Sejumlah penelitian telah menunjukkan betapa efektifnya pembelajaran mendalam dalam mengekstraksi fitur [18]. Salah satu varian algoritma *deep learning* yang digunakan untuk mengekstrak fitur visual adalah CNN [20]. CNN dapat digunakan bersama dengan *Transfer Learning* untuk mengekstrak fitur serta model klasifikasi [21]. *Feature map* yang dihasilkan dan lapisan konvolusi pertama adalah tempat ekstraksi fitur CNN. Entropi silang dihitung sebagai *hyperparameter* kerugian dalam penelitian ini. Peneliti memperkirakan *feature map* lapisan konvolusi pertama, yang dapat menyediakan fitur-fitur pembeda untuk mempercepat proses klasifikasi. Ekstraksi fitur yang digunakan pada penelitian ini adalah ekstraksi fitur dari arsitektur CNN (ResNet-50, Inception-V3 dan DenseNet-121). Gambar 3 menunjukkan proses ekstraksi fitur menggunakan CNN sebagai berikut [10].



Gambar 3. Ekstraksi Fitur Arsitektur CNN

D. Arsitektur Convolutional Neural Network

CNN terdiri dari lapisan-lapisan konvolusional yang bergantian dengan jumlah filter yang sama pada setiap lapisan dan koneksi ke lapisan lainnya. Tiga konsep dalam arsitektur CNN yaitu distribusi bobot, proses downsampling, dan bidang reseptif lokal yang membuatnya berguna dalam proses pengenalan gambar [22]. Bagian kecil dari lapisan di atas memberikan masukan ke setiap *neuron* dibidang reseptif lokal. Lapisan pengambilan sampel bawah dan lapisan konvolusional keduanya menggunakan bidang reseptif lokal. Selain itu, lapisan konvolusional mengalami pembagian bobot untuk mengelola kapasitas dan menurunkan kompleksitas model. Kemudian, *nonlinear down sampling* digunakan pada lapisan *down sampling* untuk mereduksi jumlah parameter dan ukuran spasial citra. Hal tersebut memberi kekuatan dan efisiensi yang lebih besar dalam pengenalan gambar pada CNN [22]. Berikut gambaran dari arsitektur CNN dapat dilihat pada Gambar 4.



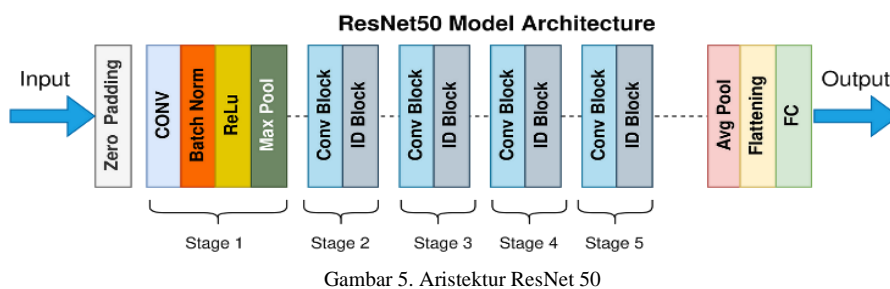
Gambar 4. Arsitektur CNN [11]

1) Arsitektur ResNet 50

ResNet adalah jaringan saraf konvolusional kompleks yang didasarkan pada blok sisa. Arsitektur ini mengatasi masalah degradasi gradien di jaringan yang sangat dalam [10]. ResNet memperkenalkan konsep blok sisa dengan menggabungkan koneksi pintasan antar lapisan untuk meningkatkan akurasi tanpa memperdalam jaringan. Sert metode ini juga mencegah korupsi saat proses menjadi lebih kompleks. ResNet memiliki lebih dari sebelas juta parameter dan 152 lapisan kedalaman jaringan. Model ini menggunakan filter konvolusi 3x3, normalisasi *batch*, pemblokiran sisa, pengumpulan rata-rata global, dan lapisan klasifikasi (*SoftMax*). Untuk keperluan penelitian ini, ResNet 50 digunakan untuk mengusulkan beberapa variasi dengan jumlah lapisan yang bervariasi. Tabel 2 merangkum parameter jaringan ResNet 50. Arsitektur ResNet-50 terlihat pada Gambar 5 [12].

