

Deep CNN for Wetland Mapping from Satellite Imagery

As'ary Ramadhan^{*1}, Rudy Herteno², Andi Farmadi³

^{1,2,3}Computer Science, Universitas Lambung Mangkurat, Indonesia

Email: ¹as'ary.ramadhan@ulm.ac.id

Received : Aug 18, 2025; Revised : Sep 5, 2025; Accepted : Sep 14, 2025; Published : Oct 23, 2025

Abstract

Wetland loss endangers the ecosystem through loss of biodiversity, carbon sequestration and flood regulation potential. A precise determination of wetlands status is necessary to safeguard for their conservation and ensure sustainable management. Implementation This study aims to assess the performance of deep CNNs in wetland detection using high-resolution Google Earth image data in South Kalimantan province, Indonesia. The work adopts the Chopped Picture Method (CPM) and the use of sliding windows for data augmentation to improve the diversity of the dataset and reduce the computational cost. Two CNN models, VGG-16Net, and LeNet-5, were trained using a dataset comprising 220 satellite images, which we converted into 89,100 patches of 56×56 pixels. Performance was compared using accuracy, precision, recall, and F1-score. Experimental results show good levels of accuracy for the two architectures, but LeNet-5 provided more stable results between test locations, having a F1-score closer to 100% and spending less computational time (≈10s per epoch) than VGG-16Net (≈40s per epoch). These results validate that CPM significantly increases the variety of training data, making it possible for a CNN to correctly identify the vague and irregular shapes of wetlands with high accuracy. In addition to advancing environmental conservation strategies, the study highlights the contribution of informatics to large-scale, automated environmental monitoring, particularly in supporting wetland conservation, sustainable land-use planning, and climate adaptation efforts.

Keywords : *Augmentation, CNN, Remote Sensing, Wetland.*

This work is an open access article and licensed under a Creative Commons Attribution-Non Commercial 4.0 International License



1. PENDAHULUAN

Lahan basah merupakan ekosistem yang memiliki peran dan fungsi penting dalam menjaga keseimbangan ekologis dan menyediakan berbagai jasa ekosistem yang krusial, seperti penyimpanan karbon, pengendalian banjir, dan habitat bagi keanekaragaman hayati [1]. Oleh karena itu keberadaannya memberikan manfaat signifikan bagi lingkungan dan masyarakat, baik pada skala lokal maupun global. Namun, ekosistem lahan basah terus mengalami tekanan akibat perubahan iklim dan aktivitas manusia. Antara tahun 1990 hingga 2015, sekitar 50% atau setara dengan 7,8 juta hektare lahan gambut di wilayah Semenanjung Malaysia, Sumatra, dan Kalimantan telah mengalami konversi menjadi kawasan perkebunan (seperti kelapa sawit, tanaman penghasil bubur kertas, dan karet), lahan pertanian, serta permukiman. Dari total lahan gambut yang tersisa seluas 4,6 juta hektare, hanya sekitar 1 juta hektare yang masih dapat dikategorikan sebagai ekosistem alami. Konversi ini tidak hanya mengganggu ekohidrologi lahan gambut yang memiliki hubungan erat dengan fungsi penyimpanan dan penyerapan karbon tetapi juga mengancam kelangsungan hidup taksa-taksa spesialis yang beradaptasi secara khusus di dalam ekosistem tersebut [2]. Oleh karena itu, identifikasi lahan basah menjadi langkah penting guna memahami, melindungi dan mengelolanya, yang akhirnya dapat memberikan manfaat besar bagi keberlanjutan lingkungan dan kehidupan manusia [3].

Teknologi penginderaan jauh telah menjadi alat penting dalam pemetaan dan pemantauan lahan basah untuk keperluan restorasi dan konservasi, termasuk klasifikasi tutupan lahan [4], deteksi perubahan [5], dan pemantauan muka air [6]. Pendekatan machine learning (ML) konvensional, seperti

Support Vector Machines (SVM) [7], Random Forests (RF) [8], dan K-Nearest Neighbors (K-NN) [9], telah digunakan secara luas untuk klasifikasi citra satelit [10]. Namun, metode ini memerlukan proses ekstraksi fitur secara manual yang memakan waktu dan sering kali kurang efektif untuk mengidentifikasi pola kompleks pada citra [11]. Sebagai contoh, beberapa penelitian menunjukkan bahwa SVM hanya mencapai akurasi 64–68% dalam pengklasifikasian lahan basah [12], sedangkan convolutional neural network (CNN) mampu memetakan wilayah lahan basah dengan akurasi lebih dari 90% pada resolusi tinggi ($\sim 1 \text{ m}^2$), tanpa memerlukan ekstraksi fitur manual [13]. Kesenjangan ini menegaskan keunggulan CNN dalam mempelajari representasi hierarkis secara langsung dari citra mentah.