TABEL II
STRUKTUR ARSITEKTUR RESNET 50

Layar	Fitur Keluaran	Ukuran Karnael
Conv1	7 x 7	156 x 156 x 3
Max pool	3 x 3	77 x 77 x 64
	1 x 1	38 x 38 x 64
Conv 2	3 x 3	38 x 38 x 64
	1 x 1	38 x 38 x 256
	1 x 1	19 x 19 x 128
Conv3	3 x 3	19 x 19 x 128
	1 x 1	19 x 19 x 512
	1 x 1	10 x 10 x 256
Conv4	3 x 3	10 x 10 x 256
	1 x 1	10 x 10 x 1024
	1 x 1	5 x 5 x 512
Conv5	3 x 3	5 x 5 x 512
	1 x 1	5 x 5 x 2048
Avg pool	7 x 7	5 x 5 x 2048
Flatten	-	5 x 5 x 2048
out	-	51200



Gambar 5. Arsitektur ResNet 50

2) Arsitektur Inception-V3

Arsitektur ini memiliki lebih sedikit dibandingkan VGGNet (140.000.000) dan AlexNet (60.000.000). Menurut penelitian sebelumnya, arsitektur ini, berkontribusi signifikan yang lebih tinggi dibandingkan AlexNet. Selain itu, jumlah total komputasi floating-point untuk seluruh jaringan Inception-V3 adalah sekitar 5.000.000.000, peningkatan yang signifikan dibandingkan dengan Inception-V1 [13]. Lapisan normalisasi *batch* (BN) ditambahkan ke arsitektur Inception-V3 untuk berfungsi sebagai jembatan antara lapisan yang terhubung sepenuhnya (FC) dan pengklasifikasi tambahan. Model BN memungkinkan model jaringan neural dalam untuk berlatih dan melakukan konvergensi lebih cepat dengan memanfaatkan metode penurunan batch gradien. Inception-V3 lebih bermanfaat karena dapat dengan mudah diinstal pada server publik untuk memberikan layanan respon cepat [11]. Dengan Inception-V3, bidang reseptif yang berbeda memungkinkan karena menggunakan kernel konvolusional dengan ukuran berbeda. Parameter jaringan Inception-V3 didapat dilihat pada Tabel 3. Arsitektur Inception-V3 seperti terlihat pada Gambar 6 [11].

3) Arsitektur DenseNet-121

Berbeda dengan arsitektur CNN lainnya, arsitektur DenseNet-121 menghubungkan semua lapisan secara bertahap [17]. DenseNet-121 menyediakan berbagai metode untuk menangani data citra. Setiap lapisan memiliki peta fitur yang ditautkan, mulai dari lapisan pertama hingga pembuatan lapisan baru. Manfaat lain seperti penggunaan kembali fitur dan pengurangan masalah ledakan atau kehilangan gradien juga diperkenalkan dalam pengembangan DenseNet-121. Perubahan dilakukan pada struktur DenseNet-121 untuk memungkinkan ekstraksi fitur, seperti *downsampling* peta fitur untuk memfasilitasi penggabungan. Selanjutnya, konsep blok padat diajukan untuk memungkinkan *downsampling*. Lapisan transisi di antara blok padat yang berisi konvolusi operasi dan normalisasi *batch*. Arsitektur DenseNet-121 memanfaatkan koneksi pintasan, yang terdiri dari

TABEL IV
STRUKTUR ARSITEKTUR DENSENET-121.

Layar	Fitur Keluaran	Ukuran Karnel
Conv1	112 x 112 x3	7 x 7 conv
Max pooling	56 x 56 x 64	3 x 3 max pool
DenseBlock_1	56 x 56 x 256	1 x 1 conv 3 x 3 conv
Transition Layer	28 x 28 x 128	1 x 1 conv 2 x 2 avg pool
DenseBlock_2	28 x 28 x 512	1 x 1 conv 3 x 3 conv
Transition Layer	14 x 14 x 256	1 x 1 conv 2 x 2 avg pool
DenseBlock_3	14 x 14 x 1792	1 x 1 conv 3 x 3 conv
Transition Layer	7 x 7 x 896	1 x 1 conv 2 x 2 avg pool
DenseBlock_4	7 x 7 x 1920	1 x 1 conv 3 x 3 conv
Average Pooling	1 x 1 x 1920	7 x 7 avg pool

E. Metode Klasifikasi

1) *Pohon Keputusan (Decision Tree)*

Pohon keputusan adalah grafik yang menunjukkan urutan tindakan dan hasilnya masing-masing dengan menggunakan metode percabangan [10]. Karena pohon keputusan tidak membuat asumsi tentang distribusi data atau struktur klasifikasi, pohon keputusan efektif untuk variabel numerik dan kategori. Kumpulan data yang besar dapat diklasifikasikan dengan presisi dan efisiensi menggunakan pohon keputusan [10].

TABEL V
CONFUSION MATRIX

Data Class	Positive classification	Negative Classification
Positive	True Positive (TP)	False Negative (FN)
Negative	False Positive (FP)	True Negative (TN)

2) *Random Forest (RF)*

Random Forest mengidentifikasi ansambel dengan menggabungkan beberapa prediktor struktur pohon hierarki. Pengklasifikasi ansambel yang disebut *Random Forest* terdiri dari banyak pohon keputusan acak. Pohon keputusan ini menghasilkan keluaran klasifikasi tunggal, dan nilai-nilai tersebut digabungkan untuk menciptakan hasil klasifikasi [15]. Untuk menghasilkan hasil klasifikasi, keluaran klasifikasi tunggal pohon keputusan ini dipilih, dan nilainya digabungkan [15].

3) *Support Vector Machine (SVM)*

SVM digunakan dalam klasifikasi berbasis kernel dan *non-linier*, di mana data masukan secara implisit dipetakan ke dalam ruang fitur berdimensi tinggi [10]. Untuk mengklasifikasikan data, SVM biasanya

membangun *hyperplane*, atau garis lurus yang membagi ruang menjadi dua zona homogen. Tugas kernel adalah untuk memetakan data ke ruang berdimensi tinggi adalah fungsi kernel. Oleh karena itu, titik data harus dapat dipisahkan secara linier. Hasilnya, model tersebut menghasilkan hasil yang lebih akurat [9].

4) *eXtreme Gradient Boosting (XGBoost)*

Boosting dan Bagging adalah dua kelas algoritma yang paling terkenal untuk klasifikasi kelompok dalam literatur [10]. Jumlah instance yang ditangani selama fase pelatihan adalah tempat munculnya perbedaan antara kumpulan kedua tipe algoritma yang bertipe sama. Boosting adalah algoritme pembelajaran ansambel yang, untuk setiap iterasi, memberikan bobot berbeda pada distribusi data pelatihan. Bobot sampel kesalahan yang diklasifikasikan secara salah meningkat dan bobot sampel yang diklasifikasikan dengan benar berkurang dengan setiap peningkatan iterasi. Akibatnya, mengubah distribusi data pelatihan dengan cara yang bermanfaat [24]. *Extreme Gradient Boosting* adalah proses menggunakan *Gradient Boosting Machine (GBM)* yang menggabungkan penurunan gradien dan peningkatan [24]. XGBoost merupakan metode yang dipilih untuk melakukan klasifikasi pada penelitian ini dengan menggunakan metode ensemble.

F. *Evaluasi Model*

Data latih diuji pada fase terakhir untuk menentukan tingkat akurasi yang dihasilkan dari setiap pelatihan eksperimen. Penelitian ini menggunakan *confusion matrix* untuk menghitung keakuratan analisis hasil akurasi. Istilah *True Positive*, *True Negative*, *False Positive*, dan *False Negative* dapat digunakan untuk menghitung akurasi, presisi, recall, dan skor F1. Dengan menggunakan rumusan yang diberikan dalam persamaan, keakuratan, sensitivitas, dan spesifisitas prediksi model klasifikasi ditentukan berdasarkan hasil *confusion matrix*. Penelitian ini hanya mengkaji akurasi dan skor f1. Tabel 5 menampilkan empat istilah yang, ketika kinerja dinilai menggunakan *confusion matri*, mewakili hasil dari proses klasifikasi.