Deep learning (DL), khususnya CNN telah menjadi solusi baru untuk pengenalan dan klasifikasi citra karena tidak memerlukan ekstraksi fitur secara manual [14]. DL melibatkan pembelajaran fitur dan klasifikasi secara simultan serta menggunakan data pelatihan untuk mengkategorikan konten citra tanpa spesifikasi awal fitur citra [14]. Jaringan DL adalah model struktur dalam yang terdiri dari beberapa pemetaan nonlinier, memiliki kemampuan ekspresi fungsi yang kuat, dapat mempelajari sampel pelatihan yang lebih kompleks, dan memiliki ketahanan yang baik dalam klasifikasi fitur kompleks pada citra penginderaan jauh [15]. Di antara semua jaringan berbasis DL, convolutional neural network (CNN) adalah yang paling populer [4] untuk mempelajari fitur visual dalam aplikasi visi komputer, termasuk penginderaan jauh [16].

Penelitian terbaru telah menunjukkan bahwa CNN mampu melakukan segmentasi gambar dengan baik berdasarkan kontennya [17]. Sebagai contoh, Wieman menggunakan DL untuk mengekstrak informasi dari peta historis [18] [19]. Selain mendeteksi dan mengklasifikasikan area yang lebih luas, CNN telah digunakan untuk mendeteksi objek yang sangat spesifik dalam citra penginderaan jauh dan dapat diterapkan dengan tingkat ketelitian yang cukup untuk memberikan informasi tentang berbagai spesies pohon [20]. Meskipun penerapan CNN telah digunakan dalam sejumlah penelitian penginderaan jauh untuk identifikasi berbagai jenis tutupan lahan menggunakan citra satelit [21], efisiensinya belum diuji untuk identifikasi area lahan basah seperti (rawa-rawa, hutan genangan, danau, sawah dan tanah gambut) dengan citra yang terdistribusi dengan sedikit sampel untuk pelatihan dan dalam bentuk yang tidak jelas dan tidak beraturan (ambiguous dan amorphous shapes).

Augmentasi data adalah metode untuk meningkatkan jumlah sampel pelatihan. Namun, metode ini tidak dapat meningkatkan sampel data secara signifikan [22]. Untuk mengatasi masalah tersebut menggunakan metode ekstraksi patches, yang secara signifikan dapat meningkatkan jumlah sampel ke tingkat yang memadai. Dalam studi terkini, Ise et al [23] mengembangkan metode CPM (chopped picture method) untuk mengklasifikasikan objek yang ambigu dan amorf secara lebih mudah. Metode ini membagi gambar menjadi kotak-kotak kecil dan secara efisien meningkatkan jumlah citra pelatihan. Penggunaan metode ini memungkinkan Ise et al [23] mengklasifikasikan tiga spesies lumut dan objek "non-lumut" dalam gambar uji dengan akurasi 95%. Namun, metode ini hanya telah diterapkan pada citra beresolusi tinggi, dan kelayakannya untuk gambar beresolusi rendah, seperti citra penginderaan jauh, belum diteliti.

Pada penelitian ini, kami melakukan investigasi terhadap efisiensi penerapan model deep learning dan CPM untuk mengekstrak patches. Sliding windows juga diterapkan dalam penelitian ini untuk mempermudah atau memperkecil komputasi yang dilakukan selama proses deteksi area lahan basah (rawa-rawa, hutan genangan, danau, sawah dan tanah gambut) berbasis komputer dari citra Google Earth. Kami menggunakan citra Google Earth di wilayah Kalimantan Selatan sebagai target untuk deteksi area lahan basah. Citra Google Earth memiliki keunggulan utama berupa ketersediaan citra resolusi tinggi secara gratis, dengan cakupan spasial dan temporal yang luas. Citra ini berasal dari gabungan penyedia satelit komersial seperti DigitalGlobe dan Airbus, menghasilkan visual tajam dengan resolusi < 1 meter di banyak lokasi [24]. Keunggulan ini menjadikannya efektif untuk mendeteksi fitur lahan kecil seperti

lahan basah. Weijia Li et al [25] melaporkan peningkatan akurasi klasifikasi lahan basah dengan citra google earth hingga 25%.

Pada penelitian ini, kami secara khusus mengkaji rumusan masalah penelitian berikut: (1) Bagaimana resolusi citra Google Earth mempengaruhi akurasi deteksi dengan Deep Convolutional Neural Networks; (2) Bagaimana hasil dari proses CPM untuk ekstraksi patches dan penggunaan sliding windows untuk memperkecil komputasi memengaruhi akurasi deteksi pada citra Google Earth dengan Deep Convolutional Neural Network; dan (3) apakah model dengan Deep Convolutional Neural Network yang dilatih untuk satu lokasi geografis dapat bekerja dengan baik di lokasi yang berbeda.

2. METODE


Pada penelitian ini, kami memilih 2 kabupaten/kota wilayah Kalimantan Selatan (Banjar dan Barito kuala), di Indonesia, sebagai target untuk analisis area lahan basah karena terdapat lahan basah yang signifikan [25] [26]. Kami menggunakan Google Earth sebagai sumber akuisisi citra. Terdapat Citra yang berbeda beda dari Google Earth mulai dengan rentang resolusi medium untuk citra Landsat sampai dengan resolusi tinggi citra satelit QuickBird. Di sini, kami menggunakan citra satelit resolusi tinggi QuickBird. Setiap lokasi penelitian dicitrakan dari citra Google Earth pada bulan April 2025 (Barito Kuala dan Hulu Sungai Utara) dan Agustus 2025 (Banjar). Gambar 1 menunjukkan target wilayah yang dianalisis dalam penelitian ini.