III. HASIL UJI COBA


Penelitian ini mengevaluasi akurasi ekstraksi fitur menggunakan arsitektur CNN dan klasifikasi menggunakan metode machine learning. Berikut hasil penelitian ini dapat dilihat pada Tabel 6.

TABEL VI
HASIL KOMPARASI METODE KLASIFIKASI MACHINE LEARNING

Model	Akurasi (%)	F1 Score (%)	Waktu (Menit)
Resnet-50 + Decision Tree	59	59	4
ResNet-50 + RF	77	77	5
ResNet-50 + SVM	85	85	8
ResNet-50 + XGBoost	82	82	55
Inception V3 + Decision Tree	58	58	2
Inception V3 + RF	64	64	3
Inception V3 + SVM	64	64	5
Inception V3 + XGBoost	64	64	48
DenseNet-121 + Decision Tree	69	69	2
DenseNet-121 + RF	79	79	4
DenseNet-121 + SVM	81	81	5
DenseNet-121 + XGBoost	81	81	59

Berdasarkan Tabel 6, Arsitektur CNN yang digunakan sebagai ekstraksi fitur dan metode *machine learning* digunakan sebagai klasifikasi digabungkan, memperoleh hasil cukup baik di beberapa metode. Hasil yang memperoleh akurasi terbaik pertama yaitu model ResNet-50 dengan metode SVM menghasilkan nilai akurasi sebesar 85% dengan lama waktu proses adalah 8 menit. Dilanjutkan dengan hasil terbaik kedua yaitu model ResNet-50 dengan metode XGBoost dengan hasil akurasi adalah 82% lama proses adalah 55 menit. Dan nilai akurasi terbaik selanjutnya diperoleh dari model DenseNet-121 dengan metode SVM dan XGboost yaitu sebesar 81% dengan lama waktu 5 menit dan 59 menit. Dari ketiga hasil akurasi terbaik yang diperoleh, dapat diketahui bahwasanya arsitektur ResNet-50 dan DenseNet-121 cukup baik digunakan sebagai metode ekstraksi fitur. Dibandingkan dengan Inception-V3, hasil akurasi yang diperoleh diatas menginformasikan bahwa inception-v3 kurang cocok digunakan sebagai metode ekstraksi fitur pada penelitian ini. Selain itu, untuk metode *machine learning* yang digunakan sebagai klasifikasi, metode XGBoost merupakan metode yang memerlukan waktu cukup lama dalam proses pelatihan. Dapat dilihat pada Tabel 6, XGBoost memerlukan waktu 59 menit ketika proses pelatihan model DenseNet-121 dengan XGBoost. Dilanjutkan proses terlama kedua adalah model ResNet-50 dengan XGBoost dengan lama proses 55 menit. Kemudian model Inception-V3 dengan XGBoost dengan lama

waktu proses adalah 48 menit. Berikut representasi grafis perbandingan seluruh model dalam klasifikasi kerapatan vegetasi dapat dilihat pada Gambar 8.