Gambar 1. Target wilayah yang dianalisis (Gambar dihasilkan menggunakan domain Content Delivery Network (CDN) resmi yang digunakan oleh Natural Eart)

2.1. Convolutional Neural Network

Penelitian ini kami menerapkan CNN, yang merupakan sebuah jenis khusus dari jaringan saraf feedforward yang terdiri atas beberapa lapisan konvolusi dan lapisan pooling. Gambar 2 menunjukkan skematik dari CNN yang digunakan dalam penelitian ini. Jaringan saraf feedforward adalah jenis jaringan saraf buatan di mana koneksi antar node (simpul) tidak membentuk suatu siklus. Artinya, aliran informasi hanya bergerak satu arah, dari lapisan input menuju lapisan output, tanpa adanya umpan balik ke lapisan sebelumnya. Jaringan ini, yang melakukan pemodelan serupa dengan aktivitas neuron di otak, umumnya disajikan sebagai sistem unit pemrosesan yang saling terhubung (neuron buatan) yang mampu menghitung nilai dari masukan, menghasilkan keluaran yang dapat digunakan pada unit-unit berikutnya



Gambar 2. Skematik dari CNN

Neuron buatan pada dasarnya adalah unit pemrosesan yang melakukan perhitungan terhadap beberapa variabel input dan biasanya menghasilkan satu output yang dihitung melalui fungsi aktivasi. Secara umum, sebuah neuron buatan memiliki bobot yang merepresentasikan tingkat kekuatan koneksi antar neuron buatan, beberapa variabel input x_i , serta sebuah vektor ambang batas (threshold) b . Secara matematis, total masukan dan keluaran dari neuron buatan dapat dijelaskan sebagai berikut:

$$u = \sum_i w_i x_i \quad (1)$$

$$z = f(u + b) = f(\sum_i w_i x_i + b) \quad (2)$$

Di mana u , z , x , w , dan b masing-masing merepresentasikan total masukan, keluaran, variabel input, bobot, dan bias. Fungsi $f(\cdot)$ menyatakan fungsi aktivasi, yaitu suatu fungsi nonlinier seperti sigmoid, hiperbolik (tanh), atau fungsi linear terpotong (rectified linear function). Dalam studi ini, kami menggunakan fungsi linear rectified sebagai fungsi aktivasi, yang dikenal dengan sebutan Rectified Linear Unit (ReLU). Fungsi ReLU dapat didefinisikan sebagai berikut:

$$f(u) = \max\{0, u\} = \begin{cases} u & (u > 0) \\ 0 & (u \leq 0) \end{cases} \quad (3)$$

CNN terdiri atas lapisan konvolusi dan lapisan pooling. Lapisan konvolusi berperan dalam menangkap fitur-fitur dari gambar. Dalam proses ini, sebuah filter berukuran tetap dijalankan melintasi gambar untuk mengekstraksi pola-pola gradasi warna yang terdapat dalam gambar. Setelah setiap lapisan konvolusi, terdapat lapisan pooling yang dirancang untuk mengurangi variasi dari fitur-fitur tersebut; hal ini dilakukan dengan menghitung operasi tertentu dari suatu fitur pada suatu wilayah (region) dalam gambar.

Lapisan pooling memiliki dua fungsi utama. Fungsi pertama adalah mengurangi sensitivitas posisi dari fitur yang diekstraksi oleh lapisan konvolusi, sehingga jumlah output dari lapisan pooling tetap tidak berubah meskipun posisi fitur yang diekstraksi oleh lapisan konvolusi bergeser di dalam gambar. Fungsi kedua adalah memperluas bidang reseptif (receptive field) untuk lapisan konvolusi berikutnya. Pada lapisan pooling, terdapat dua jenis operasi yang umum digunakan, yaitu max pooling dan average pooling. Dalam max pooling, nilai maksimum dari suatu wilayah fitur dipilih, sedangkan pada average pooling, nilai rata-rata yang diambil. Proses ini memungkinkan hasil yang konsisten meskipun terdapat translasi (pergeseran) atau rotasi kecil pada fitur gambar. Hal ini sangat penting dalam tugas klasifikasi dan deteksi objek. Dengan demikian, lapisan pooling bertanggung jawab untuk mengambil sampel

(sampling) dari output lapisan konvolusi, mempertahankan lokasi spasial gambar, serta memilih fitur-fitur yang paling berguna untuk diproses pada lapisan-lapisan berikutnya. Setelah beberapa lapisan konvolusi dan pooling, terdapat lapisan fully connected, yang menghubungkan semua neuron dari lapisan sebelumnya dengan setiap neuron yang ada di lapisan tersebut.

Setelah melewati semua lapisan konvolusi, pooling, dan fully connected (lapisan yang terhubung penuh), gambar akan diproses oleh lapisan klasifikasi. Di sinilah model mencoba menebak gambar itu termasuk dalam kelas apa (misalnya: swamps, flooded forests, floodplains, and peatlands). Untuk melakukan hal ini, kami menggunakan fungsi softmax pada lapisan klasifikasi. Fungsi softmax menghitung kemungkinan (probabilitas) dari setiap kelas target, berdasarkan semua kemungkinan kelas yang ada. Artinya, softmax memberi tahu kita seberapa besar kemungkinan gambar termasuk ke dalam masing-masing kelas. Fungsi softmax dihitung dengan rumus berikut:

$$y_k = \text{softmax}_k(u_1, u_2, \dots, u_k) = \frac{e^{u_k}}{\sum_{j=1}^k e^{u_j}} \quad (4)$$

di mana k merepresentasikan jumlah unit keluaran dan u merepresentasikan variabel input. Untuk menilai seberapa baik kinerja jaringan (neural network), kita perlu menentukan fungsi loss (loss function). Fungsi loss ini digunakan untuk mengukur seberapa akurat prediksi jaringan dibandingkan dengan data yang sebenarnya di dalam dataset pelatihan. Tujuan dari proses pelatihan adalah meminimalkan kesalahan yang dihitung oleh fungsi loss ini — artinya, membuat prediksi jaringan semakin mendekati data yang benar. Dalam kasus ini, digunakan fungsi cross-entropy yang bekerja bersama dengan fungsi softmax. Fungsi cross-entropy digunakan untuk menghitung seberapa besar perbedaan antara hasil prediksi dan label yang benar. Fungsi cross-entropy dari fungsi softmax didefinisikan sebagai berikut:

$$E = -\sum_{n=1}^N \sum_{k=1}^K t_{n,k} \log y_k \quad (5)$$

di mana t menyatakan vektor untuk data pelatihan, K merepresentasikan jumlah kelas yang mungkin, dan N merepresentasikan jumlah total data (instance).

2.2. Approach

Kami menggunakan jaringan LeNet-5 [27], yang merupakan model deep learning klasik, karena penelitian ini menggunakan citra berukuran kecil sebagai data pelatihan dan validasi. Jaringan ini terdiri atas dua lapisan konvolusi, dua lapisan pooling, dan satu lapisan terhubung penuh (fully connected layer). Arsitektur jaringan dijelaskan pada Tabel 1. Parameter model yang digunakan dalam penelitian ini meliputi jumlah epoch pelatihan (50), laju pembelajaran (learning rate) sebesar 0,01, ukuran batch pelatihan (64), dan ukuran batch validasi (32). Sesudah itu dataset pelatihan diekstrak ke dalam bentuk array dan dibandingkan hasilnya dengan data pengujian untuk melakukan perbandingan area yang terdapat lahan persawahannya. Kami membandingkan hasilnya dengan arsitektur CNN VGG-16Net.


Tabel 1. Jaringan arsitektur yang digunakan dalam penelitian ini

Layer name	Filter size	Number of output neuron
Convolutional 1	5 x 5	20
Pooling 1	2 x 2	
Convolutional 2	5 x 5	50
Pooling 2	2 x 2	
Fully connected 1		500
Fully connected 2		5

2.3. Data Pre-Processing

Area penelitian ditentukan melalui panel pencarian dan klik “OK”. Ketinggian disesuaikan dengan zoom in menggunakan kursor. Setelah area dipilih, citra dapat disimpan ke komputer dengan resolusi yang diinginkan melalui fitur Google Earth Pro. Dataset citra dikumpulkan dari dua wilayah menggunakan Google Earth Pro, diambil pada ketinggian 100 meter. Citra memiliki resolusi dimensi sebesar 1136x632 piksel dan memiliki format citra berupa “.jpg”, serta bit depthnya sebanyak 24 bit. Jumlah dataset yang dikumpulkan tidak dibatasi pada penelitian ini, akan tetapi penulis telah mengumpulkan dataset untuk pelatihan dan pengujian ini sebanyak 220 citra yang terdiri dari citra rawa-rawa, hutan genangan, danau, sawah dan tanah gambut.

Pemotongan citra pada dataset pelatihan dilakukan dengan CPM dalam ukuran 56x56 piksel, dengan demikian jumlah citra menjadi bertambah. Setelah CPM diterapkan, jumlah citra ada sebanyak 89.100 sebagai dataset pelatihan baru. Sebanyak 75% dari total tersebut digunakan sebagai dataset pelatihan, sedangkan sisanya sebesar 25% digunakan sebagai dataset validasi, dan untuk dataset pengujian sebanyak 20 citra untuk masing masing citra rawa-rawa, hutan genangan, danau, tanah gambut dan sawah secara bersesuaian. Gambar 3 menunjukkan skema yang digunakan dalam penelitian ini.