Gambar 8. Hasil Klasifikasi Kerapatan Vegetasi Tutupan Lahan

IV. PEMBAHASAN

Hasil klasifikasi arsitektur CNN dengan hasil arsitektur CNN yang digunakan sebagai ekstraksi fitur menunjukkan bahwa CNN lebih tepat digunakan sebagai metode klasifikasi pada kasus penelitian ini. Hasil akurasi yang diperoleh ResNet-50 lebih unggul daripada arsitektur lain yaitu 91,04% dibandingkan saat ResNet-50 digunakan untuk ekstraksi fitur. Karena kesederhanaan ResNet-50 dalam mengolah data, lebih mudah menghasilkan nilai akurasi dibandingkan DenseNet-121. Berdasarkan hasil klasifikasi sebelumnya menggunakan arsitektur CNN, DenseNet-121 mengungguli ResNet-50 sebesar 91,67%. Namun jika digunakan sebagai ekstraksi fitur, membuktikan bahwa ResNet-50 lebih mampu meningkatkan akurasi dalam ekstraksi fitur dengan klasifikasi menggunakan metode machine learning. Selain itu, untuk penggunaan waktu, ResNet-50 jauh lebih cepat dibandingkan Inception V3 dan DenseNet-121. Hal ini dikarenakan struktur jaringan ResNet-50 lebih sederhana dibandingkan Inception V3 dan DenseNet-121 yang memiliki pembelajaran sangat mendalam dibandingkan ResNet-50. Kemudian, untuk penelitian kasus klasifikasi kerapatan vegetasi lahan gambut di Hutan Lindung LiangAnggang merekomendasikan penggunaan arsitektur ResNet-50 sebagai metode ekstraksi fitur dan DenseNet-121 sebagai metode klasifikasi khusus. Dibandingkan dengan penelitian Camile Sothe, penelitian ini memperoleh hasil yang tidak jauh berbeda dengan penelitian sebelumnya. Pada penelitian Camile Sothe, metode SVM dan RF memperoleh akurasi sebesar 84,37% [25]. Sedangkan pada penelitian ini menggunakan metode SVM dan RF dengan ekstraksi fitur ResNet-50 diperoleh hasil akurasi sebesar 85%. Untuk hasil perbandingan kombinasi arsitektur dan machine learning, hasil terbaik adalah ResNet-50 dengan kombinasi SVM sebesar 85% dengan pembagian dataset 80:20. Sedangkan ResNet-50 dengan kombinasi SVM dengan pembagian 70:30 memperoleh hasil akurasi sebesar 84%. Disusul kombinasi DenseNet 121 dengan metode SVM dan XGBoost sebesar 81% dengan pembagian dataset 70:30 dan 80:20. Arsitektur Inception-V3 pada penelitian ini kurang cocok dalam bidang klasifikasi maupun sebagai ekstraksi fitur. Dilihat dari hasil Inception-V3 yang mana hasilnya tidak melebihi dari 70% sebagai metode klasifikasi maupun metode ekstraksi fitur.

V. KESIMPULAN

Penelitian ini membahas serta menampilkan hasil manfaat penggunaan ekstraksi fitur yang diambil dari arsitektur CNN sebagai proses sebelum dilakukannya klasifikasi. Metode CNN yang terkenal dibidang klasifikasi dijadikan sebagai ekstraksi fitur dan kemudian dilakukan klasifikasi dengan membandingkan beberapa metode *machine learning*. Penelitian ini menggunakan dua arsitektur CNN yaitu ResNet-50 dan DenseNet-121 kemudian mengubah kedua arsitektur tersebut menjadi ekstraksi fitur. Metode pembelajaran mesin yang diusulkan sebagai metode klasifikasi pada penelitian ini adalah *Decision Tree*, *Random Forest*, *Support Vector Machine*, dan *XGBoost*. Dari hasil perbandingan pengujian antar metode *machine learning*, *Support Vector Machine* lebih unggul dibandingkan metode *machine learning* lainnya. Hal ini dibuktikan dengan hasil akurasi yang diperoleh sebesar 85% dengan

ekstraksi fitur menggunakan ResNet-50 yang mana lama waktu proses adalah 8 menit. Disusul model terbaik kedua yaitu ResNet-50 dengan XGBoost yang memperoleh hasil akurasi yang sebesar 82% dengan lama waktu proses adalah 55 menit. Sedangkan penggunaan ekstraksi fitur dengan metode DenseNet-121, didapatkan dengan kombinasi metode *Support Vector Machine* dan Metode XGBoost dengan hasil akurasi yang diperoleh adalah 81%. Keterbatasan model dari penelitian ini yaitu masih kurang optimal dari peningkatan akurasi, khususnya pada arsitektur Inception-v3. Selain itu, hipotesis dari peneliti masih kurangnya pengoptimalan dari proses pengolahan data. Arsitektur CNN yang dijadikan sebagai ekstraksi fitur belum sepenuhnya mampu dan baik dalam melakukan proses pengolahan dataset citra UAV dikarenakan dataset yang digunakan begitu kompleks dan memiliki resolusi gambar yang tinggi. Harapan kedepannya untuk penelitian ini dapat menerapkan metode tambahan dalam proses pengolahan dataset seperti penambahan metode khusus ekstraksi fitur yaitu metode GLCM, HSV dan metode ekstraksi fitur lainnya. Dan penelitian ini dapat dijadikan sebagai tolak ukur perbandingan untuk penelitian lainnya dengan kasus klasifikasi tutupan lahan berdasarkan kerapatan vegetasi dengan penggunaan dataset citra UAV.