Gambar 3. Garis besar pendekatan yang diterapkan dalam penelitian ini. Gambar ini dihasilkan menggunakan data dari citra Google Earth

2.4. Evaluasi Performa Model

Evaluasi performa model dilakukan dengan menggolongkan hasil klasifikasi pada perbandingan class antara dataset pengujian aktual dengan hasil prediksi dari model kedalam empat kategori, yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Kemudian dari empat kategori tersebut digunakan sebagai parameter pengukuran kinerja dalam metode perhitungan akurasi atau sistem pendukung pengambilan keputusan yang disebut confusion matrix. Selanjutnya, dilakukan perhitungan nilai akurasi klasifikasi (classification accuracy), tingkat recall (recall rate), tingkat presisi (precision rate) dan F1-score menggunakan persamaan sebagai berikut:

$$\text{classification accuracy} = (TP + TN) / (TP + TN + FP + FN) \quad (6)$$

$$\text{Recall rate} = TP / (TP + FN) \quad (7)$$

$$\text{Precision rate} = TP / (TP + FP) \quad (8)$$


$$F1 - Score = \frac{2 * precision\ rate * recall\ rate}{precision\ rate + recall\ rate} \quad (9)$$

Pengujian pada penelitian ini dilakukan pada empat macam kondisi atau file yang berbeda, yaitu dataset pelatihan dan pengujian dengan ketinggian citra 100 meter menggunakan arsitektur LeNet-5, dataset pelatihan dan pengujian dengan ketinggian citra 100 meter menggunakan arsitektur VGG-16Net. Tujuannya untuk menguji dan membandingkan performa kedua arsitektur melakukan CNN, sehingga dapat diperoleh hasil yang terbaik dan melakukan pembelajaran terhadap gambar yang telah dipotong-potong dengan berhasil. Kemudian mengamati pengaruh kondisi dataset dari perbedaan faktor ketinggian terhadap tingkat akurasi keberhasilan dan mengidentifikasi lahan basah. Pada pengujian ini memiliki epoch dalam pemodelan sebanyak 25. Akurasi diperoleh ketika keakuratan suatu model dapat mengklasifikasi citra validasi dan loss menandakan ketidakakuratan atau kegagalan dalam memprediksi suatu model. Jika pemodelan berhasil, maka loss pada validasi mencapai nilai yang sangat kecil umumnya mendekati nilai 0 dan pada akurasinya mencapai nilai yang mendekati nilai 1, serta umumnya disebut sebagai kondisi goodfit. Namun ketika loss pada validasi menjadi tinggi dan terdapat variasi biasanya selama pembelajaran, maka diindikasikan terjadinya overfitting. Sebaliknya apabila loss pada validasi menjadi rendah dibandingkan dengan loss pada pelatihan, maka terjadi underfitting.

3. HASIL

3.1. Hasil pelatihan dan pengujian VGG-16NET dan LeNet-5 dengan CPM


Nilai akurasi pelatihan dan pengujian VGG-16NET pada epoch terakhir adalah 0.9907 dan 0.9839 dengan ketinggian citra 100 meter. Nilai kegagalan pelatihan pada epoch terakhir sebesar 0.0091 dan kegagalan validasi sebesar 0.0184 untuk ketinggian 100 meter. Hasil pelatihan dan pengujian LeNet-5 dengan ketinggian 100 meter sebesar 0.9975 dan 0.9517 masing masing untuk akurasi pelatihan dan akurasi validasi. Nilai kegagalan pada epoch terakhir pada kegagalan pelatihan sebesar 0.0031, sedangkan pada kegagalan validasi sebesar 0.6122 untuk ketinggian 100 meter. Kurva hasil pelatihan dan pengujian dapat dilihat pada Gambar 4



Gambar 4. Hasil pelatihan dan pengujian VGG-16NET

3.2. Hasil Akurasi Klasifikasi Lokasi Berbeda

Berdasarkan kelima evaluasi performa model terhadap ketinggian dan arsitektur CNN yang berbeda, diperoleh lima hasil perhitungan performa model dalam klasifikasi dan prediksinya. Kemudian, hasil tersebut dapat dibandingkan antar evaluasi. Akurasi pada kedua kabupaten tergolong sangat baik karena terdapat nilai mendekati 1 dan 1. Akurasi tertinggi terdapat pada kedua kabupaten yaitu barito kuala dan banjar, yakni mencapai 100%. Presisi pada kedua kabupaten tergolong sangat baik, baik untuk citra sawah, rawa-rawa, tanah gambut, hutan genangan dan danau, karena keduanya mendekati nilai 1. Presisi tertinggi ada pada citra hutan genangan, sawah, rawa rawa, tanah gambut pada kabupaten banjar dengan nilai 100%, sedangkan presisi tertinggi untuk citra hutang genangan, rawa rawa, danau dan tanah gambut yang terdapat pada kabupate barito kuala dengan nilai 100%. Sementara itu persentase recall rate untuk citra bukan danau mencapai 98% pada dua kabupaten. F1 -score pada kedua kabupaten tergolong sangat baik, baik untuk citra rawa rawa, sawah, hutan genangan, tanah gambut dan danau, karena mendekati nilai 1 atau persentase 100%. Grafik perbandingan kedua kabupaten pada ketinggian 100 Meter terhadap performa model dari kedua arsitektur ditunjukkan pada Gambar 6.



Gambar 6. Grafik Perbandingan Performa Model pada Tiga Pulau dengan Ketinggian 100 Meter untuk Dua Arsitektur

Hasil perbandingan menunjukkan bahwa arsitektur VGG-16Net mencapai akurasi sempurna (100%) pada kabupaten banjar, tetapi kinerjanya menurun di kabupaten barito kuala dengan presisi 98% dan recall 96%. Sementara itu, arsitektur LeNet-5 Modifikasi menunjukkan performa yang lebih stabil dengan akurasi keseluruhan 100%. Tabel 2 menunjukkann akurasi dan F1-Score pada masing masing arsitektur CNN.


Tabel 2. Akurasi dan F1-Score Arsitektur CNN

Arsitektur CNN	Accuracy (%)	F1-Score (%)
VGG-16Net	98.39	96.00
LeNet-5	95.17	98.00

Hasil ini mengindikasikan bahwa pada citra dengan ketinggian 100 meter, arsitektur LeNet-5 lebih konsisten dan andal dalam klasifikasi maupun prediksi dibandingkan VGG-16Net.

3.2.1. Identifikasi Citra Pengujian dalam Resolusi Piksel

Hasil akurasi piksel pada dataset pengujian dengan ketinggian 100 meter menggunakan arsitektur LeNet-5 Modifikasi menunjukkan bahwa citra uji memiliki dimensi 1116×632 piksel dengan total 637.084 piksel. Pada klasifikasi, citra dengan nilai level lebih dari 0,5 ditetapkan sebagai citra sawah, dan danau, sedangkan citra dengan nilai level kurang dari atau sama dengan 0,5 dikategorikan sebagai citra rawa rawa, sawah, dan danau. Berdasarkan model yang telah diperoleh, evaluasi terhadap dataset pengujian pada kedua kelas citra tersebut dapat dilihat pada Gambar 7.



Gambar 7. Hasil Identifikasi Lahan basah pada Ketinggian 100 Meter dengan LeNet-5

4. DISKUSI

Hasil evaluasi eksperimental dalam penelitian ini menunjukkan bahwa model berbasis CNN secara signifikan mendapatkan akurasi yang lebih baik dibandingkan dengan SVM dalam tugas klasifikasi lahan basah. Nilai F1-score, arsitektur CNN memperlihatkan performa yang lebih unggul, LeNet-5 mencapai hasil stabil mendekati 100% di berbagai lokasi uji, sementara VGG16Net memperoleh akurasi sempurna di Kabupaten Banjar tetapi menurun di Barito Kuala (presisi 98%, recall 96%). Sebagai perbandingan, penelitian sebelumnya menggunakan SVM pada citra multispektral hanya melaporkan F1-score lebih rendah (akurasi 64–68%) [12], yang mencerminkan keterbatasan ekstraksi fitur manual dalam menangani bentuk lahan basah yang kompleks dan amorf. Hasil evaluasi ini menegaskan bahwa CNN memiliki kemampuan menggeneralisasi dan pembelajaran fitur yang lebih baik dibandingkan dengan SVM.

Di antara varian arsitektur CNN, LeNet-5 dan VGG16Net menunjukkan perbedaan trade-off. Arsitektur VGG16Net dengan jaringan yang mendalam, memberikan daya representasi yang lebih tinggi tetapi memerlukan sumber daya komputasi yang lebih besar (≈ 40 detik per epoch). LeNet-5, meskipun

lebih sederhana, mampu mencapai kinerja yang sebanding bahkan lebih stabil dengan waktu pelatihan yang jauh lebih singkat (≈ 10 detik per epoch), sehingga lebih sesuai untuk diterapkan pada experiment dengan dataset yang kecil. Hasil ini sejalan dengan temuan sebelumnya [28] bahwa jaringan yang lebih sederhana dapat lebih unggul ketika citra masukan berupa potongan kecil (56×56 piksel). Oleh karena itu, dari segi efisiensi F1-score, LeNet-5 secara konsisten lebih unggul dibandingkan SVM maupun VGG16NET.

Selain metrik kinerja, dampak informatika dari adopsi CNN juga penting. Klasifikasi berbasis CNN memungkinkan dilakukannya pemetaan lingkungan secara skala besar dan otomatis, khususnya pada ekosistem lahan basah yang krusial untuk penyimpanan karbon, keanekaragaman hayati, dan regulasi banjir. Kemampuan CNN mendeteksi bentuk lahan basah yang ambigu dan tidak beraturan dengan presisi tinggi dapat mendukung pengambilan keputusan dalam konservasi ekologi, perencanaan tata guna lahan berkelanjutan, dan strategi adaptasi iklim.

Meskipun demikian, penelitian ini juga menunjukkan beberapa aspek yang perlu ditingkatkan. Bukti adanya potensi overfitting pada LeNet-5 mengindikasikan perlunya dataset yang lebih besar dan lebih beragam untuk meningkatkan kemampuan generalisasi model. Penelitian selanjutnya sebaiknya mengeksplorasi arsitektur hibrida, seperti CNN-RNN, yang dapat menangkap ketergantungan spasio-temporal dari citra sehingga memperkuat ketahanan pemantauan lingkungan. Selain itu, memperluas dataset dengan citra multi-temporal dan multi-regional akan semakin memperkuat penerapan metode berbasis CNN untuk pemetaan lahan basah skala luas.