DAFTAR PUSTAKA

- [1] M. Warren, K. Hergoualc'h, J. B. Kauffman, D. Murdiyarto, and R. Kolka, "An appraisal of Indonesia's immense peat carbon stock using national peatland maps: Uncertainties and potential losses from conversion," *Carbon Balance Manag.*, vol. 12, no. 1, 2017, doi: 10.1186/s13021-017-0080-2.
- [2] "Tropical and Subtropical Wetlands Distribution version 2 - CIFOR Knowledge," CIFOR. Accessed: Jun. 11, 2023. [Online]. Available: <https://www.cifor.org/knowledge/dataset/0058/>
- [3] G. Hope, U. Chokkalingam, and S. Anwar, "The stratigraphy and fire history of the Kutai Peatlands, Kalimantan, Indonesia," *Quat. Res.*, vol. 64, no. 3, pp. 407–417, 2005, doi: 10.1016/j.yqres.2005.08.009.
- [4] L. Tacconi, "Preventing fires and haze in Southeast Asia," *Nat. Clim. Chang.*, vol. 6, no. 7, pp. 640–643, 2016, doi: 10.1038/nclimate3008.
- [5] Z. Xu, K. Guan, N. Casler, B. Peng, and S. Wang, "A 3D convolutional neural network method for land cover classification using LiDAR and multi-temporal Landsat imagery," *ISPRS J. Photogramm. Remote Sens.*, vol. 144, pp. 423–434, 2018, doi: 10.1016/j.isprsjprs.2018.08.005.
- [6] Y. Sari, Y. F. Arifin, N. Novitasari, and M. R. Faisal, "Effect of Feature Engineering Technique for Determining Vegetation Density," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 7, pp. 655–661, 2022, doi: 10.14569/IJACSA.2022.0130776.
- [7] B. Bansod, R. Singh, R. Thakur, and G. Singhal, "A comparison between satellite based and drone based remote sensing technology to achieve sustainable development: A review," *J. Agric. Environ. Int. Dev.*, vol. 111, no. 2, pp. 383–407, 2017, doi: 10.12895/jaeid.20172.690.
- [8] Y. Heryadi and E. Miranda, *Land cover classification based on sentinel-2 satellite imagery using convolutional neural network model: A case study in Semarang Area, Indonesia*, vol. 830, no. January. Springer International Publishing, 2020. doi: 10.1007/978-3-030-14132-5_15.
- [9] M. Jogin, Mohana, M. S. Madhulika, G. D. Divya, R. K. Meghana, and S. Apoorva, "Feature extraction using convolution neural networks (CNN) and deep learning," *2018 3rd IEEE Int. Conf. Recent Trends Electron. Inf. Commun. Technol. RTEICT 2018 - Proc.*, pp. 2319–2323, 2018, doi: 10.1109/RTEICT42901.2018.9012507.
- [10] S. Benyahia, B. Meftah, and O. Lézoray, "Multi-features extraction based on deep learning for skin lesion classification," *Tissue Cell*, vol. 74, 2022, doi: 10.1016/j.tice.2021.101701.
- [11] G. W. Intyanto, "Klasifikasi Citra Bunga dengan Menggunakan Deep Learning: CNN (Convolution Neural Network)," *J. Arus Elektro Indones.*, vol. 7, no. 3, p. 80, 2021, doi: 10.19184/jaei.v7i3.28141.
- [12] K. E. E. Rani and S. Baulkani, "Construction of Deep Learning Model using RESNET 50 for Schizophrenia Prediction from rsfMRI Images," pp. 1–14, 2022.
- [13] J. Cao, M. Yan, Y. Jia, X. Tian, and Z. Zhang, "Application of a modified Inception-v3 model in the dynasty-based classification of ancient murals," *EURASIP J. Adv. Signal Process.*, vol. 2021, no. 1, 2021, doi: 10.1186/s13634-021-00740-8.
- [14] M. Sholik and C. Faticah, "Klasifikasi Sel Serviks Pada Citra Pap Smear berdasarkan Fitur Bentuk Deskriptor Regional dan Fitur Tekstur Uniform Rotated Local Binary Pattern," *JUTI J. Ilm. Teknol. Inf.*, vol. 15, no. 2, p. 214, 2017, doi: 10.12962/j24068535.v15i2.a669.
- [15] M. Hassaballah, Y. M. Wazery, I. E. Ibrahim, and A. Farag, "ECG Heartbeat Classification Using Machine Learning and Metaheuristic Optimization for Smart Healthcare Systems," *Bioengineering*, vol. 10, no. 4, pp. 1–16, 2023, doi: 10.3390/bioengineering10040429.
- [16] S. Supangat, M. Z. Bin Saringat, and M. Y. F. Rochman, "Predicting Handling Covid-19 Opinion using Naive Bayes and TF-IDF for Polarity Detection," *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 22, no. 2, pp. 173–184, 2023, doi: 10.30812/matrik.v22i2.2227.
- [17] A. N. A. Thohari, L. Triyono, I. Hestningsih, B. Suyanto, and A. Yobioktobera, "Performance Evaluation of Pre-Trained Convolutional Neural Network Model for Skin Disease Classification," *JUITA J. Inform.*, vol. 10, no. 1, p. 9, 2022, doi: 10.30595/juita.v10i1.12041.
- [18] Y. Xu, W. Yang, X. Wu, Y. Wang, and J. Zhang, "ResNet Model Automatically Extracts and Identifies FT-NIR Features for Geographical Traceability of Polygonatum kingianum," *Foods*, vol. 11, no. 22, 2022, doi: 10.3390/foods11223568.
- [19] Y. Sugianela and N. Suciati, "Ekstraksi Fitur Pada Pengenalan Karakter Aksara Jawa Berbasis Histogram of Oriented Gradient," *JUTI J. Ilm. Teknol. Inf.*, vol. 17, no. 1, p. 64, 2019, doi: 10.12962/j24068535.v17i1.a819.
- [20] M. Schramme and J. A. Macías, "Analysis and measurement of internal usability metrics through code annotations," *Softw. Qual. J.*, vol. 27, no. 4, pp. 1505–1530, 2019, doi: 10.1007/s11219-019-09455-4.
- [21] M. A. Al-Malla, A. Jafar, and N. Gheimeh, "Pre-trained CNNs as Feature-Extraction Modules for Image Captioning: An Experimental Study," *Electron. Lett. Comput. Vis. Image Anal.*, vol. 21, no. 1, pp. 1–16, 2022, doi: 10.5565/rev/elcvia.1436.
- [22] M. G. Alaslani and L. A. Elrefaie, "Convolutional Neural Network Based Feature Extraction for Iris," *Int. J. Comput. Sci. Inf. Technol.*, vol. 10, no. 2, pp. 65–78, 2018, doi: 10.5121/ijcsit.2018.10206.
- [23] F. Salim, F. Saeed, S. Basurra, and S. N. Qasem, "DenseNet-201 and Xception Pre-Trained Deep Learning Models for Fruit Recognition," *Electronics*, 2023.
- [24] I. Hanif, "Implementing Extreme Gradient Boosting (XGBoost) Classifier to Improve Customer Churn Prediction," 2020, doi: 10.4108/eai.2-8-2019.2290338.
- [25] C. Sothe *et al.*, "Evaluating a convolutional neural network for feature extraction and tree species classification using uav-hyperspectral images," *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. 5, no. 3, pp. 193–199, 2020, doi: 10.5194/isprs-Annals-V-3-2020-193-2020.