5. KESIMPULAN

Hasil penelitian menunjukkan bahwa CNN, khususnya arsitektur LeNet-5 dengan CPM dan sliding windows, mampu mencapai akurasi tinggi dan stabil dalam klasifikasi lahan basah dari citra satelit dibandingkan dengan VGG-16Net yang lebih kompleks. LeNet-5 terbukti lebih efisien secara komputasi dan tetap konsisten pada berbagai lokasi uji dan ketinggian tangkapan citra dengan google earth pro. Hasil penelitian ini menerangkan bahwa CNN meningkatkan efektivitas pemetaan lahan basah, yang berkontribusi langsung pada bidang informatika lingkungan. Penerapan CNN memungkinkan pemetaan skala besar secara otomatis, mendukung konservasi ekosistem, pengelolaan lahan berkelanjutan, serta strategi adaptasi terhadap perubahan iklim. Namun, potensi overfitting pada LeNet-5 menunjukkan perlunya dataset yang lebih besar dan beragam. Untuk penelitian selanjutnya, disarankan penggunaan model hybrid dengan CNN-RNN atau CNN-Transformer serta dataset multi-temporal dan multi-regional. Hal ini akan memperkuat generalisasi model dan memperluas dampak penerapannya pada pemantauan lingkungan berbasis penginderaan jauh.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) Universitas Lambung Mangkurat yang telah memberikan dukungan dana penelitian pada tahun 2025 melalui kontrak nomor 1721/UN8/LT/2025.

REFERENSI

- [1] L. dkk Khairiyati, *Buku Ajar Pengantar Lingkungan Lahan Basah*. 2022.
- [2] K. A. Hapsari, T. Jennerjahn, S. H. Nugroho, E. Yulianto, and H. Behling, "Sea level rise and climate change acting as interactive stressors on development and dynamics of tropical peatlands in coastal Sumatra and South Borneo since the Last Glacial Maximum," *Glob. Chang. Biol.*, vol. 28, no. 10, pp. 3459–3479, May 2022, doi: <https://doi.org/10.1111/gcb.16131>.
- [3] L. K. Sharma and R. Naik, "Wetland Ecosystems BT - Conservation of Saline Wetland Ecosystems: An Initiative towards UN Decade of Ecological Restoration," L. K. Sharma and R. Naik, Eds., Singapore: Springer Nature Singapore, 2024, pp. 3–32. doi: 10.1007/978-981-97-

- 5069-6_1.
- [4] M. Mahdianpari, B. Salehi, F. Mohammadimanesh, and M. Motagh, "Random forest wetland classification using ALOS-2 L-band, RADARSAT-2 C-band, and TerraSAR-X imagery," *ISPRS J. Photogramm. Remote Sens.*, vol. 130, pp. 13–31, 2017, doi: <https://doi.org/10.1016/j.isprsjprs.2017.05.010>.
 - [5] B. Brisco, F. Ahern, K. Murnaghan, L. White, F. Canisus, and P. Lancaster, "Seasonal change in wetland coherence as an aid to wetland monitoring," *Remote Sens.*, vol. 9, no. 2, pp. 1–19, 2017, doi: 10.3390/rs9020158.
 - [6] S. Wdowinski, S.-W. Kim, F. Amelung, T. H. Dixon, F. Miralles-Wilhelm, and R. Sonenshein, "Space-based detection of wetlands' surface water level changes from L-band SAR interferometry," *Remote Sens. Environ.*, vol. 112, no. 3, pp. 681–696, 2008, doi: <https://doi.org/10.1016/j.rse.2007.06.008>.
 - [7] F. Hashim, H. Dibs, and H. S. Jaber, "Applying Support Vector Machine Algorithm on Multispectral Remotely sensed satellite image for Geospatial Analysis," *J. Phys. Conf. Ser.*, vol. 1963, no. 1, 2021, doi: 10.1088/1742-6596/1963/1/012110.
 - [8] S. Gxokwe, T. Dube, and D. Mazvimavi, "Leveraging Google Earth Engine platform to characterize and map small seasonal wetlands in the semi-arid environments of South Africa," *Sci. Total Environ.*, vol. 803, p. 150139, 2022, doi: 10.1016/j.scitotenv.2021.150139.
 - [9] R. B. Barito *et al.*, "Landsat Image Classification Based on K-Nearest Neighbor," in *2022 International Seminar on Application for Technology of Information and Communication (iSemantic)*, 2022, pp. 485–489. doi: 10.1109/iSemantic55962.2022.9920385.
 - [10] C. S. Cunha, L. A. Guasselli, T. F. Belloli, and C. C. Korb, "Classification of Potential Wetlands using the Random Forest in Google Earth Engine in Geomorphological Units - Rio Grande do Sul, Brazil," *Rev. Bras. Cartogr.*, vol. 75, pp. 1–22, 2023, doi: 10.14393/rbcv75n0a-69753.
 - [11] A. D. P. Pacheco, J. A. D. S. Junior, A. M. Ruiz-Armenteros, and R. F. F. Henriques, "Assessment of k-nearest neighbor and random forest classifiers for mapping forest fire areas in central portugal using landsat-8, sentinel-2, and terra imagery," *Remote Sens.*, vol. 13, no. 7, pp. 1–25, 2021, doi: 10.3390/rs13071345.
 - [12] C. Sothe *et al.*, "Comparative performance of convolutional neural network, weighted and conventional support vector machine and random forest for classifying tree species using hyperspectral and photogrammetric data," *GIScience Remote Sens.*, vol. 57, no. 3, pp. 369–394, Apr. 2020, doi: 10.1080/15481603.2020.1712102.
 - [13] K. Mainali, M. Evans, D. Saavedra, E. Mills, B. Madsen, and S. Minnemeyer, "Convolutional neural network for high-resolution wetland mapping with open data: Variable selection and the challenges of a generalizable model," *Sci. Total Environ.*, vol. 861, p. 160622, 2023, doi: <https://doi.org/10.1016/j.scitotenv.2022.160622>.
 - [14] N. Ståhl and L. Weimann, "Identifying wetland areas in historical maps using deep convolutional neural networks," *Ecol. Inform.*, vol. 68, no. September 2021, p. 101557, 2022, doi: 10.1016/j.ecoinf.2022.101557.
 - [15] X. M. Guan, D. Wang, L. Wan, and J. Zhang, "Extracting Wetland Type Information with a Deep Convolutional Neural Network," *Comput. Intell. Neurosci.*, vol. 2022, 2022, doi: 10.1155/2022/5303872.
 - [16] J. Song, S. Gao, Y. Zhu, and C. Ma, "A survey of remote sensing image classification based on CNNs," *Big Earth Data*, vol. 3, no. 3, pp. 232–254, 2019, doi: 10.1080/20964471.2019.1657720.
 - [17] S. Minaee, Y. Boykov, F. Porikli, A. Plaza, N. Kehtarnavaz, and D. Terzopoulos, "Image Segmentation Using Deep Learning: A Survey," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 44, no. 7, pp. 3523–3542, 2022, doi: 10.1109/TPAMI.2021.3059968.
 - [18] J. Weinman, Z. Chen, B. Gafford, N. Gifford, A. Lamsal, and L. Niehus-Staab, "Deep Neural Networks for Text Detection and Recognition in Historical Maps," in *2019 International Conference on Document Analysis and Recognition (ICDAR)*, 2019, pp. 902–909. doi: 10.1109/ICDAR.2019.00149.
 - [19] A. Le Bris, S. Giordano, and C. Mallet, "CNN Semantic Segmentation to Retrieve Past Land Cover out of Historical Orthoimages and Dsm: First Experiments," *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. 5, no. 2, pp. 1013–1019, 2020, doi: 10.5194/isprs-annals-V-2-

- 2020-1013-2020.
- [20] S. Branson, J. D. Wegner, D. Hall, N. Lang, K. Schindler, and P. Perona, "From Google Maps to a fine-grained catalog of street trees," *ISPRS J. Photogramm. Remote Sens.*, vol. 135, pp. 13–30, 2018, doi: <https://doi.org/10.1016/j.isprsjprs.2017.11.008>.
- [21] M. Mahdianpari, M. Rezaee, Y. Zhang, and B. Salehi, "Wetland classification using deep convolutional neural network," *Int. Geosci. Remote Sens. Symp.*, vol. 2018-July, no. November, pp. 9249–9252, 2018, doi: [10.1109/IGARSS.2018.8517919](https://doi.org/10.1109/IGARSS.2018.8517919).
- [22] E. Ahmadzadeh, K. Jaferzadeh, S. Shin, and I. Moon, "Automated single cardiomyocyte characterization by nucleus extraction from dynamic holographic images using a fully convolutional neural network," *Biomed. Opt. Express*, vol. 11, no. 3, p. 1501, 2020, doi: [10.1364/boe.385218](https://doi.org/10.1364/boe.385218).
- [23] T. Ise, M. Minagawa, and M. Onishi, "Classifying 3 Moss Species by Deep Learning, Using the 'Chopped Picture' Method," *Open J. Ecol.*, vol. 08, no. 03, pp. 166–173, 2018, doi: [10.4236/oje.2018.83011](https://doi.org/10.4236/oje.2018.83011).
- [24] D. Potere, "Horizontal positional accuracy of google earth's high-resolution imagery archive," *Sensors*, vol. 8, no. 12, pp. 7973–7981, 2008, doi: [10.3390/s8127973](https://doi.org/10.3390/s8127973).
- [25] W. Li, R. Dong, H. Fu, J. Wang, L. Yu, and P. Gong, "Integrating Google Earth imagery with Landsat data to improve 30-m resolution land cover mapping," *Remote Sens. Environ.*, vol. 237, no. November 2019, 2020, doi: [10.1016/j.rse.2019.111563](https://doi.org/10.1016/j.rse.2019.111563).
- [26] S. Rizal, "Pemanfaatan Lahan Basah bagi Masyarakat di Wilayah Kalimantan Selatan," Kompasiana. Accessed: Mar. 23, 2025. [Online]. Available: https://www.kompasiana.com/syamsulrizal4805/637459a508a8b55498451c02/pemanfaatan-lahan-basah-bagi-masyarakat-di-wilayah-kalimantan-selatan?page=2&page_images=1
- [27] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998, doi: [10.1109/5.726791](https://doi.org/10.1109/5.726791).
- [28] S. Watanabe, K. Sumi, and T. Ise, "Identifying the vegetation type in Google Earth images using a convolutional neural network: a case study for Japanese bamboo forests," *BMC Ecol.*, vol. 20, no. 1, pp. 1–14, 2020, doi: [10.1186/s12898-020-00331-5](https://doi.org/10.1186/s12898-020-00331-5).